doi: 10. 20238/j. issn. 1671-4172. 2026. 06. 008
丁巍, 魏师琳, 贾穗子, 等. 机器学习在TBM掘进参数与围岩等级预测中的应用——以引绰济辽工程为例[J]. 有色金属(矿山部分), 2026, 78(6): 75-87.
Ding Wei, Wei Shilin, Jia Suizi, et al. Application of machine learning in predicting TBM tunneling parameters and surrounding rock classification: a case study of the Yinchuojiliao water diversion project[J]. Nonferrous Metals (Mining Section), 2026, 78(6): 75-87.

机器学习在TBM掘进参数与围岩等级预测中的应用——以引绰济辽工程为例

丁　巍[1,2], 魏师琳[3], 贾穗子[3], 李一丹[3], 楚一帆[4,5], 张效忠[1,2]
(1. 贵州工程应用技术学院 土木建筑工程学院, 贵州 毕节 551700;
2. 毕节市山区桥梁智慧监测重点实验室, 贵州 毕节 551700;
3. 中国地质大学(北京)工程技术学院, 北京 100083;
4. 矿冶科技集团有限公司, 北京 100160;
5. 国家金属矿绿色开采国际联合研究中心, 北京 102628)

摘　要: 全断面隧道掘进机(TBM)施工过程中产生大量可反映地质状况的实时数据。为充分利用该数据并建立精确的掘进参数与围岩等级预测模型, 本文提出了一种基于滑动均值滤波与一阶差分符号变化的掘进段自动分割方法, 将掘进循环段划分为空推段、上升段与稳定段; 并采用BP、SVM、GPR、RF和RBF五种机器学习方法进行对比建模。结果表明: GPR在掘进参数回归预测中表现最优, 基于上升段及进入稳定段60 s内的数据, 稳定段平均推力与单盘扭矩的测试集决定系数R^2分别达到0. 897与0. 867; RF在围岩等级分类中精度最高(ACC=0. 985, $F1$均值=0. 985), GPR次之(ACC=0. 930, $F1$均值=0. 930)。综合考虑预测精度与模型统一性, 本文选取GPR作为统一预测模型, 该模型在提供高精度掘进参数预测值的同时可输出预测置信区间与围岩等级预测概率, 为TBM操作人员提供地质-机械联合决策支持, 有效避免了多模型并行部署带来的工作量繁重与决策冲突等问题。

关键词: TBM掘进段; 机器学习; GPR; 围岩等级; 掘进参数预测
中图分类号: TD421. 5; TD803　　**文献标志码:** A　　**文章编号:** 1671-4172(2026)06-0075-13

Application of machine learning in predicting TBM tunneling parameters and surrounding rock classification: a case study of the Yinchuojiliao water diversion project

Ding Wei[1,2], Wei Shilin[3], Jia Suizi[3], Li Yidan[3], Chu Yifan[4,5], Zhang Xiaozhong[1,2]
(1. School of Civil Engineering and Architecture, Guizhou University of Engineering Science, Bijie 551700, China;
2. Bijie Key Laboratory of Intelligent Monitoring for Mountain Bridges, Bijie 551700, China;
3. School of Engineering and Technology, China University of Geosciences (Beijing), Beijing 100083, China;
4. BGRIMM Technology Group, Beijing 100160, China;
5. National Center for International Joint Research on Green Mining of Metal Mines, Beijing 102628, China)

Abstract: A large amount of real-time data reflecting geological conditions is generated during the operation of Tunnel Boring Machine (TBM). To fully utilize this data and establish accurate prediction models for TBM tunneling parameters and

收稿日期: 2026-07-21
基金项目: 贵州省科技计划项目(黔科合基础MS〔2025〕244); 贵州省科技厅计划项目(青年引导项目)(黔科合基础QN〔2026〕014-6)
作者简介: 丁　巍, 博士, 主要从事TBM隧道掘进、机器学习、防灾减灾等方面的研究工作。
通信作者: 魏师琳, 博士, 主要从事TBM隧道掘进、机器学习、防灾减灾等方面的研究工作; 贾穗子, 博士, 主要从事TBM隧道掘进, 机器学习, 防灾减灾等方面的研究工作。

surrounding rock classification, this paper proposes an automatic segmentation method for tunneling sections based on sliding mean filtering and first-order difference sign changes, dividing the tunneling cycle into air pushing section, rising section and stable section. Five machine learning methods (BP, SVM, GPR, RF and RBF) are compared for modeling. The results show that GPR performs best in the regression prediction of tunneling parameters, with the test set coefficients of determination (R^2) for average thrust and single-disk torque reaching 0.897 and 0.867, respectively, based on data from the rising section and the first 60 s of the stable section. RF achieves the highest accuracy in surrounding rock classification (ACC=0.985, $F1$ mean=0.985), followed by GPR (ACC=0.930, $F1$ mean=0.930). Considering both prediction accuracy and model uniformity, GPR is selected as the unified prediction model, which can provide not only high-precision tunneling parameter predictions but also prediction confidence intervals and surrounding rock classification probabilities, offering geomechanical joint decision support for TBM operators and effectively avoiding the heavy workload and decision conflicts caused by multi-model parallel deployment.

Key words: TBM excavation section; machine learning; GPR; surrounding rock level; tunneling parameter prediction

由于我国具备良好的工业生产技术以及基础建设的快速推进，隧道掘进机(Tunnel Boring Machine，TBM)已经成为铁路工程以及采矿工程的优先选项[1]。这是由于其具有施工速度快、人身安全高、劳动强度低、对环境干扰小等诸多优点[2]。因此，越来越多的隧道工程采用TBM进行施工。在施工过程中，TBM通常会从不同的传感器和其他设备收集各种性能信息。如何有效利用该信息，提高钻井效率并预防可能发生的地质灾害成为了近些年的研究热点[3]。

目前，TBM技术在金属矿山深部巷道掘进中的应用也取得了显著进展。刘泉声等[4]系统总结了深部金属矿山巷道TBM掘进技术的应用现状，指出未来10年我国将有30%以上金属矿山开采深度达到或超过千米，深部高地应力、高地温等复杂地质环境对TBM掘进技术提出了更高要求。黄登侠等[5]依托天山胜利隧道工程，采用微震监测技术对TBM掘进过程中的岩爆灾害进行了有效预警，验证了实时监测在TBM施工安全中的可行性。

近年来，大数据和机器学习方法的应用引起了人们的极大兴趣。大量研究成果表明，机器学习或深度学习的方法能够有效地将TBM掘进过程的数据及时传输到云平台系统[6]，并对掘进数据进行分析，从而协助TBM实际操作人员做出正确的决策。周小雄等[7]采用BLSTM-AM(双向长短期记忆网络-注意力机制)模型对TBM的稳定段掘进参数进行预测，取得了良好的预测结构。黄登侠等[5]使用混合神经隐马尔可夫模型获得准确的概率地质描述。Zhang等[8]采用聚类分析方法，通过对实时掘进参数进行聚类，来预测实时地质条件。Hu等[9]利用随机森林方法预测了隧道掘进机穿透坚硬岩石的速度。目前，在对TBM传到的数据进行分析时，如何有效地划分一个掘进段的各个阶段，并且如何选取合适的特征对TBM掘进参数和围岩等级进行预测，依然是进行机器学习前的重要的步骤。

因此，为解决该问题，本文在对数据进行预处理的过程中，首先提取了一个完整的工作段，并对其异常值进行了处理，然后提出能够识别一个掘进循环中三个阶段的函数。本文基于该数据利用高斯过程回归(Gaussian Process Regression，GPR)算法对TBM掘进过程进行了参数预测以及围岩等级预测。本文依托内蒙古引绰济辽工程，做出如下探索：1)提出了TBM掘进循环划分的新办法；2)比较了5种机器学习方法，选取一种最适合用于TBM参数和围岩等级预测的算法；3)基于上升段和进入稳定段60 s内数据实时预测了整个稳定段的掘进参数。

1 工程地质概况

本文研究数据取自引绰济辽调水工程。该工程被列入国务院“十三五”期间172项重大节水供水工程名录，地理坐标处于内蒙古自治区东北部，其核心任务为将绰尔河水系的水量输送至西辽河，进而为沿线各城市与工业园区提供水源保障。该工程设计年最大调水能力为4.88亿m^3，输水主洞长度为58.505 km，洞线比降为1/3000。围岩类别从Ⅱ类到Ⅴ类均有分布，其中以Ⅲ类和Ⅳ类为主。TBM掘进参数的获取频率为1 Hz，TBM主要技术参数如表1所示。

