尹鹏博，何芳婵，江生金，等. 聚类、迁移学习与集成学习耦合的输水隧洞 TBM 刀盘推力预测及掘进安全预警[J]. 水利水电技术(中英文)，2026，57(8)：260-273. DOI：10. 13928/j. cnki. wrahe. 2026. 08. 019

YIN Pengbo，HE Fangchan，JIANG Shengjin，et al. A Coupled clustering，transfer learning，and ensemble learning approach for cutterhead thrust prediction and excavation safety early warning in water conveyance tunnel TBM operations[J]. Water Resources and Hydropower Engineering，2026，57(8)：260-273. DOI：10. 13928/j. cnki. wrahe. 2026. 08. 019

聚类、迁移学习与集成学习耦合的输水隧洞 TBM 刀盘推力预测及掘进安全预警

尹鹏博[1]，何芳婵[2,3]，江生金[4]，成　荃[5]，寇　磊[5]

(1. 河南水利投资集团有限公司，河南 郑州　450002；2. 河南省水利科技应用中心，河南 郑州　450003；3. 河南省水利工程安全技术重点实验室，河南 郑州　450003；4. 河南省前坪水库灌区工程有限公司，河南 洛阳　471200；5. 郑州大学 水利与交通学院，河南 郑州　450001)

摘　要：【目的】在长距离输水隧洞施工中，精准预测隧道掘进机(TBM)刀盘推力对保障施工安全与提升掘进效率具有重要意义。传统深度学习模型如 LSTM、GRU 与 Transformer 虽能提供较高精度，但普遍存在参数量大、训练时间长、现场数据适应性差等问题，难以满足工程现场快速响应与实时更新的需求。【方法】提出了一种聚类、迁移学习和集成学习耦合的长距离输水隧洞 TBM 刀盘推力快速预测和掘进安全预警框架：首先，通过聚类算法对刀盘推力上升段数据进行变化形态分类，构建子数据库；随后，基于迁移学习训练变化形态分类模型，以提升新数据的适配效率；最后，结合集成学习方法，在各变化形态子数据库中实现高精度刀盘推力回归预测，并引入推力贯入滑动平均前导比(*LAFPI*)作为敏感特征，以提供有效预警。【结果】结果显示：刀盘推力预测框架能够在保持极低参数量(0. 015B)和 2 分钟训练时间的情况下，实现对超过 1000 个时间节点的刀盘推力数据的高精度预测(R^2>0. 85)。【结论】与表现最优的传统大型神经网络模型相比，训练时间缩短了 86. 9%，静态参数量降低了 97. 4%。通过融合聚类分析、迁移学习和集成学习技术，显著提升了实时训练和应用效率，具备强大的现场实时预测能力，能够有效应对长距离隧道施工中的复杂地质条件，在提高施工安全性和掘进效率方面具有重要的工程应用前景。

关键词：隧道掘进机；刀盘推力；聚类算法；迁移学习；集成学习；安全预警；影响因素；TBM

DOI：10. 13928/j. cnki. wrahe. 2026. 08. 019　　**开放科学(资源服务)标志码(OSID)**：

中图分类号：TV213. 4　　**文献标志码**：A　　**文章编号**：1000-0860(2026)08-0260-14

收稿日期：2025-05-15；**修回日期**：2025-07-24；**录用日期**：2025-08-28；**网络出版日期**：2026-06-11

基金项目：河南省前坪灌区北干管汝阳供水工程科研项目(QPRY-ZX-2024-01)；河南省 2024 年水利科技攻关项目(GG202455)；国家自然科学基金项目(52079128)

作者简介：尹鹏博(1990—)，男，工程师，硕士，主要从事水工结构研究。E-mail：563580058@ qq. com

通信作者：寇　磊(1983—)，男，副教授，博士，主要从事输水隧洞及地下工程施工安全研究。E-mail：koulei@ zzu. edu. cn

©Editorial Department of Water Resources and Hydropower Engineering. This is an open access article under the CC BY-NC-ND license.

A Coupled clustering, transfer learning, and ensemble learning approach for cutterhead thrust prediction and excavation safety early warning in water conveyance tunnel TBM operations

YIN Pengbo[1], HE Fangchan[2,3], JIANG Shengjin[4], CHENG Quan[5], KOU Lei[5]

(1. Henan Water Resources Investment Group Company, Zhengzhou 450002, Henan, China; 2. Henan Provincial Water Conservancy Technology Application Center, Zhengzhou 450003, Henan, China; 3. Henan Key Laboratory of Safety Technology for Water Conservancy Project, Zhengzhou 450003, Henan, China; 4. Henan Qianping Reservoir Irrigation District Project Company, Luoyang 471200, Henan, China; 5. School of Water Conservancy Science and Transportation, Zhengzhou University, Zhengzhou 450001, Henan, China)

Abstract: [Objective] Accurate prediction of Tunnel Boring Machine (TBM) cutterhead thrust is crucial for ensuring construction safety and improving excavation efficiency in long-distance water tunnel projects. However, traditional deep learning models such as LSTM, GRU, and Transformer, while capable of achieving high prediction accuracy, generally suffer from large parameter sizes, long training times, and poor adaptability to on-site data, making them unsuitable for real-time updates in practical engineering scenarios. [Methods] A rapid prediction and excavation safety early warning framework for TBM cutterhead thrust in long-distance water conveyance tunnels is proposed, based on the coupling of clustering, transfer learning, and ensemble learning. First, clustering algorithms are applied to classify the ascending phase data of cutterhead thrust into different variation forms, constructing sub-databases. Then, transfer learning is used to train variation form classification models, enhancing the adaptability to new data. Finally, an ensemble learning method is employed to achieve high-precision regression prediction of cutterhead thrust within each variation form sub-database, incorporating the Leading Averaged Force-Penetration Index (*LAFPI*) as a sensitive feature for identifying surrounding rock transitions, thus providing effective early warning. [Results] The result show that the cutterhead thrust prediction framework, with only 0.015 billion parameters and just two minutes of training time, can achieve high-precision prediction ($R^2 > 0.85$) for cutterhead thrust data containing over 1, 000 time points. [Conclusion] Compared with traditional large neural network models, the training time is reduced by 86.9%, and the model size is reduced by 97.4%. The proposed framework, by integrating clustering analysis, transfer learning, and ensemble learning techniques, significantly improves real-time training and application efficiency. It possesses strong real-time prediction capabilities, effectively addressing the complex geological conditions in long-distance tunnel construction, and holds significant engineering application prospects, particularly in enhancing construction safety and excavation efficiency.

Keywords: tunnel boring machine; cutterhead thrust; clustering algorithm; transfer learning; ensemble learning; safety warning; influence factors; TBM

0 引 言

输水隧洞建设在国内建设如火如荼，如引江补汉、滇中引水工程等[1-3]。隧道掘进机(TBM)在现代输水隧洞工程中发挥着不可或缺的作用，其安全性、适应性和可靠性对工程成本、质量和效率具有重要影响，因此实现施工过程中的掘进参数精准控制是保障项目安全高效进行的关键[4]。然而，由于刀盘前方不可预测的地质条件、不均匀载荷分布以及外部扰动[5-6]，在 TBM 施工过程中实现自适应参数调整仍面临显著挑战[7-9]。与此同时，TBM 必须在整个隧道施工期间应对复杂的地质环境[10-11]。例如，在强风化岩层与断层破碎带交替出现的区域，岩石强度的剧烈波动可能导致刀盘推力需求突变，而地下水活动或围岩应力释放则可能引发突发性阻力变化，进一步加剧参数调控难度[12]。为实现精准操作控制，需根据围岩条件动态调节刀盘转速、掘进速度等核心参数。尽管采取了上述措施，但地层条件的复杂性和多变性仍然使得 TBM 掘进施工的参数超前预测及姿态控制工作极具挑战。优化关键掘进参数是实现盾构施工稳定性和效率的核心基础[13]，近年来通过预测关键负载参数(如刀盘推力、刀盘扭矩或贯入度)来指导主动参数调整、预防卡机等异常情况的研究备受关注[14-15]。例如，基于实时地质雷达数据与振动传感器反馈的动态模型，可构建多尺度预测框架以捕捉刀盘前方地层特征与推力需求间的非线性关系；同时，针对不同围岩分级制定差异化的参数阈值策略，能够显著降低设备过载风险[16]。这使得负载预测方法与自适应控制策略的研发成为盾构工程领域的研究热点[17]，其突破将直接影响到超长隧道穿越复杂地质时的安全性与经济性指标。

TBM 施工过程中产生的海量数据，使得传统统计学方法和理论模型难以有效解析掘进参数波动规律、地质异常特征及围岩质量等关键信息[18]。例如，在硬岩掘进中刀盘扭矩与岩石可钻性系数的非线性关联，以及断层带突变地层引发的压力脉冲信号，往往超出传统回归分析或有限基模型的解析能力。因此，基于机器学习与深度学习的人工智能算法的应用已成为 TBM 工程领域的重要研究方向[19]。这些先进技术通过自动特征提取和复杂模式识别机制，显著提升了数据利用效率——循环神经网络(RNN)可捕捉时间序列参数的动态演变规律，而卷积神经网络(CNN)能从多传感器空间分布中识别地质异常区域，为关键参数预测和性能优化提供了新的解决方案。

