

DOI: 10.13382/j.jemi.B2508298

# 惯性数据驱动的钻孔工序识别方法\*

陈旭<sup>1,2</sup> 郑晓亮<sup>1,3</sup> 薛生<sup>1,2,3</sup> 庞靖煜<sup>1,2</sup> 杨志强<sup>3</sup>

(1. 安徽理工大学深部煤炭安全开采与环境保护全国重点实验室 淮南 232001; 2. 安徽理工大学安全科学与工程学院 淮南 232001; 3. 安徽理工大学煤炭精准开采国家地方联合工程中心 淮南 232001)

**摘要:** 煤矿钻孔施工场景复杂,受强光水雾与粉尘的干扰,难以准确识别钻孔工序,为提升煤矿钻孔施工过程中的钻孔工序智能识别水平,提出一种基于惯性数据驱动的钻孔工序识别方法。首先,分析了钻孔过程中各工序的钻尾惯性响应特性,研制了惯性响应测量短节,给出了短节部署方案;其次,引入了双向长短时记忆(BiLSTM)网络提取惯性数据的时序特征,改进了经典Transformer Encoder网络,构造了针对惯性双模态的Transformer(DMT)特征提取网络,设计了惯性双模态数据的BiLSTM-DMT网络来提取惯性数据的特征,实现钻孔工序智能感知与识别;最后,开展了井下实测任务,得到了7类典型钻孔施工工序的惯性数据集,优选了BiLSTM网络的神经元数量,对比分析了多种融合模型的识别效果。实验结果表明,所提方法在训练实例中实现了98.87%的工序识别准确率,在工程实例中实现了96.26%的准确率,明显优于其他对比算法,说明方法能够有效地识别钻孔施工工序,且具备较高的识别精度和鲁棒性,为煤矿钻孔施工中的智能钻孔工序识别发展提供了新的技术路径。

**关键词:** 智能钻探; 钻孔工序识别; 惯性感知; BiLSTM; Transformer

**中图分类号:** TH7; TP391.4; TN911.6 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Method for recognizing drill tool actions using inertial response of the drill tail

Chen Xu<sup>1,2</sup> Zheng Xiaoliang<sup>1,3</sup> Xue Sheng<sup>1,2,3</sup> Pang Jingyu<sup>1,2</sup> Yang Zhiqiang<sup>3</sup>

(1. State Key Laboratory of Safe Mining of Deep Coal and Environmental Protection, Anhui University of Science and Technology, Huainan 232001, China; 2. School of Safety Science and Engineering, Anhui University of Science and Technology, Huainan 232001, China, China; 3. Joint National-Local Engineering Research Centre for Safe and Precise Coal Mining, Anhui University of Science and Technology, Huainan 232001, China)

**Abstract:** The complex working environment of coal mine drilling operations, characterized by intense illumination, water mist, and dust interference, poses significant challenges for accurate identification of drilling procedures. To enhance intelligent procedure recognition during coal mine drilling operations, this study proposes an inertial data-driven drilling procedure identification method. Firstly, the inertial response characteristics of the drill tail during various procedures were systematically analyzed. An inertial response measurement module was developed and its deployment scheme formulated. Secondly, a bidirectional long short-term memory (BiLSTM) network was employed to extract temporal features from inertial data. The classical Transformer Encoder network was improved to construct a dual-modal Transformer (DMT) feature extraction network specifically for inertial data. A BiLSTM-DMT network was designed to effectively capture features from dual-modal inertial data, enabling intelligent perception and identification of drilling procedures. Finally, field measurements were conducted underground, yielding an inertial dataset encompassing seven typical drilling procedures. The neuron configuration of the BiLSTM network was optimized through comparative analysis of multiple fusion models. Experimental results demonstrate that the proposed method achieves 98.87% recognition accuracy in training instances and 96.26% in engineering applications, significantly outperforming existing comparative algorithms. This confirms the method's effectiveness in identifying drilling

收稿日期: 2025-04-09 Received Date: 2025-04-09

\* 基金项目: 煤炭安全精准开采国家地方联合工程研究中心开放基金(EC2021003)、中国中煤能源集团2021年重大专项(ZMYHT \* AJ-W-WSZNCC-02-21-090)资助

procedures with high accuracy and robustness, thereby establishing a novel technical pathway for intelligent procedure recognition in coal mine drilling operations.