本文数据为中国水利水电第六工程局有限公司施工的二标段，该标段对应的桩号范围为K10+840～K66+137，工程布置如图1所示，采用编号为CREG 667和CREG 668的两台敞开式TBM进行施工，直径为5.2 m。

表1　TBM主要特征参数

Table 1　TBM main characteristic parameters

特征参数	数值
刀盘直径D/mm	5 200
额定刀盘推力F_{max}/kN	11 340
额定刀盘扭矩T_{max}/(kN·m)	3 340
最大推进速度v_{max}/(mm·min^{-1})	120
最大刀盘转速n_{max}/(r·min^{-1})	11.45
数据采集频率/Hz	1
滚刀数量N/把	34
最大推进位移X/mm	1 800
平均滚刀间距x/mm	70

根据文献[10]及引绰济辽工程地质勘察报告，本文围岩等级按工程岩体分级标准划分为Ⅱ～Ⅴ级，各级别含义如下：1) Ⅱ级，岩体较完整，结构面不发育，岩质坚硬，岩体基本质量指标BQ＞550；2) Ⅲ级，岩体完整性一般，结构面较发育，岩体基本质量指标BQ为451～550；3) Ⅳ级，岩体较破碎，结构面发育，岩体基本质量指标BQ为351～450；4) Ⅴ级，岩体破碎，结构面极发育或岩质软岩，岩体基本质量指标BQ≤350。本文数据集中Ⅱ～Ⅴ级围岩样本数量分别为50、50、50、50，共200个样本，覆盖引绰济辽工程二标段K10＋840～K66＋137桩号范围。

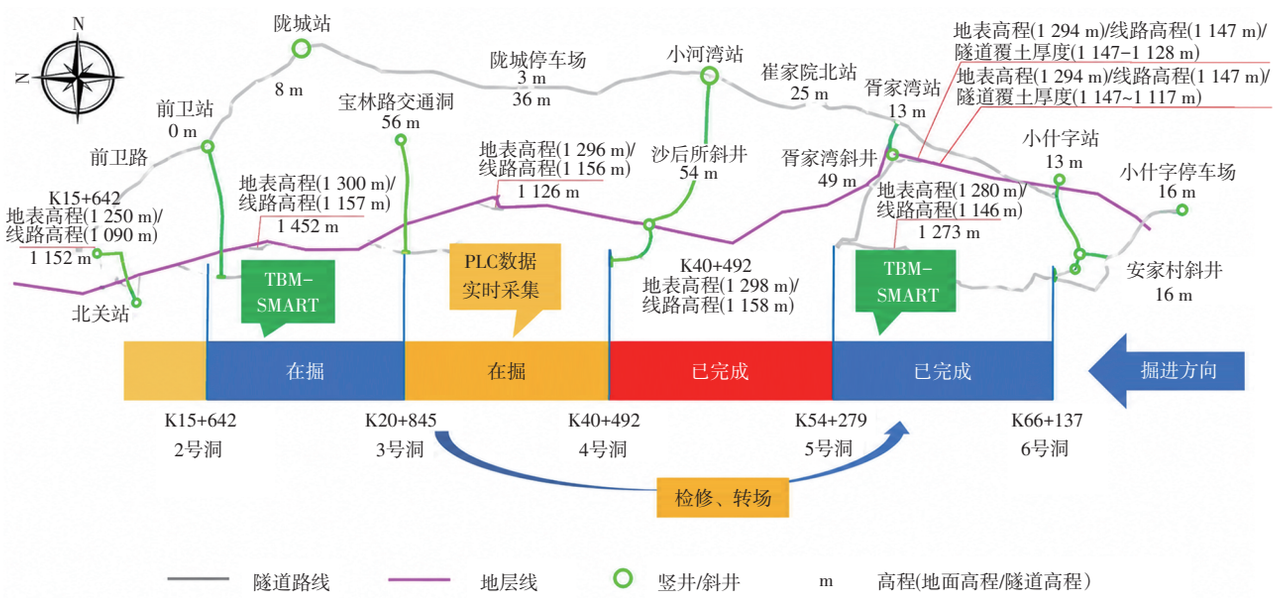


图1　工程布置

Fig. 1　Engineering layout

2　数据预处理和特征提取

2.1　掘进循环提取

本文以贯入度指标为例，TBM在施工过程中可分为停机区和工作区如图2所示。本文通过TBM施工过程的贯入度对TBM是否处于掘进状态进行判定。同时还需满足推力和扭矩都大于0，则认为该时刻TBM处于掘进状态，反之则判定其为非掘进状态。本文选取工作区的基础数据作为数据集，其中每个循环段持续时间为3 000 s左右。

2.2　异常值判定和处理

TBM掘进过程中，由于操作失误的原因或设备问题，数据中会存在异常值，从而影响预测模型的准确性，图3中存在贯入度时序曲线的异常值。即对于

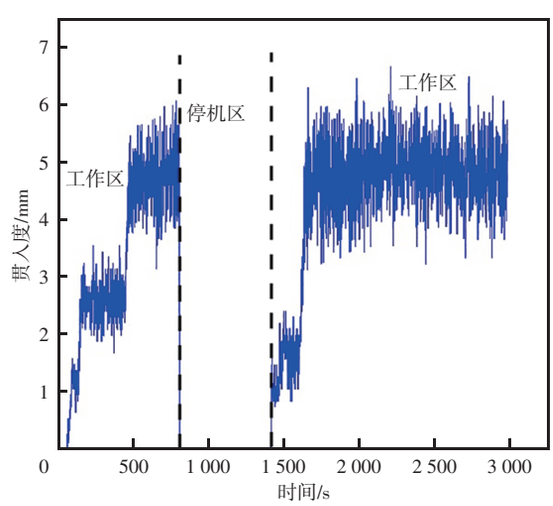


图2　TBM施工过程划分

Fig. 2　TBM construction process division

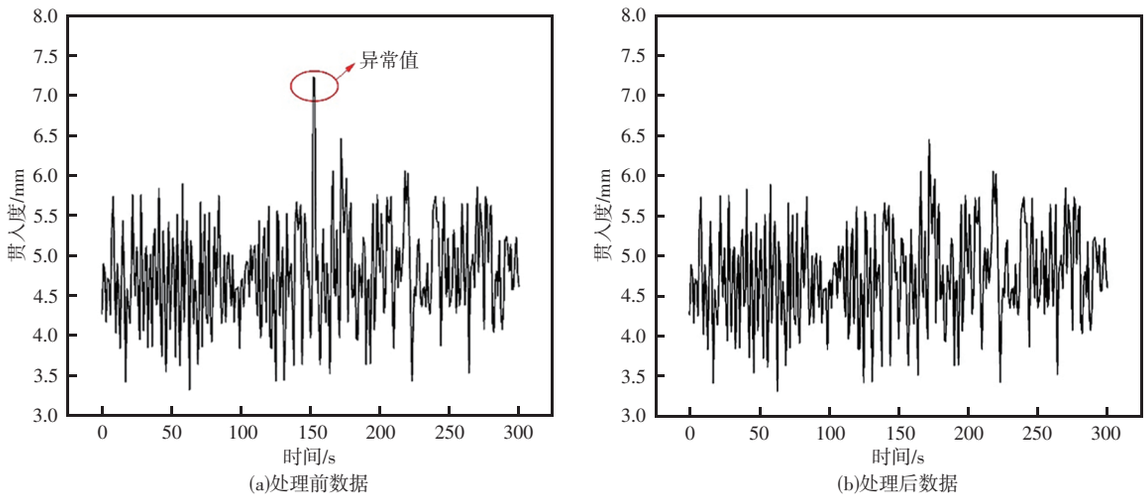


图3 异常值处理结果

Fig. 3 Outlier processing results

掘进过程中的极大异常点，采用三倍标准差(3σ)准则进行判定[11]。即通过计算整个掘进循环的贯入度和掘进速度的均值μ和标准差σ，当掘进速度或贯入度大于$\mu+3\sigma$时，则判定为异常点。对识别出的异常点，取其前后5个邻近数据点的平均值进行替换。对识别出来的异常点，取5个临近数据点的平均值替代。

