

DOI: 10.19650/j.cnki.cjsi.J2413630

不同地质条件下盾构机掘进速度预测方法*

王毓灿¹, 元海文¹, 孙齐², 杨磊³, 肖长诗⁴

(1. 武汉工程大学电气信息学院 武汉 430205; 2. 中国葛洲坝集团股份有限公司 武汉 430030;
3. 武汉大学水利水电学院 武汉 430072; 4. 武汉理工大学航运学院 武汉 430063)

摘要:盾构机掘进性能受不同地质条件影响明显。该研究以电驱土压平衡盾构机为对象,统计了961环3761006条掘进数据,包括砂质黏性土层等6种地质组合以及对应的盾构机掘进参数。通过相关性分析,确定与掘进速度紧密相关的特征变量,包括总推力、同步注浆量和泡沫压力等。然后,针对实际盾构工程存在数据分布不均衡问题,对原始数据高斯重采样,生成包含19950个有效样本的数据集。随后,提出了一种基于Kolmogorov-Arnold Network(KAN)的盾构机掘进速度预测方法,KAN模型通过多层次复合函数的组合逼近非线性关系,将多因素耦合的非线性关系又近似分解为一系列单变量函数组合,在确保模型预测精度的同时,极大提高计算效率。以深圳至大亚湾地铁盾构工程为例,开展实验论证,结果表明:与卷积神经网络(CNN)、长短时记忆网络(LSTM)等模型相比,KAN在处理高维数据和非线性耦合关系方面表现出优越性能,其预测结果能够精确拟合实测数据。在地质条件较为单一(如全风化混合花岗岩、土状强风化混合花岗岩)的预测误差较低,平均误差控制在5.12%~7.02%,而在混合地层中预测误差有所增大,但总体平均误差仍控制在15%以内。该方法为复杂地质条件下盾构机施工优化提供了有力的决策支持。未来将地质空间分布信息以序列形式引入模型,并增加刀盘磨损的输出预测,为盾构施工的智能化管理提供更加全面的解决方案。

关键词:盾构机;掘进预测;地质分析;特征选择;Kolmogorov-Arnold Network

中图分类号: TH6 TP312 TP3.05 U455.43 **文献标识码:** A **国家标准学科分类代码:** 520.20 560.55

Prediction of tunneling speed of shield machine under varying geological conditions

Wang Yucan¹, Yuan Haiwen¹, Sun Qi², Yang Lei³, Xiao Changshi⁴

(1. School of Electrical and Information Engineering, Wuhan Institute of Technology, Wuhan 430205, China;
2. China Gezhouba Group Co., Ltd., Wuhan 430030, China; 3. School of Water Resources and Hydropower, Wuhan University, Wuhan 430072, China; 4. School of Navigation, Wuhan University of Technology, Wuhan 430063, China)

Abstract: The tunneling performance of shield machines is greatly influenced by varying geological conditions. This study investigates an electrically-driven earth pressure balance shield machine, analyzing 3,761,006 tunneling data points across 961 rings. The dataset includes six geological combinations, such as sandy cohesive soil layers, along with corresponding tunneling parameters. Through correlation analysis, key features strongly related to tunneling speed, including total thrust, sync grouting volume, and foam pressure, were identified. To address the issue of uneven data distribution in practical tunneling projects, Gaussian resampling was applied, resulting in a dataset with 19,950 valid samples. A tunneling speed prediction method for shield machines based on the Kolmogorov-Arnold Network (KAN) was then proposed. The KAN model approximates nonlinear relationships by combining multi-level composite functions, breaking down the complex nonlinear interactions into simpler univariate function combinations. This approach ensures high prediction accuracy while significantly improving computational efficiency. Using the Shenzhen-to-Daya Bay Metro Shield Tunneling Project as a case study, experiments showed that the KAN model outperforms CNN and LSTM models in handling high-dimensional data and nonlinear coupling relationships. The prediction results align closely with measured data, with prediction errors ranging from 5.12% to 7.02%, while prediction errors in mixed layers increased, but the overall average error remained within 15%.

收稿日期:2024-12-25 Received Date: 2024-12-25

* 基金项目:湖北省自然科学基金(2022CFB313)项目资助

to 7.02% in simpler geological conditions (such as completely weathered mixed granite and strongly weathered mixed granite). In mixed geological layers, the prediction errors are higher, but the overall average error remains below 15%. This method offers strong decision support for optimizing shield machine operations under complex geological conditions. In the future, geological spatial distribution data will be incorporated into sequential modeling, and cutterhead wear prediction will be added to provide a more comprehensive intelligent management solution for shield tunneling.

Keywords: shield machine; tunneling prediction; geological analysis; feature selection; Kolmogorov-Arnold Network

0 引言

随着地铁与隧道工程高质量建设,盾构机及相关技术被广泛研究和推广应用。盾构机精准的掘进预测对工程进度规划、成本预算的优化具有重要意义。众所周知,实际工程中地质工况丰富多样,盾构机的掘进性能(如掘进速度、刀盘磨损等)受地质条件影响明显^[1]。传统物理模拟的算法或软件存在计算周期长、复杂度高等特点。

在实际隧道开挖过程中,围岩地质条件复杂多变,盾构机施工中掘进参数的选择与控制通常依赖于操作人员的经验判断。然而,由于掘进参数与岩体状态参数之间的匹配性较差,当遇到地层变化等复杂地质条件时,难以迅速且有效地调整掘进方案和控制参数。这种情况容易导致盾构机卡机、地质灾害甚至严重的人员伤亡事故^[2]。然而,传统的盾构机性能预测方法较少考虑岩体变化的影响,这使得盾构机掘进速度的预测面临着较大的挑战。因此,如何更加深入地理解岩机之间的相互作用,并为不同地质条件下的盾构机掘进速度开发出更高精度且鲁棒性更强的预测模型,已成为当前研究的热点。