**Keywords:** intelligent drilling; drilling process identification; inertial perception; BiLSTM; Transformer

## 0 引言

煤矿瓦斯抽采钻孔施工是煤矿安全与灾害治理中的核心环节。随着煤矿行业智能化需求的不断增长,智能化钻探技术在提升施工效率、减少人为操作和提高安全性方面具有重要潜力<sup>[1]</sup>。然而,目前煤矿钻进作业中的智能化水平较低,钻机的智能感知能力不足。普通钻机在煤矿钻孔施工中占据重要地位,但其无法智能识别钻进工序且人力要求高、施工效率低、成孔统计繁琐。

钻孔施工过程受粉尘、水汽、强光与遮挡等影响,现有视觉钻孔施工工序识别技术仍存在瓶颈,多源响应钻孔施工工序识别技术则面临着设备改造难、参数多源与鲁棒性低等问题,因此,提出新方法以提高钻孔施工智能化水平,是煤矿智能钻探发展过程中的重要一环。

近年来,一些学者已尝试通过计算机视觉和多模态传感器技术来实现钻进作业的自动化监控。例如,马斌等<sup>[2]</sup>利用单摄像头捕捉钻具运动视频从而推算钻杆姿态变化实现钻具动作识别;胡玮等<sup>[3]</sup>针对退钻过程进行检测并推算出实际动作从而实现钻杆计数;Yu 等<sup>[4]</sup>从物体运动的角度提出了重复计数框架,结合多个基于深度学习的模型进行钻孔深度的自动识别;张富凯等<sup>[5]</sup>引入深度学习改进 YOLOv8 模型对钻杆尾部进行跟踪,能够实时跟踪钻杆尾部运动状态,并判定换钻状态;Tan 等<sup>[6]</sup>考察了钻机的运行情况,利用优化的 Retinex 矿井图像增强算法,对初始井下图像进行预处理从而优化识别精度;杜京义等<sup>[7]</sup>通过捕捉人体关键点信息构建了换钻动作感知模型,实现了钻机换钻动作的提取识别;张栋等<sup>[8-9]</sup>提取了钻机工作图像通过轻量化模型实现了对钻机工作状态的分析提取。

与视觉感知钻孔施工工序的方法不同,许多学者提出利用钻机平台的多源响应实现钻孔施工工序识别。王忠宾等<sup>[10]</sup>基于钻具运动特性采用动力学分析的方法实现对钻进过程的施工流程监测;朱钱祥等<sup>[11]</sup>通过采集钻机多源响应,利用层次分析法实现了多种工序的智能判断;范海鹏<sup>[12]</sup>基于多模态传感器监测矩阵提出了分布式钻进过程运行状态监测评价的方法并精准描述了钻进系统运行状态;Zheng 等<sup>[13]</sup>利用多钻井参数结合贝叶斯分类器得出最终的钻进过程;李飞等<sup>[14]</sup>基于井下振动采集模块并引入了压缩感知技术实现了钻机状态预警;胜亚楠<sup>[15]</sup>提出实时采集钻机平台的工程参数作为输入参数的井下复杂工序诊断方法;黎育朋<sup>[16]</sup>针对钻进系统提出早期故障预

警与钻进故障诊断方法,通过测量随钻过程的钻机平台多源响应实现对钻进系统钻孔施工工序的识别。

除了上述视觉识别与响应辨识的方法之外,还有一些学者提出利用惯性参数实现研究对象状态的识别方法。魏东等<sup>[17]</sup>基于惯性测量单元(IMU)提出刮板输送机形态检测方法实现了刮板输送机形态的准确感知;陶慧等<sup>[18]</sup>利用微惯性测量组合实现输电杆塔螺栓状态识别;李卓峰等<sup>[19]</sup>和张明月<sup>[20]</sup>将惯性测量单元安设于人类手部用于识别手势与手部状态;Abro 等<sup>[21]</sup>采用 IMU 测量直升机的俯仰角和偏航角,为状态观测器提供真实的姿态数据以实现对整个系统完整运动状态的感知。综上,利用惯性响应实现搭载对象的动作识别具备广泛的可行性,受此启发,考虑设计一种利用惯性数据实现钻进工序的智能识别方法。

当下,混合模型已广泛应用于状态辨识、故障诊断等信号识别领域。魏玮等<sup>[22]</sup>结合多种神经网络构建了动态模型用于预测电站风机状态;乔琦等<sup>[23]</sup>联合 DenseNet-ViT 构建了燃气轮机转子故障诊断模型在目标域数据集中取得了较高的识别精度;王雷等<sup>[24]</sup>引入双向长短期记忆(BiLSTM)融合 Attention 构建了变工况故障识别方法,与传统诊断方法相比获得了更稳定的识别结果。相较于单一模型,混合模型在复杂环境下的辨识能力较强,且能够更精确的提取响应的多层次特征。

针对上述视觉识别易受干扰、多源响应部署困难的问题,本文提出一种惯性数据驱动的钻孔工序识别方法,分析了钻进工序并构建了钻进工序-钻尾惯性响应字典表,研发了钻尾惯性响应采集短节,给出了短节部署方案,引入了 BiLSTM 提取角速度模态与加速度模态的时序特征,改进了 Transformer Encoder 网络,搭建了 BiLSTM 结合双模态 Transformer (DMT) 模型,采集了实际钻孔施工过程的钻尾惯性数据,优化了 BiLSTM-DMT 模型的网络参数,对比了几种经典模型的效果,分析了模型各模块的有效性,验证了方法的泛化能力,最终实现了惯性数据驱动识别钻孔工序。

