

文章编号:1672-3961(2025)01-0086-11

DOI:10.6040/j.issn.1672-3961.0.2023.320

盾构滚刀磨损的影响因素敏感性分析及预测

孙尚渠,张恭禄,蒋志斌*,李朝阳

(山东科技大学土木工程与建筑学院,山东 青岛 266590)

摘要:以汕头湾海底隧道盾构段的监测数据为基础,基于数理统计法和机器学习法探究不同影响因素对滚刀磨损的敏感性程度。确定4个对滚刀磨损有明显影响的因素,分别为掘进距离、转速、转程和旋转角;建立以上述4个影响因素作为神经网络输入节点的反向传播神经网络(backpropagation neural network, BPNN)的滚刀磨损预测模型,采用遗传算法(genetic algorithm, GA)对预测模型进行优化并开展预测研究。结果表明:相较于BP模型,GA-BP模型的决定系数 R^2 从0.7064提高到0.8239,预测精度明显提升,说明GA能够明显提高BPNN模型的预测能力。

关键词:滚刀磨损;敏感性分析;数理统计;反向传播神经网络;遗传算法

中图分类号:TU94

文献标志码:A

引用格式:孙尚渠,张恭禄,蒋志斌,等.盾构滚刀磨损的影响因素敏感性分析及预测[J].山东大学学报(工学版),2025,55(1):86-96.

SUN Shangqu, ZHANG Gonglu, JIANG Zhibin, et al. Sensitivity analysis of influencing factors and prediction of shield disc cutter wear [J]. Journal of Shandong University (Engineering Science), 2025, 55(1):86-96.

Sensitivity analysis of influencing factors and prediction of shield disc cutter wear

SUN Shangqu, ZHANG Gonglu, JIANG Zhibin*, LI Zhaoyang

(College of Civil Engineering and Architecture, Shandong University of Science and Technology, Qingdao 266590, Shandong, China)

Abstract: This article was based on the monitoring data of the shield tunnel section of the Shantou Bay Subsea Tunnel and explored the sensitivity of different influencing factors to the characteristic values of cutter wear using mathematical statistics and machine learning methods. Four influencing factors that had a significant impact on the characteristic values of cutter wear were identified, namely excavation distance, rotation speed, rotation distance, and rotation value. A backpropagation neural network based cutter wear prediction model was established with the four influencing factors mentioned above as input nodes for the neural network. The prediction model was optimized using genetic algorithm and prediction research was conducted. The results showed that the prediction error of the model was small, compared with the BP model, the determination coefficient R^2 of the GA-BP model had increased from 0.7064 to 0.8239, indicating a significant improvement in prediction accuracy. This indicated that the genetic algorithm could significantly improve the predictive ability of the backpropagation neural network model.

Keywords: disc cutter wear; sensitivity analysis; mathematical statistics; backpropagation neural network; genetic algorithm

0 引言

随着中国城市地下空间的快速建设和发展,盾构法以其快速、安全、环保等优点,广泛应用于地下

隧道建设。盾构机长时间掘进作业必然导致刀具磨损,进而影响施工质量和效率。同时,刀具磨损严重造成的刀具失效需要开仓换刀,频繁开仓容易引起开挖面失稳、隧道坍塌等工程事故^[1]。通过预测刀具磨损情况,可以及时调整盾构机掘进参数,

收稿日期:2023-12-25

基金项目:泰山学者工程专项经费资助项目(tsqn202312192);山东省高等学校青年创新发展计划资助项目(2022KJ214);中国国家铁路集团有限公司科技研究开发计划资助项目(K2021G021)

第一作者简介:孙尚渠(1990—),男,山东枣庄人,副教授,硕士生导师,博士,主要研究方向为复杂地质盾构破岩机理与高效掘进。

E-mail:sunshangu@163.com

*通信作者简介:蒋志斌(1999—),男,山东潍坊人,硕士研究生,主要研究方向为大直径盾构隧道刀具损坏机理与防控。

E-mail:jdat163com@163.com

延长刀具使用寿命,精确开仓换刀时机,提高施工效率。过去十几年来,盾构刀具磨损预测研究取得了显著进展,预测盾构机刀具磨损的方法主要分为两类:经验公式法和数据驱动方法。经验公式法主要是基于滚刀破岩机理分析,同时结合工程师的经验和专家知识,通过制定经验公式预测刀具磨损^[2-6];数据驱动方法是通过收集大量盾构机掘进数据和刀具磨损量,使用统计分析和机器学习方法建立刀具磨损预测模型。

国内外诸多学者对经验公式法预测刀具磨损进行了研究,这为探究盾构刀具磨损提供了思路。文献[2]根据盘型滚刀磨损机理及运动学分析,分析刀具磨损与岩土参数、施工参数等数据,得到盘型滚刀磨损的影响因素;文献[3]研究复合地层下隧道掘进机(tunnel boring machine, TBM)滚刀磨损的影响因素,并根据地质条件、掘进参数以及掘进过程中摩擦能,提出一种预测滚刀磨损的方法;文献[4]结合实际监测数据,研究磨损过程中刃宽变化与岩体条件对TBM滚刀磨损速率的影响,研究结果表明岩体参数是影响滚刀磨损的关键参数;文献[5]根据国内某输水隧道收集的现场数据,解释了滚刀的磨损规律,并针对花岗岩和具有相同强度或磨蚀性的岩石,开发了一种新的经验模型预测盘型滚刀磨损及寿命;文献[6]分析了某输水隧道的施工数据,引入一种岩石单轴抗压强度为30~150 MPa的预测滚刀磨损的经验模型。前人基于经验公式法的研究仅针对某单一或相似地质条件下的掘进参数、地质参数与刀具磨损的关系进行总结,只对类似地质条件工程的盾构刀具磨损预测起到借鉴作用,有较大的局限性,难以广泛应用到其他盾构工程。