自 2022 年以来，多数研究者已从提出单一的 CNN、RNN 和 Transformer 模型或其变体，转向设计融合这些基础架构与先进技术的混合模型，强调多方法优势以解决复杂任务。此外，跨模型应用日益普遍，如在时间序列问题中应用 CNN，反之亦然，凸显了现代建模策略的灵活性和适应性。针对 TBM(隧道掘进机)实际运行特性和安全需求，研究主要聚焦于以下 3 个方面：(1)参数回归预测：主要预测刀盘推力、刀盘扭矩、贯入度等参数，研究通常涉及数据降维与降噪、损失函数设计和模型优化，主要采用 RNN、Transformer 及其衍生模型[20-21]。在这一领域，学者们尤其关注如何通过自注意力机制捕捉长序列的时空依赖关系，并结合门控循环单元(GRU)缓解梯度消失问题。此外，针对地下环境数据噪声大的特点，研究中常引入基于物理约束的损失函数或集成小波变换、卡尔曼滤波等预处理技术提升预测鲁棒性。(2)围岩分类：利用掘进参数和岩渣图像数据，主要采用 CNN 及其变体。处理掘进参数时，通常将其重构为多通道图像格式，例如将时间序列转化为热力图或频谱图以保留空间特征；在处理岩渣图像时，研究者广泛采用边缘检测、形态学闭运算等预处理技术增强岩石纹理特征，并结合迁移学习利用 ImageNet 预训练模型提升小样本场景下的分类精度[22-24]。部分工作还引入注意力门控模块，动态融合多传感器数据的上下文信息。(3)TBM 姿态控制：通过控制掘进参数来降低盾构姿态偏差(STM)，采用多种模型，强调结合实时数据实现模型的轻量化部署与预测更新[25-27]。在策略层面，研究者常设计分层控制架构。

随着研究深入，越来越多的研究者倾向于使用复合模型处理多种形式的数据，例如先对围岩进行分类，再在各类别内训练掘进参数的回归预测模型[28]。这种" 分而治之" 的方法显著提升了多地质条件下的泛化能力——通过将不同地层类别视为独立子空间，避免了单一模型面对复杂非线性关系时的过拟合问题。此外，跨模态融合趋势愈发明显：岩渣图像特征与掘进参数序列被映射到统一嵌入空间后进行联合建模，利用多头注意力机制实现信息互补。值得注意的是，为应对地下工程实时决策需求，研究者开始探索模型压缩技术(如知识蒸馏、量化剪枝)与在线学习框架的结合，在保证精度的同时将推理速度提升 3~5 倍，这对保障 TBM 在突发地质变化中的安全掘进具有重要意义。

上述方法构建了复合模型并验证了其有效性，但它们的模型容量大、算力要求高、训练时间长[29-30]。针对这一问题，本文提出一个算力要求低、训练时间短，预测精度接近这些复杂模型的新框架。该框架需要包含 3 个部分：第一，对原始数据进行变化形态分类；第二，对新数据预测变化形态；第三，基于变化形态对刀盘推力进行预测。以上特点保证该模型在预训练后，能充分利用现场数据完成在线训练、迁移学习或微调，实现在实际工程中模型的快速部署、准确预测。

1 输水隧洞 TBM 掘进循环变化形态分类及预测

本节将某输水隧洞中的 TBM 原始数据划分为多个变化形态子数据库，并基于这些子数据库构建变化形态预测模型，为各子数据库上的刀盘推力预测模型的建立奠定基础。该方法有效降低了刀盘推力模型的复杂度和训练难度，提升了实际工程中的部署效率，并增强了现场实时数据训练模型的可行性。

1.1 工程概况

研究对象为某输水隧洞工程项目，设计年最大调水量为 4.88 亿 m^3，主输水隧道总长度为 58.505 km，隧道坡降比为 1∶3 000。输水线路地处山区向平原过渡地带，沿线地形地貌复杂，地面高程范围为 300~596 m，相对高差较大，局部地区高程超过 500 m。为适应地形变化，工程采用无压隧洞形式穿越山区，隧洞总体埋深在 70~120 m 之间。

对实际掘进路线中的围岩类型进行了详尽勘测，结果显示Ⅱ类至Ⅴ类围岩长度占比分别为 8.8%、46.9%、41.6%和 2.7%。围岩地层以弱风化至微风化岩石为主，岩性主要包括花岗岩、砂岩、熔岩、凝灰角砾岩和凝灰岩等，其中花岗岩占比为 29.5%、砂岩为 16.5%、熔岩为 12%、凝灰角砾岩为 22.6%、

凝灰岩为 14.8%。隧道段地质条件复杂，部分地层滚刀磨蚀性较强，对掘进设备的性能提出了较高要求。

1.2 TBM 原始数据特征提取与清理

在工程原始数据中，包含约 1 200 万个时间步序列，每个时间步的数据维度超过 400 个特征参数。为处理如此大规模且高维的数据集，首先进行了系统化的数据清洗与降维。在数据预处理阶段，通过统计分析识别出含有大量缺失值的关键参数，剔除了约 220 个低质量特征。针对机电系统参数中普遍存在的零值问题，采用动态阈值策略进行二次筛选，剔除连续时间窗口内静默状态(即数值持续为零)超过 90% 的传感器数据，进一步减少了冗余数据。最后，结合工程经验从剩余参数中确定了与刀盘推力存在强关联性的 9 组关键变量：围岩类型、实际转速(r/min)、设定转速(r/min)、刀盘扭矩(kN·m)、刀盘推力(kN)、贯入度(mm/r)、推进位移(mm)、实际速度(mm/min)和给定速度(%)。模型输入特征的分类与结构示意如图 1 所示。

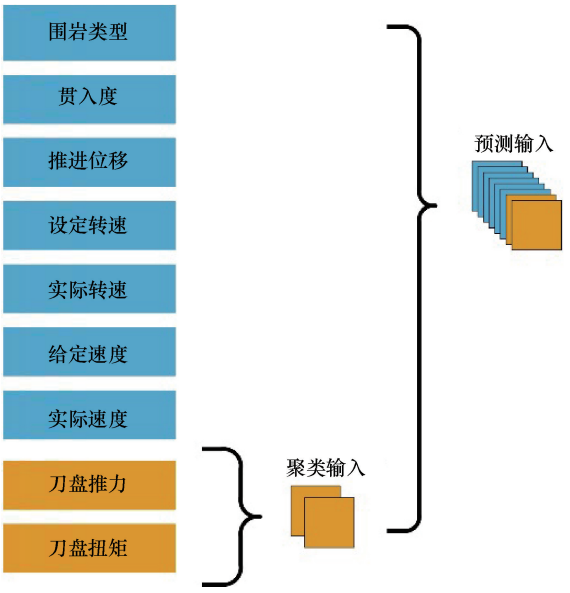


图 1 模型输入特征的分类与结构示意

Fig. 1 Categorization and structure of input features for the model

1.3 基于聚类算法的原始数据变化形态分类模型

1.3.1 掘进循环和截断长度的确定

在 TBM 掘进的过程中，刀盘推力和刀盘扭矩密切相关。定义刀盘推力的两个非 0 点间的数据段为一个掘进循环，并以其为窗口将文件分割为若干个片段，简称“掘进循环”。由于单个刀盘扭矩掘进循环的时间窗口内包含多个刀盘推力掘进循环，因此需区分处于扭矩上升阶段和扭矩平稳阶段的刀盘推力掘进循环。基于此，选择这两个特征作为划分刀盘推力变化形态的依据。

掘进循环长度差异显著是 TBM 施工过程的典型特征，为实现聚类分析的数据标准化处理，需对原始数据进行统一截断：若截断窗口过短，将导致掘进参数的上升段特征被截断，无法完整保留设备-地层相互作用的关键演化过程；反之若截断长度过大，则可能包含大量平稳运行或停机状态的冗余信息，使不同地质条件下的循环样本代表性出现偏差。

通过分段线性拟合迭代法确定上升段分割点，并采用初始分割点修正法解决收敛性问题(见图 2)。最终结果仅有 15 个不收敛掘进循环，占 0.22%。截断长度对掘进循环保留率和分割点覆盖率的影响图(见图 2)绘制了累计分割点占比折线和剩余掘进循环占比折线。试验证明：85% 的刀盘推力上升段长度小于 200。为便于构建基于 ResNet 的变化形态预测模型，拟取截断长度为 200；计算截断长度从 0 以 25 为间隔增长到 250 时的剩余掘进循环占比，200 处于保留率变化平稳区间，验证了选择 200 为截断长度可减小数据量对截断长度的敏感性(68.96% 保留率)并确保模型训练稳定性，最终确定截断长度为 200。

