文章编号:1673-0291(2026)03-0175-11 **DOI**:10.11860/j.issn.1673-0291.20250174

基于机器学习的重载铁路轨道质量指数分析方法

陶志刚[1a,2],郭保青[1a,1b],周 斌[3],史红梅[1a],曾 玮[4],李光晔[4]

(1.北京交通大学 a.先进轨道交通自主运行全国重点实验室,b.机械与电子控制工程学院,北京 100044;
2.国家能源投资集团有限责任公司 科技创新部,北京 100011;3.北京低碳清洁能源研究院,
北京 102211;4.国家能源集团新能源技术研究院有限公司,北京 102209)

摘 要:针对重载铁路轨道质量指数预测准确性不高的问题,提出基于机器学习的分析方法.首先,以某大型能源企业重载铁路2015年至2023年2 906个区段的303 381条轨检车检测记录和维修记录为原始数据集进行数据清洗,并按照区段特性将数据集分为无坡无曲线、无坡有曲线、有坡无曲线、有坡有曲线4类;其次,将每类区段数据集处理为连续3个月且期间无维修记录的序列数据集合,利用异常识别方法剔除轨道质量指数(Track Quality Index, TQI)极差过大的序列;再次,以序列中前2个月的TQI及其7个分量(左高低、右高低、左轨向、右轨向、轨距、水平、三角坑)为输入,使用循环神经网络、长短时记忆、门控循环单元、多层感知机、支持向量机、线性回归6种机器学习模型滚动预测第3个月的TQI;最后,分析对比不同模型对不同类型区段TQI的预测性能.研究结果表明:利用6种机器学习模型对4类区段的TQI进行预测时,真实值与预测值的拟合度R^2均大于0.94,预测结果准确;在6种模型中,循环神经网络表现尤为突出,在不同测试集上的平均R^2为0.967 5,标准差为±0.000 8,针对4个典型区段的TQI进行预测的R^2分别为0.990 1、0.974 3、0.988 3和0.988 9,相比于另外5种模型预测结果更稳定,对不同场景的适应性更强.研究证明机器学习方法能够满足重载铁路TQI预测的需求,研究成果可为科学合理的大机捣固维修作业计划制定和智能化工务维护提供参考.

关键词:铁路运输;重载铁路;机器学习;轨道质量指数;轨道几何检测

中图分类号:U216.3 **文献标志码**:A

Machine learning-based analysis method for track quality index of heavy-haul railway

TAO Zhigang[1a,2], *GUO Baoqing*[1a,1b], *ZHOU Bin*[3], *SHI Hongmei*[1a], *ZENG Wei*[4], *LI Guangye*[4]

(1a. State Key Laboratory of Advanced Rail Autonomous Operation, 1b. School of Mechanical, Electronic and Control Engineering, Beijing Jiaotong University, Beijing 100044, China; 2. Science and Technology Innovation Division, China Energy Investment Corporation Co., Ltd., Beijing 100011, China; 3. National Institute of Clean-and-Low-Carbon Energy, Beijing 102211, China; 4. China Energy New Energy Technology Research Institute Co., Ltd., Beijing 102209, China)

Abstract: To address the low prediction accuracy of the Track Quality Index (TQI) in heavy-haul rail-

收稿日期:2025-10-29;**修回日期**:2026-05-20
基金项目:国家自然科学基金(U246920087)
Foundation item: National Natural Science Foundation of China(U246920087)
第一作者:陶志刚(1982—),男,安徽蚌埠人,博士生.研究方向为轨道交通检测理论与技术.**email**: hytzg@163.com.
通信作者:郭保青(1978—),男,河北涞水人,教授,博士,博士生导师. **email**: bqguo@bjtu.edu.cn.

引用格式:陶志刚,郭保青,周斌,等.基于机器学习的重载铁路轨道质量指数分析方法[J].北京交通大学学报,2026,50(3):175-185.
TAO Zhigang, GUO Baoqing, ZHOU Bin, et al. Machine learning-based analysis method for track quality index of heavy-haul railway[J]. Journal of Beijing Jiaotong University, 2026, 50(3): 175-185.(in Chinese)

ways, this study proposes an analysis method based on machine learning. First, a raw dataset comprising 303 381 track inspection and maintenance records collected between 2015 and 2023 from 2 906 sections of a heavy-haul railway operated by a major energy enterprise is utilized. Following data cleaning, the dataset was categorized into four track section types based on geometric characteristics: neither gradients nor curves, curves without gradients, gradients without curves, and both gradients and curves. Second, the data for each category were processed into sequential datasets spanning three consecutive months without maintenance interventions. Sequences exhibiting an excessively large range in the TQI were then eliminated using anomaly detection methods. Third, using the TQI and its seven components (left-rail longitudinal level, right-rail longitudinal level, left-rail alignment, right-rail alignment, gauge, cross level, and track twist in triangle form) from the first two months of each sequence as inputs, six machine learning models, such as Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Multi-Layer Perceptron (MLP), Support Vector Machine (SVM), and linear regression, are leveraged to perform rolling predictions of the TQI for the third month. Finally, the predictive performance of the different models across various section types is comparatively analyzed. The results indicate that when using the six machine learning models to predict the TQI across the four section types, the coefficient of determination R^2 between the measured and predicted values exceeds 0.94 for all models, suggesting highly accurate and reliable prediction performance. Among the six models, the RNN demonstrates particularly outstanding performance, achieving an average R^2 of 0.967 5 with a standard deviation of $\pm$0.000 8 across various test sets. Specifically, for the four representative track sections, the prediction R^2 values are 0.990 1, 0.974 3, 0.988 3, and 0.988 9, respectively. Compared to the other five models, the RNN yields more stable prediction results and exhibits greater adaptability to diverse scenarios. This study demonstrates that machine learning methods effectively meet the demands of TQI prediction in heavy-haul railways, providing a valuable reference for establishing scientific tamping maintenance schedules and advancing intelligent track maintenance practices.

Keywords: railway transportation; heavy-haul railway; machine learning; track quality index; track geometry measurement

重载铁路承担着中国能源保供的重要任务,具有大运量、高效率、低成本的特点,对服务国家战略和高质量发展具有不可替代的作用.由于重载铁路大轴重、大运量的特性,加速了轨道不平顺状态的劣化,及时追踪、预测不平顺状态是轨道养护维修工作亟待解决的关键问题.早期轨道不平顺状态研究主要聚焦于车辆-轨道耦合动力学[1-2]、轨道下沉[3-5]等相关力学特性及理论公式,通过实验数据拟合公式参数进而预测轨道不平顺状态参数.随着轨道检测与统计技术的成熟,基于统计分析的轨道不平顺状态研究逐步兴起.文献[6]针对特定轨道区段的45组轨检数据,构建了轨道质量指数(Track Quality Index, TQI)随时间变化的多阶段线性预测模型.文献[7-8]基于不平顺状态劣化的非线性特征,利用指数函数拟合构建了相邻两次捣固维修之间轨道几何状态的劣化模型.简单的线性或非线性模型的预测性能和普适性难以达到预期的要求.针对轨道不平顺状态劣化的随机性,文献[9]利用马尔可夫模型建立了基于静态TQI预测动态值的方法,研究了TQI静态、动态两种检测值随线路质量等因素的变化关系.文献[10]采用连续19组轨检数据建立非等时距灰色模型,实现对未来连续7次TQI数据的预测,平均相对误差低于2.54%.

