

DOI: 10.13718/j.cnki.xdzk.2024.01.017

王海涛, 沈平, 高博. 基于 MTLBO 和 ELM 的沥青路面抗滑性能预测 [J]. 西南大学学报(自然科学版), 2024, 46(1): 196-208.

基于 MTLBO 和 ELM 的沥青路面抗滑性能预测

王海涛, 沈平, 高博

中交第二公路勘察设计研究院有限公司, 武汉 430056

摘要: 针对沥青路面抗滑性能预测在精度和可靠性方面的不足, 本文提出了基于改进教学优化算法(Modified Teaching-Learning-Based Optimization, MTLBO)和极限学习机(Extreme Learning Machine, ELM)的沥青路面抗滑性能预测模型. 首先, 利用 MMLS3 载荷模拟器对 6 块路面试样进行模拟加载, 达到每个加载周期后, 利用高精度激光扫描仪和摆式仪分别对路面试样的宏观纹理和抗滑性能表征指标摆值(British Pendulum Number, BPN)进行采集, 提取与抗滑性能相关的纹理指标. 其次, 鉴于 ELM 训练过程时间短且具有良好的模型泛化能力, 本文利用 ELM 预测沥青路面 BPN 的变化趋势. 为了提高 ELM 的全局搜索能力和预测结果的准确性, 引入 MTLBO 对 ELM 输入层和隐藏层之间的权重(ω_i)和偏置(b_i)进行优化, 从而更好地反映路面 BPN 与纹理指标之间的非线性映射关系. 最后, 以均方根误差(Root Mean Square Error, RMSE)和预测样本复相关系数(R^2)作为评价指标, 与现有的支持向量机(Support Vector Machines, SVM)、ELM、基于教学优化的极限学习机(TLBO-ELM) 3 种方法进行比较, 本文所提出的基于改进教学优化的极限学习机(MTLBO-ELM)预测结果的均方根误差分别降低了 1.80%, 1.50%, 1.07%.

关键词: 沥青路面; 路面模拟加载; 抗滑性能;

MTLBO-ELM 模型; 模型预测

中图分类号: TU997; U491.2⁺5

文献标志码: A

开放科学(资源服务)标识码(OSID):



文章编号: 1673-9868(2024)01-0196-13

Prediction of Skid Resistance of Asphalt Pavement Based on MTLBO and ELM

WANG Haitao, SHENG Ping, GAO Bo

CCCC Second Highway Consultants Co. Ltd., Wuhan 430056, China

Abstract: To address the shortcomings of asphalt pavement skid resistance prediction in terms of accuracy and reliability, this paper proposed an asphalt pavement skid resistance prediction model based on Modified Teaching and Learning Optimization (MTLBO) and Extreme Learning Machine (ELM). Firstly, the

收稿日期: 2022-11-14

基金项目: 湖北省交通运输厅科技项目(2020-186-1-6); 中交集团重大科技项目(2016-ZJKJ-11).

作者简介: 王海涛, 工程师, 主要从事道路与桥梁研究.

MMLS3 load simulator was used to simulate the loading of six pavement specimens. After each loading cycle was reached, the macroscopic texture and the British Pendulum Number (BPN) of the pavement specimens were collected using a high-precision laser scanner and a pendulum meter respectively, and then the texture indicators related to the skid resistance were extracted. Secondly, given the short training process of ELM and its good model generalization capability, this paper used ELM to predict the change trend of asphalt pavement BPN. In order to improve the global search capability of ELM and the accuracy of the prediction results, MTLBO was introduced to optimize the weights (ω_i) and biases (b_i) between the input and hidden layers of ELM. It was aimed to construct a non-linear mapping relationship between the pavement BPN and the texture index. Finally, root mean square error (RMSE) and predicted sample complex correlation coefficient (R^2) were used as evaluation indicators. Compared with existing Support Vector Machines (SVM), ELM and Extreme Learning Machines based on teaching and learning optimization (TLBO-ELM), the root mean square error of the prediction results of the proposed Extreme Learning Machine based on Modified Teaching Learning Optimization (MTLBO-ELM) is reduced by 1.80%, 1.50%, and 1.07% respectively.

