基于多层振动特征与残差学习的隧道底部上拱识别

闫子权[1,2]，李中奇[3]，郭文杰[3]，孙林林[1,2]，曾鑫[3]

（1. 中国铁道科学研究院集团有限公司铁道建筑研究所，北京 100081；2. 高速铁路轨道系统全国重点实验室，北京 100081；3. 山区土木工程安全与韧性全国重点实验室，江西 南昌 330013）

摘要：针对隧道底部上拱通过轨面几何变形与层间支承变化影响振动传递的问题，提出了基于多层振动特征与残差学习的隧道底部上拱识别方法。首先，沿钢轨至围岩的竖向传递路径，将六层振动级及两侧相邻级差组织为三通道输入，并融合道床板谱峰、频带占比与运行工况，联合表征单层量级和层间相对响应；其次，构建固定岭回归与 CNN–BiLSTM 相结合的残差学习模型，以正则化线性估计拟合总体关系，由神经网络学习剩余偏差，实现轨面等效上拱量连续反演；最后，将连续输出映射为病害等级，并对同组重复记录的预测取平均，联合评价反演精度与状态识别效果。实验结果表明，在 1 000 组、5 000 条合成特征记录的分组验证中，上拱约 20 mm 时，道床板与仰拱填充层加速度均方值分别达到正常工况的约 5.1 倍和 7.8 倍；本文方法在 750 条测试记录上的均方根误差为 0.6203 mm，较岭回归降低 2.62%，分级准确率为 91.60%；同组 5 条记录平均后，150 组预测的均方根误差为 0.3896 mm，分级准确率为 95.33%。该方法可为同类轨道结构的上拱程度识别与重复观测状态评估提供依据。

关键词：高速铁路；隧道底部上拱；振动响应；卷积神经网络；残差学习；病害识别

中图分类号：U231.3；U451　　**文献标志码：**A

Identification of Tunnel Bottom Heave Using Multilayer Vibration Features and Residual Learning

Yan Ziquan[1,2], Li Zhongqi[3], Guo Wenjie[3], Sun Linlin[1,2], Zeng Xin[3]

(1. Railway Engineering Research Institute, China Academy of Railway Sciences Corporation Limited, Beijing 100081, China; 2. State Key Laboratory of High Speed Railway Track System, Beijing 100081, China; 3. State Key Laboratory of Performance Monitoring and Protecting of Rail Transit Infrastructure, East China Jiaotong University, Nanchang 330013, China)

Abstract: Tunnel bottom heave affects vibration transmission through changes in track geometry and interlayer support, and multilayer vibration responses provide observations for identifying defect severity in high-speed railway tunnels. First, vibration levels at six structural layers from the rail to the surrounding rock and adjacent-level differences on both sides are organized as three-channel inputs, together with the track-slab spectral peak, frequency-band ratios and operating conditions, to represent individual-layer magnitudes and relative interlayer responses; second, a residual learning model combining fixed ridge regression and a CNN–BiLSTM network is developed to estimate the overall linear relationship and its remaining deviations, respectively, yielding continuous estimates of equivalent rail-surface uplift; finally, the continuous outputs are mapped to damage grades and predictions from repeated records within each group are averaged to evaluate estimation accuracy and condition identification. Experimental results show that, in grouped validation using 5,000 synthetic feature records from 1,000 groups, the mean-square accelerations of the track slab and invert filling layer at approximately 20 mm heave reach approximately 5.1 and 7.8 times their normal-condition values, respectively; on 750 test records, the proposed method achieves a root mean square error of 0.6203 mm, a 2.62% reduction relative to ridge regression, and a grading accuracy of 91.60%; averaging five records within each group yields a root mean square error of 0.3896 mm and a grading accuracy of 95.33% across 150 test groups. The method supports heave identification and condition assessment using repeated observations for comparable track structures.

Key words: high-speed railway; tunnel bottom heave; vibration response; convolutional neural network; residual learning; damage identification

收稿日期：2026-10-10

基金项目：江西省自然科学基金(20242BAB20234)

高速铁路隧道底部上拱是影响无砟轨道服役状态的重要病害。围岩及下部支承结构的隆起可向轨道系统传递，引起轨面高程变化、道床板抬升、层间离缝和局部支承削弱，进而改变轮轨作用及基础设施动力响应[1-3]。这类病害既涉及可测的轨道几何变形，也涉及埋置结构内部的接触状态变化，仅凭轨面变形难以完整描述下部支承的动力特征。与此同时，运营隧道的检测受到作业空间、列车运行及维修天窗的限制，需要利用可连续采集的响应信息辅助病害评估。列车通过时，振动沿钢轨、轨枕、道床板、仰拱填充层、仰拱和围岩逐层传递，层间支承变化会同时影响响应幅值、频率分布及相邻层的相对振动。因而，将结构动力分析与多层振动特征识别相结合，建立响应变化与上拱程度之间的定量关系，是隧道隐蔽病害监测与维修决策的重要研究内容。

围绕底部上拱的形成、变形传递及动力影响，已有研究形成了较为系统的认识。在病害成因与整治方面，范胜元等[4]通过现场病害调查与室内试验，分析了基岩遇水膨胀、局部应力集中及结构受力不均对仰拱抬升和开裂的作用，并结合接触应力监测评估整治效果。刘景宇等[5]研究了高速铁路地基泥岩膨胀变形的计算方法，邓逆涛等[6]探讨了含黄铁矿填料的路基上拱特性与机理，肖小文等[7]分析了高地应力互层岩体中的隧底隆起问题。这些工作从岩土材料、应力条件及结构约束等角度解释了上拱来源，为确定病害的几何和支承变化提供了依据。在动力响应方面，王景春等[8]考察了围岩与衬砌劣化对隧道底部结构的影响，李谷等[9]研究了典型轨道病害下的轮轨力响应，晏兆晋等[10]分析了周期性短波病害对应的车辆响应时频特征，程建军等[11]讨论了地基膨胀引起的轨道上拱响应。Du 等[12]结合现场测试与数值分析研究了初始损伤隧底结构的动力响应及裂纹扩展，强调了下部结构损伤状态与动力作用的联系；Auersch[13]通过车辆、轨道与地基同步振动测试，考察了不同线路结构的响应及传递特征。刘庆杰等[14]的地铁车辆段试车线实测表明，车速与轨道形式均影响振动级和振动传递，说明响应分析应同时考虑运行条件与支承形式。车辆—轨道耦合动力学[15-16]及轨道交通引起的地面振动分析框架[17]，进一步为描述激励输入、结构相互作用和向下传递过程提供了基础。上述研究表明，病害几何与支承状态均应纳入动力分析；面向状态识别，还需要把各结构层的响应变化转化为能够共同表征上拱程度的输入特征。

在振动识别方法方面，研究逐渐从预先选取特征并建立统计映射，发展到利用神经网络联合提取特征与判别结构状态。Abdeljaber 等[18]采用一维卷积神经网络直接处理加速度信号，在看台模拟结构上验证了损伤检测与定位方法；Liu 等[19]将传递率函数与一维卷积网络结合，在结构健康监测基准模型上开展损伤识别，说明测点间响应关系能够为特征组织提供依据。在轨道病害识别中，Yin 等[20]结合轴箱加速度时频表示与卷积网络识别轨道缺陷，体现了将响应特征与具体监测位置相联系的建模方式。卷积网络通过局部连接与参数共享提取相邻输入的组合特征[21]；长短期记忆网络通过门控机制处理序列关联[22]，双向循环结构则利用序列两个方向的信息[23]，注意力机制为不同位置的表示分配权重[24]。这些技术为多层结构振动特征的联合建模提供了可用工具，但应用效果取决于序列位置的物理含义及学习目标的设置。对于由振动级、相邻级差和频率指标组成的汇总特征，相邻级差由振动级导出，输入具有相关性；岭回归通过正则化处理共线性，为拟合总体变化关系提供了基础[25]。另一方面，物理信息神经网络将控制方程残差引入训练目标[26]，体现了利用结构知识约束数据建模的思路。Wang 等[27]研究了物理引导残差神经网络的结构损伤识别，Lei 等[28]进一步结合模态降阶与物理引导学习开展大型结构损伤识别，说明输入表示和约束形式应与可获得的结构信息相适应。由此，振动识别中的结构信息既可用于选择输入和规定其排列方式，也可用于设计预测关系，需要结合数据形式与具体识别任务确定实现方式。

