新建车站密贴下穿既有结构变形规律及预测模型

王箭明*
（上海陆家嘴（集团）有限公司，上海 200122）

摘　要　为降低密贴下穿工程中既有结构附加变形过大可能导致的结构承载力不足、轨道交通线路不平整等工程风险，特此开展新建车站施工对上部既有结构的扰动变形机理及预测模型研究。首先，以某地铁新建车站零距离下穿既有车站为工程背景，介绍零距离暗挖施工方案；其次，结合现场监测数据分析既有车站结构竖向及水平位移、道床沉降、轨道高差、轨距等扰动变形响应特征；最后，结合长短期记忆（LSTM）神经网络、自适应惯性权重粒子群优化（AWPSO）算法及先验信息约束（PIC），构建结构变形预测模型并进行验证分析。研究结果表明，AWPSO-LSTM-PIC 模型能够有效利用先验信息约束和超参数寻优模块，在小样本多任务预测问题中具有较为优异预测性能，平均拟合优度 R^2 达到 0.938，具备一定的可解释性，可为密贴工程条件下既有车站变形控制提供实时预警与决策辅助支持。

关键词　密贴下穿，既有结构，变形规律，时序预测，先验信息约束，自适应惯性权重
中图分类号：TU94；U231.3　　**文献标志码**：A　　**DOI**：10.15935/j.cnki.jggcs.202604.0010

Deformation Behavior and Prediction Model of Newly Built Stations Closely Underpassing Existing Structures

WANG Jianming*
（Shanghai Lujiazui (Group) Co.,Ltd., Shanghai 200122, China）

Abstract　To mitigate safety risks induced by excessive additional deformation of existing structures in closely aligned underpass projects—such as inadequate structural bearing capacity and uneven rail transit lines—this study investigates the disturbance deformation mechanism and develops a prediction model for the overlying existing structures during new station construction. Using the case of a newly built metro station at zero distance beneath an existing station as the engineering context, the zero-clearance excavation method and an automated monitoring scheme are first introduced. Subsequently, based on field monitoring data, the disturbance-induced deformation response of the existing station structure is analyzed, covering vertical and horizontal displacement, track bed settlement, rail level difference, and track gauge variation. Finally, a structural deformation prediction model integrating a Long Short-Term Memory (LSTM) neural network, an Adaptive Weighted Particle Swarm Optimization (AWPSO) algorithm, and Prior Information Constraints (PIC) is constructed and validated. The results demonstrate that the proposed AWPSO-LSTM-PIC model effectively incorporates prior information constraints and a hyperparameter optimization module, exhibiting outstanding predictive performance in small-sample, multi-task prediction scenarios. The average coefficient of determination (R^2) reaches 0.938, reflecting considerable interpretability and generalization capability.

Keywords　closely underpassing, existing structures, deformation law, time series prediction, prior information constraint, adaptive inertia weight

收稿日期：2025-10-02

* **联系作者**：王箭明，工学博士，长期从事岩土工程领域研究工作。E-mail：jmwang@ljz.com.cn

0 引 言

随着我国经济飞速发展,居民交通出行需求不断增长,城市轨道交通建设发展逐渐转向密集型和交互型[1]。地下工程施工会改变周围环境应力状态,导致邻近既有结构产生显著的附加应力和变形,影响城市轨道交通线路的正常运行[2]。因此,深入揭示新建地下工程对邻近既有结构的扰动变形机理,并预测其发展趋势,可以辅助工程决策人员及时采取控制措施,确保工程施工和交通运营安全[3]。

理论分析、数值模拟、现场监测、室内试验是探究新建地下工程施工对既有结构影响的重要研究手段[4-5]。刘天宇等[6]以能量法为基础,探究了双线隧道施工对上部既有隧道结构沉降的影响机理。张顶立等[7]从弹性地基梁理论角度出发,建立了隧道施工开挖引起既有结构变形的预测方法。Yu等[8]基于30个采用PBA工法的地铁车站施工案例,总结分析了浅埋软土地层条件下的地表沉降规律。杨宇杰等[9]基于FLAC 3D数值模拟软件对比分析了不同新建通道工况下既有车站结构的变形及力学响应。麻建飞等[10]提出了密贴下穿工程预顶支开挖构筑工法,结合数值模拟及现场监测验证了其适用性。李利等[11]通过现场监测结果证明了采用主动预顶撑、注浆抬升等工艺可实现既有结构沉降的动态控制。其中,现场监测是最直观有效的研究手段,能够获得实际施工条件下既有结构真实响应。然而,密贴地下工程中既有结构变形会受到施工条件、地层参数、交通荷载等各种复杂因素的影响,难以准确揭示变形数据背后隐藏的机理与规律,从而限制了既有结构变形监测数据的应用。

近年来,随着结构健康监测系统(SHMS)等信息采集技术的不断进步,以及机器学习和深度学习技术的快速发展,越来越多的研究者将关注点转向了地下工程中的结构变形预测领域[12-16]。王立新等[17]采用BP神经网络进行地层力学参数反演,实现了近接施工对既有地铁结构的变形预测。Zhang等[18]提出了基于经验公式的神经网络(EFBNN)和经验信息约束神经网络(EICNN)两种模型,在隧道长期沉降预测任务上具有较好的泛化能力和预测性能。Li等[19]采用双向长短期记忆网络(Bi-LSTM)对山区隧道施工中的变形数据进行了预测。顾亦宁等[20]以地铁隧道临近基坑开挖为工程背景,基于代理模型提出基坑开挖影响下隧道结构响应的数字孪生建模方法,实现了对隧道结构变形的精准实时预测。张东明等[21]基于物理信息神经网络(PINNs),将隧道结构响应物理方程和实测数据两种类型的神经元结合,实现了盾构隧道结构竖向位移的精准预测,具有显著的泛化性及鲁棒性优势。针对密贴下穿工程既有结构变形预测领域,传统深度学习方法主要通过数据驱动的方式学习数据间的关联性特征,需要依赖高质量的大样本数据集,且多针对的是单监测点预测任务,无法有效考虑结构变形数据具有的时间和空间特征。

本文以某地铁新建车站密贴下穿既有车站为工程背景,首先介绍零距离下穿施工和自动化监测方案;其次,结合现场监测数据分析新建车站暗挖施工对既有车站及轨道交通结构的变形影响规律。最后,基于长短期记忆神经网络、自适应惯性权重粒子群优化算法、先验信息约束构建结构变形预测模型,并结合现场监测数据进行模型验证和分析。

1 工程概况

1.1 既有地铁车站

既有地铁车站为地下一层三柱四跨侧式站台车站,其中半地下层为站厅层,地下一层为站台层,并与新建地铁车站成十字侧岛换乘,如图1所示。车站总长167.50 m,总宽25.80 m,站台有效长度为120 m,侧站台宽8.05 m。车站主体和两端区间均为明挖法施工。

1.2 新建地铁车站

拟建场地范围内上覆第四系人工填土层,第四系更新统下蜀组黏性土层,覆盖层厚度为36~38 m,下伏基岩为第三系定远群泥质砂岩泥岩。勘察区内地表水不发育,无河流、水塘分布,地下水类型为孔隙水和基岩裂隙水,地下水埋深1.9~3.8 m。场地内土体物理力学参数如表1所示。

新建车站与既有车站采用侧、岛十字型换乘方案。新建地铁车站为地下两层14 m岛式站台,主体标准段主要为双柱三跨钢筋混凝土箱型框架结构。车站总长580.8 m,标准段宽度为22.9 m。