Key words: asphalt pavement; pavement simulation loading; skid resistance; MTLBO-ELM; model prediction

随着我国经济的高速发展,国家在道路建设方面投入了大量资金,城市道路特别是高速公路的建设为 GDP 的不断增长做出了突出贡献。目前,我国公路网的总规模已经位居世界前列,公路总里程约为 450 万公里,其中高速公路网里程为 14.26 万公里,公路总长度居世界第一^[1-2]。

截至 2022 年 6 月,我国机动车保有量达 4.06 亿辆^[3]。在交通网络中,我国车流量密度较大且道路情况复杂,在驾车行驶过程中往往易出现突发情况。尤其是在城市快速道路和高速公路中,面对车速快和行驶过程中的突发情况,需要驾驶员更好地操控他们的车辆,这意味着路面需要给车辆提供较大的摩擦力。根据道路碰撞分析表明,路面摩擦系数每提高 0.1,雨天事故率可以降低 13%^[4]。

从车辆出行安全的角度来看,路面抗滑性能十分重要。沥青道路在长时间的服役中,路面的三维形貌会发生相应的变化,从而导致路面抗滑性能的改变,在道路路面的评估过程和道路后期养护中越来越受到社会的关注。为确保人们的出行安全,公路机构必须保证道路网络中路面能够保持足够的摩擦力水平,因此有必要对道路的三维形貌进行特征提取,并筛选出与路面抗滑性能相关的特征参数,对路面抗滑性能进行准确预测,进而对路面抗滑性能维护提出指导性建议。

目前,许多科研人员围绕沥青路面长期服役中路面三维形貌的变化导致抗滑性能的演变开展了大量的研究工作。Ding 等^[5]利用制备的不同颗粒高度路面样板,进行三维激光扫描并测量其抗滑数值,将采集到的路面三维形貌信息进行处理,获取其表面积,然后利用路面表面积去研究抗滑性能,以探究何种颗粒能提供最大抗滑性能。由于路面抗滑性能与路面多项特征参数相关,只考虑路面三维表面积指标较为单一。Kassem 等^[6]开发了路面摩擦损失的预测模型,该模型利用统计分析的手段建立起骨料形状特征、骨料耐磨和抛光性、骨料级配和抛光周期的参数与路面摩擦抗滑之间的多元线性模型,但线性模型评估多模态因素对路面摩擦力的预测可能会受到遗漏变量偏差的影响。战友等^[7]使用三维激光扫描技术对路面行车道轮迹带进行扫描,获取其 4 类表面三维纹理参数,利用随机森林回归模型将路面摩擦与纹理特征建立联系,由于随机森林模型不能超出训练数据范围外进行预测,这将导致在建模过程中出现过度拟合的现象。杨喜英等^[8]利用混凝土耐磨试验机开展露石混凝土路面的加速磨损实验,对混凝土路面的抗滑衰减曲线进行绘制,该实验仅仅探究了路面抗滑衰减的规律,并没有进一步开展抗滑性能预测的研究。刘亚敏等^[9]建立了基于遗传算法的 SMA 路面抗滑性能预测模型,由于初始值的设置对于优化模型的最终效果影响较大,若

选择不当,很容易使优化陷入局部收敛,所以该预测模型具有调参困难的缺点.

上述对于路面抗滑性能预测的研究都存在特征变量单一、可用数据少等问题,甚至有些研究直接利用统计分析建立线性模型.面对可用数据样本少的情况,现有的传统预测模型在模型稳定性、泛化能力和预测结果准确性方面都存在一定的不足.