现有研究已揭示底部上拱的变形传递与局部动力影响，并形成了利用振动信号识别结构状态的方法。面向多层轨道基础设施，上拱识别需要进一步处理两个问题：一是将单层响应量级与相邻层相对变化共同纳入输入，使特征组织对应实际传递路径；二是处理振动级与其导出级差之间的相关性，并利用非线性模型修正多变量线性估计的剩余偏差。本文将响应分析用于确定敏感层位和特征含义，以六层振动级及相邻级差描述竖向响应分布；在固定岭回归估计上训练神经网络残差分支，并结合运行工况反演等效

上拱量。由此建立从响应规律、输入构建到连续反演及状态分级的分析过程。

本文的主要贡献为：（1）沿钢轨至围岩的竖向传递路径，将六层振动级及两侧相邻级差构成三通道结构层输入，并与道床板谱峰、敏感频带占比及运行工况联合表征病害，使单层响应量级与层间相对分布共同参与反演；（2）构建固定岭回归估计与 CNN–BiLSTM 残差修正相结合的识别模型，利用正则化线性分支拟合相关输入的总体关系，通过非线性分支学习剩余偏差，实现轨面等效上拱量的连续估计；（3）衔接连续反演、阈值分级与同组重复观测平均，在按样本编号隔离的分组验证中分别评价逐记录和逐组预测，并结合等级边界误判分析，说明重复观测对状态识别的改善及其统计含义。

1 研究对象与振动特征表征

1.1 底部上拱的几何与支承变化

研究对象为高速铁路隧道内双块式无砟轨道及其下部支承结构。沿竖向传递路径，钢轨、双块式轨枕、道床板、仰拱填充层、仰拱和隧底围岩分别记为 A1～A6 六个结构层（图 1）。各层通过扣件和接触界面连接，具有不同的质量、刚度和阻尼，承担相应的荷载传递作用。六层响应在同一断面和一致的列车通过时窗内进行比较。本文以病害传递至轨面的等效上拱量量化变形程度，测量位置、几何输入及识别目标保持一致。

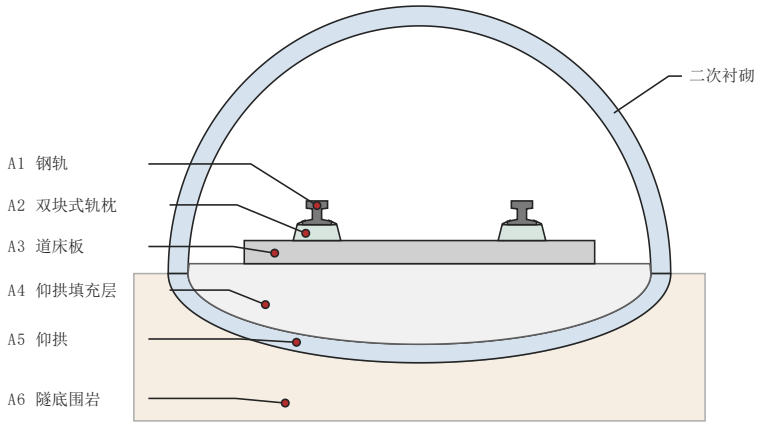

图 1 线路基础设施结构、测点与振动传递路径

Fig.1 Structural layers, monitoring points and vibration transmission paths of railway infrastructure

围岩遇水膨胀、高地应力挤压及材料劣化等因素可推动仰拱与填充层隆起[4-7]，并通过下部支承向道床板和轨面传递，形成附加几何变形、局部离缝及有效接触面积变化。本文将传递至轨面的附加位移作为病害的等效几何表征，以峰值和纵向影响长度描述变形，以局部支承刚度折减描述接触变化，力学等效见图 2。轨面竖向附加位移取半波正弦形式：

$$u_0(x)=h\sin\left(\frac{\pi x}{L}\right),\quad 0\le x\le L \tag{1}$$

式中：$u_0(x)$ 为病害引起的轨面附加竖向位移；h 为其峰值，称为轨面等效上拱量，下文简称上拱量；L 为病害纵向影响长度；x 为区段内纵向坐标；π 为圆周率。数据标签与识别输出均按这一等效几何量解释，隧底实际隆起与轨面位移之间的传递取决于中间结构及接触状态。病害区段支承刚度表示为 $k_{\mathrm{d}}=\beta k_0$，其中 k_{d} 和 k_0 分别为病害与正常支承刚度，β 为刚度折减系数，$0\le\beta\le1$。几何变形与支承变化分别进入动力分析。

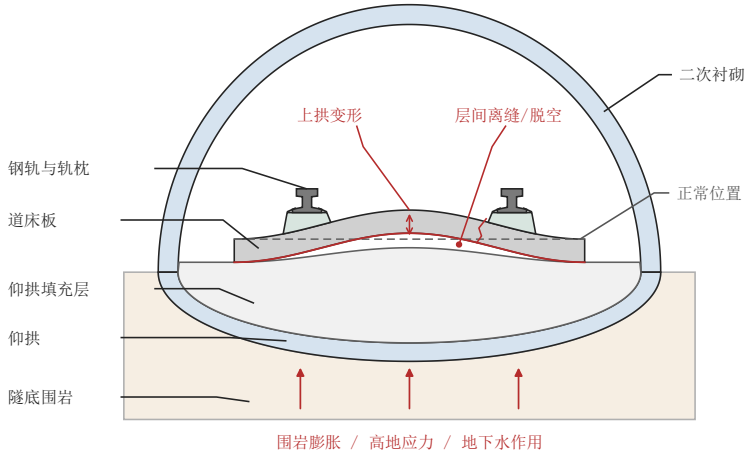

图 2 底部上拱的几何变形及局部支承变化

Fig.2 Geometric deformation and local support changes caused by tunnel bottom heave

几何变化通过轮轨相对位移影响接触力，支承变化通过结构动力特性影响响应传递。两类作用分别对应病害的变形与接触特征，可共同解释谱峰移动和局部响应放大。已有隧底振动与裂纹研究表明，仰拱及填充层是承受列车动力作用的重要部位[12]，其响应应与轨道上部结构联合分析。该等效描述面向以竖向隆起和局部支承变化为主的病害，不同成因通过变形形态、接触状态与材料参数进入分析；显著偏压、扭转及断裂后的结构响应还涉及横向与非线性接触效应。

1.2 耦合动力分析与响应比较

采用车辆—轨道—隧道—围岩竖向耦合分析框架[15-16]。车辆以多刚体系统描述，钢轨以离散扣件支承的 Euler–Bernoulli 梁描述，轨枕、道床板及下部结构采用弹性支承板或质量层表示。层间设置弹簧—阻尼单元，围岩边界采用黏弹性形式，车辆与轨道通过赫兹接触关系耦合。该框架将轮轨激励、轨道支承和隧底结构响应纳入同一动力系统，其控制方程为

$$\boldsymbol{M}\ddot{\boldsymbol{u}}+\boldsymbol{C}\dot{\boldsymbol{u}}+\boldsymbol{K}\boldsymbol{u}=\boldsymbol{F}(t) \tag{2}$$

式中：$\boldsymbol{M}$、$\boldsymbol{C}$ 和 $\boldsymbol{K}$ 分别为质量、阻尼和刚度矩阵；t 为时间，$\boldsymbol{u}$、$\dot{\boldsymbol{u}}$ 和 $\ddot{\boldsymbol{u}}$ 分别为竖向位移、速度和加速度向量；$\boldsymbol{F}(t)$ 为包含轮轨接触作用的荷载向量。采用 Newmark 法进行时间积分，并在时间步内迭代更新轮轨接触力。正常与病害工况采用一致的结构分层和响应统计方法。

响应分析分为两个层面：首先比较正常工况下各层的振动量级，确定主要衰减环节；随后考察上拱工况相对正常工况的振动级增量、谱峰变化和敏感频带响应。前者给出结构传递的基准分布，后者表征病害造成的偏离。车辆—轨道—地基同步测试研究表明，激励频率、轨道传递特性与下部介质共同影响响应[13]，因此后续识别同时保留速度、轴载荷与多层振动特征。

动力响应分析用于确定敏感层位及其特征含义，识别模型利用这些可观测特征反演式（1）定义的轨面等效上拱量。道床板与填充层的响应增量提供单层变化信息，相邻级差描述局部响应分布，谱峰和频带占比补充频域信息；速度与轴载荷用于表征共同影响响应的运行条件。刚度折减、离缝程度等病害设定参数保留在响应解释中，预测分支使用的输入均列于表 2。

1.3 振动量级、频带及层间特征

本文从信号统计意义表征振动能量响应。加速度均方值对应加速度功率谱密度在分析频段内的积分，反映给定时窗内的响应强度；其单位为加速度单位的平方。结构动能由质量与速度确定，应变能由刚度与位移确定，两者与加速度均方值具有不同的物理定义。以下采用均方值及其频带占比描述振动信号强度与频域分布，采用振动加速度级比较跨层位的响应量级。对于时窗内的离散竖向加速度，均方根值及