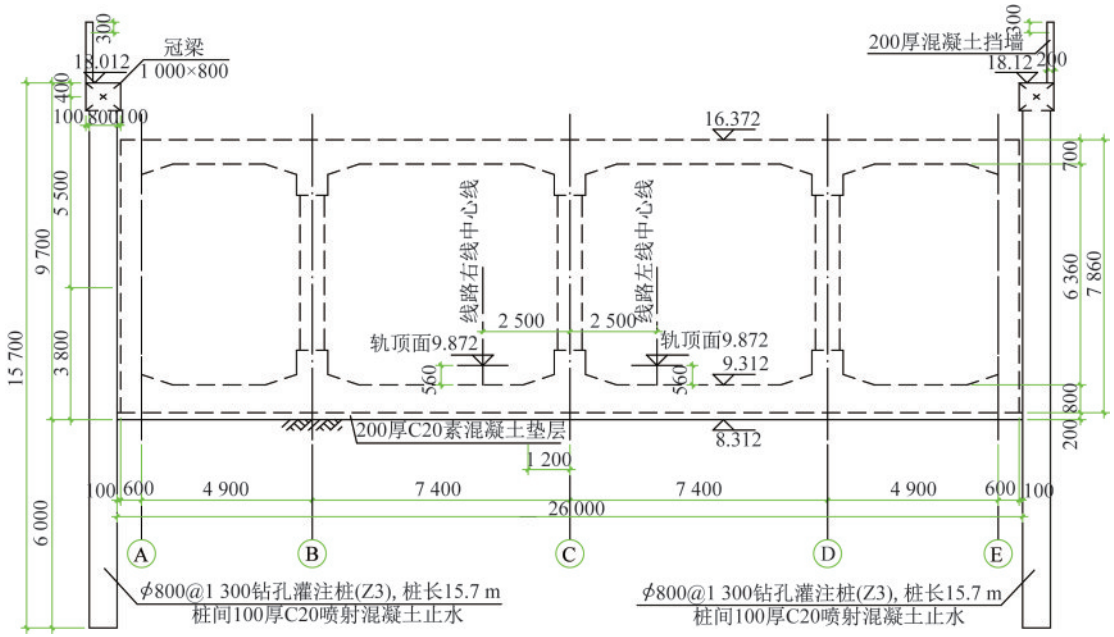


图 1　既有地铁车站结构横断面图

Fig.1　Cross section diagram of existing station structure

表 1　　拟建场地土体力学参数

Table 1　Mechanical parameters of soil in the proposed site

层号	土层类别	重度/(kN·m^{-3})	黏聚力/kPa	摩擦角/(°)
1	人工填土	18.0	5.0	12.0
2	素填土	18.0	18.0	8.0
3	黏土	19.6	40.9	15.0
4	粉质黏土	20.1	29.4	17.8

新建地铁车站结构局部零距离下穿既有地铁车站，其中新建地铁车站部分采用暗挖法施工。新建地铁车站密贴下穿既有地铁车站，没有足够的起拱空间条件，传统拱形断面的设计方法难以满足现场施工要求。因此，新建车站采用平顶直墙 CRD 与多重主动预顶撑相结合的复合式工艺进行施工，如图 2 所示。

具体而言，新建地铁车站暗挖段为平顶直墙单层三跨结构，开挖毛洞净宽 23.50 m，高 8.07 m，按照设计方案将车站分为两行七列共 14 个导洞开挖，单个导洞最大开挖高度为 3.9 m，最大宽度为 3.5 m。新建地铁车站暗挖段初期支护为 300 mm 厚，由 C25 喷射混凝土、钢筋网、锁脚锚杆及钢格栅（钢筋格栅及钢架格栅）组成支护体系，拱顶超前支护采用预注浆，格栅间距控制在 0.5 m；二次衬砌结构为暗挖段车站的顶板、底板及侧墙。

本工程通过分导洞分步开挖、优先施工竖向受力构件、超前预注浆加固土体等方法，减少暗挖车站施工对周围环境的影响。同时，在施工工序的不同阶段采用千斤顶预压地层，实现对既有车站结构沉降的动态精准控制。

2　现场监测

2.1　现场监测方案

由于新建车站暗挖段施工时，地层开挖会改变原结构的受力状态，若施工不当容易造成既有地铁车站变形，增大地表的沉降，严重时甚至引起既有地铁车站结构破坏。同时，新建地铁车站施工过程中土体卸载、主体结构加载及超前注浆加固等活动可能造成既有车站结构下沉、侧移及隆起，变形过大将导致结构开裂、漏水及轨面标高不满足轨道安全运营要求等严重后果。因此，根据本工程的环境条件，既有车站的变形是重点监测对象。通过现场监测信息反馈和现场施工情况，及时调整施工的速度和方法，并采取相应的工程措施，优化施工工艺，达到工程优质、安全施工、经济合理、施工快捷的目的。

现场监测内容主要包括既有车站结构竖向及水平位移、裂缝、轨道横向及轨向高差、轨间距、道床脱空量等，如图 3 所示。监测点的布设原则必须满足 GB 50911—2013、GB 50497—2019 及其他相关规范的要求，同时应结合预评估分析，在结构变形较大的区域和位置加密监测点布置。

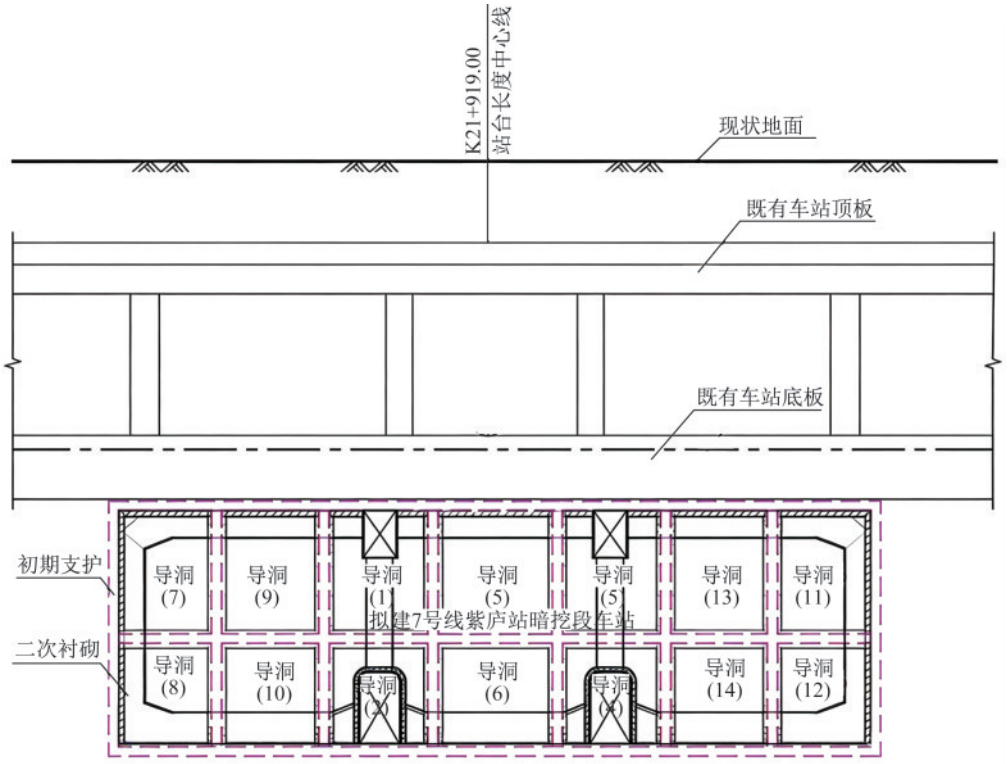


图2 新建地铁车站暗挖段开挖示意图

Fig.2 Schematic diagram of excavation for the hidden excavation section of the newly-built station

