

基于 TBM 刀盘振动的 WSN-LSTM 围岩感知模型

龚秋明¹, 李顺文¹, 黄流¹, 王驹^{2,3}, 曹子祥¹, 马洪素^{2,3}

(1. 北京工业大学 城市与工程安全减灾教育部重点实验室, 北京 100124; 2. 核工业北京地质研究院, 北京 100029; 3. 国家原子能机构高放废物地质处置创新中心, 北京 100029)

摘要: 针对现有基于 TBM 振动信号的围岩识别方法在特征提取有效性和工程适应性方面的不足, 提出了一种基于 TBM 刀盘振动的小波散射网络 (WSN) 和长短期记忆网络 (LSTM) 的围岩感知方法。首先, 依托北山地下实验室螺旋斜坡道工程, 在 TBM 刀盘上安装振动监测系统, 采集 TBM 掘进过程中的振动信号, 通过稳定段提取、降噪、分割等数据预处理方法, 并匹配隧道沿线地质信息, 建立了基于刀盘振动的岩体感知数据库。其次, 利用 WSN 对振动信号进行多尺度时序特征提取, 以增强特征的表达能力与抗噪能力, 并利用 LSTM 捕捉时序依赖关系的优势, 构建了 WSN-LSTM 围岩感知模型。研究表明, WSN-LSTM 模型在测试集上的准确率达到 93.7%, 相较于基于小波散射网络的支持向量机 (SVM) 模型提高了 5.6 个百分点, 且高于基于幅值域统计特征提取下的浅层机器学习模型 (随机森林与 LightGBM), 验证了 WSN 对刀盘振动信号特征提取的优势, 以及捕捉刀盘振动特征时序依赖的必要性。

关键词: TBM; 围岩感知; 振动监测系统; 小波散射网络; 深度学习

中图分类号: U45, TP181

文献标志码: A

doi:10.13705/j.issn.1671-6833.2026.04.020

TBM (隧道掘进机) 在施工过程中的地质信息主要来源于前期的地质勘查报告, 操作人员难以及时获取掌子面前方地质条件, 导致支护决策不准确和掘进参数调整不合理等问题, 而要改善这些问题则需探究一种快速准确获取岩体信息的方法。

TBM 掘进实际上是 TBM 与岩体相互作用的过程, 掘进参数在一定程度上反映了岩体信息, 因此基于掘进参数的机器学习围岩识别方法被广泛提出^[1-3]。现有研究表明, 影响该方法识别效果的关键因素主要有两个^[4]: 一是输入端的特征选择与数据预处理方法; 二是算法选择与模型框架。但随着后续不同数据处理方案被提出, 以及机器学习领域的高速发展, 该方法的总体识别精度并没有显著提高, 因此在实际工程中没有得到广泛应用。主要原因在于掘进参数主要是岩机相互作用的间接参数, 具有多解性, 且人为操作因素对掘进参数影响较大。

随着传感器、通信等技术快速发展, 使得通过在 TBM 各部位安装传感器以获取岩机相互作用更为

直接相关的参数成为可能。其中振动信号^[5] 以其与围岩条件有着较强的相关性、时效性强、监测方便等优点受到了广泛关注。Gong 等^[6]、李宗林等^[7]、杨亚磊等^[8] 分别在 TBM 刀盘、主机和主梁上安装振动传感器并进行了现场试验, 揭示了在不同掘进参数与地质条件下的 TBM 振动响应规律。TBM 刀盘位于掘进机的最前端, 与掌子面岩体直接接触, 最能直接反映岩体条件^[9]。刘东鑫等^[10] 通过计算刀盘振动时间窗口长度与振动均方根的变异系数, 得出刀盘旋转一周后各项特征基本趋于稳定的规律。Tang 等^[11] 将原始刀盘振动信号分割后直接输入 1DCNN-BiLSTM 神经网络模型, 虽然在测试集上取得了 90% 以上的准确率, 但现场 TBM 施工的原始振动信号信息维度高, 并且呈现典型的非平稳、非线性特征, 直接使用原始信号输入不仅显著增加计算负担, 而且可能导致模型对无关噪声的过拟合。如何有效且准确地提取振动信号中与破岩相关的特征成为了一大难题。

收稿日期: 2026-03-24; 修订日期: 2026-04-11

基金项目: 国家自然科学基金资助项目 (52438005)

作者简介: 龚秋明 (1969—), 男, 湖南安化人, 北京工业大学教授, 博士, 博士生导师, 主要从事 TBM 智能化施工方面的研究, E-mail: gongqiuming@bjut.edu.cn。

引用本文: 龚秋明, 李顺文, 黄流, 等. 基于 TBM 刀盘振动的 WSN-LSTM 围岩感知模型 [J]. 郑州大学学报 (工学版), 2026, 47 (4): 00-00. [Gong Qiuming, Li Shunwen, Huang Liu, et al. Surrounding rock mass sensing model based on TBM cutterhead vibration using WSN-LSTM [J]. Journal of Zhengzhou University (Engineering Science), 2026, 47 (4): 00-00.]

