

基于GBDT-CNN-GRU融合模型的TBM隧道低样本围岩智能识别

马金山² 常定¹ 卓鹏飞²

1 浙江江南工程管理股份有限公司

2 上海市市政工程设计研究总院(集团)有限公司

DOI:10.32629/etd.v6i7.18230

[摘要] 在地下工程中,全断面硬岩隧道掘进机(Tunnel Boring Machines,TBM)在IV与V类围岩条件下作业时,常会对施工安全构成较大风险。针对这一问题,本文提出一种融合GBDT、CNN、GRU及注意力机制的多特征融合模型(简称GCGA),用于提升TBM对围岩等级的预测精度。同时以深圳市公明水库—清林径水库连通工程为案例,在3个不同工区进行了验证。结果表明:GCGA模型整体预测准确率优于随机森林和SVM等算法;在低样本量IV类和V类围岩识别中,预测准确率分别提升至88.89%和95.02%;本文结论为GCGA模型在复杂围岩条件下具有较强的预测精度与适用性,为TBM隧道施工中的风险防控提供了有效技术支持。

[关键词] TBM; 岩体等级; 隧洞工程; 特征融合模型

中图分类号: TV512 文献标识码: A

Research on Low-Sample Surrounding Rock Identification of TBM Tunnels Based on the GBDT-CNN-GRU Fusion Model

Jinshan Ma² Ding Chang¹ Pengfei Zhuo²

1 Zhejiang Jiangnan Engineering Management Co., Ltd.

2 Shanghai Municipal Engineering Design Institute (Group) Co., Ltd.

[Abstract] In underground engineering, the operation of full-face hard rock Tunnel Boring Machines (TBM) in Class IV and V surrounding rock environments poses significant risks to construction safety. To address this, this paper proposes a multi-feature fusion model integrating GBDT, CNN, GRU, and an attention mechanism (abbreviated as GCGA) to improve the prediction accuracy of surrounding rock grades. The model employs GBDT to screen key tunneling parameters, uses a CNN module to extract local correlation features among parameters, and utilizes a GRU module to capture dynamic temporal patterns in the data. Additionally, a category attention mechanism is introduced to enhance focus on critical categories (Class IV and V surrounding rocks). Using the Gongming Reservoir-Qinglinjing Reservoir connection project in Shenzhen as a case study, four types of parameters including TBM working pressure and penetration rate were selected as inputs to predict rock mass grades. Field validation confirmed that the model meets engineering requirements. 1) The overall prediction accuracy of the GCGA model for rock mass reaches 96.85%, outperforming traditional algorithms such as Random Forest (64.71%) and SVM (94.13%); 2) The identification accuracy for low-sample Class IV and V surrounding rocks increased to 88.89% and 95.02%, respectively, with maximum improvements of 55.56% and 85.02%; 3) In this project, TBM tunneling efficiency is primarily influenced by working pressure, penetration rate, penetration depth, and cutter head speed. The GCGA model exhibits strong prediction accuracy and applicability under complex surrounding rock conditions, providing effective technical support for risk prevention and control in TBM tunnel construction.

[Key words] TBM; rock mass grade; Tunnel engineering; feature fusion model

引言

全断面硬岩隧道掘进机(Tunnel Boring Machine, TBM)已在交通、铁路及水利等工程中得到广泛应用^[1-3]。与传统钻爆法相比, TBM具有掘进效率高、适用范围广、安全效果好的优点, 已成为地下工程施工的主要方式^[4]。然而, 由于复杂的地质条件与勘探精度的限制, TBM事故时有发生, 并常伴随严重的经济损失。有研究对中国西南地区6个深埋隧洞项目TBM卡机事故进行分析发现, 因技术人员误判IV与V类围岩, 单次经济损失高达400~600万元^[5]。

为降低风险与损失, 学者们从不同角度开展相关研究。例如, 孟尧等^[6]基于有限元方法构建了围岩-支护协同作用的三维数值模型, 揭示了不同岩体等级在TBM荷载作用下的应力分布规律, 为工程师进行风险评判和保障施工安全提供了参考。在风险量化方面, 有学者基于改进的层次分析法构建了涵盖地质条件、设备状态与施工管理的评价体系, 并提出了强化支护措施^[7]。此外, 在智能预警领域, 有研究利用机器学习方法开发TBM异常状态识别模型, 例如基于多传感器数据融合与改进LightGBM的传送皮带故障预警系统, 有效降低了设备故障对工作进度的影响^[8]。