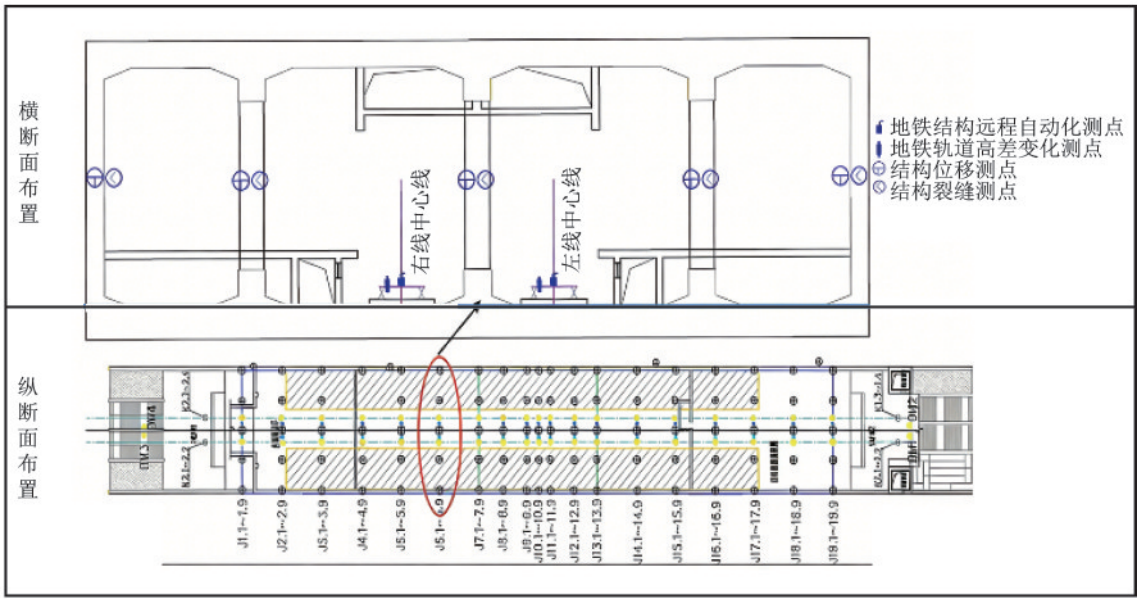


图3 既有地铁车站监测点布置示意图

Fig.3 Layout diagram of monitoring points for the existing station

本工程现场监测方式以自动化监测为主，并辅以现场人工监测。现场自动化监测系统主要由数据采集、数据传输、控制系统、告警系统、数据处理、数据分析和数据管理等部分组成，涉及的主要仪器有监测机器人徕卡TM30全站仪、GPRS通讯模块、监测软件GeoMoS及现场IT设备等。

新建地铁车站暗挖段施工期间监测频次为4次/d，当施工至关键工况或遇到暴雨等恶劣天气状况以及预评估中变形较大区域及最不利危险点时应加密监测频率，当达到或超过预警值时应采取实时监测。

2.2　现场监测数据分析

通过上述现场监测方案及时采集监测数据并进行分析，有利于探究暗挖段不同施工工序及施工方式对既有车站结构的影响，分析结构安全状态。

由于本项目中既有车站结构竖向位移是密贴施工中需要关注的重点监测对象，工程沿既有地铁车站结构纵向布设 19 个监测点，即 J1.5—J19.5，车站中心处适当加密监测点。现场既有车站结构竖向位移分析基于测点 J1.5、J5.5、J10.5、J15.5 及 J19.5 展开，如图 4 所示。

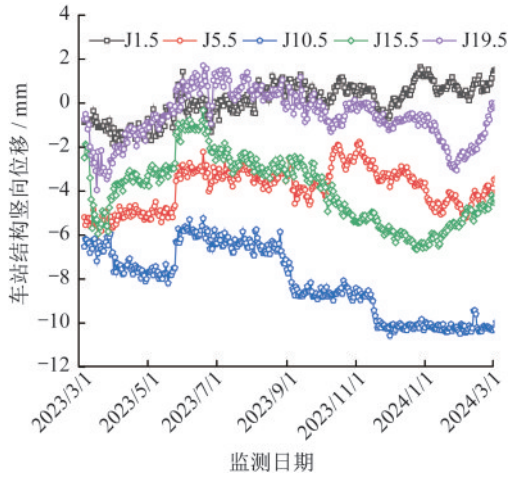


图 4　时间维度既有车站结构竖向位移监测值

Fig.4　Development of measured vertical displacement of the existing station with time

由图 4 既有车站结构竖向位移可知，前期五个监测点的结构竖向位移变化趋势大致相同，后期监测点 J1.5、J5.5、J15.5 及 J19.5 的位移发展具有相似的变化规律，施工期间竖向位移值相对变化量较小。然而，随着施工过程的进行，监测点 J10.5 与其他监测点之间的竖向位移变化差异性逐渐增大，呈现阶梯形下沉趋势。

监测点 J1.5 和 J19.5 处于既有车站结构的两端，距离新建暗挖车站断面较远，受到的施工扰动影响较小，因此整体沉降值较小。相对而言，监测点 J5.5 和 J15.5 与新建暗挖车站断面的距离较小，新建车站施工对既有车站结构沉降的影响增强，此处的沉降值有明显提升。监测点 J10.5 位于既有车站结构中间位置，受新建车站施工影响显著。在 2023 年 3 月至 6 月期间，由于现场进行渗漏水处置施工，开挖掌子面渗漏水封堵注浆及超前加固，导致此期间监测点 J10.5 处的既有车站结构位移呈现下沉趋势，而在渗漏水封堵注浆及超前加固完成后，车站结构有明显的隆起，随后进行了新建地铁车站导洞 1 和导洞 2 的开挖，可以看出在导洞开挖过程中由于采用平顶直墙 CRD 工法与复合式主动支顶等工艺，导洞开挖过程中对于既有车站结构竖向位移的控制效果较好，整体变化趋势较为平稳。然而，在导洞拆除部分甚至全部初期支护后，上部既有车站在新建车站未形成完整承载受力体系的情况下产生较大竖向沉降。因此，在施作二次衬砌时，应充分利用周围土体及二衬结构应力重分布的时空效应，形成良好的受力托换体系。

为了进一步分析既有车站结构空间维度上的变形规律，以五个竖向位移监测点在 2023 年 3 月 31 日车站堵漏、2023 年 7 月 30 日导洞开挖、2024 年 2 月 26 日衬砌施工期间采集到的现场监测数据为例展开分析，如图 5 所示。

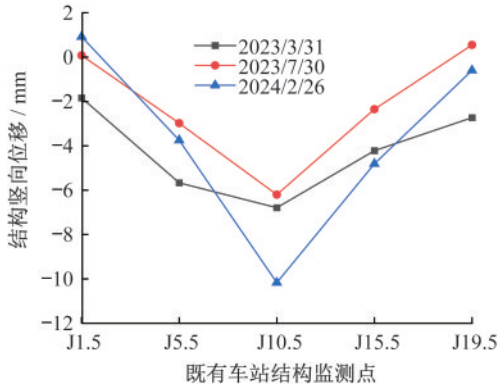


图 5　空间维度既有车站结构竖向位移监测值

Fig.5　Distribution of measured vertical displacement of the existing station

由图 5 既有结构位移空间分布规律可以看出，既有车站结构竖向位移在空间维度上呈现出中间大两边小的“Peck”型沉降变形规律。新建车站开挖处既有车站结构变形值最大，且随着与新建地铁车站中心水平距离的增加，施工扰动的影响逐渐降低，具体表现为：既有车站结构在 2023 年 3 月 31 日—2023 年 7 月 30 日车站堵漏期间的变形曲线较为平缓，而在 2024 年 2 月 26 日车站施工期间的变形曲线明显变陡，变形速率逐渐增大。

以监测点 J5.5、J10.5、J15.5 监测数据为例，分析新建暗挖车站施工对既有车站结构水平位移变化的影响，如图 6 所示。

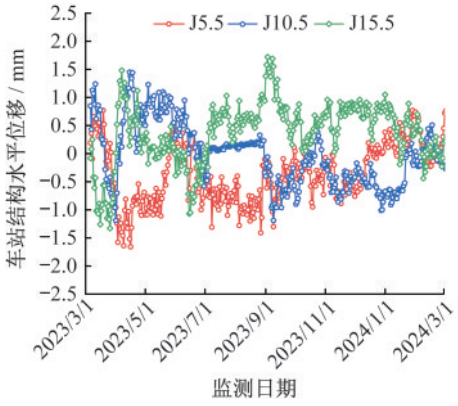


图6 既有车站结构水平位移监测值

Fig.6 Measured horizontal displacement of the existing station

由图6可知，三个监测点在监测过程中水平位移变化幅值较小且大致相同。监测点J10.5的初始变形量与最终变形量趋于一致，且呈现波动趋势。这主要是因为采集的现场监测数据与导洞1、2、3、4的开挖过程相对应，导洞1、2与导洞3、4关于监测点J10.5所处的结构中心位置对称，施工过程中的导洞开挖及超前注浆等工艺对既有车站结构产生的附加变形会相互抵消。监测点J5.5和J15.5关于车站中心对称，故两条结构水平位移变化曲线具有明显的负相关关系。与既有车站结构竖向位移相比，新建车站暗挖段施工对上部既有车站结构水平位移的影响较小，满足密贴下穿工程对既有结构的变形控制标准。因此，实际施工过程应重点关注既有车站结构的竖向位移变化，加密监测点布置并提高监测频率。

