

文章编号:1671-6833(2026)03-0038-09

基于机器学习的盾构正面滚刀掘进效率预测模型

丁小彬^{1,2}, 吴志远¹, 任续锋¹, 袁霖轩¹

(1. 华南理工大学 土木与交通学院, 广东 广州 510640; 2. 华南理工大学 华南岩土工程研究院, 广东 广州 510640)

摘要:以往工程中对滚刀开仓换刀时机的判断主要依赖传感器数据和人为经验,导致开仓换刀时滚刀已经严重磨损从而影响掘进速度,或者滚刀磨损值未达到预期造成开仓成本损耗。为了能准确判断滚刀开仓换刀时机,总结出掘进效率计算方法对滚刀的使用价值进行表征,并用机器学习方法对其进行预测。研究依托深圳市 CFL 隧道工程,调研以往文献分析盾构机掘进效率的影响因素,优选 15 种特征作为输入参数,将滚刀掘进效率作为输出参数,经过数据处理一共得到 37 849 条数据序列作为总样本集。采用机器学习的方法利用数据集进行训练,选用的算法模型包括 Random Forest、Extra Tress、GBDT 和 XGBOOST。结果表明:机器学习模型能够很好地预测滚刀的掘进效率,其中 XGBOOST 模型的预测效果最好,决定系数为 0.955,平均绝对误差为 7.053,均方根误差为 13.249,最适作为盾构正面滚刀掘进效率的预测模型,研究结果可以为盾构机开仓换刀时机提供参考。

关键词:盾构施工;掘进效率预测;机器学习;开仓换刀

中图分类号:P642

文献标志码:A

doi:10.13705/j.issn.1671-6833.2026.03.012

21 世纪以来,中国城市化加速推进。地下隧道系统不仅有效疏解交通压力,更成为推动城市经济升级与空间重构的重要载体。盾构法因其施工高效、环境影响可控、综合效益突出等优势,已发展为城市隧道主流施工方式。

盾构刀具维保作为隧道工程核心环节,面临高额成本消耗。当前盾构滚刀掘进过程存在可视化监测缺失,换刀决策多依赖传感器数据与人工经验预判,导致刀具过度损耗后被动更换或无效开仓造成资源浪费。本研究构建盾构正面滚刀掘进效率机器学习预测模型,通过实时预测滚刀掘进效率,达成开仓精准化目标,降低工期延误与设备异常风险。

以往研究没有对盾构机滚刀掘进效率的明确定义和计算方法,其中大多用掘进速度(掘进速率)或者贯入度等指标代表盾构机整体的掘进效率。宋克志等^[1]结合重庆越江隧道盾构掘进工程,利用回归分析总结出在泥岩砂岩交互地层条件下影响盾构机掘进效率(每转切深)的因素;Hassanpour 等^[2]研究了不同地质参数对盾构机掘进性能的影响;Liu 等^[3]总结了岩体完整性、隧道覆盖层等参数与贯入

度的相关性特征;Alvarez Grima 等^[4]采用基于人工神经网络(ANN)的神经模糊方法,建立了盾构机转速、直径、推力及地质条件等参数与掘进效率的关系模型;Elbaz 等^[5]通过遗传算法(GA)优化 GMDH 方法,解决其易陷入局部最优解的难点,利用 GMDH-GA 模型预测了 4 个区段盾构机的滚刀寿命。

综上,以往研究注重于特定施工条件下的掘进速率与贯入度指标计算,尚未建立盾构滚刀掘进效率的明确定义及量化方法,且缺乏单刀换刀决策依据。本研究通过将设备损耗纳入评价体系,以滚刀磨损量为关键参数,提出以轨迹长度与对应滚刀磨损量的比值作为盾构正面滚刀掘进效率的计算方法,依托深圳市 CFL 隧道工程记录数据计算获得滚刀掘进效率的预估值,再对其进行预测研究以解决现实中基于单把滚刀的换刀时机确定问题。本文参考以往的研究,使用机器学习的方法,分别建立基于 Random Forest、Extra Tress、GBDT 和 XGBOOST 模型架构的盾构正面滚刀掘进效率预测模型,对比评价指标获得最优模型,研究结果可为现场施工提供参考。

收稿日期:2025-12-25; **修订日期:**2026-02-16

基金项目:国家自然科学基金资助项目(41827807);广东省现代土木工程技术重点实验室项目(2021B1212040003)

作者简介:丁小彬(1984—),男,河南周口人,华南理工大学副教授,博士,主要从事岩土工程、地下工程等相关研究, E-mail:dingxb@scut.edu.cn。

引用本文:丁小彬,吴志远,任续锋,等. 基于机器学习的盾构正面滚刀掘进效率预测模型[J]. 郑州大学学报(工学版), 2026,47(3):38-46. (DING X B, WU Z Y, REN X F, et al. Prediction model of shield frontal hob tunneling efficiency based on machine learning[J] Journal of Zhengzhou University (Engineering Science), 2026,47(3):38-46.)