目前, TBM掘进风险研究主要集中于不良地质条件的识别, 大部分研究是通过建立TBM运行数据与地质信息相关联的风险诊断模型进行判断^[9]。然而, 这类研究仍存在不足。首先, 虽然已有成果证明TBM参数与围岩等级存在关联, 但鲜有研究将动态时序特征及静态特征进行深度耦合; 其次IV与V类围岩样本稀少, 却是影响安全的关键因素。现有的Time-SMOTE算法虽能缓解样本不均衡问题, 但未考虑物理约束, 从而生成的样本可能偏离物理规律并增加模型误判概率; 最后, 部分模型过度依赖复杂算法, 而未融入施工现场的物理机制, 导致可解释性与工程适用性不足。上述问题削弱了传统模型的预测准确度与精度。

针对上述问题, 尤其是低样本IV与V类围岩导致的误判风险, 本文提出一种融合梯度提升决策树(Gradient Boosting Decision Tree, GBDT)、卷积神经网络(Convolutional Neural Networks, CNN)、门控循环单元(Gate Recurrent Unit, GRU)及注意力机制的融合模型(简称GCGA模型), 用于实现TBM掘进过程中对掌子面围岩等级提前判别。以深圳市公明水库-清林径水库连通工程为案例, 对模型的工程适用性与实际效能进行了验证。



图1 研究路线图

1 模型构建

1.1 总体思路

为高效处理TBM工况数据并实现掌子面围岩岩体等级的提前预测, 本文构建了GCGA特征融合模型。研究流程主要包括数据预处理、模型训练与模型验证三个部分, 整体路线见图1表达。

1.1.1 数据预处理

首先, 将TBM机载传感器以1Hz采集的原始数据, 按60秒为时间窗口进行分组; 其次, 剔除停机、退回等数据, 仅保留掘进状态样本; 而后, 采用滑动窗口中值平滑法, 消除传感器瞬时波动造成的短期噪声; 随后, 应用Z-score ($\mu=0, \sigma=1$), 确保不同量纲数据在统一尺度下输入模型, 并对围岩岩体等级标签采用独热编码。最后, 通过Pearson相关性分析以保留关键输入特征。

1.1.2 模型训练与验证

训练: 将预处理数据输入GCGA模型, 并通过网格搜索优化超参数, 以提升整体预测精度和关键类别的识别效果;

验证: 使用测试集评估模型性能, 并与随机森林、SVM等经典算法对比。

1.2 模型构建

1.2.1 GBDT模型

GBDT是一种基于决策树的迭代算法。其通过逐步构建决策树, 每一棵树用于修正前一棵树的残差, 最终形成具有良好泛化能力的模型^[9]。在本研究中, GBDT用于七个TBM参数中筛选关键特征, 为GCGA模型提供高质量输入。

1.2.2 CNN模型

卷积神经网络由卷积层、池化层与全连接层组成^[10]。卷积层主要作用为提取数据集中的特征变量, 卷积层中的卷积核数、步长与数据提取效果通常相关^[11], 池化层将特征值进行压缩降维, 全连接层则将网络前面层的特征数据经过权重运算, 并通过激活函数运算得出最终预测结果^[12]。

在本研究中, 经过GBDT筛选后的重要特征间的关系复杂, 由于CNN具有良好的提取局部特征的能力, 故采用CNN对重要特征实施进一步信息提取。由于输入的参数较多且TBM运行时间较长, 所以, 应用ReLU函数作为激活函数以加快收敛速度。而且TBM数据为结构化数组, 故将CNN设置为1维卷积模型。同时, 设置卷积层为3层以保障拟合结果, 而后将数据输入到时序模块中。