目前,国内外已经对盾构机掘进速度进行了大量研究,这些研究根据预测方法的不同,通常可分为3类:理论模型、经验模型和机器学习模型。延艳彬等^[3]引入数量化理论 I 构建含围岩与地下水等定性及岩石力学参数定量数据的预测模型,研究双护盾盾构机掘进速度影响因素。Pan 等^[4]在检验、比较并关联实验室 LCM (linear cutting machine) 法、半理论 CSM (Colorado School of Mines) 法及经验 NTNU (Norwegian University of Science and Technology) 法这3种常用方法的预测结果,结合前人研究提出能更可靠准确预测盾构机最佳岩石切削条件下现场掘进性能的经验公式。周振梁等^[5]利用数理统计方法探究地质与掘进参数规律,分析其对掘进速度影响,建立回归公式与多因素预测模型,关注其回归关系及验证预测效果。Armaghani 等^[6]则通过结合现场观测数据与实验室测试数据,建立了基于岩石信息的盾构机掘进速度预测经验模型。尽管上述研究通过回归等方法实现了盾构机掘进速度预测,但由于地质参数与盾构机掘进参数之间呈现高度耦合且非线性关系,使得这些方法受到极大局限性。

现代机器学习算法凭借强大的非线性数据处理^[7]和特征表示能力^[8],逐渐被应用于盾构机性能预测与智能控制。赵光祖等^[9]采用模拟退火算法和遗传算法优化的 BP (back propagation) 神经网络克服盾构机性能预测的局部最优问题; Armaghani 等^[10]构建人工神经网络模型,以盾构机掘进参数与岩体参数作为输入特征,对贯入度进行预测; Wang 等^[11]提出一种因果门控循环单元智能模型,对盾构机掘进过程性能参数进行预测,并通过实验说明其效果较好;姜晓迪^[12]结合岩石单轴抗压强度、巴西劈裂强度、岩石耐磨性、刀盘推力和刀盘转速等5个关键特征,提出了一种 BP 神经网络与部分最小二乘回归相结合的掘进速度预测模型。尽管现代机器学习方法已经在盾构机掘进预测方面取得明显成就,但仍存在以下不足:一方面,由于盾构机掘进过程中岩机相互作用的复杂性,当盾构机从完整性较好的坚硬岩层进入至掌子面较破碎的软岩地层时,掘进参数波动较大,导致现有模型的鲁棒性变差,很难在不同地质条件下实现精确预测;另一方面,现有的预测方法大多仅侧重于算法的替换或优化,忽视了数据采集过程中可能存在的测量误差^[13]、数据录入问题和设备精度不高等因素,这些问题会导致数据中包含噪声,未能充分挖掘数据特性对盾构机掘进速度预测精度的影响。因此,在不同地质工况影响下建立高精度掘进预测模型存在极大挑战。这些问题严重制约了现有智能化预测模型在盾构机掘进工程中的推广与应用。

为解决上述难题,该研究重点分析不同地质条件下盾构机掘进速度预测方法。以深圳至大亚湾地铁盾构工程为应用背景,收集了包括砂质黏性土层等6种地质组合条件下对应的盾构机掘进数据,用于开展研究分析。提出了一种基于 KAN (Kolmogorov-Arnold Network)^[14]的盾构机掘进速度预测方法。与传统深度学习模型相比, KAN 模型具有卓越的高维数据处理能力和非线性关系解析优势,能够精准捕获盾构机在复杂地质条件下的掘进特征,为施工方案的优化调整提供强有力的数据支持和科学指导。

1 盾构数据分析与处理

在盾构数据采集过程中,盾构机产生的数据量庞大且复杂,直接处理比较困难。现场环境嘈杂噪声大,给数

据采集带来干扰,导致获取的数据包含较多误差。并且,数据分布呈现出不均匀的状态,不同类型数据的占比有明显差异,使得模型学习时难以充分且精准地把握数据特征。掘进参数的选择对盾构施工有着重要的意义,合适的掘进参数可以在一定程度上控制地表沉降,对延长刀具寿命、保障盾构机良好工作状态也有积极作用。

针对这些情况,该研究开展了定量的盾构数据分析,对不同地质条件下掘进参数的相关性展开特征选择。同时,提出一种高斯重采样策略,降低样本分布不均衡对模型学习的影响。

1.1 数据预处理

考虑到盾构施工面临的地质多样性和高度依赖操作人员经验的特点,原始采集数据中频繁蕴含异常工况记录。此外,遵循盾构机的既定作业流程,设备周期性地需要进

行加固支撑与维护,这一过程产生了大量非作业时段的数据记录。因此,对原始盾构机掘进数据实施清洗,旨在精准排除上述两类非典型工作状态信息,是减少因异常值干扰而引发的掘进参数误判预警的关键步骤。基于盾构机操作规范,在非正常作业状态下,理论上总推力与刀盘扭矩应处于零值水平。据此原则,去除此类状态下的缺失值、零值及重复记录,以确保数据集的纯净度与分析的有效性。

图1所展示的识别结果是对左线部分掘进参数进行数量分析后的直观呈现。观察图中所展示的掘进参数分布状况,可以明显看出各参数的数值分布存在一定的集中趋势和离散程度。为了确保数据分析的准确性和有效性,同时促进数据的均匀分布,各掘进参数被设定了有效的取值范围约束,如表1所示。

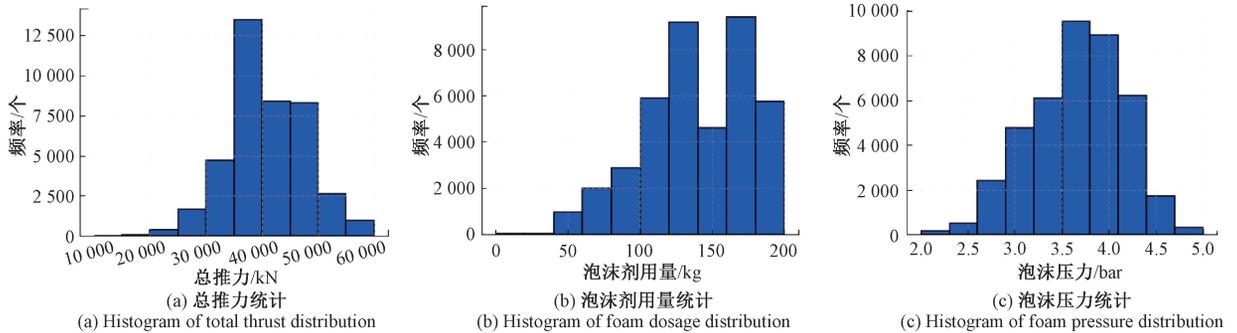


图1 部分掘进参数统计分析

Fig. 1 Statistical analysis of tunneling parameters

将掘进过程中涉及的各关键参数的无效值剔除后,重新整理数据,并分别针对这些参数绘制了直方图,以系统地考察它们的分布特征。通过这一分析过程,计算了包括均值、中位数、标准差等在内的关键统计量,这些统计值不仅反映了各掘进参数的整体水平,也为后续的深入数据分析和模型构建提供了坚实的基础。

