

# 基于 LSTM-DNN(长短期记忆-深度神经网络) 融合模型的土压平衡盾构土仓压力预测方法\*

王伯芝<sup>1,2</sup> 黄永亮<sup>1,2</sup> 陈文明<sup>3,4</sup> 丁爽<sup>3,4</sup> 刘浩<sup>2</sup>  
刘学增<sup>5</sup> 彭子晖<sup>6</sup> 吴炜枫<sup>6</sup> 王嘉烨<sup>6</sup>

(1. 山东大学齐鲁交通学院, 250002, 济南; 2. 济南轨道交通集团有限公司, 250014, 济南; 3. 上海同岩土木工程科技股份有限公司, 200092, 上海; 4. 上海地下基础设施安全检测与养护装备工程技术研究中心, 200092, 上海; 5. 同济大学土木工程学院, 200092, 上海; 6. 上海市隧道工程轨道交通设计研究院, 200235, 上海)

**摘 要** [目的]土仓压力是土压平衡盾构施工安全评估的关键参数,准确预测土仓压力有助于施工技术人员及时采取管控措施,进而保障地铁隧道的建设安全性。因此,有必要对土压平衡盾构土仓压力预测方法进行研究。[方法]提出一种多分支的 LSTM(长短期记忆)-DNN(深度神经网络)融合模型。LSTM 分支通过回溯历史数据提取其时序演变特征,DNN 分支提取掘进状态特征,将两者组合后通过全连接层进行融合,实现对土仓压力的预测。依托济南轨道交通 1 号线实际盾构隧道数据对模型进行验证,并与 LSTM 模型、DNN 模型进行了对比分析。[结果及结论]基于 LSTM-DNN 融合算法建立的土仓压力预测模型可以高效收敛,且所提模型在训练集和验证集上的预测效果良好。在后续的 100 步测试中,由 LSTM-DNN 融合模型得出的土仓压力预测值较好地反映了真实值的变化趋势,其平均偏差为 7.65 kPa,相对误差为 6.09%,预测精度较高。

**关键词** 城市轨道交通;土仓压力预测;长短期记忆;深度神经网络

中图分类号 U455.43

DOI:10.16037/j.1007-869x.2024.12.007

## Earth Chamber Pressure Prediction Method for Earth Pressure Balance Shield Based on LSTM-DNN Fusion Model

WANG Bozhi<sup>1,2</sup>, HUANG Yongliang<sup>1,2</sup>, CHEN Wenming<sup>3,4</sup>, DING Shuang<sup>3,4</sup>, LIU Hao<sup>2</sup>, LIU Xue-zeng<sup>5</sup>, PENG Zihui<sup>6</sup>, WU Weifeng<sup>6</sup>, WANG Jiaye<sup>6</sup>

(1. School of Qilu Transportation, Shandong University, 250002, Jinan, China; 2. Jinan Rail Transit Group, Co., Ltd., 250014, Jinan, China; 3. Shanghai Tongyan Civil Engineering Technology Co., Ltd., 200092, Shanghai, China;

4. Shanghai Underground Infrastructure Safety Testing and Maintenance Equipment Engineering Technology Research Center, 200092, Shanghai, China; 5. Civil Engineering College, Tongji University, 200092, Shanghai, China; 6. Shanghai Tunnel Engineering & Rail Transit Design and Research Institute, 200235, Shanghai, China)