目前对于 TBM 振动特征的处理方法大致可以分为两类。一类是基于幅值域的分析方法,如 Tang 等^[12]、吴优等^[13]、Fang 等^[14]通过提取方差、均方根、峰峰值等时域特征以及将时域信号进行傅里叶变换后所提取的偏度、均方频率等频域特征作为模型的输入,这些特征虽然计算简单但无法获取非平稳信号中的非线性关系和时间序列中的局部特征,容易丢失有用信息。同时该方法还需依据专家经验,根据不同的数据类型挑选不同特征,这些缺点导致训练后的模型泛化能力差,且性能在很大程度上依赖手工设计特征的质量。另一类是通过 Wigner-Ville 分布^[15]、小波分析^[16]等方法将一维的时域与频域信号映射到二维的时频域平面,并转化为图像输入到深度学习模型中,Liu 等^[16]通过小波变换将信号转换为时频图像,结合 ResNet-18 建立岩体分类模型,准确率高达 98%。但吴优等^[13]通过复现该方法,在不同项目的数据集上仅有 77% 的准确率,表明该方法虽能同时展示信号的时频域信息,但对于复杂和多样化的 TBM 振动信号存在适应性较差的缺点。

2012 年 Mallat^[17]提出了小波散射网络(wavelet scattering network)并对其进行了严格的数学证明。这是一种基于小波变换思想与深度学习思想相结合的卷积网络,能够在不需要训练的情况下提取稳定且具备平移不变性的多尺度时序特征,同时降低噪声干扰。樊鑫等^[18]和 Andén 等^[19]使用该网络与浅层机器学习相结合,证明了基于小波散射网络特征提取后的分析判别方法对于非平稳的煤矿微震信号、经典音乐分类数据集和通话语音数据集都有 90% 以上的准确率,验证了该网络在处理不同类别复杂振动信号上的鲁棒性。TBM 振动信号为典型时序信号,经过小波散射提取后的特征具有时序性,而像 LSTM^[20]等具有长时依赖建模能力的深度学习模型往往有着更好的效果。

综上所述,现有基于幅值域的特征提取方法无法同时提取包含时域与频域共同信息,而基于时频域图像的方法对于复杂多样的振动信号适应性差。小波散射网络能够提取稳定且具备平移不变性的多尺度时序特征,同时 LSTM 则擅长建模长时依赖关系。二者结合既能有效抑制噪声、降低计算负担,又能充分挖掘振动信号的动态演化规律。本文依托北山地下实验室螺旋斜坡道工程,在 TBM 刀盘上安装了一套振动监测系统,连续、自动采集 TBM 掘进过程中刀盘三轴振动加速度,并建立了基于刀盘振动的岩体感知数据库。通过使用小波散射网络有效提取了与围岩等级相关的时序特征,并基于此建立深

度学习模型,为基于振动信号进行围岩感知提供了一种新的技术思路。

1 依托工程与振动监测系统搭载

1.1 工程概况

北山地下实验室位于甘肃省酒泉市新市场,是中国首个高放废物地质处置地下设施^[21]。如图 1 所示,该设施包含 3 个竖井、2 个水平实验场地和螺旋斜坡道。螺旋斜坡道主要采用 TBM 法施工,开挖直径 7.03 m,最大倾角 1:10,水平曲线半径 255 m,最大埋深 560 m,全长约 7.47 km,分别连接到 -280 m 和 -560 m 深处的地下实验场地。TBM 施工段跨越 K0+495~K7+473,全长约 6.98 km,埋深 33~560 m。




图 1 北山地下实验室主要结构示意图^[21]

Figure 1 Schematic diagram of the main structure of the Beishan Underground Laboratory^[21]

1.2 螺旋斜坡道沿线岩体条件

螺旋斜坡道主要穿越不同风化等级的花岗岩。岩石单轴抗压强度(UCS)平均约 170 MPa,峰值可达 235 MPa。抗拉强度范围为 6~15 MPa,平均值为 11 MPa。Cerchar 岩石磨蚀指数 CAI 在 4.3~5.3,岩石的磨蚀性极高。地面钻孔揭露岩石质量指数 RQD 大于 90 的区段占隧道总长度的 86%,围岩完整性较好。隧道轴线沿线分布有数条小型断裂带。地下水以裂隙水形式赋存于岩体裂隙及断裂构造中,螺旋斜坡道区段主要表现为干涸或轻微渗水。最大地应力达到 20 MPa。

1.3 TBM 设计参数

螺旋斜坡道采用中国铁建重工集团股份有限公司研制的敞开式硬岩隧道掘进机“北山 1 号”施工。该掘进机配备独特的锥形刀盘,刀盘上共安装 55 把滚刀,包括 4 把直径 45.72 cm 的双联中心滚刀、35 把直径 50.8 cm 的面板刀,以及 12 把直径 50.8 cm 的边刀。刀盘平均刀间距为 60 mm,其中中心滚刀和面板刀采用前置布置,边刀则为后置布置。整机总长约 95 m,开挖直径为 7.03 m。刀盘最大转速为

10 转/min,最大推进力可达 23 562 kN,额定扭矩为 5 160 kN·m,推进油缸的最大行程为 1.8 m。

1.4 TBM 刀盘振动监测系统搭建

在“北山 1 号”敞开式 TBM 上,安装了一套由北京工业大学和北京玖瑞科技有限公司自研的振动监测系统^[6],布置图如图 2 所示。该监测系统已经经过室内旋转实验平台的验证并且在多个工程项目上进行了成功的应用,充分验证了监测系统的可靠性与准确性。振动传感器量程为 200g,采样频率为 3 200 Hz。振动传感器被固定于刀盘溜渣板背面,距刀盘正中心约 2 m,可有效避免掘进过程中渣片对传感器的冲击以及对刀具更换的干扰。TBM 初期掘进阶段监测到的刀盘振动最大幅值约为 62g、最大主振频率约为 1 340 Hz,证明传感器量程满足日常监测的需求。




图 2 TBM 刀盘振动监测系统布置图

Figure 2 Layout diagram of the TBM cutterhead vibration monitoring system

振动监测系统主要由 3 个模块组成:数据获取模块、通信与控制模块,以及数据处理与显示模块,系统结构图如图 3 所示。数据获取模块通过三轴加速度传感器、时钟芯片和储存器采集并存储数据。通信与控制模块负责上位机与数据获取模块之间的实时通信,确保数据传输无缝进行;而数据处理与显示模块则内置于主控室的上位机,负责数据的处理、可视化展示及导出,并通过内置信号处理算法对数据进行实时处理。