表1 掘进参数统计值

Table 1 Statistical value of tunneling parameters

掘进参数	单位	取值范围	均值	中位数
刀盘转速	rpm	1.2~1.8	1.5	1.5
总推力	kN	10 000~70 000	40 911.4	40 000
注浆压力	bar	0~8	3.14	3.12
同步注浆量	m ³	0~40	6.68	6.51
泡沫原液比例	%	5~6	6	6
泡沫压力	bar	0~6	3.67	3.71
泡沫剂用量	kg	0~250	139.62	139.4
刀盘扭矩	kN·m	0~10 000	4 187.99	3 990
掘进速度	mm/min	0~80	33.88	34

由表1可知,各掘进参数的均值与中位值较为接近。均值和中位值作为描述数据集中心趋势的两个重要统计量,当它们相互接近时,通常意味着数据分布较为均匀,没有显著的离群值或异常点。这一观察结果表明,在剔除了无效值之后,掘进参数的分布相对较为集中,且没有明显的偏态或极端值影响整体数据的代表性。

1.2 特征选取

该研究的数据基础源自于深大城际项目1标段中,T4枢纽站至机场东区间一工区隧道段的详实工况数据,具体涵盖了左线(共计452环)与右线(共计509环)的施工记录。施工过程中采用了先进的电驱动土压平衡式盾构机^[15]进行隧道掘进作业,确保了数据采集的准确性和代表性。地质勘察结果揭示了隧道掘进路径穿越的复杂地质环境,共涉及6大类地层^[16],依次为砂质黏性土层、全风化混合花岗岩层、土状强风化混合花岗岩层、块状强风化混合花岗岩层、中风化混合花岗岩层及微风化混合花岗岩层。这些地质类型以不同的体积比例相互交织,共同构成了每一掘进环的独特地质剖面,其详细的百分占比分布如图2所示,例如,某地质条件分布为:13%

的土状强风化混合花岗岩、63% 中风化混合花岗岩和 24% 微风化混合花岗岩,则可定义为(0,0,0.13,0,0.63,0.24)。

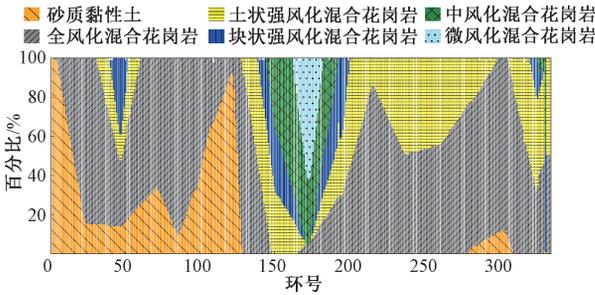


图 2 深大城际铁路某工区右线地质分布

Fig. 2 Geological distribution of the right line of a work area of Shenzhen-Dalian intercity railway

除了地质条件,盾构机本身的掘进参数也与掘进速度紧密相关,包括总推力、刀盘转速、注浆压力、同步注浆量、泡沫压力、泡沫剂用量、泡沫原液比例、刀盘扭矩^[17]等。

总推力的大小由刀盘切削力、土仓压力阻力、盾体摩擦力及后配套牵引力等多种因素的综合作用决定,刀盘转速是盾构机刀盘每分钟的转动次数,通常将刀盘转速设定在 1.5 rpm 左右。控制总推力和刀盘转速能提高切削效率,同时减少机械磨损^[18]和能量消耗,保证掘进稳定性。注浆压力是通过注浆管道向地层注入浆液的压力,同步注浆量是实时注入到土体中的浆液体积。注浆压力能增强地层稳定性、减少土体的变形和坍塌,同步注浆量能及时填充盾构掘进空隙,减少地表沉降,保障隧道结构完整。泡沫压力指注入的泡沫剂通过管道产生的气泡压力,泡沫剂用量指掘进过程中使用的泡沫剂的总量。适当的泡沫压力可以增强泡沫剂的效果,确保泡沫的均匀性和持久性,降低掘进阻力的同时,减少土体对设备的粘附和磨损。

此外,泡沫原液比例表示泡沫剂与水或其他溶液的混合比例,调整比例能增强土壤流动性并减少掘进阻力,通常将泡沫原液比例设定在 5%~6% 的区间;而刀盘扭矩是盾构机刀盘在工作过程中所需要的旋转力矩,反映了刀盘的切削难度和掘进阻力。

利用 Spearman 相关系数对上述掘进参数进行相关性分析,如图 3 所示。总推力、泡沫剂用量和泡沫压力与地质条件及掘进速度之间的相关性系数分别为 0.59、0.53、0.54 和 -0.26、-0.34、0.14。结果表明,这些参数的变化对地质条件和掘进速度有较大影响,且它们之间存在明显相关性。

最终确定了地质条件、总推力、同步注浆量和泡沫压力作为掘进速度预测的关键特征^[19]。

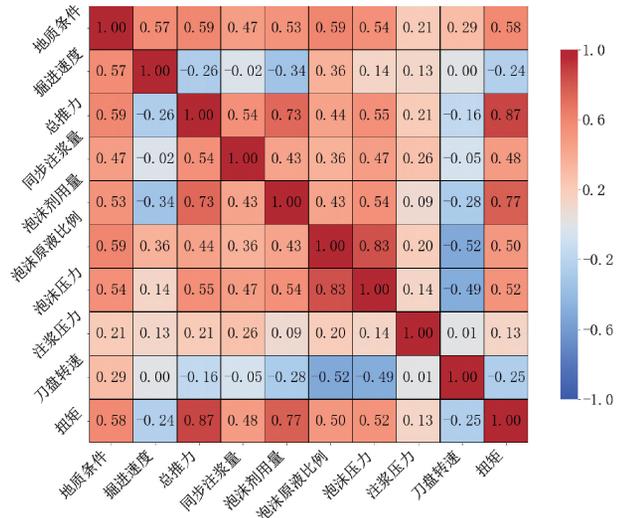


图 3 地质条件与掘进参数相关性分析

Fig. 3 Correlation analysis between geological conditions and tunneling parameters