1.2.3 GRU模型

GRU是长短期记忆网络(Long Short-Term Memory, LSTM)的一种简化变体, 广泛应用于时序数据分析领域^[13]。相较LSTM模型, GRU将LSTM单元的遗忘门与输出门融合为更新门, 从而使GRU降低了网络的参数量。同时, 模型应用重置门与更新门控制信息的传递与记忆状态的更新, 从而提高模型捕捉数据的长期依赖关系的性能。GRU模型单元数量同样影响数据拟合情况, 本研究中, GRU模型单元数设置为24个以提高模型结果计算能力。

其中,更新门 z_t 表达式为

$$z_t = \sigma(W_z x_t + U_z h_{t-1}) \quad (1)$$

公式中: x_t 为输入变量, W_z 为更新门权重矩阵, h_{t-1} 为前一段时间的隐藏状态, U_z 为 h_{t-1} 的权重矩阵, σ 为sigmoid激活函数使得 $W_z x_t + U_z h_{t-1}$ 转换在0到1区间。

重置门 r_t 表达式为

$$r_t = \sigma(W_r x_t + U_r h_{t-1}) \quad (2)$$

公式中: W_r 为 x_t 的权重矩阵, U_r 为 h_{t-1} 的权重矩阵, 而后应用sigmoid激活函数得出结果。

候选单元隐藏状态 \tilde{h}_t 表达式为

$$\tilde{h}_t = \tanh[W x_t + (r_t \odot U h_{t-1})] \quad (3)$$

公式中: W 为 x_t 的权重矩阵, U 为 h_{t-1} 的权重矩阵, \odot 表示逐个元素相乘, \tanh 为激活函数计算 $W x_t + r_t \odot U h_{t-1}$ 的值。

当前时刻隐藏状态为 h_t 表达式为

$$h_t = \tanh(z_t \odot \tilde{h}_t + (1 - z_t) h_{t-1}) \quad (4)$$

1.2.4 注意力机制

注意力机制是一种模仿人类注意力分配机制的算法, 其旨在通过调整权重以关注数据中的关键信息而忽略次要信息。同时, 模型获得更高的可扩展性和鲁棒性。目前, 注意力机制分为硬注意力、自注意力与软注意力^[14]。硬注意力是将注意力权重离散的形式分配, 常呈现随机性与不确定性以针对性地聚焦于数据中的关键要素^[15]。自注意力特点是关注于数据内部元素的相互关联, 通过计算各个元素间的关联程度得到全局信息的新特征, 其常用于长距离依赖与多变时间动态任务^[16]。软注意力机制是通过构建输入特征全局的权重分布函数, 以动态形式分配注意力权重强度, 从而实现全局加权融合。

本模型中, 由于V与IV类别的数据量少且在实际工程中关注度较高, 而II与III等级岩体类别的数据量较大。所以, 本模型对V与IV类别增加软注意力机制, 增强模型对关键类别的特征聚焦能力, 进而提升模型对于关键类别的准确率^[17]。

1.2.5 结果评估指标

模型性能以各岩体分类准确率作为核心评价指标, 并与分类任务经典模型进行对比。评估涵盖分类准确率与精确率等量化指标, 同时结合特征重要性的地质合理性进行多维度分析, 以验证GCGA模型在复杂关系建模方面的优势。

2 工程应用

2.1 工程背景

本研究依托深圳市原水公司公明水库—清林径水库连通工程(简称“公清项目”), 输水干线全长40.98km, 主要采用深埋隧洞方式施工, 隧洞埋深范围为40.00~198.00m。隧洞过流断面直径5.20m, 开挖直径约6.40m。项目地貌以丘陵、台地和冲积平原为主, 局部存在岩体强烈风化及岩溶现象。由于线路地形与地质情况是复杂多样的, 全程深埋隧洞施工主要采用TBM完成。

2.2 数据采集与预处理

本研究选取独立的区段地质数据作为实验对象。测试集数

据不用于模型的超参数调整, 仅作为整体性能评估。TBM机载传感器以1秒采样间隔获取原始数据。数据预处理步骤如下: (1) 状态筛选: 剔除停机、退回等非掘进状态数据, 仅保留有效掘进过程; (2) 平滑处理: 采用滑动窗口中值平滑法, 消除传感器采集过程中的瞬时噪声; (3) 归一化处理: 对所有参数进行归一化, 以保证不同量纲数据的可比性。