除了既有车站结构竖向及水平位移外，轨道横向及轨向高差、轨间距、道床脱空量等也属于密贴下穿工程施工过程中需要监测的重要对象。若产生较大变形且处理不及时，容易影响既有轨道交通运营安全，造成严重的安全事故。

同时，选取既有轨道交通结构上行线及下行线对应监测点进行变形规律分析，如图7所示。上行线道床沉降监测点J1.7和J19.7变形曲线基本一致且波动较小，监测点J5.7和J15.7变形曲线具有一定的正相关关系；下行线监测点J1.3和J19.3处道床沉降呈现负相关特性，且监测点J1.3和J19.3处的变形曲线基本一致。整体来说，上行线监测点J10.7和下行线监测点J19.3处的变形曲线均呈现阶梯形下降趋势，但上行线道床在初期具有一定的抬升变形，这与施工过程中超前预注浆的加固范围相关。

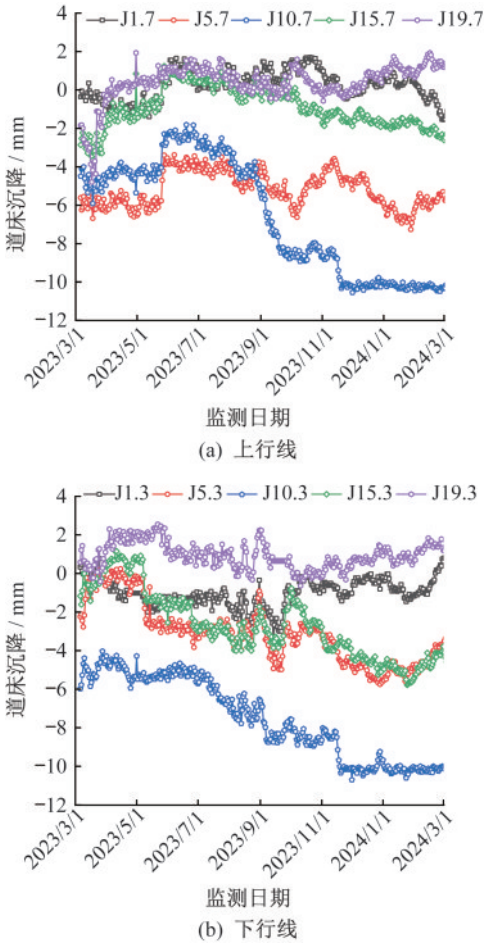


图7 道床沉降监测值

Fig.7 Development of measured roadbed settlement

由上述分析可知，新建车站施工对既有车站及轨道交通结构的影响主要集中在暗挖下穿既有结构中心位置。因此，后续变形规律分析主要针对既有结构中心监测点所采集的现场数据。

选取既有轨道交通结构上行线监测点J10.7—J10.6以及下行线监测点J10.4—J10.3分析轨距变化曲线，如图8所示。可以看出，施工初期上行线及下行线轨距变形趋势相反，后续变形趋势基本吻合，且变形量在安全控制范围内。

既有轨道交通结构轨向和横向高差，如图9所示。由图9可知，在施工期间，无论是轨道横向高差还是轨向高差，上行线与下行线监测点的变形曲线呈对称分布，具有明显的负相关性。相比轨向高差而言，横向高差变形幅值较大，且上行线与下行线的差异性更明显，表明实际工程中轨道横向高差更容易受到新建车站施工扰动的影响，应根据现场监测数据及时反馈并调整施工方法及控制措施。

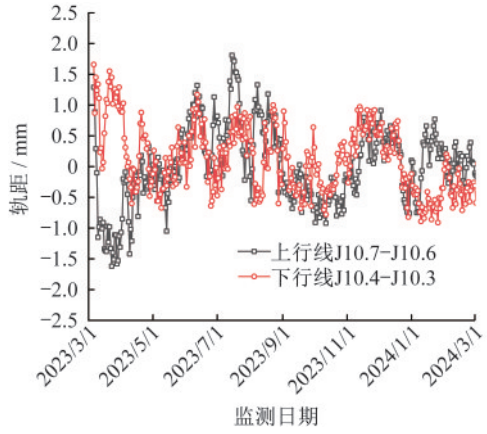
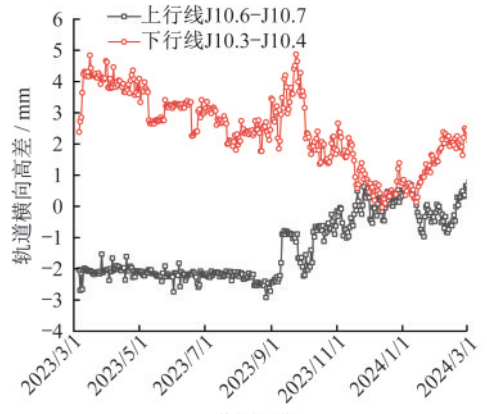
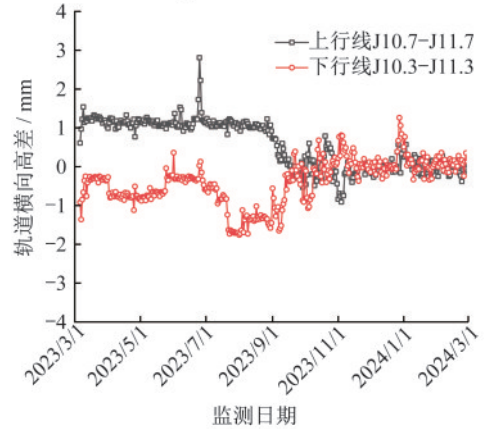


图 8　轨距监测值

Fig.8　Development of measured track gauge



(a) 轨道横向高差



(b) 轨道轨向高差

图 9　轨道高差监测值

Fig.9　Development of measured track elevation difference

3　结构变形预测方法

由现场监测数据分析可知，新建车站暗挖施工会对既有车站结构竖向位移、道床沉降、轨道横向高差等产生较大影响。当变形值较大时，容易对车站结构及轨道交通运营安全状态产生不利影响。因此，开展结构变形预测方法研究可以分析未来变形发展趋势，从而采取预防性控制加固措施，这对于保护既有结构的安全性和稳定性具有重要意义。本文以既有车站结构竖向位移为例，基于 LSTM 神经网络，结合先验信息约束及 AWPSO 算法建立密贴下穿工程结构变形预测方法。

3.1　方法及原理

3.1.1　长短期记忆人工神经网络

LSTM 是一种特殊的循环神经网络（RNN），通过独特的门机制来控制信息的流动，有效地解决了传统 RNN 在长时间序列中存在的梯度消失或梯度爆炸等问题，主要用于处理和预测时间序列数据。图 10 展示了 LSTM 单元的结构设计，主要分为遗忘门、输入门、细胞状态及输出门四个组件，各组件的主要原理介绍如下：

（1）遗忘门。遗忘门 f_t 决定当前时间步长中哪些信息需要遗忘。它接受前一时间步的隐藏状态 h_{t-1} 和当前输入 x_t，并生成一个介于 0 和 1 之间的值，表示信息遗忘的程度。

$$f_t=\sigma\left(W_{\mathrm{f}}\cdot\left[h_{t-1},x_t\right]+b_{\mathrm{f}}\right) \tag{1}$$

式中：W_{f} 为权重矩阵；b_{f} 为偏置项；σ 表示为 Sigmoid 函数。

（2）输入门。输入门控制更新单元状态的程度。通过接收隐藏状态 h_{t-1} 和当前输入 x_t，生成两个输出，即分别为输入门的激活值 i_t 和候选状态 $\tilde{C}$。

输入门激活值可以表示为

$$i_t=\sigma\left(W_{\mathrm{i}}\cdot\left[h_{t-1},x_t\right]+b_{\mathrm{i}}\right) \tag{2}$$

