

DOI: 10.11835/j.issn.2096-6717.2022.069



开放科学(资源服务)标识码 OSID:



机器学习方法在盾构隧道工程中的应用 研究现状与展望

陈湘生^{a,b,c}, 曾仕琪^a, 韩文龙^a, 苏栋^{a,b,c}

(深圳大学 a. 土木与交通工程学院; b. 滨海城市韧性基础设施教育部重点实验室; c. 深圳市地铁
地下车站绿色高效智能建造重点实验室, 深圳 518060)

摘要: 随着盾构隧道工程信息化水平的提升, 隧道掘进设备作业过程监测技术日益完善, 记录的工程数据蕴含了掘进设备内部信息及其与外部地层的相互作用关系。机器学习因其数据分析能力强, 无需先验的理论公式和专家知识, 相较于传统的建模统计分析方法具有更大的应用空间。通过机器学习方法对收集的信息与数据进行深度挖掘并分析其内在联系, 有助于提升盾构隧道工程建设的效率和安全保障水平。简述机器学习方法的基本原理, 总结和分析机器学习方法在盾构工程中的应用研究状况, 综述基于机器学习的盾构设备状态分析、盾构设备性能预测、围岩参数反演、地表变形预测和隧道病害诊断等5个方面的进展, 并分析当前研究的不足。最后, 分析盾构隧道工程向智能化方向发展需重点攻克的难题。

关键词: 盾构隧道; 机器学习; 隧道施工; 大数据; 人工智能

中图分类号: U455.43 **文献标志码:** A **文章编号:** 2096-6717(2024)01-0001-13

Review and prospect of machine learning method in shield tunnel construction

CHEN Xiangsheng^{a,b,c}, ZENG Shiqi^a, HAN Wenlong^a, SU Dong^{a,b,c}

(a. College of Civil and Transportation Engineering; b. Key Laboratory for Resilient Infrastructures of Coastal Cities (MOE);
c. Shenzhen Key Laboratory of Green, Efficient and Intelligent Construction of Underground Metro Station, Shenzhen
University, Shenzhen 518060, Guangdong, P. R. China)

Abstract: With the development of engineering information level and the monitoring technology in the field of shield tunnel, the recorded engineering data contains the internal information of tunneling equipment and its interaction with the external stratum. Machine learning has more application space than traditional modeling statistical analysis methods because of its strong data analysis ability and no requirement on prior theoretical formula and expert knowledge. Improving the efficiency and safety level of shield tunnel construction is helpful

收稿日期: 2021-12-31

基金项目: 深圳市自然科学基金(JCYJ20210324094607020); 国家自然科学基金(51938008); 广东省重点领域研发计划(2019B111105001)

作者简介: 陈湘生(1956-), 男, 教授, 博士生导师, 中国工程院院士, 主要从事隧道及地下工程研究, E-mail: xschen@szu.edu.cn。
苏栋(通信作者), 男, 教授, 博士生导师, E-mail: sudong@szu.edu.cn。

Received: 2021-12-31

Foundation items: Natural Science Foundation of Shenzhen (No. JCYJ20210324094607020); National Natural Science Foundation of China (No. 51938008); Key Research and Development Project of Guangdong Province (No. 2019B111105001)

Author brief: CHEN Xiangsheng (1956-), professor, doctoral supervisor, member of the Chinese Academy of Engineering, main research interests: tunneling and underground engineering, E-mail: xschen@szu.edu.cn.
SU Dong (corresponding author), professor, doctoral supervisor, E-mail: sudong@szu.edu.cn.

to deeply mine the collected information and data and analyze their internal relationship through machine learning method. This paper briefly describes the basic principle of machine learning methods, summarizes and analyzes its application in shield tunnel engineering. In particular, the progress on the equipment status analysis, shield performance prediction, geological parameters analysis, prediction of ground surface deformation and examination of tunnel hazard based on the machine learning method are summarized. Finally, the key problems to be solved so as to realize the intelligent shield tunnel engineering are analyzed and forecasted.

Keywords: shield tunnel; machine learning; tunnel construction; big data; artificial intelligence

随着经济水平的不断发展,交通运输需求日益增长,而隧道能有效利用地下空间、节约地面土地资源,在交通运输基础设施(包括铁路、公路和城市轨道交通)建设中的比重越来越大。盾构工法因具有对地面影响小、掘进速度快、作业面安全等优势,在隧道建设中被广泛采用。随着人工智能技术的涌现与发展,盾构隧道工程建设也从过去追求高速、机械化向高质量、智能化方向发展。

在“大数据”背景下,盾构隧道建设呈现出高容量数据存储能力、高效实时数据处理能力和高强多源异构适应性的“三高”需求,机器学习(Machine Learning, ML)方法开始成为分析隧道工程建设“大数据”的新工具。机器学习的吸引力源自它独特的信息处理能力,如具有非线性、高并行性及高容错性的学习和泛化能力^[1]。机器学习通过足量的样本输入对数据特征进行学习,再对数据进行回归拟合分析,进而对具有相似模式的新输入进行有效分析和预测^[2]。自 20 世纪 80 年代初以来,就有学者尝试使用机器学习相关方法来解决实际工程问题^[3-4],随着相关研究成果的积累和技术的发展,机器学习算法已能在一定程度上提高盾构隧道工程的智能分析与决策水平,增强对掘进过程中设备状态以及施工风险的预测与控制,促进地下空间工程向智能、安全、绿色方向发展^[5]。

回顾并总结机器学习方法在盾构隧道工程中的设备状态分析、盾构性能预测、地质参数研究、地表变形预测和隧道病害预测等 5 个方面的应用研究现状,分析相关研究的进展和不足,并对机器学习方法在盾构隧道工程中的应用研究前景进行分析与展望,旨在推动机器学习方法在盾构隧道工程中的应用研究。

1 机器学习方法基本原理

基于人工智能的数据分析算法发展历程如图 1 所示。作为人工智能的核心,机器学习是一种通过先构建算法模型、再根据输入数据自动解析数据内在联系的技术,其可洞察输入数据中的关联关系,

帮助使用者更好地做出预测并进行决策。随着研究的深入,机器学习的研究者发现可以让人工神经网络(Artificial Neural Network, ANN)自行学习如何抓取数据的特征,这种方式尤其适用于文字、图像和声音等数据,于是演变出了一种新的机器学习方法——深度学习(Deep Learning, DL)。深度学习以神经网络算法为基础,根据学习过程中的样本数据自适应地构建(训练)出基本规则,极大地拓展了机器学习算法的智能性。如今,机器学习及相关算法凭借其智能特性被广泛应用于数据挖掘、计算机视觉与图像处理、预见性维护等领域。

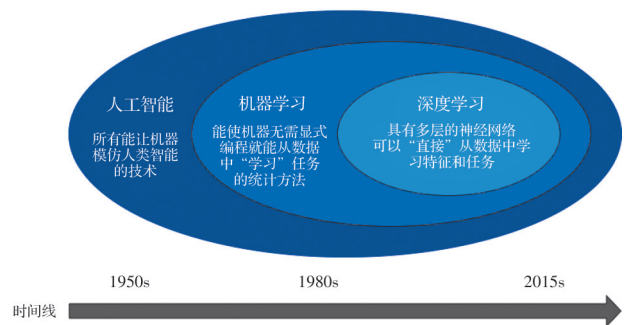


图 1 基于人工智能的数据分析算法发展历程^[6]

Fig. 1 Development history of data analysis algorithms based on artificial intelligence^[6]

机器学习的核心原理是通过输入信息训练计算机模仿人与动物“从经验中学习成长”的天性,其基于直接从数据中“学习”信息的计算方法,而不依赖于预设的方程模型。当训练样本数量增加时,训练出的模型性能相应提升,从而能更好地解决实际问题。机器学习算法可分为 4 种基本类型:监督学习(Supervised Learning, SL)、非监督学习(Unsupervised Learning, UL)、半监督学习(Semi-Supervised Learning, SSL)和强化学习(Reinforcement Learning, RL)^[7]。