1 工程背景及输入参数选用

1.1 工程概况

CFL 隧道工程位于广东省深圳市,全长约 5.16 km。该工程采用的盾构机“春风号”是中国首个直径达到 15 m 级别的大直径泥水平衡盾构机,总长 135 m,重量超过 4 800 t,开挖直径达到 15.80 m。

勘察报告显示该项目岩土地层情况复杂,地貌主要以冲洪积平原为主,盾构区段自上而下包含填土、填砂、黏土、卵石、花岗岩、砂岩、板岩、碎裂岩等多种地层类型。

本研究以 CFL 隧道工程的前 1 628 掘进环为依托,观察工程地质剖面图,发现虽然盾构机途经的地层存在着上软下硬的组合形式,但是基本上全是由不同风化程度的岩石构成,且大多数为中风化和微风化岩层。379—400 环盾构区间地质剖面图如图 1 所示。




图 1 CFL 隧道 379—400 环盾构区间地质剖面图
Figure 1 Geological profile of the 379—400 ring shield section of the CFL tunnel

1.2 刀盘刀具概况

CFL 隧道工程采用常压换刀刀盘,主梁上部分刮刀和滚刀可在常压环境下更换。相较于带压换刀刀盘,常压换刀技术在实际应用中换刀次数更为频繁^[6],因此 CFL 隧道工程积累了大量设备损耗情况检查数据。盘形滚刀作为盾构机破碎岩层而设计的刀具,是换刀时最主要的被更换刀具。在实际工程中,识别滚刀的工作状态,及时更换掘进效率低的滚刀,对于确保盾构机的高效运行和工程施工的顺利进行至关重要。

不同类型的滚刀被设计在隧道掘进机刀盘上的不同位置,通常滚刀可按照安装的位置分为中心滚刀、正面滚刀和边缘滚刀三大类,中心滚刀由 12 把双轴双刃滚刀组成,编号为 C1~C12;正面区域的矩形框范围内呈 6 条辐条状的为正面滚刀,由 56 把双轴双刃滚刀组成,编号为 C13~C68;边缘区域的椭圆形分布着边缘滚刀,边缘滚刀有 15 把,编号为 C69~C81-2。

1.3 盾构掘进参数选用

盾构正面滚刀掘进效率的影响因素复杂多变,任何对滚刀掘进状态或损耗程度有影响的因素都可以归纳为掘进效率的影响因素。张明富等^[7]通过监测设备采集盾构推力、扭矩和掘进速度等参数,建立数学模型直观描述滚刀磨损系数与各参数间的非线性关系;丁小彬等^[8]等综合考虑了包括土压力、盾构推力、刀盘扭矩、贯入度等掘进参数,利用神经网络算法构建了滚刀磨损量预测模型;曹利等^[9]以狮子洋隧道盾构工程为背景,分析了硬岩和复合地层条件下刀具磨损量和推力、刀盘转速、推进速度等掘进参数之间的关系,并建立磨损预测模型公式。CFL 隧道工程记录了推力和扭矩的最大值,如果推力过大,可能会导致刀盘承受瞬时极限负荷,加速推进的同时提高刀具的磨损,降低掘进效率。刀盘扭矩的大小与刀盘的旋转阻力和摩擦有关,扭矩在单掘进环内遇到特殊情况瞬间增加,也会影响盾构机的掘进和刀具损耗,于是把推力和扭矩在单掘进环内的最大值也纳入盾构掘进参数采用范围。CFL 隧道工程采用泥水平衡盾构机掘进,泥水仓压力反映了刀盘和地层之间的压力大小,影响盾构机掘进状态。综上,采用盾构推力、推力最大值、刀盘扭矩、扭矩最大值、贯入度、掘进速度、刀盘转速、泥水仓压力作为机器学习模型掘进参数类的输入参数。