机器学习凭借其突出的非线性拟合能力与高效的运行速度,在图像识别、自然语言处理、无人驾驶等众多领域都取得了重大成就^[7-9]。随着隧道建设过程中数字化、信息化的推广,大量施工信息的获取和记录逐步成为可能,这为滚刀磨损的量化研究奠定了基础。针对机器学习模型预测盾构刀具磨损方面,前人进行了大量相关研究。文献[10-11]通过多种优化算法结合反向传播神经网络(backpropagation neural network, BPNN)建立了滚刀磨损预测模型,在实际工程中预测效果较好;文献[12]在分析滚刀磨损时,综合考虑盾构掘进参数,运用BPNN模型建立了针对硬岩地层的滚刀磨损预测模型;文献[13]进一步降低传统BPNN模型出现局部最优解的风险,结合遗传算法(genetic

algorithm, GA)对BPNN模型进行优化,使滚刀磨损预测误差能够控制在较小范围内;文献[14]针对传统的支持向量机预测模型易陷入局部最优解,将模拟退火算法和遗传算法优化到滚刀磨损预测模型中,具有较高的预测精度。目前机器学习仅通过大量数据对输出目标进行拟合,拟合过程视为一个“黑匣子”,其拟合结果的可解释性差,同时输入参数和选择预测模型存在较大主观性,但凭借其突出的非线性拟合能力和准确的预测精度,在盾构刀具磨损领域的研究与应用也不断深入。

综上,本研究基于汕头湾海底隧道工程盾构段,该工程穿越多种复杂地质,包括上软下硬复合地层及不同差异风化的花岗岩等。在输入参数选择上结合专家知识和工程经验,从掘进距离、转速、转程、旋转角、温度和刀盘转速6个影响因素与滚刀磨损组成的数据集入手,使用数据挖掘方法探究各影响因素对滚刀磨损的敏感性程度,探究影响盾构滚刀磨损的主导影响因素;在预测模型及优化算法的选择上,本研究通过统计现有滚刀磨损预测研究中机器学习模型和优化算法的出现频次,选择反向传播神经网络模型与遗传算法进行超参数优化,基于主导因素建立遗传算法优化的反向传播神经网络的滚刀磨损预测方法,为盾构滚刀磨损预测研究提供借鉴。

1 数据收集与前处理

1.1 数据来源与含义

选取掘进距离、刀盘转速、滚刀运动参数(转速、转程、旋转角)及温度6个影响因素进行滚刀磨损的敏感性分析研究。其中:掘进距离作为目前盾构停机换刀的关键指标,选择作为本研究的参数之一;刀盘转速作为盾构掘进作业中控制的关键掘进参数,其大小直接决定了滚刀的磨损程度,需要用它分析滚刀磨损的敏感性;滚刀作为直接与岩土面接触的部件,其运动参数能反映滚刀磨损的程度,同时滚刀作为金属,切割岩土体时温度升高也可能加剧滚刀磨损,因此,需探究温度对滚刀磨损是否存在影响。

本研究所用数据来自汕头湾海底隧道工程盾构段第582~609环,其中掘进距离和刀盘转速通过盾构机自身传感器进行收集,滚刀运动参数(转速、转程、旋转角)和温度由盾构机搭载的常压泥水刀盘刀具监测系统获得,上述6种监测数据的参数和磨损量的含义如表1所示。由于刀具数量

较多,限于篇幅无法对刀盘上所有刀具安装传感器进行敏感性分析,本研究仅选取该工程盾构机刀盘上安装半径不同且位于不同刀梁上的3把正

面滚刀进行数据挖掘和神经网络模型预测研究,3把正面滚刀编号为35#、37#、55#,安装位置如图1所示。

表1 6种监测数据及磨损量所代表的物理含义

Table 1 Physical meanings represented by six types of monitoring data and wear value

参数名称	参数含义	详细说明
掘进距离	盾构机前进距离	按照环号进行记录,2 m/环
转速	滚刀实时转速评价指标	掌子面完整度高且滚刀无磨损情况下,滚刀转速指标理论值为100,滚刀转速越低,该参数越小,滚刀不转时为0
转程	滚刀旋转量指标	在计算机两次接收时间之间滚刀旋转的角度
旋转角	滚刀旋转量指标	综合评估滚刀在两次接收时间之间的旋转情况,可作为滚刀旋转异常判断的第一参考指标
温度	滚刀内置旋转传感器处的温度	刀筒积渣、刀盘结泥饼、滚刀偏磨等均会造成温度明显上升
刀盘转速	刀盘实时转速评价指标	盾构机刀盘的旋转速度
磨损量	刀具磨损量	根据滚刀转速比计算出的滚刀大致磨损量




图1 选取的3把正面滚刀安装位置图

Fig.1 Installation position of three selected front disc cutters

1.2 数据前处理



在实际采集盾构机掘进过程产生的大规模数据中通常存在数据局部缺失、噪声大和参数冗余等问题,同时在数据采集过程中因掘进环境恶劣多变、传感器老化等原因不可避免地导致数据质量出现问题,例如数据存在缺失和异常等情况^[15]。为了提高数据质量,为后续敏感性分析和机器学习方法预测提供可靠的数据基础,需要对原始数据进行数据前处理。