极限学习机(ELM)能够通过调整输入层、隐藏层和输出层之间的相关参数,建立输入变量与输出变量之间的非线性映射关系,具有训练时间短、所需参数少、泛化能力强等优点^[10].改进教学优化算法(MTLBO)能够不断轮换“最优解”,使局部搜索能力得到提高^[11],通过引入该优化算法对 ELM 输入层和隐藏层间的权重和偏置进行优化,进而可以提高 ELM 预测结果的准确性.因此,本文通过室内模拟道路抗滑性能衰变实验,获取各项关键性能指标,并利用 MTLBO-ELM 模型对沥青路面抗滑性能随时间的衰退规律进行预测和评价.

1 理论描述

1.1 极限学习机(ELM)

传统的神经网络(Neural Network, NN)技术在速度和准确性方面存在一定的缺点,因此 Huang 等^[12]提出了名为极限学习机(ELM)的一种单层前馈网络.ELM 通常由 1 个输入层、1 个隐藏层和 1 个输出层组成,如图 1 所示.输入层和隐藏层之间的权重(ω_i)和偏置(b_i)是随机固定的,这种方法减少了计算时间,降低了复杂性,因此其学习速度要比其他传统前馈网络更快.隐藏神经元用不同的激活函数激活,通常使用高斯激活函数.




图 1 极限学习机的结构

ELM 输入层、隐藏层和输出层的节点数分别为 n 、 L 、 m ,有 N 个不同的样本 (x_i, t_i) ,其中输入 $x_i = [x_{i1}, x_{i2}, \cdots, x_{in}]^T \in \mathbb{R}^n$,期望的输出 $t_i = [t_{i1}, t_{i2}, \cdots, t_{im}]^T \in \mathbb{R}^m$, $h(x)$ 为激活函数并在式(1)中描述.

$$\sum_{i=1}^L \beta_i h_i(x_j) = \sum_{i=1}^L \beta_i h_i(\omega_i x_j + b_i) = Y_j$$

(1)

式中: $\beta_i = [\beta_{i1}, \beta_{i2}, \cdots, \beta_{im}]^T$ 为第 i 个隐藏节点到输出节点之间的输出权重矩阵; Y_j 为 ELM 的输出.式(1)可以由式(2)简单表达.

$$H\beta = T$$

(2)

式中: T 为目标输出矩阵; H 为隐藏层的输出矩阵,如式(3)所示.

$$H(\omega, b, x) = \begin{bmatrix} h_1(\omega_1 x_1 + b_1) & \cdots & h_L(\omega_L x_1 + b_L) \\ h_1(\omega_1 x_2 + b_1) & \cdots & h_L(\omega_L x_2 + b_L) \\ \vdots & & \vdots \\ h_1(\omega_1 x_N + b_1) & \cdots & h_L(\omega_L x_N + b_L) \end{bmatrix}$$

(3)

输出权重矩阵可以用式(4)表示:

$$\beta = H^+ T \quad (4)$$

式中: H^+ 为矩阵 H 的 Moore-Penrose 广义逆矩阵.

β 是对预测准确性影响最大的因素, 完全取决于 ω_i 和 b_i . 根据样本的数据特征, 通过优化算法决定 ω_i 和 b_i 而不是随机选择, 可以提高 ELM 的效率. 在本文中与路面抗滑性能相关性最大的 6 个宏观纹理参数被视为输入, 路面抗滑性能指标 BPN 被视为 ELM 预测的目标.

1.2 教学优化算法 (TLBO)

教学优化算法 (Teaching-Learning-Based Optimization, TLBO) 是由 Rao 等^[13] 基于课堂活动而提出的新型智能算法, 其原理是教师对学习者的影响效应. 像其他基于群体的优化技术一样, 教师被认为是到目前为止获得的最佳解决方案^[14]. 这一算法主要分为 2 部分: 教阶段, 即向老师学习; 学习阶段, 即通过学习者之间的互动来学习.