**Abstract** [Objective] Earth chamber pressure is a key parameter for EPB (earth pressure balance) shield construction assessment. Accurate prediction of earth chamber pressure helps construction technicians take timely control measures to ensure subway tunnel construction safety. Therefore, it is necessary to study the earth chamber pressure prediction method of EPB shield. [Method] A multi-branch LSTM (long and short term memory)-DNN (deep neural network) fusion model is proposed. LSTM branch extracts its time series evolution characteristics by backtracking historical data, while DNN branch extracts excavation state characteristics. The two branches are combined and then integrated through a fully connected layer to realize the prediction of earth chamber pressure. This multi-branch model is verified based on the actual shield tunnel data of Jinan Rail Transit Line 1, and compared with LSTM and DNN models respectively. [Result & Conclusion] The prediction model of earth chamber pressure based on LSTM-DNN fusion algorithm can converge efficiently, and has good prediction effects on the training set and the verification set. In the subsequent 100-step test, the predicted value of earth chamber pressure obtained by the LSTM-DNN fusion model better reflects the change trend of the actual value, with an average deviation of 7.65 kPa and a relative error of 6.09%, indicating a higher prediction accuracy.

**Key words** urban rail transit; earth chamber pressure predic-

\* 山东省重点研发计划项目(重大科技创新工程)(2019JZZY010428);山东省自然科学基金项目(ZR2020QE256,ZR2020QE243);上海市“科技创新行动计划”启明星项目(扬帆专项)(22YF1446100);上海市青年科技英才扬帆计划项目(23YF1440500)

tion; LSTM; DNN

目前,土压平衡盾构机施工已经成为我国地铁建设的主要方法之一,土仓压力作为土压平衡盾构机的重要监测参数,其控制值直接影响着盾构掘进的安全、质量和效率。

为了预测土仓压力,已有学者利用理论推导、数值模拟、室内试验等技术方法,建立土仓压力的数学物理模型<sup>[1]</sup>。然而,盾构土仓压力受到复杂地质状况、渣土改良不确定性、掘进参数改变响应滞后性等因素的影响,较难建立精准的土仓压力预测模型。随着物联网技术的快速发展,现场施工数据已能实现高效收集与大量存储,因此,基于数据驱动的土仓压力预测研究逐渐成为了研究热点。

机器学习非常擅长挖掘数据之间的关联性。目前,已有学者开始将支持向量机<sup>[2-3]</sup>、随机森林<sup>[4]</sup>、BP(反向传播)神经网络<sup>[5-6]</sup>、LSTM(长短期记忆)神经网络<sup>[7]</sup>等机器学习算法应用于预测土仓压力。在实际盾构掘进过程中,盾构机司机可以通过观察历史土仓压力变化来调整掘进状态,实现当前土仓压力的平稳控制。因此,为了更好地挖掘出盾构机司机操作经验中隐含的规律,需要综合考虑盾构掘进参数时序特征和当前掘进状态特征。


鉴于此,为了准确预测土压平衡盾构的土仓压力,指导现场施工参数调整和安全管控,本文提出一种多分支的 LSTM-DNN(深度神经网络)融合模型,其中的 LSTM 分支用于挖掘掘进参数的时序演变特征,DNN 分支用于挖掘当前的掘进状态特征,将两者组合后通过全连接层进行融合,通过现场监控数据对模型进行训练和验证,最终实现盾构土仓压力的预测。本文研究可为盾构技术人员及时发现土仓压力数据异常、调整盾构掘进参数提供技术支持。

## 1 LSTM-DNN 融合模型

### 1.1 LSTM 单元

LSTM 单元是一种用于处理时间序列数据的网络结构,通过引入门控机制控制信息的流通和损失,能够很好地解决时间序列的长距离时序依赖问题。LSTM 单元结构示意图如图 1 所示。

LSTM 单元包含 3 个门控结构,分别为遗忘门、输入门、输出门。遗忘门的作用是控制历史信息被



注:  $x_t$  为当前时刻的输入信息;  $h_{t-1}$  为前一时刻的隐含层状态;  $\sigma$  为 Sigmoid 激活函数;  $i_t$  为当前时刻需要记忆的信息;  $g_t$  为当前时刻的候选记忆信息;  $\tanh$  为双曲正切激活函数;  $o_t$  为 Sigmoid 单元状态;  $C_t$  为记忆单元状态;  $f_t$  为遗忘门。