1.3.2 归一化对异常值和噪声的影响

为有效降低数据的信息损失并减小异常值的干扰，在参数归一化处理时根据特征特性选择了差异化的归一化范围。3 种归一化方法的影响如图 3 所示。针对刀盘推力这一关键指标，采用掘进循环内的动态归一化方法，通过聚焦于单个循环内的波动范围，能够更清晰地凸显变化的趋势特征，避免因长期累计数据导致的关键信息被全局极值稀释。对于刀盘扭矩参数，则采取基于单次运行文件的独立归一化策略，这一处理方式可有效抑制不同工况间差异带来的噪声干扰，在保持平稳段数据分布稳定性的同时，防止小幅度波动被全局标准化过度放大。贯入度指标同样采用掘进循环归一化，旨在捕捉循环内部的位移变化规律；其余参数(如推进速度、注浆量等)则统一使用全局归一化方法，确保跨时段对比的基准一致性。

1.3.3 变化形态分类结果

使用 K-Means 算法和 3 种层次聚类算法划分刀盘推力变化形态。由于 K-Means 算法需预先设定簇数这一关键参数，其结果易受经验影响。为此，通过绘制肘部曲线确定合理簇数(见图 4)，系统分析不同簇数对应的簇内误差平方和(*SSE*)。当簇数从 2 递增至 15 时，曲线斜率在 6~9 区间呈现明显转折拐点，表

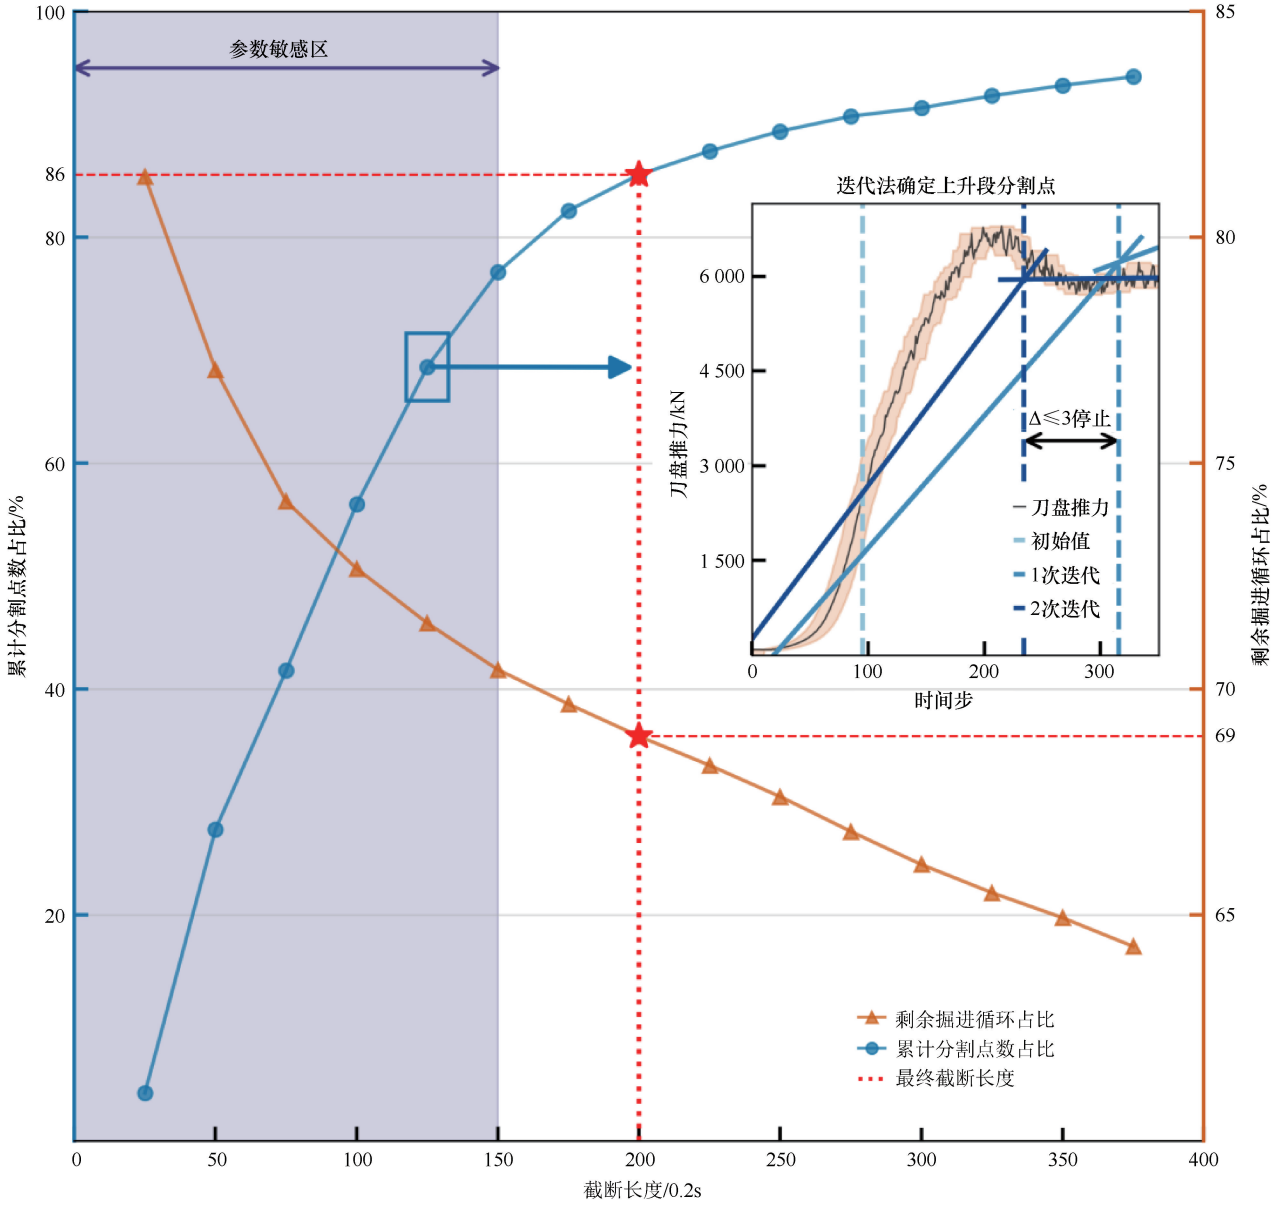


图 2　截断长度对掘进循环保留率和分割点覆盖率的影响

Fig. 2　Truncation length impact on excavation cycle retention and segmentation point coverage

明该范围既能有效捕捉推力变化的多样性特征，又可避免过度细分导致过拟合风险。

使用轮廓系数验证聚类算法，试验表明：单链和平均链层次聚类算法划分出了多个罕见变化形态，且变化形态间数据量极不平衡，会影响变化形态预测模型的效果和鲁棒性。故使用 K-Means、全链层次聚类和沃德法层次聚类对刀盘推力进行变化形态划分，生成 3 组共计 12 套变化形态标签用于训练新数据变化形态预测模型。

1.4　基于迁移学习的变化形态预测模型

1.4.1　时序数据清理和训练集划分方式

选择 PyTorch 框架中在 ImageNet 数据集上预训练的 ResNet 模型，构建了迁移学习预测体系，通过特征复用显著降低了从头设计深度网络所需的标注样本量与计算资源。其中 ImageNet 数据集作为源域，掘进循环过程中刀盘推力与扭矩序列构造的二维图像为目标域；迁移策略采用“微调+分阶段训练”方式，在保留卷积特征提取主干的基础上，仅对新增模块进行任务特化。

在数据处理方面，将上升段长度为 200 的刀盘推力与扭矩时间序列拼接为 20×20 的二维矩阵，视为单通道灰度图像；该图像被放大至 200×200，并通过边缘零填充调整为 224×224，以满足 ResNet 的输入要求，充分利用卷积网络在局部模式识别方面