2.3 掘进段分割

掘进段的划分是构建高质量数据集的关键。如图4所示，为某一掘进段除去停机数据后的贯入度随时间变化的曲线。一个掘进循环大致可以划分为3个阶段：空推段、上升段和稳定段[12]。

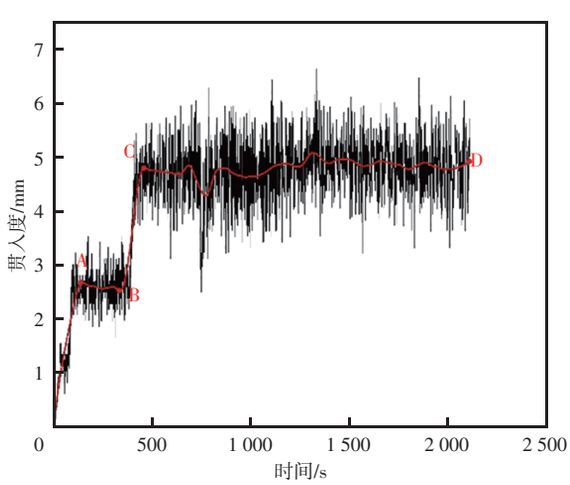


图4 掘进段划分

Fig. 4 Dig near section division

为了准确识别掘进段的三个阶段，本文采用窗口大小为30(对应30 s)的滑动均值滤波对贯入度曲线进行平滑处理，以消除高频噪声。定义滤波后贯入度的一阶差分$T_i=\overline{p}_{i+1}-\overline{p}_i$，其中$\overline{p}_i$为滤波后的贯入度。基于$T_i$的符号变化，将掘进段划分为四个子段(图4)：OA(空推段)、AB(初始波动段)、BC(上升段)和CD(稳定段)，其中OA段为刀盘空转接近岩面的空推阶段，存在微小贯入度是由于刀盘与岩面初始接触及设备惯性所致；AB段为刀盘初始贯入时的波动调整段；BC段为贯入度持续上升的岩-机相互作用主要阶段；CD段为贯入度趋于稳定的平稳掘进阶段，上升段(BC段)作为岩-机相互作用的重要阶段，是观察TBM掘进状态，选取适当掘进参数的关键时机[8]，其分段函数如下：

$$T_i=\overline{p}_{i+1}-\overline{p}_i=\begin{cases}>0 & 0<i<t_{\mathrm{A}}\\ <0 & t_{\mathrm{A}}<i<t_{\mathrm{B}}\\ >0 & t_{\mathrm{B}}<i<t_{\mathrm{C}}\\ =0 & i>t_{\mathrm{C}}\end{cases}\tag{1}$$

式中，T_i为第i时刻的贯入度变化趋势；t_{A}、t_{B}、t_{C}为各阶段分界时刻，由T_i符号变化点自动识别确定。具体判定规则为：OA段满足$T_i>0$且持续时长小于5 s；AB段满足$T_i<0$；BC段满足$T_i>0$且持续时长大于10 s；CD段满足$T_i<0.01$ mm/r且持续时长大于20 s。其中，5、10 s为最小持续时间阈值，0.01 mm/r为稳定段贯入度变化率阈值，均依据TBM刀盘响应周期(约3～5 s)及现场操作经验设定。

本文根据TBM实际操作人员的经验，选取上升段数据对稳定段TBM掘进参数进行预估。本文提出的TBM循环段划分方法更符合TBM操作人员的实际操作情况，数据规律性也更强，更适用于机器学习算法学习。

2.4　特征选择与数据集生成

TBM设备数据包含198个参数指标，记录了各子系统的运行数据。其中围岩等级样本来源于不同掘进循环段及不同桩号区段，各样本在时间和空间上相互独立。在这些数据中，刀盘驱动系统和推进系统的运行参数是反映岩-机相互作用最主要的参数，这与TBM破岩机理及岩-机相互作用理论一致。Gertsch等[13]通过ColoradoRedGranite的盘形滚刀切割试验表明，推力、扭矩与贯入度是表征TBM破岩效率的核心参数；Singhal[14]进一步指出，岩石性质对盘形滚刀贯入速率具有决定性影响。因此，本文选取与岩-机相互作用关系最密切的5个核心参数作为模型输入：刀盘转速n、刀盘扭矩T、总推力F、推进速度和贯入度p。其中，贯入度p由推进速度与刀盘转速之比计算得到。根据给定的4个控制参数分别建立总推力和刀盘扭矩的预测模型与岩体分类的预测模型，其参数如表2所示。

表2　模型的控制参数

Table 2　Control parameters of the model

输入		回归问题输出
上升段数据	预测参数	预测类别
刀盘转速 总推力实际转速	单盘平均推力	Ⅱ Ⅲ
刀盘扭矩	单盘刀盘扭矩	Ⅳ
贯入度		Ⅴ

2.5　模型训练与评估

对于性能参数，本文采用以下四个指标进行各模型性能评估：1）决定系数(R^2)，2）平均相对误差(MRE)，3）分类准确率ACC，4）$F1$均值所涉及到的数学表达式如下：

$$R^2=1-\frac{\sum_{j=1}^{m}(\tilde{y}_j-y_j)^2}{\sum_{j=1}^{m}(\tilde{y}_j-\overline{y})^2} \tag{2}$$

$$MRE=\frac{\sum_{j=1}^{m}|(\tilde{y}_j-y_j)|}{y_j}\Big/m \tag{3}$$

$$ACC=\frac{TP+TN}{TP+TN+FP+FN} \tag{4}$$

$$Precision=\frac{TP}{TP+FP} \tag{5}$$

$$Recall=\frac{TP}{TP+FN} \tag{6}$$

$$F1=2\times\frac{Precision\times Recall}{Precision+Recall} \tag{7}$$

式中，$\tilde{y}_j$和y_j分别表示预测值和实验值；m表示数据总数；$\overline{y}_j$为试验值的平均值。R^2值介于0～1，而模型越接近1时，预测能力越好，在接近0时，预测性能差。ACC反映模型整体的预测正确率，$F1$均值则综合考量模型对各类围岩(Ⅱ-Ⅴ级)识别能力的均衡性，避免单一类别预测偏差被整体准确率掩盖。这些性能指标是整体预测准确性的良好度量指标。

2.6　数据划分与预处理

为保证各模型对比的公平性，本文对五种模型采用完全一致的数据划分策略：采用随机分层抽样(Stratified Random Sampling)，按80%训练集、20%测试集划分，其中围岩等级分类任务按各等级(Ⅱ～Ⅴ级)样本比例进行分层，确保训练集与测试集中各类别比例一致。划分前对输入特征进行Z-score标准化处理：

$$x'=\frac{x-\mu}{\sigma} \tag{8}$$

式中，μ和σ分别为训练集各特征的均值与标准差，测试集采用训练集的统计量进行标准化，以避免数据泄露。

3　机器学习方法

为了得到最适用于TBM掘进参数与围岩等级预测的机器学习模型，本文共建立了5种机器学习模型，对其进行比较，得到最优的机器学习模型。图5以流程图的形式展示了机器学习模型的实施过程，从中可以很清晰地看到数据从输入到输出的全过程。

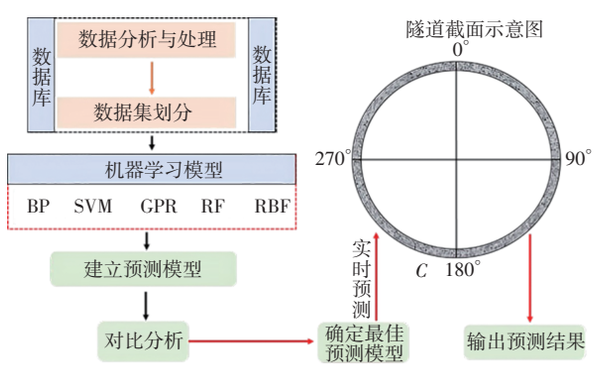


图5　机器学习训练过程图

Fig. 5　Machine learning training process diagram

本文采用5折交叉验证(5-fold Cross-Validation)进行超参数调优[15]。对于BP、SVM、RF和RBF模型，采用网格搜索(Grid Search)遍历超参数组合，以平均相对误差(MRE)为回归任务优化目标，以分类准确率(ACC)为分类任务优化目标；对于GPR模型，