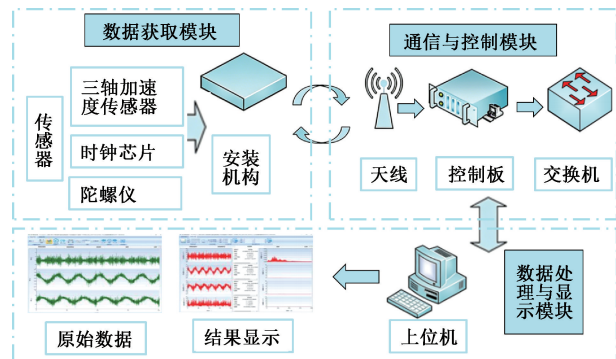


图 3 TBM 刀盘振动监测系统结构图

Figure 3 TBM cutterhead vibration monitoring system layout

系统可每小时自动完成一次校准,并与上位机时钟同步,以确保数据采集的准确性和一致性。校准后的 5 min 内,系统进入连续监测状态,当检测到加速度并持续超过 2 min 时,系统自动连续采集 120 s 的振动数据,随后通过无线网络传输至中心端,再通过网线输入到主控室的上位机中。以上设计确保了所获取的数据能够准确反映 TBM 实际掘进工况,避免了无效或空载数据的干扰,为后续围岩等级智能识别提供了高质量的原始数据支持。

2 基于刀盘振动的围岩感知数据库

2.1 掘进参数预处理

TBM 掘进参数从工控室 PLC 端连续获取,采集频率为 1 Hz,掘进数据每个采样点记录了当前的时间、刀盘推力、刀盘转速等。掘进参数序列数据受到 TBM 动态破岩或者传感器异常等因素的影响,存在一定的噪声,这些噪声会影响后续数据处理的效率和精度。采用 Savitzky-Golay 滤波函数^[22]实现对掘进参数序列的去噪平滑,通过多次对比上升段与稳定段的划分效果后选取窗口长度 15 s、二阶多项式的参数设置进行平滑滤波。在 TBM 掘进过程中,一个完整的掘进循环通常分为空推段、上升段和稳定段,如图 4 所示。采用 Bottom-Up 算法^[23]进行掘进上升段与稳定段的分割,拟合线段数目设置为 10,最大正值斜率拟合线段的末端为分割点。




图 4 完整掘进循环划分

Figure 4 Complete tunneling cycle segmentation

TBM 掘进参数稳定段具有数据更为稳定、可靠性高的优点,能够准确反映刀盘与围岩之间的持续破碎作用及振动响应。为了保证训练样本的稳定性与代表性,本文仅选取 TBM 稳定段的振动数据来构建数据库。

2.2 振动数据预处理

由于振动监测系统的工作环境恶劣,且存在较大的噪声,振动数据需进行一系列预处理。每条刀盘振动原始监测数据为 120 s,但由于振动传感器在

启、停时刻采样数据不稳定,去除振动数据首尾各 10 s 的数据,只保留中间 100 s 数据。当振动时长大于刀盘旋转一周的时间后,振动的各项特征基本趋于稳定^[10],对振动采集时刻的现场刀盘转速进行统计分析,发现刀盘转速大都超过 3 转/min。在刀盘转速为 3 转/min 时刀盘旋转一周的时间为 20 s。为了能合理利用所有数据,同时又不失一般性,选择将 100 s 振动时域数据按照 20 s 的窗口进行分割,相邻窗口重叠 10 s,将一条数据共分割为 9 条 20 s 的振动数据。

为了消除振动传感器偶然误差产生的异常点,通过计算振动数据分位数,寻找前 0.05% 的数据,将这部分数据视为异常值,使用 0 值进行替换。这可以完全去除原始数据中少量的偏离点且极少量的数据缺失不会显著改变数据的整体分布。通过傅里叶变换后,发现原始数据的频域图在低频区间存在较大的直流分量,使用高通滤波并多次试验后将阈值设定为 1 Hz,这时能够刚好去除频域下的直流分量,如图 5 所示。经过上述预处理,最终获得了稳定、可靠的振动数据。




图 5 滤波前后径向振动频域图

Figure 5 Radial vibration frequency domain before and after filtering

2.3 岩体参数获取

在 TBM 掘进过程中,通过地质素描记录隧道洞壁岩体条件。隧道壁岩芯以 50 m 间隔钻孔获取,并进行单轴抗压强度试验,获得岩石强度。本文共统计了 TBM 始发桩号 K0+495 至 K3+196 共 2 702 m 的岩体数据,地质编录区间的围岩按 GB 50487—2008《水利水电工程地质勘察规范》^[24]进行分级,其中 I 级围岩占 13.2%、II 级围岩占 48.3%、III 级围岩占 31.2%、IV 级围岩仅占 7.3%。

2.4 数据库建立

TBM 稳定段数据库中需要同时包含围岩等级与掘进参数稳定段的刀盘振动数据。首先通过掘进参数的掘进里程列与围岩里程分类表相互匹配,这样每条掘进参数都带有围岩等级标签。再通过刀盘振动数据的开始采样时间与位于稳定段的掘进参数的日期时间列进行匹配,保留能够匹配成功的振动数据,即为稳定段的振动数据,再通过所匹配的掘进参数为每条振动数据打上围岩等级标签。最终完成基于稳定段振动数据的岩体感知数据库的构建。数据库的建立流程如图 6 所示。