## 1 方法框架

惯性数据驱动的钻孔工序识别方法如图 1 所示,利用惯性测量短节采集钻尾处的惯性响应参数,通过去除异常值、滤除噪声与加窗切分数据等方法对参数进行预处理再输入至 BiLSTM 网络中提取特征,经过双模态 Transformer 网络融合提取特征后输出工序类别。

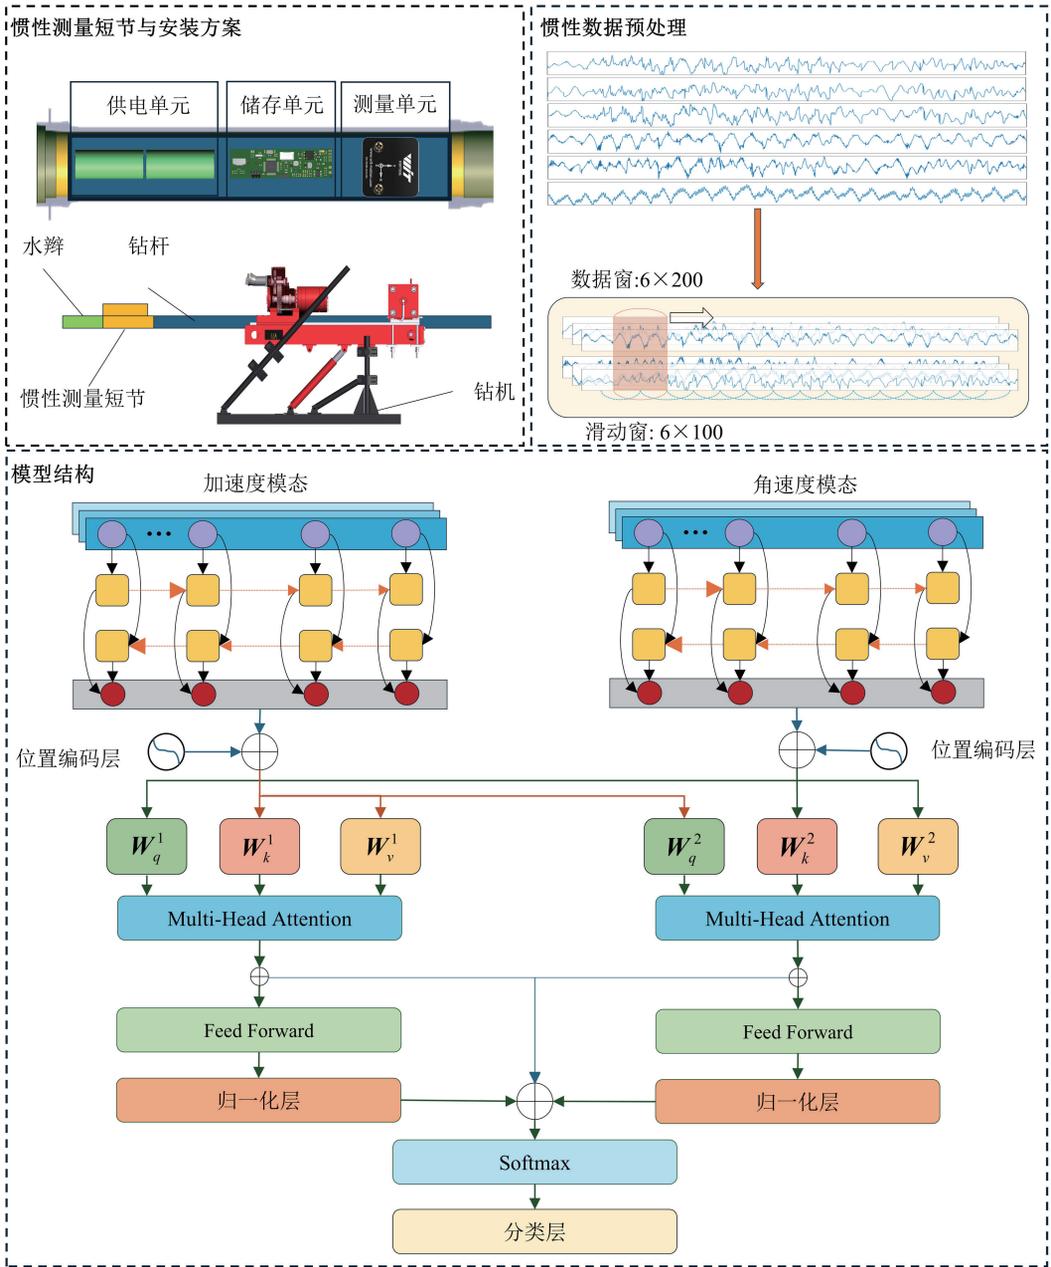


图 1 惯性数据驱动的钻孔施工工序辨识方法

Fig. 1 Identification method of drilling construction process driven by inertial data