图 1 LSTM 单元结构示意图

Fig. 1 Schematic diagram of LSTM unit structure

遗忘的程度,可以表示为:

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

式中:

$W_f$ ——遗忘门的权重;

$b_f$ ——遗忘门的偏置项。

输入门的作用是控制当前信息被接受的程度,可以表示为:

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

$$g_t = \tanh(W_g[h_{t-1}, x_t] + b_g) \quad (3)$$

式中:

$W_i, W_g$ ——输入门需要记忆的信息、候选记忆信息的权重;

$b_i, b_g$ ——输入门需要记忆的信息、候选记忆信息的偏置项。

在遗忘门和输入门计算完成后,更新记忆单元,则有:

$$C_t = C_{t-1}f_t + i_tg_t \quad (4)$$

最终,通过输出门获得隐含层状态,可以表示为:

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

$$h_t = o_t \tanh C_t \quad (6)$$

式中:

$W_o$ ——输出层的权重;

$b_o$ ——输出层的偏置项。

### 1.2 DNN 模型

DNN 具有强大的非线性表达能力,通过逐层的特征提取与转换不断获得高级特征,最终通过特征融合获得输出结果。DNN 模型由输入层、多个隐藏层、输出层组成,且层与层之间是全连接的。DNN 模型结构示意图如图 2 所示。

在 DNN 模型中,通过上层神经元的线性组合




图 2 DNN 模型结构示意图

Fig. 2 Schematic diagram of DNN model structure

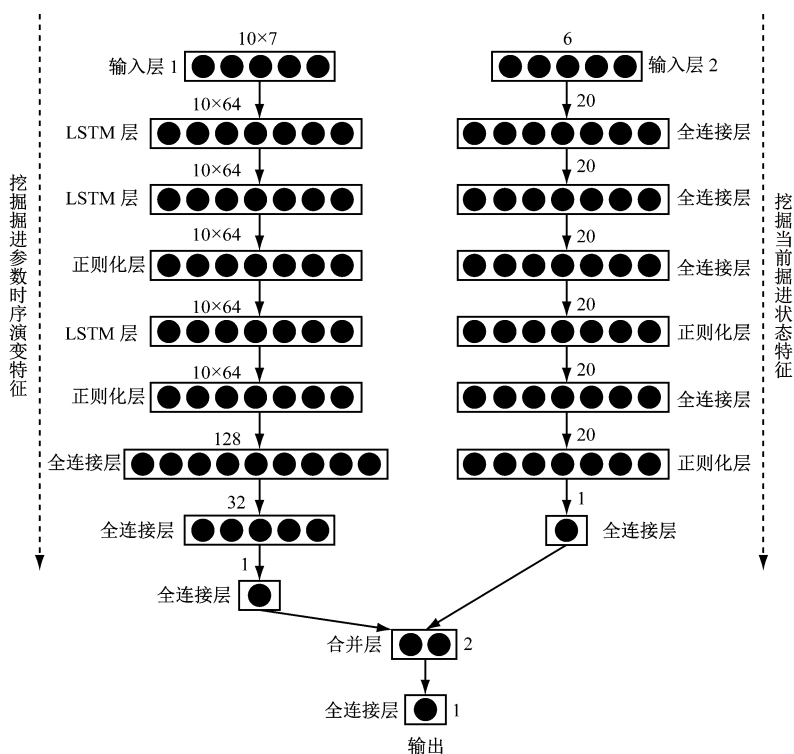
及激活函数转换来获取下层神经元的结果。激活函数的作用是提高 DNN 模型的非线性表达能力, 本文采用 Relu 函数作为激活函数。

### 1.3 LSTM-DNN 融合模型

当土压平衡盾构机需要调整土仓压力时, 盾构机司机通常既会参考历史土仓压力的变化趋势, 又会参考盾构机当前的掘进状态, 因此为了更好地挖

掘人工操作经验中的规律, 提出一种 LSTM-DNN 融合模型。其中, LSTM 模型分支用于提取时序演变特征, DNN 模型分支用于提取当前的掘进状态特征, 并将所提取的高级特征进行融合, 以获得最终的盾构土仓压力。本文所提 LSTM-DNN 融合模型结构示意图如图 3 所示。