近年来,随着机器学习的发展,其在复杂模式识别[11]、数据驱动建模[12-14]、预测优化[15-17]等方面的能力,为众多领域开辟了新的解决路径,也有文献提出使用机器学习模型进行TQI预测相关研究:文献[18]利用100组轨检数据和支持向量机(Supported Vector Machine,SVM)建立了TQI预测模型,通过核函数优化了小样本数据下的泛化问题,对3个测试集数据预测R^2不低于0.97;文献[19]基于26组轨检数据,利用非等间距灰色GM(1,1)模型预测TQI序列,再利用粒子群优化的支持向量机模型对灰色预测值进行纠正,构建了轨道不平顺变化趋势预测模型,预测结果的相对误差低于2.82%;文献[20]引入多层感知机(Multi-Layer Perceptron,MLP)模型对

铁路轨道几何状态劣化进行了预测,以土耳其Arifiye-Eskisehir区段内820条数据为输入,各项指标预测值的平均R^2值为0.772;文献[21]采用马尔可夫残差对GM(1,1)模型进行了改进,以18次轨检数据外推之后4次的数据,准确率相比于传统模型有所提升.

尽管重载铁路存在轴重大、磨耗加剧、冲击载荷特征更明显等情况,但鉴于机器学习模型对多变量、非线性关系强大的拟合能力,利用机器学习模型可以实现以较高精度预测重载铁路的TQI.然而,既有成果大多选取单一或少量区段的数据作为研究对象,少样本量一方面会影响模型的预测性能,另一方面会影响模型在重载铁路场景下的普适性.为解决上述问题,在本文研究中收集了某大型能源企业重载铁路的轨检车检测记录和检修记录,为精准适配重载铁路不同区段的线路特性差异,将数据按照区段特性(有无坡度、有无曲线)分为无坡无曲线、无坡有曲线、有坡无曲线、有坡有曲线4类,经过数据清洗、序列生成、异常值识别等步骤后,利用前2个月的TQI及其7个分量(左高低、右高低、左轨向、右轨向、轨距、水平、三角坑)为输入,分别使用循环神经网络(Recurrent Neural Network, RNN)、长短时记忆神经网络(Long Short Term Memory,LSTM)、门控循环单元(Gated Recurrent Unit,GRU)、MLP、SVM、线性回归6种机器学习模型预测第3个月的TQI;通过分析6种模型对4种区段TQI的预测性能,确定TQI预测方法.

1　重载铁路轨检数据集及预处理

1.1　数据预处理

1.1.1　原始数据

研究对象为某大型能源企业的重载铁路,长度584.2 km.轨检车每25 cm测量一次轨道几何状态参数,包括左高低、右高低、左轨向、右轨向、轨距、水平、三角坑,TQI的计算式为

$$\mathrm{TQI}=\sum_{p=1}^{n}\delta_p \tag{1}$$

式中:TQI为轨道几何质量指数;δ_p为轨道几何状态参数,p取值为1~7的连续整数时分别为左高低、右高低、左轨向、右轨向、轨距、水平、三角坑.

以200 m内的800条检测数据计算区段几何状态参数均值.根据企业管理规定,轨检车每5 km进行一次里程点校正,确保不同日期对同一测点的实际检测位置基本相同.在进行重载铁路TQI检测时,一般不考虑样本内的车站部分[22],因此在研究中会预先筛选剔除道岔、站场等部分的数据.本文收集了2015年至2023年的轨道检修记录与2 906个区段的303 381条原始检测记录,每条记录除上述7个几何状态参数和TQI外,还包含检测日期、区段起始点、坡度值、转弯半径.

1.1.2　数据清洗

轨检数据时空范围跨度大,在产生、记录、传输等不同阶段存在误差或异常(硬件技术性误差、环境干扰性误差和人为操作失误等),导致数据集中存在部分错误或无效的数据.数据清洗是大数据应用过程中的重要环节,目的在于识别和删除重复数据、异常数据,保证数据的有效性和一致性.识别并剔除原始检测数据中存在缺失值的18 335条记录及重复的7 957条记录,剩余有效记录277 089条.

1.1.3　数据分类

坡道和曲线是划分铁路等级的重要依据[23],因此按照记录中坡度值和转弯半径数据可将2 906个区段分为无坡无曲线、无坡有曲线、有坡无曲线和有坡有曲线4类.其中,无坡无曲线数据集包含有效记录124 321条,无坡有曲线包含19 105条,有坡无曲线包含82 073条,有坡有曲线包含51 590条.

1.2　数据集生成

1.2.1　序列生成

结合检修记录,分别针对无坡无曲线、无坡有曲线、有坡无曲线、有坡有曲线4类数据,提取连续3个月、相邻2次检测日期≤31天且期间无检修记录的数据作为建模数据集,如图1所示.

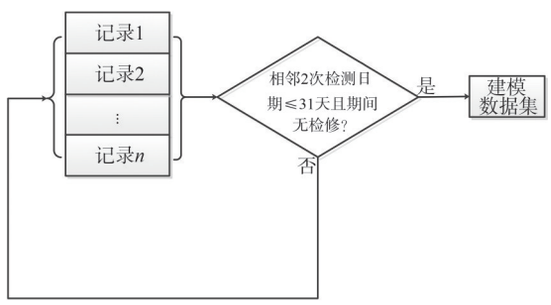


图1　检测记录序列生成流程

Fig. 1　Generation process of the inspection record sequences

由图1可知,数据集建模包括2个处理步骤.

步骤1:从当前记录开始提取3条记录,若相邻2条记录的检测时间都不超过31天且期间无检修记录,将这3条记录存入建模数据集,否则跳入下一步.

步骤2:从下一条记录开始,重复上述步骤1,直至序列中剩余记录不足3条,停止提取.

经统计,无坡无曲线数据集包含连续3个月且期间无检修的轨检车检测记录序列77 535个;无坡

有曲线数据集包含序列 11 856 个；有坡无曲线数据集包含序列 51 602 个；有坡有曲线数据集包含序列 31 570 个.

1.2.2 异常数据识别

针对无坡无曲线、无坡有曲线、有坡无曲线、有坡有曲线 4 种区段的检测记录序列集合，分别计算每种区段中每个序列的 TQI 极差，统计每个区段中全部序列 TQI 极差的四分之一位数（$Q1$）、四分之三位数（$Q3$）及分位距（IQR=$Q3-Q1$）. 根据 Tukey 准则，异常值上限为四分之三位数加 1.5 倍的分位距（$Q3+1.5\times$IQR），TQI 极差超过该值的序列判定为异常序列[24]. 经核对，异常序列源于企业在两次轨道检测之间进行了小修但未上报，以致 TQI 发生突变但无法通过图 1 所示流程识别. 经统计，无坡无曲线数据集包含异常序列 7 123 个，无坡有曲线数据集包含异常序列 995 个；有坡无曲线数据集包含异常序列 5 147 个；有坡有曲线数据集包含异常序列 2 722 个. 在后续建模时需剔除异常序列.

1.2.3 建模数据集划分

针对 4 种区段的建模数据集，随机打乱顺序，避免模型在训练时受到数据本身时序特征的影响，提升模型的泛化能力. 需要对建模数据集进行划分，如图 2 所示.