候选状态则为

$$\tilde{C}=\tanh\left(W_{\mathrm{C}}\cdot\left[h_{t-1},x_t\right]+b_{\mathrm{C}}\right) \tag{3}$$

式中：W_{i} 和 W_{C} 为权重矩阵；b_{i} 和 b_{C} 为偏置项；tanh 为双曲正切函数。

（3）细胞状态更新。LSTM 的细胞状态 C_t 是信息传递的主线。细胞状态根据遗忘门和输入门的输出进行更新：

$$C_t=f_t*C_{t-1}+i_t*\tilde{C} \tag{4}$$

式中：C_{t-1} 是前一个时间步的细胞状态，*表示逐元素乘积，即 Hadamard 乘积。

（4）输出门。输出门决定当前时间步的隐藏状态，并控制信息流向下一步。

输出门的激活值o_t可用下式表达：

$$o_t=\sigma\left(W_o\cdot\left[h_{t-1},x_t\right]+b_o\right) \tag{5}$$

最终的隐藏状态h_t则为

$$h_t=o_t*\tanh\left(C_t\right) \tag{6}$$

式中：W_o为权重矩阵；b_o为偏置项。

LSTM的基本工作原理可以概括为：在每个时间步t，接收当前输入x_t和上一时刻的隐藏状态h_{t-1}和细胞状态C_{t-1}；通过遗忘门、输入门和输出门计算得到当前时刻的门值f_t、i_t、o_t及候选状态$\tilde{C}$，更新细胞状态C_t和隐藏状态h_t；将当前时刻的隐藏状态h_t和细胞状态C_t继续传给下一时刻，进而实现对长期依赖关系的有效捕捉，在时间序列预测任务领域中表现出优异的性能。

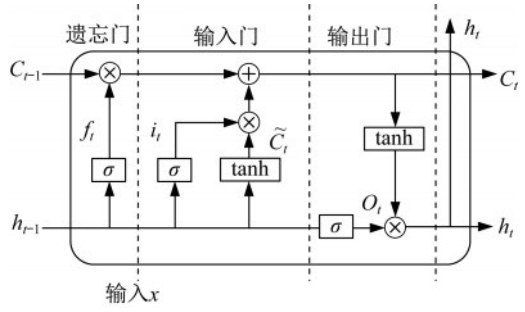


图10 LSTM单元结构示意图

Fig.10 Structural diagram of LSTM neural unit

本文所采用的具体LSTM网络结构见图11，主要包括输入层、两层LSTM、全连接层以及输出层。首先，输入序列经由输入层传递到第一层LSTM进行训练及信息处理，然后第一层LSTM的输出作为第二层LSTM的输入进一步提取深层次特征，并将最后一个LSTM单元的处理信息传递至全连接层；最后，将全连接层处理后的信息传递至输出层输出下一时刻的预测结果。

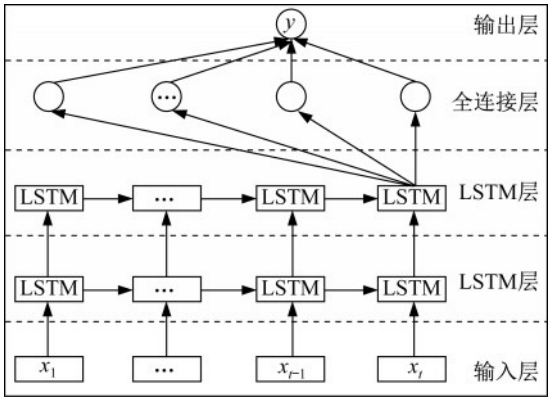


图11 LSTM单元结构示意图

Fig.11 Structural diagram of LSTM neural unit

传统LSTM多任务模型仅从数据驱动的角度出发，难以有效捕捉不同时间序列间的关联性特征，在小样本数据情况下模型表现性能较差，容易出现过拟合情况，且缺乏可解释性和泛化性。结合图5分析结果可知，既有车站结构竖向位移在空间维度上呈现出“Peck”型变形规律，不同监测点的变形序列具有明显的空间关联性。

Peck公式最开始用来表征隧道开挖引起的地表沉降变形，但可以用来描述密贴工程下穿结构的空间变形特征。可以表示为：

$$S(x)=S_{\max}\cdot\exp\left(-\frac{x^2}{2i^2}\right) \tag{7}$$

式中：$S(x)$表示地表在水平距离x处的沉降量；$S_{\max}$表示地表沉降槽的最大沉降量，即地表沉降曲线的峰值；x是与隧道中心线的水平距离；i表示沉降槽宽度参数，通常与隧道深度和开挖直径相关。

Peck公式中的参数$S_{\max}$及i是通过既有车站结构竖向位移的现场实测数据拟合得到。具体而言，在每一时刻基于多个监测点的实测位移，采用最小二乘法对Peck公式进行拟合，反演得到对应的参数。本文进一步选取了变形发展过程中的典型时刻监测数据并绘制Peck公式拟合曲线进行对比，如图12所示。可以看出，采用Peck公式得到的拟合曲线与实测值吻合度较高。此外，为避免个别时刻结果的偶然性影响，对所有时刻既有车站结构竖向位移实测值的拟合结果进行统计分析。结果表明，平均拟合优度R^2及平均均方根误差$RMSE$分别为0.920和0.966，Peck公式在时间维度上具有较好的拟合稳定性。

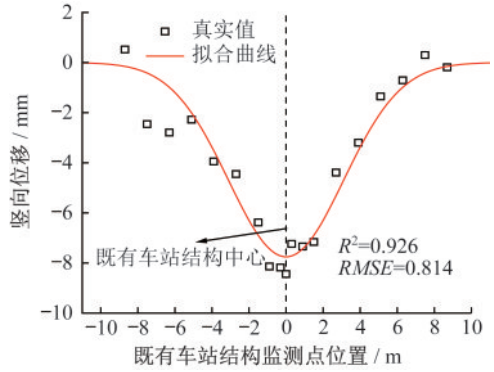


图12 结构竖向位移实测值与Peck公式拟合曲线对比

Fig.12 Comparison between measured vertical displacements and the fitted Peck-type curve

值得注意的是，在密贴下穿施工条件下，既有车站结构的整体刚度、地层条件及施工工艺等因

素均会对结构变形特征产生影响，其实际变形过程并不完全等同于自由地层条件下的典型 Peck 地表沉降槽。因此，本文引入 Peck 公式并非假定结构变形严格服从该经验规律，而是将其作为一种具有明确工程物理背景的空间分布先验，用于约束多监测点预测结果在空间尺度上的整体一致性与工程合理性。融合先验信息约束和数据约束构建损失函数 L，可以表示为：

$$L=\lambda_{\text{data}}L_{\text{data}}+\lambda_{\text{peck}}L_{\text{peck}} \tag{8}$$

式中：L_{data} 和 L_{peck} 分别表示数据损失项和先验信息损失项；λ_{data} 和 λ_{peck} 分别表示两种损失项的权重因子。

先验信息约束损失项可以表示为：

$$L_{\text{peck}}=\frac{1}{m}\sum_{i=1}^{m}\left[y_{i\text{p}}-S\left(x_i\right)\right]^2 \tag{9}$$

式中：m 是样本总数量；$y_{i\text{p}}$ 是第 i 个样本实测值。

在本文提出的预测框架中，既有车站结构的整体刚度、周围地层的力学性质以及新建车站的施工工艺等复杂效应，均通过现场监测数据的时间演化特征得到隐含体现，并由 LSTM 网络进行学习建模，从而使预测模型在一定程度上具备良好的灵活性与泛化能力。而 Peck 公式作为一种具有明确工程物理背景的先验信息，在空间分布层面提供主导变形形态约束，用以抑制小样本条件下多监测点预测结果可能出现的空间失衡现象。因此，在具有典型 Peck 公式变形特征的工程场景中，该方法具有较好的适用性。

数据损失项和先验信息损失项权重因子是决定预测模型性能的关键超参数，难以通过人为试验的方式确定其最优组合。因此，本文拟采用改进的粒子群优化算法（Particle Swarm Optimization，PSO）确定其最优组合。