1.4 滚刀机械参数选用

本文所研究的盾构正面滚刀掘进效率将滚刀的磨损量作为反映盾构机设备损耗情况的参数,研究对象聚焦于每一把滚刀,因此滚刀的机械结构和位置特征都是影响正面滚刀掘进效率的关键因素。刘高峰等^[10]结合盾构滚刀破岩原理,分析了滚刀几何参数、截面形式及地层信息对滚刀磨损的影响;王瑶等^[11]从刀盘结构角度指出,刀圈强度、刀刃宽度、轴承等机械参数及地质条件变化是滚刀磨损的主要原因。除此之外,滚刀的安装半径对其磨损程度具有显著影响。对于同一刀盘上的不同安装半径的滚刀,刀盘每转一圈其在空间中的行程也不同。安装半径越大,行程越长,滚刀磨损量越大,对滚刀的工作性能影响也就越严重。结合现场的设备条件和以往研究,采用滚刀安装半径、滚刀类型、滚刀尺寸作为机器学习模型滚刀机械参数类的输入参数。

1.5 地层参数选用

在不同地质条件下掘进的盾构机,其掘进的难易程度必然不同,正面滚刀的掘进效率也会产生变化。谭青等^[12]通过离散元法建立滚刀切割模型,分

析不同围压条件下的掘进数据,发现在红层中压柱式镶齿滚刀可提高盾构机的掘进效率。杨延栋等^[13]研究了全断面岩石隧道中,机械和地质因素对盾构机滚刀磨损的影响,指出单轴抗压强度(UCS)和等效石英含量(EQC)共同对滚刀磨损产生影响;1.1节中提到 CFL 盾构工程前 1 628 掘进环途经的地层基本上全是由不同风化程度的岩石构成,且大多数为中风化和微风化岩层。因此结合以往研究和现场地质条件,采用岩石单轴抗压强度、岩石 RQD 值、岩石耐磨率、围岩等级作为机器学习模型地层参数类的输入参数。

综上,本文选用包括盾构掘进参数、滚刀机械参数和地层参数在内的总计 15 种参数作为机器学习模型输入参数,输出参数为滚刀的掘进效率,参数的具体获取和计算过程见 2.1 节、2.2 节。

2 数据获取及预处理

2.1 输入参数获取

盾构掘进参数的数据包括盾构推力、刀盘扭矩、掘进速度、刀盘转速、贯入度、泥水仓压力可以从春风号盾构机数据采集系统获取,其中每个掘进环的推力最大值、推力平均值、扭矩最大值、扭矩平均值由原始数据提取和计算获得。地层参数包括单轴抗压强度、RQD 值、岩石耐磨率和围岩等级可以结合勘察报告和地质剖面图获取。对于盾构刀盘横截面有多种地层分布的情况,依据不同地层的分布情况采用加权平均的方式确定对应掘进环的岩石单轴抗压强度、岩石 RQD 值和岩石耐磨率。围岩等级参数则直接从工程详勘报告中不同掘进区段的综合围岩等级获取。滚刀参数包括安装半径、滚刀类型、滚刀尺寸可以通过查阅盾构机刀盘图纸和换刀记录获取。

2.2 输出参数获取

本文结合以往研究和工程实际,采用滚刀在盾构机掘进过程中的轨迹长度与该段轨迹下滚刀磨损量的比值表征盾构正面滚刀的掘进效率,其物理意义即滚刀每个单位磨损量所能掘进的行程,轨迹长度通过滚刀在平面内转动一圈的周长乘以转动圈数(环间距/单环平均贯入度)得出。比值越大代表滚刀在相同的磨损程度下可以掘进的行程越长,正面滚刀的掘进效率越高。具体公式如公式(1)所示。

$$\phi_{\text{Est}} = \frac{D}{\omega} = \frac{2\pi RL/p}{\delta} \quad (1)$$

式中: ϕ_{Est} 为掘进效率预估值, m/mm ; D 为滚刀轨

迹长度, m ; ω 为滚刀磨损量, mm ; r 为滚刀轨迹半径, m ; L 为环间距, m ; p 为单环平均贯入度, m ; δ 为每环磨损量计算值, mm 。