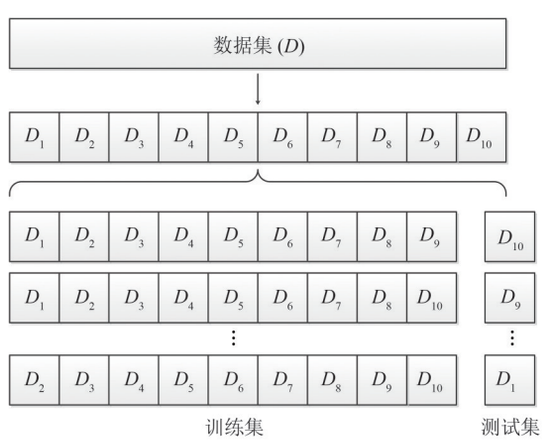


图 2 10 折交叉验证示意图

Fig. 2 Schematic of 10-fold cross-validation

图 2 中，D 为数据集，$D_1\sim D_{10}$ 为数据集 D 的子数据集. 将数据集均分为 10 个互不相交的子集，建模时以 9 个子集作为训练集，剩余 1 个子集作为测试集，共进行 10 次训练和测试. 对模型预测 TQI 的性能进行评价，评价指标选择拟合度 R^2 为

$$R^2=1-\frac{\sum_{j=1}^{n}(y_j-\hat{y}_j)^2}{\sum_{j=1}^{n}(y_j-\bar{y})^2} \tag{2}$$

式中：y_j 为第 j 个样本的真实值；$\hat{y}_j$ 为第 j 个样本的预测值；$\bar{y}$ 为真实值的均值；n 为样本数.

2 基于机器学习的 TQI 预测方法

鉴于轨道几何劣化及 TQI 演化的时序特征，搭建 3 种时序建模（RNN、LSTM、GRU）和 3 种非时序模型（MLP、SVM、线性回归）.

2.1 时序模型

2.1.1 RNN

由输入层、隐藏层、输出层组成，构建 RNN 模型如图 3 所示.

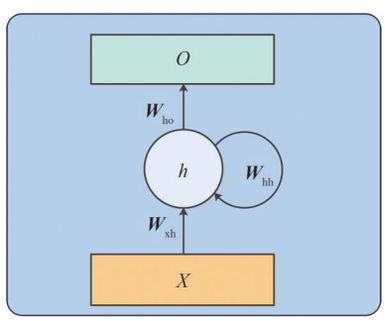


图 3 RNN 结构示意图

Fig. 3 RNN architecture

图 3 中：X 为 RNN 的输入；O 为 RNN 的输出；$\boldsymbol{W}_{\mathrm{xh}}$ 为输入层到隐藏层的转换矩阵；$\boldsymbol{W}_{\mathrm{hh}}$ 为隐藏层循环至隐藏层的转换矩阵；$\boldsymbol{W}_{\mathrm{ho}}$ 为隐藏层到输出层的转换矩阵. RNN 计算具体包括 3 个步骤.

步骤 1：将第 1 时刻数据 $x^{(1)}$ 和初始化隐藏层状态 $\boldsymbol{h}^{(0)}$（随机矩阵）代入隐藏层状态矩阵 $\boldsymbol{h}^{(t)}$，表达式为

$$\boldsymbol{h}^{(t)}=\tanh(\boldsymbol{W}_{\mathrm{xh}}\boldsymbol{x}^{(t)}+\boldsymbol{W}_{\mathrm{hh}}\boldsymbol{h}^{(t-1)}+b_{\mathrm{h}}) \tag{3}$$

式中：$\boldsymbol{h}^{(t)}$ 为第 t 时刻的隐藏层状态矩阵；tanh 为双曲正切函数；b_{h} 为隐藏层的偏置项.

步骤 2：将第 2 时刻数据 $x^{(2)}$ 和第 1 时刻的隐藏层状态 $\boldsymbol{h}^{(1)}$ 代入式（3）计算出 $\boldsymbol{h}^{(2)}$. 以此类推，可计算得到第 t 时刻隐藏层状态 $\boldsymbol{h}^{(t)}$.

步骤 3：将 $\boldsymbol{h}^{(t)}$ 最后一个时间步对应数据进行线性转换，得到 $o^{(t)}$ 为对第 t 时刻的预测结果，其中 $o^{(t)}$ 表达式为

$$o^{(t)}=\boldsymbol{W}_{\mathrm{ho}}\boldsymbol{h}^{(t)}+b_{\mathrm{o}} \tag{4}$$

式中：$o^{(t)}$ 为第 t 时刻的预测结果；b_{o} 为输出层的偏置项.

2.1.2 LSTM

LSTM 结构由输入门、遗忘门、输出门、记忆元组成，如图 4 所示.

图 4 中：输入门决定第 t 时刻的输入数据 $x^{(t)}$ 和第 $t-1$ 时刻的隐藏层状态 $\boldsymbol{h}^{(t-1)}$ 中有多少信息存入第 t 时刻的细胞状态 $c^{(t)}$；遗忘门决定第 $t-1$ 时刻的

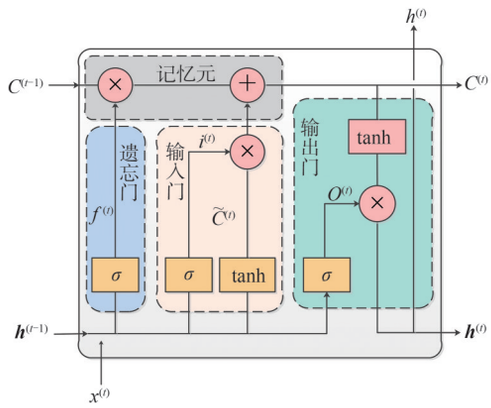


图 4　LSTM 结构示意图

Fig. 4　LSTM architecture

细胞状态 $c^{(t-1)}$ 中有多少信息被保留;输出门决定当前细胞状态 $c^{(t)}$ 中有多少信息输出到隐藏状态 $\boldsymbol{h}^{(t)}$;记忆元负责存储和传递长期依赖信息.计算过程包括 3 个步骤.

步骤 1:通过第 1 时刻数据 $x^{(1)}$ 和初始化隐藏层状态 $\boldsymbol{h}^{(0)}$(随机矩阵)计算得到第 1 时刻的遗忘门结果、输入门结果、输出门结果及中间结果.

遗忘门结果表达式 $f^{(t)}$ 为

$$f^{(t)}=\sigma(\boldsymbol{U}_{\mathrm{f}}\boldsymbol{h}^{(t-1)}+\boldsymbol{W}_{\mathrm{f}}\boldsymbol{x}^{(t)}+b_{\mathrm{f}}) \tag{5}$$

式中:σ 表示 Sigmoid 函数;$\boldsymbol{U}_{\mathrm{f}}$ 为遗忘门对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{f}}$ 为遗忘门对第 t 时刻数据进行转换的矩阵;b_{f} 为遗忘门的偏置项.

输入门结果表达式 $i^{(t)}$ 为

$$i^{(t)}=\sigma(\boldsymbol{U}_{\mathrm{i}}\boldsymbol{h}^{(t-1)}+\boldsymbol{W}_{\mathrm{i}}\boldsymbol{x}^{(t)}+b_{\mathrm{i}}) \tag{6}$$

式中:$\boldsymbol{U}_{\mathrm{i}}$ 为输入门对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{i}}$ 为输入门对第 t 时刻数据进行转换的矩阵;b_{i} 为输入门的偏置项.