振动加速度级定义为

$$a_{\mathrm{RMS}}=\sqrt{\frac{1}{N_t}\sum_{q=1}^{N_t}a_q^2},\quad L_a=20\log_{10}\left(\frac{a_{\mathrm{RMS}}}{a_0}\right) \tag{3}$$

式中：a_{RMS} 为时窗内竖向加速度均方根值；L_a 为振动加速度级；N_t 为时窗内采样点数；q 为采样点序号；a_q 为第 q 个加速度样值；a_0 为基准加速度，取 $a_0=10^{-6}\,\mathrm{m/s^2}$。各层采用相同统计时窗和分析频段。下标 RMS 表示均方根。

为描述谱峰位置及中频响应，将道床板主谱峰频率记为 f_{c}，下标 c 表示特征频率；第 j 层 40～80 Hz 频带占比记为 η_j，其中 j 为结构层序号，道床板与仰拱填充层分别对应第 3、4 层。频带占比定义为

$$\eta_j=\frac{\int_{40}^{80}S_{a,j}(f)\mathrm{d}f}{\int_{\mathcal{B}}S_{a,j}(f)\mathrm{d}f},\quad j=3,4 \tag{4}$$

式中：f 为频率；$S_{a,j}(f)$ 为第 j 层加速度功率谱密度；$\mathcal{B}$ 为各工况统一采用的分析频段；$\mathrm{d}f$ 表示对频率积分。频带占比为 40～80 Hz 内加速度均方值占分析频段内总均方值的比例。第 3 节使用数据表中已有的谱峰与频带占比字段。

将第 j 层振动加速度级记为 L_j，相邻级差定义为 $D_{j,j+1}=L_j-L_{j+1}$。在相同基准加速度下，该级差为两层加速度均方根值比的对数表达，其含义是测点响应的相对量级。各层采用一致的统计时窗、分析频段和基准加速度，使级差具有可比性。振动级保留单层量级，相邻级差显式表示层间差异；两者的相关性由岭回归正则化处理，其层位关系由结构层输入保留。

2 底部上拱作用下的振动响应规律

2.1 正常工况下的层间衰减

正常工况下，六层振动加速度级由钢轨的 148.2 dB 降至隧底围岩的 88.3 dB，总级差为 59.9 dB（图 3）。钢轨、轨枕和道床板接近轮轨激励，响应量级较高；沿下部支承传递后，各层量级逐级降低。该分布用于建立正常响应基准，并与病害工况下的单层增量和相邻级差变化对应比较。

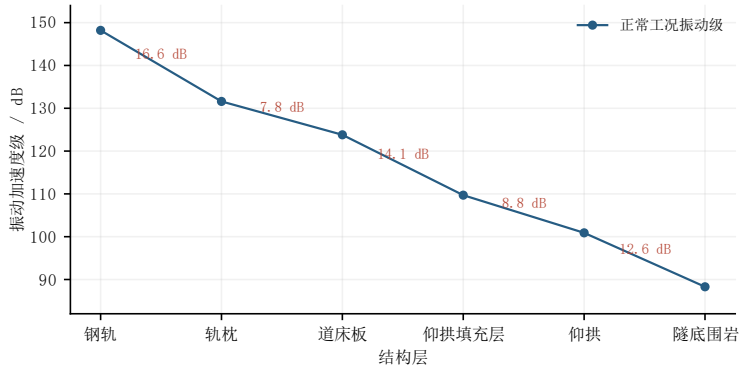

图 3 正常工况下六层结构的振动级及相邻级差

Fig.3 Vibration levels and adjacent-level differences across six structural layers under normal conditions

五组相邻级差依次为 16.6、7.8、14.1、8.8 和 12.6 dB，说明正常工况下的响应量级变化沿竖向路径分布不均。其中，钢轨—轨枕与道床板—仰拱填充层的级差分别占总级差的 27.7%和 23.5%。这些百分数描述各段对数级差的构成，耗散能量比例则需要由界面作用力及运动响应确定。相邻级差在本文中的作用是定位响应幅值变化较集中的层间位置，并为病害识别构建局部相对特征。

按振动级与均方根值的换算关系，道床板至仰拱填充层 14.1 dB 的级差对应下层加速度均方根约为上层的 19.7%；总级差 59.9 dB 对应隧底围岩均方根约为钢轨的 0.10%。均方根值比给出幅值变化，病害与正常工况的均方值比则在第 2.3 节用于量化响应强度增量，两者采用各自明确的统计含义。

2.2 上拱量与道床板谱峰变化

上拱引起轨面附加变形与局部支承变化，影响道床板响应的频率分布。针对本文双块式无砟轨道构型及所分析的竖向上拱工况，道床板主谱峰随式（1）所定义的等效上拱量增加而下移，两者的经验关系为

$$f_c \simeq 78 - 0.92h \tag{5}$$

式中：f_c 以 Hz 计，h 以 mm 计；78 Hz 为当前结构正常基准对应的经验截距，0.92 Hz/mm 为上拱量变化对应的谱峰斜率幅值。按该关系，上拱 10、20 mm 和 30 mm 分别对应约 68.8、59.6 Hz 和 50.4 Hz。式（5）用于本文构型及 0～32 mm 目标区间内的响应解释和单谱峰反演参照，截距与斜率由结构支承及运行条件共同决定。

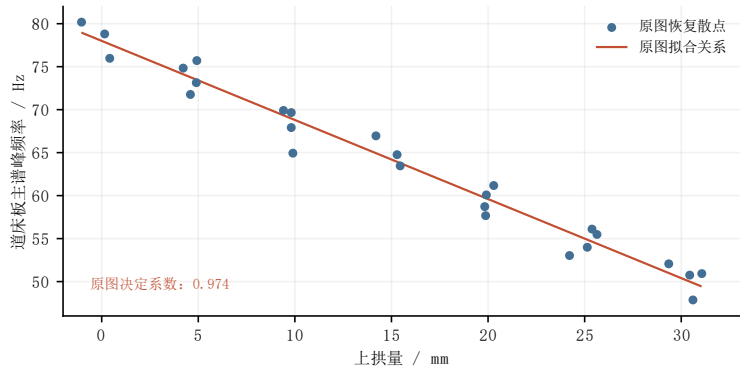

图 4 上拱量与道床板主谱峰频率的关系

Fig.4 Relationship between heave amplitude and dominant spectral peak frequency of the track slab

注：散点由原图数字化恢复，拟合关系和决定系数沿用原图。

图 4 为上拱量与道床板主谱峰频率的关系图，从结构动力特性看，局部支承削弱使相关模态的等效刚度下降，可解释主谱峰下移的趋势；轨面几何变化还会改变轮轨激励。谱峰位置表征频率分布的位置变化，40～80 Hz 频带占比表征响应在选定频段的集中程度。将两者与振动级及相邻级差联合使用，可同时表示频率移动、单层幅值和层间相对响应。对其他轨道构型，谱峰及敏感频带应结合相应结构的正常基准确定。

式（5）构成单指标反演参照，第 4 节通过相同测试记录检验其与多特征方法的精度差异。多变量模型同时引入速度、轴载荷及多层振动信息，以处理相同谱峰可能对应不同运行和支承条件的情况。响应分析由此为输入选择提供物理依据，连续上拱量由后续数据模型联合估计。

2.3 关键层位响应增量及其识别意义

上拱量约 20 mm 时，各结构层振动级均增加，但增量存在明显差异。钢轨与轨枕分别增加 0.8 dB 和 3.2 dB，道床板与仰拱填充层分别增加 7.1 dB 和 8.9 dB，仰拱与隧底围岩分别增加 5.8 dB 和 3.5 dB（图 5、表 1）。最大增量出现在仰拱填充层，道床板次之，表明病害影响在传递路径中具有层位差异。

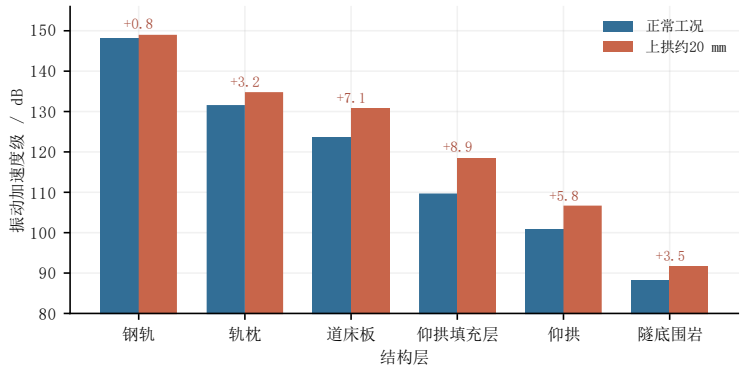

图 5 正常工况与上拱约 20 mm 工况的振动级

Fig.5 Vibration levels under normal conditions and approximately 20 mm heave

表 1 六层振动级及上拱引起的响应增量

Tab.1 Vibration levels across six structural layers and increments induced by heave