1) 监督学习:通过人工预设的训练特征和输出结果来训练模型,使模型具有预测未来输出的能力^[7]。常见的算法有:决策树、人工神经网络、支持向量机、朴素贝叶斯、随机森林等。监督学习主要用于分类和回归问题^[8]。

2) 非监督学习:从输入信息中解析出隐藏在数

据中的内在结构^[9]。常见的算法有:聚类算法、降维算法等,主要用于解决聚类和降维问题。

3)半监督学习:将监督学习与非监督学习相结合的一种学习方法。一般半监督学习的目标是找到一个函数迎合(回归任务),然后用分类任务的信息去优化回归函数。

4)强化学习:训练模型通过与输入信息的反复交互来学习处理任务。这种学习方法使模型面对动态环境能够做出一系列决策,从而使任务奖励期望最大化。

机器学习模型的建立通常包含以下几个步骤:收集数据、预处理数据和提取特征、训练模型、调整模型^[10]。

1)收集数据。收集数据的常见方法是运用信号处理或聚类技术来汇聚数据,如通过模拟仿真或传感器测量获得目标设备或系统的相关数据。

2)预处理数据和提取特征。在提取特征之前,大多数数据集都需要进行预处理,包括删除异常值和异常趋势、处理丢失的数据以及对数据进行归一化。特征提取是机器学习最重要的步骤之一,它将原始数据转变成适合机器学习算法的信息。特征提取消除了各类测量数据中的冗余现象,有助于学习阶段的泛化,而泛化是避免对特定样本过拟合的关键。

3)训练模型。主要步骤包括选择训练和验证的数据、选择训练的算法、反复训练和评估分类模型。在盾构隧道工程中常用的模型有盾构设备状态预测模型、地表沉降预测模型及隧道病害预测模型等。

4)调整模型。通过技术手段提高模型性能,常用方法包括调节模型参数、添加或修改训练数据、变换或提取新特征。

盾构隧道工程中常使用的机器学习基本算法有人工神经网络(Artificial Neural Network, ANN)、支持向量机(Support Vector Machine, SVM)、回归树(Regression Tree, RT)、随机森林(Random Forests, RF)等,常使用的深度学习算法有卷积神经网络(Convolutional Neural Networks, CNN)、循环神经网络(Recurrent Neural Networks, RNN)、生成对抗网络(Generative Adversarial Network, GAN)等。同时,以上算法与其他人工智能方法相结合并改进得到的复合人工智能方法可使机器学习模型有更高的准确率。

2 机器学习方法在盾构隧道工程中的应用研究现状

在盾构掘进过程中,可以采集大量的数据资料,如围岩参数、盾构状态及施工数据等,部分数据能反映盾构掘进设备与周围环境的相互作用规律。通过这些数据训练得到的机器学习模型不仅有助于解决盾构工程中信息处理不足、集成化不足、分析水平差等问题,还能对工程相关信息进行汇总并解析其中的关联性,从而对盾构隧道的设计、施工与运维发挥重要的作用。

基于机器学习的盾构工程管理应用是通过对盾构隧道建设中的相关工程数据进行整理存储和分类关联,基于不同机器学习方式进行分析,将所得分析模型形成相关数据库,再使用编程软件构建机器学习应用管理信息平台(如图2)。目前,机器学习方法在盾构隧道工程中的应用主要包括盾构设备状态分析与掘进性能预测、地质参数反演与地表变形预测、隧道病害监测与预测等^[11]。

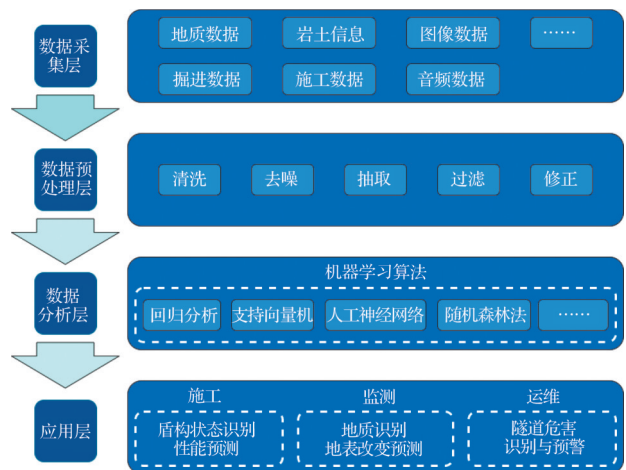


图2 机器学习应用管理示意图

Fig. 2 Schematic diagram of machine learning application management

2.1 基于机器学习的盾构设备状态分析与掘进性能预测

盾构机的设备状态和掘进性能对隧道建设的施工效率、质量和安全有着决定性影响,而机器学习方法在盾构掘进机运行情况识别与相关性能预测两个方面具有较好的适应能力和较大的应用空间。

2.1.1 基于机器学习的盾构设备状态分析

盾构机组成复杂,在施工过程中容易出现各种故障;且因其在地下空间挖掘前进,出现故障时排查异常困难。刀盘作为盾构机的主要组成部分,是盾构设备故障的主要来源。针对刀盘故障问题,研

究人员重点研究了基于机器学习算法的刀盘故障诊断方法。Jin 等^[12]建立一个排除无效和异常数据的函数来识别盾构机运行状态,开发了基于多算法优化的隧道掘进机刀盘扭矩实时预测方法。Guo 等^[13]提出了一种将多个稀疏自编码器(Sparse Autoencoder, SA)与长短期记忆神经网络(Long-Short Term Memory, LSTM)相结合的基于时间序列预测刀盘故障的方法。Mahmoodzadeh 等^[14]使用高斯过程回归(Gaussian Process Regression, GPR)、支持向量机、决策树和 K 近邻(K-Nearest Neighbor, KNN)4 种机器学习方法,基于实测数据来预测 TBM 刀具的寿命。Han 等^[15]提出了一种基于 BP 神经网络(Back Propagation Neural Network, BPNN)的复杂机械设备故障预测模型。Elbaz 等^[16]将基于神经网络的数据预处理方法与遗传算法(Genetic Algorithm, GA)相结合,来预测刀具的寿命。Zou 等^[17]把盾构开挖参数输入能自动检索特征的算法中,然后将自动检索出的特征输出作为反向传播网络的输入完成预测,从而对盾构机将出现的故障进行诊断。

由于隧道盾构机是实时运作,如果对监测数据分析只体现静态关联性,难以对实际工程进行管控指导。因此,需要对数据动态特征进行汇总解析,研究基于时序特征的状态分析方法。Rumelhart 等^[18]在 20 世纪 80 年代以人工神经网络结构为基础提出了循环神经网络(Recurrent Neural Network, RNN),循环神经网络中的复式结构具有类似计算机内存的短时存储功能,可利用这一特性来处理与时间变化相关的问题^[19],该方法近年也被应用于隧道掘进机故障诊断研究中。Gao 等^[20]基于盾构施工过程中采集得到的实际运行数据,采用循环神经网络、长短期记忆神经网络和门控循环单元网络(Gated Recurrent Unit Networks, GRU)3 种模型实时预测盾构运行参数和性能,结果表明,循环神经网络模型的效果最好。Sun 等^[21]应用长短时网络,将盾构机传感器的时间序列数据作为初始数据来预测和诊断泥饼形成、刀具磨损、泥浆管堵塞和地面沉降等。Huang 等^[22]基于吉林松花江引水隧道数据,选择与刀盘扭矩最密切相关的 10 个特征量作为输入变量,提出了一种基于长短期记忆网络的隧道掘进刀盘扭矩实时预测方法。Qin 等^[23]提出了一种结合卷积神经网络和长短期记忆神经网络来提取隐式特征和序列特征的方法,可根据设备运行状态参数来预测盾构设备的刀盘扭矩。