输出门结果表达式 $o^{(t)}$ 为

$$o^{(t)}=\sigma(\boldsymbol{U}_{\mathrm{o}}\boldsymbol{h}^{(t-1)}+\boldsymbol{W}_{\mathrm{o}}\boldsymbol{x}^{(t)}+b_{\mathrm{o}}) \tag{7}$$

式中:$\boldsymbol{U}_{\mathrm{o}}$ 为输出门对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{o}}$ 为输出门对第 t 时刻数据进行转换的矩阵;b_{o} 为输出门的偏置项.

记忆元中间结果表达式 $\tilde{c}^{(t)}$ 为

$$\tilde{c}^{(t)}=\tanh(\boldsymbol{U}_{\mathrm{c}}\boldsymbol{h}^{(t-1)}+\boldsymbol{W}_{\mathrm{c}}\boldsymbol{x}^{(t)}+b_{\mathrm{c}}) \tag{8}$$

式中:tanh 为双曲正切函数,$\boldsymbol{U}_{\mathrm{c}}$ 为输入门对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{c}}$ 为输入门对第 t 时刻数据进行转换的矩阵;b_{c} 为记忆元的偏置项.

步骤 2:通过记忆元公式计算出第 1 时刻的记忆元状态与隐藏层状态,其中记忆元状态表达式 $c^{(t)}$ 为

$$c^{(t)}=i^{(t)}\odot\tilde{c}^{(t)}+f^{(t)}\odot c^{(t-1)} \tag{9}$$

隐藏层状态表达式 $\boldsymbol{h}^{(t)}$ 为

$$\boldsymbol{h}^{(t)}=o^{(t)}\odot\tanh(c^{(t)}) \tag{10}$$

以此类推,可计算得到第 t 时刻隐藏层状态 $\boldsymbol{h}^{(t)}$.

步骤 3:将 $\boldsymbol{h}^{(t)}$ 最后 1 个时间步对应数据代入式(4)进行线性转换,所得 $o^{(t)}$ 为对第 t 时刻的预测结果.

2.1.3　GRU

GRU 结构由更新门和重置门组成,如图 5 所示.

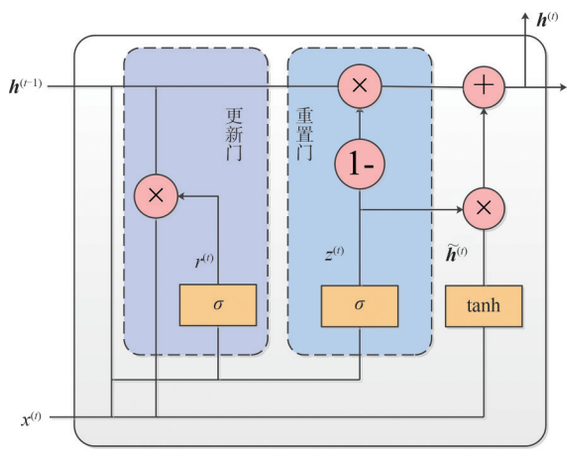


图 5　GRU 结构示意图

Fig. 5　GRU architecture

图 5 中,重置门用于决定是否忽略过去的信息,更新门用于控制新旧信息的融合比例.计算过程包括 3 个步骤.

步骤 1:通过第 1 时刻数据 $x^{(1)}$ 和初始化隐藏层状态 $\boldsymbol{h}^{(0)}$(为随机矩阵)计算得到第 1 时刻重置门结果 $r^{(1)}$、更新门结果 $z^{(1)}$、隐藏层中间结果 $\tilde{\boldsymbol{h}}^{(1)}$.

其中重置门结果表达式 $r^{(t)}$ 为

$$r^{(t)}=\sigma(\boldsymbol{U}_{\mathrm{r}}\boldsymbol{h}^{(t-1)}+\boldsymbol{W}_{\mathrm{r}}\boldsymbol{x}^{(t)}+b_{\mathrm{r}}) \tag{11}$$

式中:$\boldsymbol{U}_{\mathrm{r}}$ 为重置门对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{r}}$ 为重置门对第 t 时刻数据进行转换的矩阵;b_{r} 为重置门的偏置项.

更新门结果表达式 $z^{(t)}$ 为

$$z^{(t)}=\sigma(\boldsymbol{U}_{\mathrm{z}}\boldsymbol{h}^{(t-1)}+\boldsymbol{W}_{\mathrm{z}}\boldsymbol{x}^{(t)}+b_{\mathrm{z}}) \tag{12}$$

式中:$\boldsymbol{U}_{\mathrm{z}}$ 为更新门对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{z}}$ 为更新门对第 t 时刻数据进行转换的矩阵;b_{z} 为更新门的偏置项.

隐藏层中间结果表达式 $\tilde{\boldsymbol{h}}^{(t)}$ 为

$$\tilde{\boldsymbol{h}}^{(t)}=\tanh(\boldsymbol{U}_{\mathrm{h}}(\boldsymbol{r}^{(t)}\odot\boldsymbol{h}^{(t-1)})+\boldsymbol{W}_{\mathrm{h}}\boldsymbol{x}^{(t)}+b_{\mathrm{h}}) \tag{13}$$

式中:$\boldsymbol{U}_{\mathrm{h}}$ 为隐藏层对第 $t-1$ 时刻隐藏层状态进行转换的矩阵;$\boldsymbol{W}_{\mathrm{h}}$ 为隐藏层对第 t 时刻数据进行转换的矩阵;b_{h} 为隐藏层的偏置项.

隐藏门结果表达式 $\boldsymbol{h}^{(t)}$ 为

$$\boldsymbol{h}^{(t)}=(1-z^{(t)})\odot\tilde{\boldsymbol{h}}^{(t)}+z^{(t)}\odot\boldsymbol{h}^{(t-1)} \tag{14}$$

步骤 2：以此类推，计算得到第 t 时刻隐藏层状态 $\boldsymbol{h}^{(t)}$.

步骤 3：将 $\boldsymbol{h}^{(t)}$ 最后 1 个时间步对应数据进行线性转换，所得 $o^{(t)}$ 为第 t 时刻预测结果.

2.1.4 损失函数与优化器

在训练 RNN、LSTM、GRU 的过程中，利用均方误差（Mean Squared Error，MSE）衡量 TQI 预测值与真实值的偏差，利用 Adam[25] 算法优化模型参数，直至 MSE 达到阈值或达到预设训练次数，MSE 为

$$\mathrm{MSE}=\frac{1}{n}\sum_{j=1}^{n}(y_j-\hat{y}_j)^2 \tag{15}$$

2.2 非时序模型

2.2.1 MLP

MLP 模型结构如图 6 所示.

图 6 中：MLP 模型由 1 个输入层、1 个隐藏层、1 个输出层组成，计算过程包括两个步骤.