结构层	正常/dB	上拱/dB	振动级增量 ΔL_j /dB	加速度均方值比
钢轨	148.2	149.0	0.8	1.2
轨枕	131.6	134.8	3.2	2.1
道床板	123.8	130.9	7.1	5.1
仰拱填充层	109.7	118.6	8.9	7.8
仰拱	100.9	106.7	5.8	3.8
隧底围岩	88.3	91.8	3.5	2.2

为将振动级增量转换为响应强度变化，定义病害与正常工况的加速度均方值比：

$$R_j = \frac{(a^{\mathrm{d}}_{\mathrm{RMS},j})^2}{(a^{\mathrm{n}}_{\mathrm{RMS},j})^2} = 10^{\Delta L_j/10} \tag{6}$$

式中：R_j 为第 j 层病害与正常工况的加速度均方值比；上标 d 和 n 分别表示病害与正常工况；ΔL_j 为该层振动加速度级增量。道床板与仰拱填充层的均方值分别达到正常工况的约 5.1 倍和 7.8 倍，而钢轨约为 1.2 倍，说明应联合绝对量级与相对基准变化确定敏感层位。

上拱还改变了层间相对响应。道床板—填充层级差由 14.1 dB 减小至 12.3 dB，说明填充层相对道床板的响应提高；填充层—仰拱级差则由 8.8 dB 增至 11.9 dB，反映相邻两段传递关系发生不同方向的变化。这样的局部差异在总振动级中容易被合并，而相邻级差能够将其保留下来。

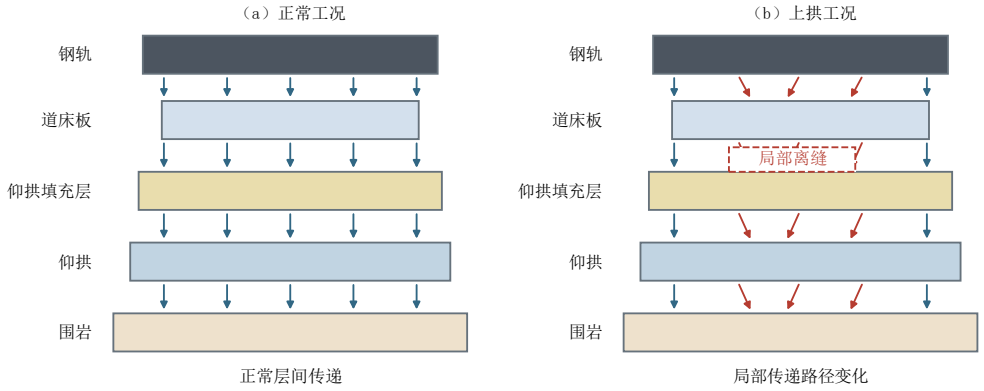

图 6 层间接触变化引起的振动传递路径调整示意

Fig.6 Changes in vibration transmission paths induced by interlayer contact changes

图 6 从接触路径角度示意局部离缝的作用：有效支承位置和接触力分布改变后，不同层位对同一激励的响应增量出现差异。综合谱峰下移、敏感频带增强及多层振动级变化，后续模型采用完整的六层振动级、五组相邻级差、道床板谱峰和两个频带占比，并加入速度与轴载荷。由此，输入同时包含工况、整体响应和层间相对分布三个方面的信息。

3 基于岭回归与 CNN–BiLSTM 的上拱识别方法

3.1 样本组织与结构层序列输入

识别试验采用 5 000 条合成汇总特征记录，对应 1 000 个带 SYN 标记的样本编号，每个编号包含 5 条记录，组内上拱标签一致。本文按式（1）的几何定义，将标签统一作为轨面等效上拱量，取值覆盖 0～32 mm；速度约 200～350 km/h，轴载荷约 120～170 kN。数据集将 0～2 mm、>2～8 mm、>8～16 mm 和>16 mm 分别记为无、轻微、中等和严重四级，各含 250 组、1 250 条记录。分级阈值用于本数据集连续反演结果的状态评价，具体线路的维修阈值由相应管理要求确定。

以样本编号为分组单位，先按病害等级分层，再划分训练、验证和测试集合。同组 5 条记录整体进入同一集合，得到 700 组训练样本、150 组验证样本和 150 组测试样本，分别对应 3 500、750 和 750 条记录。数据无缺失值，亦无完全重复行。样本编号承担分组和结果追踪作用，上拱标签、等级、影响长度、刚度折减及离缝设定参数均不参与输入。

表 2 输入特征及其在模型中的作用

Tab.2 Input features and their roles in the model

类别	特征	维度	作用
工况	速度、轴载荷	2	描述列车运行与载荷条件
振动量级	A1～A6 振动加速度级	6	描述六层响应分布
层间关系	五组相邻层振动级差	5	描述相邻层相对响应
特征频率	A3 道床板主谱峰	1	描述谱峰位置
频带分布	A3、A4 的 40～80 Hz 频带占比	2	描述敏感频带响应比例

表 2 列出 16 维输入：6 个振动级、5 个相邻级差、1 个道床板主谱峰、2 个频带占比及速度、轴载荷。先由原始振动级计算五组级差，再对各维特征分别标准化；训练记录的均值和标准差用于验证、测试及后续预测

$$z_{ip}=\frac{x_{ip}-\mu_p^{\mathrm{tr}}}{s_p^{\mathrm{tr}}},\quad p=1,\ldots,16 \tag{7}$$

式中：i 为记录序号；p 为特征维度序号；x_{ip} 和 z_{ip} 分别为原始及标准化特征；μ_p^{tr} 和 s_p^{tr} 分别为训练记录中第 p 维特征的均值和标准差，上标 tr 表示训练集。结构层序号统一采用 j。标准化后的振动级及级差按式（9）重排，速度、轴载荷、道床板谱峰及两个频带占比构成五维全局特征。

结构层输入的六个位置依次对应钢轨、轨枕、道床板、仰拱填充层、仰拱和隧底围岩，各位置的三个通道依次为本层振动级、上侧相邻级差和下侧相邻级差。级差先独立标准化，随后填入相邻位置；两端缺少的级差在标准化后补零。序列轴表示结构层位，卷积与双向循环均沿六层位置计算。每条记录独立进入模型，同组记录的平均在完成各条预测后进行。

3.2 线性拟合与非线性残差学习

模型由固定线性分支与非线性残差分支构成（图 7、表 3）。岭回归使用完整 16 维标准化特征，拟合振动量级、频率与工况对上拱量的总体线性关系；残差分支将六层三通道输入编码后与五维全局特征拼接，估计线性预测的剩余偏差。训练过程中固定岭回归参数，使神经网络围绕已有估计完成修正。该建

模方式将相关特征的正则化拟合与结构层响应的非线性组合分配给两个分支。

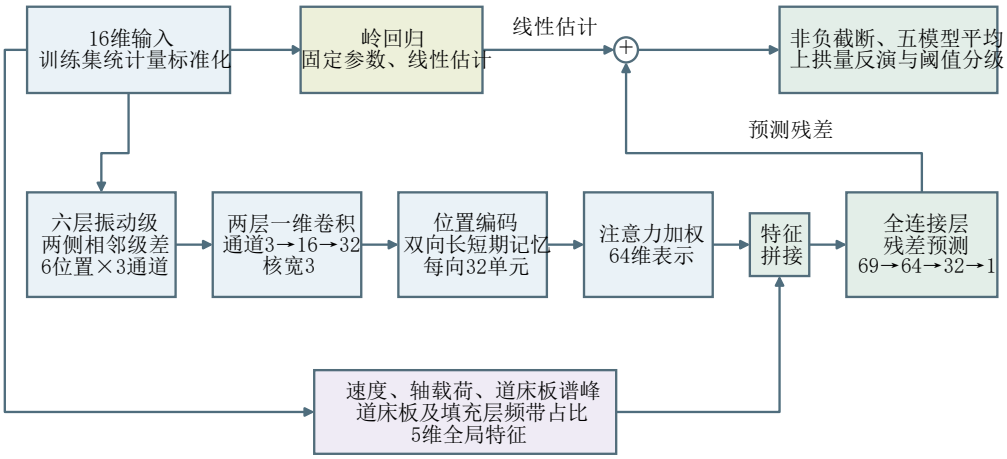

图 7 岭回归与 CNN–BiLSTM 相结合的残差学习模型

Fig.7 Residual learning model combining ridge regression and CNN–BiLSTM

首先，考虑振动级与相邻级差之间的相关性，采用岭回归[25]估计线性系数：

$$(b,\mathbf{w})=\arg\min_{b,\mathbf{w}}\left\{\sum_{i=1}^{n}(h_i-b-\mathbf{w}^{\mathrm{T}}\mathbf{z}_i)^2+\alpha\|\mathbf{w}\|_2^2\right\} \tag{8}$$

