

基于LSTM神经网络的沥青路面抗滑性能预测

王红辉

(湖南大学设计研究院有限公司, 湖南 长沙 410006)

摘要: 为实现高速公路沥青路面抗滑性能衰减规律的研究和预测,收集了四川川南某高速公路2016—2021年路面抗滑性能指数SRI和交通量数据,分析了交通荷载与路龄对沥青路面抗滑性能影响;建立了RNN神经网络模型和LSTM神经网络模型,以历年的SRI值、累计轴载、路龄作为输入,最后1a的SRI值作为输出,实现对高速公路SMA路面抗滑性能指数的预测,并用平均绝对百分比误差MAPE和均方根误差RMSE来对RNN神经网络和LSTM神经网络的预测精度进行评估。结果表明:LSTM神经网络训练集和测试集的平均MAPE值和平均RMSE值分别为0.296 7、0.349 9和3.914 3、3.621 6,相比于RNN神经网络,分别减少了1.002 8、1.021 4和0.441、0.201 1,LSTM模型能够对SMA路面抗滑性能指标进行有效预测。

关键词: 高速公路;沥青路面;抗滑性能指数;RNN神经网络;LSTM神经网络

中图分类号: U416.217

文献标志码: A

文章编号: 1009-7716(2025)07-0291-07

Prediction of Anti-skid Performance of Asphalt Pavement Based on LSTM Neural Network

WANG Honghui

(Hunan University Design and Research Institute Co., Ltd., Hunan 410006, China)

Abstract: In order to study and predict the attenuation law of the anti-skid performance of the asphalt pavement of the expressway, the pavement anti-skid performance index (SRI) and traffic volume data of an expressway in southern Sichuan from 2016 to 2021 are collected. The influence of traffic load and pavement age on the anti-skid performance of the asphalt pavement is analyzed. The RNN neural network model and the LSTM neural network model are established. Taking SRI values, cumulative axle loads and pavement ages over the years as inputs, and the SRI value of the last year as the output, the anti-skid performance indexes of the expressway SMA pavement are predicted. And the mean absolute percentage error (MAPE) and the root mean square error (RMSE) are used to evaluate the prediction accuracy of the RNN neural network and the LSTM neural network. The results show that the average MAPE and RMSE values of the training set and the test set of the LSTM neural network are 0.296 7, 0.349 9, 3.914 3, and 3.621 6, respectively. Compared with the RNN neural network, these values are reduced by 1.002 8, 1.021 4, 0.441, and 0.201 1, respectively, which indicates that the LSTM model can effectively predict the anti-skid performance index of the SMA pavement.

Keywords: expressway; asphalt pavement; anti-skid performance index; RNN neural network; LSTM neural network

0 引言

路面抗滑性能是评价路面质量的关键指标之一,直接影响驾驶员在恶劣天气条件下的行车安全^[1-2],在新建沥青路面投入使用初期,集料表层的沥青膜会发生破损现象,进而使得摩擦系数出现一定程度的增长。随着集料表面微观纹理对摩擦系数的促进作用逐渐显现,路表集料随即开启磨耗与磨光过程。

在此期间,路面的抗滑性能会逐步呈现下降趋势^[3-4]。对路面抗滑性能衰减规律加以研究并对其进行预测^[5-8],始终是道路交通安全领域着重研究的关键问题。

当前,路面抗滑性能预测模型的研究尚处于定性研究层面,多数情况下是借助不同的室内加速磨耗设备来探究抗滑性能的变化规律^[9-14]。文献[15]利用多因素加载磨耗设备(MAAM),对不同材料和不同条件下的沥青混合料抗滑衰减规律进行分析,建立了沥青路面抗滑性能预测模型。文献[16]采用室内揉搓试验,分析了SMA-13和GAC-16磨耗层初