掘进效率计算值 ϕ_{calc} 可以直接通过计算公式计算得出,但是其与实际工程中滚刀的掘进效率值有所差别。此时要根据实际工程即深圳 CFL 隧道工程的滚刀换刀记录将计算公式中的磨损量 δ 放缩至工人实际测量得出的磨损量大小,再计算得出滚刀掘进效率预估值 ϕ_{Est} 。因为放缩系数是根据后期测量值得出的,掘进效率预估值无法在盾构施工过程中计算得到,必须依托以往工程的数据建立机器学习预测模型,以实现对新工程的滚刀掘进效率进行及时预测。掘进效率预估值的计算公式如式(2)所示。

$$\phi_{\text{Est}} = \frac{D}{\omega} = \frac{2\pi RL/p}{a\delta} \quad (2)$$

式中: a 为磨损量放缩系数。

对于掘进效率预估值计算公式中滚刀的磨损量放缩系数的确定,需要先通过查阅现场换刀记录得到滚刀在对应盾构区间内的磨损量测量值,再将磨损量测量值除以对应盾构区间每环滚刀磨损量计算值之和得到放缩系数值。本文每环磨损量计算方法参考了多种以往研究中的磨损量计算公式,为了确定最适合本研究机器学习预测研究的磨损量计算公式,下文比较了 4 种运用不同磨损量计算方式的滚刀掘进效率计算方法。具体方法如下。

方法一:假设每一掘进环磨损量相同,直接将开仓测的滚刀累积磨损量测量值平均分配到对应盾构区段的每一个掘进环再进行掘进效率计算。

方法二:运用张凤祥等^[14]总结的盾构滚刀磨损量经验公式计算每一环磨损量再进行放缩与掘进效率计算。

方法三:运用杨延栋等^[15]推导建立的正面滚刀正常磨损速率预测模型计算每一环磨损量再进行放缩与掘进效率计算。

方法四:运用德国科学家霍尔姆总结的磨损量计算公式^[16]计算每一环磨损量再进行放缩与掘进效率计算。

分别利用以上 4 种方法计算出掘进效率作为数据集的输出参数,并运用 MATLAB 神经网络工具箱对其进行预测模型训练。机器学习神经网络架构为 Back-Propagation,优化算法为 Levenberg-Marquardt,训练集占样本总数 70%,验证集占 15%,测试集占 15%。模型训练结果如图 2 所示,采用相关系数 R 作为模型评价指标。




图 2 不同方法得到的掘进效率预估值作为输出的拟合结果

Figure 2 The estimated tunneling efficiency obtained by different methods used as the fitting result of the output

经比较,利用方法三计算的掘进效率作为输出参数的数据集训练的机器学习预测模型预测效果最好,测试集相关系数 R 达到 0.818,故采用杨延栋等^[15]推导建立的正面滚刀正常磨损速率预测模型计算每一环磨损量再进行放缩与掘进效率计算。最终研究采用的掘进效率预估值(模型输出参数)计算公式如式(3)所示。

$$\phi_{Est} = \frac{D}{\omega} = \frac{2\pi RL/p}{a \frac{1}{T^{\frac{1}{6}} D_0 \sigma_s p^{\frac{1}{6}}}} = \frac{2\pi T^{\frac{1}{6}} D_0 \sigma_s \hat{\theta}}{0.16 K_s S^{\frac{1}{3}} \sigma_c RL} \cdot \frac{1}{0.16 K_s S^{\frac{1}{3}} \sigma_c p^{\frac{5}{6}} \theta} \quad (3)$$

式中： K_s 为磨粒磨损系数； R 为滚刀安装半径，m； S 为刀间距，m； σ_c 为岩石抗压强度，MPa； T 为刀刃宽度，mm； D_0 为滚刀直径，m； σ_s 为刀刃屈服强度，

MPa； $\hat{\theta}$ 为区间内磨损量计算值之和，mm； θ 为区间内磨损量测量值，mm。

2.3 数据预处理

本研究的数据预处理步骤主要分为数据采集、数据清洗、数据集划分、小波去噪、参数归一化,使用算法语言为 Python,软件为 Anaconda,步骤具体说明如下。

(1)数据采集。研究按照 2.1 节和 2.2 节所述的参数收集和计算方法,对 CFL 隧道工程前 1 628 掘进环 56 把正面滚刀(C13~C68)的数据进行收集整理,一共收得到 51 626 条原始数据样本。每一条数据样本由 15 个输入参数和 1 个输出参数构成。其中,输入参数包括掘进参数、地层参数、滚刀机械参数,输出参数为滚刀掘进效率,样本以 Excel 格式进行储存。

(2)数据清洗。由于盾构机掘进参数数据的记录过程和滚刀磨损量数据的测量过程比较繁琐和复杂,数据可能会受到人为因素或不可控因素影响而产生异常,因此运用高斯分布统计方法对数据进行筛选。高斯分布示意如图 3 所示,其计算公式如式(4)所示。




图 3 高斯分布示意图

Figure 3 Schematic diagram of Gaussian distribution

$$CI = \left(\bar{x} - 1.96 \cdot \frac{s}{\sqrt{n}}, \bar{x} + 1.96 \cdot \frac{s}{\sqrt{n}} \right) \quad (4)$$