对于重复和存在局部缺失的数据进行删除,对剩余数据通过箱型图法进行可视化分析,将超过均值3倍标准差的数据定义为异常值并删除^[16],如图2所示。对半径依次增大的3把正面滚刀初始数据集经数据处理后剩余241组。此外,由于不同的影响因素具有不同的量纲,可能对敏感性分析结果造成误差,为了消除这种影响,需要对数据集进行无量纲化处理。最小-最大标准化的优点是保留了数

据的原始分布和形态,简单易懂,常用于特征缩放、图像处理、聚类分析和神经网络训练等任务中^[17]。同时,最小-最大标准化可以使不同尺度和单位的特征在模型中具有同等重要性,避免某些特征对模型的影响过于显著。选择最小-最大标准化对数据进行无量纲化处理,便于后续特征的敏感性分析和神经网络预测。最小-最大标准化的计算公式为

$$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}}$$

式中, x_{norm} 是标准化后的值, x 是原始数据, x_{min} 是最小数据, x_{max} 是最大数据。



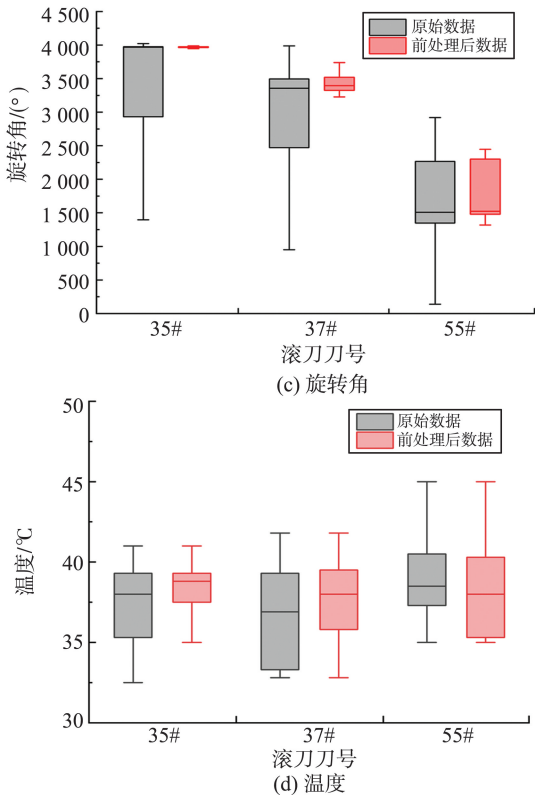


图 2 部分数据前处理前后的对比箱型图

Fig.2 Box plots of comparison before and after data preprocessing

2 敏感性分析

通过对前期文献调研的初步分析,掘进距离和刀盘转速可能对滚刀磨损的影响较大且存在差异性^[18],同时研究滚刀运动参量(转速、转程、旋转角)和温度对滚刀磨损的影响,本章通过数理统计和机器学习两种方法,探讨各影响因素与滚刀磨损之间的敏感性程度。

2.1 基于数理统计的敏感性分析

2.1.1 Spearman 相关性分析

除转程外的其他影响因素和滚刀磨损的数据集中性强,无法满足 Pearson 相关性分析中数据需符合正态曲线分布的要求,因此选用 Spearman 相关系数进行初步相关性分析,3 把滚刀的相关性分析结果如图 3 所示。

由图 3 可知,掘进距离、转速和转程的 Spearman 相关系数均较大,表现出与滚刀磨损存在明显的相关性;其余影响因素对滚刀磨损也呈现出一定程度的相关性。同时从各个影响因素间的 Spearman 相关系数可以推断出 6 个影响因素相互影响,单独判断某个影响因素对滚刀磨损的敏感性程度可能会导致较大的误差。因此,为探究上述影响因素对滚刀磨损的独立影响性,在 Spearman 相关

性分析的基础上,采用偏相关分析方法进一步研究。




图 3 3 把正面滚刀的 Spearman 相关系数热力图

Fig.3 Heatmap of Spearman correlation coefficient three front disc cutters

2.1.2 偏相关系数分析

偏相关分析的目的是在评价某一影响因素对滚刀磨损的敏感性程度时,消除其他影响因素造成的影响,以便更准确地评估各因素与滚刀磨损之间的敏感性程度。偏相关性分析是通过偏相关计算公式计算出各因素与磨损量间的偏相关系数,并利用 T 检验对系数进行显著性分析^[19]。在偏相关分析中,T 检验的结果通常会给出一个显著性 P 值,如果 P 小于 0.05,则说明两个变量之间的关系是真实存在的;如果 P 大于 0.05,则说明偏相关系数不显著,即两个变量之间的关系可能是由于随机因素引起的,而不是

真实存在的。偏相关系数结果如表2所示。

表2 偏相关性系数结果

Table 2 Results of partial correlation coefficient

影响因素	35#		37#		55#	
	系数	P	系数	P	系数	P
掘进距离	0.926	0.000	0.950	0.000	0.976	0.000
转速	0.296	0.002	0.299	0.002	0.310	0.000
转程	0.315	0.007	0.225	0.024	0.340	0.007
旋转角	-0.490	0.003	-0.422	0.000	-0.471	0.000
温度	-0.116	0.330	-0.349	0.000	0.358	0.000
刀盘转速	-0.057	0.631	0.192	0.055	-0.110	0.301

注:0.000的含义并不为0,表示仅保留小数点后3位。

从表2可以看出,除刀盘转速和温度外,其余影响因素的显著性P值均小于0.05,说明掘进距离、转速、转程和旋转角与滚刀磨损的偏相关性显著。对于3把正面滚刀磨损,掘进距离的偏相关性系数均较高,表现出很高的敏感性,说明掘进距离属于影响滚刀磨损的主导因素,对于这一结果是显而易见的,因此也验证了该方法的正确性。细化来看,除掘进距离表现出强相关性外,转速、转程和旋转角也表现出一定的相关性,并且4个影响因素的敏感性排序为掘进距离>旋转角>转程>转速;温度和刀盘转速的相关性较小,且对于不同的正面滚刀,既有可能出现正相关性也可能出现负相关性,说明其对滚刀磨损的敏感性程度较低。