1.2.1 教阶段

在班级中, 一个知识渊博的人被指派为班级的教师, 他可以根据自身的知识来提高全班的平均成绩. 班级的学生被召集以产生初始班级, $\mathbf{X}_i = [x_{i,1}, x_{i,2}, \dots, x_{i,D}, \dots, x_{i,N_p}]$, $i=1, 2, \dots, N_p$, $\mathbf{X}_i$ 为第 i 个个体, D 为优化问题的维度, N_p 为种群规模. 在教学过程中, $\mathbf{Avg}_i$ 是学习者在单一科目中的平均成绩. 在班级中成绩较好的学生被选为最有知识能力的人 ($\mathbf{X}_T$), 他推动了所有学生的平均成绩. t 是当前的迭代次数, $\mathbf{X}_T^t$ 为 t 次迭代下的教师, $\mathbf{X}_T^t$ 试图将平均值 $\mathbf{Avg}_i$ 移向自己的水平, 即学生们在教师的帮助下更新他们的成绩, 以提高平均成绩, 如式 (5) 所示.

$$\mathbf{X}_i^t = \mathbf{X}_i^{t-1} + rand \times (\mathbf{X}_T^t - T_f \times \mathbf{Avg}_i) \quad (5)$$

式中: $rand$ 为 $[0, 1]$ 上的随机数; T_f 为教学因子, 决定要改变的平均值, T_f 的取值为 1 或 2. 这是一个启发式的步骤, 以相等的概率随机决定, 如式 (6) 所示.

$$T_f = round(2 \times rand) \quad (6)$$

式中: $round$ 代表四舍五入取整.

1.2.2 学习阶段

在学习阶段, 学习者可以在其他学生的帮助下提高自己的知识水平, 以提高平均成绩. 如果共同学习者与自己相比知识更丰富, 学习者就可以扩大自己的知识^[15]. 学生之间改变立场的互动在式 (7) 中描述.

$$\mathbf{X}_i^t = \begin{cases} \mathbf{X}_i^{t-1} + rand \times (\mathbf{X}_i^{t-1} - \mathbf{X}_j^{t-1}) & f(\mathbf{X}_i^{t-1}) < f(\mathbf{X}_j^{t-1}) \\ \mathbf{X}_i^{t-1} + rand \times (\mathbf{X}_j^{t-1} - \mathbf{X}_i^{t-1}) & f(\mathbf{X}_i^{t-1}) > f(\mathbf{X}_j^{t-1}) \end{cases} \quad (7)$$

1.3 改进的教学优化算法 (MTLBO)

在 TLBO 算法中, 提高整个班级在教阶段的表现, 教师是一个重要的影响因素. 为了提高 TLBO 算法的探索能力, 对 TLBO 的教阶段进行修改. 在这项工作中, 班级被分成不同的部分. 学生按照他们的函数值被缩短, 成绩最高的学生 (较好的函数值) 被分配为某一区的教师. 在每个部分, 学生被随机分配. 学生们通过让出相应的教师 $\mathbf{X}_{T,sec}^t$ 来更新他们的位置, 如式 (8) 所示.

$$\mathbf{X}_i^t = \mathbf{X}_i^{t-1} + rand \times (\mathbf{X}_{T,sec}^{t-1} - T_f \times \mathbf{Avg}_{i,sec}) \quad (8)$$

式中: $\mathbf{Avg}_{i,sec}$ 是一个特定部分学生的平均成绩.

通过这种方法, 该算法的局部搜索能力得到了加强, 这有助于增加解决方案的多样性. 在 TLBO 算法中, 所有的学生都朝一个方向 (朝向教师) 迁移, 这可能会误导整个班级, 这个问题可以通过分配部分教师来解决^[11].