现场共采集7类TBM参数: 工作压力、工作扭矩、总扭矩、总推力、刀盘转速、贯入度与贯入深度。为避免特征冗余, 首先对参数进行Pearson相关性分析($r < 0.80$), 结果见图2。最终筛选出工作压力、贯入度、贯入深度和刀盘转速作为模型输入特征。

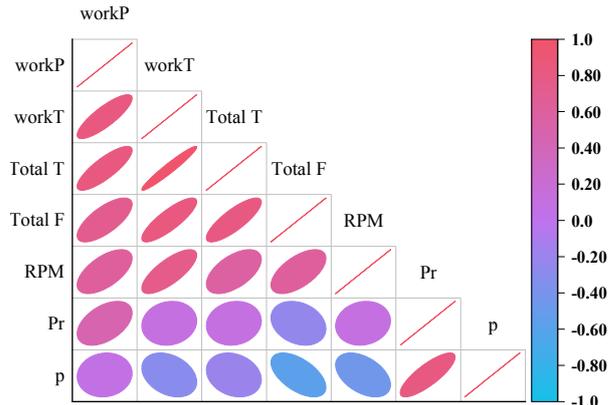


图2 掘进参数间相关性热图

2.3 模型构建

2.3.1 数据集划分

以一个工区数据作为数据集, 首先按8:2划分训练集和测试集; 再将训练集按8:2的比例拆分为训练集与验证集, 分别用于模型训练和超参数优化。各类岩体样本分布见图3。测试集仅用于最终性能评估。

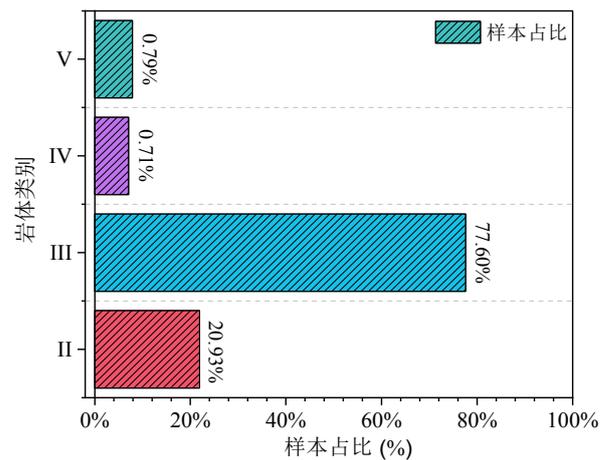


图3 TBM各类数据占比图

2.3.2 模型训练与超参数寻优

本研究将TBM的总推力、工作压力、工作扭矩、刀盘转速与贯入度作为输入特征, 岩体等级作为输出结果, 搭建GCGA岩体等级预测模型(GCGA结构如图4)。

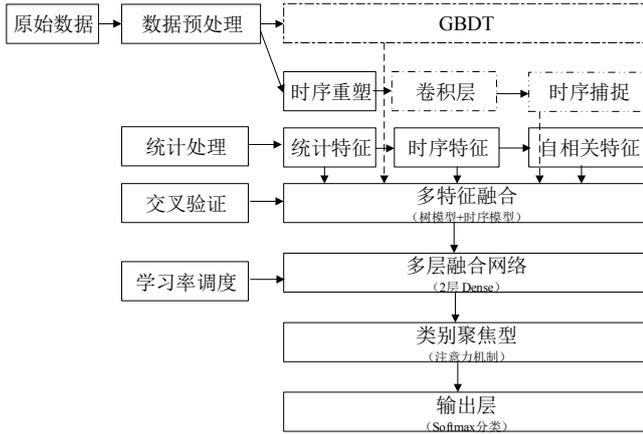


图4 GCGA模型结构图

为提升预测精度及收敛速度,采用网格搜索法进行超参数寻优,具体取值范围与结果见表1。

表1 模型超参数取值范围及模型取值

GCGA模块	超参名称	搜索范围	取值间隔	取值
GBDT	learning_rate	[0.05, 0.001]	0.0005	0.03
GBDT	max_depth	[2, 5]	1	3
GBDT	min_samples_leaf	[2, 10]	1	5
GBDT	n_estimators	[100, 500]	50	150
CNN	kernel_size	[2, 5]	1	3
CNN	out_channels	[32, 64]	8	32
CNN	out_channels	[48, 96]	8	48
CNN	out_channels	[64, 128]	8	64
GRU	hidden_size	[32, 64]	8	48
注意力机制	attention_dim	[16, 64]	8	32
注意力机制	weight	[1, 10]	1	1: 1: 9: 10