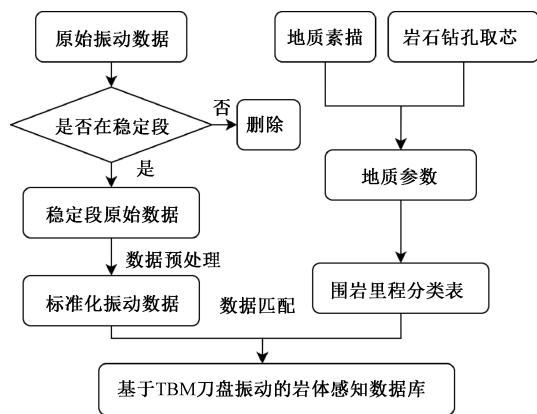


图 6 基于 TBM 刀盘振动的岩体感知数据库建立流程
Figure 6 Workflow of establishing a rock mass sensing database based on TBM cutterhead vibration

本文建立了覆盖始发桩号 K0+495 至 K3+196 全长 2 702 m 掘进过程的完整数据库。共获得刀盘三轴振动原始样本 1 090 条,其中 I 级围岩 162 条、II 级 458 条、III 级 380 条、IV 级 90 条。经分割后,最终形成 9 810 条时序完整的振动数据序列,其中 I 级 1 458 条、II 级 4 122 条、III 级 3 420 条、IV 级 810 条。该数据库为深度学习模型的训练与泛化提供数据支撑。

3 基于 TBM 刀盘振动的 WSN-LSTM 围岩感知模型

3.1 WSN-LSTM 围岩感知模型框架

基于 TBM 刀盘振动的围岩感知模型的框架如图 7 所示。该模型将小波散射网络和长短期记忆网络相结合。首先,将预处理后的刀盘三向振动信号分别输入小波散射网络,以自动提取不同尺度下同时包含时域与频域信息的多维特征。随后,将这些时序特征分别送入 3 个并联的 LSTM 层进行深层时序建模,并在全连接层中完成特征融合。最终,通过输出层的全连接结构实现围岩类别的判别。模型训练过程均基于 Pytorch 框架和 Python3.8 语言环境实现。

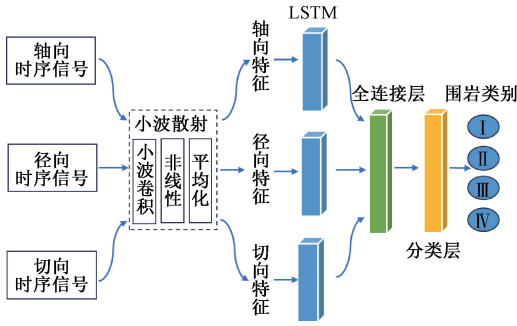


图7 基于TBM刀盘振动的围岩感知模型框架

Figure 7 Framework of the rock mass sensing model based on vibration of TBM cutterhead

3.2 算法简介

3.2.1 小波散射网络

小波散射网络 (WSN)^[17] 是一种融合小波变换与卷积神经网络 (CNN) 思想的深度学习模型, 该模型通过多频带多层小波分解与小波基平移卷积操作, 提取信号全局信息与局部细微变化的特征, 兼具噪声鲁棒性; 同时借助池化操作压缩特征冗余, 提升后续模型的计算效率与泛化能力。与传统 CNN 不同, WSN 可无监督地从原始信号中自动提取时频域多尺度特征, 其平移不变性与稳定性使其在时变信号处理、长时序分析等任务中具备显著优势。

3.2.2 长短时记忆网络

长短期记忆网络 (LSTM)^[20] 通过引入记忆单元与门控机制, 解决了循环神经网络的梯度消失问题, 可有效捕获时序数据的长短期依赖, 适配非线性高维时序应用场景, 同时结合小波散射特征, 可充分挖掘时序依赖、揭示围岩-振动响应的非线性规律, 有效提升围岩感知的精度与鲁棒性。

3.2.3 小波散射网络对典型 TBM 刀盘振动信号的特征提取分析

为了验证小波散射网络对 TBM 刀盘振动特征的代表能力, 将不同频率与幅值的原始振动信号输入小波散射网络, 将输出的包含时间尺度与频率尺

度的二维振动特征以热图形式进行可视化, 如图 8 所示。由图 8 可知, 随着频率增加, 能量由低频尺度向高频尺度集中, 且特征波动更为明显; 而随着振幅增大, 对应频率部位能量变高。




图8 特性差异对比图

Figure 8 Comparison of characteristic differences

刀盘振动主要由滚刀破岩直接产生, 因此在不同围岩等级所产生的振动信号表现不同, 围岩等级从 I 至 IV 级的典型振动时域信号如图 9 所示。




图9 不同围岩等级的典型径向振动时域信号

Figure 9 Typical radial time-domain vibration signals in different surrounding rock mass classes