其核函数超参数(长度尺度、噪声方差)通过最大化对数边际似然(Log Marginal Likelihood)自动优化,无需人工网格搜索。各模型均在相同的交叉验证划分下进行调参。

3.1 BP神经网络

反向传播(BP)神经网络模型作为一种工程当中的应用广泛的前馈型神经网络,非线性映射能力强,具有优质泛化的能力[16]。该模型核心运行特征体现为信号前向传递与误差反向回传。在该计算流程内,首先导入完成训练的神经网络模型,对输入数据集执行归一化预处理,随后调用BP神经网络算法运算,输出一组概率向量。BP 神经网络具备对海量输入-输出映射关系开展学习与存储的能力,无需预先明确刻画映射关系对应的函数表达式。该网络以最速下降法作为学习准则,依托多轮误差反向传播迭代更新网络权值参数,以此实现拟合系数等模型评价指标的最优收敛,BP 神经网络的模型结构如图6所示。

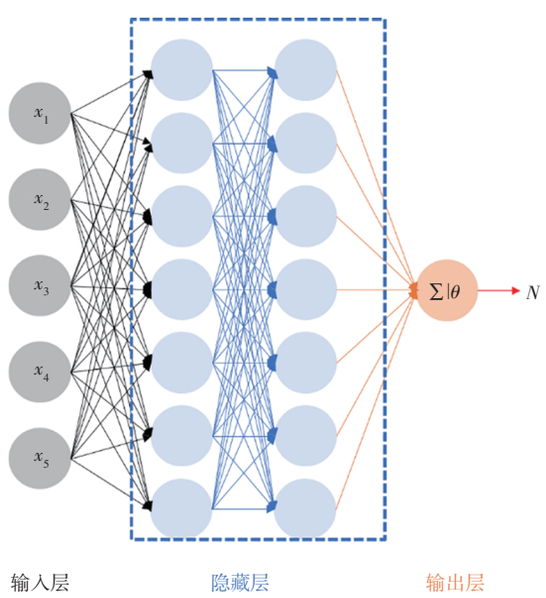


图6 BP神经网络模型图

Fig. 6 BP neural network model diagram

从图6可知,BP神经网络中包括输入层、隐含层和输出层。影响BP神经网络性能的参数主要包括:隐含层当中的节点个数、激活函数f等[17]。相关研究表明,隐含层神经元数量会对模型拟合能力产生显著影响。在其他参数保持不变的前提下,神经元数目降低会造成模型拟合性能减弱,增加神经元数量则能够优化拟合效果。但训练样本不足时,神经元数量过多极易诱发过拟合问题,因此,合理确定隐含层神经元规模是模型构建的关键环节。从激活函数角度分析,模型的识别精度与收敛效率均受激活函数的直接制约。针对高次曲线拟合场景,Sigmoid 函数相比线性函数可实现更高的拟合精度,但同时会造成运算开销明显增大。

对于第i个神经元,X_i为神经元的输入,w_i为连接权值调节各个输入量的占重比。将信号结合输入到神经元有多种方式,选取最便捷的线性加权求和可得Net神经元净输入,如下所示:

$$Net=\sum_{j=1}^{n} w_j x_i \tag{9}$$

$$y=f(Net-\theta) \tag{10}$$

3.2 支持向量机SVM

支持向量机是根据统计学习理论提出的小样本学习方法[18]。作为20世纪90年代逐步发展成型的智能学习方法,该机器学习算法以统计学习理论为核心支撑搭建而成。算法的核心优化亮点在于通过求解结构风险的最小值,显著增强模型的通用适配能力,以此将模型经验风险与置信范围控制在理想的最低水平。区别于常规传统机器学习方法,该算法对样本数据的需求量更低,在整体训练样本数量不足的情况下,依然可以保障数据分析质量,获取理想的模型优化与拟合效果。

支持向量机在高维当中建立超平面或超平面几何,然后把本来的由有限维空间映射到高维空间里,因为在高维空间处理和解决问题会比较简单[19]。该算法一方面能够实现经验误差的有效降低,另一方面还可完成几何间隔的最大化处理。从原理层面加以解释,就是让距离分类平面最近的样本点同分类边界保持更大的间隔距离,借助该机制实现泛化误差的有效缩减。对于支持向量机而言,采用不同的核函数,算法结构也会产生差异,常用的核函数分别为线性核函数、多项式核函数、Sigmoid核函数,具体表达式如下:

$$K(x,y)=x^T y+C \tag{11}$$

$$K(x,y)=(\alpha x^T y+C)^d \tag{12}$$

$$K(x,y)=\tan h(\alpha x^T y+C) \tag{13}$$

式中,α表示调节参数;d表示最高次项数;C表示可选常数,一般取$1/n$,n为数据维度。

3.3 高斯回归模型

在高斯过程中,连续的输入空间的任何点与正态分布的随机变量相关[20],而且任何随机变量的有限

集合满足多重正态分布，例如，变量间的任意线性组合是正态分布，高斯过程分布是所有随机变量在连续域中的联合分布。

惰性学习方法(Lazy Learning)建立的模型可移植性强[21]，适用于不同的问题域，但要求较大空间来实时保存训练数据集，因为缺少对数据集合的抽象而使得预测过程计算量大。懒惰分类器适用于数据集的特征较少的情况，因此，从机器学习算法的角度而言，高斯过程属于惰性学习范式，该方法依靠衡量不同样本之间的相似程度，结合已有的训练数据集，对未知输入样本的观测输出开展预测工作，得到的预测输出一般服从边缘分布(Marginal Distribution)。

对于给定数据集$D_N=[X_n, y_n]^N_{n-1}$，其中，$X_n \ni \mathrm{R}$，令$\boldsymbol{X}=[x_1, x_2, \cdots, x_n]$作为观测输入的数据矩阵，取自输入空间。$\boldsymbol{Y}=[y_1, y_2, \cdots, y_n]$作为观测输出向量，即输出空间。考虑非线性映射$\emptyset_{(x)}: x \ni R$，这个映射可能是未知或无限维的，因此需要利用核函数来构建特征空间，核函数如下所示：

$$K(x_i, y_j)=(\emptyset_{(x_i)}, \emptyset_{(y_j)}) \tag{14}$$

在高斯回归模型中，每个样本y_n可以表示为：

$$y=f(x)+\varepsilon \tag{15}$$

式中，f是高斯过程$f \sim N(0, K)$，$\boldsymbol{K}=K(x_i, x_j)$，是核函数定义的特定协方差矩阵，$\varepsilon \sim N(0, \sigma^2)$。定义$\boldsymbol{K}_{Xx}=[K(x_1, x), \cdots, K(x_N, x)]$，对于任意的测试数据估计预测分布，基于高斯概率假设，可以得到条件分布：

$$p(y|x, X, Y) \sim N(f(x), g(x)) \tag{16}$$

式中，

$$f(x)=K_{Xx}^{\mathrm{T}}(\boldsymbol{K}+\sigma^2\boldsymbol{I})^{-1}\boldsymbol{Y} \tag{17}$$

$$g(x)=\sigma^2+\boldsymbol{K}(x, x)-K_{Xx}^{\mathrm{T}}(\boldsymbol{K}+\sigma^2\boldsymbol{I})^{-1}\boldsymbol{K}_{Xx} \tag{18}$$

式中，$\boldsymbol{I}$为响应规模的单位矩阵。

3.4　随机森林

随机森林是机器学习中十分常用的算法[22]。随机森林算法是对原始数据集执行有放回的随机抽样操作，抽取和原数据集样本规模保持一致的数据，以此构建独立的数据子集合；同时对特征空间开展随机筛选，挑选部分特征作为各棵决策树的输入变量。基于上述生成的各个数据子集分别训练对应的决策树模型，大量经过训练的决策树组合在一起，便构成完整的随机森林模型。

受上述双重随机机制的影响，所构建的各棵树模型之间存在明显差异性。即便面对相同的预测任务，不同树模型输出的结果也会存在一定程度的偏差。随机森林模型的核心思想便是借助众多基础树模型的集成作用，获取稳定性与可靠性更高的输出，如图7所示，模型最终的预测输出由全部子树模型共同综合确定。