1.3 高斯重采样

根据上述数据分析,该工区主要地质条件是砂质黏性土层、全风化混合花岗岩层等 6 种地质类型及其组合,即每一种地质条件由此 6 种地质类型的百分比组合定义。在实际盾构工程中,同一工区内地质类型通常分布集中且不均匀,导致采集到不同地质条件对应的样本数据数量严重不一致,从而影响所提模型的训练效果。因此,该研究在原始数据基础上采取高斯重采样策略:在保持原始样本分布不变的前提下,改变每一种地质条件对应的样本数量,使其接近或一致。

结合实际地质分布,累计获得 399 种地质条件。对每种地质条件下盾构机掘进参数(总推力、同步注浆量等)数据分布统计,通过可视化分析,利用高斯拟合对参数分布进行拟合,估计对应的分布参数(μ,σ)。具体估算公式如式(1)~(2)所示。

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i \tag{1}$$

$$\sigma = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{\mu})^2} \tag{2}$$

其中, n 是样本个数, x_i 表示某地质条件下掘进参数样本。随后,利用参数分布(μ,σ), 建立服从该分布的高斯函数,并进行数据重采样。

假设某地质条件(0,0,0.13,0,0.63,0.24)下,盾构机掘进过程中的总推力分布如图 4 所示,经过高斯拟合获得对应的分布参数(35 087.99,1 181.45),根据该分布参数进行数据重采样,得到指定数量的新样本。该研究创新性引入了高斯重采样策略,主要是解决实际工程中不同地质条件数据样本分布不均衡问题。通过这种策

略,将399种地质条件下对应的样本数量统一为100个。例如,对盾构机总推力原始数据分布统计分析,其分布符合高斯特性。对原始数据(图4(a))实施高斯重采样,可

以获得不同地质条件类别分布均衡的数据样本(图4(b)),有效解决了实际工程中原始数据集样本分布不均衡问题。

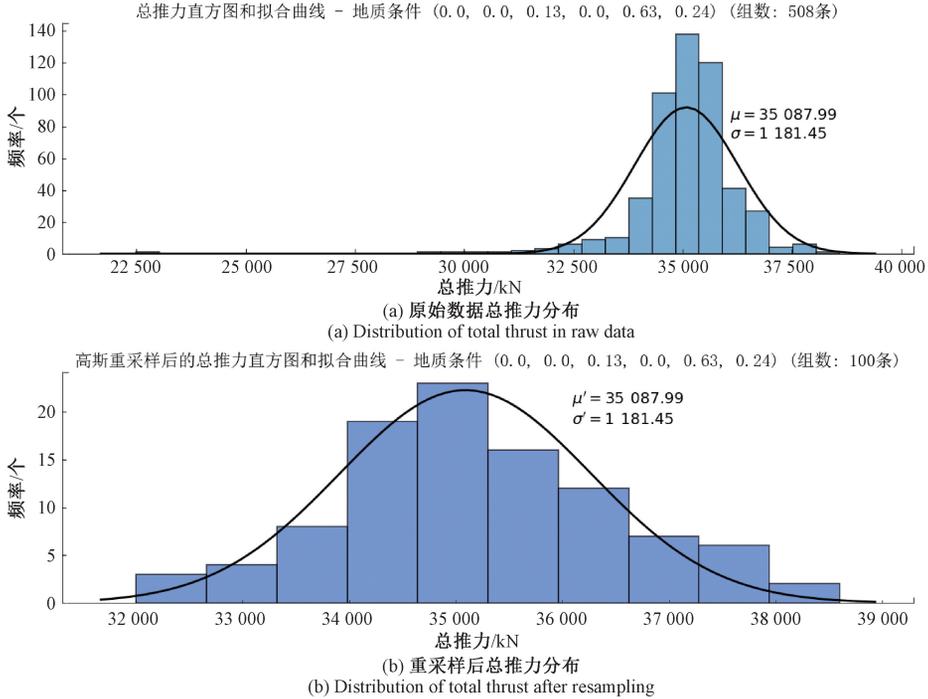


图4 盾构机掘进参数总推力高斯重采样

Fig. 4 Gaussian resampling of total thrust in tunneling parameters

表2直观展示了部分地质数据重采样前后的样本数量。为说明高斯重采样对提升模型学习性能的有效性,分别采用原始数据集(样本数量超300万)和重采样后的数据集(样本数量19950条)对同一个深度学习模型(下文KAN模型)进行训练。基于原始数据的

模型平均预测误差为22.5%,而基于重采样数据得到的模型平均预测误差为15%,降低7.5%,且预测不确定性更加稳定。结果表明,与原始数据集相比,重采样的数据集在样本数量更少更均衡的情况下对提升模型性能更有优势。

表2 部分地质数据重采样前后样本数量统计

Table 2 Statistics of sample counts for selected geological data before and after resampling (条)

地质条件	重采样前数量	重采样后数量
100%砂质黏性土	3 722	100
100%全风化混合花岗岩	3 650	100
100%土状强风化混合花岗岩	14 795	100
13%土状强风化、63%中风化和24%微风化混合花岗岩	508	100
23%土状强风化和77%块状强风化混合花岗岩	1 766	100
22%土状强风化、8%块状强风化、68%中风化和2%微风化混合花岗岩	545	100
28%土状强风化、15%块状强风化和中风化混合花岗岩	615	100
70%全风化和30%土状强风化混合花岗岩	1 899	100
55%砂质黏性土和45%全风化混合花岗岩	102	100
4%全风化、18%土状强风化、2%块状强风化、73%中风化和3%微风化混合花岗岩	618	100

2 盾构机掘进速度预测方法

以地质条件和掘进参数为输入,构建基于 KAN 的多变量回归模型,设置 LBFGS 优化器和均方误差 (mean squared error, MSE) 损失函数,通过在上节的数据集的训练和测试,从而提出一种盾构机掘进速度预测方法,实现不同地质条件下的精准预测。

2.1 KAN 回归预测模型

KAN 通过多层次的复合函数逼近任意连续函数,在参数量更少的情况下具有更强大的非线性逼近能力,其特有的激活函数设计也提升了其表达能力,适用于复杂工况条件下盾构机掘进速度非线性回归。Kolmogorov-Arnold 定理^[20]指出,对于任何在单位 n 维超立方体 $I^n = [0, 1]^n$ 上的连续函数 $f: I^n \rightarrow I$, 都可以表示为一系列双变量函数的嵌套组合形式,即:

$$f(x_1, \dots, x_n) = \sum_{q=0}^{2n+1} \Phi_q \left(\sum_{p=1}^n \phi_{q,p}(x_p) \right) \quad (3)$$