收稿日期: 2024-12-31

作者简介: 王红辉(1976—),男,学士,高级工程师,注册土木工程师,从事道桥隧研究与设计咨询工作。

始抗滑性能差异的原因,研究了不同类型路面抗滑性能衰变规律与抗滑耐久性的关键指标。文献[17]采用有限元模拟技术,深入研究了众多因素对车辆滑水速度造成的影响。针对不同类型的沥青路面,在各种降雨强度条件下,对轮胎滑水速度和制动距离进行细致剖析,由此给出了雨天车辆在透水沥青路面行驶时能够保障安全的行驶车速区间,以及应当维持的车距控制准则。以上研究多是通过室内试验和有限元仿真对沥青路面的抗滑性能进行定性研究,与实际运行时的沥青路面抗滑性能衰变规律有所差别。近年来,深度学习技术在众多领域收获了颇为显著的成效^[18-20]。已有许多学者将深度学习技术应用到路面工程领域中,文献[21]基于遗传算法和BP神经网络,搭建了一个沥青混合料永久变形的预估模型。文献[22]基于卷积神经网络VGG16对沥青路面是否存在裂缝进行预测,取得了较好的预测精度。文献[23]以交通量、路龄、气温、降雨量和养护费用作为输入,以路面PQI作为输出节点,使用BP神经网络建立路面使用性能预测模型。长短时记忆网络(long short-term memory, LSTM)作为循环神经网络中的一种特殊类型,具备有效抓取数据长期依赖关联的能力,在时间序列数据的预测工作方面有着良好的适用性。

本文收集了某高速公路2016—2021年路面抗滑性能指数(SRI)和交通参数数据,分析实际路面抗滑性能的衰减趋势;对原始数据进行预处理,以提高对路面质量的评估准确性和预测效率;建立RNN神经网络模型和LSTM(long short-term memory, LSTM)神经网络模型对高速公路SMA路面抗滑性能指数进行预测,以更好地理解 and 预测高速公路路面抗滑性能的变化趋势,期望能为高速公路管理部门提供更准确的路面质量评估和维护决策支持,从而提升高速公路交通的安全性和效率。

1 数据介绍及数据预处理

1.1 工程概况

本文以某高速公路路段(K1 723+932~K1 858+732)为工程背景,该路段分两期建成通车,一期工程K1 785+560~K1 858+732段于2011年12月建成通车,二期工程K1 723+932~K1 785+560段于2012年11月建成通车,路面结构型式为:4 cm 改性沥青 SMA-13+6 cm 改性沥青 AC-20+8 cm 普通沥青 AC-25C+20 cm 水泥稳定碎石基层+36 cm 水泥稳定碎石底基层。该

路段自运营以来,还未对整条道路进行过大中修处理,仅在2018年对其中一处隧道路段(K1762+083~K1770+117)实施了加铺罩面处治。为了对该路段的抗滑性能衰减规律更好的进行分析,剔除加铺罩面的隧道路段进行之后的研究分析。

1.2 数据收集

本文调研收集了2016—2021年该路段的抗滑性能指标SRI值和该高速公路各站口交通量资料。抗滑性能指标SRI值来源于高速公路历年定检数据,该高速公路自2016年后没有更换过检测单位,可以保证数据的一致性和稳定性。抗滑指标SRI值是根据横向力系数SFC值计算得到,要求在路面保持潮湿的状态下用横向力系数测试车在60 km/h车速下测得横向力系数SFC60。根据该高速公路各站口交通量资料,统计得到各年交通量组成如表1所列。从2016—2021年的交通量资料可看出,在2020年之前,交通量呈现逐年增加的趋势,2020年之后受疫情影响,交通量有所减少。从交通量组成看,中小客和小货车约占总交通流的44%,中货、大货、特大货和集装箱等各种货车约占总交通流的52%。

表1 交通量组成							单位:辆/d
年份	小客车	大客车	小货车	中货车	大货车	特大货	集装箱
上行							
2016	2 986	219	624	180	455	665	145
2017	3 482	255	727	209	530	776	169
2018	3 915	287	907	246	622	872	198
2019	4 182	306	969	262	665	932	211
2020	2 059	151	477	129	327	459	104
2021	3 520	258	815	212	536	784	171
下行							
2016	3 505	257	732	211	534	614	170
2017	4 088	299	854	246	623	716	198
2018	4 596	337	871	266	674	805	214
2019	4 910	360	931	284	720	860	229
2020	2 417	177	458	140	355	424	113
2021	4 132	303	783	248	629	724	200

1.3 数据预处理

1.3.1 异常值处理

原始数据中,由于检测设备故障,记录的失误等可能会导致出现异常值。样本中过多的异常值,将会导致统计分析的结果有较大偏差。针对异常值,常采用箱型图进行识别,超过 $Q_1+1.5IQR$ 和 $Q_3+1.5IQR$ 这个范围的数据被定义为异常值,其中: Q_1 是下四分位数, Q_3 是上四分位数, IQR 是四分位数, $IQR=Q_3-Q_1$ 。对于识别出来的异常值,采用附近点均值进