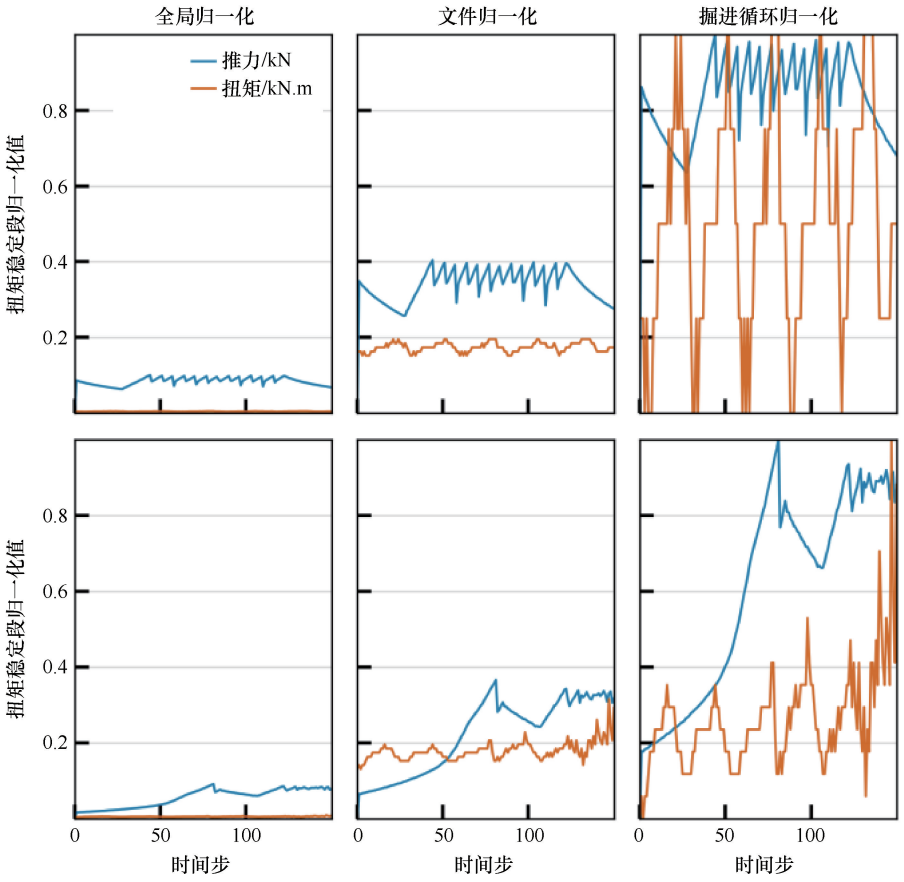


图 3　3 种归一化方法的影响

Fig. 3　Impact of three normalization methods

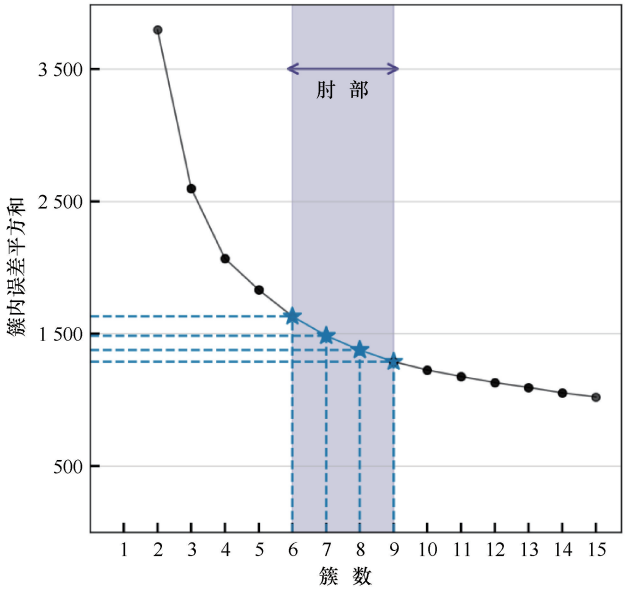


图 4　肘部曲线确定合理簇数

Fig. 4　Elbow curve for determining optimal number of clusters

的优势。

在模型架构适配方面，保留 ResNet 原有卷积结构，并在其后增设包含 256 个隐藏节点的全连接层，使用 Softmax 激活输出对应于前文聚类得到的 6～9 类变化形态。模型训练分为两个阶段：初始阶段采用 Adam 优化器(学习率 0.001)快速拟合任务结构，随后切换为 SGD 优化器(动量 0.9)，并将学习率衰减为原值的 1/10，以实现稳定而高效的参数微调。

由于时序数据的特性，数据清洗(排除长度小于 200 的掘进循环)和训练集划分方式可能破坏其时间连续性。通过绘制 ResNet34 在正常处理、不清洗数据和不随机划分数据集 3 种情况下的训练曲线，得到数据处理方式与聚类方法对分类效果的影响图(见图 5)。由图 5 总结出以下结论：首先，随机划分数据集能显著提升模型性能；其次，不同聚类算法对数据处理方式有各自的偏好，沃德法层次聚类在正常处理数据上效果较好，全链层次聚类对未清洗数据表现更佳，而 K-Means 聚类的效果与簇数相关；最后，尽管不同方法的结果存在差异，但总体差异较小，基本在 5%以内。综上所述，由于 7 簇 K-Means 聚类算法获得的标签所训练出的变化形态预测模型在测试集上表现出最高的准确度，故最终确定采用 7 簇 K-Means 聚类算法所生成的标签作为后续分析的分类依据。

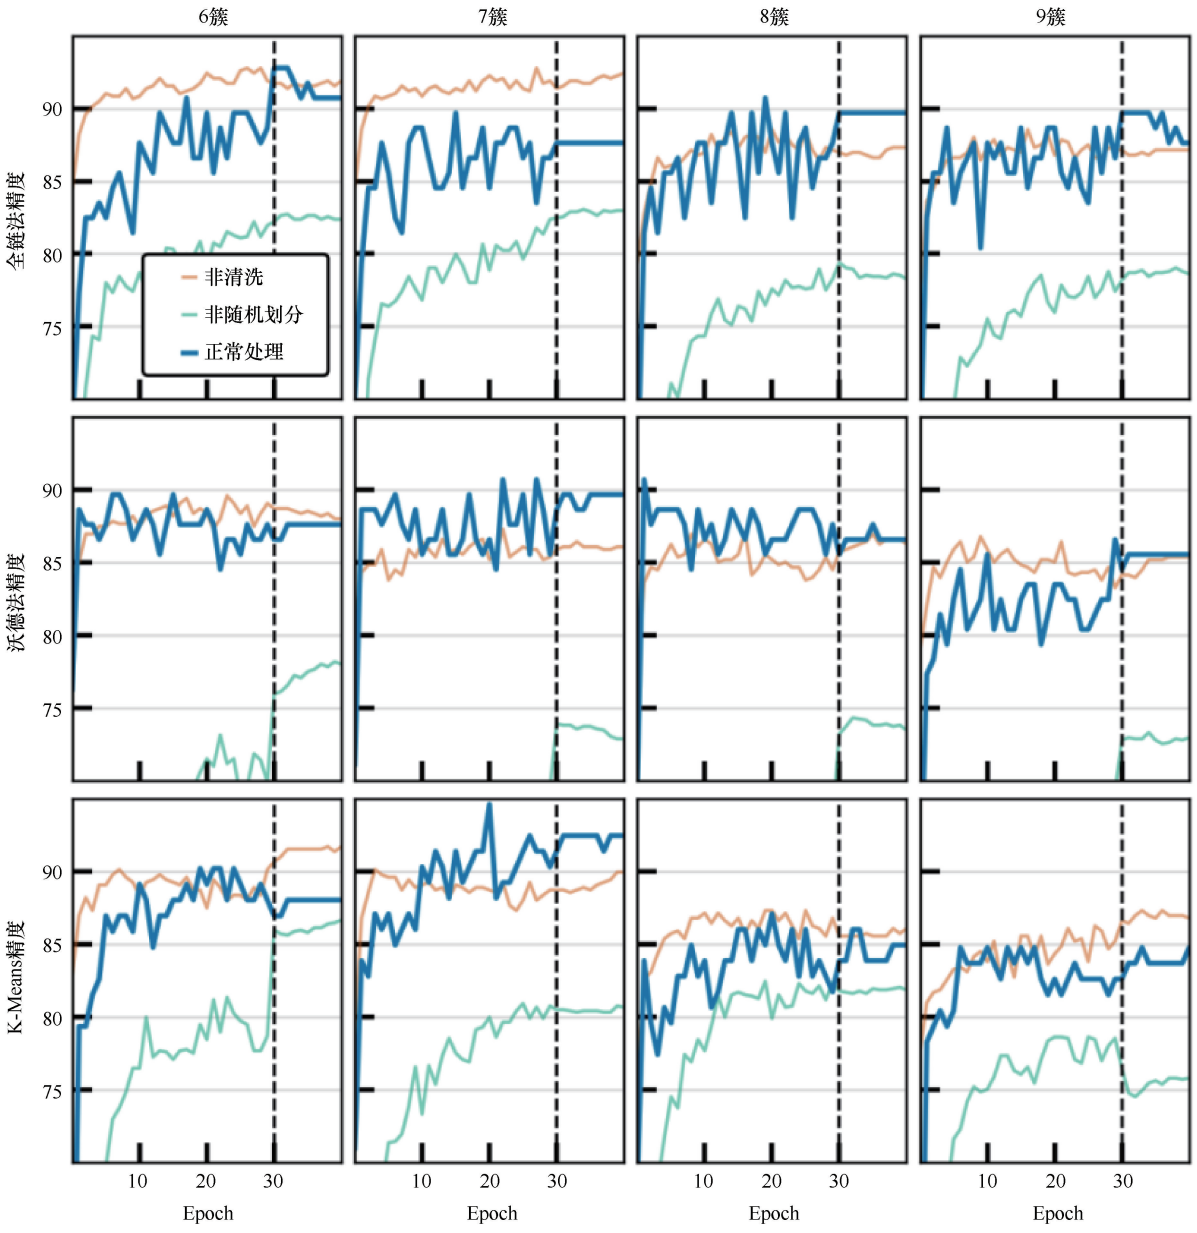


图 5　数据处理方式与聚类方法对分类效果的影响

Fig. 5　Impact of data processing method and clustering algorithms on classification performance