式中: Φ_i 为从 I^2 到 I 的连续双变量函数,该定理揭示了即使是高度复杂的 n 维函数也可以被一系列简单的双变量函数以特定方式组合来近似。在实际应用中,每层神经网络接受两个输入并输出一个值,模拟上述的双变量函数结构^[21]。具体来说,对于第 i 层,神经网络可以表示为:

$$\Phi_i = (x, y) = g_i(\mathbf{W}_i x + b_i + \mathbf{V}_i y + c_i) \quad (4)$$

式中: g_i 是一个激活函数; \mathbf{W}_i 和 \mathbf{V}_i 是权重矩阵; b_i 和 c_i 是偏置项; x 和 y 分别是来自前一层的两个输入或初始输入数据的分量。通过堆叠这样的层, KAN 能够逼近任意复杂的函数关系。

针对盾构机多元回归预测问题,设计一种基于 KAN 的深层网络架构。通常,更深的网络具备更强的复杂模型表示能力^[22]。具体架构可描述为:

$$\text{KAN}(x) = (\Phi_{L-1} \circ \Phi_{L-2} \circ \dots \circ \Phi_0)(x) \quad (5)$$

式中: Φ_{L-1} 表示第 $L-1$ 个 KAN 层,共 L 层。每一个 KAN 层通过一系列可学习函数 $\Phi_{q,p}$ 转换输入 x ,使网络具有

高度自适应性。

基于 KAN 的盾构机掘进速度预测模型包括输入层、隐藏层和输出层。在预测任务中,由于输入为地质条件和掘进参数 9 个变量,则输入层节点数设置为 9。由式(3)可知,对于 n 个输入变量,隐藏层节点数设置为 $2n+1$ 个是理论上确保模型能够分解成任意连续函数的最小要求。在模型构建过程中,如果任务复杂度较高,可根据需求增加隐藏层的层数来增强模型表达能力。通过模型调试,设置隐藏层的层数为 2,隐藏层节点分别为 32。输出层通过单变量函数和加权组合的方式,将隐藏层的特征合并至 1 个节点输出,即掘进速度。

此外,每一层 KAN 采用残差激活函数^[14] $\phi(x)$, 由一个残差函数 $b(x)$ 和一个样条函数 $\text{spline}(x)$ 共同组成:

$$\phi(x) = w_b b(x) + w_s \text{spline}(x) \quad (6)$$

式中:函数 $\text{spline}(x)$ 被参数化为 B 样条的线性组合,用于对输入信号非线性映射。 B 样条的阶数设置为 3,即每段函数由三次多项式表示,段数设置为 10,表示每段分为 10 个区间。这些设置决定了激活函数的高维非线性表达能力。

2.2 模型参数学习机制

盾构机掘进速度预测模型在训练过程采用 LBFGS 优化器和均方误差作为损失函数。LBFGS 是一种适合大规模问题且内存效率高的优化算法,在计算更新方向时,不仅考虑了当前梯度信息,还通过构建一个逼近的二阶导数矩阵 (Hessian 矩阵) 来加速收敛,适合深度学习中的小批量或全量梯度计算。损失函数采用 MSE,用于衡量模型预测值与真实值之间的差异。

利用 2.1 节特征选择和重采样后的数据创建数据集,共计 19 950 条。按照 6:4 比例随机划分为训练集和测试集。设置学习率为 0.000 1、每次批量化调用 40 组、最大训练次数设为 300 次,正则化强度设为 0.1。当模型损失值 MSE 随着训练次数不再发生明显变化时,终止模型训练,在一定程度上可抑制过拟合,图 5 展示了基于 KAN 的盾构机掘进速度训练和预测任务流程。

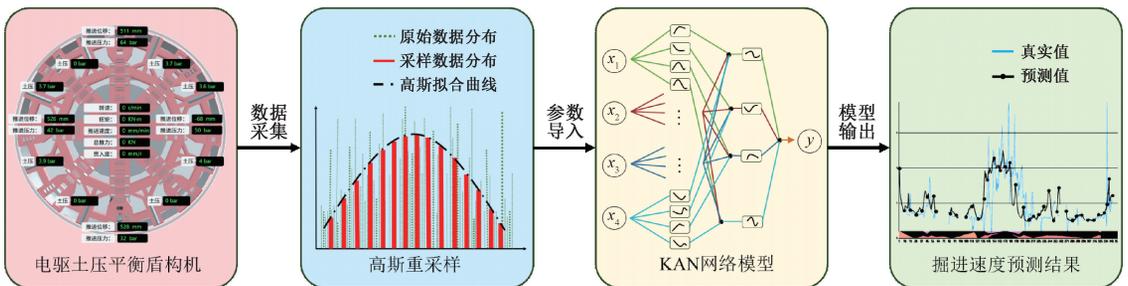


图 5 基于 KAN 的盾构机掘进速度预测流程

Fig. 5 Tunneling speed prediction process based on KAN

3 结果与分析

为分析盾构机掘进速度预测模型的性能,选择5个评价指标:MSE、均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分误差(mean average precision error, MAPE)、决定系数 R^2 。其中前4个指标越小,表示拟合效果越优,而决定系数越接近于1,则拟合效果最佳。各评价指标具体计算如式(7)~(11)所示:

$$MSE = \frac{1}{N} \sum_{j=1}^N (\hat{y}_j - y_j)^2 \quad (7)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (\hat{y}_j - y_j)^2} \quad (8)$$

$$MAE = \frac{1}{N} \sum_{j=1}^N |\hat{y}_j - y_j| \quad (9)$$

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left(\frac{|\hat{y}_j - y_j|}{y_j} \right) \times 100\% \quad (10)$$

$$R^2 = 1 - \frac{\sum_{j=1}^N (\hat{y}_j - \bar{y})^2}{\sum_{j=1}^N (y_j - \bar{y})^2} \quad (11)$$

其中, y_j 为真实值, \hat{y}_j 为预测值, \bar{y} 为平均值, N 为样本数量。

3.1 掘进速度预测

依据第2章内容,获得盾构机掘进速度预测模型,在训练集和测试集的预测结果如图6所示。图中1:1线为参考线即模型预测的最理想状况,此时预测值与真实值完全相同。当数据分布越接近参考线,则预测精度越高;越远离参考线,表明预测精度越低。在训练集、测试集上预测值与真实值均较为接近,可见基于KAN的预测模型性能表现良好。