由于部分数据存在非线性分布,而上述相关性系数结果均假设数据线性分布进行计算分析,这可能会对相关性系数结果造成影响。因此,结合机器学习中的非线性算法进一步探究各因素与滚刀磨损之间的影响程度,以提高敏感性分析的准确性。

2.2 基于机器学习的敏感性分析

为了减少因数据分布状态不同而导致运算结果出现较大误差,同时增加结论的可信度,本研究结合相关文献选择使用度较高的多元回归、随机森林和极端梯度提升(extreme gradient boosting, XGBoost)3种算法模型对数据集进行交叉验证计算^[20]。在多元回归模型中,敏感性判断原理是通过比较特征变量的系数权重确定各影响因素对目标变量的影响程度,系数权重表示影响因素在模型中的重要性,较大的系数权重意味着该影响因素对目标变量的影响更大。在随机森林中,通过构建多个决策树,计算每个影响因素在所有决策树中的分裂贡献度,然后取平均值作为该影响因素的重要性指标。在XGBoost模型中,通过多次迭代构建多个弱学习器(模型树),并计算各影响因素对模型树分裂的贡献度,然后将所有模型树中的贡献度进行加权平均得到最终的特征重要性指标。

将数据集按照4:1的比例划分为训练集和测试集,代入上述3种非线性算法模型中进行K折交叉验证计算(K取1~5),使用均方误差、均方根误差、拟合度3个评价指标进行对比分析,选择最优模型进行敏感性分析。评价指标的具体定义如下。

假设,n表示样本数量, y_i 表示第i个真实值, \hat{y}_i 表示第i个预测值, \bar{y} 表示真实值的平均值,均方误差(mean square error, MSE)

$$E_{MS} = \frac{1}{n} \sum (y_i - \hat{y}_i)^2,$$

均方根误差(root mean square error, RMSE)

$$E_{RMS} = \sqrt{E_{MS}} = \sqrt{\frac{1}{n} \sum (y_i - \hat{y}_i)^2},$$

拟合度

$$R = \sqrt{\frac{\sum (\hat{y}_i - \bar{y})^2}{\sum (y_i - \bar{y})^2}}.$$

3种模型的评价指标计算结果如表3所示。

表3 3种模型评价指标结果对比

Table 3 Comparison of models error results

模型	刀号	E_{MS}/mm^2	E_{RMS}/mm	R
多元回归	35#	0.628 7	0.395 3	0.765 5
	37#	1.078 4	1.163 0	0.506 7
	55#	0.516 8	0.267 1	0.265 7
随机森林	35#	1.392 0	2.784 0	0.671 2
	37#	0.978 6	0.957 7	0.485 2
	55#	0.712 8	0.508 1	0.195 5
XGBoost	35#	0.438 5	0.192 3	0.770 2
	37#	0.788 2	0.621 6	0.514 9
	55#	0.236 7	0.056 0	0.285 5

由表3可知,在3种非线性算法模型中,XGBoost模型对3把正面滚刀磨损的 E_{MS} 和 E_{RMS} 拟合度R最接近于1,说明XGBoost模型对于本研究中3把滚刀数据集的拟合程度最优。

3种模型在35#、37#和55#滚刀训练集和测试集交叉验证的均方误差对比如图4~9所示。




图4 3种模型在35#滚刀训练集交叉验证的均方误差对比
Fig.4 Comparison of E_{MS} of the cross-validation of 3 models in 35# cutter training set




图 5 3 种模型在 35# 滚刀测试集交叉验证的均方误差对比
Fig.5 Comparison of E_{MS} of the cross-validation of 3 models in 35# cutter test set




图 9 3 种模型在 55# 滚刀测试集交叉验证的均方误差对比
Fig.9 Comparison of E_{MS} of the cross-validation of 3 models in 55# cutter test set

由图 4~9 可知,XGBoost 模型相较于随机森林和多元回归模型,在训练集和测试集的 K 折交叉验证的均方误差较小。

综合上述对比结果可得,XGBoost 模型更适合用于本研究的数据集。因此,结合 XGBoost 模型的特征重要性模块,分析 6 个影响因素对滚刀磨损的影响程度并得到其中的主要影响因素,6 个影响因素与 3 把正面滚刀磨损量的敏感性分析结果如图 10 所示。




图 6 3 种模型在 37# 滚刀训练集交叉验证的均方误差对比
Fig.6 Comparison of E_{MS} of the cross-validation of 3 models in 37# cutter training set

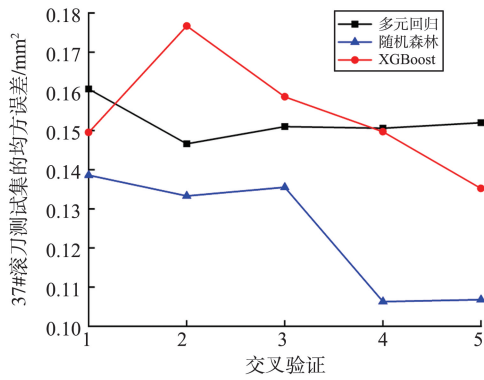


图 7 3 种模型在 37# 滚刀测试集交叉验证的均方误差对比
Fig.7 Comparison of E_{MS} of the cross-validation of 3 models in 37# cutter test set