盾构设备监测信息复杂、特征繁多,基于未调整的原始数据无法训练出高精度的预测模型,因

此,机器学习模型预测的准确率在很大程度上取决于数据预处理的效果。循环神经网络对时序特征有着极强的学习能力,被广泛应用于盾构设备状态的分析中,但其存在训练优化慢、计算能力需求大等不足,在盾构设备状态分析与预测中仍有很大的拓展空间。

2.1.2 基于机器学习的盾构掘进性能预测

在盾构施工过程管理中,盾构机的推进速率、刀盘荷载及土仓压力等性能指标对工期管理和成本把控具有重要意义。传统研究主要通过理论模型、室内试验和模拟仿真等预测盾构机的性能,但通常仅能分析某一方面的性能。基于现场实测数据,运用回归分析、模糊数学或者神经网络等机器学习算法,可综合分析盾构施工过程中的设备状况、性能指标与围岩参数的内在联系等,从而达到较高的预测精度。

针对盾构的掘进效率问题,研究人员基于围岩信息等数据,利用机器学习方法训练掘进效率分析模型。Salimi 等^[24]对伊朗两个硬岩隧道项目盾构工程现场监测数据进行分析,结果表明,支持向量机算法在盾构性能预测中具有较好的效果。Fattahi 等^[25]比较了支持向量回归和差分进化算法(Differential Evolution Algorithm, DE)、人工蜂群算法(Artificial Bee Colony Algorithm, ABC)和重力搜索算法(Gravitational Search Algorithm, GSA)等算法对盾构性能预测精度的影响,发现不同算法的预测结果差异较小。Stypulkowski 等^[26]建立并评估了基于岩土参数与设备操作参数的盾构推进预测神经网络回归模型,发现相关数据有巨大预测潜力。Afradi 等^[27]使用人工神经网络和支持向量机方法预测了伊朗 Beheshtabad 输水隧道施工中的盾构掘进贯入度,研究结果表明,支持向量机的预测结果较人工神经网络的结果更精确。Fattahi 等^[28]提出使用模拟退火算法(Simulated Annealing, SA)、萤火虫算法(Firefly Algorithm, FA)、入侵杂草优化算法(Invasive Weed Optimization, IWO)和洗牌蛙跳算法(Shuffled Frog Leaping Algorithm, SFLA)等优化算法改进的人工神经网络模型,提高了间接预测盾构推进效率算法的计算效率。Gao 等^[29]基于杭州第二水源工程输水隧道监测数据,分别采用了长短期记忆神经网络、循环神经网络和传统的时间序列模型(Time series analysis, TSA)来预测盾构掘进贯入度,结果表明长短期记忆神经网络的预测性能更好。

更多基于机器学习算法的盾构掘进性能预测研究和应用案例见表 1。从表 1 可知,大多数学者主

要基于地质数据进行掘进效率预测,部分学者也基于盾构机的工作参数,如转速、功率、推力等指标进行研究,但参数相对较少。目前大多数研究选用小

时作为研究时间单位,但其尺度过大,不足以反映盾构设备掘进的时间变化特性,影响了预测的精度。

表 1 基于机器学习的掘进效率预测模型的参数与算法对比

Table 1 Comparison of parameters and methods of the measured data-driven tunneling efficiency prediction model

文献	算法	地质参数	运行参数
Fattahi 等 ^[30]	ANFIS	DPW、ALPHA、UCS、BI	
Armaghani 等 ^[31]	ANN	WZ、RMR、RQD、UCS、BTS	WT、CT
Samaei 等 ^[32]	CART	DPW、ALPHA、UCS、BI、BTS	
Eftekhari 等 ^[33]	ANN	RMR、RQD、UCS、BTS、 Q_0	WT、CF、CT
Oraee 等 ^[34]	ANFIS	RQD、DPW、UCS	
Torabi 等 ^[35]	ANN	UCS、C、PHI、POI	
Shao 等 ^[36]	GP、SVM、ANN	UCS、BTS、PSI、ALPHA	
Martins 等 ^[37]	ANN、SVM	UCS、PSI、DPW、ALPHA	
Pham 等 ^[38]	ANN	RQ、RF、RT	CD、CF、CT、CP、WT

注:ANN为人工神经网络;ANFIS为自适应神经模糊推理系统;CART为分类回归树;GP为高斯过程;SVM为支持向量机;DPW为碎岩体平均间距;ALPHA为结构面方位角;UCS为单轴抗压强度;BI为岩石脆性系数;WZ为风化带指数;BTS为巴西抗拉强度;RMR为岩体等级;RQD为岩石质量指标; Q_0 为石英百分比;C为土层黏聚力;PHI为摩擦角;POI为泊松比;PSI为峰斜率指数;RQ为岩石质量指数;RF为岩石破裂指数;RT为岩石纹理指数;WT为刀盘转速;CT为刀盘转矩;CF为刀盘推力;CD为刀盘直径;CP为刀盘功率。

现场采集数据的速度往往大于现有机器学习方法的分析速度,为解决这一问题,近年来计算能力更加高效的算法,如深度神经网络(Deep Neural Network, DNN)^[23,39]及动态回归树^[40]等,也逐渐用于建立基于现场数据的机器学习预测模型。Yagiz 等^[41]应用人工神经网络和非线性多元回归模型(Multiple Nonlinear Regression Analysis, MNRA)来预测隧道掘进机的性能。Xu 等^[42]基于马来西亚某隧道工程的现场监测和室内试验数据,使用监督机器学习算法来预测隧道掘进效率。Armaghani 等^[43]基于马来西亚彭亨—雪兰莪排水隧道的实测数据对盾构推进速度进行了预测分析,结果表明,粒子群算法(Particle Swarm Optimization, PSO)与人工神经网络相结合的模型预测性能更强。Feng 等^[44]基于中国东北地区引松供水隧道工程中采集到的数据,使用深度信念神经网络(Deep Belief Neural Network, DBNN)对盾构掘进效率进行预测分析,结果表明深度信念神经网络预测能力强、操作简单。Mahdevari 等^[45]基于支持向量机,开发了一种新型回归模型来预测硬岩条件下盾构机的掘进效率。Sun 等^[46]在围岩勘察信息的基础上,研究隧道掘进机的运行行为(尤其是动力行为),并采用随机森林算法对其推进速度进行预测。Li 等^[47]基于盾构掘进过程中的监测数据,利用长短期记忆网络对盾构机实时总推力和刀盘工作变化规律状态进行提前预测,研究表明,这一方法比传统理论模型有更好的预测能力。

研究人员也基于机器学习算法,对土仓/泥水

压力、姿态控制等性能指标进行预测研究。对于泥水平衡式盾构机^[48],泥水压力是控制盾构隧道施工沉降与变形的关键。Wang 等^[49]先通过典型关联分析法去除隧道工作面压力监测信息中的噪声,然后通过长短期记忆网络对泥水平衡盾构机在含有泥岩的混合地层条件下的浆液压力进行预测,保证了预测的精准度。Li 等^[50]采用循环神经网络挖掘泥浆压力和其他参数之间的复杂关系,预测施工过程中所需的泥浆压力值,显著提高了隧道掘进中泥浆系统的鲁棒性。Zhou 等^[51]提出一种基于进化神经网络的泥浆气室压力预测控制方法,以保证泥水平衡盾构隧道开挖面的稳定性。