在 TLBO 算法的学习阶段, 学生们通过相互交流不断地修正教师的位置, 式 (7) 通过纳入教师的优势而被修改为式 (9).

$$\mathbf{X}_i^t = \begin{cases} \mathbf{X}_i^{t-1} + rand \times (\mathbf{X}_i^{t-1} - \mathbf{X}_j^{t-1}) + rand \times (\mathbf{X}_T^{t-1} - \mathbf{X}_i^{t-1}) & f(\mathbf{X}_i^{t-1}) < f(\mathbf{X}_j^{t-1}) \\ \mathbf{X}_i^{t-1} + rand \times (\mathbf{X}_j^{t-1} - \mathbf{X}_i^{t-1}) + rand \times (\mathbf{X}_T^{t-1} - \mathbf{X}_i^{t-1}) & f(\mathbf{X}_i^{t-1}) > f(\mathbf{X}_j^{t-1}) \end{cases} \quad (9)$$

在每次迭代中，一些呆板的学生会被其他一些学生淘汰(随机初始化学生). 学生的淘汰在式(10) 和 (11) 中描述. 图 2 为 MTLBO 算法的流程图.

$$N = find(f(\mathbf{X}_T) + o') < f(\mathbf{X}_i) \quad (10)$$

$$\mathbf{X}_i(N) = LB + rand \times (UB - LB) \quad (11)$$

式中: N 为要淘汰的学生人数; $\mathbf{X}_i(N)$ 是要考虑的新学生; LB 和 UB 是下边界和上边界; o' 是一个常数, 与迭代的次数成比例衰减.




图 2 MTLBO 算法流程图

2 基于 MTLBO 和 ELM 的路面抗滑性能预测模型

ELM 通常是分类和回归的首选, 其性能比 NN 更好. ELM 的性能可以通过适当地调整相关的输入权

重、偏置和隐藏神经元的数量来提高. 因此, 本文通过 MTLBO 算法适当决定 ELM 的相关输入权重和偏置来最小化预测误差.

MTLBO-ELM 预测模型中优化算法只在训练 ELM 模型时使用. ELM 的相关参数是在训练模型期间由 MTLBO 优化算法决定, 使得预测误差最小. MTLBO 的首要目标是通过适当选择 ELM 的输入层权重和偏置实现训练误差最小化, 具有这些参数的 ELM 模型被用于测试数据集.




图 3 MTLBO-ELM 预测流程示意图

本文利用 MTLBO 方法优化 ELM 模型参数的流程如图 3 所示, 选取路面试样随时间变化的宏观纹理表征指标平均断面深度 M_{pd} 、断面算数平均值 R_a 、断面标准差 R_q 、极差 R_z 、驼峰度 R_{ku} 、偏斜度 R_{sk} 作为 MTLBO-ELM 的输入, 抗滑性能 BPN 作为 MTLBO-ELM 的输出, 即预测量. 在模型训练过程中将 ELM 预测的 BPN 与真实值之差输入到 MTLBO 的优化算法中, 从而实现动态调整 ELM 输入层与隐藏层之间的权重和偏差, 通过 MTLBO 优化算法获得的参数能够有效提高 ELM 预测的泛化性和准确性.

3 数值模拟分析

为验证本文所提出模型的有效性, 首先选取某道路交通流量数据进行车流量预测. 本文一共采集了 1 年内的交通流量数据, 每隔 5 min 记录 1 次该时间段内的车流量数据. 本文截取 5 d 的车流量数据, 利用前 4 d 的车流量数据训练 MTLBO-ELM 模型, 最后用训练好的 MTLBO-ELM 模型去预测第 5 d 的车流量. 同时利用相同的数据集通过 SVM、ELM 和 TLBO-ELM 进行训练, 并预测第 5 d 的车流量.

表 1 不同预测模型对交通流量数据的精度比较

	SVM	ELM	TLBO-ELM	MTLBO-ELM
RMSE	3.498 1	2.917 4	1.074 5	0.583 7
R^2	0.142 5	0.492 8	0.873 1	0.935 9

图 4 为 MTLBO-ELM 模型训练过程和预测结果, 表 1 给出不同预测模型对交通流量数据的精度比较. 表 1 中 MTLBO-ELM 模型的 RMSE 为 0.583 7, R^2 为 0.935 9, 在对比模型中其评价指标最好, 由此可见 MTLBO-ELM 模型的泛化能力较强. 因此, 通过交通流量数据集预测结果, 证明了 MTLBO-ELM 模型的有效性, 为接下来的道路表面抗滑性能预测奠定了基础.