图 8 3 种模型在 55# 滚刀训练集交叉验证的均方误差对比
Fig.8 Comparison of E_{MS} of the cross-validation of 3 models in 55# cutter training set




图 10 XGBoost 模型中各影响因素权重分布
Fig.10 Weight distribution of various influencing factors in XGBoost model

由图 10 可知,3 把滚刀的影响因素敏感程度大致重合,其中掘进距离、旋转角、转程和转速对于刀具磨损的影响权重较大,属于主导影响因素。

2.3 结果分析

结合表 2 和图 10 可知,除掘进距离对滚刀磨损的敏感性最高外,滚刀的运动参数(旋转角、转程、转速)对滚刀磨损也存在不同程度的敏感性,说明滚刀运动参数对滚刀磨损也有不同程度的影响。

前文比较和分析了不同影响因素对滚刀磨损的敏感性程度,从影响因素的角度进行分析,相同影响因素对不同安装半径的滚刀磨损的敏感性程

度也存在一定差异,其对安装半径不同的滚刀的磨损影响程度可能有所不同。因此,在分析和评估影响因素时,需要考虑其敏感性的差异,从而更准确地理解和预测滚刀磨损的变化。通过3把正面滚刀同一影响因素横向比较发现:滚刀在刀盘上的安装半径也会对滚刀磨损的敏感性产生影响,对于掘进距离和转速,随着滚刀安装半径的增大,敏感性程度也随之增加;旋转角和转程对37#滚刀的作用要略小于35#和55#滚刀的影响;温度对滚刀磨损的敏感性大小有较大差别且出现了完全相反的相关性,出现这种现象的原因可能是部分刀梁出现结泥饼现象或者开挖面进出浆引起温度异常,进而导致上述结果;较于其他影响因素,刀盘转速的影响权重最低,这是由于盾构机在掘进过

程中控制了刀盘转速使其稳定,刀盘转速稳定导致其敏感性程度不高。

为了更好地发挥上述分析对滚刀磨损研究的参考价值,基于敏感性分析结果,从转速和转程两个影响因素入手,结合数据集给出了3把正面滚刀受转速和转程共同作用下滚刀磨损量的分布规律,结果如图11所示,其中蓝色点为红色实心圆点在平面上的投影,并将投影进行了曲线拟合。从图11可知,3把正面滚刀在转速和转程共同作用下磨损量呈非线性分布,且磨损量随转速和转程的变化均呈现变大的趋势,但从转速-磨损、转程-磨损的拟合曲线上看,拟合曲线存在较大差异,不能通过某一因素对滚刀磨损量进行预测,因此利用负反馈神经网络模型对滚刀磨损预测进行研究。




图11 3把正面滚刀磨损量在转速与转程共同作用下的分布图

Fig.11 Distribution of 3 disc cutters wear under the action of speed and stroke

3 基于神经网络的磨损量预测

3.1 滚刀磨损预测模型分析

当前机器学习方法主要解决分类和回归两类问题^[21],盾构刀具磨损预测属于回归问题,在此基础上前人做了较多的相关研究,其模型及优化算法的选择为本研究量化分析滚刀磨损提供了参考。本研究通过统计现有滚刀磨损预测相关文献中机

器学习模型和优化算法的出现频次,并进行降序排列,如表4所示。其中反向传播神经网络与支持向量机出现频次大于5次,优化算法出现频次最高的为遗传算法,共计5次。

在选择滚刀磨损预测模型时,可参考表4中出现频次对所用模型进行筛选,以期获得与滚刀磨损关联密切的机器学习方法,用于构建预测模型。本研究选用反向传播神经网络作为滚刀预测的机器学习模型,遗传算法作为模型优化算法。

表4 滚刀磨损预测模型汇总

Table 4 Summary of disc cutter wear prediction models

模型	优化算法	频次	参考文献
反向传播神经网络	遗传算法	4	文献[10,12,22-24]
	粒子群算法	1	文献[22]
	Levenberg-Marquadt 算法	1	文献[11]
	Elman 模糊算法	1	文献[25]
	无	1	文献[13]
支持向量机	遗传算法	1	文献[14]
	模拟退火算法	1	文献[14]
	粒子群算法	1	文献[26]
	无	3	文献[26-28]
多元非线性回归	无	1	文献[29]

3.2 基于优化神经网络的磨损量预测

综合前文滚刀预测模型统计结果以及敏感性分析结果,选用出现频次最高的 BPNN 模型和遗传算法优化 BP 神经网络(GA-BP)两种模型分别构建多因素影响下的盾构滚刀预测模型,模型输入层节点数为 4,分别对应掘进距离、旋转角、转程和转速,输出层节点数为 1,对应滚刀磨损量,隐含层节点数确定使用的经验公式^[30]为

$$n = \sqrt{a+b} + k,$$

式中, a 为输入层神经元个数, b 为输出层神经元个数, k 为 1~10 的常数。通过上述经验公式得出隐含层的节点数为 3~13,以 35#滚刀建立不同隐含层数量的预测模型,并从预测模型的拟合误差和拟合轮次进行测试对比。拟合误差越小,表示模型的拟合程度更优;拟合轮次越小,说明计算速度更快。测试结果如图 12 所示。




图 12 35#滚刀不同隐含层数量模型的测试结果
Fig.12 Testing results of models with different numbers of hidden layers for the 35# disc cutter

由图 12 可知,经过测试后发现隐含层节点数为 9 时,神经网络模型的误差和迭代轮次都是最少的,说明其拟合程度和计算效率最优,因此构建 4-9-1 的神经网络模型,其初始学习率设置为 0.001,最大迭代次数为 1 000,最大误差阈值为 10^{-6} 。