在盾构姿态预测与控制方面,Zhou 等^[52]提出了基于小波变换噪声滤波器、卷积神经网络特征提取器和长短期记忆预测器的盾构隧道姿态和位置的预测框架,用于确定盾构机的姿态和位置。Wang 等^[53]建立了基于小波变换和双向长短期记忆法的动态调节模型来预测盾构机前进速度和扭矩,研究结果表明,该模型具有较高的预测准确度。Wang 等^[54]针对盾构掘进过程中轴线姿态偏差难以准确预测和修正的问题,提出了一种基于盾构掘进数据驱动的轴线姿态偏差预测和修正方法。Zhang 等^[55]采用主成分分析法研究掘进输入参数的相互关联,并应用门控循环神经网络算法实时预测盾构的掘进姿态。

以上研究表明,目前机器学习方法对盾构机关键性能(如掘进效率、土仓/泥水压力、姿态调整等)预测的应用取得了一定的进展,多数预测模型输入信息以地层勘察数据为主,以盾构掘进过程中的设

备参数为辅。通常先进行不同输入与预测结果的相关性分析,进而筛选出最具相关性的输入特征,再将该特征导入合适的机器学习回归算法训练预测模型。

实际工程验证表明,基于这一思路建立的预测模型比直接用非线性回归算法训练的预测模型的准确度更高。

2.2 基于机器学习的地质参数反演与地表变形预测

盾构掘进过程中的监测数据包含了地质工况及周边环境的动态变化信息(如图3),研究人员可通过相应机器学习方法构建模型,对盾构隧道工程地质信息进行反演识别,并对盾构掘进引起的地表变形进行预测。




图3 变形因素的相互关系

Fig. 3 Relationship among deformation factors

2.2.1 基于机器学习的地质参数反演

盾构隧道等地下工程存在于地下岩土体中,岩土材料具有非均质、非连续、非线性等特点,传统的勘察方法成本高,获取的岩土参数信息有限,而理论和数值计算方法不能很好地解决盾构掘进扰动影响下的地层岩土参数问题^[56]。机器学习算法可以利用施工过程的监测数据进行反演分析,计算地质体的实时“等效参数”^[57],成为解决相关问题的重要方法。Liang等^[58]提出了一种基于模糊反向传播神经网络的新反向分析方法,并使用该方法由现场测量的位移来反演地下围岩力学参数和初始应力。Suwansawat等^[59]提出了基于人工神经网络确定盾构掘进施工参数、地表变形和围岩参数相关性的方法。郝哲等^[60]提出了一种利用微分法和人工神经网络方法相结合的反演岩体力学参数的方法,该方法先对训练参数进行优化,再使用位移数据训练人工神经网络,从而对围岩力学参数进行反演分析。高攀科等^[61]针对一般BP神经网络中部分数据有缺陷的情况,提出了一种基于改进BP神经网络的软弱岩石位移反分析方法。

在盾构掘进过程中,准确获取掌子面地质信息有助于设置最佳盾构作业参数,使盾构机获得更好的掘进效率。然而,由于盾构机的封闭性设计及较

窄的作业面使操作人员无法直接观察周围环境,利用机器学习方法间接识别地质条件成为研究热点之一。Yu等^[62]为了充分利用所有收集到的现场数据来提高地质构造识别模型的性能,提出了一种新的约束密集卷积自编码器和基于深度神经网络的半监督学习方法。Zhang等^[63]提出一种综合程序来预测隧道掘进机的地质条件(即岩体类型),该程序基于盾构作业的4类数据,即刀盘速度、刀盘扭矩、推力和推进速率,采用层次平衡迭代归约和聚类算法进行分析。Yang等^[64]建立基于盾构机作业数据的地质条件自动预测模型,利用K聚类算法进行聚类分析,再根据地质数据识别地质类型。Erharter等^[65]基于在建设中的布伦纳隧道收集到的数据,对比了多层感知器和长短期记忆神经网络在岩体特性自动分类中的性能表现,结果表明,长短期记忆神经网络识别效果更贴合实际工况。Liu等^[66]提出基于分类回归树和集成学习模型相结合的方法来预测围岩分类,对松花江输水隧道建设的监测数据进行分析,结果表明该混合方法的准确率较高。Kim等^[67]提出一种具有6个隐藏层的深度神经网络方法,基于盾构掘进过程中的监测数据对地质类型进行分析与分类。Shi等^[68]用深度神经网络方法与传统数据挖掘方法分别对地质类型进行预测,结果表明,深度神经网络方法可以更准确地估计开挖前的地质条件。Yu等^[69]为充分利用盾构掘进过程中产生的海量未标注数据和有限标注数据,提出一种基于深度神经网络半监督方法建立的岩体类型预测模型。Zhao等^[70]提出了一种基于实时数据驱动的智能预测隧道地质条件的方法,该方法基于前馈多输出人工神经网络算法,预测结果优于常见的随机森林、支持向量机等方法。

以上研究表明,基于机器学习方法的围岩参数反演和地质识别在盾构隧道工程中有广泛的应用前景。然而,目前反演的信息主要是地层的岩土类型与空间分布,能够实现岩土类型与力学参数同时反演和预测的研究还有待进一步开展。

2.2.2 基于机器学习的地表变形预测

盾构机在施工过程中会与地层发生较强的相互作用(如图4),对盾构掘进过程控制不当会导致地层产生较大变形,对周边环境产生危害。因此,地表变形预测与控制是保证隧道掘进安全的重要措施之一。为减少盾构施工引起的地表变形及对周边环境的负面影响,研究人员基于机器学习方法研究掘进参数与地表变形之间的内在关联,以期达到实时精准预测地表变形的效果。

基于机器学习的地表变形预测研究中,孙钧




图 4 不同施工阶段的地面沉降^[71]

Fig. 4 Ground settlement at different stages of construction^[71]

等^[71]利用人工神经网络技术研究了城市地铁盾构隧道施工扰动引起的地表变形和沉降机理,建立的人工神经网络模型可以准确预测工作面前方 5 m 的地表沉降。Suwansawat 等^[59]提出了一种基于人工神经网络的方法预测地表沉降问题,该方法具有将输入映射到输出模式的能力,并将所有影响参数纳入到地表沉降预测中。Kohestani 等^[72]对比了随机森林方法和人工神经网络方法预测盾构隧道引起的

最大地表沉降,结果表明随机森林预测精度更高。Pourtaghi 等^[73]为了最大限度地降低隧道开挖的风险,提出了一种基于小波网络与人工神经网络相结合的最大地表沉降预测方法。Zhang 等^[55]提出了基于随机森林算法的土压平衡盾构沉降智能控制方式,可以预测隧道施工引起的沉降,且在沉降超过容许值时优化盾构运行参数。Chen 等^[74]比较了回归神经网络和随机森林及其他 4 种常见数据挖掘方法预测隧道引起沉降的效果,结果表明,6 种机器学习算法中回归神经网络和随机森林方法的表现最好。Cao 等^[75]提出了一种在小样本情况下对地面沉降进行预测的深度学习模型,该方法通过长短记忆神经网络对每个分量进行预测并叠加以获得最终的预测结果。Zhang 等^[76]综述了相关机器学习算法及其在地下工程中的应用,对比了包括极限梯度提升、多元自适应回归样条、人工神经网络和支持向量机等算法在预测支撑开挖引起的最大侧向变形的准确性。更多基于机器学习方法进行地层变形预测的研究参见表 2。

表 2 不同特征参数隧道施工变形预测方法

Table 2 Tunnel construction deformation prediction method with different characteristic parameters