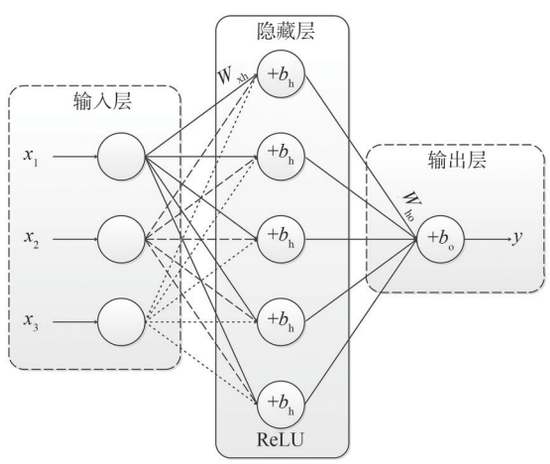


图 6 MLP 结构示意图

Fig. 6 MLP architecture

步骤 1：通过输入层的 x_i 组成的输入矩阵 $\boldsymbol{X}$ 计算得到每个隐藏层节点的输出，隐藏层节点 h_m 表达式为

$$h_m=\mathrm{ReLU}(\boldsymbol{W}_{\mathrm{xh}}\boldsymbol{X}+b_h) \tag{16}$$

式中：ReLU（Rectified Linear Unit）为线性整流函数；$\boldsymbol{W}_{\mathrm{xh}}$ 为输入层至隐藏层的权重.

步骤 2：通过 h_m 组成的矩阵 $\boldsymbol{H}$ 计算得到预测结果，输出层节点表达式 y 为

$$y=\boldsymbol{W}_{\mathrm{ho}}\boldsymbol{H}+b_o \tag{17}$$

式中：$\boldsymbol{W}_{\mathrm{ho}}$ 分别为隐藏层至输出层的权重；b_{o} 为输出层的偏置项.

2.2.2 SVM

SVM 通过建立第 j 个样本输入变量 x_j 与预测值 $\hat{y}_j$ 的关系，表达式为

$$\hat{y}_j=\boldsymbol{w}^{\mathrm{T}}x_j+b \tag{18}$$

式中：$\hat{y}_j$ 为第 j 个样本的预测值；$\boldsymbol{w}^{\mathrm{T}}$ 为权重向量；x_j 为第 j 个样本的输入数据；b 为偏置项.

在建模过程中，SVM 会通过损失函数寻找超平面，使尽可能多的预测值 $\hat{y}_j$ 与真实值 y_j 之差落在阈值 ε 之内，超出 ε 的偏差用于优化模型参数，优化目标表达式为

$$\min_{\boldsymbol{w},b,\xi,\xi^*} Z=\left[\frac{1}{2}\|\boldsymbol{w}\|^2+C\sum_{i=1}^{n}(\xi_j+\xi_j^*)\right] \tag{19}$$

式中：Z 为 SVM 模型的优化目标；$\|\boldsymbol{w}\|^2$ 为权重向量的 L_2 范数；C 为惩罚系数，用于平衡模型复杂度和训练误差；ξ_j 和 ξ_j^* 为松弛变量.

模型约束表达式为

$$\text{s.t.}\begin{cases} y_j-(\boldsymbol{w}^{\mathrm{T}}x_j+b)\leqslant\varepsilon+\xi_j \\ (\boldsymbol{w}^{\mathrm{T}}x_j+b)-y_j\leqslant\varepsilon+\xi_j^* \\ \xi_j\geqslant 0 \\ \xi_j^*\geqslant 0 \end{cases} \tag{20}$$

式中：ε 为真实值与预测值允许偏差的阈值.

2.2.3 线性回归

线性回归利用式（18）建立第 j 个样本输入变量 x_j 与预测值 $\hat{y}_j$ 的关系，以式（15）优化模型参数.

3 重载铁路 TQI 预测结果分析

3.1 模型超参数优化

3.1.1 时序模型超参数优化

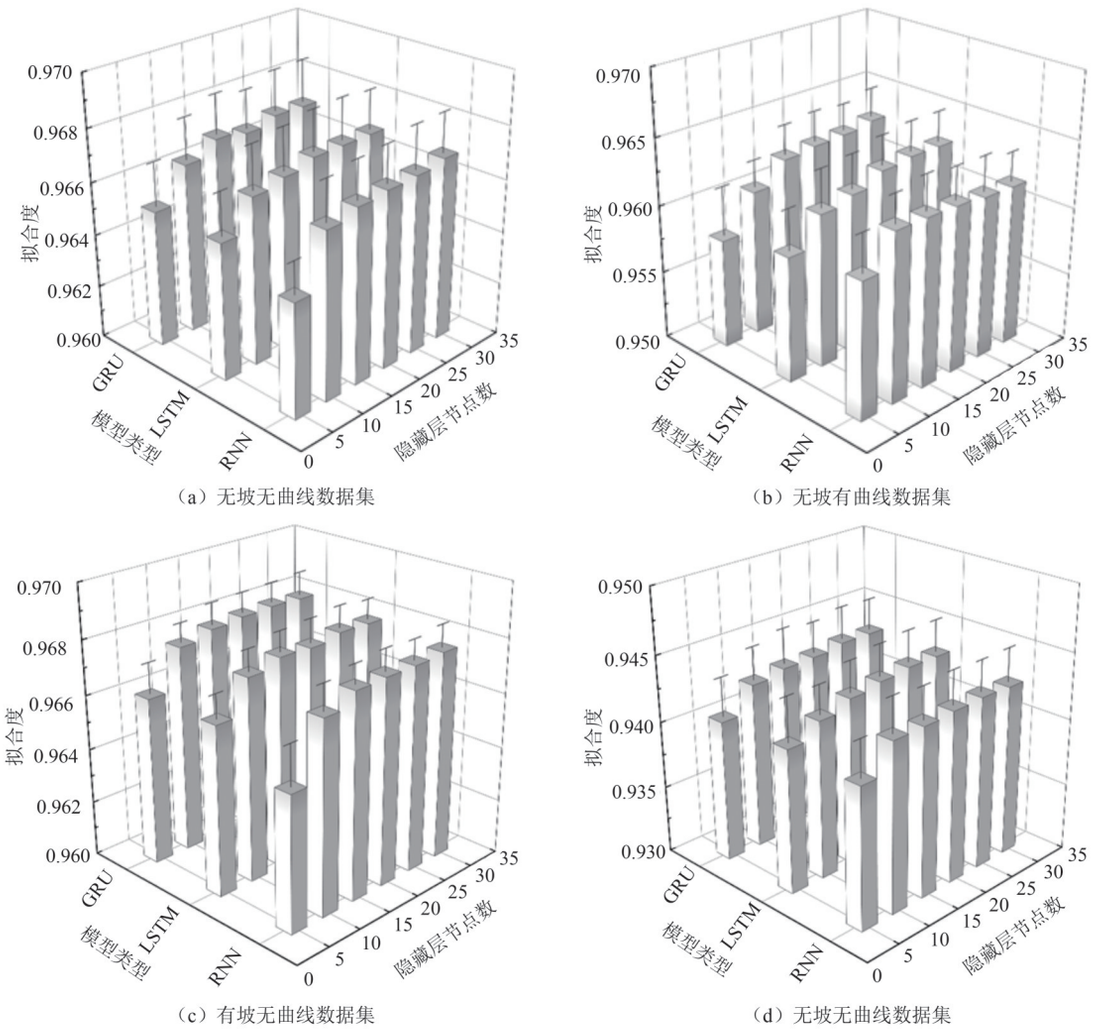
时序模型预测结果对比情况如图 7 所示.