## 2 钻尾惯性响应测量系统

### 2.1 钻孔施工工序惯性响应特性分析

钻孔施工包括抽送钻杆、停钻、退钻、进钻、正转、反转及接钻 7 种常见工序,其中给进过程会伴随破岩动作,钻头处的振动能量通过钻杆传递到钻尾,从而引发钻尾处振动加速度的响应。部署方案如图 2 所示,当钻杆正转时, Y 轴角速度呈正向阶跃变化,而反转时角速度符号

反转;给进动作下, Z 轴加速度呈现的持续正向偏移,退钻时则出现负向偏移。通过量化分析 7 类工序的惯性响应特征(表 1),建立工序-信号特征对应字典库。

### 2.2 钻具尾端惯性响应采集短节设计

钻具尾端惯性响应采集短节的设计如图 3 所示,主要由 3 个功能模块组成。惯性测量单元,用于实时采集钻具尾端的加速度和角速度数据,数据存储单元:用于存储采集到的钻尾惯性响应数据,确保数据在长时间工作中能够稳定保存;供电模块,为短节提供所需的电力,确

保其在持续工作过程中能长时间稳定运行。

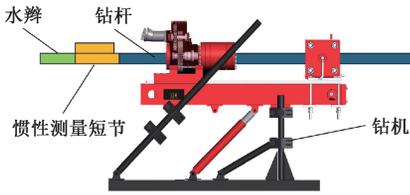


图 2 惯性测量短节部署方案示意图

Fig. 2 Schematic diagram of the installation scheme of the inertial measurement sub

表 1 钻尾惯性响应特征

Table 1 Characteristic of drill tail inertia response

| 序号 | 钻孔施工工序 | 旋转方向 | 前进方向  | 振动情况 |
|----|--------|------|-------|------|
| 1  | 抽送钻杆   | —    | 前进/后退 | 否    |
| 2  | 停钻     | —    | —     | 否    |
| 3  | 退钻     | 逆时针  | 后退    | 否    |
| 4  | 给进     | 逆时针  | 前进    | 是    |
| 5  | 正转     | 逆时针  | —     | 否    |
| 6  | 反转     | 顺时针  | —     | 否    |
| 7  | 接钻     | —    | —     | 否    |

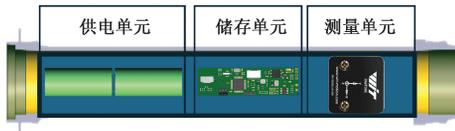


图 3 惯性测量短节示意图

Fig. 3 Schematic diagram of inertial measurement sub

惯性测量短节参数如表 2 所示,该短节基于 HWT906 IMU 研发设计,其加速度计模块其能够精确测量微小的加速度变化并覆盖广泛的动态范围,适用于多种应用场景,角速度计能够精确测量角速度的变化适用于高速旋转或高动态环境,采集频率范围为 0.2 ~ 1 000 Hz,此外,短节还具备 32 GB 的存储容量并能够持续工作 100 h 以上。

表 2 惯性测量短节参数

Table 2 Parameters of inertial measurement sub

| 惯性测量短节 |              |                 |
|--------|--------------|-----------------|
|        | 加速度计         | 角速度计            |
| 分辨率    | 0.000 5 g    | 0.061 °/s/(LSB) |
| 量程     | ±16 g        | ±2 000°/s       |
| 静止零偏   | ±20~40 mg    | ±0.5°/s~1°/s    |
| 采集频率   | 0.2~1 000 Hz |                 |
| 存储容量   | 32 GB        |                 |
| 续航时间   | ≥100 h       |                 |

### 2.3 惯性测量短节的部署方案

为消除井下钻孔施工中常见的粉尘、水雾、照度和人

员等因素对钻孔施工工序识别准确度的干扰,同时也为了避免钻机平台多传感器部署带来的效率与鲁棒性损失,本文提出了一种基于钻尾惯性响应的部署方案(图 2)。

## 3 钻孔施工工序识别模型

### 3.1 BiLSTM

钻进施工时不同工序在带动钻具尾端运动过程中,惯性数据变化具备时间依赖性。由于惯性响应误差的多源性,惯性数据通常呈现非平稳特性,单向长短期记忆(LSTM)网络难以充分捕捉其复杂的特征关系。因此,本文采用 BiLSTM 网络(图 4)对各工序的惯性数据进行特征提取。BiLSTM 是 LSTM<sup>[25]</sup>的扩展,能够同时捕捉序列的前、后向信息。BiLSTM 由正向 LSTM 和反向 LSTM 两部分组成,正向 LSTM 按照时间序列的顺序处理数据,而反向 LSTM 则按逆序处理。通过这种双向处理机制,BiLSTM 能够更好地建模序列中的双向依赖关系,增强对序列全局特征的理解。