利用遗传算法对 BP 神经网络的学习率和最大迭代次数进行优化,遗传算法的具体优化过程为:编码→产生初始种群→选择、变异、交叉→计算种群的适应度函数。其中,编码就是将选择优化的超参数平铺为一条染色体的形式;初始种群的数量对结果交叉和变异的本质就是增加种群的多样性,下次迭代最佳适应种群可能就出现在交叉或者变异后的个体;计算种群适应度,适应度越大对应的概率越大,越容易被选择;将遗传交叉变异过后的染色体组成新的种群进行下一次迭代。在经过一定迭代次数后挑出适应度最高的染色体作为最后的结果。本研究中的初始种群数量设置为 5,迭代次数为 50,交叉率和变异率为 MATLAB 2022b 中自带的初始设置,适应度的计算函数选择为 E_{MS} 。

结合 BP 和 GA-BP 两种模型的滚刀磨损预测与实际值曲线对比,并计算 E_{MA} 、 E_{MS} 、 E_{RMS} 以及 R^2 4 种评价指标,对比分析上述评价指标得到最适合该数据集的预测模型。将数据前处理后的 35#、37#、55#3 把正面滚刀数据集的前 80% 划分为模型训练集,后 20% 划分为模型测试集。开展滚刀磨损预测,整体预测流程及遗传算法优化过程如图 13 所示。BP 模型和 GA-BP 模型的 3 把滚刀测试集的预测值与真实值的对比如图 14 所示,2 种模型的预测评价指标计算结果列于表 5。

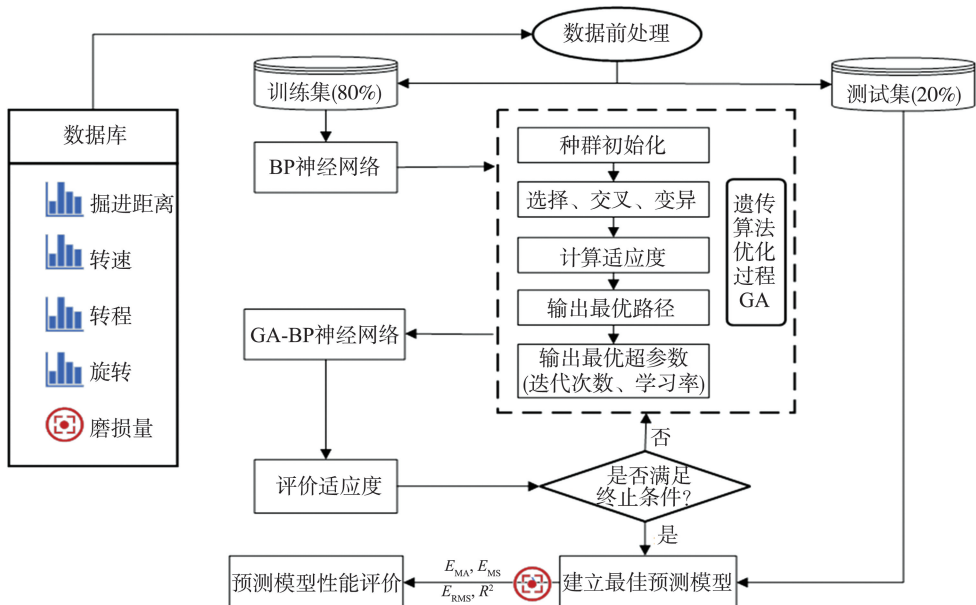


图 13 基于遗传算法优化的 BP 神经网络预测模型流程图
Fig.13 Flow chart of BPNN prediction model optimized based on GA




图14 3把正面滚刀测试集预测结果对比

Fig.14 Comparison of prediction results for 3 front disc cutters of test set

表5 神经网络预测误差

Table 5 Neural network prediction error

模型	刀号	E_{MA}/mm	E_{MS}/mm^2	E_{RMS}/mm	R^2
BP	35#	0.161 7	0.044 5	0.210 9	0.683 1
	37#	0.521 7	0.409 2	0.639 7	0.745 0
	55#	0.344 3	0.178 6	0.422 6	0.691 1
GA-BP	35#	0.126 5	0.023 4	0.152 9	0.814 2
	37#	0.368 5	0.180 8	0.425 2	0.852 4
	55#	0.232 6	0.097 7	0.312 5	0.805 2

3.3 预测结果分析与讨论

对比3把正面滚刀的预测结果和误差,结合图14和表5可知:(1)BP神经网络模型对滚刀磨损预测值与实际值拟合程度较高,从预测误差的结果来看,BP神经网络预测模型的误差指标均较小,3把滚刀的平均预测决定系数 R^2 达0.7064,说明该预测模型能较好地预测滚刀磨损。(2)遗传算法优化的神经网络模型(GA-BP)相较于BP模型,其各项误差指标更小,决定系数 R^2 更接近于1,说明GA-BP模型对于滚刀磨损预测的拟合程度更优,预测效果更加稳定,说明遗传算法可明显优化BP神经网络模型的预测能力。(3)GA-BP模型对3把滚刀磨损预测的平均决定系数 R^2 为0.8239,仅有37#滚刀的 R^2 大于0.8500,35#和55#两把滚刀预测精度并没有满足工程所需。造成拟合度不够的原因可能是数据量较少,3把滚刀的数据量只有241组,同时数据采集过程中因掘进环境恶劣多变、传感器老化等原因不可避免地导致数据质量出现问题。(4)上述问题为滚刀磨损预测精度的提高提供思路。一是提高数据数量,同时明确掘进参数异常是由于监测异常所致还是滚刀磨损所致,为后续机器学习预测奠定更可靠的数据基础;二是在选择滚刀磨损的机器学习模型和优化算法方面,进行更深层次的研究,以期为盾构滚刀磨损预测提供更精确的模型与算法开发。