3.1.2 自适应惯性权重粒子群优化算法

粒子群优化算法（PSO）是一种由 Kennedy 和 Eberhart 首次提出的启发式全局优化算法。PSO 算法灵感来源于鸟群觅食行为，其基本思想是通过模拟一群个体（即“粒子”）在搜索空间中移动，协同寻找全局最优解。每个粒子代表问题空间中的一个可能解，并具有速度和位置两个属性。粒子的位置表示当前解，速度则用于更新位置，经过不断迭代追踪粒子和种群的最优位置即可获得所求问题的最优解。

在 PSO 算法中，粒子的更新依据两个主要原则：个体最佳位置和全局最佳位置。个体最佳位置 *pbest* 是粒子在搜索过程中的历史最佳位置，而全局最佳位置 *gbest* 是所有粒子中经历的最佳位置。粒子的速度和位置更新公式如下：

$$\begin{aligned}v_i(t+1)=&wv_i(t)+c_1r_1\left[pbest_i-x_i(t)\right]+\\&c_2r_2\left(gbest-x_i(t)\right)\end{aligned} \tag{10}$$

$$x_i(t+1)=x_i(t)+v_i(t+1) \tag{11}$$

式中：$v_i(t)$ 表示第 i 个粒子第 t 次迭代时的速度；$x_i(t)$ 表示第 i 个粒子第 t 次迭代时所处的位置；w 表示惯性权重，调节粒子的搜索能力及收敛性，c_1 和 c_2 是个体及社会学习因子，分别表示粒子和群体最优位置的影响权重；r_1 和 r_2 是（0，1）之间的随机数，可以增加算法的随机性和多样性。

然而，PSO 算法存在局部搜索能力较弱和易于陷入早熟收敛等不足。惯性权重是 PSO 算法的关键参数之一，通过改变粒子寻优的变化速率进而影响到全局搜索和局部搜索的平衡。因此，众多学者针对常值惯性权重、随机惯性权重、时变惯性权重、混沌惯性权重以及自适应惯性权重五个方面进行了粒子寻优策略改进，并取得了丰富的研究成果。

自适应惯性权重根据算法性能反馈动态调整权重值，能够有效平衡算法在不同阶段的全局搜索与局部搜索能力，在实际应用中展现出显著的优势。因此，本文针对自适应惯性权重改进策略开展相关研究。首先，定义粒子 i 在 t 时刻与全局最优位置的距离为 $k_i(t)$，用下式表示：

$$k_i(t)=\sqrt{\sum_{d=1}^{D}\left(x_{id}(t)-gbest\right)^2} \tag{12}$$

式中：D 代表寻优空间维度。

然后结合 Sigmoid 函数建立自适应惯性权重动态调整公式为

$$w_i(t)=\frac{1}{1+\exp\left[-k_i(t)\right]} \tag{13}$$

联立式（10）—式（13）即可形成自适应惯性权重粒子优化（AWPSO）算法。该算法具有以下特点：当粒子当前位置与全局最优位置相对距离增大时，惯性权重会相应增加，提升粒子的全局搜索能力；相反，惯性权重会随之减小，增强粒子的局部搜索能力。基于这种改进策略，粒子的全局和局部搜索能力会得到有效平衡，进而提升算法的寻优效率和寻优精度。

3.2 预测模型构建

本文搭建的结构变形预测模型框架如图13所示，主要包括数据预处理、超参数寻优、数据与先验信息约束、模型训练等模块。

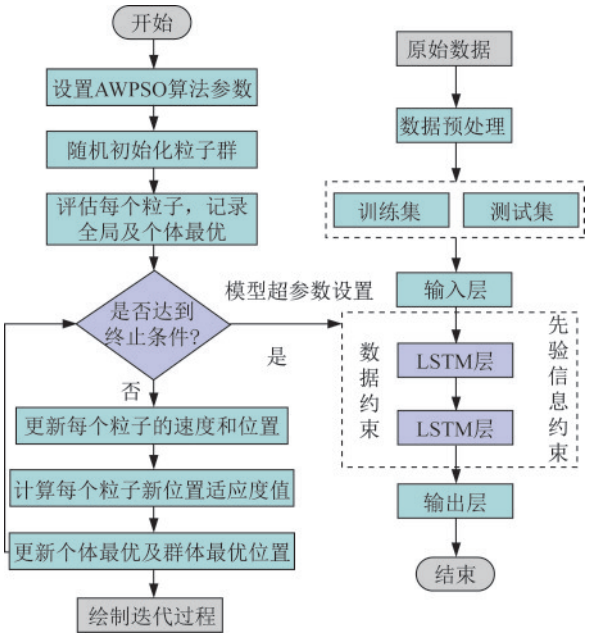


图13 结构变形预测模型框架

Fig.13 Framework for structural deformation prediction model

3.2.1 数据预处理

首先基于拉依达准则对结构变形数据进行降噪处理，并采用线性内插法填补缺失值。随后采用下式对变形数据进行归一化处理。

$$y_n=\frac{y-y_{\min}}{y_{\max}-y_{\min}} \tag{14}$$

式中：y及y_n分别为样本归一化前后的参数值；$y_{\max}$为归一化前某一参数的最大值；$y_{\min}$为归一化前某一参数的最小值。

将数据预处理后的样本数据按照80%和20%的比例划分训练集和测试集。

3.2.2 模型超参数设置

综合考虑模型训练的计算成本与收益，本文采用提出的AWPSO算法确定数据损失项和先验信息损失项权重因子的最优超参数组合。AWPSO算法相应的搜索维度设置为2，个体学习因子取c_1=1.8，社会学习因子取c_2=1.8。同时为了保证模型的高精度性和稳定性，通过多次试验确定粒子数量设置为5，迭代次数设置为50。其余模型超参数则通过试验及既有研究确定，最终设置时间窗口大小为10、隐藏层神经元数量为32、批处理大小为16、LSTM层数为2、Adam优化器学习率为0.001、训练轮次为500。

3.2.3 评价指标

选取均方误差、均方根误差、平均绝对误差以及拟合优度作为结构变形预测模型的性能评价指标，分别由下式表示：

$$MSE=\frac{1}{m}\sum_{i=1}^{m}\left(y_{ip}-y_i\right)^2 \tag{15}$$

$$RMSE=\sqrt{\frac{1}{m}\sum_{i=1}^{m}\left(y_{ip}-y_i\right)^2} \tag{16}$$

$$MAE=\frac{1}{m}\sum_{i=1}^{m}\left|y_{ip}-y_i\right| \tag{17}$$

$$R^2=1-\frac{\sum_{i=1}^{m}\left(y_{ip}-y_i\right)^2}{\sum_{i=1}^{m}\left(y_{ave}-y_i\right)^2} \tag{18}$$

式中：y_i是第i个样本实测值；y_{ave}是样本平均值。

3.3 模型验证

选取工程案例中既有车站结构的四个竖向位移监测点J2.5、J6.5、J14.5及J18.5作为研究对象，共计368组数据，时间跨度约为一年。考虑到密贴下穿工程的高度复杂性以及不同监测点竖向位移之间显著的时空相关性，本文将该数据集视为典型的小样本工程数据集。在确定模型最优超参数之后，进行模型的训练，如图14所示。通过优化算法确定的数据约束和先验信息约束损失权重因子分别为0.9和0.11。

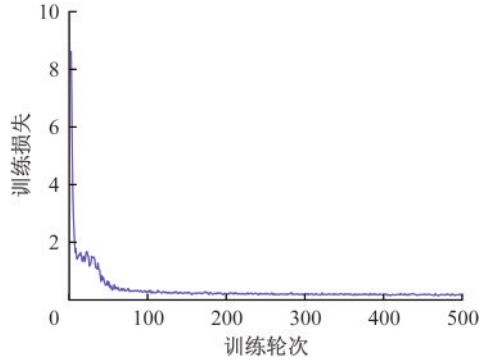


图14 损失曲线

Fig.14 Loss curve

在训练初期，训练集损失曲线急剧下降，后期变化相对较为平缓，表明模型的拟合和泛化能力都在迅速提高。模型损失值大约在100轮达到最优，然后保存当前最优参数并在测试集上进行预