图 4 MTLBO-ELM 模型训练过程和预测结果

4 道路抗滑性能衰变模拟实验

沥青路面在经过车辆的反复碾压之后，沥青表面的沥青膜剥落，路面骨料裸露出来，路面的抗滑性能到达峰值；继续经过车辆的反复碾压，骨料被抛光，路面抗滑性能出现一定的衰退。为研究这一衰变过程的规律，在实体道路上长期监测路面的抗滑性能有诸多限制，因此本文通过加速加载器在实验室内模拟路面抗滑性能衰变的过程。

4.1 加速加载器

为了能模拟出在车辆反复碾压下真实路面抗滑性能的变化，本实验采用了 MMLS3 载荷模拟器，图 5 为其实物图。该设备可以在 7 200 次轮载/小时、2.7 kN 的最大轮载下进行实验。将试样放入该设备中，到达相应轮载荷次数后，将试样取出，完成各项指标的记录，将试样放回并进行下个阶段的载荷实验^[16]。

4.2 模拟实验

根据某道路的沥青比比制作了 6 个路面试样，其中一试样如图 6 所示。加速加载器的加载参数设置为 5 200 次轮载/小时，小轮与路面试样间的压力为标准轴载 0.7 MPa。按照表 2 所示的记录周期对试样进行监测。为了能够真实还原路面的使用情况，在各个加载周期内按照实际道路的养护标准进行洒水养护，

从而能够真实地体现出路面抗滑性能的衰变过程^[17].



图 5 MMLS3 载荷模拟器




图 6 路面试样

4.3 模拟实验结果


将路面样本在不同轮载荷次数下的表面变化直观记录下来, 如图 7 所示. 在图 7 中可以明显地观察到路面试块的颜色和抛光度发生了明显的变化.

表 2 监测记录


周期	1	2	3	4	5	6	7	8	9	10
累计轮载/万次	0	18.31	36.70	55.17	73.71	92.33	111.03	148.64	205.64	235.60




a. 0次



b. 55.1万次



c. 111万次



d. 235.6万次

图 7 不同轮载次数下的试样

5 沥青路面表征指标

5.1 沥青路面纹理表征指标

沥青路面纹理可以用多种指标来进行表征, 主要指标如表 3 所示. 本文只利用与路面抗滑性能相关性最大的纹理指标构建预测模型.

5.2 路面抗滑性能指标

沥青路面主要有 BPN 和横向力系数(Sideway Force Coefficien, SFC)两项抗滑指标来表征路面抗滑性能^[18], 本文所要预测的抗滑指标 BPN 由摆式仪测得, 摆锤的回摆高度可直接从仪器上读出, 即摆值的大小. 我国规定高速公路、一级公路的 BPN 一般大于 45^[19].

5.3 路面指标筛选

对表 3 中的各项路面纹理指标与 BPN 进行相关性分析, 筛选出如下路面纹理指标用来对 BPN 进行多元预测.

表 3 特征指标

统计特征指标	断面算数平均值 R_a
	断面标准差 R_q
	极差 R_z
	偏斜度 R_{sk}
	驼峰度 R_{ku}
横向宏观纹理指标	平均波长 L_a
	波长的均方根 L_q
几何特征指标	平均斜率 S
	平均曲率 C
平均断面深度	M_{pd}

(1) 平均断面深度 M_{pd}

$$M_{pd} = \frac{peak(1st) + peak(2nd)}{2} - Average$$

(12)

根据 ISO13743-1 规定在计算 M_{pd} 时断面的水平长度需要超过 100 mm，将断面分为 2 部分，式中 $peak(1st)$ 为第 1 部分的峰值； $peak(2nd)$ 为第 2 部分的峰值； $Average$ 为整个断面的平均高度。

(2) 断面算数平均值 R_a

$$R_a = \frac{1}{n} \sum_{i=1}^n |Z_i - \bar{Z}|$$

(13)

