

基于 CNN-BiLSTM 的施工初期盾构机掘进速度预测

张纪奥¹, 马怀祥¹, 王承震², 李东升², 乔卉卉¹

(1. 石家庄铁道大学 机械工程学院, 河北 石家庄 050043;

2. 中铁十四局集团有限公司, 山东 济南 250014)

摘要:对盾构机掘进速度的预测可有效指导设备施工和工程的顺利进行。在隧道施工初期数据量较少时,针对掘进速度难以预测的问题,采用迁移学习策略建立盾构机掘进速度预测模型。提出了以 TPI、FPI、SE、C 4 种混合指标对盾构施工进行聚类分级和判别,降低设备参数和地质信息差异对迁移模型的影响。依托南京长江隧道工程和芜湖过江隧道工程的现场掘进参数进行验证。结果表明,以当前时刻掘进参数作为模型输入,下一时刻掘进速度作为模型输出,建立的基于 CNN-BiLSTM 的预测模型,可有效提取掘进参数特征,实现掘进速度预测,其预测值可以很好地反映实测数据的变化趋势;与其他 3 种智能模型对比,该模型在 MAE 和 RMSE 上表现最优,验证了模型的优越性和有效性。基于 CNN-BiLSTM 的预测模型,可有效解决施工初期数据量较少情况下掘进速度预测问题。

关键词:盾构;速度预测;迁移学习;CNN-BiLSTM;k-means

中图分类号:U455.43 **文献标志码:**A **文章编号:**2095-0373(2023)04-0095-07

0 引言

盾构机作为隧道与地下工程建设的专用装备,具有安全环保、掘进速度快和劳动强度低等优点,在盾构施工过程中,其掘进速度是装备运行操控与项目施工规划的参考依据^[1],因此,对盾构机掘进速度进行预测研究具有重要工程意义。

近年来,国内外学者对此主要进行了理论模型、经验模型和智能模型方面的研究。在理论模型研究方面,张厚美等^[2]修正了掘进速度与总推力、刀盘扭矩的计算公式;王洪新等^[3]对土仓压力、总推力、螺旋机转速和掘进速度间关系的数学表达式进行了推导。在经验模型研究方面,李杰等^[4]采用多元非线性回归建立了复合地层下掘进速度的预测模型;于云龙等^[5]通过对原始掘进参数进行二次转换,修正了盾构机传统掘进速度模型。在智能模型研究方面,随着大数据和人工智能技术的发展,机器学习被广泛应用于盾构掘进预测中。黄靓钰等^[6]、林春金等^[7]、孙伟良等^[8]采用 BP 神经网络建立了掘进参数、土仓压力和地表沉降的预测模型;GAO et al^[9]使用循环神经网络、长短时记忆网络和门控循环单元建立了盾构掘进参数的预测模型;ELBAZ et al^[10]将卷积神经网络和基于聚类算法的长短时记忆网络相结合,实现了盾构机掘进系统的能耗预测。

目前在盾构机掘进参数预测研究中,所用数据多为掘进循环下的参数均值,在工程施工初期,数据量不足会导致上述模型的预测效果降低,且现有研究大多依托某单一工程,缺乏不同工程下预测模型的适用性研究。鉴于此,依托南京长江隧道工程和芜湖过江隧道工程,采用迁移学习策略,提出一种基于混合指标分级的 CNN-BiLSTM 迁移预测模型。首先,在已完成工程上对盾构机混合指标进行 k-means 聚类分级,构建 CNN-BiLSTM 模型进行预训练;然后,对新工程上的混合指标等级进行判别,并将预训练模型

收稿日期:2023-09-05 责任编辑:车轩玉 DOI:10.13319/j.cnki.sjztdxxb.20230230

基金项目:国家自然科学基金(12202287);中铁十四局集团芜湖长江隧道建设指挥部工程科研项目(ZTSSJ-WHSD-GCKY-2021-002);中铁十四局集团装备有限公司科研项目(CRCC14-ZB-KYHT-2023-002)

作者简介:张纪奥(1999—),男,硕士研究生,研究方向为盾构机智能维保。E-mail:ja_5426@163.com

张纪奥,马怀祥,王承震,等.基于 CNN-BiLSTM 的施工初期盾构机掘进速度预测[J].石家庄铁道大学学报(自然科学版),2023,36(4):95-101.