4 结论

本研究基于数理统计方法和非线性算法,分析了6个影响因素与滚刀磨损之间的敏感性程度,挖掘影响滚刀磨损的主导性因素,并根据主导因素建立了盾构滚刀磨损预测的神经网络模型。预测结果表明,BP神经网络模型对滚刀磨损的预测精度较好,为滚刀磨损预测研究提供了思路。

(1)基于敏感性分析结果,确定了4个关于滚刀磨损的关键因素,分别为掘进距离、转速、转程和旋转角,其敏感性大小排序为掘进距离>旋转角>转程>转速。

(2)统计了13篇滚刀磨损量预测文献中所用机器学习及优化算法的出现频次,根据出现频次选择BP神经网络与遗传算法,建立了主导因素影响下BP神经网络的滚刀磨损预测模型,并采用遗传算法对BP模型的最大迭代次数和学习率进行了优化。

(3)根据预测模型评价指标,GA-BP模型对3把滚刀预测结果的 R^2 平均值为0.8239,较BP模型提高了16.6%,优于BP模型的预测效果。

(4)从模型预测评价指标上来看,33#和35#滚刀的 R^2 小于0.8500,并未达到工程所需。滚刀数据数量和质量对机器学习模型的预测精度存在比较大的影响,后续将从数据筛选方式和模型开发两方面提高滚刀磨损的预测精度。

参考文献:

- [1] 洪开荣. 我国隧道及地下工程发展现状与展望[J]. 隧道建设, 2015, 35(2): 95-107.
HONG Kairong. State-of-art and prospect of tunnels and underground works in China[J]. Tunnel Construction, 2015, 35(2): 95-107.

- [2] SU W L, LI X G, JIN D L, et al. Analysis and prediction of TBM disc cutter wear when tunnelling in hard rock strata: a case study of a metro tunnel excavation in Shenzhen, China[J]. *Wear*, 2020: 446-447.
- [3] REN D J, SHEN S L, ARULRAJAH A, et al. Prediction model of TBM disc wear during tunnelling in heterogeneous ground [J]. *Rock Mechanics and Rock Engineering*, 2018, 51: 3599-3611.
- [4] 龚秋明, 谢兴飞, 黄流, 等. 引绰济辽工程二标隧洞段 TBM 滚刀磨损规律[J]. *隧道与地下工程灾害防治*, 2022, 4(4): 1-10.
- GONG Qiuming, XIE Xingfei, HUANG Liu, et al. Wear law of TBM cutter in the tunnel section of the second bid of the Chaoer River to Xiliao River water conveyance project [J]. *Hazard Control in Tunnelling and Underground Engineering*, 2022, 4(4): 1-10.
- [5] LIU Q S, LIU J P, PAN Y C, et al. A wear rule and cutter life prediction model of a 20-in-TBM cutter for granite: a case study of a water conveyance tunnel in China[J]. *Rock Mechanics and Rock Engineering*, 2017, 50: 1303-1320.
- [6] HASSANPOUR J. Development of an empirical model to estimate disc cutter wear for sedimentary and low to medium grade metamorphic rocks [J]. *Tunnelling and Underground Space Technology*, 2018, 78: 90-99.
- [7] 刘振丙, 方旭升, 杨辉华, 等. 基于多尺度残差神经网络的阿尔茨海默诊断分类[J]. *山东大学学报(工学版)*, 2018, 48(6): 1-7.
- LIU Zhenbing, FANG Xusheng, YANG Huihua, et al. The diagnosis of Alzheimer's disease classification based on multi-scale residual neural network [J]. *Journal of Shandong University (Engineering Science)*, 2018, 48(6): 1-7.
- [8] 周荣翔, 贾修一. 中文反语识别特征分析[J]. *山东大学学报(工学版)*, 2019, 49(1): 41-46.
- ZHOU Rongxiang, JIA Xiuyi. Features analysis for Chinese irony detection [J]. *Journal of Shandong University (Engineering Science)*, 2019, 49(1): 41-46.
- [9] 潘秋景, 李晓宙, 黄杉, 等. 机器学习在盾构隧道智能施工中的应用——综述与展望[J]. *隧道与地下工程灾害防治*, 2022, 4(3): 10-30.
- PAN Qiuqing, LI Xiaozhou, HUANG Shan, et al. Application of machine learning to intelligent shield tunnelling: review and prospects[J]. *Hazard Control in Tunnelling and Underground Engineering*, 2022, 4(3): 10-30.
- [10] 丁小彬, 谢宇轩, 薛皓文, 等. 基于神经网络的盾构滚刀磨损量预测方法探讨[J]. *地下空间与工程学报*, 2023, 19(2): 560-568.
- DING Xiaobin, XIE Yuxuan, XUE Haowen, et al. Investigation of quantitative predication of TBM disc cutter wear by ANN [J]. *Chinese Journal of Underground Space and Engineering*, 2023, 19(2): 560-568.
- [11] 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.
- DING Xiaobin, XIE Yuxuan, XUE Haowen, et al. A method for disc cutter wear prediction based on neural network algorithm[J]. *Journal of Zhengzhou University (Engineering Science)*, 2023, 44(1): 83-88.
- [12] 韩冰宇, 袁大军, 金大龙, 等. 复合地层盾构刀具磨损分析与预测[J]. *土木工程学报*, 2020, 53(增刊1): 137-142.
- HAN Bingyu, YUAN Dajun, JIN Dalong, et al. Analysis and predication of shield cutters wear in mixed ground[J]. *China Civil Engineering Journal*, 2020, 53(Suppl.1): 137-142.
- [13] 石超, 薛皓文, 丁小彬. 基于 BP 神经网络的硬岩地层盾构滚刀磨损预测[J]. *现代隧道技术*, 2020, 57(增刊1): 217-225.
- SHI Chao, XUE Haowen, DING Xiaobin. Prediction of cutter wear of shield machine in hard rock stratum based on BP neural network [J]. *Modern Tunnelling Technology*, 2020, 57(Suppl.1): 217-225.
- [14] 杨俊哲, 邱承有. 盾构刀具磨损速率预测研究[J]. *施工技术*, 2016, 45(22): 25-30.
- YANG Junzhe, QIU Chengyou. Prediction of cutting tool wear rate[J]. *Construction Technology*, 2016, 45(22): 25-30.
- [15] 赵寄辰. 基于大数据的盾构机刀具剩余使用寿命预测方法研究[D]. 西安:西安电子科技大学, 2020: 21-23.
- ZHAO Jichen. Research on prediction method of remaining useful life of shield machine tools based on big data[D]. Xi'an: Xidian University, 2020: 21-23.
- [16] QIN C J, SHI G, TAO J F, et al. Precise cutterhead torque prediction for shield tunnelling machines using a novel hybrid deep neural network [J]. *Mechanical Systems and Signal Processing*, 2021, 151: 107386.
- [17] ZHOU X Z, ZHAO C, BIAN X C. Prediction of maximum ground surface settlement induced by shield tunneling using XGBoost algorithm with golden-sine seagull optimization [J]. *Computers and Geotechnics*, 2023, 154: 105156.
- [18] 吴俊, 袁大军, 李兴高, 等. 盾构刀具磨损机理及预测分析[J]. *中国公路学报*, 2017, 30(8): 109-142.