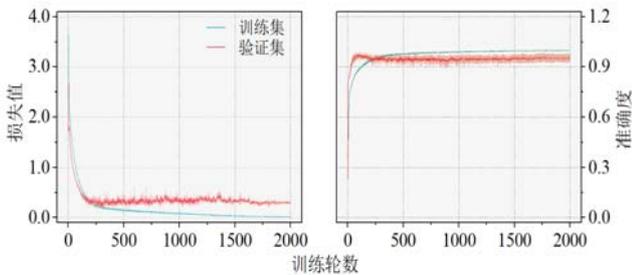


图5 GCGA模型准确率曲线(左)、损失率曲线(右)图

模型训练过程如图5所示。训练与验证集损失值随迭代次数快速下降并趋于稳定,准确率曲线收敛良好,且训练集与验证集

表现一致,无明显过拟合或欠拟合说明GCGA模型具有较强的特征学习与泛化能力。

2.4模型性能评估

项目的岩体等级分类任务中,五种模型性能对比如图6a所示。整体准确率分别为:随机森林(64.71%)、GBDT(69.82%)、SVM(94.13%)、CGRU(98.12%)、GCGA(96.85%)。GCGA显著优于传统机器学习方法,整体表现接近CGRU。

在精确率方面,GCGA达到最高值(98.65%)显示其有效融合了GBDT的特征筛选能力与CGRU的时序建模优势。召回率结果进一步表明了CGRU与GCGA在正样本识别上表现突出。

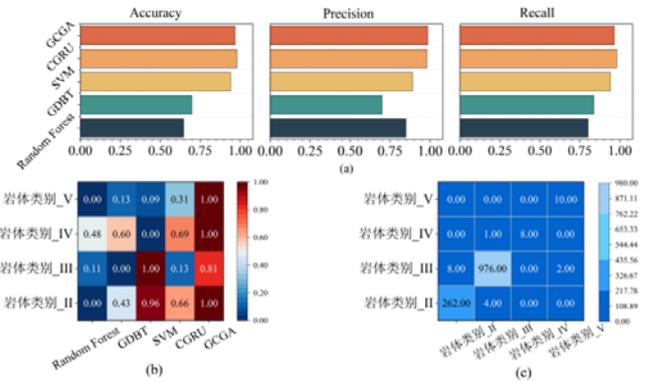


图6 模型对岩体等级预测效果评价(a)、对不同岩体类别的预测准确率(b)、混淆矩阵(c)

针对不同岩体类别(见图6b),各模型对II类和III类岩体识别准确率较高,但在判别IV类和V类岩体上差异明显。传统模型准确率普遍不足70.00%,GCGA对IV类和V类的识别率分别达到88.89%与85.40%,显著优于其他方法。这表明GCGA模型在整体分类性能及关键类别识别上均具有明显优势。

混淆矩阵分析结果如图6c所示,GCGA总体召回率为96.59%,说明模型分类性能稳定。但在IV类样本识别上仍存在一定误差(误判率11.11%),多数被混淆为III类。这可能由于两类岩体地质特征相近,且IV类样本数量不足导致模型学习不足。

2.5模型效果验证

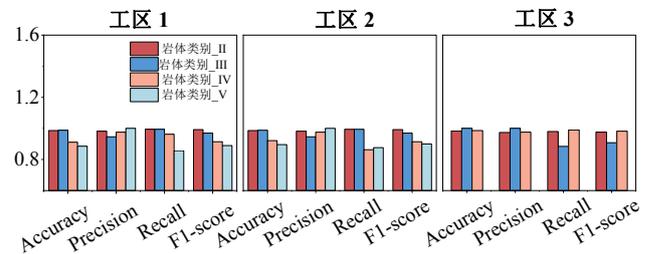


图7 其他工区模型表现

为检验GCGA的泛化能力,本文在公清项目三个工区进行验证,其中第三个工区不含V类围岩。结果如图7所示:各工区准确率均超过0.85,精确率、召回率与F1分数也均在0.80以上,验证了模型在不同地质条件的稳定性与可靠性。但V类围岩样本不足