将轴向、径向、切向的三轴振动时序信号按照最优超参数输入小波散射网络进行振动信号特征提取, 小波散射热图如图 10 所示。

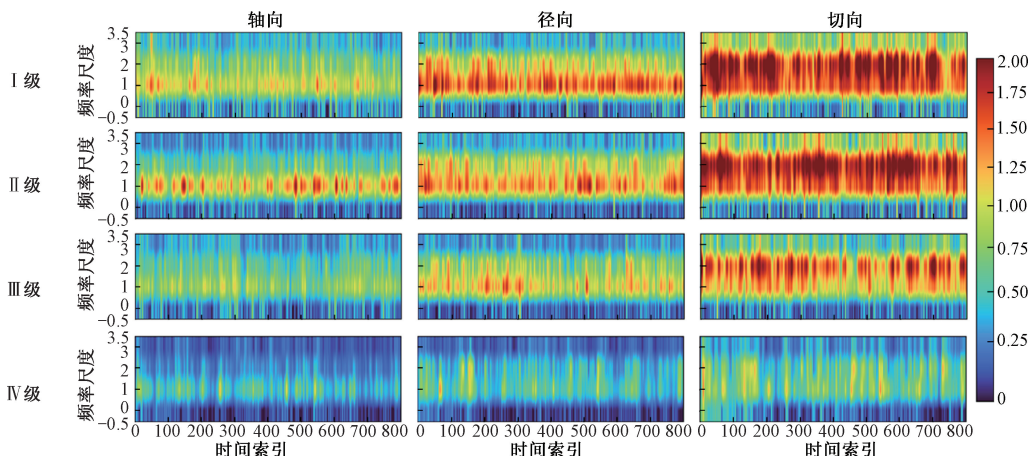


图10 不同围岩等级的典型三向小波散射系数热图

Figure 10 Typical three-directional wavelet scattering coefficient heatmaps in different surrounding rock mass classes

图 10 中小波散射网络最优的超参数小波尺度、滤波器数目和最大散射阶数寻优方法和结果详见 4.1 节。对图 10 中三轴振动下的小波散射热图进行对比分析发现,切向始终呈现最高的频率幅值与最宽的尺度带,尤以 I、II 级围岩最为显著;径向次之,轴向整体最弱,轴向能量主要汇聚于低频区间。随着围岩等级由 I 至 IV 级降低,三向谱图的幅值与所处的频率尺度都整体递减,其中 IV 级三向均以低频能量为主。从时间演化看, I、II 级在三向上表现为较为平稳、连续的能量分布, III 级出现间歇性增强, IV 级最为稀疏且能级最低。这一规律与破岩过程相符:高完整性岩体需要更大的刀盘扭矩与刀盘推力,刀盘-岩体接触刚度、剪切耦合强,因而形成连续且宽带的高能量谱;随着围岩完整性降低,切削阻力降低,接触不稳定与裂隙等导致能量呈现间歇性释放,最终表现为低能且断续的谱特征。

通过上述分析可以说明小波散射网络能够充分捕捉不同振动强度下信号的时域和频域信息。

4 围岩等级感知模型测试及结果分析

4.1 WSN-LSTM 围岩等级感知模型训练

将 3 个方向的振动时域数据作为输入,围岩等级作为输出,设定训练集与测试集的比例为 8:2。为了消除单次数据划分带来的随机性影响,本文采用了 5 折交叉验证。5 折交叉验证平均准确率为 $93.7\% \pm 0.5\%$,模型性能不受数据划分方式影响。鉴于 IV 类岩体样本数量相对较少,针对数据集不平衡问题,目前常见的策略有合成采样法、加权损失函数法与重复采样法^[25]。考虑到振动数据的复杂性,采用合成采样法对数据进行过采样可能会产生不符合实际破岩机理的虚假时序特征,从而对模型判别边界产生干扰。对比加权损失函数法与重复采样法的模型效果后发现,重复采样法能够获得更优的整体分类性能,尤其在 IV 类的识别效果上更为稳定。其中可能的原因为小波散射网络具备平移不变性和稳定性,对原始信号中的随机噪声具有一定的抑制作用。虽然数据被重复了,但输入的特征已经经过了小波的去噪,降低了噪声被放大的风险。因此选择对 IV 类岩体在训练集与测试集中的数据进行了重复采样,确保 IV 类岩体数据的数量与 I 类岩体数据在数据集中的比例相当。

在训练过程中,采用 Adam 优化器更新网络参数,以最小化交叉熵损失(cross entropy loss)函数来优化模型性能。其中,Adam 优化器一阶矩与二阶矩估计的指数衰减率 β_1 和 β_2 分别设置为 0.9 和

0.999。为防止模型在训练过程中出现过拟合或性能退化,引入基于验证集的检查点机制,每隔 5 个 *epoch* 在验证集上进行一次性能评估,当验证指标优于当前最优结果时自动保存模型参数;若验证集损失在连续 10 个 *epoch* 内没有改进,则提前终止训练。模型训练的批量大小设置为 64。

本文针对小波散射网络和长短期记忆网络模型分别构建了参数搜索空间,并采用以验证集 *F1* 分数为核心评价指标进行辅助,以训练时间、收敛迭代次数作为次要评价指标的两阶段网格搜索方法进行参数寻优。在第一阶段,采用较大搜索步长对参数空间进行粗粒度遍历,以快速缩小候选范围,并依据验证集 *F1* 分数对所有组合进行排序,筛选性能排名前 30% 的候选配置进入下一阶段。在第二阶段,进一步缩小搜索步长,开展细粒度网格搜索,最终确定最优超参数配置。小波散射网络部分最优超参数为小波尺度 3、滤波器数目 2、最大散射阶数 2; LSTM 部分最优参数为隐藏层特征维度 256、隐藏层层数 2、输出特征维度 128,学习率 0.001。

在最优组合下小波散射网络的验证集加权 *F1* 分数达 0.93,高于其他组合的 0.83~0.9,且单样本特征提取时间仅 0.8 s; LSTM 在该组合下的验证集上的过拟合程度最低,其中训练集 *F1* = 0.95,验证集 *F1* = 0.93,差值仅 0.02,且收敛迭代次数为 38 次,效率优于其他组合的 45~60 次。最后计算在测试集上的准确率(*Accuracy*)、精确率(*Precision*)、召回率(*Recall*)、*F1* 分数等模型评价指标来评估围岩等级识别结果的性能^[26],如式(1)~(4)所示:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}; \quad (1)$$

$$Precision = \frac{TP}{TP + FP}; \quad (2)$$

$$Recall = \frac{TP}{TP + FN}; \quad (3)$$

$$F1 = \frac{2Precision \cdot Recall}{Precision + Recall}。 \quad (4)$$

算法 1 WSN-LSTM 围岩感知算法

输入:径向振动信号 X_r 、切向振动信号 X_t 、轴向振动信号 X_a 、围岩标签 Y 、学习率 η 、批大小 N 、训练轮数 E ;