文献	算法	主要输入特征参数	数据量
Ocak 等 ^[78]	ANN,SVM,GP	$F_p, P_r, E_x, T_{vp}, D, A, H, D_l, D_r, SPT, U_w, G_c, G_w$	230
Wang 等 ^[79]	ANN	$H, E_i, S_i, G_w, F_p, P_r, P_a, G_p, G_f$	661
Hasanipanah 等 ^[80]	PSO-ANN	H_v, C_o, Y	143
Kohestani 等 ^[72]	RF,ANN	$H, D_s, G_c, G_i, I_w, F_p, P_r, P_a, T_{vp}, G_p$	49
Goh 等 ^[81]	MARS	$H, P_r, E_p, SPT, M_c, E, G_p$	148
Mahmoodzadeh 等 ^[82]	LSTM,DNN,KNN, SVM,GP,DT,LR	T_w, H, C_m, C_o, F_a, E	300
Zhang 等 ^[83]	ANN	$T_h, C_i, P_r, G_p, G_v, F_p, T_d, T_v, K_{TS}, G_w, B_{CT}, S_{CT}, R_{CT}, S_{IT}, R_{IT}, K_H, K_D$	328

注: F_p 为表面压力; P_r 为渗透率; E_x 为挖掘材料的数量; T_{vp} 为尾部空隙灌浆填充百分比; D 为隧道直径; A 为隧道之间的距离; H 为隧道深度; D_l 为左侧隧道与地面监测点之间的距离; D_r 为右侧隧道与地面监测点之间的距离; SPT 为标准渗透测试; U_w 为单位重量; G_c 为地质条件; G_w 为地下水的影响; E_i 为开挖面到沉降标记; S_i 为地层类型; P_a 为俯仰角; G_p 为灌浆压力; G_f 为灌浆; T_h 为推力; C_i 为刀盘扭矩; T_d 为隧道偏差; T_v 为隧道空隙; K_{TS} 为喀斯特洞穴处理方案; B_{CT} 为隧道顶部回填土的厚度; S_{CT} 为隧道顶部砂土厚度; R_{CT} 为隧道顶部风化岩石的厚度; S_{IT} 为隧道底架下砂土厚度; R_{IT} 为隧道底架下的岩石厚度; K_H 为溶洞高度; K_D 为溶洞与隧道内底之间的距离; D_s 为距轴的距离; G_i 为倒置地质; I_w 为转化为地下水位; H_v 为水平与垂直应力比; C_o 为凝聚力; Y 为弹性模量; E_p 为土压力; M_c 为平均水分含量; E 为地层弹性模量; D_r 为决策树; L_R 为线性回归; T_w 为隧道宽度; C_m 为施工方法; F_a 为摩擦

通过对基于机器学习的地质参数反演和地表变形预测研究的综述可知,盾构施工长期在复杂环境下进行,监测系统采集的数据大部分是相似的无特征信息。传感器在施工现场不仅布设困难,而且容易受到现场施工作业影响(如设备损坏、丢失和供电中断等问题),从而导致监控数据无效或缺失^[77]。同时,大量标记无效的样本数据会导致机器学习算法的训练样本数据不足,给地质参数反演和地表变形预测带来困难。因此,采用在实验室中的模拟工况下采集的实验数据来训练机器学习模型,

对实验数据与监测数据之间的数值及特征差异进行分析,再通过迁移学习技术来应用实验数据训练模型,在实测数据样本不足的情况下,这是一种可行的修正预测模型的方法,但目前相关的成功案例还鲜见报道。

2.3 基于机器学习的隧道病害监测与预测

隧道健康状态是隧道建设过程及后期运营阶段的重要监测内容。目前,研究人员已经开展了基于机器学习算法的隧道病害监测研究,并通过分析隧道健康情况,建立了隧道病害预测模型,服务盾

构隧道的管养。Cha等^[84]利用深层结构卷积神经网络自动学习图像特征的能力,结合滑动窗口技术实现对混凝土裂缝的检测识别。在探地雷达的信号处理方面,深度学习也发挥着巨大作用。Besaw等^[85]利用深度信念网络从探地雷达反射信号中提取出复杂数据的有效特征,提供了一种雷达数据异常检测和分类的新方法。Makantasis等^[86]采用卷积神经网络分层构造高层次特征,实现隧道病害类型的自动识别。Chen等^[87]基于东北地区引松供水盾构隧道工程的监测数据,开发与深度置信网络相结合的时间序列预测方法,可预测隧道墙体的倒塌危害。

对于隧道运营期监测数据的处理,采用传统机器学习方法的缺点在于需要手动定义目标的特征,对于复杂场景中的数据来说,目标的特征并不具体,很难定量描述。深度学习的发展改变了此现状,它通过卷积神经网络等算法进行特征提取,有效实现监测和检测数据中异常信息的分类和位置信息的获取。由于隧道衬砌结构病害特征的相似性以及结构的复杂性,在隧道衬砌检测方面,目前用深度学习实现多种病害分类的相关研究较少。

3 机器学习方法在盾构隧道工程中的应用难点与发展方向

学者们在基于机器学习方法(如图5)的盾构设备状态分析与掘进性能预测、地质参数反演与地表变形预测、隧道病害监测与预测等方面(如图6)取得了一定的研究成果,提升了盾构隧道工程的勘察、设计、施工与运营水平,但该方法仍有进一步研究和发展的空间,在实际工程中的普遍推广也存在一些困难。

3.1 应用难点与不足

目前,机器学习方法在盾构隧道工程中应用的




图5 参考文献涉及的算法统计

Fig. 5 Statistics of research methods in the literature involved in this paper




图6 参考文献涉及的研究目的统计

Fig. 6 Statistics of research purpose in the literature involved in this paper

主要难点与不足主要表现在以下几个方面。

1) 机器学习的预测实用性因盾构工程实时采集信息能力不足而受限。实时监测数据能极大增强机器学习算法的即时预测能力,但盾构设备本身构造复杂,施工环境恶劣,隧道掘进过程中难以为大量监测仪器提供合适的安装空间;盾构设备狭长且位于地层中,监测设备采集到的数据难以实时传送到收集终端,这些因素都限制了机器学习预测方法的普及和推广。

2) 盾构隧道工程实测信息的数据模态、样本类别、信息结构等特征差异大,现阶段主要是通过数据类型转化及人工修正等方式来进行数据归一化,但处理过程需要大量的人工标注,主观性大,可能会导致数据内部某些潜在特征被忽视。因此,需要深入挖掘数据背后的产生机制,识别异常样本的特征,探明关键性因素并进行人工标注,但目前面向机器学习的多源异构数据处理方法还有待进一步研究。

3) 相较于传统的数值解析法或经验公式法,基于盾构隧道工程实测数据的机器学习预测模型通常具有更高的拟合精度,但要达到高精度,需要耗费大量运算时间与计算能力进行模型训练。因此,限制机器学习算法在盾构工程中大面积推广应用的一大原因就是现场计算能力。在隧道掘进现场,由于数据采集或监测设备提供的平台计算能力不足,难以满足利用实测数据训练机器学习算法的需求,因此,需探索与云计算或硬件加速相结合的技术。

3.2 未来发展方向

机器学习方法是基于现有数据分析理论上的更高层次的分析方法,其在盾构隧道工程中的应用主要包括装备运行状态识别、关键参数关联分析、刀具故障预测、地层参数识别等,相关研究可提高施工管理水平、减少盾构施工对邻近环境的影响。随着5G传感、物联网、云计算、北斗通信等新技术的快速迭代,盾构机实测数据的存储数量和质量、

实时性都将得到持续发展,这对机器学习方法来说是“如虎添翼”。然而,机器学习算法要真正达到在实际工程中广泛应用的水平,未来还需在以下方面进行探索和发展。

1)海量多源数据的汇聚。不同厂家生产的隧道掘进机监控设备存在差异,采集的信息不同源且不兼容。可通过远程服务器根据对应的端口协议汇总数据,以此集成不同工程、不同设备、不同隧道的监测信息,通过大数据训练来增强机器学习模型的泛化能力,而这需打破现有数据的管理壁垒。