目前, 已有的基于数据驱动建立的土压平衡盾构土仓压力预测模型往往仅有一个输入端口, 将反映掘进状态的参数或时序参数特征作为输入端, 以实现土仓压力的预测。考虑到时序数据是一种有序的数据结构, 而反映当前掘进状态的参数是无序的, 因此本文建立的 LSTM-DNN 融合模型拥有两个输入端口, 形成两个庞大的分支。其中: 输入端口 1 对应历史掘进参数形成的时序特征; 输入端口 2 对应当前时刻的掘进参数特征。



注: 图中数字为单元特征形状, 表示单元中需要训练优化的参数数量。

图 3 LSTM-DNN 融合模型结构示意图

Fig. 3 Schematic diagram of LSTM-DNN fusion model

对于输入端口 1 的时序特征, 通过依次由 LSTM、两层正则化 (Dropout) 的长短期记忆层、三层全连接层 (Dense) 组成的深层次 LSTM 模型分支来提取高级特征; 对于输入端口 2 的特征, 通过依次由两层全连接层、两层正则化的全连接层、全连接层组成的 DNN 模型分支来提取高级特征, 进一步

对高级特征进行合并 (Concatenate), 并通过全连接层获得最终的输出结果 (Output)。上述两个分支模型中均引入了 Dropout 技术, Dropout 是深度学习中常用的正则化技术之一, 可以有效降低模型发生过拟合的风险, 其主要思想是随机使部分神经元失活而减弱相邻神经元的适用性, 迫使各神经元发挥更

大的作用,最终建立的模型将不会依赖于少数神经元,对输入的微小变化不太敏感,进而提高模型的泛化能力。

为了实现土仓压力的精准预测,首先需要确定 LSTM-DNN 融合模型中的输入参数。土压平衡盾构机的土仓压力影响因素较多,主要包括刀盘扭矩、总推进力、刀盘转速、螺机转速、掘进速度,这 5 个确定性参数对土仓压力有着重要的影响<sup>[7]</sup>。此外,土仓压力还受到出土量的影响,然而,出土量往往通过现场施工人员估算得到,难以精准获得。考虑到螺机扭矩与出土量存在一定的相关性<sup>[8]</sup>,本文将螺机扭矩也作为输入参数。土仓压力的取值对掘进质量的控制起着重大作用,考虑到施工中会参考历史土仓压力的取值变化对当前状态进行调整,以提升施工质量,因而将历史土仓压力也考虑到模型的输入参数中。

另外,模型中的输入端口 1 还需确定时序特征的步长,若回溯历史数据的步长过小,则无法反映其演变特性;若回溯历史数据的步长过大,则无法捕捉到短距离内变化的地质状况。本文的步长选取范围为 5~15 步,经过试算,选取 10 步(对应 10 环盾构隧道管片施工过程)为步长,以获得满足工程要求的结果。综上所述,LSTM-DNN 融合模型中两个输入端口的特征形状分别为  $10 \times 7$ (包含历史土仓压力)、6(见图 3)。

## 2 案例数据来源及预处理

### 2.1 数据来源

本文的工况数据来源于济南轨道交通 1 号线玉符河站—王府庄站区间的左线盾构隧道,该隧道位于刘长山路正下方,下穿京沪铁路。盾构起点里程为 K27+087.056,终点里程为 K28+390.041,盾构段总长约为 1 303 m。该盾构隧道结构底板埋深约为 13.7~24.0 m,底板标高为 17.8~26.5 m。使用土压平衡盾构机进行掘进施工,盾构机的主要性能参数如表 1 所示。