式中: $\bar{x}$ 为样本均值; s 为样本标准差; n 为样本大小。

(3)数据集划分。根据实际工程中滚刀换刀记录台账版本的不同,将总样本集分成普通质量样本(样本 1)和高质量样本(样本 2)。样本 1 依据的刀具换刀记录将不同时间的滚刀换刀记录都整合在一个表格里,图片不清晰难以识别,并有记录缺失现象,加大了滚刀状态辨别难度,影响数据集质量,其样本数据量为 13 627 条,数据范围为前 612 掘进环。样本 2 依据的滚刀换刀记录用单独的文件记录每次换刀情况,图片清晰,记录翔实,保证了数据采集的真实性和可靠性,样本数据量为 24 222 条,数据范围为 612 掘进环至 1628 掘进环。

(4)小波去噪。利用 Python 代码中的 pywt 库,对样本数据进行小波分解与重构,小波基设置为 Daubechies 4,分解层数取 5,阈值取 1/2 标准差。

(5)参数归一化。不同参数数据之间存在数量级上的差距,会导致模型误判特征重要性,本文采用最大最小归一化方法,将输入参数限制在 $[0, 1]$ 的范围内,公式如式 6 所示。

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

式中: X 为原始数据; X' 为归一化后的数据; $X_{\min}$ 为数据集中的最小值; $X_{\max}$ 为数据集中的最大值。

3 模型方法

3.1 Random Forest 模型

Random Forest 由 Breiman^[17]于 2001 年提出,通

过集成多棵决策树的预测结果,显著提高了模型的分类或回归性能,具备较强的抗过拟合能力。其主要思想是通过 Bootstrap Aggregating 技术对训练数据集进行有放回的随机采样,生成多个不同的数据子集,并在这些子集上分别构建决策树。每棵树在节点分裂时随机选择一部分特征进行训练,以降低特征间的相关性,提高泛化能力。

3.2 Extra Trees 模型

Extra Trees(extremely randomized trees)与随机森林的主要区别体现在数据采样和节点分裂策略上。随机森林通过有放回采样从原始数据集中生成多个子集进行训练,而 Extra Trees 则直接使用整个数据集,从而减少了数据重采样带来的方差。此外,在节点分裂时,随机森林通过从随机选择的特征中选取最佳分裂点,而 Extra Trees 则在随机选择特征后,进一步通过随机方式确定分裂点。Extra Trees 与 Random Forest 算法的流程图如图 4 所示。




图 4 Extra Trees 模型与 Random Forest 模型

Figure 4 Flow chart of Extra Trees model and Random Forest algorithms model

3.3 GBDT 模型

GBDT(gradient boosting decision tree)核心思想是通过加法模型与前向分步算法逐步构建多个弱学习器,每个弱学习器在模型当前误差的负梯度方向上进行拟合,从而逐步减少训练误差。GBDT 通过在每次迭代中拟合损失函数的负梯度来优化模型,进而不断提升整体预测能力。该算法具有较强的灵活性,能够处理多种类型的损失函数,适用于回归和分类问题。

3.4 XGBoost 模型

XGBoost(extreme gradient boosting)梯度增强算法对 GBDT 模型进行多项关键改进,在优化过程中

引入二阶导数 (Hessian 矩阵) 改进了传统 GBDT 的梯度提升策略,并通过引入正则化机制,以增强模型的泛化能力并有效缓解过拟合问题。同时,XGBoost 实现了决策树构建过程的并行化和近似算法,利用直方图技术加速特征分裂过程,在处理大规模数据集时表现出色。

4 预测结果与分析

4.1 实验环境及流程

本研究基于 Python 算法和 Anaconda 软件建立环境对机器学习模型进行构建和训练,模型实验具体流程如下。

(1)超参数搜索:使用网格搜索 (Grid Search) 方法对机器学习模型进行超参数优化,通过使用 5 折交叉验证,提高模型的泛化能力,并采用均方误差 (MSE) 的负值作为性能评分标准。

(2)模型训练:将样本中的 70% 数据用于模型训练,在模型迭代次数达到参数设定值或目标函数达到要求时终止训练。

(3)模型验证:读取经过训练的机器学习模型,将样本测试集输入参数输入模型,得到滚刀掘进效率预测值,结合真实值绘制模型拟合效果图以及预测结果与实际值对比图,并利用模型评价指标对预测结果进行对比分析。