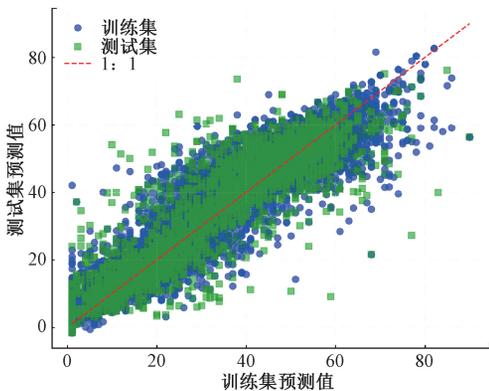


图6 KAN模型在训练集、测试集上的预测性能对比
Fig. 6 Comparison of KAN model prediction performance on the training and testing datasets

如表3所示,提供了所提预测模型分别在训练集、测试集上的预测性能。其中,该模型的MSE和RMSE在训练集和测试集上数值接近,表明模型具有一定泛化能力,学习过程没有过拟合或欠拟合。而且, R^2 均大于0.6,MAPE均在15%以下,表明该模型预测精度较高,满足实际工程需求。

表3 模型性能评价

Table 3 Performance evaluation of KAN model

数据集	MSE/ (mm·min ⁻¹) ²	RMSE/ (mm·min ⁻¹)	MAE/ (mm·min ⁻¹)	MAPE/ %	R ²
训练集	56.154	7.861	8.832	13.686	0.675
测试集	55.954	7.528	8.807	14.358	0.672

将基于KAN模型的盾构机掘进速度预测模型部署在现场智慧盾构大数据系统平台,实时接入新的地质工况数据,实际预测结果和预测误差如图7所示。其中,最大误差值52.92%,最小误差值0.08%,平均误差值达到了13.27%,预测基本准确。

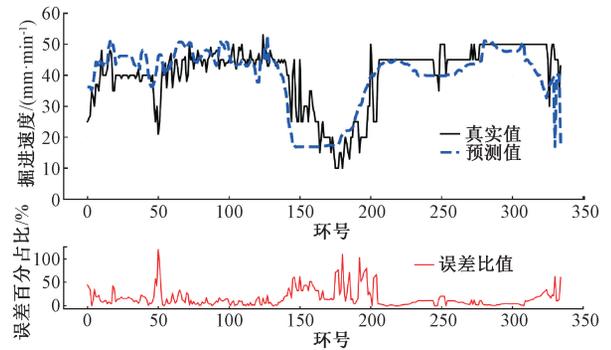


图7 实际地质工况条件的预测结果和对应误差
Fig. 7 Prediction results under actual geological conditions and corresponding errors

为进一步说明KAN预测模型在不同地质工况条件下的表现性能,如图8所示,随机挑选了6种地质条件,并根据掘进参数进行掘进速度预测。图8(a)为全风化混合花岗岩、土状强风化混合花岗岩混合为主的地质条件,预测平均误差为5.12%,图8(b)为砂质粘性土和全风化混合花岗岩混合为主的地质条件,预测平均误差为6.88%,图8(c)表示以砂质粘性土、全风化混合花岗岩和土状强风化混合花岗岩混合为主地质条件,预测平均误差为7.02%,而在图8(d)~(f)中,预测平均误差也控制在10%以内。在盾构机实际施工应用中,上述预测结果满足数字化管理要求。