式中：n 为训练记录数，h_i 为第 i 条记录的真实上拱量，$\mathbf{z}_i$ 为其 16 维标准化特征向量；b 为截距，$\boldsymbol{w}$ 为回归系数向量，α 为正则系数，取 $\alpha=0.01$；上标 T 表示转置，$\|\mathbf{w}\|_2$ 为系数向量的二范数。截距不参与惩罚，岭回归拟合后固定全部参数。

其次，将六层振动级与相邻级差组织为三个通道：

$$\boldsymbol{s}_j=[z_{L_j},z_{D_{j-1,j}},z_{D_{j,j+1}}]^{\mathrm{T}},\quad j=1,\ldots,6 \tag{9}$$

式中，$\boldsymbol{s}_j$ 为第 j 层的三通道输入向量，z_{L_j} 为该层标准化振动级，$z_{D_{j-1,j}}$ 和 $z_{D_{j,j+1}}$ 分别为两侧相邻级差的标准化值。序列两端缺少的级差通道补零。两层一维卷积采用核宽 3 和长度保持填充，经批归一化与 ReLU 提取相邻层组合特征；输出叠加可学习位置向量后进入单层 BiLSTM，每个方向设置 32 个单元[22-23]。

表 3 模型结构、参数设置及输出方式

Tab.3 Model architecture, parameter settings and outputs

阶段	设置	输出维度
线性分支	16 维输入；岭系数 0.01；拟合后固定	1
结构层输入	本层振动级、上侧级差、下侧级差	6×3
卷积编码	核宽 3；通道 3→16→32；批归一化、ReLU	6×32
位置与双向循环	可学习位置向量；单层 BiLSTM，每向 32 单元	6×64
注意力加权	64→1 评分，沿六个位置归一化	64
全局特征拼接	速度、轴载荷、谱峰、两个频带占比	69
残差回归	全连接 69→64→32→1；隐藏层 ReLU	1
连续估计与分级	线性估计＋残差；逐模型非负截断；五模型平均；2、8、16 mm 阈值	1 及等级

将 BiLSTM 在第 j 层的 64 维输出向量记为 $\boldsymbol{H}_j$，采用注意力机制[24]计算层位权重并获得加权表示：

$$\omega_j=\frac{\exp(\boldsymbol{w}_{\mathrm{a}}^{\mathrm{T}}\boldsymbol{H}_j)}{\sum_{\ell=1}^{6}\exp(\boldsymbol{w}_{\mathrm{a}}^{\mathrm{T}}\boldsymbol{H}_\ell)},\quad \boldsymbol{g}=\sum_{j=1}^{6}\omega_j\boldsymbol{H}_j \tag{10}$$

式中：ω_j 为第 j 层的注意力权重，$\boldsymbol{w}_{\mathrm{a}}$ 为评分权重向量，下标 a 表示注意力评分，ℓ 为归一化求和的层位序号，$\boldsymbol{g}$ 为六层输出的加权表示。评分采用无偏置线性映射。将 $\boldsymbol{g}$ 与五维全局特征拼接，得到 69 维输入，由全连接层输出残差 $r_\theta(\boldsymbol{z})$；θ 为神经网络可训练参数，$\boldsymbol{z}$ 为一条记录的完整标准化特征向量。两个分支的连续输出相加：

$$\tilde{h}=b+\boldsymbol{w}^{\mathrm{T}}\boldsymbol{z}+r_\theta(\boldsymbol{z}) \tag{11}$$

式中：$\tilde{h}$ 为非负截断前的上拱量预测。残差输出层权重与偏置采用零初始化，使初始估计与岭回归一致；随后仅更新神经网络参数。式（11）与真实标签之间的误差构成训练目标，因此残差由固定线性估计上的偏差直接学习，训练参数见表 4。

表 4 训练与评价设置

Tab.4 Training and evaluation settings

项目	设置
训练/验证/测试	700/150/150 组；3500/750/750 条记录
等级分布	训练每级 875 条；验证 190/185/185/190 条；测试 185/190/190/185 条
划分种子	20260926；验证与测试二次划分为 20260927
优化器	AdamW；初始学习率 0.001；权重衰减 0.01
训练规模	批量 256；最多 240 轮；梯度范数裁剪 5；Dropout 为 0
学习率与早停	验证 RMSE 连续 12 轮无改善则减半；下限 0.00001；40 轮无改善早停
独立初始化	20260926、13、42、2026、2027；五次预测等权平均
基线调参	仅在训练组内进行五折分组交叉验证
区间估计	150 个测试组；5000 次配对 Bootstrap

3.3 训练目标、预测集成与等级输出

网络优化以连续上拱量为目标。采用训练标签标准差归一化的均方误差，使训练损失具有稳定的数值尺度，并保持岭回归参数固定：

$$\mathcal{L}(\theta)=\frac{1}{n}\sum_{i=1}^{\mathrm{n}}\left(\frac{\tilde{h}_i-h_i}{s_h}\right)^2 \tag{12}$$

式中：$\mathcal{L}(\theta)$ 为神经网络训练损失；$\tilde{h}_i$ 为第 i 条训练记录的截断前预测；s_h 为训练上拱标签的标准差。采用 AdamW 优化器[29]更新网络参数，并依据验证集均方根误差调整学习率和实施早停。零残差状态纳入第 0 轮候选，各次训练保留验证误差最低的权重。

采用五个固定随机种子独立训练相同网络。预测时，先将每个网络的上拱估计截断至非负，再对五次预测等权平均：

$$\hat{h}=\frac{1}{K}\sum_{k=1}^{K}\max(0,\tilde{h}^{(k)}),\quad K=5 \tag{13}$$

式中：$\hat{h}$ 为五模型平均后的非负上拱量估计；K 为独立模型数，取 $K=5$；k 为模型序号；$\tilde{h}^{(k)}$ 为第 k 个模型的截断前预测；max 为取最大值运算。平均后的连续估计按数据集阈值映射为四级状态

$$\hat{c}=\mathrm{I}(\hat{h}>2)+\mathrm{I}(\hat{h}>8)+\mathrm{I}(\hat{h}>16) \tag{14}$$

式中：$\hat{c}$ 为预测等级，$\mathrm{I}(\cdot)$ 为指示函数，条件成立取 1，否则取 0。输出 0～3 依次对应无、轻微、中等和严重；阈值 2、8、16 的单位为 mm。恰好位于阈值的预测归入较低一级，连续估计与分级结果共用同一回归输出。

训练按分组划分、训练集标准化、岭回归拟合、残差分支优化及模型平均依次进行。预测时，每个模型先将线性估计与残差相加，再截断为非负，最后对五个模型的连续输出等权平均并按阈值分级。五模型平均作用于同一条输入记录；同组重复观测平均则作用于五条不同记录的最终连续估计，两种平均的对象与统计单位分别报告。

4 试验设置与识别结果分析

4.1 评价指标及基线设置

全部方法采用第 3.1 节确定的分组划分。训练集用于参数拟合，验证集用于神经网络早停与学习率调整，测试集用于报告预测表现。数据划分种子及训练参数见表 4。连续反演采用均方根误差（RMSE）、平均绝对误差（MAE）和决定系数评价，其中 RMSE 反映整体平方误差，MAE 反映平均偏差幅度：

$$\mathrm{RMSE}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}(\hat{h}_i-h_i)^2},\quad \mathrm{MAE}=\frac{1}{N}\sum_{i=1}^{N}|\hat{h}_i-h_i| \tag{15}$$

$$R^2=1-\frac{\sum_{i=1}^{N}(\hat{h}_i-h_i)^2}{\sum_{i=1}^{N}(h_i-\bar{h})^2} \tag{16}$$