4.2 模型评价指标

采用决定系数 (R^2)、平均绝对误差 (MAE) 和均方根误差 (RMSE) 作为评价模型预测效果的关键指标,计算公式分别如式 (6)、式 (7)、式 (8) 所示。 R^2

衡量模型对数据变异的解释能力,越接近 1 表示模型拟合效果越好,对异常值较为敏感。

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \tag{6}$$

MAE 为预测值与实际值绝对误差的平均值,能够直观反映模型的平均误差,且对异常值的敏感性较低。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{7}$$

RMSE 通过对预测误差平方后的平均再开平方来度量误差,强调大误差的影响,具有良好的统计特性,同样对异常值敏感。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \tag{8}$$

式中: y_i 为实际值; $\hat{y}_i$ 为预测值; $\bar{y}$ 为实际值平均值; n 为样本数量。

4.3 模型结果分析评价

(1)掘进效率模型拟合效果评价。2.3 节中将总样本集分成普通质量样本 (样本 1) 和高质量样本 (样本 2) 分别进行训练。样本 1 和样本 2 测试集的模型拟合效果如图 5。横坐标表示真实值,纵坐标表示预测值,每个数据点代表一个样本的真实值与模型预测值的对应关系。如果数据点分布密集且均匀地围绕对角线,说明模型具有较好的拟合性能;相反,若数据点偏离对角线较远,则可能指示模型的预测精度较低。从点的聚集程度上看,样本 2 的拟合效果优于样本 1,GBDT 和 XGBoost 模型的拟合性能优于 Random Forest 和 Extra Trees 模型。具体指标结果对比与分析见 4.4 节。




图 5 测试集的模型拟合效果图

Figure 5 Model fitting effect of the test set

(2)掘进效率模型预测结果评价。样本 1 和样本 2 部分测试集预测结果与实际值对比图如图 6。横坐标表示数据编号,纵坐标则表示掘进效率,真实值曲线为黑色,预测值曲线为红色。从预测值曲线与实际值曲线的重合程度来看,当掘进效率值变化较大时,样本 2 的预测精准度优于样本 1。分析原




图 6 测试集预测结果与实际值对比图

Figure 6 Comparison between the predicted results and the actual values of the test set

4.4 模型评价指标对比

模型预测结果评价表如表 1 所示。

表 1 模型预测结果评价表

模型	样本 1			样本 2		
	R^2	MAE	RMSE	R^2	MAE	RMSE
Random Forest	0.836	11.392	22.503	0.941	7.246	15.180
Extra Trees	0.814	13.293	23.966	0.910	10.647	18.732
GBDT	0.872	9.448	19.894	0.952	7.028	13.697
XGBoost	0.875	9.095	19.611	0.955	7.053	13.249

从评价指标结果来看,所有模型样本 2 的决定系数均大于样本 1,平均提升 10.63%,平均绝对误差和均方根误差均小于样本 1,平均绝对误差平均下降 26.03%,均方根误差平均下降 29.21%。分析原因,样本质量的提高可以提升模型的拟合效果和预测精度,增强模型的适配性。相对于样本 2 来说,样本 1 更能代表现实世界的特征与分布,减少数据中的噪声和冗余信息,减少误标记和错误数据的引入,降低错误传播的风险,提高训练效果,增强模型训练过程的稳健性。分析不同模型的表现,Extra Trees 模型的拟合效果和预测精准度最差。样本 1 中决定系数为 0.814,平均绝对误差为 10.647,均方根误差为 23.966;样本 2 中决定系数为 0.910,平均绝对误差为 10.647,均方根误差为 13.293,说明节点分裂时随机选择特征和阈值,并没有提升此研究

因是样本 1 的数据质量不佳导致其掘进效率值在某区段异常增大,超出模型的拟合范围,模型难以对其进行学习预测。此外,GBDT 和 XGBoost 模型的整体曲线重合度优于 Random Forest 和 Extra Trees 模型,具体指标结果对比及分析见 4.4 节。

中模型的训练质量,相反导致模型对部分数据的敏感性增加,影响学习效果。剩下 3 种模型中,XGBoost 模型的结果评价表现最好。样本 1 中决定系数为 0.875,平均绝对误差为 9.095,均方根误差为 19.611;样本 2 中决定系数为 0.955,平均绝对误差为 7.053,均方根误差为 13.249。分析原因,与 Random Forest 模型相比,XGBoost 的增量学习策略允许模型在每次迭代中利用上一次训练的结果,说明本研究数据集参数分布的复杂性对模型学习要求较高,XGBoost 的学习策略在这方面更加灵活和敏感;对于 GBDT 模型,XGBoost 通过引入正则化项有效控制本研究模型复杂度,降低了过拟合风险,并采用了一种基于二阶导数的损失函数优化方法,说明本研究数据具有高度非线性和复杂的特征分布,二阶导数能够提供关于损失函数曲率的信息,使得模型在参数更新时不仅考虑当前的梯度方向,还能根据曲率信息调整步长,从而更有效地绕过局部极值,朝向全局最优解。