### 2.2 数据预处理

盾构机是一种极其复杂的综合性机械设备,安装了大量监测系统以便进行数据采集。本文共收集到 800 步连续采集的 7 580 735 行数据(采集频率约为 1 Hz)。由于管片拼装、日常维护、故障等原因会导致盾构机处于非掘进状态,非掘进状态的数据统计意义不大,因此可直接剔除。依据掘进速度为

0 这一条件,识别非掘进状态。此外,每个循环段从启动到平稳运行往往需要一定的时间,该时间段内,盾构机的运行状态往往称为非平稳运行阶段,此处的运行时间取为 120 s,非平稳运行状态的数据也需剔除,最终仅保留平稳运行阶段的实时数据。第 100 步时,对比原数据、剔除非掘进状态后、剔除非平稳运行阶段后的掘进速度变化,掘进速度预处理前、后 3 种数据的取值变化情况如图 4 所示。

表 1 盾构机主要性能参数表

Tab. 1 Main performance parameters of the shield machine

参数	取值或说明
型号	CTE6650
开挖直径/mm	6 680
整机总长/m	85
装机功率/kW	1 815
刀盘开口率/%	40
最大掘进速度/(mm/min)	80
最大刀盘转速/(rad/min)	3.15
最大设计压力/kPa	500
千斤顶最大推力/kN	40 860

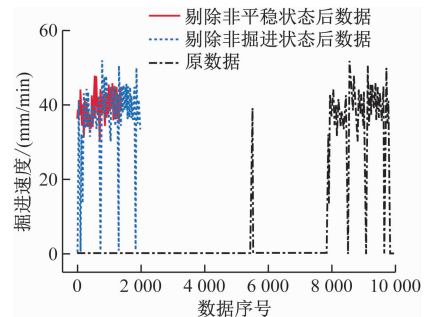


图 4 掘进速度预处理前、后 3 种数据的取值变化情况

Fig. 4 Value changes of three types of data before and after excavation speed preprocessing

由图 4 可知:该环存在大量的非掘进状态数据,剔除非掘进状态数据后,数据量大幅缩减,但依旧存在多个突变点,进一步剔除初始非平稳运行阶段的数据后,掘进速度实时变化曲线较为平稳。由此可知,同一环内的实时掘进参数取值变化不大,这与同一环内地质状况基本相同相一致,因此将同一环内预处理后的实时掘进参数取均值作为环代表值。主要掘进参数统计值如表 2 所示。

## 3 盾构土仓压力预测分析

### 3.1 提取训练数据集

为了更好地对盾构土仓压力预测模型进行训



表 2 主要掘进参数统计值  
Tab. 2 Statistics of main excavation parameters

参数	统计指标			
	最大值	最小值	均值	标准差
刀盘扭矩/ (kNm)	4 140.71	853.52	2 004.82	679.74
总推进力/kN	14 626.83	5 561.06	9 446.62	1 365.25
掘进速度/ (mm/min)	69.74	23.51	48.33	7.51
刀盘转速/ (rad/min)	1.53	0.93	1.08	0.13
螺旋输送机 转速/(rad/min)	9.90	1.47	6.94	1.15
螺旋输送机 扭矩/(kNm)	41.42	6.69	22.14	4.66
土仓压力/kPa	149.38	63.95	123.07	16.91

练与评估,前 700 步的数据用于构建训练模型,后 100 步的数据用于测试。考虑到参数量纲及单位不同,将前 700 步数据的各参数量纲一化到 $[0,1]$ 区间内,则有:

$$z^* = \frac{z - z_{\min}}{z_{\max} - z_{\min}} \quad (7)$$

式中:

$z, z^*$ ——表 2 中任意某种掘进参数量纲一化前、后的取值;