分析上述预测结果表明,误差的产生主要受地质条件复杂性、掘进参数波动性以及数据分布特性的综合

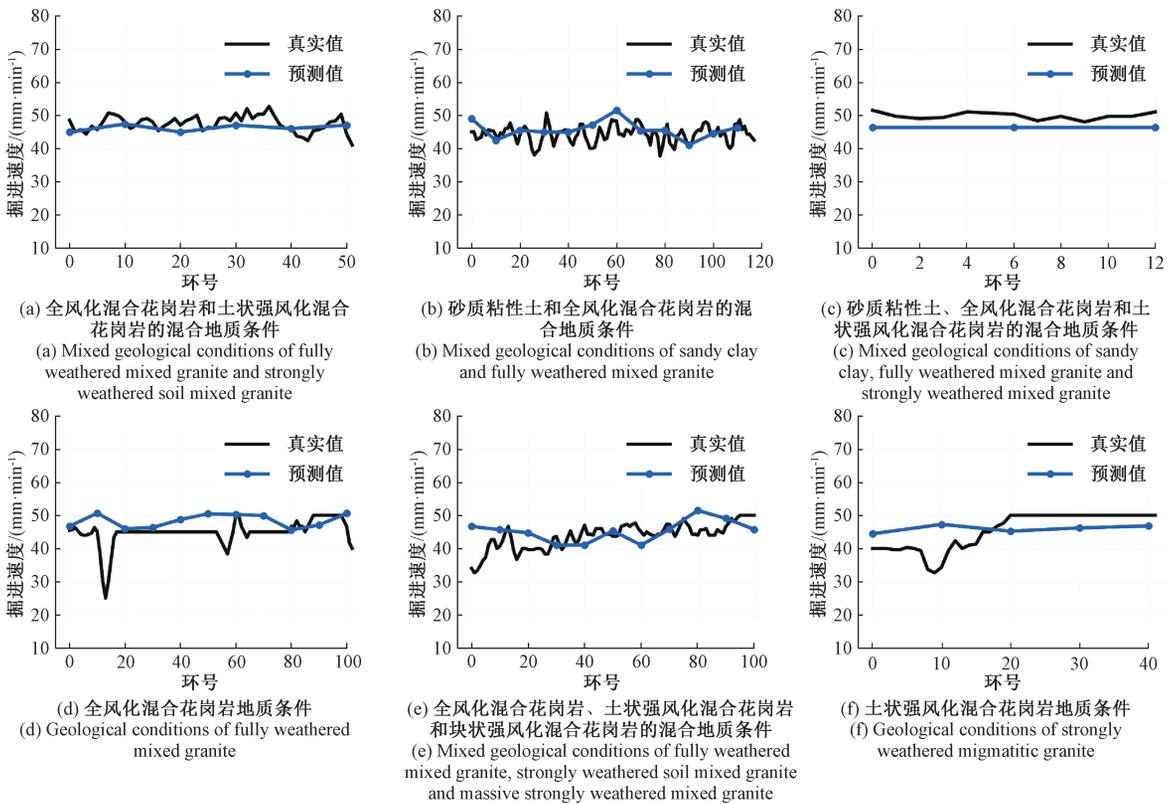


图 8 不同地质条件下的掘进速度预测结果

Fig. 8 Predictions of tunneling speed under different geological conditions

影响。对于地质条件较为单一的工况(如全风化混合花岗岩与土状强风化混合花岗岩),模型的预测误差较低,平均值在 5.12%~7.02% 范围内。然而,在复杂混合地层中,非均匀性和力学参数的高非线性特征显著增加了模型的学习难度,可能导致极端预测误差的出现。此外,掘进参数在施工过程中的高频波动对模型的稳定性提出了更高要求,这种动态变化在某些地质条件下对预测精度的影响尤为显著,例如最大误差达到 52.92% 的场景可能源于此类波动。数据样本分布的局限性也是影响模型泛化能力的重要因素,尤其是复杂工况的数据占比不足时,模型在这些区域的表现可能会偏离真实值。针对上述问题,提升模型性能的策略包括增加复杂地质条件下的样本数量,优化模型结构以增强其对动态特征的捕捉能力,例如引入具有时序分析能力的模型,并结合实时校准机制提高预测结果的可靠性。这些改进措施在未来研究工作将有助于进一步降低误差,提升模型在复杂工程场景中的适用性。

3.2 模型对比分析

将基于 KAN 的盾构机掘进速度预测模型与其他学习模型进行对比。因此,基于卷积神经网络(convolu-

tional neural network, CNN) 和长短时记忆网络(long short term memory network, LSTM) 分别建立相应的预测模型。CNN 模型、LSTM 模型与 KAN 模型采用的训练集一致,在同样的测试集上开展性能评价,获得 5 项评价指标,结果如表 4 所示。

表 4 KAN、CNN 和 LSTM 模型预测性能对比

Table 4 Performance comparisons between KAN, CNN and LSTM models

模型	MSE/ (mm·min ⁻¹) ²	RMSE/ (mm·min ⁻¹)	MAE/ (mm·min ⁻¹)	MAPE/ %	R ²
CNN	61.927	7.869	5.398	32.373	0.452
LSTM	87.198	13.682	10.64	28.192	0.435
KAN	53.367	7.305	5.328	16.265	0.794

在这三者当中,KAN 模型无论是在绝对误差(MSE, RMSE, MAE) 还是相对误差(MAPE, R²), 都表现出了更好的预测性能。预测误差最小意味着对数据变化的解释能力更强。尽管 CNN 和 LSTM 模型也有不错的预测效果,但在同等条件设置下,表现略逊于 KAN 模型。

4 结 论

该研究主要分析不同地质工况对盾构机掘进性能的影响,提出了一种基于 KAN 的盾构机掘进速度预测方法,并利用深大城际铁路项目实测数据进行了分析与验证。具体研究工作包括:

1) 特征参数的筛选与数据处理:通过对掘进参数和地质参数直方图统计和相关性分析,确定了影响掘进速度的关键特征参数,引入高斯重采样策略,有效解决了不同地质条件样本数据分布不均衡的问题,从而创建了用于盾构机掘进预测的高质量数据集。

2) KAN 预测模型的提出与验证:提出基于 KAN 的盾构机掘进速度预测模型,训练后平均预测误差低于 15%,在处理这种多因素耦合且高度非线性任务时展现出显著优势。

该研究提出的盾构机掘进速度预测方法已成功部署于深大城际铁路智慧管控平台,为复杂地质条件下的盾构施工管理提供了有效的决策支持,尤其在掘进进度估算方面取得了显著的应用成果。此外,盾构机掘进性能评估还包括刀盘扭矩,刀盘扭矩能够表示对刀盘的磨损程度,长期施以过大的刀盘扭矩,对刀盘寿命的影响愈明显。在未来研究工作中,将在现有模型基础上,增加对刀盘扭矩的预测,并结合时间累积实现对刀盘寿命的估算,为盾构机掘进性能实施更全面的评估。

参考文献

- [1] 沈翔,袁大军,吴俊,等. 复杂地层条件下盾构掘进参数分析及预测[J]. 现代隧道技术,2020,57(5):160-166.
SHEN X, YUAN D J, WU J, et al. Analysis and prediction of driving parameters of shield tunnelling in complex strata[J]. Modern Tunnel Technology, 2020, 57(5):160-166.
- [2] 韩超,张柯. 双护盾隧道掘进机穿越地铁区间断层破碎带卡机机理及防卡机技术[J]. 城市轨道交通研究,2022,25(6):153-158.
HAN CH, ZHANG K. Jamming mechanism of double shield TBM excavating in metro tunnel interval fault fracture zone and antijamming technology[J]. Research on Urban Rail Transit, 2022,25(6):153-158.
- [3] 延艳彬,许健,陈剑,等. 基于数量化理论 I 的双护盾 TBM 掘进速度预测研究[J]. 水资源与水工程学报,2015,26(4):200-205.
YAN Y B, XU J, CHEN J, et al. Research on forecast

of driving speed of double-shield TBM based on quantitative theory I [J]. Journal of Water Resources and Hydraulic Engineering, 2015,26(4):200-205.

- [4] PAN Y C, LIU Q SH, LIU Q, et al. Comparison and correlation between the laboratory, semi-theoretical and empirical methods in predicting the field excavation performance of tunnel boring machine (TBM)[J]. Acta Geotechnica, 2021, 17(2):653-676.
- [5] 周振梁,谭忠盛,李宗林,等. 一种基于数据挖掘的掘进速度预测模型[J]. 应用基础与工程科学学报,2021,29(5):1201-1219.
ZHOU ZH L, TAN ZH SH, LI Z L, et al. A data mining based prediction model for penetration rate [J]. Applications Journal of Fundamental and Engineering Sciences, 2021,29(5):1201-1219.
- [6] ARMAGHANI D J, FARADONBEH R S, MOMENI E, et al. Performance prediction of tunnel boring machine through developing a gene expression programming equation[J]. Engineering with Computers, 2018, 34:129-141.
- [7] LIU Q SH, XUE Y G, LI G K, et al. Application of KM-SMOTE for rockburst intelligent prediction [J]. Tunnelling and Underground Space Technology, 2023, 138:105180.
- [8] 尹宝才,王文通,王立春. 深度学习研究综述[J]. 北京工业大学学报,2015,41(1):48-59.
YIN B C, WANG W T, WANG L CH. Review of deep learning[J]. Journal of Beijing University of Technology, 2015,41(1):48-59.
- [9] 赵光祖,王亚旭,李尧,等. 基于优化 BP 神经网络的 TBM 性能预测[J]. 河南理工大学学报(自然科学版),2020,39(5):139-145.
ZHAO G Z, WANG Y X, LI Y, et al. Prediction of TBM performance based on optimized BP neural network[J]. Journal of Henan Polytechnic University (Natural Science Edition), 2020,39(5):139-145.
- [10] ARMAGHANI D J, MOHAMAD E T, NARAYAN-ASAMY 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.
- [11] WANG K Y, ZHANG L M, FU X L. Time series prediction of tunnel boring machine (TBM) performance