时, 预测准确度仍低于90.00%, 提示后续研究需进一步提升少数类别识别能力。

3 讨论

本研究提出了一种针对围岩样本类别不均衡问题的多特征融合模型(GCGA), 并将其应用于深圳市某项目TBM掘进数据。结果表明, 该模型在多分类任务中表现优异, 尤其在少样本的IV类与V类围岩识别中, 预测准确率较传统模型分别提升了19.62%~62.50%与60.97%~88.29%, 有效缓解了因样本分布不均衡导致的预测误差。

GCGA模型取得较高的预测精度的原因主要包括以下几个方面: 首先, CNN模块能够高效提取局部特征^[18], 而GBDT从全局视角筛选出宏观重要特征, 实现了多尺度特征的互补; 其次, GRU模块捕捉了TBM掘进参数随时间演化的长程依赖关系, 增强了模型对时序模式的刻画能力^[19]; 再次, 针对IV类和V类少数样本, 引入类别注意力机制以提升其在模型训练中的权重, 缓解了样本不足造成的识别瓶颈^[20]; 最后, 利用滑动窗口中值平滑方法有效抑制了传感器采集中的瞬时噪声, 这提升了输入数据的可靠性。

尽管如此, IV类与V类围岩的识别准确率仍未超过95.00%, 其主要原因在于样本数量严重不平衡限制了模型对少数类别特征的充分学习, 导致分类边界模糊。特别是IV类与III类围岩因地质特征相近更容易发生混淆。在应对样本不平衡问题时, 传统方法多采用Time-SMOTE算法进行过采样^[21]。但该方法容易导致生成随机性强或位于类别边缘的样本, 并且增加边界混淆风险, 甚至导致模型过拟合。相比之下, 本文通过类别加权与注意力机制提升了少数类别的学习能力, 使IV类和V类围岩的预测准确率分别达到88.89%与85.40%, 远高于传统模型不足20.00%的水平。整体来看, GCGA模型在样本不均衡的多分类任务中展现出最优性能。

4 结论

依托项目, 本文系统地研究了TBM掘进参数与岩体等级之间的时序性关系, 并构建了GCGA特征融合模型。通过理论分析与工程实证, 本文得到以下主要结论:

GCGA模型能够有效融合多源环境与施工参数信息, 显著提升岩体等级预测的准确率。特别是在IV类与V类等少样本岩体的识别中, 预测性能优于传统机器学习方法, 体现出较强的不平衡数据适应能力。

关系热图表明TBM工作压力、贯入度、贯入深度和刀盘转速对项目的掘进效率具有潜在的影响, 尤其是控制TBM掘进风险与效率的核心参数。

与经典算法模型及CGRU模型对比可以发现, GCGA通过类别注意力机制与样本加权的协同作用有效缓解了数据分布不均衡引起的分类偏差, 这增强了模型对少数类样本的感知与预测能力。

综上, 本研究提出GCGA模型为TBM掘进过程中岩体等级的动态预测提供了一种有效方法。模型经三个不同工区验证, 展现出

良好的泛化能力。该成果对提升TBM掘进效率、保障施工安全与推动隧道施工智能化具有重要的工程应用价值。然而, 该模型仍存在一定的局限性。一方面, 本研究序列与验证所用数据均来源于公清项目缺乏跨区域测试, 因而在不同地质条件及施工工艺下的泛化能力尚待验证。另一方面, 在工程应用中计算资源有限, 轻量化的传统机器学习方法仍具有实际价值。因此, 未来研究可从以下方面深化: (1) 引入跨地域、多项目TBM数据进行验证, 以提升模型的泛化能力; (2) 针对IV类和V类围岩的特征差异开展解耦研究, 结合TBM-围岩作用机理强化模型的判别能力; (3) 探索具备地质约束的样本生成方法, 提升合成样本的合理性与质量, 从而进一步改善少数类别的识别效果。

【参考文献】

[1] XIE W, LI W, LIU X, et al. In-situ methods for the TBM dismantling in a long-distance and deep-buried tunnel: Case study of Xinjiang water conveyance tunnel[J]. *Tunnelling and Underground Space Technology*, 2022, 129: 104683.