$z_{\min}, z_{\max}$ ——上述掘进参数的最小值、最大值。

基于上述量纲一化后的数据提取训练样本集,输入端口 1(时序输入数据)的数据为回溯过去 10 步的 7 个盾构机参数;输入端口 2 的数据为当前时刻的 6 个掘进参数,输出参数为当前时刻的土仓压力。提取输入端口 1 的数据、输入端口 2 的数据、输出参数的盾构土仓压力为一个训练样本,沿着时序维度依次向下滚动 1 步提取训练样本,直至覆盖全部数据。训练样本滚动提取过程示意图如图 5 所示。

将上述提取的数据集进一步划分为训练集和验证集,其中,前 80% 数据集作为训练集进行模型训练,后 20% 数据集作为验证集用于模型评估。

### 3.2 盾构土仓压力预测模型评估

盾构土仓压力的预测属于回归问题,因此将均方误差作为损失函数,依据训练集基于 Adam 算法训练 LSTM-DNN 融合模型。Adam 算法是一种自适应学习率算法,收敛速度较快,其初始学习率设定为 0.001,训练批次大小设定为 32 个,最大迭代

次数设置为 200 次,采用 Early Stopping 技术提前终止模型的训练,即当模型损失值不再明显降低时,提前终止模型训练。这种策略可以降低模型发生过拟合的风险,提早停止迭代次数设置为 20 次。融合模型中,各 Dropout 层的神经元失活比例设置为 0.3。LSTM-DNN 融合模型在训练集、验证集上的损失值变化趋势如图 6 所示。

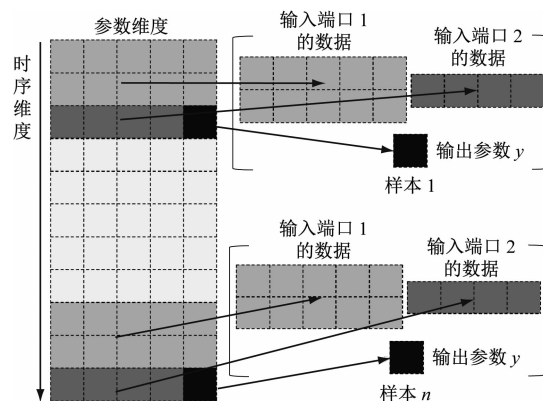


图 5 训练样本滚动提取过程示意图

Fig. 5 Rolling extraction process diagram of training samples




图 6 LSTM-DNN 融合模型在训练集、验证集上的损失值变化趋势

Fig. 6 Loss value change trends of LSTM-DNN fusion model on training set and validation set

经过约 40 次迭代训练后,模型损失值已经足够小,训练集、验证集损失值分别为 0.011、0.006,两者损失值均足够小且较为接近,因此所建立的盾构土仓压力预测模型预测精度良好。LSTM-DNN 融合模型在训练集、验证集上的土仓压力预测结果如图 7 所示。

LSTM-DNN 融合模型在训练集、验证集上的土仓压力预测值均较好地反映了实际值的变化趋势,且预测值与实际值较为接近。由此可知,所提预测模型的精度和鲁棒性良好。从整体来看,实际的土压平衡盾构土仓压力存在一定程度的波动性,这与数据存在一定程度的噪声有关,而模型预测值则较

为稳定。




图7 LSTM-DNN融合模型在训练集、验证集上的土仓压力预测结果

Fig. 7 Earth chamber pressure prediction results of LSTM-DNN fusion model on training set and validation set

进一步对模型的预测误差进行量化分析,由于LSTM-DNN融合模型是基于训练集建立的,因此验证集上的误差更能体现模型的泛化误差。LSTM-DNN融合模型在验证集上的土仓压力误差曲线如图8所示。由图8可知:预测的土仓压力最大偏差值为20 kPa,偏差均值为5 kPa;相对误差基本分布在5%以内,最大相对误差为18%,平均相对误差为4%。由此可知,所建立的盾构土仓压力预测模型精度较高,可满足工程需求。