(3) 断面标准差 R_q

$$R_q = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2}$$

(14)

(4) 极差 R_z

$$R_z = \max(Z) - \min(Z)$$

(15)

(5) 驼峰度 R_{ku}

$$R_{ku} = \frac{1}{\sigma^4 n} \sum_{i=1}^n (Z_i - \bar{Z})^4$$

(16)

(6) 偏斜度 R_{sk}

$$R_{sk} = \frac{1}{\sigma^3 n} \sum_{i=1}^n (Z_i - \bar{Z})^3$$

(17)

式中： n 为断面轮廓采样点数； Z_i 为第 i 个测量点的高度； $\bar{Z}$ 为 n 个测量点的平均高度； σ 是 Z 的标准差。

6 实验结果分析

为了进一步表明图 7 的微观变化，将其中某一试样的各项相关性指标的变化曲线表示出来，如图 8 所示。从图 8 的曲线中可以明显地观察到路面随着轮载次数的增加，其纹理特征值和 BPN 也会发生明显的变化。

选取实验当中路面试样随时间变化的宏观纹理表征指标平均断面深度 M_{pd} 、断面算数平均值 R_a 、断面标准差 R_q 、极差 R_z 、驼峰度 R_{ku} 、偏斜度 R_{sk} 作为 MTLBO-ELM 的输入，抗滑性能 BPN 作为 MTLBO-ELM 的输出，即预测量。用前 5 组路面试样的监测数据作为模型的训练，最后一组路面试样的监测数据作为测试，即训练样本数为 50，预测样本数为 10。




图 8 各项指标变化曲线

本文使用了 3 种常用的预测方法进行比较,即支持向量机 SVM,极限学习机 ELM,基于教学优化的极限学习机 TLBO-ELM. 图 9 为 3 种常用预测模型的预测结果. 图 10 为本文所提出的 MTLBO-ELM 模型的预测结果.

为了定量评价本文提出方法与其他常用模型对多因素影响下沥青路面抗滑性能预测结果的好坏,本文用均方根误差(RMSE)和预测样本复相关系数(R^2)作为定量分析的指标. 表 4 为各预测模型的预测结果精度比较.

由表 4 可知,ELM 模型在路面抗滑性能预测上比 SVM 有更出色的表现,进一步通过优化算法探索 ELM 的相关参数,TLBO-ELM 的性能得到了提高. 本文所提出的 MTLBO-ELM 模型的 RMSE 为 0.5032, R^2 为 0.95. 从评价指标的角度,本文提出的 MTLBO-ELM 预测模型在路面抗滑性能预测方面具有更好的性能.




图 9 3 种常用不同模型预测的结果

表 4 不同模型预测结果的精度比较

	SVM	ELM	TLBO-ELM	MTLBO-ELM
RMSE	2.312 3	1.996 5	1.581 1	0.503 2
R^2	0.173 8	0.589 2	0.811 5	0.95




图 10 本文提出 MTLBO-ELM 模型的训练和预测结果

7 结论

- 1) 采用 MMLS3 加速加载实验装置模拟了 6 个沥青路面试样在车辆载荷作用下微观纹理、抗滑性能 BPN、外貌形状和颜色的变化规律. 实验结果表明, 沥青路面在建设完成投入使用的前期, 因车轮的反复碾压, 表面的沥青剥落, 骨料裸露, 导致抗滑性能增加; 随着碾压次数的加大, 表面骨料被抛光, 抗滑性能出现一定的下降;
- 2) 利用沥青路面的宏观纹理指标平均断面深度 M_{pd} 、断面算数平均值 R_a 、断面标准差 R_q 、极差 R_z 、驼峰度 R_{ku} 和偏斜度 R_{sk} 去预测路面抗滑性能指标 BPN, 具有可行性;
- 3) 通过对基本 TLBO 算法中的教阶段和学习阶段进行改进, 进一步提高了 TLBO 算法的局部搜索能力. 利用改进的 TLBO 算法优化 ELM 预测模型的相关参数, 固定具体参数后的 ELM 在路面抗滑性能预测方面性能出色. 该模型对沥青路面抗滑性能的评价具有一定的指导意义.