1.4.2　变化形态预测模型效果

ResNet 架构包含多种深度的变体(如 ResNet-50、ResNet-101 等)。为确定最佳模型深度，在不同方法和簇数下绘制了不同深度模型的训练曲线，得到模型深度对分类效果的影响图(见图 6)。分析图 6 可知：首先，K-Means 聚类倾向于浅层模型，而沃德法层次聚类和全链层次聚类在当前试验条件下未表现出明显倾向；其次，随着簇数的增加，深层模型的效果趋于提升，浅层模型的效果则趋于下降；最后，数据处理方法未表现出显著影响。综上所述，由 7 簇 K-Means 聚类算法获得的标签所训练的 ResNet50 变化形态预测模型在测试集上表现出最高的准确度，该结果也与上一节中关于聚类算法选择的结论相一致，因此最终确定使用 ResNet50 作为变化形态的预测模型。

2　基于集成学习的输水隧洞 TBM 刀盘推力预测模型

本节利用上一节构建的变化形态分类及预测模型，将原始数据按照变化形态划分类为若干子数据库，并使用变化形态预测模型预测新数据的变化形态；随后，在对应的变化形态子数据库上构建集成训

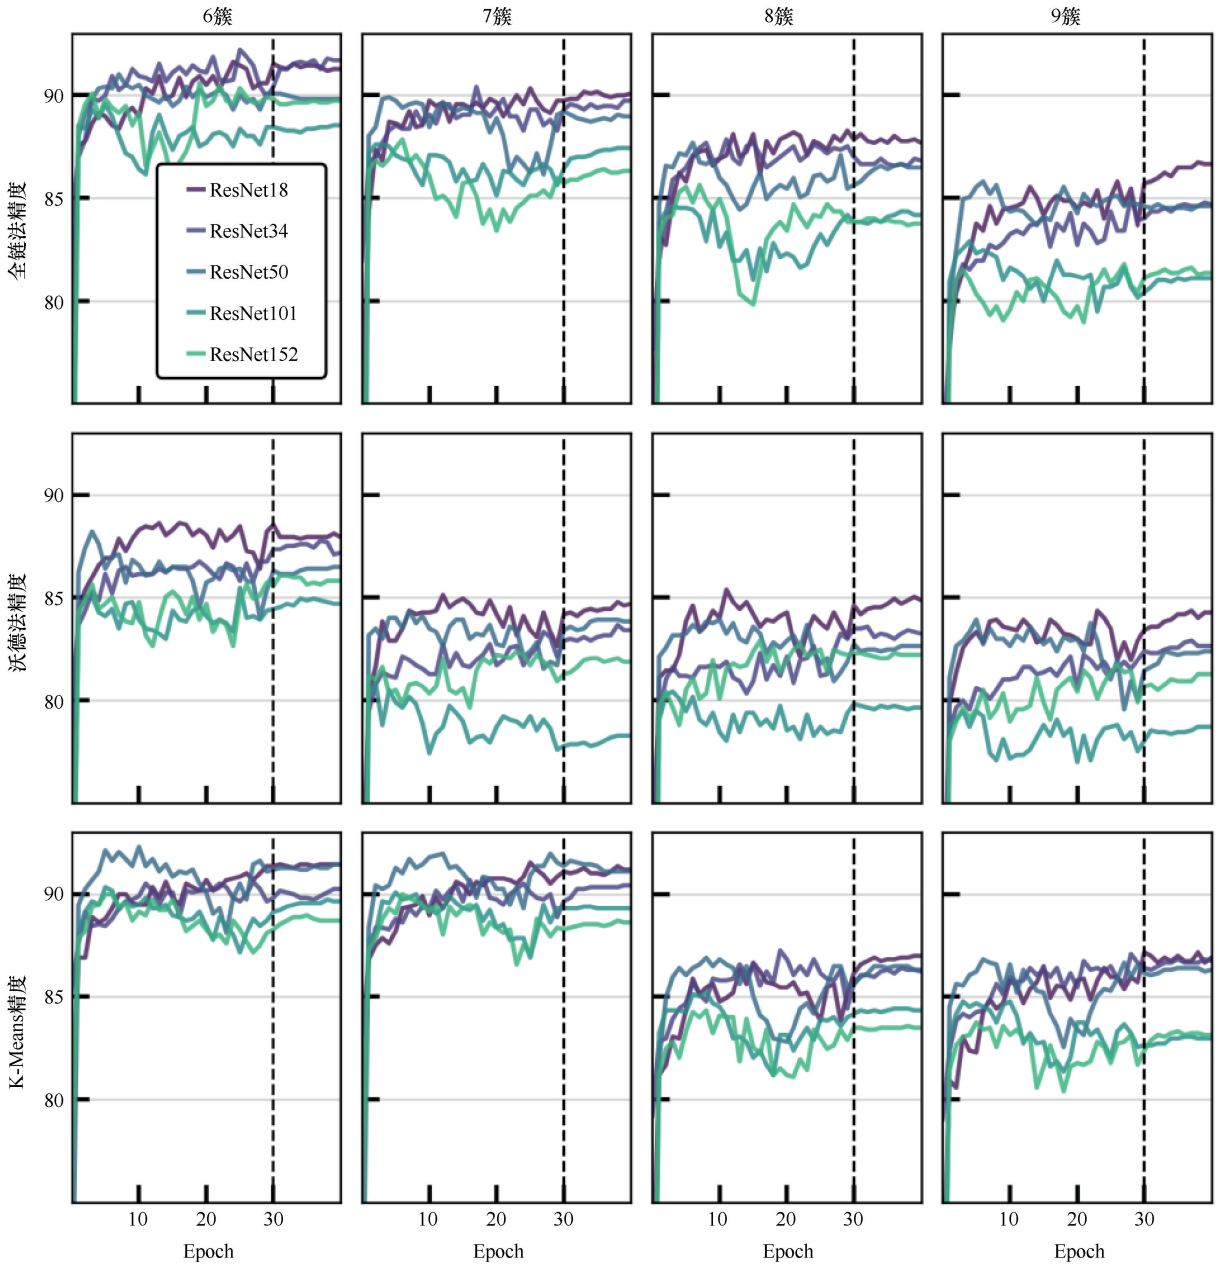


图 6　模型深度对分类效果的影响

Fig. 6　Impact of model depth on classification performance

练模型，以预测刀盘推力。

2.1　刀盘推力预测效果

2.1.1　基模型参数及优化

采用同质集成(Homogeneous Ensemble)下的并行 Bagging 思路构建预测框架，通过多次独立训练结构一致的 MLP 模型以提升整体鲁棒性。在训练过程中，构建多个初始权重不同的 MLP 模型，并在验证集上评估其性能，最终选取表现最优者作为预测模型输出。之所以选用 MLP 作为基模型，主要基于以下考虑：首先，MLP 结构简单，可有效排除模型复杂性对预测结果的干扰，更清晰地反映基学习器的性能差异；其次，MLP 模型参数量小、训练速度快，适用于现场环境中的快速部署与更新需求。

输入基模型的数据在归一化后使用长度为 5 的马尔科夫链进行处理，超出部分以 0 填充。训练过程使用以下方法进行控制。(1)预训练和微调。预训练阶段使用 Adam 优化器；微调阶段使用 SGD 优化器。(2)动态学习率。微调阶段使用指数衰减学习率。(3)使用 Weight Decay 和 Dropout。(4)数据扩充策略。使用与待预测数据具有相同变化形态类别的掘进循环扩充训练集，以提高模型泛化能力。

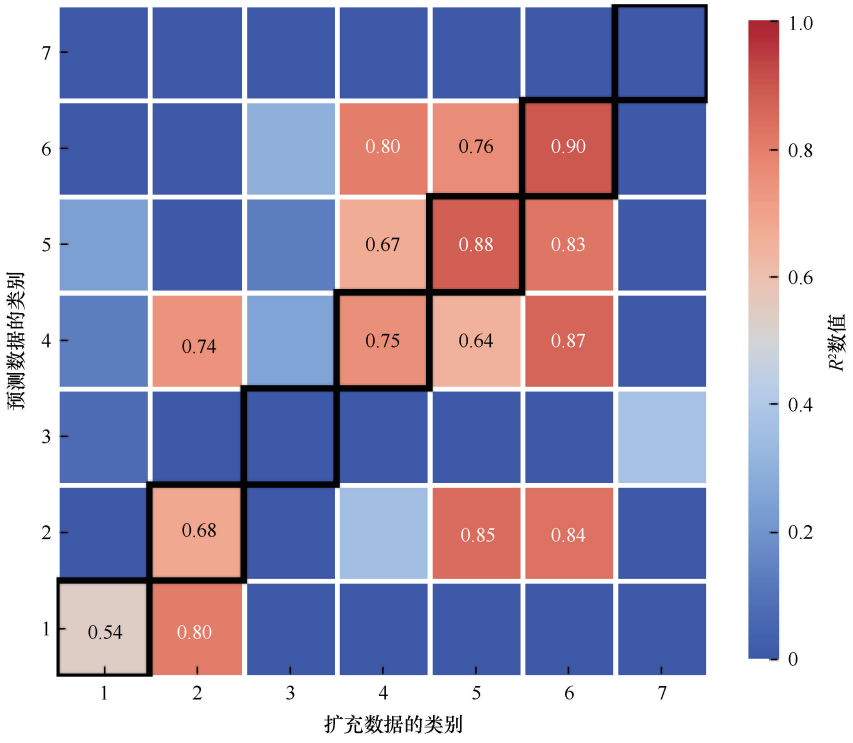


图 7　不同数据库中基模型的预测效果

Fig. 7　Prediction performance of base-models across different datasets

2.1.2　刀盘推力预测效果

从 3 号洞数据中随机选取了 7 种不同变化形态的掘进循环作为预测对象，并针对每个样本，结合 7 个变化形态子库的数据进行扩充处理。在每种扩充条件下，分别训练 10 个基模型，并选取 R^2 得分最优者作为最终模型。不同数据库中基模型的预测效果如图 7 所示。试验结果表明：在参数量仅为 0.015B 的 MLP 模型上，经过约 2 min 训练即可实现最高 R^2>0.9，展现出模型在准确性、训练效率及小型化建模方面的良好性能。