图8 LSTM-DNN融合模型在验证集上的土仓压力误差曲线

Fig. 8 Earth pressure error curves of LSTM-DNN fusion model on validation set

### 3.3 模型对比分析

将训练好的 LSTM-DNN 融合模型(模型训练

是基于前 700 步的数据)应用于 700 步—800 步的盾构隧道施工数据。基于深层次的 LSTM 模型(图3中左分支模型),以及 DNN 模型(图3中右分支模型)建立盾构土仓压力预测模型,以对比分析本文所提 LSTM-DNN 融合模型的预测效果,模型训练时均基于相同的数据集。

3 种模型在 700 步—800 步的土仓压力预测结果如图9所示。由图9可知:3 种模型的预测值与实际值的偏差均在可接受范围内;LSTM 模型较好地预测了土仓压力的变化趋势,然而其波动性较大,预测值与实际值之间仍存在一定程度的偏差;除了个别步外,DNN 模型整体上的预测结果较为稳定,720 步—760 步的土仓压力预测值与实际值较为接近,然而在土仓压力变化明显的环(780 步附近)没有反映出其变化趋势;LSTM-DNN 融合模型不仅很好地反映了土仓压力的变化趋势,且其预测精度更高。




图9 3种模型在700步—800步的土仓压力预测结果

Fig. 9 Earth pressure prediction results of three models at steps 700-800

采用回归问题的评价指标对模型误差进行对比分析,评价指标包括 MSE(均方误差)、RMSE(均方根误差)、MAE(平均绝对误差)、MAPE(平均绝对百分误差)、MDE(中位数绝对误差)。3 种模型的评价指标计算结果如表3所示。

表3 3种模型的评价指标计算结果

Tab. 3 Evaluation index calculation results of 3 models

模型名称	MSE	RMSE	MAE	MAPE/%	MDE
DNN	153.30	12.38	9.65	7.73	7.91
LSTM	142.46	11.94	9.65	7.65	8.92
LSTM-DNN	86.51	9.30	7.65	6.09	6.27

由表3可知:3 种模型均可实现较高精度的预测;3 种模型的 MAE、MDE 指标均小于 10,表明 3 种模型的盾构土仓压力预测偏差基本在 10 kPa 以内;3 种模型的 MAPE 指标均小于 10%,表明 3 种

模型的相对误差均满足工程需求。对比模型的5个评价指标可知,本文所提 LSTM-DNN 融合模型具有更高的预测精度,可为盾构土仓压力的精准预测提供一种新的方法。

## 4 结论

1) 提出了 LSTM-DNN 融合模型,实现了土压平衡盾构土仓压力的预测;所提模型可同时提取时序演变和掘进状态特征,验证集上预测的土仓压力最大偏差值为 20 kPa,偏差均值为 5 kPa,最大相对误差为 18%,平均相对误差为 4%,所提 LSTM-DNN 融合模型的预测精度良好。

2) 将所提 LSTM-DNN 融合模型应用于后续连续的 100 环中,模型预测值很好地反映了土仓压力的变化趋势,且其土仓压力的平均偏差为 7.65 kPa,相对误差为 6.09%,可满足工程需求。

3) 将所提 LSTM-DNN 融合模型与深层次的 LSTM 模型、DNN 模型进行对比分析,所提模型 MSE、RMSE、MAE、MAPE、MDE 指标误差均为最小。

## 参考文献

- [1] YU H, MOONEY M, BEZUIJEN A. A simplified excavation chamber pressure model for EPBM tunneling[J]. Tunnelling and Underground Space Technology, 2020, 103: 103457.
- [2] 刘宣宇, 张凯举, 邵诚. 基于数据驱动的盾构机密封舱土压预测[J]. 煤炭学报, 2019, 44(9): 2898.  
LIU Xuanyu, ZHANG Kaiju, SHAO Cheng. Earth pressure prediction in soil chamber of shield machine based on data-driven[J]. Journal of China Coal Society, 2019, 44(9): 2898.
- [3] LI Z, SHAO C, ZHOU X, et al. Earth pressure prediction in the chamber for earth pressure balanced shield machines[J]. International Journal of Computer Applications in Technology, 2018, 57(4): 354.