- WU Jun, YUAN Dajun, LI Xinggao, et al. Analysis on wear mechanism and prediction of shield cutter [J]. China J. Highw. Transp, 2017, 30(8): 109-142.
- [19] 武松, 潘发明. SPSS 统计分析大全[M]. 北京:清华大学出版社, 2014: 218.
- [20] 陈勇, 邹皓天, 苏剑, 等. 基于数据挖掘的土水特征曲线影响分析及预测研究[J]. 应用基础与工程科学学报, 2023, 31(2): 451-461.
- CHEN Yong, ZOU Haotian, SU Jian, et al. Impact analysis and prediction research of soil-water characteristic curves based on data mining[J]. Journal of Basic Science and Engineering, 2023, 31(2): 451-461.
- [21] 周志华. 机器学习[M]. 北京:清华大学出版社, 2016: 18-19.
- [22] 陈玉坤, 管会生, 周磊, 等. 基于BP神经网络的盘型滚刀磨损预测研究[J]. 现代隧道技术, 2021, 58(5): 78-84.
- CHEN Yukun, GUAN Huisheng, ZHOU Lei, et al. Research on the wear prediction of disc cutters based on BP neural network[J]. Modern Tunneling Technology, 2021, 58(5): 78-84.
- [23] 乔金丽, 孟秋杰, 刘建琴, 等. 基于遗传规划的复杂地层中盾构滚刀磨损寿命预测[J]. 工矿自动化, 2018, 44(9): 51-58.
- QIAO Jinli, MENG Qiujie, LIU Jianqin, et al. Prediction of wear life of shield disc cutter in complex formations based on genetic programming[J]. Industry and Mine Automation, 2018, 44(9): 51-58.
- [24] ELBAZ Khakid, SHEN Shuilong, ZHOU Annan, 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, 2020, 7(2): 238-251.
- [25] 李笑, 苏小江. 基于Elman神经网络的盾构滚刀磨损预测方法研究[J]. 辽宁工程技术大学学报(自然科学版), 2010, 29(6): 1121-1124.
- LI Xiao, SU Xiaojiang. A new method for forecasting shield's disc-cutters wearing based on Elman neural network[J]. Journal of Liaoning Technical University (Natural Science), 2010, 29(6): 1121-1124.
- [26] ZHOU C, DING L Y, ZHOU Y, et al. Hybrid support vector machine optimization model for prediction of energy consumption of cutter head drives in shield tunneling [J]. Journal of Computing in Civil Engineering, 2019, 33(3): 04019019.1-04019019.17.
- [27] 王思琪. 基于支持向量机的盾构刀具磨损预测研究[D]. 南京:南京理工大学, 2020: 59-81.
- WANG Siqi. Research on wear prediction of shield disc cutter based on support vector machine[D]. Nanjing: Nanjing University of Science & Technology, 2020: 59-81.
- [28] 周志锋. 基于支持向量机的盾构滚刀磨损预测研究[D]. 广州:广州大学, 2018: 35-47.
- ZHOU Zhifeng. Research on wear prediction of shield hob based on support vector machine[D]. Guangzhou: Guangzhou University, 2018: 35-47.
- [29] 李笑, 苏小江. 盾构滚刀磨损的多元非线性回归预测[J]. 辽宁工程技术大学学报(自然科学版), 2010, 29(6): 281-283.
- LI Xiao, SU Xiaojiang. Forecast of wear shield's disc cutters based on multivariate nonlinear regression [J]. Journal of Liaoning Technical University (Natural Science), 2010, 29(6): 281-283.
- [30] 陈明. MATLAB神经网络原理与案例精讲[M]. 北京:清华大学出版社, 2013.

(编辑:郭少华)