2)基于云计算和 5G 技术的机器学习算法开发。盾构隧道工程相关的机器学习模型训练计算成本高,因此,现有大多数机器学习分析模型是采集数据后在实验室平台进行训练。与云计算相结合的远程训练模式是满足工地实时计算需求的可行途径,即工地监测端负责数据汇总,上传至云端进行机器学习训练、优化、预测,再将结果返回至工地端。在云计算模式下,与 5G 无线通信技术相结合的机器学习算法是盾构工程需要探索的方向。

3)盾构隧道工程智能管控平台构建。随着盾构隧道掘进数据的不断累积,以及智能算法能力的不断提升,可以构建以机器学习方法为核心的盾构隧道工程智能管理模式和平台(如图 7 所示),逐步实现盾构隧道工程在设计、施工及运营环节的信息汇聚、智能决策和智能管控,促进隧道工程由信息化往智能化、自动化方向迈进。




图 7 基于机器学习的智能管理模式

Fig. 7 Intelligent management mode based on machine learning

4 结论

作为人工智能方法的重要组成部分,机器学习是工程信息化重要发展方向。机器学习算法能够深入挖掘盾构隧道监测大数据的隐含特征,为盾构装备状态识别与性能预测、地质识别与地表变形预测,隧道健康监测与预警等方面提供技术支持。笔者总结了当前机器学习技术在盾构隧道工程中应用研究的主要进展与不足,并结合当前实际技术水平展望后续应用研究的主要方向,以期为隧道工程智能化发展添砖加瓦。

参考文献

- [1] JAIN A K, MAO J C, MOHIUDDIN K M. Artificial neural networks: A tutorial [J]. Computer, 1996, 29(3): 31-44.
- [2] JAVAD G, NARGES T. Application of artificial neural networks to the prediction of tunnel boring machine penetration rate [J]. Mining Science and Technology (China), 2010, 20(5): 727-733.
- [3] NEAUPANE K M, ADHIKARI N R. Prediction of tunneling-induced ground movement with the multi-layer perceptron [J]. Tunnelling and Underground Space Technology, 2006, 21(2): 151-159.
- [4] ATTEWELL P, WOODMAN J P. Predicting the dynamics of ground settlement and its derivatives caused by tunnelling in soil [J]. Ground Engineering, 1982, 15(8): 13-22.
- [5] 陈丹, 刘喆, 刘建友, 等. 铁路盾构隧道智能建造技术现状与展望 [J]. 隧道建设(中英文), 2021, 41(6): 923-932.
CHEN D, LIU Z, LIU J Y, et al. State-of-art and prospects for intelligent construction technology for railway shield tunneling [J]. Tunnel Construction, 2021, 41(6): 923-932. (in Chinese)
- [6] ZHANG W G, LI H R, LI Y Q, et al. Application of deep learning algorithms in geotechnical engineering: A short critical review [J]. Artificial Intelligence Review, 2021, 54(8): 5633-5673.
- [7] 翟嘉琪, 杨希祥, 程玉强, 等. 机器学习在故障检测与诊断领域应用综述 [J]. 计算机测量与控制, 2021, 29(3): 1-9.
ZHAI J Q, YANG X X, CHENG Y Q, et al. Overview of application of fault detection and diagnosis based on machine learning [J]. Computer Measurement & Control, 2021, 29(3): 1-9. (in Chinese)
- [8] 李杰其, 胡良兵. 基于机器学习的设备预测性维护方法综述 [J]. 计算机工程与应用, 2020, 56(21): 11-19.
LI J Q, HU L B. Review of machine learning for predictive maintenance [J]. Computer Engineering and Applications, 2020, 56(21): 11-19. (in Chinese)
- [9] 施清清, 周伯儒, 倪申. 基于机器学习的空调系统管路焊堵自动检测研究 [J]. 计量与测试技术, 2019, 46(4): 31-33.
SHI Q Q, ZHOU B R, NI S. Research on automatic detection of pipeline welding blockage in air conditioning system based on machine learning [J]. Metrology & Measurement Technique, 2019, 46(4): 31-33. (in Chinese)
- [10] GOMES SOARES S, ARAÚJO R. An on-line weighted ensemble of regressor models to handle concept drifts [J]. Engineering Applications of Artificial Intelligence, 2015, 37: 392-406.

- [11] 孙振川, 钱彤途, 任颖莹, 等. 隧道掘进机工程大数据管理平台关键技术及应用研究[J]. 隧道建设(中英文), 2020, 40(6): 783-792.
SUN Z C, QIAN T T, REN Y Y, et al. Study on key technologies and application of engineering big data management platform of tunnel boring machine [J]. Tunnel Construction, 2020, 40(6): 783-792. (in Chinese)
- [12] JIN Y R, QIN C J, TAO J F, et al. An accurate and adaptative cutterhead torque prediction method for shield tunneling machines via adaptative residual long-short term memory network [J]. Mechanical Systems and Signal Processing, 2022, 165: 108312.
- [13] GUO J W, LAO Z P, HOU M, et al. Mechanical fault time series prediction by using EFMSAE-LSTM neural network [J]. Measurement, 2021, 173: 108566.
- [14] MAHMOODZADEH A, MOHAMMADI M, HASHIM IBRAHIM H, et al. Machine learning forecasting models of disc cutters life of tunnel boring machine [J]. Automation in Construction, 2021, 128: 103779.
- [15] HAN H, GAO X. Fault prediction of shield machine based on rough set and BP neural network [C]//2017 4th International Conference on Information Science and Control Engineering (ICISCE). July 21-23, 2017, Changsha, China. IEEE, 2017: 994-998.
- [16] ELBAZ K, SHEN S L, ZHOU A N, et al. Prediction of disc cutter life during shield tunneling with AI via the incorporation of a genetic algorithm into a GMDH-type neural network [J]. Engineering, 2021, 7(2): 238-251.
- [17] ZOU L, LIANG L. Fault diagnosis of shield machine based on SOM-BP neural network fusion [C]//2018 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC). August 15-17, 2018, Xi'an, China. IEEE, 2018: 232-237.
- [18] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. Nature, 1986, 323(6088): 533-536.
- [19] ZHANG L, YI Z. Selectable and unselectable sets of neurons in recurrent neural networks with saturated piecewise linear transfer function [J]. IEEE Transactions on Neural Networks, 2011, 22(7): 1021-1031.
- [20] GAO X J, SHI M L, SONG X G, et al. Recurrent neural networks for real-time prediction of TBM operating parameters [J]. Automation in Construction, 2019, 98: 225-235.
- [21] SUN Z H, ZHENG H Y, SHI B H. Faults prediction and diagnoses of shield machine based on LSTM [C]//2019 Chinese Control and Decision Conference (CCDC). June 3-5, 2019, Nanchang, China. IEEE, 2019: 5254-5259.
- [22] HUANG X, ZHANG Q T, LIU Q S, et al. A real-time prediction method for tunnel boring machine cutterhead torque using bidirectional long short-term memory networks optimized by multi-algorithm [J]. Journal of Rock Mechanics and Geotechnical Engineering, 2022, 14(3): 798-812.
- [23] QIN C J, SHI G, TAO J F, et al. Precise cutterhead torque prediction for shield tunneling machines using a novel hybrid deep neural network [J]. Mechanical Systems and Signal Processing, 2021, 151: 107386.
- [24] SALIMI A, ROSTAMI J, MOORMANN C, et al. Application of non-linear regression analysis and artificial intelligence algorithms for performance prediction of hard rock TBMs [J]. Tunnelling and Underground Space Technology, 2016, 58: 236-246.
- [25] FATTAHI H, BABANOURI N. Applying optimized support vector regression models for prediction of tunnel boring machine performance [J]. Geotechnical and Geological Engineering, 2017, 35(5): 2205-2217.
- [26] STYPULKOWSKI J B, BERNARDEAU F G, JAKUBOWSKI J. Descriptive statistical analysis of TBM performance at Abu Hamour Tunnel Phase I [J]. Arabian Journal of Geosciences, 2018, 11(9): 1-11.
- [27] AFRADI A, EBRAHIMABADI A, HALLAJIAN T. Prediction of the penetration rate and number of consumed disc cutters of tunnel boring machines (TBMs) using artificial neural network (ANN) and support vector machine (SVM) —Case study: Beheshtabad water conveyance tunnel in Iran [J]. Asian Journal of Water, Environment and Pollution, 2019, 16(1): 49-57.
- [28] FATTAHI H, BAZDAR H. Applying improved artificial neural network models to evaluate drilling rate index [J]. Tunnelling and Underground Space Technology, 2017, 70: 114-124.
- [29] GAO B Y, WANG R R, LIN C J, et al. TBM penetration rate prediction based on the long short-term memory neural network [J]. Underground Space, 2021, 6(6): 718-731.
- [30] FATTAHI H. Adaptive neuro fuzzy inference system based on fuzzy c-means clustering algorithm, a technique for estimation of TBM penetration rate [J]. Iran University of Science & Technology, 2016, 6: 159-171.
- [31] ARMAGHANI D J, MOHAMAD E T, NARAYANASAMY M S, et al. Development of hybrid intelligent models for predicting TBM penetration rate in hard rock condition [J]. Tunnelling and Underground Space Technology, 2017, 63: 29-43.
- [32] SAMAEI M, RANJBARNIA M, NOURANI V, et al. Performance prediction of tunnel boring machine through developing high accuracy equations: A case study in adverse geological condition [J]. Measurement, 2020, 152: 107244.