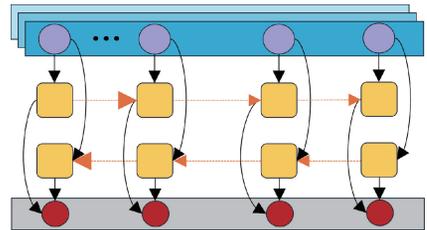


图 4 BiLSTM 网络

Fig. 4 BiLSTM network

BiLSTM 网络在每个时间步长内计算前向 LSTM 隐状态  $\vec{h}_a$  和后向 LSTM 隐状态  $\overleftarrow{h}_a$ ,并将两个隐状态拼接得到最终输出  $H_a$ ,其公式如下:

$$\vec{h}_a = \vec{o}_a \times \tanh(\vec{C}_a) \quad (1)$$

$$\overleftarrow{h}_a = \overleftarrow{o}_a \times \tanh(\overleftarrow{C}_a) \quad (2)$$

$$H_a = [\vec{h}_a; \overleftarrow{h}_a] \quad (3)$$

式中:  $\vec{C}_a$  和  $\overleftarrow{C}_a$  分别表示前向和后向当前记忆单元;  $\vec{o}_a$  和  $\overleftarrow{o}_a$  分别表示前向和后向输出门的输出。

### 3.2 双模态 Transformer

在惯性驱动钻进工序识别任务中,惯性数据由角速度与加速度两种模态数据组成,如表 1 所示,角速度与加速度对各工序的响应程度不同,主要体现在对不同工序的模态敏感程度存在显著区别。因此,为了充分提取不同工序的惯性数据特征,考虑引入经典 Transformer

encoder<sup>[26]</sup> 设计 DMT 结构,将两种模态各通道数据经 BiLSTM 提取特征后分别输入至 Transformer, 对角速度-加速度模态间的时间依赖关系进行有效建模,捕捉不同模态之间的工序信息。其流程简要描述如下。

首先,将 BiLSTM 提取的特征向量进行位置编码处理,再经由多头自注意力机制 (multi-head self-attention) 计算注意力权重,充分融合两种模态的时序关系,并捕捉序列中不同位置之间的依赖关系,再通过多个注意力头,模型可以从不同的角度捕获信息,提升模型对长距离依赖的建模能力。其运算过程如下:

$$MultiHead(Q, K, V) = Concat[head_1, head_2, \dots, head_p] W^G \quad (4)$$

$$head_p = Attention(Q_p, K_p, V_p) \quad (5)$$

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) V \quad (6)$$

式中: *MultiHead* 表示多头自注意力机制; *Q*、*K*、*V* 分别代表查询、键和值矩阵; *W<sup>G</sup>* 表示可训练的权重矩阵; *p* 表示头的个数; *Attention* 表示注意力机制; *d<sub>k</sub>* 表示 *k* 矩阵的列数,即向量的维度。

### 3.3 BiLSTM-DMT 钻进工序识别模型结构

BiLSTM-DMT 钻进工序识别模型(图 5)主要运行步骤如下。

1) 时序特征提取, BiLSTM 层以序列模式处理输入, 从前向和后向序列中捕获依赖关系, 提取多尺度的时序特征。

2) 全局依赖建模, 双模态 Transformer 计算特征间全局依赖生成注意力加权特征, 在通过残差连接融合加权特征与归一化层输出特征保留底层信息, 进一步细化高阶特征分布。

3) 特征聚合与分类, 再通过 Softmax 层输出概率分布, 分类层基于交叉熵损失优化模型参数并输出样本类型。

## 4 实验与讨论

### 4.1 数据集构建

现场采集的惯性数据会伴随钻机运行参数变化而变化, 这种基于实际环境过程中建立的数据集内涵了多种施工情况下各工序的对应的惯性数据, 为钻进工序识别提供丰富的特征, 可使训练的模型具备更好的泛化能力与鲁棒性。本研究以某矿瓦斯预抽采顺煤层钻孔施工工程为研究对象, 使用 ZDY6500LPS 钻机作为实验平台, ZDY6500LPS 钻机作业参数如表 3 所示, 钻杆采用 φ73 mm 的肋骨钻杆。按图 1 方案将惯性测量短节安装于钻具尾端, 井下应用示意图如图 6 所示。

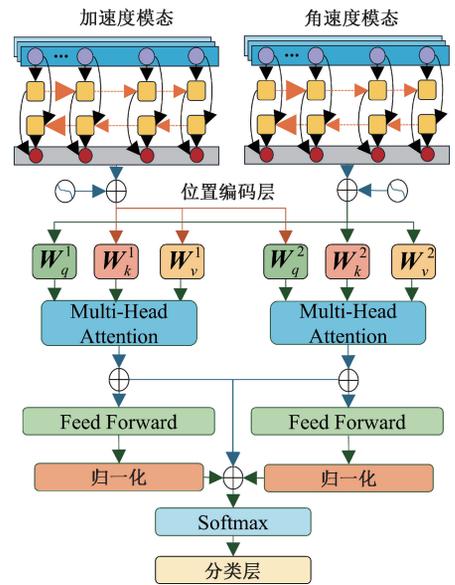


图 5 钻孔施工工序识别模型结构  
Fig. 5 Borehole construction process identification model structure