行替换,最终得到样本数据上下行各 130 组数据。该高速公路 SRI 值的箱型图如图 1 所示。




图 1 SRI 箱型图

在对数据集完成预处理操作之后,随即对其进行划分操作,把其中 80% 的数据设定为训练集,借助这部分数据来开展模型的训练工作;而另外 20% 的数据确定为测试集,用于检验模型的精确程度。

1.3.2 归一化处理

原始数据集中的输入变量和输出变量,在量纲以及数值范围上有所不同,这种差异会对模型训练过程以及最终模型的精度产生影响。所以,在开展模型训练之前,有必要对原始数据集进行归一化操作。归一化处理不仅能够加速模型训练的收敛进程,还能提高模型的运行效率。在本文研究中,选用 0-1 标准归一化方法对数据集的变量进行处理,其公式表达为:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

式中: x 为原特征变量; x^* 为归一化后的特征变量; $x_{\max}$ 为样本特征最大值; $x_{\min}$ 为样本特征最小值。

2 神经网络模型构建

2.1 RNN 神经网络

在处理具有序列变化特征的数据时,循环神经网络(recurrent neural network, RNN)相比于其他机器

学习模型展现出更显著的优势。RNN 在普通多层 BP 神经网络的基础架构上,特别增加了隐含层各单元间的横向连接形式。凭借这种连接方式,RNN 可以把神经网络在前一个时间步得到的值传输到当前时间步,进而使神经网络具备了记忆功能。一个完备的 RNN 模型结构涵盖两个维度^[24-26]:其一为纵向维度,涉及当前状态下的特征输入以及目标输出;其二为横向维度,主要负责具有先后顺序的历史数据的传递过程。

2.2 LSTM 网络模型

当 RNN 处理序列结构较长的数据时,常常会因为梯度消失和梯度爆炸等问题,致使模型难以精准地捕捉到长距离的历史输入信息,而且距离当前顺序位越远的历史信息就越容易被忽略掉。针对这一状况,众多学者展开了大量深入的研究。而长短时记忆神经网络(long short-term memory, LSTM)^[27-29]是 RNN 的一种特殊变体。LSTM 通过在 RNN 的基础上额外增加了一个记忆状态,专门用于保存长期的信息,从而有效地解决了 RNN 在训练过程中容易出现的“梯度消失”难题。LSTM 的基本单元结构可参照图 2。




图 2 LSTM 模型结构图

LSTM 的基本单元构造包含 3 个门控机制,这 3 个门控机制能够对当下信息与过往信息的权重进行调节,从而优化得出最佳模型。其计算公式如下所示:

$$f_t = \sigma[W_f \cdot (h_{t-1}, x_t) + b_f] \tag{1}$$

$$i_t = \sigma[W_i \cdot (h_{t-1}, x_t) + b_i] \tag{2}$$

$$\tilde{C}_t = \tanh[W_c \cdot (h_{t-1}, x_t) + b_c] \tag{3}$$

$$O_t = \sigma[W_o \cdot (h_{t-1}, x_t) + b_o] \tag{4}$$

$$C_t = \tilde{C}_t \odot i_t + C_{t-1} \odot f_t \tag{5}$$

$$h_t = O_t \odot \tanh(C_t) \tag{6}$$

式中: f_t 、 i_t 、 $\tilde{C}_t$ 、 O_t 、 C_t 、 h_t 分别为遗忘门、输入门、输入门节点、输出门、当前时刻细胞记忆状态、当前时刻隐藏层输出; W_f 、 W_i 、 W_c 、 W_o 和 b_f 、 b_i 、 b_c 、 b_o 分别为遗忘门、输入门、输入节点、输出门的权重和偏置参数

(h_{t-1}, x_t) 为上一时刻的隐藏输出和当前时刻输入的拼接; $\odot$ 为矩阵元素积; σ 和 $\tanh$ 为sigmoid函数变化和 $\tanh$ 函数变化。