参考文献:

[1] 梁科科, 常馨玉, 任天逸, 等. 我国公路网规模及发展水平研究 [J]. 交通运输研究, 2021, 7(4): 51-57.

[2] 刘晨阳, 冯继豪, 张永祥, 等. 超载运输车辆对沥青路面的破坏及制动距离的影响 [J]. 河南农业大学学报, 2016, 50(4): 490-493, 505.

[3] 姚洁, 邱劲. 基于 SSA-BP 算法的道路交通流量预测研究 [J]. 西南大学学报(自然科学版), 2022, 44(10): 193-201.

[4] 王维锋. 路面抗滑性能影响弯道行车安全的仿真分析 [J]. 交通信息与安全, 2017, 35(6): 32-37.

[5] DING S H, WANG K C P, YANG E H, et al. Influence of Effective Texture Depth on Pavement Friction Based on 3D Texture Area [J]. Construction and Building Materials, 2021, 287: 123002.

[6] KASSEM E, AWED A, MASAD E A, et al. Development of Predictive Model for Skid Loss of Asphalt Pavements [J]. Transportation Research Record: Journal of the Transportation Research Board, 2013, 2372(1): 83-96.

[7] 战友, 李强, 马啸天, 等. 基于宏微观纹理特征融合的路面摩擦性能预测 [J]. 浙江大学学报(工学版), 2021, 55(4): 684-694.

[8] 杨喜英, 刘伟, 祝海折. 露石水泥混凝土路面抗滑衰减规律研究 [J]. 公路工程, 2015, 40(4): 225-228.

[9] 刘亚敏, 韩森, 徐鸥明. 基于遗传算法的 SMA 路面抗滑性能预测模型 [J]. 应用基础与工程科学学报, 2013, 21(5): 890-898.

[10] 王飞雪, 戴蓉. 基于投票 ELM 和黑洞优化的云计算 DDoS 攻击检测 [J]. 西南大学学报(自然科学版), 2022, 44(8): 205-215.

[11] SAHU R K, SHAW B, NAYAK J R. Short/Medium Term Solar Power Forecasting of Chhattisgarh State of India Using Modified TLBO Optimized ELM [J]. Engineering Science and Technology, an International Journal, 2021, 24(5): 1180-1200.

[12] HUANG G B, CHEN L, SIEW C K. Universal Approximation Using Incremental Constructive Feedforward Networks with Random Hidden Nodes [J]. IEEE Transactions on Neural Networks, 2006, 17(4): 879-892.

[13] RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-Learning-Based Optimization: A Novel Method for Constrained Mechanical Design Optimization Problems [J]. Computer-Aided Design, 2011, 43(3): 303-315.

[14] 童楠, 符强, 钟才明. 基于自主学习行为的教与学优化算法 [J]. 计算机应用, 2018, 38(2): 443-447, 470.

[15] 何杰光, 彭志平, 崔得龙, 等. 一种多反向学习的教与学优化算法 [J]. 工程科学与技术, 2019, 51(6): 159-167.

[16] 杨跃琴. 沥青路面宏观纹理的精确表征及抗滑性能衰减规律研究 [D]. 北京: 北京建筑大学, 2021.

[17] 杨建国, 谢永利, 张晓, 等. 高速公路隧道路面抗滑可靠性分析 [J]. 西南大学学报(自然科学版), 2009, 31(11): 145-149.

[18] 吴国雄, 高超, 肖彬. 沥青路面整体模量对路面抗滑性能影响研究 [J]. 重庆交通大学学报(自然科学版), 2017, 36(2): 32-37.

[19] 李智, 田力, 陈思宇. 花岗岩沥青路面抗滑层抗滑性能及耐久性试验研究 [J]. 科学技术与工程, 2014, 14(18): 295-300.

责任编辑 汤振金
柳剑