应用到新工程上进行微调,使预测模型在旧工程下学习到的特征知识能更好地应用到新工程中。

1 工程概况和数据清洗

1.1 工程概况

南京长江隧道位于江苏省南京市,横越长江南北两岸,全长 5 850 m。盾构段施工部分为左右两线,采用 2 台海瑞克泥水式盾构同时施工,刀盘开挖直径为 14.96 m,左右线从浦口区同向始发。隧道地层断面如图 1 所示^[11],盾构隧道分别穿越淤泥质粉质黏土地层、粉细砂地层、砾砂地层、圆砾地层和强风化泥岩地层。

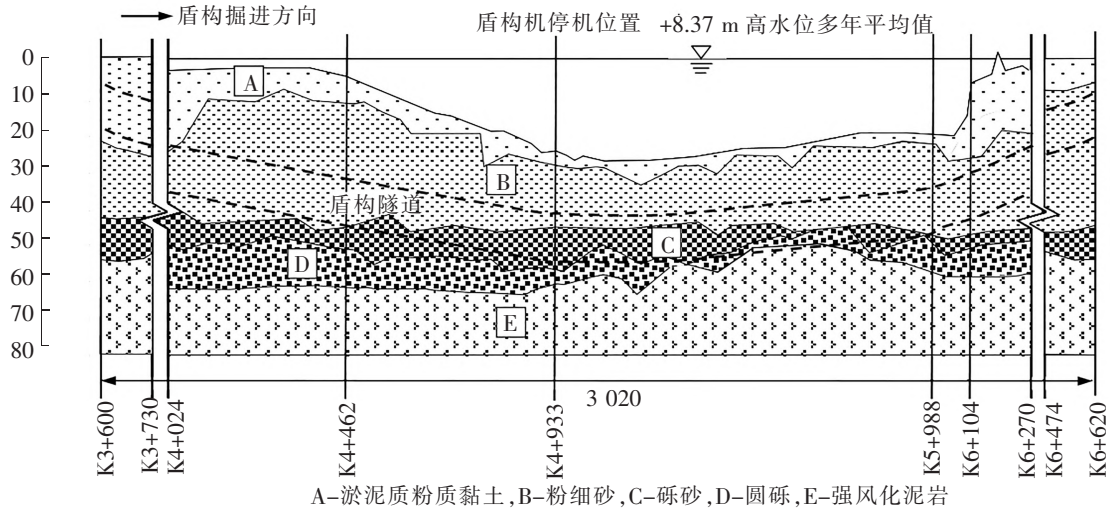


图 1 南京长江隧道地质断面图(单位:m)

芜湖城南过江隧道位于安徽省芜湖市长江大桥和长江二桥之间,长约 4.9 km。采用 2 台气垫式泥水平衡盾构,刀盘开挖直径为 15.07 m,盾构从江北同向先后始发,分别穿越长江后,在江南接收^[12]。地质断面如图 2 所示,盾构隧道分别穿越粉细砂、泥质粉砂岩、凝灰角砾岩和粉质黏土等多种地层。




图 2 芜湖过江隧道地质断面图

1.2 数据清洗

施工过程中,盾构机数据监测系统会对掘进参数进行采集保存,在管片安装、设备维护和其他情况下,监测系统通常会连续工作,导致大量的无效数据被保存下来。以南京长江隧道工程部分掘进速度为例,如图 3 所示,其中每个样本点为盾构机监测系统的采样点,采样间隔为 10 s。

将盾构机的总推力、掘进速度和刀盘扭矩作为划分工作状态和停机状态的指标^[13],式(1)、式(2)为指示函数,将导致的数据认为是停机状态下的数据,进行清洗。

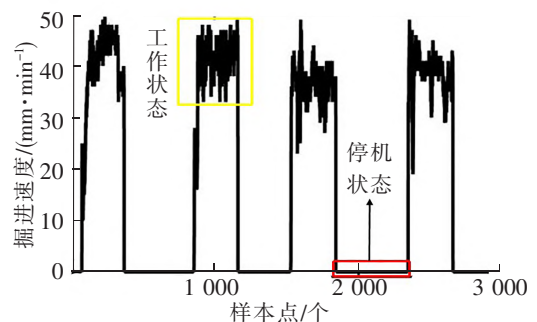


图 3 不同状态下掘进速度

$$F(X) = f(F)f(V)f(T) \tag{1}$$

$$f(x) = \begin{cases} 0, & x=0 \\ 1, & x \neq 0 \end{cases} \tag{2}$$

2 研究方法

2.1 k-means 算法

k-means 算法作为一种非层次聚类算法,通过迭代过程把数据集划分为不同类别,并逐次更新聚类中心直至达到要求的精度^[14]。基本步骤为:首先,随机选取个初始聚类中心;然后,将每个数据点分配到距离最近的聚类中心所在簇中;最后,计算每个簇中数据点均值,并将其作为新的聚类中心,重复以上 2 个步骤,直至收敛或达到最大迭代数。