- during excavation using causal explainable artificial intelligence (CX-AI) [J]. Automation in Construction, 2023, 147:104730.
- [12] 姜晓迪. 基于现场实测数据的双护盾 TBM 掘进性能预测研究[D]. 郑州:郑州大学,2020.
- JIANG X D. Research on double shielded TBM performance prediction based on field measured data [D]. Zhengzhou: Zhengzhou University, 2020.
- [13] 黄喆,王浩森,胡成军,等. 基于双线激光基准的盾尾间隙测量方法研究[J]. 仪器仪表学报,2023,44(7):85-92.
- HUANG ZH, WANG H S, HU CH J, et al. Research on the measurement method of shield tail clearance based on double line laser datum[J]. Chinese Journal of Scientific Instrument, 2023,44(7):85-92.
- [14] LIU Z M, WANG Y X, SACHIN V, et al. KAN: Kolmogorov-Arnold Networks[J]. ArXiv preprint arXiv: 2404.19756, 2024.
- [15] 王振华,彭勇,王忠钊,等. 复杂环境下城际铁路大直径双模盾构选型技术及应用[J]. 科学技术与工程, 2024,24(20):8699-8706.
- WANG ZH H, PENG Y, WANG ZH ZH, et al. Selection technology and application of large-diameter dual-mode shield for intercity railway under complex environment[J]. Science, Technology and Engineering, 2024,24(20):8699-8706.
- [16] 宫思艺,孔宪光,刘丹,等. 融入复杂地层动态识别的盾构施工地表沉降预测方法研究[J]. 仪器仪表学报,2019,40(6):228-236.
- GONG S Y, KONG X G, LIU D, et al. An approach for predicting shield construction ground surface settlement of complex stratum using dynamical strata identification[J]. Chinese Journal of Scientific Instrument, 2019,40(6):228-236.
- [17] 王伯芝,陈文明,黄永亮,等. 基于集成 Dropout-DNN 模型的盾构掘进速度预测方法[J]. 科学技术与工程,2023,23(17):7558-7565.
- WANG B ZH, CHEN W M, HUANG Y L, et al. Prediction method of shield tunneling speed based on integrated Dropout-DNN model[J]. Science, Technology and Engineering, 2023,23(17):7558-7565.
- [18] 汪鑫,廖小平,刘树胜,等. 多传感器融合下多工况刀具磨损状态预测的深度森林方法研究[J]. 仪器仪表学报,2023,44(9):265-274.
- WANG X, LIAO X P, LIU SH SH, et al. Research on the deep forest method for tool wear state prediction under multiple working conditions with multi-sensor fusion[J]. Chinese Journal of Scientific Instrument, 2023,44(9):265-274.
- [19] 刘晓倩,崔焕勇,刘海宁,等. 融合多特征选择和自注意力机制的 LSTM 燃料电池退化预测方法[J]. 电子测量与仪器学报,2024,38(5):219-228.
- LIU X Q, CUI H Y, LIU H N, et al. Integrating multiple feature selection and self-attention mechanism in LSTM for fuel cell degradation prediction[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(5):219-228.
- [20] GENET R, INZIRILLO H. TKAN: Temporal Kolmogorov-Arnold Networks [J]. ArXiv preprint arXiv: 2405.07344, 2024.
- [21] CRISTIAN J, LUIS B, ROBERTO P, et al. Kolmogorov-Arnold Networks (KANs) for time series analysis [J]. ArXiv preprint arXiv:2405.08790, 2024.
- [22] XU K P, CHEN L F, WANG SH R. Kolmogorov-Arnold Networks for time series: Bridging predictive power and interpretability [J]. ArXiv preprint arXiv: 2406.02496v1, 2024.

作者简介



王毓灿,2022年于武汉工商学院获学士学位,现为武汉工程大学硕士研究生,主要研究方向为机器学习的应用和数据挖掘。

E-mail:22303010067@stu.wit.edu.cn

Wang Yucan received his B.Sc. degree from Wuhan Technology and Business University in 2022. Now he is a M.Sc. candidate at Wuhan Institute of Technology. His main research interests include the application of machine learning and data mining.



元海文(通信作者),2018于武汉理工大学获博士学位,现为武汉工程大学副教授,硕士生导师,主要研究方向为视觉导航、无人机、传感器融合和机器学习。

E-mail:hw_yuan@whut.edu.cn

Yuan Haiwen (Corresponding author) received his Ph.D. degree from Wuhan University of Technology in 2018. Now he is an associate professor and M.Sc. advisor at Wuhan Institute of Technology. His main research interests include visual navigation, unmanned aerial vehicles, sensor fusion, and machine learning.



孙齐,2023 年于美国俄勒冈州立大学获博士学位,现为中国葛洲坝集团股份有限公司博士后,主要研究方向为施工智能仿真与辅助决策。

E-mail: qsun2722@ceec.net.cn

Sun Qi received her Ph.D. degree from Oregon State University in the United States in 2023. Now she is currently a postdoctoral researcher at China Gezhouba Group Co., Ltd., Her main research interests include intelligent construction simulation, decision support systems.



杨磊,2005 年于武汉大学获博士学位,现为武汉大学副教授,硕士生导师,主要研究方向为施工导截流、水工水力学和水利工程管理。

E-mail: lylshow@whu.edu.cn

Yang Lei received his Ph.D. degree from Wuhan University in 2005. He is an associate professor and M.Sc. advisor at Wuhan University. His main research interests include construction diversion and river closure, hydraulic engineering hydraulics, and water conservancy project management.



肖长诗,2006 年于美国卡耐基梅隆大学获博士学位,现为武汉理工大学教授,博士生导师,主要研究方向为交通信息工程及控制。

E-mail: cs_xiao@hotmail.com

Xiao Changshi received his Ph.D. degree from Carnegie Mellon University in the United States in 2006. Now he is a professor and Ph.D. advisor at Wuhan University of Technology. His main research interests in transportation information engineering and control.