- [33] EFTEKHARI M, BAGHBANAN A, BAYATI M. Predicting penetration rate of a tunnel boring machine using artificial neural network [C]//Isrm International Symposium-6th Asian Rock Mechanics Symposium: Onepetro, 2010.
- [34] ORAEE K, KHORAMI M, HOSSEINI N. Prediction of the penetration rate of TBM using adaptive neuro fuzzy inference system (ANFIS) [C]//Proceeding of Sme Annual Meeting and Exhibit, 2012: 297-302.
- [35] TORABI S R, SHIRAZI H, HAJALI H, et al. Study of the influence of geotechnical parameters on the TBM performance in Tehran-Shomal highway project using ANN and SPSS [J]. *Arabian Journal of Geosciences*, 2013, 6(4): 1215-1227.
- [36] SHAO C J, LI X L, SU H Y. Performance prediction of hard rock TBM based on extreme learning machine [M]//Intelligent Robotics and Applications. Berlin, Heidelberg: Springer, 2013: 409-416.
- [37] MARTINS F F, MIRANDA T. Prediction of hard rock TBM penetration rate based on data mining techniques [C]//Proceedings of the 18th International Conference on Soil Mechanics and Geotechnical Engineering, Paris, 2013, 2: 1751-1754.
- [38] PHAM H V, YUJI F, KAMEI K. Hybrid artificial neural networks for TBM performance prediction in complex underground conditions [C]//2011 IEEE/SICE International Symposium on System Integration (SII). December 20-22, 2011, Kyoto, Japan. IEEE, 2011: 1149-1154.
- [39] KOOPIALIPOOR M, TOOTOONCHI H, JAHED ARMAGHANI D, et al. Application of deep neural networks in predicting the penetration rate of tunnel boring machines [J]. *Bulletin of Engineering Geology and the Environment*, 2019, 78(8): 6347-6360.
- [40] SALIMI A, FARADONBEH R S, MONJEZI M, et al. TBM performance estimation using a classification and regression tree (CART) technique [J]. *Bulletin of Engineering Geology and the Environment*, 2018, 77(1): 429-440.
- [41] YAGIZ S, GOKCEOGLU C, SEZER E, et al. Application of two non-linear prediction tools to the estimation of tunnel boring machine performance [J]. *Engineering Applications of Artificial Intelligence*, 2009, 22(4/5): 808-814.
- [42] XU H, ZHOU J, ASTERIS P G, et al. Supervised machine learning techniques to the prediction of tunnel boring machine penetration rate [J]. *Applied Sciences*, 2019, 9(18): 3715.
- [43] ARMAGHANI D J, KOOPIALIPOOR M, MARTO A, et al. Application of several optimization techniques for estimating TBM advance rate in granitic rocks [J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2019, 11(4): 779-789.
- [44] FENG S X, CHEN Z Y, LUO H, et al. Tunnel boring machines (TBM) performance prediction: A case study using big data and deep learning [J]. *Tunnelling and Underground Space Technology*, 2021, 110: 103636.
- [45] MAHDEVARI S, SHAHRIAR K, YAGIZ S, et al. A support vector regression model for predicting tunnel boring machine penetration rates [J]. *International Journal of Rock Mechanics and Mining Sciences*, 2014, 72: 214-229.
- [46] SUN W, SHI M L, ZHANG C, et al. Dynamic load prediction of tunnel boring machine (TBM) based on heterogeneous in-situ data [J]. *Automation in Construction*, 2018, 92: 23-34.
- [47] LI J H, LI P X, GUO D, et al. Advanced prediction of tunnel boring machine performance based on big data [J]. *Geoscience Frontiers*, 2021, 12(1): 331-338.
- [48] 王潇. 盾构施工喷涌及地表变形的预警预测方法研究 [D]. 北京: 北京交通大学, 2020.
- WANG X. Research on method of pre-warning and prediction for spewing and ground surface movements in shield construction [D]. Beijing: Beijing Jiaotong University, 2020. (in Chinese)
- [49] WANG Q, XIE X Y, SHAHROUR I, et al. Use of deep learning, denoising technic and cross-correlation analysis for the prediction of the shield machine slurry pressure in mixed ground conditions [J]. *Automation in Construction*, 2021, 128: 103741.
- [50] LI X F, GONG G F. Predictive control of slurry pressure balance in shield tunneling using diagonal recurrent neural network and evolved particle swarm optimization [J]. *Automation in Construction*, 2019, 107: 102928.
- [51] ZHOU C, DING L Y, HE R. PSO-based Elman neural network model for predictive control of air chamber pressure in slurry shield tunneling under Yangtze River [J]. *Automation in Construction*, 2013, 36: 208-217.
- [52] ZHOU C, XU H C, DING L Y, et al. Dynamic prediction for attitude and position in shield tunneling: A deep learning method [J]. *Automation in Construction*, 2019, 105: 102840.
- [53] WANG R H, LI D Q, CHEN E J, et al. Dynamic prediction of mechanized shield tunneling performance [J]. *Automation in Construction*, 2021, 132: 103958.
- [54] WANG P, KONG X G, GUO Z K, et al. Prediction of axis attitude deviation and deviation correction method based on data driven during shield tunneling [J]. *IEEE Access*, 7: 163487-163501.
- [55] ZHANG P, CHEN R P, WU H N. Real-time analysis and regulation of EPB shield steering using random