[2] 吴俊. 基于分区随钻参数的隧道围岩智能分级方法研究[D]. 重庆交通大学, 2024.

[3] HUANG G, QIN C, WANG H, et al. TBM rock fragmentation classification using an adaptive spot denoising and contour-texture decomposition attention-based method[J]. *Tunnelling and Underground Space Technology*, 2025, 161: 106498.

[4] 郭东. TBM隧道围岩稳定与衬砌安全智能实时诊断[D]. 哈尔滨工业大学, 2023.

[5] ZHANG L, WANG Y, FU X, et al. Geological risk prediction under uncertainty in tunnel excavation using online learning and hidden Markov model[J]. *Frontiers of Engineering Management*, 2025, 12(3): 447-466.

[6] 孟尧. 长距离水工隧洞TBM开挖围岩稳定有限元分析[J]. *云南水力发电*, 2025, 41(04): 77-80.

[7] 王晗旭. TBM水工隧洞工程质量评价体系研究[D]. 华北水利水电大学, 2024.

[8] 侯文鑫. 基于随机森林的TBM连续皮带机故障诊断研究[D]. 兰州交通大学, 2024.

[9] 李傲. 基于LightGBM模型的中国上市公司绿色信贷信用风险评估研究[D]. 江西财经大学, 2025.

[10] 高帅. 基于凌日搜索并行优化的电能质量扰动识别分类研究[D]. 湖北民族大学, 2025.

[11] 李永花, 代青措, 马玉芳, 等. 基于LSTM和KNN组合模型的黄河源区日径流量模拟研究[J]. *沙漠与绿洲气象*, 2025, 19(3): 157-164.

[12] 常伊婷, 蒋尚明, 崔毅, 等. 安徽省干旱危险性评价及等级划分[J]. *华北水利水电大学学报(自然科学版)*, 2024, 45(006): 41-48.

[13] 丁腾威, 冯硕, 李娜, 等. 基于Siamese CNN-LSTM的磨削变形预测方法[J/OL]. *计算机集成制造系统*, 1-20[2025-09-27].

[14] 庞文锦. 基于特征融合和注意力机制的细粒度图像分类方法研究[D]. 江南大学, 2024.

[15] 胡金鑫. 基于机器学习的风力发电机组轴承故障诊断研究[D]. 重庆交通大学, 2024.

[16] 胡志坚, 叶政春, 郑瀚森. 基于自注意力生成式对抗网络的肺癌图像语义分析方法[J]. 中国医学物理学杂志, 2025, 42(07): 969-973.

[17] 王晓兰, 张惟东, 王惠中. 基于注意力机制的CNN-LSTM短期负荷预测[J]. 计算机与数字工程, 2024, 52(10): 3014-3018.

[18] 傅中元. 基于改进CPO-VMD-CNN-BiLSTM的桥门式起重机减速箱轴承故障诊断模型研究[J/OL]. 湖北大学学报(自然科学版), 1-10[2025-09-27].

[19] 邓涵优, 陈红梅, 肖清, 等. 基于多头注意力动态图卷积网络的交通流预测[J]. 太原理工大学学报, 2024, 55(1): 172-183.

[20] 胡昊, 陈军朋, 李擎, 等. 基于CNN-GRU-ATT的城市暴雨积水预测研究[J]. 华北水利水电大学学报(自然科学版), 2024, 45(4): 27-35.

[21] 沈俊鑫, 李宇恒, 沈冰亮, 等. 基于DA-KSMOTE-Stacking的PPPCP预测模型[J]. 计算机仿真, 2025, 42(01): 508-513.

作者简介:

马金山(1995--), 男, 汉族, 吉林长春人, 硕士, 上海市政工程设计研究总院(集团)有限公司(深圳), 助理工程师, 研究方向: TBM智能化与智能感知技术。