本研究运用Adam优化方法对RNN网络模型和LSTM网络模型开展训练工作,其中学习率设定为0.001。在网络训练进程中,采用均方损失函数MSE进行相关计算与评估:

$$\text{MSE} = (\hat{y}_i - y_i)^2 \quad (1)$$

式中: y_i 为真实值, $\hat{y}_i$ 为预测值。

2.3 预测模型评价指标选取

为评估RNN神经网络和LSTM神经网络的预测精确程度,本研究选用平均绝对百分比误差(MAPE)与均方根误差(RMSE)这两个指标。MAPE能够以直观的方式展现预测值与真实值之间的契合度,其数值越小,则意味着神经网络的预测精准性越高。RMSE对于预测值和真实值中出现的特大或特小误差反应极为敏锐,可有效评估预测值与真实值之间的偏离状况,当RMSE值越小时,表明神经网络的预测精度越佳。MAPE和RMSE的计算公式如下所示:

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (7)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (8)$$

式中: y_i 为真实值; $\hat{y}_i$ 为预测值; n 为样本数量。

3 数据分析及模型预测

为了验证建立的LSTM模型能够更加精确预测SMA路面的抗滑性能指标,将收集到的高速公路2016—2022年的沥青路面抗滑性能指标SRI、累计轴载作用次数和路龄作为数据集,分析了交通荷载与路龄对沥青路面抗滑性能的影响,使用RNN神经网络和LSTM神经网络对沥青路面抗滑性能指标进行预测,并对两种神经网络的预测结果进行对比分析。

3.1 交通荷载与路龄对沥青路面抗滑性能影响

本章研究的交通量数据主要依据《公路沥青路面设计规范》(JTG D50—2017)里的相关条款,将各种车型换算成当量轴次,不过在这一换算过程中,并未涉及与抗滑相关的折算。一方面,沥青路面的疲劳损伤在很大程度上受大客车、货车这类轴重较大的交通荷载的影响;另一方面,小客车的反复磨耗作用对沥青路面抗滑性能的削弱也不容忽视。鉴于不同车型对路面的作用次数有所不同,为了便于计算

并使结果具有一定的代表性,本研究计划采用年交通量的折算数乘以车道系数(0.5)来确定当年的轴载作用次数,然后逐年累加,以此作为累计轴载作用次数。

由于2016年以前的交通量数据缺失,无法从高速公路建成之初就对SRI与累计轴载作用次数的关系展开分析,所以只能以2016年为起始点来计算相对累计轴载作用次数,进而通过相对衰减速率来分析SRI的衰减状况。该高速路段以及SRI测值随时间变化的数据如图3所示。




图3 累计轴载作用次数与SRI测值逐年分布

从图3能够观察到,此高速公路的累计轴载作用次数在运营时间不断增长的过程中,总体上呈现出近似线性的增加态势,尤其在2016—2022年,基本保持着相等的步距增长。这意味着经过多年的运营,该高速公路交通量的增长态势已趋于稳定。相应地,该高速公路的沥青路面抗滑性能指数SRI随着运营时间的持续推移以及累计轴载作用次数的逐步上升,呈现出下降的趋势。值得注意的是2019年的交通量相对其他年份来说有一个较大幅度的增加,同时,该年的SRI值有一个大幅度地下降。说明高速公路SMA路面抗滑性能指标的变动趋势与累计轴载作用次数的变动趋势呈现一种负相关趋势。

为直观地展示路龄与SMA路面抗滑性能指数SRI之间的关系,图4展示了该高速公路2016—2021年

上、下行主车道及上下行主车道平均抗滑指标 SRI 值随高速公路运营年限的变化。为探讨高速公路沥青路面抗滑性能的衰减规律,收集同一地区另一条高速公路表面层 SMA-13 自 2012 年建成通车以来的抗滑指标 SRI 值,如图 5 所示。




图 4 抗滑指标衰减趋势




图 5 另一高速公路通车近 10 a 的抗滑指标衰减趋势

从图 4 可以看出,建成通车营运 4~5 a 后,到 2016 年路面抗滑指标 SRI 约为 90,随后抗滑指标逐年衰减,又经过 5 a 运营,至 2021 年抗滑指标 SRI 约为 75。由图 5 可知,该高速公路自 2012 年通车以来,随着通车年限的不断增加,抗滑指标 SRI 值先增加后减小,这一变化规律与文献^[2]研究结论相一致;通车 3 a 后达到峰值,其后随通车时间的延长不断衰减,到 2021 年(通车运营 9 a),其抗滑性能总体在 80 分以上。新建 SMA-13 路面抗滑指标 SRI 值衰减呈现这一先增后减变化的主要原因:刚铺筑完成的沥青混合料,碎石表面均匀包裹一层沥青膜,特别是 SMA 混合料沥青用量相对较大、沥青膜相对较厚,车辆运行时,碎石表面的部分微观纹理由于沥青膜的包裹不能与轮胎产生切削、迟滞和能量耗散作用,导致抗滑指标 SRI 值较低;随着开始投入运营后车辆荷载的反复作用,沥青薄膜逐渐变薄、磨损,集料逐步外露,集料纹理与轮胎相互作用导致沥青路面的抗滑性能明显提高。但随着运营时间进一步推移,