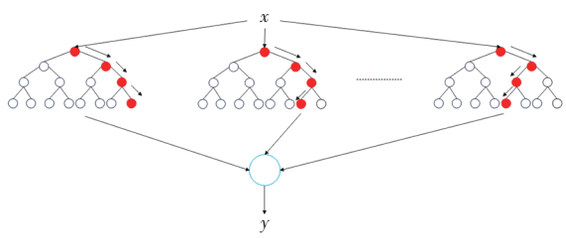


图7　RF模型图

Fig. 7　RF model diagram

对于随机节点t，可以计算该节点中所有观测值的残差，如下所示：

$$e_{ti}=y_{ti}-\bar{y}_T \tag{19}$$

$$\bar{y}_T=\frac{\Sigma_i w_i y_t}{\Sigma_i w_i} \tag{20}$$

式中，y_{ti}是节点t中的试验数据；$\bar{y}_T$是节点t的响应的加权平均值；w_i是随机森林节点t的加权系数。

3.5　径向基神经网络

径向基函数神经网络是一种性能良好的前向网络，具有最佳逼近、训练简洁、学习收敛速度快以及克服局部最小值问题的性能，目前已经证明径向基网络能够以任意精度逼近任意连续的函数[23]。因此，它已经被广泛应用于模式识别、非线性控制和图像处理等领域。

RBF径向基神经网络的核心建模原理，是依托径向基函数作为隐含层的激活基元，完成高维特征映射空间的构建。网络借助隐含层的非线性映射机制对原始输入向量实施空间变换，将低维流形下线性不可分的样本分布，投影到高维特征空间，突破低维空间的数据分布约束，进而把原始空间中的非线性分类难题转化为高维特征域内线性可分的求解问题。径向函数常用的核函数如下：

$$k(x, x_i)=\exp\left(-\frac{\|x-x_i\|^2}{2\alpha^2}\right) \tag{21}$$

式中，x_i表示核函数中心；α表示宽度参数，用它来确定每一个径向神经元对去输入矢量。

RBF要学习的参数有三个：基函数的中心x_i和

方差α以及隐含层与输出层之间的权值w。

1)确定基函数的中心x_i

从训练样本中随机选取I个不同的样本作为$x_i(n)$ $(i=1,2,\cdots,I_K)$,设置迭代步骤n。随机输入训练样本,并寻找训练样本离哪个中心最近,即找到$i(X_K)=\text{argmin}\|X_K-x_i(n)\|$,其中$i=1,2,\cdots,I_K$,$x_i(n)$表示第$n$次迭代时径向奇函数的第$i$个中心。

通过下列公式调整基函数的中心:

$$x_i(n+1)=\begin{cases}x_i(n)+\mu[X_k(n)-x_i(n)]\\x_i(n)\end{cases} \tag{22}$$

式中,μ是学习步长,且其值在0~1。

2)确定基函数的方差α

一旦RBF神经网络的中心确定以后,那么其宽度由式(23)来确定:

$$\alpha_i=\frac{d_i}{\sqrt{2n}} \tag{23}$$

式中,n为隐含层单元的个数;d_i为所选中心之间的最大距离。

3)隐含层到输出层之间的权值w

求输出权值的直接方法就是伪逆矩阵法:

$$T=\boldsymbol{G}\times\boldsymbol{u} \tag{24}$$

式中,$\boldsymbol{u}$是训练集中的期望响应向量,矩阵$\boldsymbol{G}^*$是矩阵$\boldsymbol{G}$的伪逆,而矩阵$\boldsymbol{G}$定义为:

$$\boldsymbol{G}=\{g_{qi}\} \tag{25}$$

式中,g_{qi}是第q个输入样本向量:

$$g_{qi}=\exp\left(-\frac{\|x-x_i\|^2}{\alpha^2},M\right) \tag{26}$$

式中,$q=1,2,\cdots,N$;$i=1,2,\cdots,M$。

4 预测结果

4.1 分类问题

本文采用的围岩等级数据是由现场工程师根据现场条件,按照规范[12]得到。整个数据集包括:50个Ⅱ级岩体样本,50个Ⅲ级岩体样本,50个Ⅳ级岩体样本和50个Ⅴ级岩体样本。

为筛选出适用于TBM掘进工况下岩体分类任务的最优机器学习模型,以此协助现场作业人员判别掘进过程中的围岩赋存状态,实现软弱围岩工况的提前预警,进而为现场操作人员的施工决策提供技术支撑。本文共采用5种机器学习模型对岩体进行建模,计算结果如图8所示。

从图8的各算法的混淆矩阵中可以得出,使用随机森林算法对岩体分类进行预测的效果最佳,支持向量机则较差。为了直观体现各算法的预测准确率,本文将各模型的评价指标参数列于表3。表3同样证明了随机森林算法更适合用于岩体分类的预测。

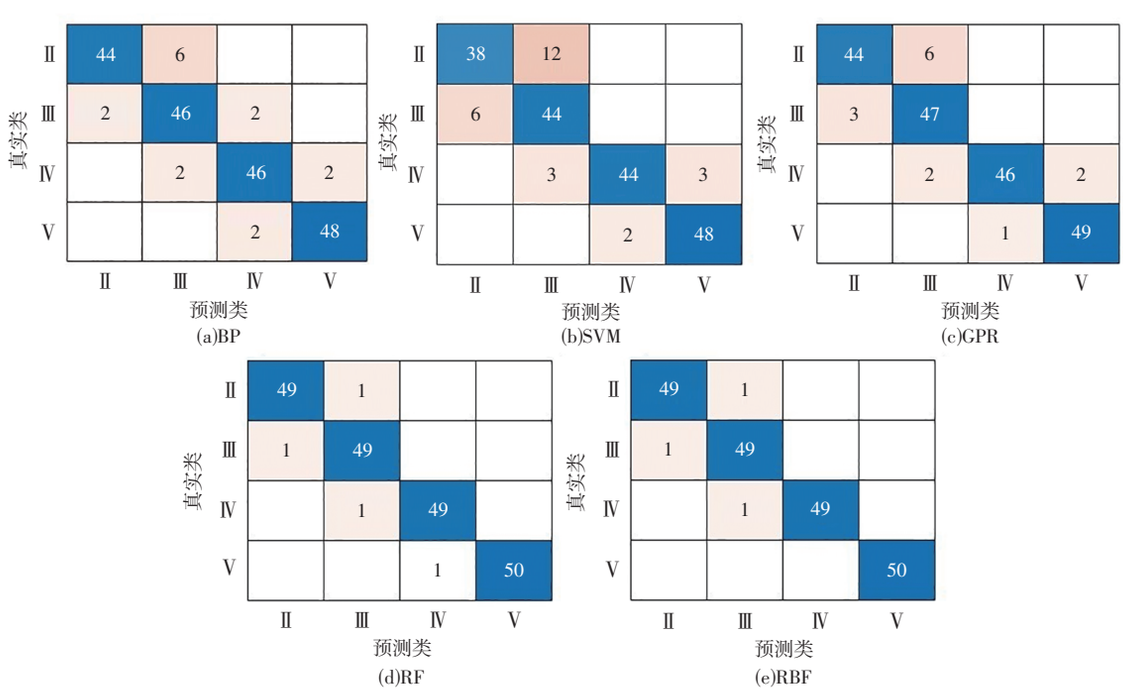


图8 各算法混淆矩阵

Fig. 8 Each algorithm confuses matrix

表3　各算法预测岩体分类评价指标

Table 3　Classification evaluation indexes of rock mass predicted by each algorithm

岩体分类	BP	SVM	GPR	RF	RBF
Ⅱ的$F1$	0.92	0.81	0.91	0.98	0.86
Ⅲ的$F1$	0.88	0.81	0.90	0.97	0.86
Ⅳ的$F1$	0.92	0.92	0.95	0.99	0.94
Ⅴ的$F1$	0.96	0.95	0.97	0.96	0.96
ACC	0.921	0.874	0.930	0.985	0.905
$F1$均值	0.920	0.871	0.930	0.985	0.905