2.2　模型的迁移效果与消融试验

设计了消融试验验证模型各部分的性能，并将其应用于 3 号洞数据中随机抽取的一个掘进循环验证迁移效果。试验分别控制变化形态分类模型与集成训练阶段数据扩充策略的启用情况，并使用 0.015B 参数量的同结构模型进行训练。结果如不同策略组合下的模型消融试验结果对比如图 8 所示：(1)两种方法均使用时，预测结果的 R^2 = 0.907；(2)仅使用变化形态分类模型时，模型不能学习变化趋势；(3)仅使用数据扩充策略时，预测结果的 R^2 = 0.789；(4)两种方法均不使用时，模型不能学习变化趋势。

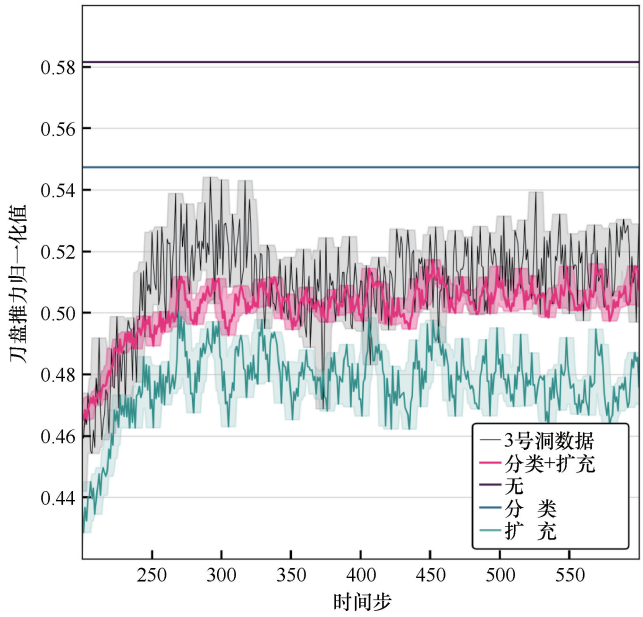


图 8　不同策略组合下的模型消融试验结果对比

Fig. 8　Comparison of model ablation results under different strategy combinations

2.3　模型对比分析

本研究所使用数据集的显著特点在于其数据量远超同类研究：在已有文献中，同领域模型训练所使用的数据总量通常不超过 20 万条，而本研究的数据规模超过 1 200 万条。因此，模型的泛化能力在本研究中尤为关键。此外，现有研究在模型对比试验中普遍

存在变量控制不充分的问题，影响了对比结果的可信度。为了提高试验的有效性与可比性，并贴合工程实际需求，选取了时序预测任务中常用的 LSTM[31-32]、GRU[33]和 Transformer 模型作为对比对象[34-35]，绘制常用模型预测效果对比图(见图 9)。

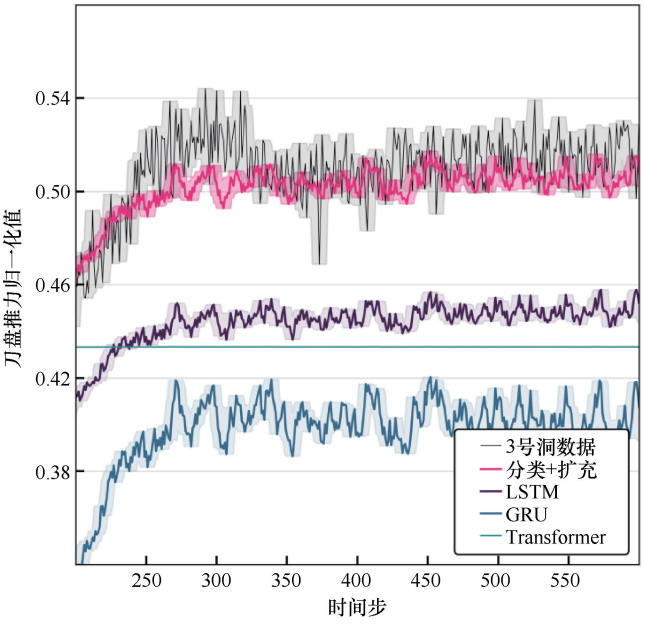


图 9　常用模型预测效果对比

Fig. 9　Comparison of prediction performance among common models

所有模型均在搭载 RTX 4070(12 GB 显存)的设备上进行训练，参数规模控制在约 0.5B，采用 32 位浮点数(FP32)精度，已接近该显卡的计算与显存性能上限。为确保试验的公平性，3 个模型使用一致的参数优化策略，包括早停机制(Early Stopping)和动态学习率调整(Learning Rate Scheduling)，以提升训练效率。模型层数对训练时间有显著影响，参考相关研究，在模型结构中统一设置为 3 层，同时在超参数优化过程中控制模型总参数量在 0.5B 量级。

在上述统一设定下，系统对比分析了各模型在以下四个维度的表现，得到常用模型关键性能指标汇总如见表 1 所列，绘制常用模型综合性能雷达图(见图 10)：(1)预测精度(Accuracy)。以模型预测结果的决定系数(R^2值)衡量，数值越大表示模型拟合效果越好。(2)训练效率(Efficiency)。由于所有模型均采用参数寻优与早停机制，训练时长存在一定随机性，因此不直接比较总训练时间。为更加客观地反映训练效率，选用模型在训练过程中每个 Epoch 的平均训练时间作为评估指标。该指标经负处理后归一化，数值越大表示训练效率越高。(3)紧凑性(Compactness)。以模型总参数量作为评估指标，衡量其结构复杂度。该指标经负处理后归一化，数值越大表示模型更紧凑、资源占用更少。(4)推理延迟(Latency)。以模型在推理阶段的平均响应时间作为评估指标，反映其实时响应能力。该指标经负处理后归一化，数值越大表示推理速度越快，适应性越强。

表 1　常用模型关键性能指标汇总

Table 1　Summary of key performance metrics of common models

模　型	R^2	训练时间/s	参数量/十亿	推理延迟/ms
分类+扩充	0.88	116	0.015	0.000 9
LSTM	0.47	894	0.58	0.001 5
GRU	−0.27	1 004	0.49	0.001 6
Transformer	−0.08	430	0.46	0.006 6

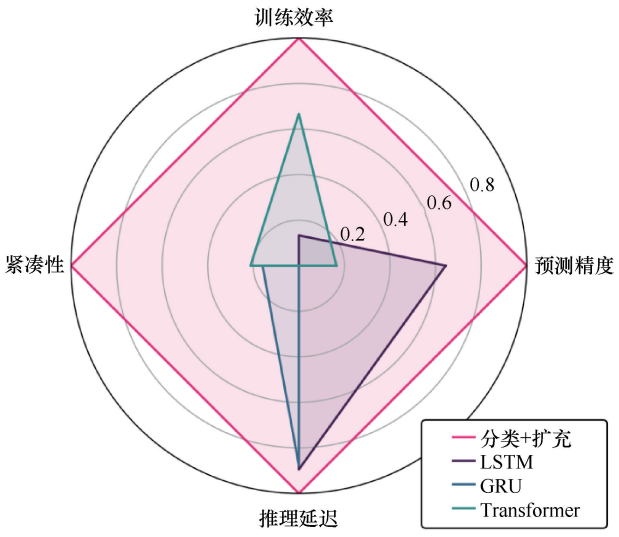


图 10　常用模型综合性能雷达图

Fig. 10　Radar chart of comprehensive performance of common models

3　结果讨论

3.1　结果分析

在图 7 中，同一行的模型使用具有相同变化形态的子数据库进行训练，同一列的模型用于预测具有相同变化形态的掘进循环数据，不同列的模型则用于预测不同变化形态的数据。基于此，可以得出以下结论。

(1)当训练使用的子数据集与测试数据具有相同的变化形态时(对应于图 7 中对角线上的单元格)，模型表现出较优异的性能。这表明，所预测的变化形态能够准确匹配至正确的数据子库，从而实现了训练数据与测试数据在变化特征上的高度相似性，增强了模型的泛化能力。

(2)虽然模型的 R^2 值整体有限，但考虑到常规模型(如 1B)在起步阶段即需消耗大量参数，并且训练时间通常在小时级别，本研究提出的模型在训练成本和效率方面展现出显著优势，具有良好的应用潜力。