输出:围岩等级分类结果 \hat{Y} 、最优模型权重 w_{best} 。

① for *epoch* in 1 to E : //训练模型

② $F_{r} = \text{wsn}(X_r)$ 、 $F_{t} = \text{wsn}(X_t)$ 、 $F_{a} = \text{wsn}(X_a)$; //对三轴时序信号分别进行小波散射变

换,提取特征

③ $H_r = \text{LSTM}(F_r)$ 、 $H_t = \text{LSTM}(F_t)$ 、 $H_a = \text{LSTM}(F_a)$; //三通道 LSTM 时序建模

④ $H_{\text{fusion}} = \text{concat}(H_r, H_t, H_a)$ 、 $H_{\text{fc}} = \text{ReLU}$ (全连接层 1(H_{fusion}))、 $\hat{Y} = \text{softmax}$ (全连接层 2(H_{fc})); //特征融合与分类

⑤ $L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^4 y_{i,c} \cdot \log \hat{y}_{i,c}$; //计算当前批次损失 L

⑥ $w = w - \eta \cdot \nabla L(w)$; //更新模型权重

⑦ 每训练 5 轮,在验证集评估模型并保存当前最优权重;

⑧ Return \hat{Y} 、 w_{best} ;

4.2 WSN-LSTM 模型测试结果

使用混淆矩阵对在测试集中的模型性能进行评估,如图 11 所示。测试集各类围岩等级的精确率、召回率和 $F1$ 分数,如表 1 所示。




图 11 WSN-LSTM 模型混淆矩阵

Figure 11 Confusion matrix of the WSN-LSTM model

表 1 WSN-LSTM 模型围岩感知结果

Table 1 Results of surrounding rock mass sensing based on the WSN-LSTM model

围岩等级	精确率/%	召回率/%	$F1$ 分数/%
I	92.4	90.7	91.5
II	92.5	92.6	92.5
III	94.0	93.7	93.8
IV	98.1	100	99.0

模型测试结果表明,基于小波散射网络和长短期记忆网络的围岩感知模型在性能上表现出色,整体准确率达到 93.7%,验证了小波散射网络能够有效捕捉不同围岩条件下刀盘振动的有效特征。在不同围岩等级的识别中,模型的精确率、召回率和 $F1$ 分数均超过 90%,表现出较高的精度和较低的误分类率。模型在 I 类与 II 类围岩的识别相对较弱,而 IV 类围岩的识别效果最佳。可能的原因在于 I 类和 II 类围岩具有较好的岩体完整性,导致在滚刀破岩

过程中的振动响应差异不显著,因此模型在类别边界处容易将 I 类样本误判为 II 类。而 IV 类围岩较为破碎,且节理数量较多,破岩过程伴随更强烈且不规则的振动响应,从而更易被模型识别。

4.3 训练样本规模对模型性能影响

抽取了现有训练集的 20%、40%、60%、80%、100% 按照相同的训练方法进行训练,并在同一测试集上评估分类性能,其准确率分别为 75.6%、87.2%、93%、93.5%、93.7%。结果显示随着训练样本量的增加,测试集准确率呈现逐步上升趋势;其中在 20%~60% 提升较为显著,而在 60% 以后趋于平稳。证明模型在小样本下也具有鲁棒性,同时现有样本规模满足模型训练需求。

4.4 基于小波散射网络的 SVM 对照分类模型

近年来支持向量机(SVM)分类算法被广泛应用于解决非线性、高维的模式识别问题^[27]。使用相同的数据集,将小波散射网络提取后的三向特征输入 SVM 模型,并按照相同的训练方法进行训练。最终得到模型在测试集下的混淆矩阵如图 12 所示,训练模型的准确率为 88.1%。




图 12 WSN-SVM 模型混淆矩阵

Figure 12 Confusion matrix of the WSN-SVM model

基于小波散射网络的 SVM 对照分类模型相较于小波散射网络与 LSTM 的组合模型的准确率下降了 5.6 个百分点。结果表明,LSTM 通过门控机制对长短期时序依赖进行建模,能够有效捕捉振动特征随掘进过程逐步演化的动态模式,从而更准确地反映刀盘-围岩相互作用过程的连续性。相比之下,SVM 将散射特征视为相互独立的样本进行判别,忽略了特征之间的时序关联性,导致表征能力受限。对于 TBM 振动的时序特征,仅依赖静态判别边界的分类方法难以充分刻画信号中蕴含的时序演化信息。

4.5 基于幅值域下的浅层机器学习模型

按照相同的数据处理方式从分割后的 20 s 振动信号中分别提取出 3 个不同方向上的最大值、方

差、均方根等 11 个常用时域特征,以及频谱均值、均方根频率、重心频率等 13 个常用频域特征。已有研究表明,在浅层机器学习模型中随机森林与 LightGBM 模型在基于幅值域下的分类任务中表现良好^[12],将时频域特征分别输入其中,并按照 4.1 节中相同方法训练模型。随后使用随机森林的基尼重要性排序功能选择重要性排名前 15 的切向重心频率、轴向偏度等时频域特征重新作为模型的输入训练模型。最终得到模型在测试集上的结果如表 2 所示。

表 2 浅层机器学习模型测试结果

Table 2 Test results of shallow machine learning models

模型	精确率/%	F1/%
随机森林	78.3	77.7
特征选取下的随机森林	80.7	80.2
LightGBM	75.7	74.8
特征选取下的 LightGBM	85.3	84.9