测性能评估。

选取监测点J2.5和J6.5对比分析测试集中结构变形数据实测值和预测值之间的差异性，如图15所示。可以看出，模型的预测值与实测值基本吻合，在测试集上能够表现出较好的预测性能。

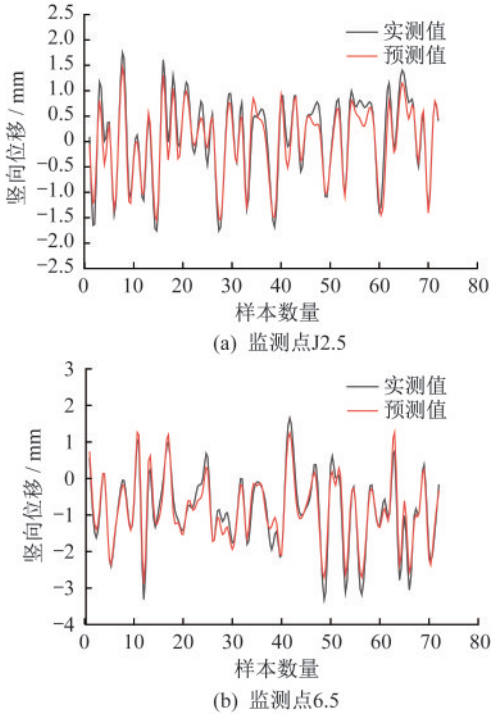


图15　测试集对比结果

Fig.15　Comparison results of test sets

为了更加直观地说明模型在测试集上的预测效果，对其监测点J2.5和J6.5进行数理统计分析，如图16所示。

由图16可知，监测点J2.5和监测点J6.5在测试集上的评价指标*MAE*、*RMSE*及R^2分别为0.185、0.237、0.920和0.222、0.272、0.932，均表现出较高的预测精度。

为进一步验证本文提出的AWPSO-LSTM-PIC预测模型的合理性和有效性，将其与LSTM和LSTM-PIC模型进行对比分析，结果如表2所示。传统LSTM模型在多监测点预测任务中各评价指标差异较大，以拟合优度R^2为例，其在不同监测点上的最大值与最小值分别为0.971和0.870，表明在小样本多任务预测条件下，单纯依赖数据驱动的模型难以同时兼顾各时间序列之间的空间关联性，容易出现预测结果不协调的问题。相比之下，引入先验信息约束后的LSTM-PIC模型在各监测点上的预测性能更加均衡，预测结果在空间分布上表现出更好的协调性。在此基础上，通过AWPSO算法

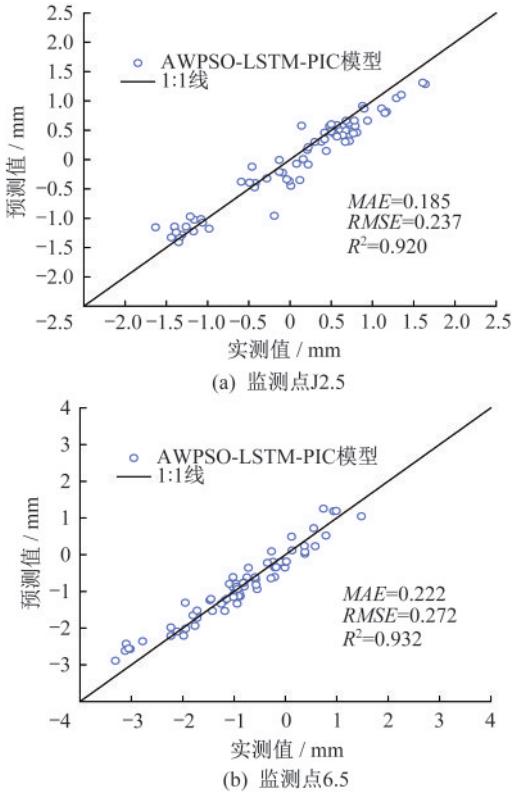


图16　测试集数理统计分析

Fig.16　Mathematical and statistical analysis of test sets

对数据约束项与经验信息约束项的损失权重进行优化，AWPSO-LSTM-PIC模型在保持多监测点预测协调性的同时进一步提升了整体预测精度。上述结果表明，Peck公式作为统一的空间变形模式约束，能够有效协调多监测点预测结果之间的空间关联性。综上所述，本文提出的AWPSO-LSTM-PIC模型通过引入具有明确工程物理意义的先验约束，在工程应用层面具备一定的可解释性，能够合理反映既有车站结构空间变形特征。

表2　三种模型预测结果对比

Table 2　Comparison of prediction results of three models

模型	指标	J2.5	J6.5	J14.5	J18.5
LSTM	*MAE*	0.216	0.202	0.200	0.267
	RMSE	0.276	0.248	0.259	0.340
	R^2	0.870	0.915	0.971	0.891
LSTM-PIC	*MAE*	0.224	0.225	0.266	0.247
	RMSE	0.272	0.271	0.322	0.311
	R^2	0.911	0.910	0.960	0.923
AWPSO-LSTM-PIC	*MAE*	0.185	0.193	0.229	0.222
	RMSE	0.237	0.233	0.273	0.271
	R^2	0.920	0.941	0.957	0.933

根据监测结果，新建车站主体明挖施工及暗挖段全断面注浆施工完成后，既有车站结构附加竖向位移最大值为8.0 mm。结合监测数据、现状调查、暗挖段设计要求、数值计算分析结果等，暗挖段施工期既有车站结构的竖向位移预警值为3 mm，控制值为5 mm。在此基础上，对AWPSO-LSTM-PIC模型的预测绝对误差进行了统计分析，如图17所示。

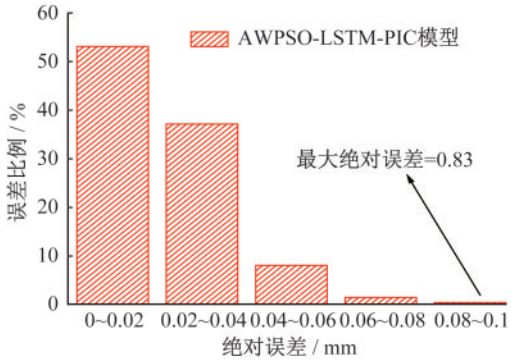


图17 测试集绝对误差统计分析

Fig.17 Statistical distribution of absolute prediction errors on the test set

结果表明，53.13%的模型预测误差分布在0~0.02 mm区间内，而预测误差大于0.04 mm的比例仅占9.72%，最大绝对误差值仅为0.83 mm，整体误差水平显著低于既有车站结构施工期的预警值与控制值。综上所述，本文提出的AWPSO-LSTM-PIC模型在工程尺度下具备较高的预测精度，能够有效识别结构变形发展趋势。在结合现场监测系统及既有工程控制阈值的前提下，该模型可为密贴工程条件下既有车站结构变形控制提供实时预警与决策辅助支持。

4 结 论

本文以某新建地铁车站密贴下穿既有车站为工程背景，开展新建车站施工对上部既有地铁结构的扰动变形规律及预测模型研究。主要结论如下：

（1）采用平顶直墙CRD与多重主动预顶撑相结合的复合式工艺可以实现既有结构变形动态控制，降低新建车站暗挖施工对既有结构的影响。新建车站暗挖施工对既有结构的竖向位移、轨道横向高差及道床沉降的影响更加显著，最大值基本处于结构中心位置。

（2）Peck公式的平均拟合优度R^2及平均均方根误差*RMSE*分别为0.920和0.966，在时间维度上具有较好的稳定性。可将其作为一种具有明确工程物理背景的空间分布先验，用于约束多监测点预测结果在空间尺度上的整体一致性与工程合理性。

（3）传统LSTM模型在不同监测点的预测性能差异性较大，拟合优度R^2的最大值和最小值分别为0.971和0.870，而加入先验信息约束的LSTM-PIC模型的性能评价指标更为均匀协调，提升了模型在隧道穿越引起既有结构沉降预测方面的泛化能力。