- [4] 李锟, 田管凤, 马宏伟, 等. 土压平衡盾构掘进参数相关性分析及预测模型[J]. 科学技术与工程, 2021, 21(9): 3814.  
LI Kun, TIAN Guanfeng, MA Hongwei, et al. Correlation analysis and prediction model of boring parameters of earth pressure balance shield[J]. Science Technology and Engineering, 2021, 21(9): 3814.
- [5] 林春金, 杨晓达, 龚英杰, 等. 基于 PSO-BP 的土压盾构土仓压力预测模型及掘进参数敏感性分析[J]. 应用基础与工程科学学报, 2021, 29(5): 1220.  
LIN Chunjin, YANG Xiaoda, GONG Yingjie, et al. Prediction model of in-chamber earth pressure for EPB shield based on PSO-BP and parameter sensitivity analysis of tunneling parameters[J]. Journal of Basic Science and Engineering, 2021, 29(5): 1220.
- [6] 李超, 李涛, 李正, 等. 基于 BP 神经网络的复合地层盾构掘进参数预测与分析[J]. 土木工程学报, 2017, 50(增刊1): 145.  
LI Chao, LI Tao, LI Zheng, et al. Prediction and analysis of shield boring parameters in a mixed ground based on BP neural network[J]. China Civil Engineering Journal, 2017, 50(S1): 145.
- [7] 成晓元, 凌静秀, 黄继辉, 等. 土仓压力与掘进参数相关性分析及预测模型[J]. 福建工程学院学报, 2022, 20(1): 13.  
CHENG Xiaoyuan, LING Jingxiu, HUANG Jihui, et al. Correlation analysis and prediction model of chamber earth pressure and excavation parameters[J]. Journal of Fujian University of Technology, 2022, 20(1): 13.
- [8] WEN Z, WANG Z, RONG X, et al. Prediction of the amount of soil discharged by an earth pressure balanced shield machine based on feature engineering[J]. KSCE Journal of Civil Engineering, 2021, 25(12): 4868.

· 收稿日期:2022-10-11 修回日期:2023-01-17 出版日期:2024-12-10  
Received:2022-10-11 Revised:2023-01-17 Published:2024-12-10  
· 第一作者:王伯芝,正高级工程师,740825286@qq.com  
通信作者:丁爽,工程师,dingshuang525@hotmail.com  
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议  
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license

## (上接第 38 页)

- SONG Gaorui, WANG Weiming, WANG Guofu, et al. Optimization of shield tunneling and shallow buried tunnel with small clear distance in parallel construction[J]. Science Technology and Engineering, 2021, 21(15): 6472.
- [8] 赵菁菁, 宿文姬. 深圳地铁近接隧道暗挖施工地表沉降控制[J]. 隧道建设, 2014, 34(11): 1055.  
ZHAO Jingjing, SU Wenji. Study on control of ground surface settlement: case study on adjacent tunnel tubes of Shenzhen metro[J]. Tunnel Construction, 2014, 34(11): 1055.
  - [9] NISHIOKA T, TAKAHASHI K, YASUDA T, et al. Observational

method for tunnel construction in difficult conditions considering environmental impact to groundwater[J]. Journal of the Society of Materials Science, 2003, 52(5): 516.

· 收稿日期:2022-10-28 修回日期:2022-12-13 出版日期:2024-12-10  
Received:2022-10-28 Revised:2022-12-13 Published:2024-12-10  
· 通信作者:马晓波,高级工程师,36550748@qq.com  
· ©《城市轨道交通研究》杂志社,开放获取 CC BY-NC-ND 协议  
© Urban Mass Transit Magazine Press. This is an open access article under the CC BY-NC-ND license