表 3 ZDYL6000 钻机作业参数

Table 3 Operation parameters of ZDYL6000 rig

| 参数                          | 指标        |
|-----------------------------|-----------|
| 可用钻杆直径/mm                   | 73、89     |
| 输出转速/(r·min <sup>-1</sup> ) | 50~210    |
| 钻孔倾角/(°)                    | -180~+180 |
| 正常给进速度/m                    | 0~1.5     |
| 给进行程/mm                     | 850       |



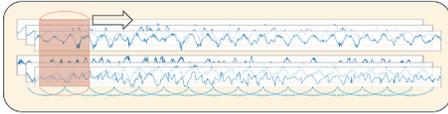
图 6 井下应用示意图

Fig. 6 Schematic diagram of downhole application

将惯性测量短节的采样频率设置为 200 Hz, 并通过储存模块保存惯性与时间数据。实际钻进时, 施工工序的切换速度以秒计算, 过长的采样窗口会造成样本中混杂多种工序的惯性数据从而影响训练结果, 因此, 如图 7 所示, 每个样本以时间步长为 200 滑动窗口为 100 的方

法构建,以提高工序变换过程中识别精度,再经过截止滤波器与 SG 滤波器构成的融合滤波器处理去除重力加速度与异常噪声干扰。

数据窗: 6×200



滑动窗: 6×100

图 7 惯性数据样本构建方法

Fig. 7 Inertial data sample construction method

实验采集了 7 种钻进工序的惯性数据包括抽送钻杆、停钻、退钻、进钻、正转、反转及接钻,经上述数据处理方法得到了训练实例数据集,其中包含 6 049 个样本,各工序的占比如下:抽送钻杆 6.46%、停钻 22.27%、退钻 11.52%、给进 13.21%、正转 27.26%、反转 13.85%和接钻 5.43%。

### 4.2 实验环境与评价指标

本文实验环境配置如下:操作系统为 Windows 11,配备 32 GB 内存,CPU 采用 Intel Core i5-13600K @ 3.50 GHz 处理器,GPU 选用 NVIDIA GeForce RTX 4060 Ti(16 GB 显存),软件运行环境包括 Python 3.11、Pytorch 2.5.1 深度学习框架以及 CUDA 12.7。本文使用准确率 (accuracy)、精确率 (precision)、召回率 (recall) 和 F1 分数作为评价指标。

### 4.3 模型参数优化

#### 1) BiLSTM 神经元数量的选择

BiLSTM 网络用来提取惯性数据的时间依赖特征。当选取不同的 BiLSTM 神经元数量时,训练结果会有明显的差异。本文对包含有不同神经元数量的 BiLSTM 模

型进行了训练,得到的对比结果如图 8 所示,由图 8 可见,随着 BiLSTM 单元数量的不断增加,分类准确率会逐渐提升,但增加到 128 个 BiLSTM 神经元时,性能指标会低于 64 个 BiLSTM 单元的结果。因此,本文选择 64 个 BiLSTM 神经元构建网络。

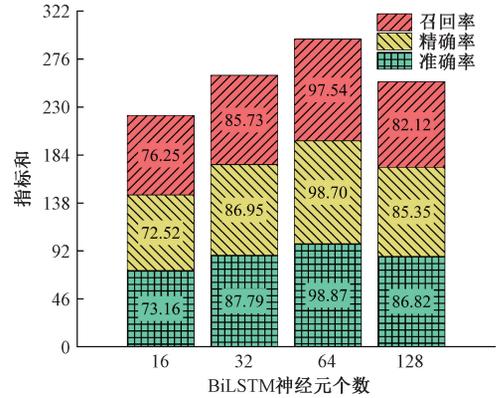


图 8 神经元数量与指标对比

Fig. 8 Comparison of the number of neurons and indicators

#### 2) 超参数设置

模型的网络结构与超参数设置如表 4 所示。首先,输入层分别接收加速度与角速度模态的三通道时序信号(长度为 200),经过一层 BiLSTM(隐藏单元数为 64)提取时序特征,并通过线性映射扩展至 512 维后输入 Transformer 编码器。Transformer 模块由两层堆叠组成,每层包含 8 头自注意力机制、前馈网络(隐藏维度 2 048)、残差连接与 Layer Normalization,输出维度保持为 512,以充分建模长序列依赖关系。随后,对加速度与角速度模态的特征进行拼接,得到 1 024 维融合向量,经全连接层(1 024→128,ReLU 激活,Dropout = 0.2)降维后,输入分类层完成 7 类岩性识别任务。

表 4 网络结构与超参数

Table 4 Network structure and hyperparameters

Table with 5 columns: Category, Type, Structure, Parameter Settings, Output Dimensions. It details the network architecture (BiLSTM, Transformer, fully connected, classification) and training hyperparameters (Batch size, Epoch, Optimizer, Learning Rate Decay, Early Stopping, Loss Function).