注：$F1$表示$F1$分数(精确率与召回率的调和平均数)；ACC表示分类准确率(Accuracy)。

4.2　回归问题

本节基于完成预处理后的数据集，针对TBM掘进循环的上升阶段与稳定阶段开展特征筛选工作，筛选出对掘进状态影响程度较高的关键参数。在此基础上引入五种机器学习算法，分别实现对TBM掘进上升段、稳定段平均推进力(F)以及单盘扭矩(T)的预测分析，研究结果可为TBM掘进参数的优化调控提供理论依据与实际参考。为公平比较五种机器学习模型在相同数据条件下的泛化性能，本节采用随机分层抽样策略，将数据集按80%∶20%划分为训练集与测试集。该划分方式可消除数据分布差异对模型评估的影响，确保各模型对比的客观性，从而筛选出适用于TBM掘进参数预测的最优算法。

为获取最佳的机器学习方法用于预测TBM挖掘过程各阶段的平均推进力(F)和单盘扭矩(T)，以帮助TBM实际操作人员判断掘进过程中机器应选取的数值，并最终辅助操作人员进行决策。本文采用了5种机器学习模型对岩体进行了建模，结果如图9所示。

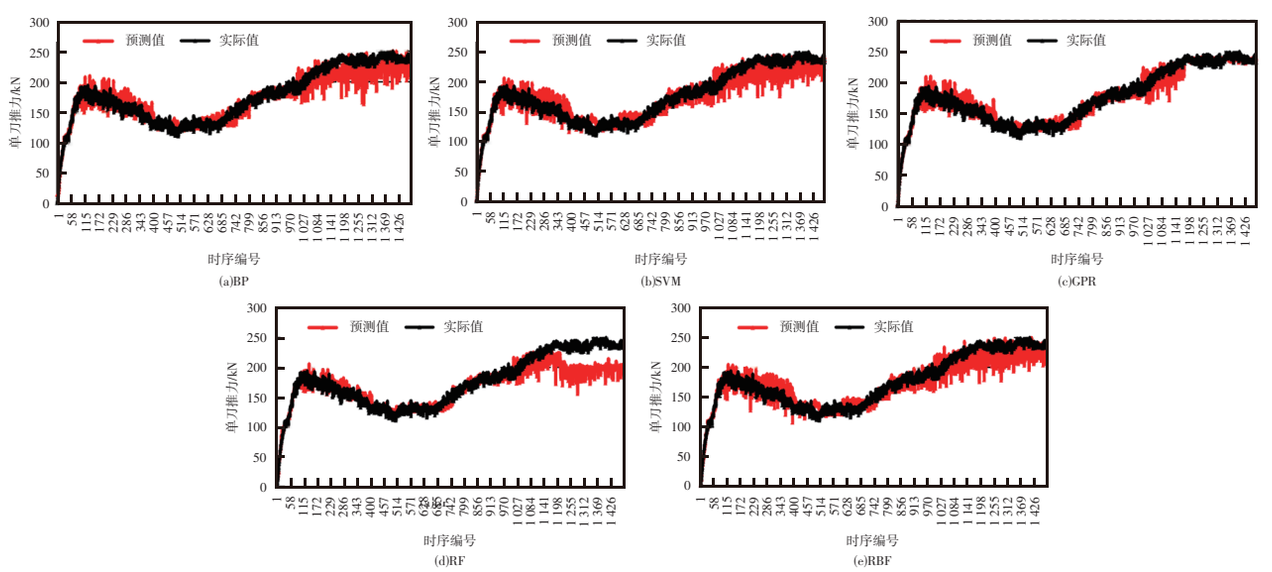


图9　各算法预测平均推力的效果图

Fig. 9　Renderings of the average thrust predicted by each algorithm

1) 推力(F)

由图9可知，各模型对平均推力的预测散点分布较为集中，整体精度均较高。由表4定量指标可知，GPR模型(R^2=0.9538，MRE=0.0451)预测精度最优，RF模型(R^2=0.8035，MRE=0.0804)相对较差。

2) 扭矩(T)

从图10中各算法的单盘扭矩的预测中可以得出，使用GPR算法对岩体参数进行预测的效果最佳，

表4　各算法预测平均推力的评价指标

Table 4　Evaluation indexes of the average thrust predicted by each algorithm

评价指标	BP	SVM	GPR	RF	RBF
R^2	0.901 3	0.901 1	0.953 8	0.803 5	0.896 6
MRE	0.076 1	0.064 5	0.045 1	0.080 4	0.065 9

注：R^2为决定系数(Coefficient of Determination)；MRE为平均相对差(Mean Relative Error)。

而RBF则相对较差。为了直观体现各算法的预测准确率，本文将各模型的评价指标参数列于表5。表5再次表明了，GPR算法更适合用于平均推力的预测。

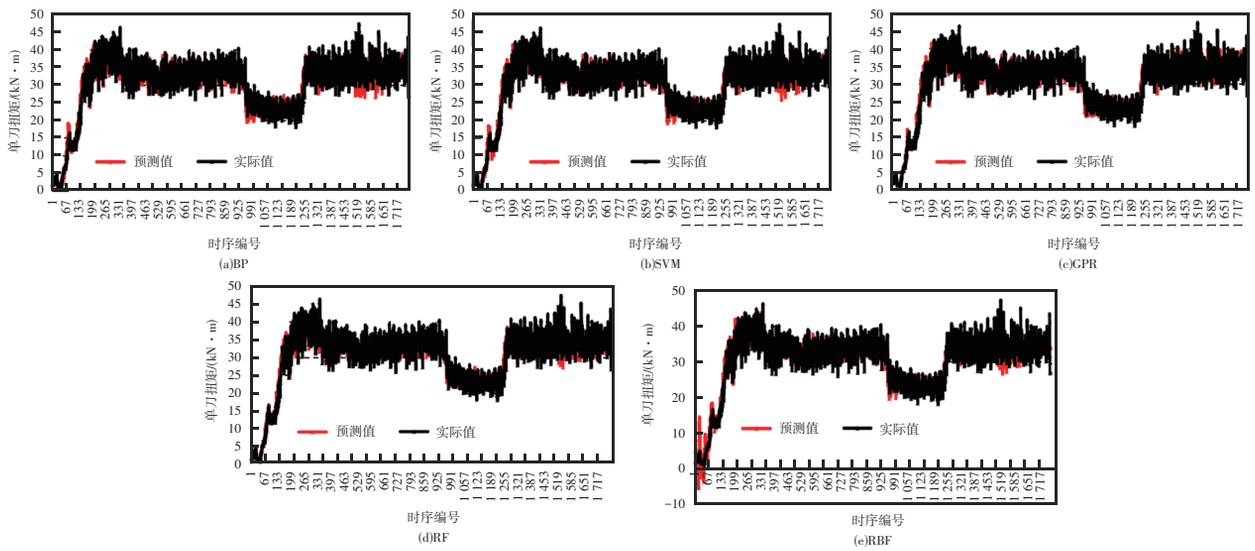


图 10　各算法预测单盘扭矩的效果图

Fig. 10　Each algorithm predicts the effect of single disk torque

表 5　各算法预测单盘扭矩的评价指标

Table 5　Evaluation Metrics for Each Algorithm′s Prediction of Single-Disc Torque

评价指标	BP	SVM	GPR	RF	RBF
R^2	0.911 7	0.906 4	0.932 1	0.934 9	0.886 0
MRE	0.069 5	0.073 2	0.058 3	0.055 1	0.117 2

4.3　各算法的超参数

将各算法的预测超参数列于表 6 中进行对比。

表 6　各算法预测超参数

Table 6　Prediction hyperparameters of each algorithm

超参数	BP	SVM	GPR	RF	RBF
参数值	学习率：0.01 6层隐藏层	c=10 g=0.01	MATERN 核函数	树木数：50 叶子：5	扩展速度：100

5　工程应用价值

第 4 节表明，RF 在围岩等级分类中精度略高（ACC=0.985，$F1$ 均值=0.985），GPR 在掘进参数回归中显著领先（推力 R^2=0.9538，扭矩 R^2=0.9321）。然而，在 TBM 现场部署多模型并行将带来数据接口维护、超参数调优及版本管理的繁重工作量，且不同模型间的决策冲突会增加操作人员判断负担。因此，需从预测精度、模型统一性与工程可实施性三个维度综合评估，选取单一模型作为 TBM 智能辅助系统的核心引擎。