基于幅值域的浅层机器学习方法在选取特征后均能不同程度地提升模型性能,表明当输入维度较低时模型表现更优,而随着输入维度增大,模型会出现特征交互不足的问题。其次,若仅对振动信号进行简单的时频域特征提取,容易引入与围岩等级无关的冗余信息,并破坏原始振动信号的时序性,从而削弱模型的判别能力。同时,传统特征工程依赖专家经验,需要为不同数据类型设计专门的特征,这不仅耗时且高度依赖领域知识,模型的泛化性往往受限于所设计特征的质量。相比之下,小波散射特征有着更强的特征表达能力,同时与神经网络的结合使信号的特征提取和模式识别主要由算法自动完成,降低了人为偏差,具有较强的自适应学习能力。

5 结论

本文依托北山地下实验室螺旋斜坡道工程,通过在 TBM 刀盘安装振动监测系统,成功实现了 2 702 m 掘进过程中刀盘三轴振动信号的连续自动采集,经过预处理后构建了包含 9 810 条数据的高质量数据库。基于上述数据库,构建了一种结合小波散射网络和长短期记忆网络的围岩等级智能识别模型。模型利用小波散射网络提取 TBM 刀盘振动信号中包含时域与频域信息的多尺度特征,使用长短期记忆网络能有效提取 TBM 振动特征时序特性。模型在测试集上达到 93.7% 的识别准确率,验证了该方法在实时围岩感知中的准确性与鲁棒性。

相较于基于幅值域下的浅层机器学习模型,本文提出的模型有着更强的特征表达能力,并且极大

地减少了对专家经验的依赖,增强了模型的泛化能力,但在模型的可解释性方面仍存在不足。针对 TBM 围岩突变的识别这一难点,未来可以将振动监测系统的采集间隔缩短,增强模型的识别频次,以适应地层复杂的 TBM 隧道工程。

(本文受到核设施退役治理专项资助科研项目(科工二司[2020]194 号)的支持。)

参考文献:

- [1] Zhu Mengqi, Zhu Hehua, Wang Xin, et al. Study on CART-based ensemble learning algorithms for predicting TBM tunneling parameters and classing surrounding rock-masses[J]. Chinese Journal of Rock Mechanics and Engineering, 2020, 39(9): 1860-1871. [朱梦琦,朱合华,王昕,等.基于集成 CART 算法的 TBM 掘进参数与围岩等级预测[J].岩石力学与工程学报,2020,39(9):1860-1871.]
- [2] Erharter G H, Marcher T, Reinhold C. Artificial neural network based online rockmass behavior classification of TBM data[C]//Information Technology in Geo-Engineering. Cham: Springer, 2020: 178-188.
- [3] Liu Zaobao, Li Long, Fang Xingli, et al. Hard-rock tunnel lithology prediction with TBM construction big data using a global-attention-mechanism-based LSTM network [J]. Automation in Construction, 2021, 125: 103647.
- [4] 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.
- [5] Mooney M, Walter B, Steele J, et al. Influence of geological conditions on measured TBM vibration frequency [C]//2014 North American Tunneling Conference, NAT 2014. Los Angeles: Society for Mining, Metallurgy and Exploration, 2014: 32-41.
- [6] Gong Qiuming, Wu Fan, Wang Dujuan, et al. Development and application of cutterhead working status monitoring system for shield TBM tunnelling[J]. Rock Mechanics and Rock Engineering, 2021, 54(4): 1731-1753.
- [7] Li Zonglin, Li Qinglou, Zhang Lilong, et al. Correlation analysis between surrounding rock parameters and main-frame vibration of an open tunnel boring machine [J]. Tunnel Construction, 2024, 44(5): 991-999. [李宗林,李庆楼,张立龙,等.敞开式 TBM 隧洞围岩参数与主机振动相关性分析[J].隧道建设(中英文),2024,44(5):991-999.]
- [8] Yang Yalei, Du Lijie, Li Qingwei, et al. Vibration characteristics of a TBM main beam under different surrounding rocks and tunneling parameters[J]. Journal of Vibra-