式中：N 为被评价集合的记录数；$\hat{h}_i$ 为第 i 条记录的上拱量预测；$\bar{h}$ 为该集合真实上拱量的均值；R^2 为决定系数。等级判别采用准确率和宏平均 F1，并通过混淆矩阵说明误判方向

$$\mathrm{Accuracy}=\frac{1}{N}\sum_{i=1}^{N}\mathrm{I}(\hat{c}_i=c_i),\quad \mathrm{MacroF1}=\frac{1}{4}\sum_{c=0}^{3}\frac{2P_cQ_c}{P_c+Q_c} \tag{17}$$

式中：c_i 和 $\hat{c}_i$ 分别为第 i 条记录的真实与预测等级；c 为等级序号；P_c 和 Q_c 分别为该等级的精确率与召回率；Accuracy 和 MacroF1 分别表示准确率与宏平均 F1。四个等级等权计算。模型差值采用 5000 次按组配对 Bootstrap 估计 95%区间，每次抽取完整样本组，并保留组内 5 条记录和不同模型的对应预测。

基线按建模原理选择，包括岭回归、决策树、近邻回归（KNN）、随机森林（RF）、直方图梯度提升（HGB）和多层感知机（MLP），分别代表线性拟合、分段拟合、局部邻域、树集成和前馈网络。各方法使用相同的数据划分与输入特征，以比较不同建模方式下的上拱量反演效果。

上述多特征基线采用相同的 16 维输入，标准化参数在每个训练折内拟合。各模型按训练组五折交叉验证的平均 RMSE 选定参数，其中 KNN 搜索邻居数、距离度量与权重方式，决策树搜索树深与叶节点最少样本数。主文选定参数见表 5，完整候选配置保存在补充结果表中。单谱峰经验反演仅使用道床板谱峰，非负上拱量估计 $\hat{h}_{\mathrm{f}}$ 按 $\hat{h}_{\mathrm{f}}=\max(0,(78-f_{\mathrm{c}})/0.92)$ 计算，其中下标 f 表示频率反演，截距和斜率分别以 Hz 及 Hz/mm 计。

表 5 多特征基线的参数及设置

Tab.5 Parameters and settings of multifeature baseline models

方法	选定参数或训练规则
岭回归	正则系数 0.01
决策树	树深不设上限；叶节点最少 10 条记录
KNN	25 个邻居；曼哈顿距离；距离倒数加权
RF	200 棵树；叶节点最少 1 条记录
HGB	300 次迭代；学习率 0.05；15 个叶节点；叶节点最少 20 条记录
MLP	两层宽度 32、16；正则系数 1；L-BFGS；最多 600 次迭代

基线验证从两个方面评价方法：一是比较多特征识别与单谱峰经验关系的预测表现，二是检验所提方法相对常规多变量模型的反演精度。第 4.3 节通过组件消融进一步分析岭回归初始估计及神经网络各组成部分的作用。

4.2 总体精度与分等级误差

表 6 中，本文方法在 750 条测试记录上的 RMSE 为 0.6203 mm，低于所列多特征基线与单谱峰参照。单谱峰经验反演的 RMSE 为 4.0453 mm，说明总体频率趋势之外，运行条件和多层响应仍包含反演所需的信息。联合输入单层振动级与相邻级差，可以同时利用响应幅值和局部相对分布。

表 6 基线与本文方法在 750 条测试记录上的表现

Tab.6 Performance of baseline models and the proposed method on 750 test records

方法	RMSE/mm	MAE/mm	R^2	准确率/%	宏 F1/%
单谱峰经验反演	4.0453	3.1509	0.82270	62.93	62.63
岭回归	0.6370	0.5015	0.99560	90.40	90.44
决策树	1.0538	0.8132	0.98797	87.07	87.09
KNN	0.8906	0.6993	0.99141	90.40	90.48
RF	0.7585	0.5914	0.99377	90.40	90.45
HGB	0.7064	0.5673	0.99459	90.67	90.70
MLP	0.6701	0.5299	0.99513	90.53	90.60
本文方法	0.6203	0.4897	0.99583	91.60	91.63

岭回归的 RMSE 为 0.6370 mm，已能解释数据中的主要变化；残差修正使其进一步降低 2.62%，MAE 由 0.5015 降至 0.4897 mm。分级准确率由 90.40%提高至 91.60%，对应正确识别记录由 678 条增至 687 条。这一结果表明，在相同 16 维输入和分组划分下，固定线性估计上的非线性修正同时改善了连续反演和阈值分级。

图 8 显示，预测值主要分布在真实值附近，平均有符号误差为 0.0254 mm，绝对误差 95%分位数为 1.2890 mm，最大绝对误差为 1.9891 mm。五个独立初始化模型的 RMSE 为 0.6191～0.6294 mm，标准差为 0.00434 mm。图 10 将误差进一步按真实上拱量及病害等级展开，用于识别总体均值难以显示的边界误判与等级差异。

连续误差与分级准确率采用相同的 750 条测试记录。前者评价上拱量偏差，后者评价连续输出跨越 2、8、16 mm 阈值后的状态判别。即使连续误差较小，阈值附近的记录仍可能进入相邻等级，因而需要结合图 9 的误判方向和表 7 的分等级误差解释识别表现。

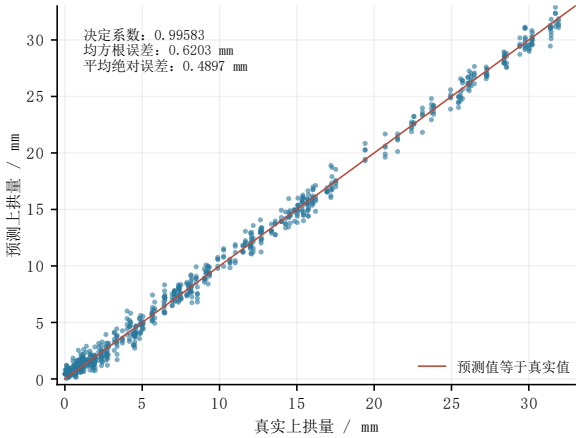

图 8 本文方法的上拱量预测值与真实值

Fig.8 Predicted and true heave amplitudes obtained using the proposed method

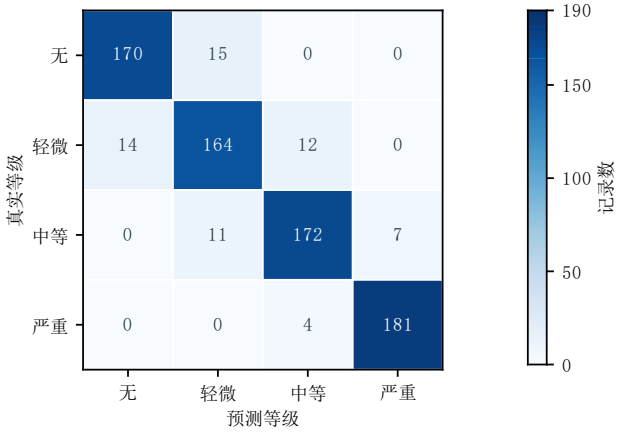

图 9 本文方法的分级混淆矩阵

Fig.9 Confusion matrix for damage grading using the proposed method

表 7 各真实等级的反演误差与召回率

Tab.7 Estimation errors and recall rates for each true damage grade

等级	记录数	RMSE/mm	MAE/mm	召回率/%
无	185	0.5199	0.4079	91.89
轻微	190	0.6777	0.5433	86.32
中等	190	0.6302	0.4999	90.53
严重	185	0.6402	0.5059	97.84

表 7 中，轻微等级的 RMSE 为 0.6777 mm、召回率为 86.32%，其误判涉及 2 mm 和 8 mm 两侧边界；严重等级的召回率为 97.84%，185 条记录中 181 条识别正确。全部 63 条误判均发生在相邻等级，其中 60 条真实上拱量距最近阈值不超过 1 mm。相较总体准确率，这一分布进一步表明误差主要影响等级交界处的判别，连续估计可提供阈值两侧的幅值信息。

状态评价同时保留连续估计和等级输出。对阈值附近的观测，可结合连续估计的变化方向及同组重复记录的平均结果判断状态趋势；对远离阈值的观测，等级结果提供直接的状态表征，见图 10。第 4.4 节采用 150 个完整测试组评价重复观测平均，使该过程与逐记录统计相互对应。