综上,从模型拟合效果分析,模型预测曲线分析以及模型评价指标分析,本文发现 XGBoost 模型优于统一一阶导数梯度提升模型和决策树模型,能够更好地预测复合地层中的盾构机滚刀掘进效率。

5 结论

本文采用滚刀在盾构机掘进过程中的轨迹长度与该段轨迹下滚刀磨损量的比值表征盾构正面滚刀的掘进效率,从而实现对滚刀开仓时机的确定。

(1)本文依托 CFL 隧道前 1 628 掘进环的工程数据,对比分析了不同滚刀掘进效率计算方法在本研究中的适用情况,总结出盾构机滚刀掘进效率计算公式,以对比按照不同掘进效率计算方法得到的数据集的拟合效果,发现利用杨延栋等^[15]推导建立的正面滚刀正常磨损速率预测模型计算滚刀掘进效率预估值作为输出的数据集拟合效果最好, R^2 达到 0.818,并推导出作为本文输出参数的掘进效率计算公式。

(2)本文从拟合效果、预测精度、评价指标、模型特点等方面对比分析了基于 Random Forest、Extra Tress、GBDT、XGBoost 模型构建的盾构正面滚刀掘进效率预测模型。其中 XGBoost 模型的结果评价表现最好,样本 1 中决定系数为 0.875,平均绝对误差为 9.095,均方根误差为 19.611;样本 2 中决定系数为 0.955,平均绝对误差为 7.053,均方根误差为 13.249。研究结果能够为实际工程盾构正面滚刀掘进效率预测提供参考。

(3)根据施工现场换刀测量记录质量,将总样本集分成普通质量样本(样本 1)和高质量样本(样本 2),发现样本 2 相对样本 1 决定系数值平均提升 10.63%,平均绝对误差值平均降低 26.03%,均方根误差值平均降低 29.21%。说明数据质量或数据记录准确性会影响模型训练和预测结果。

参考文献:

- [1] 宋克志,孙谋.复杂岩石地层盾构掘进效能影响因素分析[J].岩石力学与工程学报,2007,26(10):2092-2096.
- SONG K Z, SUN M. Analysis of influencing factors of shield tunneling performance in complex rock strata[J]. Chinese Journal of Rock Mechanics and Engineering, 2007, 26(10): 2092-2096.
- [2] HASSANPOUR J, ROSTAMI J, ZHAO J. A new hard rock TBM performance prediction model for project planning[J]. Tunnelling and Underground Space Technology, 2011, 26(5): 595-603.
- [3] LIU Q S, LIU J P, PAN Y C, et al. A case study of TBM performance prediction using a Chinese rock mass classification system-hydropower classification (HC) method[J]. Tunnelling and Underground Space Technology, 2017, 65: 140-154.
- [4] ALVAREZ GRIMA M, BRUINES P A, VERHOEF P N W. Modeling tunnel boring machine performance by neuro-fuzzy methods[J]. Tunnelling and Underground Space Technology, 2000, 15(3): 259-269.
- [5] 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.
- [6] 陈健,刘红军,闵凡路,等.盾构隧道刀具更换技术综述[J].中国公路学报,2018,31(10):36-46.
- CHEN J, LIU H J, MIN F L, et al. Technical review of cutter replacement in shield tunneling[J]. China Journal of Highway and Transport, 2018, 31(10): 36-46.
- [7] 张明富,袁大军,黄清飞,等.砂卵石地层盾构刀具动态磨损分析[J].岩石力学与工程学报,2008,27(2):397-402.
- ZHANG M F, YUAN D J, HUANG Q F, et al. Analysis of dynamic abrasion of shield cutters in sandy cobble stratum[J]. Chinese Journal of Rock Mechanics and Engineering, 2008, 27(2): 397-402.
- [8] 丁小彬,谢宇轩,薛皓文,等.基于神经网络算法的滚刀磨损量预测方法[J].郑州大学学报(工学版),2023,44(1):83-88,95.
- DING X B, XIE Y X, XUE H W, et al. A method for disc cutter wear prediction based on neural network[J]. Journal of Zhengzhou University (Engineering Science), 2023, 44(1): 83-88, 95.
- [9] 曹利,邱龑.基于推进参数的盾构刀具磨损预测模型研究[J].现代隧道技术,2017,54(3):155-161.
- CAO L, QIU Y. A prediction model for cutter wearing based on driving parameters [J]. Modern Tunnelling Technology, 2017, 54(3): 155-161.
- [10] 刘高峰,宋天田.成都地铁盾构刀具磨损分析研究[J].隧道建设,2007,27(6):89-93.
- LIU G F, SONG T T. Analysis and study on wearing of cutting tools of shield machines used in Chengdu metro construction[J]. Tunnel Construction, 2007, 27(6): 89-93.
- [11] 王瑶,杨新安.复合地层大直径盾构刀盘刀具磨损分析[J].交通科技与经济,2009,11(6):80-82.
- WANG Y, YANG X A. The analysis of abrasion cutter head of large diameter TBM in complex ground [J]. Technology & Economy in Areas of Communications, 2009, 11(6): 80-82.
- [12] 谭青,张旭辉,夏毅敏,等.不同围压与节理特征下盘形滚刀破岩数值研究[J].煤炭学报,2014,39(7):1220-1228.
- TAN Q, ZHANG X H, XIA Y M, et al. Numerical study