（4）AWPSO-LSTM-PIC模型能够有效利用先验信息约束和超参数寻优模块，在小样本多任务预测问题中具有较为优异且均匀的预测性能，平均拟合优度R^2达到0.938，在工程应用层面具备一定的可解释性，能够合理反映既有车站结构空间变形特征。

（5）AWPSO-LSTM-PIC模型中，53.13%的预测绝对误差分布在0~0.02 mm区间内，而预测误差大于0.04 mm的比例仅占9.72%，最大绝对误差为0.83 mm，可为密贴工程条件下既有车站变形控制提供实时预警与决策辅助支持。

本文提出的预测框架属于数据驱动与先验信息约束耦合的通用建模思想。在不同的工程条件下，可通过替换或扩展先验信息约束形式，使其能够合理表征该工程的主导变形机理，从而进一步提升模型在实际工程中的适用性。

参 考 文 献

[1] 赵世永.地铁车站坑中坑开挖施工中支护体系转换对周围环境的影响[J].科学技术与工程，2022，22(3)：1154-1159.
Zhao Shiyong. Impact of support system conversion on surrounding environment during pit-in-pit excavation of subway station [J]. Science Technology and Engineering, 2022, 22(3): 1154-1159. (in Chinese)

[2] Das R, Singh P K, Kainthola A, et al. Numerical analysis of surface subsidence in asymmetric parallel highway tunnels [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2017, 9(1): 170-179.

[3] Liang R, Xia T, Hong Y, et al. Effects of above-crossing tunnelling on the existing shield tunnels [J].

Tunnelling and Underground Space Technology, 2016, 58: 159-176.

[4] Bilotta E, Paolillo A, Russo G, et al. Displacements induced by tunnelling under a historical building[J]. Tunnelling and Underground Space Technology, 2017, 61: 221-232.

[5] 张振波, 王煦霖, 郑凯, 等. 双层车站零距离下穿既有车站变形控制技术[J]. 科学技术与工程, 2022, 22(2): 727-733.
Zhang Zhenbo, Wang Xulin, Zheng Kai, et al. Control technology of zero-distance under-passing existing station in new two layers station [J]. Science Technology and Engineering, 2022, 22(2): 727-733. (in Chinese)

[6] 刘天宇, 罗文俊, 颜建伟, 等. 基于能量法的双线下穿既有隧道沉降研究[J]. 工程科学与技术, 2024, 56(5): 203-211.
Liu Tianyu, Luo Wenjun, Yan Jianwei, et al. Analysis on settlement of existing tunnel induced by twin tunneling underneath based on energy method [J]. Advanced Engineering Sciences, 2024, 56(5): 203-211.(in Chinese)

[7] 张顶立, 曹利强, 房倩. 城市隧道施工的环境力学响应预测及动态控制[J]. 北京交通大学学报, 2021, 45(4): 1-8.
Zhang Dingli, Cao Liqiang, Fang Qian. Environmental mechanical response prediction and in-process control of urban tunnel construction [J]. Journal of Beijing Jiaotong University, 2021, 45(4): 1-8.(in Chinese)

[8] Yu L, Zhang D, Fang Q, et al. Surface settlement of subway station construction using pile-beam-arch approach [J]. Tunnelling and Underground Space Technology, 2019, 90: 340-356.

[9] 杨宇杰, 江永旺, 牛晓宇, 等. 密贴下穿地铁车站的新建通道开挖方法对比分析[J]. 铁道建筑, 2022, 62(1): 107-110.
Yang Yujie, Jiang Yongwang, Niu Xiaoyu, et al. Comparison analysis of excavation cases of underpass tunnel which zero-distance going under through metro station [J]. Railway Engineering, 2022, 62(1): 107-110.(in Chinese)

[10] 麻建飞, 贺少辉, 李益铭, 等. 新建地铁车站密贴下穿长久运营车站预支顶开挖构筑技术[J]. 铁道标准设计, 2024, 68(8): 115-121.
Ma Jianfei, He Shaohui, Li Yiming, et al. Construction technology of pre-supported roof excavation for the newly-built metro station closely underpassing the long-service life station [J]. Railway Standard Design, 2024, 68(8): 115-121.(in Chinese)

[11] 李利, 王永红, 柏林. 大断面暗挖平顶直墙结构密贴下穿既有线沉降控制关键技术[J]. 北京交通大学学报, 2016, 40(2): 114-119.
Li Li, Wang Yonghong, Bai Lin. Key techniques for settlement control of large section mined tunnel with horizontal proof and straight wall closely crossing underneath the existing tunnel [J]. Journal of Beijing Jiaotong University, 2016, 40 (2): 114-119. (in Chinese)

[12] Tang L, Na S H. Comparison of machine learning methods for ground settlement prediction with different tunneling datasets[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2021, 13(6): 1274-1289.

[13] 徐利锋, 包佳建, 金晶晶. 深基坑旁侧既有地铁隧道变形影响分析及沉降预测[J]. 建筑结构, 2023, 53(S1): 2860-2864.
Xu Lifeng, Bao Jiajian, Jin Jingjing. Analysis of deformation influence and settlement prediction of existing subway tunnels on the side of deep foundation pit[J]. Building Structure, 2023, 53(S1): 2860-2864. (in Chinese)

[14] Zhang P, Wu H N, Chen R P, et al. Hybrid meta-heuristic and machine learning algorithms for tunneling-induced settlement prediction: A comparative study [J]. Tunnelling and Underground Space Technology, 2020, 99: 103383.

[15] 王锋. 基于SSA-LSTM模型的软岩隧道变形特征智能预测及应用研究[J]. 现代隧道技术, 2024, 61(1): 56-66.
Wang Feng. Study on intelligent prediction of the deformation characteristics of soft rock tunnel based on SSA-LSTM model and its application [J]. Modern Tunnelling Technology, 2024, 61 (1): 56-66. (in Chinese)

[16] 张士朝, 王亚琼, 高启栋, 等. 基于不同优化算法的隧道洞口段拱顶沉降SVR预测模型及其比较评价[J]. 现代隧道技术, 2023, 60(6): 139-150.
Zhang Shichao, Wang Yaqiong, Gao Qidong, et al. Tunnel portal section crown settlement SVR prediction models based on different optimization algorithms and their comparative evaluation [J]. Modern Tunnelling Technology, 2023, 60(6): 139-150.(in Chinese)

[17] 王立新, 王强, 钟宇健, 等. 基于BP神经网络的近接

施工对地铁结构影响反演分析[J].隧道建设(中英文),2022,42(S2):102-113.
Wang Lixin, Wang Qiang, Zhong Yujian, et al. Inversion analysis of influence of proximity construction on metro structure based on back propagation neural network [J]. Tunnel Construction, 2022,42(S2):102-113.(in Chinese)

[18] Zhang D M, Guo X Y, Shen Y M, et al. Data-and experience-driven neural networks for long-term settlement prediction of tunnel [J]. Tunnelling and Underground Space Technology, 2024, 147: 105669.

[19] Li Z, Ma E, Lai J, et al. Tunnel deformation prediction during construction: An explainable hybrid model considering temporal and static factors [J]. Computers & Structures, 2024, 294: 107276.

[20] 顾亦宁,艾青,王少纯,等.基于代理模型的地铁隧道结构变形预测数字孪生方法[J].城市轨道交通研究,2023,26(9):133-137.
Gu Yining, Ai Qing, Wang Shaochun, et al. Digital twin method for metro tunnel structure deformation prediction based on proxy model [J]. Urban Mass Transit, 2023, 26(9): 133-137.(in Chinese)

[21] 张东明,周烨璐,黄宏伟,等.物理信息双驱动的长距离盾构隧道结构纵向力学性态智能诊断方法[J].岩土力学,2023,44(10):2997-3010.
Zhang Dongming, Zhou Yelu, Huang Hongwei, et al. A physics and information dual-driven intelligent diagnosis method for longitudinal mechanical behavior of long-distance shield tunels [J]. Rock and Soil Mechanics, 2023, 44(10): 2997-3010.(in Chinese)

[22] Guo S, Lin Y, Feng N, et al. Attention based spatial-temporal graph convolutional networks for traffic flow forecasting [C]//Proceedings of the AAAI conference on artificial intelligence, 2019, 33(1): 922-929.