由图 7 可知：对于时序模型，隐藏层节点数对模型的拟合精度有较大影响；随着节点数的增加，4 类数据集的真实 TQI 与预测 TQI 拟合度先提升后略微下降，说明当隐藏层节点数过少时，3 个时序模型均出现欠拟合问题，模型拟合能力较差，而当隐藏层节点数过多时，会出现过拟合问题，使拟合效果变差；当 3 个模型隐藏层节点数为 15～30 时，对无坡无曲线、无坡有曲线、有坡无曲线 3 类数据集 TQI 的预测拟合度均超过 0.96，对有坡有曲线数据集 TQI 的预测拟合度均超过 0.94，拟合效果较好.

另外，LSTM 和 GRU 对于 4 种数据集的预测结果相较于 RNN 并未表现出更优的性能，LSTM 和 GRU 的提出主要用于解决 RNN 的长期依赖问题，即 RNN 难以利用较远时间步的输入信息，导致梯度消失或爆炸. 使用前 2 个月的数据预测第 3 个月的 TQI，不涉及长期依赖问题，RNN 更为简洁的结构反而减少了过拟合风险，使拟合效果更优.

3.1.2 MLP 超参数优化

MLP 超参数优化结果中 4 种数据集真实 TQI



（a）无坡无曲线数据集　（b）无坡有曲线数据集

（c）有坡无曲线数据集　（d）无坡无曲线数据集

图 7　真实 TQI 与预测 TQI 的拟合度随模型类型、隐藏层节点数的变化

Fig. 7　Variation in the goodness of fit between the actual and predicted TQI with respect to model type and the number of hidden layer nodes

与预测 TQI 拟合度随 MLP 隐藏层节点数变化的情况如图 8 所示.

由图 8 可知,当隐藏层节点数为 15 时,4 种数据集的拟合度均为最高.对于无坡无曲线数据集,10 次测试拟合度的标准差较小,说明无坡无曲线区段轨道几何劣化本身的不确定性较小;对于另外 3 种数据集,拟合度的标准差相对较大,可归结于劣化本身的不确定性较大.

3.1.3　SVM 超参数优化

SVM 超参数优化结果中惩罚系数 C 与拟合度对比情况如图 9 所示.

由图 9 可知,4 类数据集中真实 TQI 和预测 TQI 的拟合度随着 C 的增大而提高,说明模型的预测性能逐步提升.

3.2　TQI 预测效果分析

以 RNN 预测结果为例,首先对 10 个测试集的

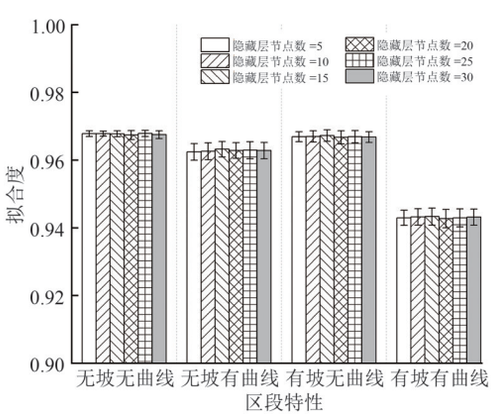


图 8　真实 TQI 与预测 TQI 拟合度随 MLP 隐藏层节点数的变化

Fig. 8　Variation in the goodness of fit between the actual and predicted TQI with respect to the number of hidden layer nodes in the MLP

TQI 真实值与预测值进行对比,展示整体预测效果;然后,给出不同方法的最佳拟合度参数及其拟合效

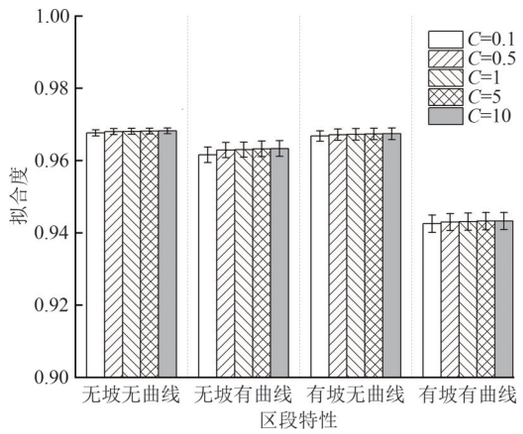


图9 真实TQI与预测TQI拟合度随SVM惩罚系数C的变化

Fig. 9 Variation in the goodness of fit between the actual and predicted TQI with respect to the SVM penalty coefficient C

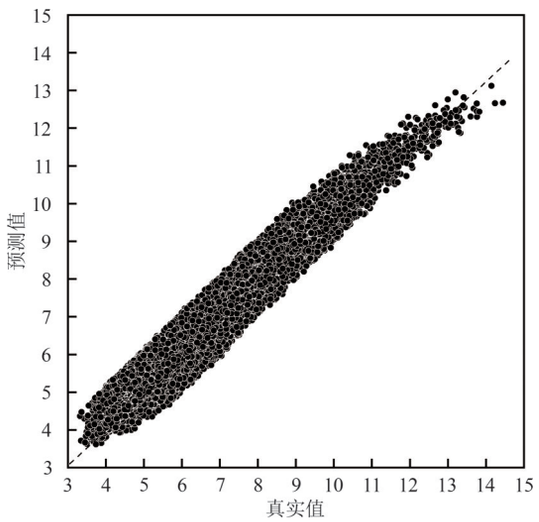


图10 10个测试集中真实TQI与预测TQI的对比

Fig. 10 Comparison between actual and predicted TQI across 10 test sets

果并展开分析;最后,给出案例中某一典型区段在研究周期内TQI真实值与预测值的对比情况,分析提出方法在实际铁路运营场景下的应用效果.

3.2.1 RNN预测TQI与实际TQI对比分析

通过对大规模数据的分析建模,得到10个测试集TQI真实值与预测值的对比情况,如图10所示.

由图10可知:TQI真实值和预测值较均匀地分布在对角线($y=x$函数)附近,说明预测值与实际值较为接近;RNN预测得到的10个测试集平均拟合度为0.967 5,测试集间的拟合度标准差为±0.000 8;当TQI分布在3~12的范围时,点较为均匀地分布于$y=x$函数附近,预测结果较为准确;当TQI大于12时,图10中的点主要分布于$y=x$函数下方,说明在该区间内预测值略小于真实值.产生这种现象的原因是较大的TQI通常表明轨道几何状态不佳,存在轨道磨损、路基沉降等现象,复杂的轨道质量情况会导致预测难度加大,未来有必要针对这类情况改进现有方法.通过对轨道分类的RNN方法预测得到的平均拟合度与类似轨道TQI预测研究[8-10]中的结果进行对比,预测性能有了较大提升,证明了提出方法的有效性.

3.2.2 机器学习方法预测TQI参数对比分析

时序模型与非时序模型的最优预测结果及对应参数如表1所示.