在训练策略上,批次大小(batch size)设置为 32,最大迭代轮数为 100。优化器采用 Adam,初始学习率为 0.001,并引入分段式学习率衰减(StepLR),每 20 轮衰减为原来的 0.5,以提高泛化性能。同时,为防止过拟合,采用 Dropout(0.2)和早停机制(patience = 10,监控验证集损失),在验证集性能不再提升时提前终止训练。损失函数采用交叉熵损失,适用于多类别分类问题。

#### 4.4 消融实验

为验证本文模型结构的有效性与惯性模态选取的合理性,以钻进工序数据集为基础构建消融实验对照组,训练策略一致,实验共设计 5 类方法,方法 1 为双模态数据+Transformer 结构;方法 2 为双模态数据+BiLSTM 结构;方法 3 为加速度模态+BiLSTM-DMT 结构;方法 4 为角速度模态 + BiLSTM-DMT 结构;方法 5 为双模态数据 + BiLSTM-DMT 结构。图 9 所示为 5 种方法的指标对比结果,观察图 9 可知,融合模型的性能指标明显优于单独的 BiLSTM 模型与 Transformer 模型,此外,加速度模态较角速度模态贡献度更高,但均低于双模态的识别效果。

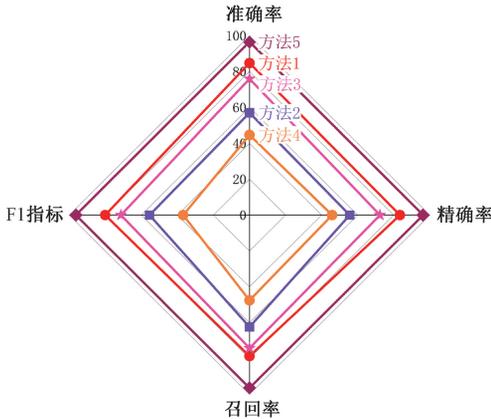


图 9 消融实验对比

Fig. 9 Comparison of ablation experiments

#### 4.5 对比实验

为验证 BiLSTM-DMT 模型的有效性,本文选取以下 3 类代表性模型进行对比实验,混合模型为卷积神经网络+BiLSTM(CNN-BiLSTM)、CNN+双向门控单元(CNN-BiGRU);注意力增强模型为 CNN-BiLSTM-Attention。

将训练实例数据集按照 8 : 2 设置训练样本与测试样本,为了确保对比实验的公平性,所有参与对比的模型均使用与本文所提模型相同的输入数据,即加速度信号与角速度信号的双模态数据。将不同的预测模型在本文数据集中进行 50 次训练后取各指标的平均值(表 5),观察表 5 可知,相较于 CNN 类混合模型与注意力增强模型,BiLSTM-DMT 在表现出色,其准确率可达 98.87%,显著优于 CNN-BiLSTM 的 69.67%和 CNN-BiLSTM-Attention

的 89.02%,实验结果表明 BiLSTM 联合 DMT 的局部-全局融合注意力机制针对性地提升了钻孔施工工序类别的识别效果,显著改善了模型的整体性能。

表 5 不同模型钻孔施工工序识别量化指标

Table 5 Different models of drilling construction process identification quantitative indicators

| 模型                   | 准确率/%        | 精确率/%        | 召回率/%        | F1 指标          |
|----------------------|--------------|--------------|--------------|----------------|
| CNN-BiLSTM           | 69.67        | 69.67        | 64.22        | 0.619 9        |
| CNN-BiLSTM-Attention | 89.02        | 89.02        | 82.68        | 0.813 0        |
| CNN-BiGRU            | 57.75        | 57.75        | 56.00        | 0.515 1        |
| BiLSTM-DMT           | <b>98.87</b> | <b>98.70</b> | <b>97.54</b> | <b>0.981 3</b> |

为了更好地体现提出本文模型的性能,本文模型的分混淆矩阵图如图 10 所示。混淆矩阵的每一行表示真实的工序类别,每一列表示预测的工序类别,图中的数值表示预测的类别占该类别真实个数的比值,对角线比值越大,说明算法模型对该类别的分类准确率越高。