围岩等级预测与掘进参数预测并非相互独立，二者存在紧密的岩-机耦合关系[13]。一方面，围岩等级（Ⅱ～Ⅴ级）从根本上决定了 TBM 掘进参数的理论取值区间[24]：围岩越破碎，刀盘贯入阻力越大，稳定段推力与扭矩通常呈上升趋势，而贯入度趋于降低。因此，围岩等级分类结果可为掘进参数回归预测提供地质约束边界，避免预测值偏离物理合理范围。另一方面，掘进参数（推力、扭矩、贯入度等）是围岩力学响应的直接表征，GPR 模型对推力和扭矩的高精度回归预测表明其已充分学习岩-机相互作用规律，这也为其围岩等级分类提供了可靠的特征基础。统一采用 GPR 模型后，两类预测结果可共享同一套潜空间特征表达，实现信息互补。

RF 在围岩等级分类中的 ACC 和 $F1$ 均值确实略高于 GPR。然而，GPR 的分类精度（ACC=0.930）已达到工程预警的可用阈值（>0.90），且其在Ⅱ～Ⅴ级围岩上的 $F1$ 分数均高于 0.90，不存在对某类软弱围岩的系统性漏判。因此，以 GPR 替代 RF 所造成的分类精度损失（ΔACC=0.055）在工程可接受范围内，不会显著增加围岩误判风险。

更为重要的是，GPR 作为概率模型，其预测结果服从高斯分布，可同时输出预测均值与预测方差（式 17～19）。在 TBM 现场施工中，操作人员不仅需要预测值，更需要知晓预测结果的可信程度。例如，当 GPR 对某段围岩预测为Ⅳ级但方差较大时，系统可自动触发“高风险不确定”预警，提示操作人员结合地质素描进行二次确认；当掘进参数预测置信区间超出安全阈值时，可提前触发降速或停机指令。RF 虽分类精度略高，但仅输出确定性类别标签，无法提供此类不确定性量化信息。从工程安全决策角度，

GPR的概率输出对TBM施工的风险管控具有不可替代的价值。

从工程部署角度，统一采用GPR模型可显著降低TBM智能辅助系统的复杂度。多模型并行部署需维护不同的数据接口、超参数库及模型版本，现场服务器资源占用与故障排查成本随模型数量线性增加。采用单一GPR模型后，系统仅需调用一套核函数超参数与训练集，推理阶段无需在分类器与回归器之间切换，避免了因模型调度错误导致的决策冲突。GPR的推理过程仅涉及矩阵乘法与核函数计算，其时间复杂度与RF相当(均为$O(n^2)$量级)，在1 Hz数据采集频率下完全满足实时性要求。此外，TBM工程的顺利实施不仅依赖于掘进过程中的参数预测，还与前期硐室设计及围岩稳定性控制密切相关。李玉选等[25]针对金属矿山TBM地下始发硐室群建设，提出了硐室群组成布置及各硐室结构参数计算方法，强调始发硐室设计需综合考虑TBM主机尺寸、地质条件及施工工序；王照亚[26]对超千米深金属矿山TBM主机组装硐室的破坏形式进行了分析，指出深部高应力环境下硐室支护设计需特别关注围岩变形控制。这些研究表明，在深部复杂地质条件下，TBM工程的前期地质评估与硐室稳定性分析是保障后续掘进参数预测系统有效部署的重要前提。本文提出的GPR模型可为掘进阶段提供实时决策支持，而结合上述硐室设计研究成果，可形成从“施工准备—实时掘进—风险预警”的全流程技术体系。

为验证GPR模型在真实掘进场景中的实时预测能力，本节采用时序划分策略：选取上升段及进入稳定段前60秒内的数据作为输入，预测稳定段60秒之后的掘进参数与围岩等级。该划分方式可模拟真实工程中“基于当前及历史数据预测后续稳定状态”的实际操作逻辑。

依托本文2.4节所得出的特征筛选结果，研究选取刀盘转速、刀盘扭矩、总推力以及推进速度四项核心掘进参数作为模型输入变量，分别构建对应的TBM掘进参数预测模型。其中，稳定段的总推力F和单盘扭矩T作为回归问题的输出参数，围岩等级作为分类问题的输出参数。

将图11与图12中的测试集和训练集的预测效果进行评价，得到模型评价指标，如表7所示。

结合表7中的评价指标数值与图11、图12的预测效果图可以得出，采用GPR算法模型对于刀盘转速和总推力预测的效果比较优异，不论是训练集还是测试集，R^2基本都达到0.85及以上。因此，本文采用的预测方法能够较为准确地预测稳定段的平均推进力(F)和单盘扭矩(T)，能够帮助TBM实际操作人员在掘进过程中做出准确判断，并最终辅助操作人员进行决策。

此外，本文所提出的掘进段划分与参数预测方法基于引绰济辽工程二标段的历史掘进数据建立，其有效性已通过测试集预测精度($R^2>0.85$)得到验证。然而，由于目前尚未开展独立于建模数据之外的现场施工验证，模型在实际掘进中的实时决策效果仍有待后续工程应用检验。

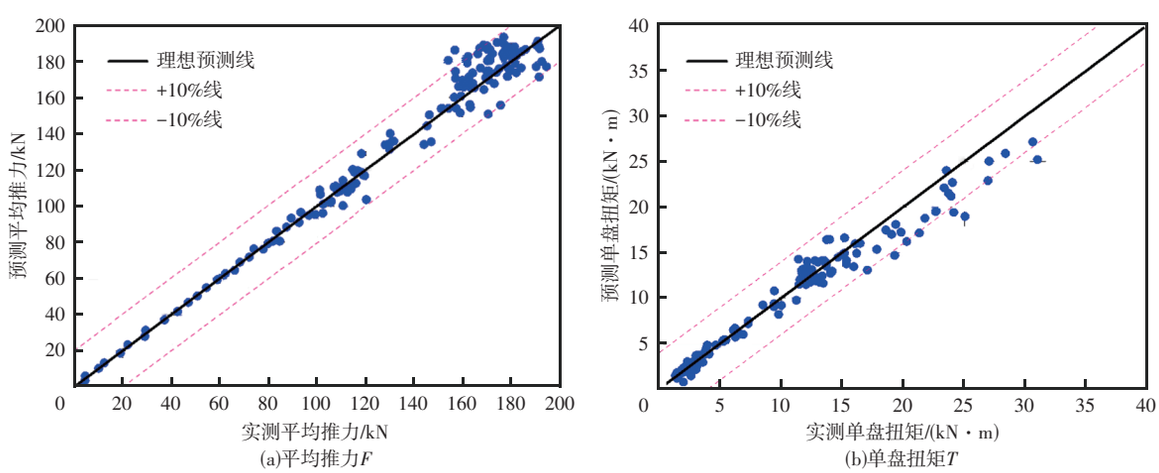


图11　训练集预测效果

Fig. 11　Prediction effects on training set

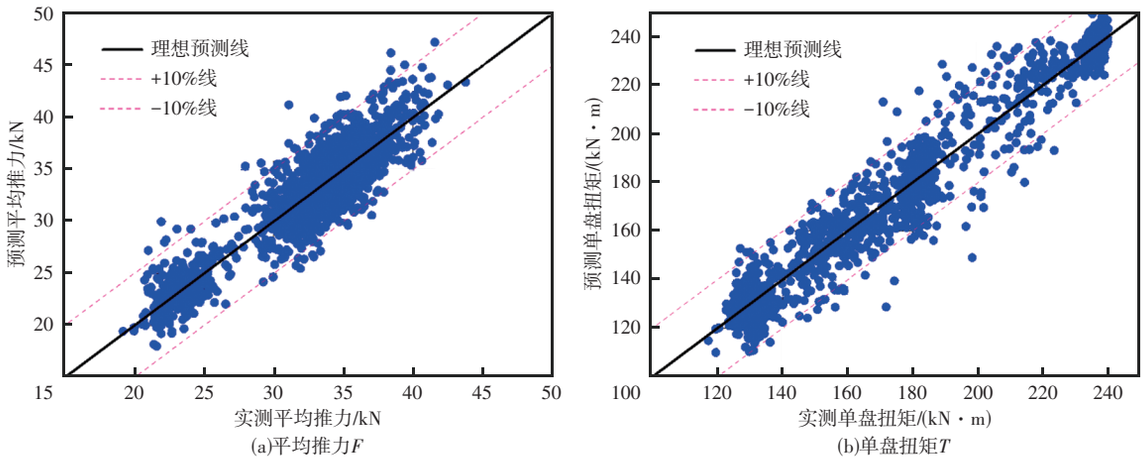


图12 测试集预测效果

Fig. 12 Prediction effects on testing set

表7 评价指标

Table 7 Evaluation indicators

评价指标	F训练	F测试	T训练	T测试
R^2	0.966 3	0.897 4	0.950 4	0.867 0

6 结论

预测实时掘进性能是TBM智能辅助施工的重要内容，是保障TBM安全施工、高效掘进的关键。本文基于五种机器学习算法建立相关模型，以解决对TBM稳定段掘进性能参数的预测问题。并从五个模型中，选出最适合的模型对TBM实时掘进进行预测。模型以刀盘转速、总推力、刀盘扭矩、推进速度及贯入度等参数作为输入参数，以稳定段推进速度和刀盘转速作为控制参数输入，对稳定段的总推力和扭矩进行预测，并基于引绰济辽工程，对本文的模型进行验证，主要的成果和结论如下：