- forest [J]. *Automation in Construction*, 2019, 106: 102860.
- [56] 刘靖. 小什隧道围岩参数智能反分析及施工应用研究 [D]. 北京: 北京交通大学, 2018.
LIU J. Research on intelligent back analysis of rock parameters and construction application of Xiao Qian tunnel [D]. Beijing: Beijing Jiaotong University, 2018. (in Chinese)
- [57] 韩小川. 夏村隧道施工监控量测与围岩参数位移反分析 [D]. 南昌: 南昌工程学院, 2015.
HAN X C. Xiaocun tunnel construction monitoring and back analysis of rock parameters from measured displacements [D]. Nanchang: Nanchang Institute of Technology, 2015. (in Chinese)
- [58] LIANG Y C, FENG D P, LIU G R, et al. Neural identification of rock parameters using fuzzy adaptive learning parameters [J]. *Computers & Structures*, 2003, 81(24/25): 2373-2382.
- [59] SUWANSAWAT S, EINSTEIN H H. Artificial neural networks for predicting the maximum surface settlement caused by EPB shield tunneling [J]. *Tunnelling and Underground Space Technology*, 2006, 21(2): 133-150.
- [60] 郝哲, 刘斌. 基于差分法及神经网络的洞室围岩力学参数反分析 [J]. *岩土力学*, 2003, 24(Sup2): 77-80.
HAO Z, LIU B. Back analysis of mechanics parameters of rocks surrounding openings on the basis of calculus of difference and neural network [J]. *Rock and Soil Mechanics*, 2003, 24(Sup2): 77-80. (in Chinese)
- [61] 高攀科, 谢永利. 隧道软弱围岩的改进 BP 神经网络位移反分析 [J]. *郑州大学学报(工学版)*, 2013, 34(1): 23-26.
GAO P K, XIE Y L. Displacement back analysis of tunnels in soft and weak rocks based on improved BP neural network method [J]. *Journal of Zhengzhou University (Engineering Science)*, 2013, 34(1): 23-26. (in Chinese)
- [62] YU H G, TAO J F, QIN C J, et al. A novel constrained dense convolutional autoencoder and DNN-based semi-supervised method for shield machine tunnel geological formation recognition [J]. *Mechanical Systems and Signal Processing*, 2022, 165: 108353.
- [63] ZHANG Q L, LIU Z Y, TAN J R. Prediction of geological conditions for a tunnel boring machine using big operational data [J]. *Automation in Construction*, 2019, 100: 73-83.
- [64] YANG H Q, SONG K L, ZHOU J Y. Automated recognition model of geomechanical information based on operational data of tunneling boring machines [J]. *Rock Mechanics and Rock Engineering*, 2022, 55(3): 1499-1516.
- [65] ERHARTER G H, MARCHER T, REINHOLD C. Rock mechanics for natural resources and infrastructure development [M]: CRC Press, 2019: 2426-2432.
- [66] LIU Q S, WANG X Y, HUANG X, et al. Prediction model of rock mass class using classification and regression tree integrated AdaBoost algorithm based on TBM driving data [J]. *Tunnelling and Underground Space Technology*, 2020, 106: 103595.
- [67] KIM T H, KWAK N S, KIM T K, et al. A TBM data-based ground prediction using deep neural network [J]. *Journal of Korean Tunnelling and Underground Space Association*, 2021, 23(1): 13-24.
- [68] SHI M L, SUN W, ZHANG T C, et al. Geology prediction based on operation data of TBM: Comparison between deep neural network and soft computing methods [C]//2019 1st International Conference on Industrial Artificial Intelligence (IAI). July 23-27, 2019, Shenyang, China. IEEE, 2019: 1-5.
- [69] YU H G, TAO J F, QIN C J, et al. Rock mass type prediction for tunnel boring machine using a novel semi-supervised method [J]. *Measurement*, 2021, 179: 109545.
- [70] ZHAO J H, SHI M L, HU G, et al. A data-driven framework for tunnel geological-type prediction based on TBM operating data [J]. *IEEE Access*, 2019, 7: 66703-66713.
- [71] 孙钧, 袁金荣. 盾构施工扰动与地层移动及其智能神经网络预测 [J]. *岩土工程学报*, 2001, 23(3): 261-267.
SUN J, YUAN J R. Soil disturbance and ground movement under shield tunnelling and its intelligent prediction by using ANN technology [J]. *Chinese Journal of Geotechnical Engineering*, 2001, 23(3): 261-267. (in Chinese)
- [72] KOHESTANI V R, BAZARGAN-LARI M R, MARNANI J A. Prediction of maximum surface settlement caused by earth pressure balance shield tunneling using random forest [J]. *Journal of AI and Data Mining*, 2017, 5: 127-135.
- [73] POURTAGHI A, LOTFOLLAHI-YAGHIN M A. Wavenet ability assessment in comparison to ANN for predicting the maximum surface settlement caused by tunneling [J]. *Tunnelling and Underground Space Technology*, 2012, 28: 257-271.
- [74] CHEN R P, ZHANG P, WU H N, et al. Prediction of shield tunneling-induced ground settlement using machine learning techniques [J]. *Frontiers of Structural and Civil Engineering*, 2019, 13(6): 1363-1378.
- [75] CAO Y, ZHOU X K, YAN K. Deep learning neural network model for tunnel ground surface settlement prediction based on sensor data [J]. *Mathematical Problems in Engineering*, 2021, 2021: 9488892.
- [76] ZHANG W G, ZHANG R H, WU C Z, et al. State-of-

- the-art review of soft computing applications in underground excavations [J]. *Geoscience Frontiers*, 2020, 11(4): 1095-1106.
- [77] 赵勇, 王敏, 高文旗, 等. 分布式光纤传感新技术在盾构隧道结构变形监测中的应用[J]. *公路*, 2017, 62(7): 326-329.
- ZHAO Y, WANG M, GAO W Q, et al. Application of distributed optical fiber sensing technology in deformation monitoring of shield tunnel [J]. *Highway*, 2017, 62(7): 326-329. (in Chinese)
- [78] OCAK I, SEKER S E. Calculation of surface settlements caused by EPBM tunneling using artificial neural network, SVM, and Gaussian processes [J]. *Environmental Earth Sciences*, 2013, 70(3): 1263-1276.
- [79] WANG F, GOU B C, QIN Y W. Modeling tunneling-induced ground surface settlement development using a wavelet smooth relevance vector machine [J]. *Computers and Geotechnics*, 2013, 54: 125-132.
- [80] HASANIPANAH M, NOORIAN-BIDGOLI M, JAHED ARMAGHANI D, et al. Feasibility of PSO-ANN model for predicting surface settlement caused by tunneling [J]. *Engineering with Computers*, 2016, 32(4): 705-715.
- [81] GOH A T C, ZHANG W G, ZHANG Y M, et al. Determination of earth pressure balance tunnel-related maximum surface settlement: A multivariate adaptive regression splines approach [J]. *Bulletin of Engineering Geology and the Environment*, 2018, 77(2): 489-500.
- [82] MAHMOODZADEH A, MOHAMMADI M, DARAEI A, et al. Forecasting maximum surface settlement caused by urban tunneling [J]. *Automation in Construction*, 2020, 120: 103375.
- [83] ZHANG K, LYU H M, SHEN S L, et al. Evolutionary hybrid neural network approach to predict shield tunneling-induced ground settlements [J]. *Tunnelling and Underground Space Technology*, 2020, 106: 103594.
- [84] CHA Y J, CHOI W, BÜYÜKÖZTÜRK O. Deep learning-based crack damage detection using convolutional neural networks [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2017, 32(5): 361-378.
- [85] BESAW L E, STIMAC P J. Deep learning algorithms for detecting explosive hazards in ground penetrating radar data [C]//*SPIE Defense + Security. Proc SPIE 9072, Detection and Sensing of Mines, Explosive Objects, and Obscured Targets XIX*, Baltimore, Maryland, USA. 2014, 9072: 224-234.
- [86] MAKANTASIS K, PROTOPAPADAKIS E, DOULAMIS A, et al. Deep convolutional neural networks for efficient vision based tunnel inspection [C]//*2015 IEEE International Conference on Intelligent Computer Communication and Processing*. September 3-5, 2015, Cluj-Napoca, Romania. IEEE, 2015: 335-342.
- [87] CHEN Z Y, ZHANG Y P, LI J B, et al. Diagnosing tunnel collapse sections based on TBM tunneling big data and deep learning: a case study on the Yinsong Project, China [J]. *Tunnelling and Underground Space Technology*, 2021, 108: 103700.

(编辑 胡英奎)