2.2 CNN 模型

卷积神经网络是一种常用的深度学习模型,由卷积层、池化层和全连接层构成,具有一定的深度结构与自主学习能力,通过模拟人脑系统,对输入信息进行处理,提取主要信息特征^[15]。卷积核作为 CNN 的核心部分,对数据进行卷积操作提取数据的内部特征,表示为

$$C_j = f(w_i \otimes A_i + b_i) \tag{3}$$

式中, f 为激活函数; w_i 为权值矩阵; \otimes 为卷积操作; b_i 为偏置矩阵。

2.3 BiLSTM 模型

长短时记忆网络(LSTM)通过引入输入门、输出门和遗忘门来解决梯度消失问题。LSTM 的核心结构为记忆细胞,包含一个细胞状态 c 、一个隐藏状态 h ,其神经元的网络结构如图 4 所示。BiLSTM 是一种双向循环神经网络模型,如图 5 所示,可同时考虑输入序列的前向和后向信息,能够更好地捕捉上下数据特征,提升模型预测精度和特征数据利用率^[16],其核心结构为 2 个方向相反的 LSTM 模型构成的堆叠结构,正向 LSTM 从前向后遍历输入序列,反向 LSTM 从后往前遍历输入序列,正向和反向过程均有其隐藏状态 h 和细胞状态 c 。




图 4 LSTM 网络结构示意图




图 5 BiLSTM 网络结构示意图

3 工程验证

在新工程掘进初期数据量不足的情况下,提出一种基于混合指标分级的 CNN-BiLSTM 迁移预测模型。首先,以南京长江隧道工程数据为源域数据,对混合指标进行聚类分级,以芜湖过江隧道工程数据为目标域数据,判断该工程上混合指标的对应等级;然后,构建模型在源域的相应等级数据上进行预训练,将模型迁移至目标域进行微调;最后,实现在施工初期少量数据下盾构掘进速度的预测。

3.1 混合指标的聚类分级

为降低不同工程下盾构机型号、地质信息和施工环境等信息对模型的影响,引入场切深指数(FPI)、扭矩切深指数(TPI)、掘进比能(SE)和切割系数(C)^[17] 4 种混合指标进行聚类分级,4 种指标的计算公

式为

$$\text{FPI} = \frac{F}{nP} \quad (4)$$

$$\text{TPI} = \frac{T}{nP} \quad (5)$$

$$\text{SE} = \frac{FP + 2\pi T}{\pi R^2 P} \quad (6)$$

$$C = \frac{nT}{F \sum r} \quad (7)$$

式中, F 为刀盘总推力; n 为刀盘上刀具数量; P 为贯入度; T 为刀盘扭矩; r 为刀具力矩半径; R 为刀盘半径。

由于施工过程中刀具磨损会造成持续变化, 难以确定具体数值, 故忽略刀具力矩半径对切割系数的影响, 将式(7)简化为

$$C = \frac{nT}{F} \quad (8)$$

对南京长江隧道工程中盾构机采集的掘进参数进行混合指标计算, 4 种指标变化趋势如图 6 所示。FPI 指数描述了盾构机在单位贯入度下所需推进力, 反映盾构机与土体的相互作用, 既考虑了地质因素影响, 又考虑到机器设备影响, 通过 FPI 指数可以快速估算岩石强度。TPI 指数描述了盾构机在单位贯入度下所需刀盘扭矩, 同 FPI 指数的考虑类似, 能够对盾构机掘进状态进行更加完整的表述。掘进比能 SE 表示盾构机在掘进单位体积土体时所需能量, 主要用于刀具开挖土体和盾壳克服摩擦力向前推进。切割系数 C 反映了刀盘总推力和刀盘扭矩之间的关系, 主要受地质状况和刀具磨损的影响。




图 6 混合指标趋势图

为避免不同指标物理量纲的影响, 聚类之前对指标进行归一化处理, 具体为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

式中, x' 为参数处理后的值; x 为当前参数值; x_{\max} 、 x_{\min} 分别为参数样本的最大值、最小值。




图 9 源域预测效果




图 10 目标域预测效果

由图 10 可以看出,模型迁移后可准确预测目标域掘进速度的变化,反映其变化规律,在评价指标 MAE 和 RMSE 上的表现分别为 1.44 和 1.92。无迁移模型由于数据量较少,产生过拟合现象,无法正确反映掘进速度的变化,由此可知迁移学习预测模型在工程建设初期的必要性。

4 结论

(1)采用 k-means 聚类方法,基于 FPI、TPI、SE、C 4 种混合指标,可对盾构机的掘进进行聚类分级判定。

(2)建立的 CNN-BiLSTM 预测模型,其在源域和目标域上的掘进速度预测值可以很好地拟合实测数据,在源域上的 MAE 和 RMSE 为 1.94 和 2.57,拟合效果优于 CNN、LSTM、BiLSTM 模型,在目标域上的 MAE 和 RMSE 为 1.44 和 1.92。