(3)图 8 表明，通过数据扩充策略，轻量化模型能够在较短训练周期内实现较高预测精度，且计算资源消耗极低，便于部署和现场应用。从图中可见：第一，仅使用变化形态分类模型时，能有效减小预测偏差，但难以学习数据趋势；第二，仅使用数据扩充策略时，能够学习趋势，但预测偏差较大；第三，结合使用两种方法，可实现对 TBM 刀盘推力的准确预测。综合来看，变化形态分类显著减少了预测偏差，数据扩充策略提升了模型对推力变化趋势的捕捉能力，两者结合后，模型展现出良好的迁移与推广效果。

(4)在图 7 中，对于变化形态类别为 3 和 7 的测试数据，模型预测效果相对较差。同时，图 6 结果显示，随着 ResNet 深度的增加，预测准确率反而出现下降现象，进一步说明当前采用的聚类算法在准确性方面仍存在一定局限性，在下一步的工作中应当聚焦于提高数据子库分类的准确性。

(5)从图 9 和图 10 可以看出，借助变化形态分类模型和数据扩充策略，即使采用最为基础的基模型 MLP，在该数据集上依然在预测精度、训练效率和模型紧凑性三个维度上显著优于常用的时序模型，如 LSTM、GRU 和 Transformer。这一结果表明该模型架构对大规模数据具备良好的适应能力与泛化能力。此外，可以预期，若将当前模型中的基模型由 MLP 替换为更为先进的时序预测结构，并适当提升参数规模，模型的预测精度有望进一步提升。

3.2 工程应用

围岩类型的突变对 TBM 的安全运行构成严重威胁，尤其在围岩从硬岩向软岩转换过程中，TBM 更易发生卡机等故障，进而对工程进度及作业人员的生命财产安全造成重大影响。推力贯入指数(Force Penetration Index，*FPI*)作为推力与贯入度的比值，常用于反映围岩特性。然而，传统的瞬时 *FPI* 指标存在以下两方面问题：第一，推力与贯入度在短时间尺度上存在显著波动，导致计算结果不稳定；第二，推力在掘进过程中通常呈现出明显的上升段和平稳段，其非线性特征进一步影响 *FPI* 的准确性。

因此，瞬时 FPI 难以稳定、合理地反映围岩变化。为此，提出一种改进指标——推力贯入滑动平均前导比(Leading Averaged Force-Penetration Index，*LAFPI*)，以提升预测精度。该指标采用长度为 3 的滑动窗口，分别计算刀盘推力和贯入度的移动平均值，且推力窗口相对于贯入度滞后一个时间公式为

$$LAFPI = \sum_{i=t-2}^{t} F_{i+1}/P_i \tag{1}$$

式中，t 为当前时刻；F_i 为 i 时刻的刀盘推力(kN)；P_i 为 i 时刻的贯入度(mm)。

这一设计具备如下优势：第一，引入均值平滑处理，有效抑制短期噪声干扰；第二，时间窗口的错位设置使得所计算的 *LAFPI* 具备一定的“前导”性质，可用于预测即将到来的围岩类型；第三，较短的窗口长度避免了历史数据对当前预测的过度“稀释”，提高了响应的灵敏性。

基于训练集中超过 800 万条的数据样本，计算了 *LAFPI* 指标，并根据围岩类别划分为Ⅱ类与Ⅲ类围岩和Ⅳ类与Ⅴ类围岩两组，绘制不同围岩类型的 *LAFPI* 概率分布及危险区划分图(见图 11)。结果表明，Ⅱ类与Ⅲ类围岩和Ⅳ类与Ⅴ类围岩的 *LAFPI* 值均近似服从正态分布，但Ⅳ类与Ⅴ类围岩对应的分布均值明显小于Ⅱ类与Ⅲ类围岩。我们选择将Ⅳ类与Ⅴ类围岩的 80%分位数与Ⅱ类与Ⅲ类围岩的 20%分位数作为危险区边界，主要基于以下考虑：更严格的分位数(如 90%与 10%)虽能提高识别准确性，但会导致危险区范围过大，产生过度预警；而放宽分位数(如

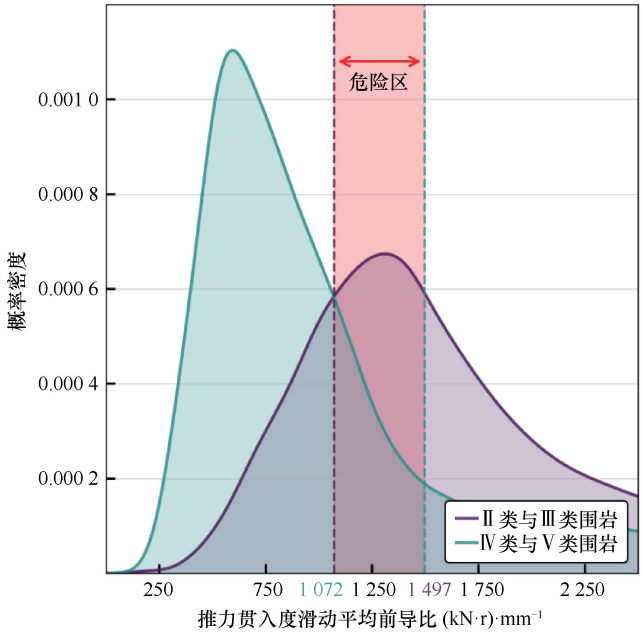


图 11 不同围岩类型的 *LAFPI* 概率分布及危险区划分

Fig. 11 Probability distributions of *LAFPI* for different surrounding rock type with risk zone indication

75%与 25%)则降低预警准确性。综合考虑预警效果与范围控制，80%与 20%分位数在试验中对应的危险区长度约为 225，占比约 20%，与异常分布比例基本匹配，能有效兼顾安全性与实用性。并据此提出如下操作建议：第一，*LAFPI* 大于 1 487(kN·r/mm)：对应Ⅱ类与Ⅲ类围岩，掘进较为安全，操作员应根据 *LAFPI* 变化情况，保持推力与转速在适当范围内；第二，*LAFPI* 小于 1 072(kN·r/mm)：对应Ⅳ类与Ⅴ类围岩，设备负载变化显著，需注意运行状态，操作员应根据 LAFPI 变化情况，保持推力与转速在适当范围内；第三，*LAFPI* 大于 1 072(kN·r/mm)小于 1 497(kN·r/mm)：可能处于岩性突变区，操作人员应高度关注掌子面围岩变化，及时采取围岩加固等措施，预防卡机等突发风险

4 结 论

依托某输水隧洞工程中的 TBM 运行参数，建立了聚类算法和迁移学习耦合的 TBM 掘进参数预测框架：先使用 K-Means 算法划分刀盘推力上升段数据的变化形态子数据库，在使用迁移学习训练基于 ResNet50 的新数据变化形态预测模型，最后使用集成训练方法构建刀盘推力预测模型。主要结论如下。

(1)采用 K-Means 聚类方法，基于推力和扭矩构建了变化形态分类模型，建立了包含形态变化信息的子数据库；采用 ResNet 构建了形态变化预测模型，并采用集成学习方法构建了参数预测模型。将两者耦合后应用于各子数据库，建立了刀盘推力预测模型。

(2)引入推力贯入滑动平均前导比(*LAFPI*)，实现对围岩类型突变的有效识别。结果显示 *LAFPI* 在Ⅱ类与Ⅲ类围岩和Ⅳ类与Ⅴ类围岩中均近似服从正态分布，设定Ⅳ类与Ⅴ类围岩 80%分位数和Ⅱ类与Ⅲ类围岩 20%分位数为危险边界，能够有效应用于长距离输水隧洞中软硬交错岩层的掘进过程，为 TBM 安全运行提供可靠预警支持。

(3)刀盘推力预测模型在某些变化形态子数据库上的预测精度可进一步提升，且当前框架未能根据数据扩充策略的效果反馈动态调整子数据集的划分，子数据库划分准确性仍有待提高。

参考文献(References)：

[1] 陈云，李骏熙，晋良海，等. 地下洞室有限空间内施工机械调度优化仿真[J]. 水力发电学报，2025，44(3)：128-138.
CHEN Yun，LI Junxi，JIN Lianghai，et al. Simulation and optimization of construction machinery scheduling in confined space of underground caverns [J]. Journal of Hydroelectric Engineering，2025，44(3)：128-138.

[2] 张中昊，李赛，汪可欣. 蠕滑-地震动联合作用下跨断层输水隧洞衬砌结构损伤分析[J]. 振动与冲击，2025，44(4)：275-285.
ZHANG Zhonghao，LI Sai，WANG Kexin. Damage analysis of lining structure of cross-fault water conveyance tunnel under the combined action of creep and ground motion [J]. Journal of Vibration and Shock，2025，44(4)：275-285.

[3] 朱明星，王东，陈浩哲，等. 悬臂掘进机" S" 形开挖路径对小断面软岩输水隧洞稳定性的影响[J]. 水力发电，2025，51(3)：57-63.
ZHU Mingxing，WANG Dong，CHEN Haozhe，et al. Influence of s-shaped excavation path of roadheader on the stability of small-section soft rock water-conveyance tunnel [J]. Water Power，2025，51(3)：57-63.