在车辆轮胎的累积磨光作用下,集料外露呈现出现的微观纹理被不断磨光,同时集料的凸起也被不断磨平,表现为路面抗滑性能不断下降。

图 4 所示的该高速公路 SMA 路面抗滑指标并没有呈现出先增加的过程,其原因是本文所收集到的 2016 年的抗滑指标已是通车 4~5 a 的检测结果,也就是说,该高速公路路面的抗滑指标由刚开始运营到峰值出现的过程已经完成,已经进入逐渐减小的阶段。路面抗滑性能在通车运营后的多长时间内达到峰值,与混合料类型、施工工艺、交通量、集料性能和环境等有关。图 5 的结果表明,该 SMA 路面在运营 3 a 后,抗滑指标达到峰值,文献^[2]为 1 a,这可能与混合料类型、交通量等因素有关。

进一步分析图 4 发现,抗滑指标历年衰变率大小并不一致,主要表现为 2017—2018 年和 2019—2020 年的下降趋势明显小于其他年份,分析原因主要为:2018 年该高速公路有一座长大隧道的水泥混凝土路面加铺了沥青层,大幅提高了其抗滑性能;受疫情影响,2020 年交通量相对 2019 年大幅降低,如表 1 所列;从图 4 可以看出,2020 年和 2021 年的抗滑指标逐渐趋于平稳,衰变率很小,表明交通量和路龄直接影响路面的抗滑性能。

3.2 模型验证及其对比分析

从之前的分析中得到,沥青路面的抗滑性能指标不仅与往年的抗滑性能指标数值有关,并且与累计轴载作用次数和路龄也有关,且呈现出规律性的变化。将进行数据预处理后的 2016—2020 年的 SMA 路面抗滑性能指标 SRI 和 2016—2021 年的累计轴载作用次数和路龄作为输入数据,将 2021 年的 SMA 路面抗滑性能指标 SRI 作为输出数据。

在对 RNN 神经网络模型和 LSTM 神经网络模型实施训练与验证操作时,把所获取的数据依据 80% 与 20% 的比例划分成训练数据集和测试数据集两部分,模型运行结果如图 6 所示。

从图 6 中可以看出,两种模型上下行数据集的预测结果都较好,训练集和测试集的数据和真实值相差不大,真实的 SRI 值与预测的 SRI 值吻合较好,证明 RNN 神经网络模型和 LSTM 神经网络模型都能对 SMA 路面抗滑性能指标进行良好的预测。为更直观地展现模型的预测效果,使用平均绝对误差 MAE 和均方根误差 RMSE 来计算两种模型输出数据与真实值之间的误差,计算结果如表 2 所列。

从表 2 中可以看出,两种模型上下行的训练集和




图6 RNN神经网络模型和LSTM神经网络模型运行结果

表2 预测结果误差

预测模型	方向	训练集		测试集	
		MAPE	RMSE	MAPE	RMSE
LSTM	上行	0.301 3	0.395 5	3.582 4	3.022 4
	下行	0.292 0	0.304 4	4.246 3	4.220 7
	平均值	0.296 7	0.349 9	3.914 3	3.621 6
RNN	上行	2.337 5	2.463 0	4.777 4	3.910 1
	下行	0.261 4	0.279 7	3.933 2	3.735 3
	平均值	1.299 5	1.371 3	4.355 3	3.822 7

测试集的MAE误差和RMSE误差都较小,其中LSTM神经网络模型训练集的平均MAPE值和平均RMSE值分别为0.296 7、0.349 9,相对于RNN神经网络模型训练集的1.299 5和1.371 3,分别减少了1.002 8和1.021 4。LSTM神经网络模型测试集的平均MAPE值和平均RMSE值分别为3.914 3、3.621 6,相对于RNN神经网络模型测试集的4.355 3和3.822 7,分别减少了0.441和0.201 1。证明LSTM神经网络模型能够对高速公路SMA路面抗滑性能指标进行更精确的预测。