表1 最佳拟合度

Tab. 1 Optimal coefficient of determination

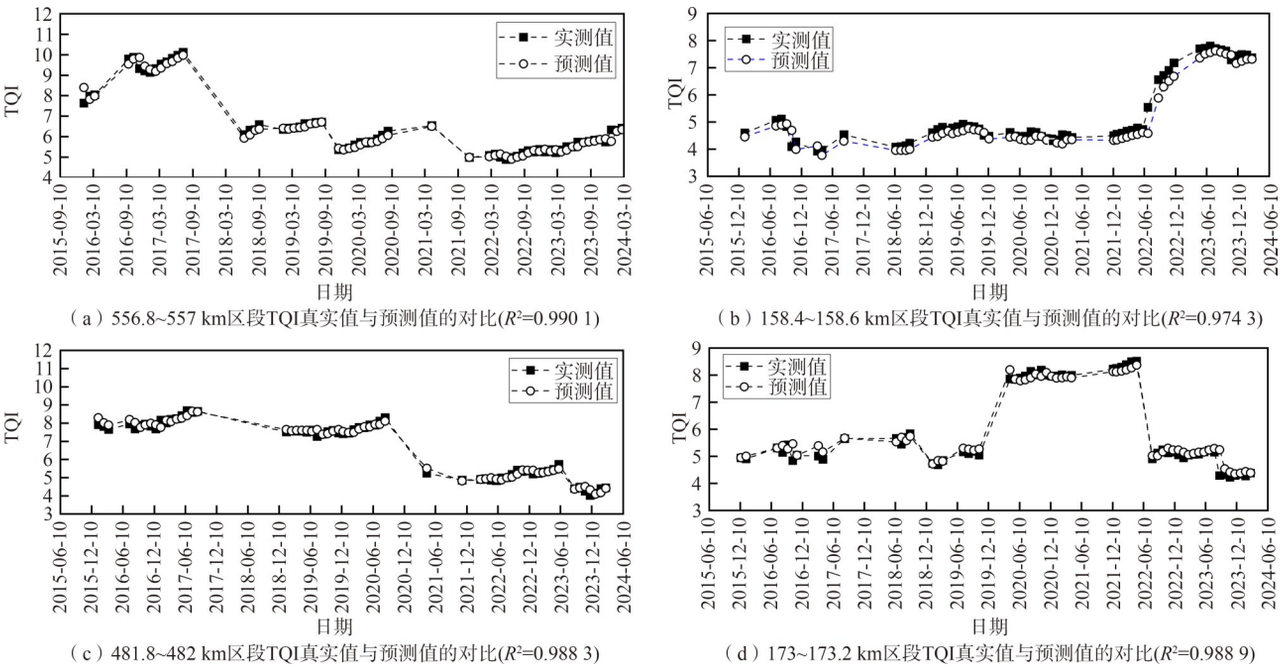
最佳拟合度	时序模型			非时序模型		
	RNN	LSTM	GRU	MLP	SVM (C=10)	线性回归
无坡无曲线	0.967 6±0.000 8 (隐藏层节点数=30)	0.967 9±0.000 8 (隐藏层节点数=25)	0.968 0±0.000 7 (隐藏层节点数=25)	0.967 9±0.000 9 (隐藏层节点数=25)	0.967 9±0.000 9	0.968 1±0.000 8
无坡有曲线	0.962 4±0.002 1 (隐藏层节点数=10)	0.962 9±0.002 3 (隐藏层节点数=25)	0.963 0±0.002 2 (隐藏层节点数=30)	0.963 2±0.002 3 (隐藏层节点数=15)	0.963 2±0.002 3	0.963 4±0.002 3
有坡无曲线	0.967 0±0.001 5 (隐藏层节点数=30)	0.966 9±0.001 5 (隐藏层节点数=25)	0.967 1±0.001 6 (隐藏层节点数=25)	0.967 2±0.001 7 (隐藏层节点数=15)	0.967 2±0.001 7	0.967 3±0.001 7
有坡有曲线	0.942 9±0.002 3 (隐藏层节点数=25)	0.943 2±0.002 4 (隐藏层节点数=25)	0.943 2±0.002 5 (隐藏层节点数=25)	0.943 2±0.002 5 (隐藏层节点数=15)	0.943 2±0.002 5	0.943 5±0.002 4

由表1可知:横向对比不同模型预测结果,本次研究不同模型的预测结果较为接近,不存在显著差异;纵向对比不同区段的预测结果,当区段中同时存在坡道和曲线时,所有模型的预测性能较其他情况有明显下降;在未来的研究中,可以考虑针对有坡有曲线区段进行改进.

3.2.3 典型区段预测结果对比分析

RNN在4类区段中预测值与实际值的对比情况,如图11所示.

由图11可知:真实值和RNN预测值的走势一致且基本吻合;从统计维度来看,无坡无曲线、无坡有曲线、有坡无曲线和有坡有曲线的拟合度分



（a）556.8~557 km区段TQI真实值与预测值的对比(R^2=0.990 1)　（b）158.4~158.6 km区段TQI真实值与预测值的对比(R^2=0.974 3)

（c）481.8~482 km区段TQI真实值与预测值的对比(R^2=0.988 3)　（d）173~173.2 km区段TQI真实值与预测值的对比(R^2=0.988 9)

图 11　4类典型区段 TQI 真实值与预测值的对比

Fig. 11　Comparison between the actual and predicted TQI across four typical track sections

别为 0.990 1、0.974 3、0.988 3 和 0.988 9，预测结果准确.

不同方法在典型区段中的预测结果拟合度对比情况如表 2 所示.

表 2　4类铁路区段的拟合度(R^2)

Tab. 2　Coefficient of determination (R^2) for four types of railway sections

拟合度 R^2	RNN	LSTM	GRU	MLP	SVM	线性回归
无坡无曲线 556.8~557 km	0.990 1	0.988 7	0.987 7	0.981 2	0.991 1	0.991 2
无坡有曲线 158.4~158.6 km	0.974 3	0.980 3	0.976 1	0.978 9	0.981 6	0.982 6
有坡无曲线 481.8~482 km	0.988 3	0.987 4	0.981 2	0.986 4	0.989 1	0.981 4
有坡有曲线 173~173.2 km	0.988 9	0.983 5	0.982 5	0.983 6	0.979 2	0.976 5

由表 2 可知，对于 4 种典型的区段，RNN 方法相比于其他方法有两点优势：预测性能优异，RNN 模型对 4 种典型区段的平均 R^2 位居第一；RNN 更加适应有坡有曲线区段的预测场景，由于有坡有曲线区段中铁路轨道情况较为复杂，因此预测难度更大，此时 RNN 相比于其他方法的预测结果更加准确.

4　结论

1）通过对 6 种预测方法在 TQI 预测中的对比分析发现，当训练数据量充足时，各方法均表现出优异的预测性能，拟合度 R^2 均高于 0.94，能够有效满足重载铁路现场实际生产对 TQI 预测的精度要求.

2）通过对不同方法进行对比，发现 RNN 对于不同类型区段的预测结果较为稳定，在特定区段平均拟合度为 0.985 4，对于有坡有曲线的区段拟合度达到 0.988 9，预测结果优秀.在实际工作中，可依据 RNN 预测结果，制订更为科学合理的工务检修计划方案.

3）对于所有预测方法，有坡有曲线的预测结果相比于另外 3 种区段类型存在一定的差距.产生该情况的原因为同时存在坡道和曲线时区段中重载轨道结构情况较为复杂，在物理层面会根据实际情况产生更多的变化.

在未来的研究中，将针对重载铁路的独特性强化相关机器学习方法，特别是细化重载铁路运输中有坡有曲线这一场景的 TQI 预测问题研究，开展包括有坡有曲线重载铁路轨道特性和机器学习参数选取方法的研究，构建考虑数据特异性的预测模型，提高模型的识别准确性.