(3)所提模型采用迁移学习策略后,可有效解决在盾构掘进初期数据量较少的情况下,深度预测模型产生的过拟合问题,在工程施工初期具有一定指导意义。

参 考 文 献

- [1]石茂林,孙伟,宋学官.隧道掘进机大数据研究进展:数据挖掘助推隧道挖掘[J].机械工程学报,2021,57(22):344-358.
- [2]张厚美,区希,易觉.运用盾构掘进参数跟踪判断滚刀损坏的研究[J].现代隧道技术,2014,51(4):121-126.
- [3]王洪新,傅德明.土压平衡盾构掘进的数学物理模型及各参数间关系研究[J].土木工程学报,2006(9):86-90.
- [4]李杰,付柯,郭京波,等.复合地层下盾构掘进速度模型的建立与优化[J].现代隧道技术,2017,54(3):142-147.
- [5]于云龙,管晓明,王旭春,等.砂黏复合地层盾构掘进参数变化规律及掘进速率预测研究[J].隧道建设(中英文),2019,39(7):1125-1131.
- [6]黄靛钰,阳军生,张聪,等.基于 BP 神经网络的水下岩溶地层盾构掘进参数预测与分析[J].土木工程学报,2020,53(增刊 1):75-80.
- [7]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):1220-1233.
- [8]孙伟良,杜守继,田勇坚,等.基于机器深度学习算法的城际铁路大直径盾构施工地表沉降预测[J].石家庄铁道大学学报(自然科学版),2022,35(4):47-52.
- [9]GAO X, SHI M, SONG X, et al. Recurrent neural networks for real-time prediction of TBM operating parameters [J]. Automation in Construction, 2019, 98: 225-235.
- [10]ELBAZ K, TAO Y, ANNAN Z, et al. Deep learning analysis for energy consumption of shield tunneling machine drive system[J]. Tunnelling and Underground Space Technology, 2022, 123: 104405-104416.
- [11]郭信君,闵凡路,钟小春,等.南京长江隧道工程难点分析及关键技术总结[J].岩石力学与工程学报,2012,31(10):2154-2160.
- [12]王志成,王涵.穿越多种典型地层的超大直径泥水盾构选型研究——以芜湖长江隧道为例[J].隧道建设(中英文),2022,42(增刊 1):493-499.
- [13]WANG X, ZHU H, ZHU M, et al. An integrated parameter prediction framework for intelligent TBM excavation in hard rock[J]. Tunnelling and Underground Space Technology, 2021, 118: 104196-104208.

- [14] 巩方超,王硕禾,张琳娜,等. 基于模糊集和 k-means 算法的变压器红外图像分割[J]. 石家庄铁道大学学报(自然科学版),2018,31(2):76-81.
- [15] 王一帆,郝如江,郭梓良,等. 基于融合 CNN 和 SSA-SVM 的滚动轴承故障诊断[J]. 石家庄铁道大学学报(自然科学版),2022,35(2):87-92.
- [16] 朱凌建,荀子涵,王裕鑫,等. 基于 CNN-Bi LSTM 的短期电力负荷预测[J]. 电网技术,2021,45(11):4532-4539.
- [17] 赵维刚,刘明月,杜彦良,等. 全断面隧道掘进机刀具异常磨损的识别分析[J]. 中国机械工程,2007(2):150-153.

Prediction of Shield Advancing Speed Based on CNN-BiLSTM in the Early Stage of Construction

Zhang Ji'ao¹, Ma Huaixiang¹, Wang Chengzhen², Li Dongsheng², Qiao Huihui¹

(1. School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

2. China Railway 14th Bureau Group Corporation Limited, Jinan 250014, China)

Abstract: The prediction of speed of shield tunneling machine can effectively guide the equipment construction and the smooth progress of the project. In order to solve the problem that shield advancing speed is difficult to predict when the data volume is small in the early stage of tunnel construction, a prediction model is established by using transfer learning. Four mixed indexes, TPI, FPI, SE and C, were proposed for clustering classification and discrimination of shield construction, so as to reduce the influence of equipment parameters and geological information differences on the transfer model. Based on verification with the field shield parameters of Nanjing Yangtze River Tunnel project and Wuhu Chengnan River Tunnel, the results show that the prediction model based on CNN-BiLSTM can effectively extract the characteristics of driving parameters and realize the prediction of driving speed by taking the advancing parameters at the current time as model input and the advancing speed at the next time as model output. The predicted value can well reflect the change trend of measured data. Compared with the other three intelligent models, this model has the best performance on MAE and RMSE, which verifies its superiority and effectiveness. The prediction model based on CNN-BiLSTM can effectively solve the prediction problem of shield advancing speed in the early stage of construction with a small amount of data.

Key words: shield; speed prediction; transfer learning; CNN-BiLSTM; k-means