4 结 论

(1)随着高速公路运营时长的不断增加,累计轴载作用次数大致呈现出线性增长的态势。与此同时,SMA路面的抗滑性能指数SRI会随着交通量的增多而逐渐降低。这表明,高速公路SMA路面抗滑性能指标的变动情况与累计轴载作用次数的变化之

间呈现出一种负相关的关系。

(2)高速公路SMA路面随着通车年限的不断增加,抗滑指标SRI值先增加后减小,造成这一现象的主要原因为:刚铺筑完成的沥青混合料,碎石表面均匀包裹一层沥青膜,特别是SMA混合料沥青用量相对较大、沥青膜相对较厚,车辆运行时,碎石表面的部分微观纹理由于沥青膜的包裹不能与轮胎产生切削、迟滞和能量耗散作用,导致抗滑指标SRI值较低;随着开始投入运营后车辆荷载的反复作用,沥青薄膜逐渐变薄、磨损,集料逐步外露,集料纹理与轮胎相互作用导致沥青路面的抗滑性能明显提高。但随着运营时间进一步推移,在车辆轮胎的累积磨光作用下,集料外露呈现出现的微观纹理被不断磨光,同时集料的凸起也被不断磨平,表现为路面抗滑性能不断下降。

(3)RNN网络模型和LSTM网络模型对高速公路SMA路面的抗滑性能指标的预测结果都较好,其中LSTM神经网络模型训练集的平均MAPE值和平均RMSE值分别为0.296 7、0.349 9,相对于RNN神经网络模型训练集的1.299 5和1.371 3,分别减少了1.002 8和1.021 4。LSTM神经网络模型测试集的平均MAPE值和平均RMSE值分别为3.914 3、3.621 6,相对于RNN神经网络模型测试集的4.355 3和3.822 7,分别减少了0.441和0.201 1。证明LSTM神经网络模

型能够对高速公路SMA路面抗滑性能指标进行更精确的预测。

参考文献:

- [1] 宁斌权. 沥青路面抗滑性能衰变规律及修复技术研究[D]. 重庆: 重庆交通大学, 2018.
- [2] 黄晓明, 郑彬双. 沥青路面抗滑性能研究现状与展望[J]. 中国公路学报, 2019, 32(4): 32-49.
- [3] TIANCHI T, KUMAR A, COR K. Finite element studies of skid resistance under hot weather condition[J]. Transportation Research Record, 2018(40): 382-394.
- [4] MAHMOUD E, MASAD E. Experimental methods for the evaluation of aggregate resistance to polishing. Abrasion and breakage[J]. Mater. Civ. Eng., 2007(4): 977-985.
- [5] 胡志飞. 沥青路面抗滑衰变特性研究[J]. 北方交通, 2021(4): 44-48.
- [6] 王振华, 张勇, 杨雷. 沥青路面材料抗滑性能衰变规律研究[J]. 公路交通科技(应用技术版), 2020(4): 127-129.
- [7] 林爱萍. 高速公路沥青路面抗滑性能研究[J]. 福建交通科技, 2020(6): 42-45.
- [8] 熊剑平, 刘可, 翟龙, 等. 石灰岩沥青混合料抗滑性能衰变特性研究[J]. 材料导报, 2018, 32(增刊1): 495-499.
- [9] 秦浪朝. 路面摩擦系数的检测与评价方法的研究[D]. 重庆: 重庆交通大学, 2015.
- [10] 钱朝清. 国外沥青路面抗滑性能影响因素研究[J]. 城市道桥与防洪, 2019(2): 165-167.
- [11] 王永平, 黄维蓉. 室内沥青路面抗滑性能衰减规律研究及模型分析综述[J]. 中外公路, 2015, 35(3): 299-302.
- [12] 余苗, 童锦尧, 孔令云, 等. 轮胎-沥青路面摩擦测试及抗滑模型研究综述[J]. 公路交通科技, 2020, 37(10): 12-24.
- [13] 汤东, 陈军. 基于室内加速磨耗试验的SMA-13抗滑衰变规律研究[J]. 城市道桥与防洪, 2020(3): 158-162.
- [14] 马健萍, 许新权, 范倩, 等. 基于加速加载试验的SMA-13沥青混合料抗滑性能研究[J]. 公路, 2022(7): 388-394.
- [15] 刘亚敏, 汪磊, 杨振. 沥青路面抗滑性能衰减规律及预测模型[J]. 长安大学学报(自然科学版), 2023, 43(5): 1-10.
- [16] 黄宏敏, 罗传熙, 黄志勇, 等. SMA与GAC路面抗滑性能衰变规律[J]. 公路交通科技, 2023, 40(10): 27-34.
- [17] 王豈. 基于轮胎-路面-水流耦合模型透水沥青路面抗滑性能研究[D]. 长沙: 长沙理工大学, 2022.
- [18] 曹阳, 杨傲, 翟博渊, 等. 基于BP神经网络的沥青路面沉陷发展预测[J]. 无损检测, 2024, 46(4): 48-52.
- [19] 陈跃琳. 基于GA-BP神经网络的足尺环道沥青路面结构层模量反算方法研究[D]. 保定: 河北大学, 2024.
- [20] 利璐, 李晨钟, 王平, 等. 基于深度学习的轨道不平顺估计车体横向加速度研究[J]. 北京交通大学学报, 2023, 47(4): 103-109.
- [21] 王刚, 张新为, 王振东, 等. 基于GA-BP神经网络的沥青混合料永久变形预估模型研究[J]. 公路, 2025(2): 21-29.
- [22] 王亮, 陈强, 郭乐乐. 基于卷积神经网络的沥青路面裂缝损伤识别研究[J]. 黑龙江科学, 2024, 15(22): 17-19.
- [23] 汪凡, 杨建喜. 基于BP神经网络的路面使用性能预测模型[J]. 中外公路, 2009, 29(1): 86-89.
- [24] A. Tanasoiu, and I. Copaci. Studies regarding the improvement of the geometrical characteristics of high speed railway[J]. Mechanical Engineering, 2007(9): 167-170.
- [25] M. Majka, and M. Hartnett. Dynamic response of bridges to moving trains: A study on effects of random track irregularities and bridge skewness[J]. Computers & Structures, 2009, 87(19): 1233-1252.
- [26] 张颖新, 刘玉洁, 王思成. CNN-RNN算法在网络入侵检测与信息安全保密技术中的应用研究[J]. 电脑知识与技术, 2024, 20(33): 44-46.
- [27] J L Elman. Finding Structure in Time[J]. Cognitive Science, 1990, 14(2): 179-211.
- [28] S. Hochreiter, and J. Schmidhuber. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [29] 何庆, 利璐, 李晨钟, 等. 基于深度学习的轨道不平顺与车体垂向加速度映射模型[J]. 铁道学报, 2023, 45(6): 106-113.

(上接第244页)

参考文献:

- [1] 刘正光, 卢耀宗, 杨文武. 大型隧道工程风险管理工程实践——从香港到内地之工程经验[J]. 隧道建设, 2010, 30(增刊1): 8-14.
- [2] 王吉云. 近十年来中国超大直径盾构施工经验[J]. 隧道建设, 2017, 37(3): 330-335.
- [3] 陈龙, 黄宏伟. 上中路隧道工程风险管理的实践[J]. 地下空间与工程学报, 2006, 2(1): 65-69; 73.
- [4] 黄宏伟, 彭铭, 胡群芳. 上海长江隧道工程风险评估研究[J]. 地下空间与工程学报, 2009, 5(1): 182-187.
- [5] 吴璇颖. 超大直径盾构隧道施工风险管理分析[J]. 城市道桥与防洪, 2011, 8(8): 297-299; 311.
- [6] 刘艳滨. 上海外滩隧道工程建设风险管理体系的构建[J]. 中国市政工程, 2010, 149(增刊1): 98-101; 154.
- [7] 宋雨妹. 上海虹梅南路隧道信息化管控的应用实例[J]. 中国市政工程, 2014, 176(6): 46-47; 50.
- [8] 杨文武, 胡悦明, 曾楚坚. 论隧道工程全过程风险管理模式[J]. 隧道建设, 2015, 35(8): 753-758.
- [9] 吴全立, 王梦恕, 骆建军. 盾构隧道工程可视化安全风险管理软件的研究与开发[J]. 现代隧道技术, 2013, 50(4): 15-23.