on breaking rock by disc cutter at different confining pressure and joint characteristics case[J]. Journal of China Coal Society, 2014, 39(7): 1220-1228.

[13] 杨延栋, 陈馈, 郭璐, 等. 全断面岩石隧道掘进机滚刀磨损影响因素分析[J]. 隧道建设, 2016, 36(11): 1394-1400.

YANG Y D, CHEN K, GUO L, et al. Analysis of influencing factors of wear of disc cutter of full-face hard rock tunnel boring machine[J]. Tunnel Construction, 2016, 36(11): 1394-1400.

[14] 张凤祥, 杨宏燕, 顾德昆, 等. 对我国发展盾构技术的一点看法[J]. 岩石力学与工程学报, 1999, 18(5): 611-614.

ZHANG F X, YANG H Y, GU D K, et al. Review on the development of shield technique in China[J]. Chinese Journal of Rock Mechanics and Engineering, 1999, 18(5): 611-614.

[15] 杨延栋, 陈馈, 李凤远, 等. 盘形滚刀磨损预测模型[J]. 煤炭学报, 2015, 40(6): 1290-1296.

YANG Y D, CHEN K, LI F Y, et al. Wear prediction model of disc cutter[J]. Journal of China Coal Society, 2015, 40(6): 1290-1296.

[16] 伍慧龙. 穗莞深城际铁路大直径盾构滚刀磨损的人工智能预测分析[D]. 上海: 上海交通大学, 2019.

WU H L. Artificial intelligence prediction and analysis of wear of large diameter shield hob on Guangzhou-Guanshen intercity railway[D]. Shanghai: Shanghai Jiao Tong University, 2019.

[17] BREIMAN L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.

Prediction Model of Shield Frontal Hob Tunneling Efficiency Based on Machine Learning

DING Xiaobin^{1,2}, WU Zhiyuan¹, REN Xufeng¹, YUAN Linxuan¹

(1. School of Civil Engineering and Transportation, South China University of Technology, Guangzhou 510640, China; 2. South China Institute of Geotechnical Engineering, South China University of Technology, Guangzhou 510640, China)

Abstract: In the past, the judgment of the timing of the opening and changing of the disc cutter mainly relied on sensor data and human experience, which led to the serious wear of the disc cutter, or affected the tunneling speed. In order to accurately judge the timing of disc cutter opening and tool replacement, in this study the excavation efficiency calculation method was summarized to characterize the use value of disc cutter, and machine learning method was used to predict it. Based on the Shenzhen CFL tunnel project, the influencing factors of the shield tunneling efficiency were analyzed in the previous literature, 15 characteristics were selected as the input parameters, and the hob tunneling efficiency was used as the output parameters, and a total of 37 849 data series were obtained as the total sample set after data processing. The machine learning method was used to train on datasets, and the algorithmic models used include Random Forest, Extra Tress, GBDT and XGBOOST. The results showed that the machine learning model could predict the tunneling efficiency of the hob cutter well, and the XGBOOST model had the best prediction effect, with a determination coefficient of 0.955, an average absolute error of 7.053, and a root mean square error of 13.249.

Keywords: shield construction; tunnelling efficiency prediction; machine learning; tool change of the shield machine