1)本文提出了基于滑动均值滤波与一阶差分符号变化的掘进段自动划分方法，实现了掘进循环中空推段、上升段与稳定段的自动识别，并采用3σ准则对异常数据进行了识别与修正，为后续建模提供了质量可控的数据基础。

2)通过对比五种机器学习模型，GPR在掘进参数回归预测中表现最优(训练集R^2分别为0.966和0.950，测试集R^2分别为0.897和0.867)，RF在围岩等级分类中精度最高。综合考虑预测精度与模型统一性，选取GPR作为统一预测模型，可为TBM操作人员提供掘进参数与围岩等级的预估参考。

3)为了避免使用不同模型预测而造成的工作量繁重、浪费时间，并且为准确预测稳定段数值，从而帮助TBM实际操作人员做出准确判定，本文选取了GPR模型对推力和扭矩进行预测，结果表明该模型的预测效果突出，对于指导TBM施工具有可行性。此外，本文通过随机划分与时序划分两种策略的对比验证，证明了GPR模型既具备优良的离线泛化性能，也适用于TBM实时掘进参数的在线预测。

参 考 文 献

[1] 荆留杰，张娜，杨晨. TBM及其施工技术在中国的发展与趋势[J]. 隧道建设，2016，36(3)：331-337.
Jing Liujie，Zhang Na，Yang Chen. Development of TBM and its construction technologies in China[J]. Tunnel Construction，2016，36(3)：331-337.

[2] Jing Liujie，Li Jianbin，Yang Chen，et al. A case study of TBM performance prediction using field tunnelling tests in limestone strata[J]. Tunnelling and Underground Space Technology，2019，83：364-372.

[3] Li Jianbin，Chen Zuyu，Li Xu，et al. Feedback on a shared big dataset for intelligent TBM Part Ⅰ：feature extraction and machine learning methods[J]. Underground Space，2023，11：1-25.

[4] 刘泉声，潘玉丛，余宏淦，等. 深部金属矿山巷道TBM掘进技术应用现状及研究进展[J]. 有色金属(矿山部分)，2024，76(6)：25-41.
Liu Quansheng，Pan Yucong，Yu Honggan，et al. Application status and research progress of TBM tunnelling technology in deep metal mine roadways[J]. Nonferrous Metals (Mining Section)，2024，76(6)：25-41.

[5] 黄登侠，周小龙，赵健，等. 基于微震监测的TBM掘进工程岩爆预警研究[J]. 有色金属(矿山部分)，2024，76(6)：105-112.
Huang Dengxia，Zhou Xiaolong，Zhao Jian，et al. Study on rockburst early warning in TBM excavation engineering based on microseismic monitoring[J]. Nonferrous Metals (Mining Section)，2024，76(6)：105-112.

[6] Adoko A C，Gokceoglu C，Yagiz S. Bayesian prediction of TBM penetration rate in rock mass[J]. Engineering Geology，

2017，226：245-256.

[7] 周小雄，龚秋明，殷丽君，等. 基于BLSTM-AM模型的TBM稳定段掘进参数预测[J]. 岩石力学与工程学报，2020，39(增刊2)：3505-3515.
Zhou Xiaoxiong，Gong Qiuming，Yin Lijun，et al. Predicting boring parameters of TBM stable stage based on BLSTM networks combined with attention mechanism[J]. Chinese Journal of Rock Mechanics and Engineering，2020，39(S2)：3505-3515.

[8] Zhang Qianli，Liu Zhenyu，Tan Jianrong. Prediction of geological conditions for a tunnel boring machine using big operational data[J]. Automation in Construction，2019，100：73-83.

[9] Hu Tao，Wang Jingcheng，Zhang Langwen. Prediction of hard rock TBM penetration rate using random forests[C]//The 27th Chinese Control and Decision Conference (2015 CCDC). May 23-25，2015，Qingdao，China. IEEE，2015：3716-3720.

[10] JTJ 026—1990 公路隧道设计规范[S].
JTJ 026—1990 Design Specification for Highway Tunnel[S].

[11] Pukelsheim F. The three sigma rule[J]. The American Statistician，1994，48(2)：88-91.

[12] 王双敬，王玉杰，李旭，等. TBM掘进数据标准化预处理方法研究[J]. 现代隧道技术，2022，59(2)：38-44，52.
Wang Shuangjing，Wang Yujie，Li Xu，et al. Study of standardized pre-processing method of TBM tunnelling data[J]. Modern Tunnelling Technology，2022，59(2)：38-44，52.

[13] Gertsch R，Gertsch L，Rostami J. Disc cutting tests in Colorado Red Granite：implications for TBM performance prediction[J]. International Journal of Rock Mechanics and Mining Sciences，2007，44(2)：238-246.

[14] Singhal R K. Mechanical excavation in mining and civil industries[J]. International Journal of Mining，Reclamation and Environment，2014，28(3)：214. DOI：10.1080/17480930.2014.912821.

[15] Kohavi R. A study of cross-validation and bootstrap for accuracy estimation and model selection[C]//Proceedings of the 14th International Joint Conference on Artificial Intelligence-Volume 2. Montreal，Quebec，Canada：Morgan Kaufmann Publishers Inc.，1995：1137-1143.

[16] Rumelhart D E，Hinton G E，Williams R J. Learning representations by back-propagating errors[J]. Nature，1986，323：533-536.

[17] 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 Guangzu，Wang Yaxu，Li Yao，et al. Prediction of TBM performance based on optimized BP neural network[J]. Journal of Henan Polytechnic University (Natural Science)，2020，39(5)：139-145.

[18] Cortes C，Vapnik V. Support-vector networks[J]. Machine Learning，1995，20(3)：273-297.

[19] 李建斌，武颖莹，李鹏宇，等. 基于局部线性嵌入和支持向量机回归的TBM施工参数预测[J]. 浙江大学学报(工学版)，2021，55(8)：1426-1435.
Li Jianbin，Wu Yingying，Li Pengyu，et al. TBM tunneling parameters prediction based on Locally Linear Embedding and Support Vector Regression[J]. Journal of Zhejiang University (Engineering Science)，2021，55(8)：1426-1435.

[20] Seeger M. Gaussian processes for machine learning[J]. International Journal of Neural Systems，2004，14(2)：69-106.

[21] Aha W. Lazy learning[J]. Artificial Intelligence Review，1997，11(1/2/3/4/5)：7-10.

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

[23] Broomhead D S，Lowe D. Multivariable functional interpolation and adaptive networks[J]. Complex Systems，1988，2：321-355.

[24] Khademi Hamidi J，Shahriar K，Rezai B，et al. Performance prediction of hard rock TBM using Rock Mass Rating (RMR) system[J]. Tunnelling and Underground Space Technology，2010，25(4)：333-345.

[25] 李玉选，郭红斌，黄丹，等. 金属矿山TBM地下始发硐室群设计及关键施工技术研究[J]. 有色金属(矿山部分)，2024，76(6)：152-160.
Li Yuxuan，Guo Hongbin，Huang Dan，et al. Study on design and key construction technology of underground starting chamber group of TBM in metal mine[J]. Nonferrous Metals (Mining Section)，2024，76(6)：152-160.

[26] 王照亚. 金属矿山超千米深TBM主机组装硐室破坏形式分析与支护设计研究[J]. 有色金属(矿山部分)，2023，75(5)：26-35.
Wang Zhaoya. Failure forms and support design of over kilometer-deep TBM main engine assembly chamber in metal mine[J]. Nonferrous Metals (Mining Section)，2023，75(5)：26-35.