[4] 王文正，林雪冰，郭飞，等. 小转弯半径叠落盾构隧道施工相互影响研究[J]. 水利水电技术(中英文)，2024，55(10)：109-123.
WANG Wenzheng，LIN Xuebing，GUO Fei，et al. Study on construction interaction of shield tunnel with overlapping curves of small turning radius [J]. Water Resources and Hydropower Engineering，2024，55(10)：109-123.

[5] 叶万军，成炜康，陈笑楠，等. 砂卵石地层大直径盾构工程地表沉降深度学习预测[J]. 中国安全生产科学技术，2023，19(8)：124-129.
YE Wanjun，CHENG Weikang，CHEN Xiaonan，et al. Deep learning and prediction on surface subsidence of large-diameter shield project in sandy cobble stratum [J]. Journal of Safety Science and Technology，2023，19(8)：124-129.

[6] 张鹏翔，任亚坤. 白云机场超浅埋隧道盾构始发掘进技术探讨[J]. 水利规划与设计，2024(2)：123-126.
ZHANG Pengxiang，REN Yakun. Discussion on shield launching and tunneling technology of ultra shallow tunnel in Baiyun Airport[J]. Water Conservancy Planning and Design，2024(2)：123-126.

[7] 秦灏. 基于自动深度学习盾构掘进姿态预测与控制[J]. 城市道桥与防洪，2024(2)：200-205.
QIN Hao. Prediction and control of shield tunneling attitude based on automatic deep learning [J]. Urban Roads Bridges & Flood Control，2024(2)：200-205.

[8] PAN Yue，ZHOU Xiaojing，QIU Shuigen，et al. Time series clustering for TBM performance investigation using spatio-temporal complex networks [J]. Expert Systems with Applications，2023，225：120100.

[9] PAN Yue，WU Maozhi，ZHANG Limiao，et al. Time series clustering-enabled geological condition perception in tunnel boring machine excavation [J]. Automation in Construction，2023，153：104954.

[10] YU Honggan, TAO Jianfeng, HUANG Xing, et al. A field parameters-based method for real-time wear estimation of disc cutter on TBM cutterhead [J]. Automation in Construction, 2021, 124: 103603.

[11] GAO Xianjie, SHI Maolin, SONG Xueguan, et al. Recurrent neural networks for real-time prediction of TBM operating parameters [J]. Automation in Construction, 2019, 98: 225-235.

[12] ZHANG Qiaoli, 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.

[13] SHI Gang, QIN Chengjin, TAO Jianfeng, et al. A VMD-EWT-LSTM-based multi-step prediction approach for shield tunneling machine cutterhead torque [J]. Knowledge-Based Systems, 2021, 228: 107213.

[14] ZHANG Xinyue, ZHANG Xiaoping, YU Honggan, et al. A confident learning-based support vector machine for robust ground classification in noisy label environments [J]. Tunnelling and Underground Space Technology, 2025, 155: 106128.

[15] YANG Taihua, WEN Tian, HUANG Xing, et al. Predicting Model of dual-mode shield tunneling parameters in complex ground using recurrent neural networks and multiple optimization algorithms [J]. Applied Sciences-Basel, 2024, 14(2): 1-9.

[16] KIM Yunhee, HONG Jiyeon, SHIN Jaewoo, et al. Shield TBM disc cutter replacement and wear rate prediction using machine learning techniques [J]. Geomechanics and Engineering, 2022, 29(3): 249-258.

[17] 王宇超，谢雄耀，黄昌富，等. 基于混合深度学习算法的盾构运动轨迹实时预测[J]. 地下空间与工程学报，2024，20(S1)：59-69.
WANG Yuchao, XIE Xiongyao, HUANG Changfu, et al. Real time prediction of shield tunneling trajectory based on hybrid deep learning algorithm[J]. Chinese Journal of Underground Space and Engineering, 2024, 20(S1): 59-69.

[18] QIN Chengjin, SHI Gang, TAO Jianfeng, et al. RCLSTMNet: A residual-convolutional-LSTM neural network for forecasting cutterhead torque in shield machine [J]. International Journal of Control Automation and Systems, 2024, 22(2): 705-721.

[19] FU Xianlei, PONNARASU S, ZHANG Limiao, et al. Online multi-objective optimization for real-time TBM attitude control with spatio-temporal deep learning model [J]. Automation in Construction, 2024, 158: 105220.

[20] 陈城，史培新，王占生，等. 基于融合多注意力机制的深度学习的盾构荷载预测方法[J]. 东北大学学报(自然科学版)，2023，44(11)：1631-1637.
CHEN Cheng, SHI Peixin, WANG Zhansheng, et al. Shield load prediction method based on deep learning with multiattention mechanism [J]. Journal of Northeastern University (Natural Science), 2023, 44(11): 1631-1637.

[21] 李港，李晓军，杨文翔，等. 基于深度学习的 TBM 掘进参数预测研究[J]. 现代隧道技术，2020，57(5)：154-9.
LI Gang, LI Xiaojun, YANG Wenxiang, et al. Research on prediction of tbm driving parameters based on deep learning [J]. Modern Tunnelling Technology, 2020, 57(5): 154-9.

[22] 姚敏，李旭，原继东，等. 基于 TBM 破岩数据的岩体条件深度学习表征方法[J]. 地球科学，2022，48(5)：1908-1922.
YAO Min, LI Xu, YUAN Jidong, et al. Deep learning characterization method of rock mass conditions based on TBM rock breaking data [J]. Editorial Committee of Earth Science-Journal of China University of Geosciences, 2022, 48(5): 1908-1922.

[23] LI Zhiqiang, TAO Yufan, DU Yuchao, et al. Classification and prediction of rock mass boreability based on daily advancement during TBM tunneling [J]. Buildings, 2024, 14(7).

[24] 周鲁，刘胜利，王宇超，等. 基于机器学习的盾构开挖面地质类型智能识别研究[J]. 建筑施工，2025，47(1)：17-22.
ZHOU Lu, LIU Shengli, WANG Yuchao, et al. Study on intelligent recognition of geological types in shield excavation face using machine learning [J]. Building Construction, 2025, 47(1): 17-22.

[25] 赵先琼，邓志强，邓朝晖，等. 基于深度学习的 TBM 密集岩碴片图像分割[J]. 哈尔滨工程大学学报，2022，43(3)：399-406.
ZHAO Xianqiong, DENG Zhiqiang, DENG Zhaohui, et al. Image segmentation of TBM dense rock detritus based on deep learning [J]. Journal of Harbin Engineering University, 2022, 43(3): 399-406.

[26] 王宇超，谢雄耀，黄昌富，等. 基于混合深度学习算法的盾构运动轨迹实时预测[J]. 地下空间与工程学报，2024，20(z1)：59-69.
WANG Yuchao, XIE Yiongyao, HUANG Changfu, et al. Real time prediction of shield tunneling trajectory based on hybrid deep learning algorithm [J]. Chinese Journal of Underground Space and Engineering, 2024, 20(z1): 59-69.

[27] 李培楠，刘学，戴泽余，等. 基于混合深度学习的盾构掘进姿态和位置的动态预测[J]. 东华大学学报(自然科学版)，2024，50(3)：145-152.
LI Peinan, LIU Xue, DAI Zeyu, et al. Dynamic prediction for attitude and position in shield tunneling based on hybrid deep learning method [J]. Journal of Donghua University (Natural Science Edition), 2024, 50(3): 145-152.

[28] SUN Mingshe, CHEN Song, HE Huafei, et al. Classification and prediction of rock mass drillability for a tunnel boring machine based on operational data mining [J]. Frontiers in Earth Science, 2024, 12: 1518844.

[29] LI Long, LIU Zaobao, FANG Xingli, et al. Multi-step real-time prediction of hard-rock TBM penetration rate combining temporal convolutional network and squeeze-and-excitation block [J]. Scientific Reports, 2024, 14(1): 14326.

[30] WANG Qiang, XIE Xiongyao, YU Hongjie, et al. Predicting slurry pressure balance with a long short-term memory recurrent neural network in difficult ground condition [J]. Computational Intelligence and Neuroscience, 2021, 2021: 6678355.

[31] CHEN Long, TIAN Zhiyao, ZHOU Shunhua, et al. Attitude deviation prediction of shield tunneling machine using Time-Aware LSTM networks [J]. Transportation Geotechnics, 2024, 45: 101195.

[32] MO Deyun, BAI Liping, HUANG Weiran, et al. TBM disc cutter wear prediction using stratal slicing and IPSO-LSTM in mixed weathered granite stratum [J]. Tunnelling and Underground Space Technology, 2024, 148: 105745.

[33] JIN Junwei, JIN Qianqian, CHEN Jian, et al. Prediction of the tunnelling advance speed of a super-large-diameter shield machine based on a KF-CNN-BiGRU hybrid neural network [J]. Measurement, 2024, 230: 114517.

[34] ZHENG Zhe, LUO Kaidi, TAN Xianzhong, et al. Autonomous steering control for tunnel boring machines [J]. Automation in Construction, 2024, 159: 105259.

[35] ZHANG Minggong, JI Ankang, ZHOU Chang, et al. Real-time prediction of TBM penetration rates using a transformer-based ensemble deep learning model [J]. Automation in Construction, 2024, 168(Part A): 105793.

（责任编辑　李贶家）