参考文献(References)：

[1] SUAREZ B, FELEZ J, ANTONIO LOZANO J, et al. Influence of the track quality and of the properties of the wheel-rail rolling contact on vehicle dynamics[J]. Vehicle System Dynamics, 2013, 51(2): 301－320.

[2] JOVANOVIC S, GULER H, COKO B. Track degrada-

tion analysis in the scope of railway infrastructure maintenance management systems[J]. Gradevinar, 2015, 67(3): 247－258.

[3] GULER H, JOVANOVIC S, EVREN G. Modelling railway track geometry deterioration[J]. Proceedings of the Institution of Civil Engineers-Transport, 2011, 164(2): 65－75.

[4] KHOUZANI A H E, GOLROO A, BAGHERI M. Railway maintenance management using a stochastic geometrical degradation model[J]. Journal of Transportation Engineering, Part A: Systems, 2017, 143: 04016002.

[5] CHAROENWONG C, CONNOLLY D P, WOODWARD P K, et al. Analytical forecasting of long-term railway track settlement[J]. Computers and Geotechnics, 2022, 143: 104601.

[6] 常欢, 刘仍奎, 方圆. 改进的轨道质量指数线性预测模型研究[J]. 铁路计算机应用, 2010, 19(6): 1－3.
CHANG Huan, LIU Rengkui, FANG Yuan. Research of improved linear prediction model of Track Quality Index[J]. Railway Computer Application, 2010, 19(6): 1－3. (in Chinese)

[7] KASHANI H F, HYSLIP J P. Ballast life and effective parameters [C]// 2018 Joint Rail Conference. Pittsburgh, 2018: V001T01A02-V001T01A02.

[8] VEIT P, MARSCHNIG S. Sustainability in track: A precondition for high speed traffic[C]//2010 Joint Rail Conference. Brooklyn, 2010: 349－355.

[9] 谭社会, 毛晓君. 基于转换矩阵的新建无砟高铁动静态轨道质量指数关系研究[J]. 铁道科学与工程学报, 2016, 13(9): 1674－1680.
TAN Shehui, MAO Xiaojun. Research on transfer matrix between dynamic and static track quality index in newly-build ballastless track of high-speed railway[J]. Journal of Railway Science and Engineering, 2016, 13(9): 1674－1680. (in Chinese)

[10] 王英杰, 楚杭, 时瑾, 等. 基于改进非等时距灰色模型与PSO优化的轨道不平顺预测[J]. 铁道科学与工程学报, 2023, 20(5): 1636－1644.
WANG Yingjie, CHU Hang, SHI Jin, et al. Prediction of track irregularity based on improved non-equal interval grey model and PSO optimization[J]. Journal of Railway Science and Engineering, 2023, 20(5): 1636－1644. (in Chinese)

[11] LIU Y, LIU J Z, ZHANG W X, et al. Few-shot outliers classification in high-speed railway track geometry based on self-supervised transformer[J]. Applied Soft Computing, 2025, 178: 113281.

[12] JIN Z H, ZHANG W, YIN Z Y, et al. Estimating track geometry irregularities from in-service train accelerations using deep learning[J]. Automation in Construction, 2025, 173: 106114.

[13] 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.
LI Lu, LI Chenzhong, WANG Ping, et al. Research on estimating lateral car-body acceleration with track irregularity based on deep learning[J]. Journal of Beijing Jiaotong University, 2023, 47(4): 103－109. (in Chinese)

[14] 曹雨欣, 徐鹏, 杨雅琴, 等. 动态检测数据驱动的高速铁路有砟轨道几何不平顺超限大值预警方法[J]. 铁道建筑, 2023, 63(3): 23－29.
CAO Yuxin, XU Peng, YANG Yaqin, et al. A large value warning method for geometric irregularity overrun in ballast track of high speed railway driven by dynamic inspection data[J]. Railway Engineering, 2023, 63(3): 23－29. (in Chinese)

[15] 王晟由, 邵春福, 董春娇, 等. 基于GPS轨迹数据的货车交通流量需求预测循环神经网络模型[J]. 北京交通大学学报, 2021, 45(3): 15－23.
WANG Shengyou, SHAO Chunfu, DONG Chunjiao, et al. Recurrent neural network model for truck traffic flow demand prediction based on GPS trajectory data[J]. Journal of Beijing Jiaotong University, 2021, 45(3): 15－23. (in Chinese)

[16] HAN L, LIAO Y Y, WANG H Y, et al. Long-term prediction for railway track geometry based on an optimised DNN method[J]. Construction and Building Materials, 2023, 401: 132687.

[17] 王辉, 宋瑞, 何维, 等. 基于CNN-GRU-Attention模型的铁路集装箱运输时间预测[J]. 北京交通大学学报, 2025, 49(4): 115－121.
WANG Hui, SONG Rui, HE Wei, et al. Railway container transportation time prediction based on CNN-GRU-Attention model[J]. Journal of Beijing Jiaotong University, 2025, 49(4): 115－121. (in Chinese)

[18] 于瑶, 刘仍奎, 王福田. 基于支持向量机的轨道不平顺预测研究[J]. 铁道科学与工程学报, 2018, 15(7): 1671－1677.
YU Yao, LIU Rengkui, WANG Futian. Prediction for track Irregularity based on support vector machine[J]. Journal of Railway Science and Engineering, 2018, 15(7): 1671－1677. (in Chinese)

[19] 马子骥, 郭帅锋, 李元良. 基于改进非等间距灰色模型和PSVM的轨道质量指数预测[J]. 铁道学报, 2018, 40(6): 154－160.
MA Ziji, GUO Shuaifeng, LI Yuanliang. Forecasting of track irregularity based on improved non-equal interval grey model and PSVM[J]. Journal of the China Railway Society, 2018, 40(6): 154－160. (in Chinese)

[20] GULER H. Prediction of railway track geometry deterioration using artificial neural networks: A case study for Turkish state railways[J]. Structure and Infrastructure Engineering, 2014, 10(5): 614－626.

[21] 邓逸帆, 李宵楠, 李政, 等. 基于马尔可夫残差修正灰色模型的轨道质量指数及其分项预测[J]. 铁道建筑, 2024, 64(6): 37－42.
DENG Yifan, LI Xiaonan, LI Zheng, et al. Track quality index and its sub items prediction based on Markov residual corrected grey model[J]. Railway Engineering, 2024, 64(6): 37－42.(in Chinese)

[22] 龙亦语, 曲建军, 刘攀, 等. 重载铁路轨道大机捣固月度维修计划经济决策方法[J]. 铁道建筑, 2025, 65(9): 1－6.
LONG Yiyu, QU Jianjun, LIU Pan, et al. Economic decision-making method for monthly maintenance plan of track large machinery tamping of heavy haul railway[J]. Railway Engineering, 2025, 65(9): 1－6.(in Chinese)

[23] 中国铁路总公司. 铁路技术管理规程: TG/01A—2017[S]. 北京: 中国铁道出版社, 2017.
China Railway. Technical management rules of railway: TG/01A—2017[S]. Beijing: China Railway Publishing House, 2017.(in Chinese)

[24] GOODARZI S, KASHANI H F, OKE J, et al. Data-driven methods to predict track degradation: A case study[J]. Construction and Building Materials, 2022, 344: 128166.

[25] DIEDERIK P K, JIMMY L B. Adam: A Method For Stochastic Optimization[C]// 3rd International Conference on Learning Representations. San Diego, 2015: 1－15.