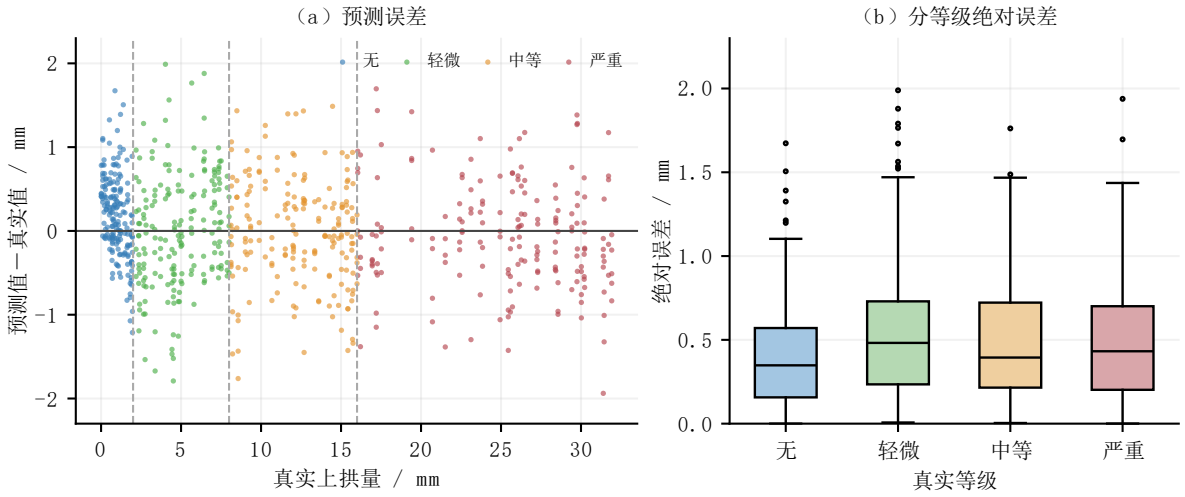

图 10 上拱量预测误差及分等级绝对误差分布

Fig.10 Prediction errors of heave amplitude and absolute error distributions by damage grade

4.3 残差学习与输入组织的消融验证

在固定数据划分、网络宽度、优化参数及五个随机种子的条件下，设置六种变体：移除岭回归；将卷积输入的两个级差通道置零，仅保留本层振动级；将六层顺序固定改为 A1、A3、A5、A2、A4、A6；将注意力加权替换为均值池化；移除 BiLSTM；增加频率一致性损失。级差与顺序试验仅改变神经网络序列输入，岭回归仍使用完整 16 维特征。所有变体均按同一验证规则选取权重。

频率一致性损失依据第 2.2 节的谱峰关系构造，用训练组频率残差标准差归一化，并以 0.001 的权重加入回归损失：

$$\mathcal{L}_{\mathrm{f}}=\frac{1}{n}\sum_{i=1}^{\mathrm{n}}\left(\frac{f_{\mathrm{c},i}-(78-0.92\tilde{h}_i)}{s_f}\right)^2 \tag{18}$$

式中：$\mathcal{L}_{\mathrm{f}}$ 为频率一致性损失；$f_{\mathrm{c},i}$ 为第 i 条训练记录的观测谱峰；s_f 为观测谱峰相对经验关系的训练残差标准差。该项检验已有谱峰输入之外的附加经验约束。表 8 同时报告预测精度、配对 RMSE 差的 95% 区间、单模型有效可训练参数量及五模型集成预测耗时；RMSE 差按本文方法减去对应变体计算。

表 8 组件消融的精度、参数量与预测耗时

Tab.8 Accuracy, parameter counts and prediction times in component ablations

设置	RMSE/mm	MAE/mm	准确率/%	RMSE 差区间/mm	参数量/个	批量耗时/ms
移除岭回归	0.6390	0.5004	90.93	[-0.0357, -0.0019]	25 569	40.67
卷积输入仅保留振动级	0.6232	0.4897	90.80	[-0.0121, 0.0062]	25 569	46.02
固定打乱层位顺序	0.6193	0.4884	91.20	[-0.0025, 0.0045]	25 569	34.96
均值池化替代注意力	0.6202	0.4892	91.47	[-0.0020, 0.0022]	25 505	24.25
移除 BiLSTM	0.6231	0.4922	91.47	[-0.0069, 0.0014]	6 593	11.61
增加频率一致性损失	0.6211	0.4897	91.60	[-0.0032, 0.0016]	25 569	33.66
本文方法	0.6203	0.4897	91.60	—	25 569	38.98

计时采用 Intel Core i7-12700KF 处理器、PyTorch 2.8.0 CPU 环境和 2 个计算线程。各模型预热 20 次后重复 40 次，取中位数；耗时包含标准化、五模型串行预测、非负截断及平均，不含文件读取与振动特征

计算。参数量按单模型实际参与预测的可训练参数统计，固定岭回归另含 16 个系数及 1 个截距。

岭回归分支固定后，神经网络学习其剩余误差；移除该分支，RMSE 由 0.6203 增至 0.6390 mm，配对差区间为[−0.0357, −0.0019] mm。这一结果支持以正则化线性估计作为残差学习的起点。级差通道由已有振动级导出，作用是显式组织局部相对响应；仅保留振动级时，正确分级记录由 687 条降至 681 条。层位顺序则为输入提供与竖向结构一致的定位，固定打乱后正确分级记录为 684 条，其回归误差与完整配置接近。

BiLSTM沿六个结构层位置组合上下文信息。移除该模块后，RMSE为0.6231 mm、正确分级686条，单模型有效参数量由25 569降至6 593，750条记录的五模型批量预测耗时由38.98降至11.61 ms。BiLSTM在当前数据中的精度收益较小，对模型规模与耗时的影响较大。注意力以 64 个评分参数完成自适应加权，相比均值池化多正确分级 1 条记录，RMSE 分别为 0.6203 和 0.6202 mm。层位顺序与池化变体的配对RMSE差区间均包含零，二者主要体现结构对应与表示聚合方式；残差框架的精度贡献由岭回归消融和基线结果共同支持。

增加频率一致性损失后，RMSE为0.6211 mm，分级准确率仍为91.60%。当前模型通过五维全局特征使用谱峰信息，最终训练采用连续上拱量损失。综合基线、组件精度与复杂度分析，本文方法的具体贡献是将振动级及其相对分布组织为多层输入，并在固定线性关系上学习病害反演的剩余偏差；BiLSTM 与注意力作为层间表示和聚合组件，其作用按相应精度与计算代价评价。

4.4 工况分层表现与监测应用

表 9 按速度与轴载荷分别统计同一 750 条测试记录，评价范围为约 200～350 km/h 及 120～170 kN。各速度层的 RMSE 为 0.6180～0.6240 mm，各轴载层为 0.5926～0.6436 mm，说明模型在当前测试范围内的分层误差保持同一量级。每条记录在速度分层和轴载分层中各计入一次，两类分层分别评价运行条件的影响。

表 9 测试集按速度和轴载荷分层的预测结果

Tab.9 Prediction results stratified by speed and axle load in the test set

变量	区间	记录数	RMSE/mm	MAE/mm	准确率/%
速度	[200, 250) km/h	220	0.6180	0.4824	90.45
速度	[250, 300) km/h	275	0.6240	0.4889	91.27
速度	[300, 350) km/h	255	0.6182	0.4968	92.94
轴载荷	[120, 135) kN	240	0.6436	0.5156	90.83
轴载荷	[135, 150) kN	220	0.6300	0.4900	90.91
轴载荷	[150, 170) kN	290	0.5926	0.4680	92.76

同组重复观测采用另一统计口径：先对每条记录完成五模型预测，再将同一编号下 5 条记录的连续估计平均，最后按原阈值分级。统计单位由 750 条记录变为 150 个测试组，各组权重相同。组平均 RMSE 为 0.3896 mm，较逐记录结果降低 37.19%，MAE 为 0.3105 mm，143 组分级正确，准确率为 95.33%。该改善来自重复记录的联合估计，评价对象为同一批完整测试组。

监测应用以相同断面的六层竖向加速度与运行条件为基础，在一致时窗和频段内计算振动级、相邻级差、谱峰及频带占比，再输入识别模型。道床板与仰拱填充层用于重点跟踪单层增量，六层特征共同表征整体分布。连续估计、阈值等级和重复观测平均分别提供变形幅值、状态类别及多次观测的综合结果，可与轨面几何复测形成配对记录。

本文定量关系对应双块式无砟轨道及其下部支承构型，预测目标为 0～32 mm 轨面等效上拱量。对于同类构型中由围岩膨胀、应力作用或支承劣化引起的竖向上拱，可沿相同层位计算响应特征，并以目标区段的正常基准和几何复测数据标定。板式轨道、有砟轨道及横向不均匀隆起需要按实际构型调整层位、