- tion and Shock, 2023, 42(12): 88-97. [杨亚磊, 杜立杰, 李青蔚, 等. 不同围岩与掘进参数下的TBM主梁振动特性[J]. 振动与冲击, 2023, 42(12): 88-97.]
- [9] Zhai Shufang, Du Hongkun, Tian Hao, et al. Numerical simulation of TBM three rolling cutters cooperative linear and rotary cutting rock breaking fragmentation[J]. Journal of Zhengzhou University (Engineering Science), 2025, 46(6): 118-126. [翟淑芳, 杜红坤, 田浩, 等. TBM三滚刀协同线性切割和回转切割破岩数值模拟[J]. 郑州大学学报(工学版), 2025, 46(6): 118-126.]
- [10] Liu Dongxin, Xiao Yuhang, Zhou Xiaoxiong, et al. Study on vibration characterization parameters of TBM rock-breaking cutterhead[J]. Modern Tunnelling Technology, 2023, 60(4): 153-162. [刘东鑫, 肖禹航, 周小雄, 等. TBM破岩刀盘振动表征参数研究[J]. 现代隧道技术, 2023, 60(4): 153-162.]
- [11] Tang Qisheng, Hu Qingsong, Wang Ganggang, et al. Tunnel face rock mass class rapid identification based on TBM cutterhead vibration monitoring and deep learning model[J]. Scientific Reports, 2025, 15: 11563.
- [12] Tang Qisheng, Gong Qiuming, Liu Yangyang, et al. Tunnel face rock mass class identification based on multi-domain feature extraction and selection of TBM cutterhead vibration signals[J]. International Journal of Rock Mechanics and Mining Sciences, 2025, 188: 106066.
- [13] Wu You, Zhou Xiaoxiong, Cao Yuxin, et al. Ground recognition model of dual-mode shield tunneling based on cutterhead vibration features[J]. Chinese Journal of Underground Space and Engineering, 2024, 20(S2): 629-637. [吴忧, 周小雄, 曹玉新, 等. 基于刀盘振动特征的双模盾构掘进地层识别模型[J]. 地下空间与工程学报, 2024, 20(增刊2): 629-637.]
- [14] Fang Yingran, Li Xinggao, Liu Hongzhi, et al. Intelligent real-time identification technology of stratum characteristics during slurry TBM tunneling[J]. Tunnelling and Underground Space Technology, 2023, 139: 105216.
- [15] Zheng Xiuhe. Research on surrounding rock sensing technology based on TBM cutterhead vibration[D]. Beijing: Beijing Jiaotong University, 2023. [郑修和. 基于TBM刀盘振动的围岩感知技术研究[D]. 北京: 北京交通大学, 2023.]
- [16] Liu Mengbo, Liao Shaoming, Yang Yifeng, et al. Tunnel boring machine vibration-based deep learning for the ground identification of working faces[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2021, 13(6): 1340-1357.
- [17] Mallat S. Group invariant scattering[J]. Communications on Pure and Applied Mathematics, 2012, 65(10): 1331-1398.
- [18] Fan Xin, Cheng Jianyuan, Wang Yunhong, et al. Intelligent recognition of coal mine microseismic signal based on wavelet scattering decomposition transform[J]. Journal of China Coal Society, 2022, 47(7): 2722-2731. [樊鑫, 程建远, 王云宏, 等. 基于小波散射分解变换的煤矿微震信号智能识别[J]. 煤炭学报, 2022, 47(7): 2722-2731.]
- [19] Andén J, Mallat S. Deep scattering spectrum[J]. IEEE Transactions on Signal Processing, 2014, 62(16): 4114-4128.
- [20] Graves A. Supervised sequence labelling with recurrent neural networks[M]. Berlin, Heidelberg: Springer, 2012: 37-45.
- [21] Wang Ju. Progress of geological disposal of high-level radioactive waste in China in the 21st century[J]. Atomic Energy Science and Technology, 2019, 53(10): 2072-2082. [王驹. 中国高放废物地质处置21世纪进展[J]. 原子能科学技术, 2019, 53(10): 2072-2082.]
- [22] Sadeghi M, Behnia F, Amiri R. Window selection of the Savitzky-Golay filters for signal recovery from noisy measurements[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(8): 5418-5427.
- [23] 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. [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.]
- [24] GB 50487—2008 水利水电工程地质勘察规范[S].
- [25] Zhou Yu, Sun Hongyu, Fang Qian, et al. Review of imbalanced data classification methods[J]. Application Research of Computers, 2022, 39(6): 1615-1621. [周玉, 孙红玉, 房倩, 等. 不平衡数据集分类方法研究综述[J]. 计算机应用研究, 2022, 39(6): 1615-1621.]
- [26] Sathyanarayanan S. Confusion matrix-based performance evaluation metrics[J]. African Journal of Biomedical Research, 2024: 4023-4031.
- [27] Abdullah D M, Abdulazeez A M. Machine learning applications based on SVM classification a review[J]. Qubahan Academic Journal, 2021, 1(2): 81-90.

Surrounding Rock Mass Sensing Model Based on TBM Cutterhead Vibration Using WSN-LSTM

GONG Qiuming¹, LI Shunwen¹, HUANG Liu¹, WANG Ju^{2,3}, CAO Zixiang¹, MA Hongsu^{2,3}

(1. Key Laboratory of Urban Security and Disaster Engineering of Ministry of Education, Beijing University of Technology, Beijing 100124, China; 2. Beijing Research Institute of Uranium Geology, Beijing 100029, China; 3. CAEA Innovation Center for Geological Disposal of High-Level Radioactive Waste, Beijing 100029, China)

Abstract: To address the limitations of existing surrounding rock mass identification methods based on TBM vibration signals in terms of feature extraction effectiveness and engineering adaptability, a novel surrounding rock mass perception method was proposed integrating wavelet scattering network (WSN) and long short-term memory network (LSTM) using TBM cutterhead vibration data. Firstly, relying on the spiral ramp project of the Beishan Underground Laboratory, a vibration monitoring system was mounted on the TBM cutterhead to acquire vibration signals during the TBM tunneling process. Then, a rock mass sensing database based on cutterhead vibration was established through a series of data preprocessing procedures, including stable tunneling segment extraction, noise reduction, and signal segmentation, combined with the matching of geological information along the tunnel alignment. Secondly, the WSN was employed to perform multi-scale temporal feature extraction from the preprocessed vibration signals, so as to enhance the feature representation capability and noise robustness. On this basis, a WSN-LSTM surrounding rock mass perception model was constructed by leveraging the inherent superiority of the LSTM network in capturing the temporal dependencies. The research results demonstrated that the proposed WSN-LSTM model achieved an accuracy of 93.7% on the test set, which yielded a 5.6 percentage points accuracy improvement compared with the wavelet scattering network-based support vector machine (SVM) model, and outperformed shallow machine learning models (random forest and LightGBM) based on amplitude-domain statistical feature extraction. These findings validated the superiority of WSN in feature extraction from TBM cutterhead vibration signals, as well as the necessity of capturing the temporal dependencies of cutterhead vibration features.

Keywords: TBM; surrounding rock mass sensing; vibration monitoring system; wavelet scattering network; deep learning