接触参数和观测方向；经验谱峰斜率、频带范围与分级阈值均由相应线路数据确定。多层相对响应与线性—残差组合可用于组织这一识别过程，具体系数和精度随标定条件确定。

5 结论

1）上拱引起的振动响应变化同时体现在局部响应增强和层间相对分布改变。轨面等效上拱量约为 20 mm 时，道床板与仰拱填充层的加速度均方值分别达到正常工况的约 5.1 倍和 7.8 倍，两层振动级差由 14.1 dB 减小至 12.3 dB。填充层响应增幅大于道床板，表明上拱作用对不同结构层的影响存在差异。联合各层振动级与相邻层级差，可从响应强度和层间相对变化两个方面表征上拱特征。

2）岭回归与非线性残差学习相结合，实现了轨面等效上拱量的连续估计与病害分级。在按样本组独立划分的测试集中，本文方法的 RMSE 为 0.6203 mm，分级准确率为 91.60%，较岭回归分别降低 2.62%和提高 1.20 个百分点；移除岭回归分支后，RMSE 增至 0.6390 mm。结果表明，保留多层振动特征与上拱量之间的线性关系，并进一步修正非线性残差，能够提高上拱识别精度。

3）病害分级误差集中于等级阈值附近，同组多记录预测平均可进一步改善识别结果。测试集的 63 条误判均发生在相邻等级之间，其中 60 条记录的真实上拱量距最近分级阈值不超过 1 mm。对同一批 150 个测试组内各 5 条记录的上拱量预测值取平均后，RMSE 降至 0.3896 mm，分级准确率提高至 95.33%。在本文双块式无砟轨道构型及所研究的上拱范围内，重复观测平均能够减小记录间波动对连续估计和等级判定的影响。

参考文献：

[1] ZHAO D P, FAN H B, JIA L L. Characteristics and mitigation measures of floor heave in operational high-speed railway tunnels[J]. KSCE Journal of Civil Engineering, 2021, 25(4): 1479-1490.

[2] 宋慧来, 赵一馨, 刘钰, 等. 有砟与无砟轨道系统隧底上拱变形传递规律[J]. 中国铁道科学, 2024, 45(2): 123-133.
SONG H L, ZHAO Y X, LIU Y, et al. Deformation transmission law of tunnel bottom heave of ballasted and ballastless track system[J]. China Railway Science, 2024, 45(2): 123-133.

[3] LEE C H, WANG T T. Invert anomalies in operational rock tunnels: appearance, causes, and countermeasures[J]. Journal of Performance of Constructed Facilities, 2016, 30(3): 04015048.

[4] 范胜元, 加武荣, 谢江胜, 等. 服役隧道仰拱上抬病害机理分析与整治措施[J]. 中国铁道科学, 2026, 47(2): 175-185.
FAN S Y, JIA W R, XIE J S, et al. Mechanism analysis and treatment measures for inverted arch uplift in in-service tunnel[J]. China Railway Science, 2026, 47(2): 175-185.

[5] 刘景宇, 张千里, 郭浏卉, 等. 高速铁路地基泥岩膨胀变形计算方法及应用研究[J]. 中国铁道科学, 2023, 44(1): 50-57.
LIU J Y, ZHANG Q L, GUO L H, et al. Calculation method and application study of swelling deformation of foundation mudstone for high-speed railway[J]. China Railway Science, 2023, 44(1): 50-57.

[6] 邓逆涛, 陈锋, 张千里, 等. 含黄铁矿填料的高速铁路路基上拱特性与机理[J]. 中国铁道科学, 2024, 45(4): 12-21.
DENG N T, CHEN F, ZHANG Q L, et al. Characteristics and mechanisms of heave of high-speed railway subgrade containing pyrite filler[J]. China Railway Science, 2024, 45(4): 12-21.

[7] 肖小文, 王立川, 阳军生, 等. 高地应力区缓倾互层岩体无砟轨道隧道底部隆起的成因分析及整治方案[J]. 中国铁道科学, 2016, 37(1): 78-84.
XIAO X W, WANG L C, YANG J S, et al. Cause analysis and treatment scheme for bottom heave of ballastless track tunnel in nearly horizontally interbedded rock mass with high geostress[J]. China Railway Science, 2016, 37(1): 78-84.

[8] 王景春, 常子红, 王大鹏. 考虑衬砌与围岩劣化的隧道仰拱动力响应分析[J]. 铁道工程学报, 2023, 40(7): 51-56.
WANG J C, CHANG Z H, WANG D P. Dynamic response analysis of tunnel inverted arch considering lining and surrounding rock deterioration[J]. Journal of Railway Engineering Society, 2023, 40(7): 51-56.

[9] 李谷, 张志超, 祖宏林, 等. 高速铁路典型轨道病害下轮轨力响应特性试验研究[J]. 中国铁道科学, 2019, 40(6): 30-36.
LI G, ZHANG Z C, ZU H L, et al. Experimental study on wheel-rail force response characteristics under typical track defects of high-speed railway[J]. China Railway Science, 2019, 40(6): 30-36.

[10] 晏兆晋, 高翠香, 徐晓迪, 等. 基于车辆响应的高速铁路周期性轨道短波病害时频特性分析[J]. 中国铁道科学, 2020, 41(1): 10-17.
YAN Z J, GAO C X, XU X D, et al. Time-frequency characteristics analysis of periodic short wave disease of track for high-speed railway based on vehicle response[J]. China Railway Science, 2020, 41(1): 10-17.

[11] 程建军, 王瑞, 祁延录, 等. 无砟轨道涵洞过渡段路基膨胀引起的轨道上拱响应[J]. 中国铁道科学, 2020, 41(6): 10-19.
CHENG J J, WANG R, QI Y L, et al. Response of track arching caused by subgrade expansion in culvert transition section of ballastless track[J]. China Railway Science, 2020, 41(6): 10-19.

[12] DU M Q, SU J, WANG X C, et al. Dynamic response and crack propagation law of tunnel invert with initial damage[J]. Engineering Failure Analysis, 2021, 119: 104939.

[13] AUERSCH L. Simultaneous measurements of the vehicle, track, and soil vibrations at a surface, bridge, and tunnel railway line[J]. Shock and Vibration, 2017, 2017(1): 1959286.

[14] 刘庆杰, 陈松, 雷晓燕, 等. 地铁车辆段试车线环境振动影响实测分析[J]. 华东交通大学学报, 2025, 42(1): 1-7.
LIU Q J, CHEN S, LEI X Y, et al. Measured analysis of environmental vibration influence on testing line of metro depot[J]. Journal of East China Jiaotong University, 2025, 42(1): 1-7.

[15] 翟婉明. 车辆—轨道耦合动力学[M]. 4 版. 北京: 科学出版社, 2015.
ZHAI W M. Vehicle-track coupled dynamics[M]. 4th ed. Beijing: Science Press, 2015.

[16] ZHAI W M, WANG K Y, CAI C B. Fundamentals of vehicle–track coupled dynamics[J]. Vehicle System Dynamics, 2009, 47(11): 1349-1376.

[17] INTERNATIONAL ORGANIZATION FOR STANDARDIZATION. Mechanical vibration—Ground-borne noise and vibration arising from rail systems—Part 1: General guidance: ISO 14837-1:2005[S]. Geneva: ISO, 2005.

[18] ABDELJABER O, AVCI O, KIRANYAZ S, et al. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks[J]. Journal of Sound and Vibration, 2017, 388: 154-170.

[19] LIU T W, XU H, RAGULSKIS M, et al. A data-driven damage identification framework based on transmissibility function datasets and one-dimensional convolutional neural networks: verification on a structural health monitoring benchmark structure[J]. Sensors, 2020, 20(4): 1059.

[20] YIN X X, YIN S M, BU Y M, et al. Track defects recognition based on axle-box vibration acceleration and deep-learning techniques[J]. Structural Durability & Health Monitoring, 2024, 18(5): 623-640.

[21] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.

[22] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[23] SCHUSTER M, PALIWAL K K. Bidirectional recurrent neural networks[J]. IEEE Transactions on Signal Processing, 1997, 45(11): 2673-2681.

[24] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[C/OL]//Proceedings of the 3rd International Conference on Learning Representations. San Diego: [s.n.], 2015[2026-10-10].

[25] HOERL A E, KENNARD R W. Ridge regression: biased estimation for nonorthogonal problems[J]. Technometrics, 1970, 12(1): 55-67.

[26] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational Physics, 2019, 378: 686-707.

[27] WANG R H, LI J, LI L, et al. Structural damage identification by using physics-guided residual neural networks[J]. Engineering Structures, 2024, 318: 118703.

[28] LEI Y Z, LI J, HAO H. Structural damage identification based on physics-guided deep learning: applications to large-scale structures[J/OL]. Structural Health Monitoring, 2025: 1-21[2026-10-10].

[29] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization[C/OL]//Proceedings of the 7th International Conference on Learning Representations. New Orleans: OpenReview.net, 2019[2026-10-10].