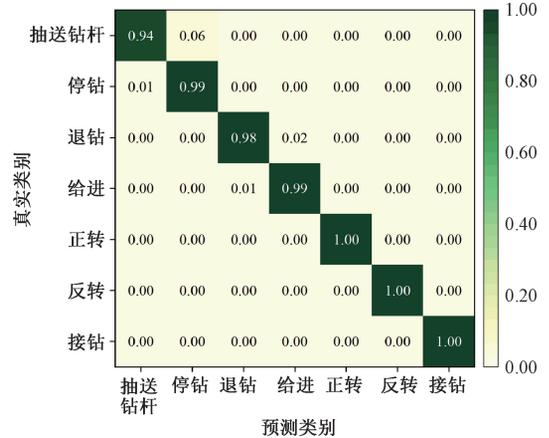


图 10 混淆矩阵

Fig. 10 Confusion matrix

#### 4.6 泛化性能实验

为进一步分析所提钻进工序识别方法的泛化性能,本文构建了工程实例数据集,该数据集来源于实际钻孔施工过程中持续采集的一段惯性测量数据,总时长为 455 s,包含角速度与加速度两种模态,且在时间尺度上连续,涵盖了全部 7 种典型工况。经由第 4.1 节数据样本处理方法处理后,共生成 910 个测试样本。随后,采用第 4.5 节训练得到的各结构最优模型对该测试集进行识别,识别结果如图 11 所示。相较于其他几类结构的识别模型,本文方法在工程实例数据集的识别结果表现良好,尽管在部分工序切换瞬间出现短暂的识别错误,但长时间持续工序识别效果显著且稳定。实验结果表明,本文提出的方法能够有效识别连续钻孔施工过程中的钻进工序,具备良好的泛化性能。

为量化评估本文方法的优势,在工程实例数据集上

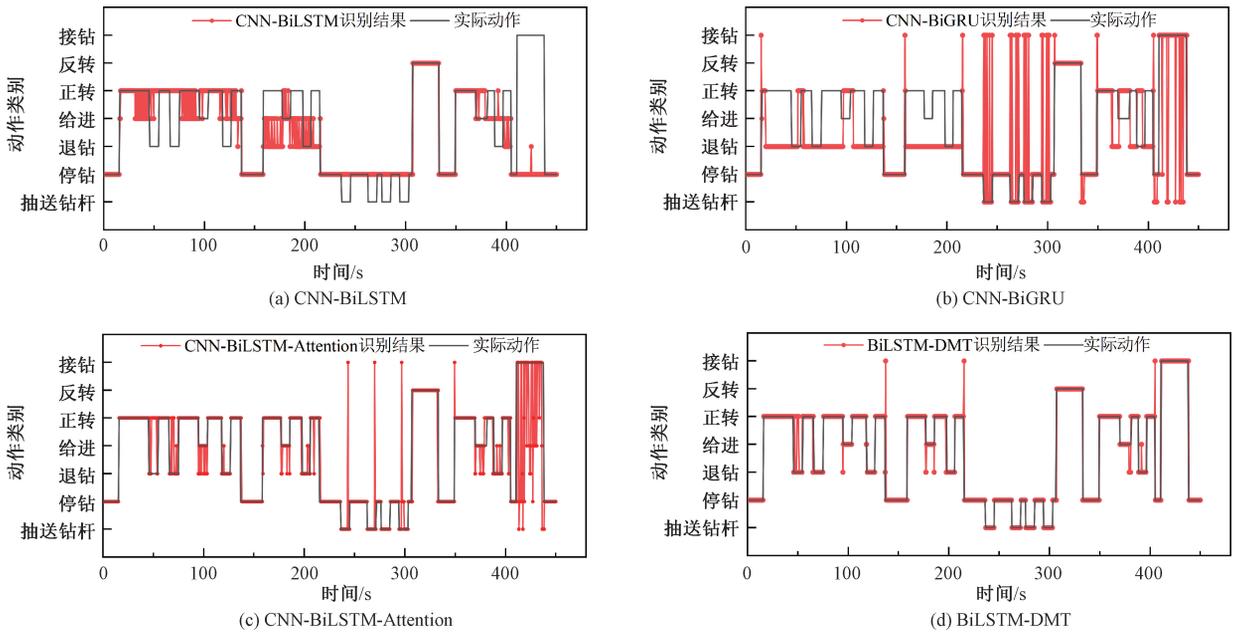


图 11 不同模型的工程实例数据集识别结果

Fig. 11 Identification results of engineering instance datasets of different models

对比了不同模型的识别结果,各项量化指标如表 6 所示。本文提出的 BiLSTM-DMT 模型在准确率(96.26%)、精确率(96.26%)、召回率(96.45%)和 F1 值(0.963 2) 4 个方面均显著优于其他对比模型。其中,准确率较性能次优的 CNN-BiLSTM-Attention 模型提升了 10.4%,且各项指标均表现均衡优异。实验结果表明,该模型通过有效的深层时序特征融合机制,不仅显著提高了钻进工序的整体识别精度,同时增强了类别判别的一致性与稳定性,充分验证了其所具有的优越识别性能和泛化能力。

表 6 不同模型的工程实例数据集量化指标

Table 6 Quantitative indicators of engineering instance datasets for different models

| 模型                   | 准确率/%        | 精确率/%        | 召回率/%        | F1 指标          |
|----------------------|--------------|--------------|--------------|----------------|
| CNN-BiLSTM           | 52.40        | 52.40        | 52.92        | 0.508 7        |
| CNN-BiGRU            | 36.74        | 36.74        | 41.28        | 0.377 5        |
| CNN-BiLSTM-Attention | 85.85        | 85.85        | 80.49        | 0.823 8        |
| BiLSTM-DMT           | <b>96.26</b> | <b>96.26</b> | <b>96.45</b> | <b>0.963 2</b> |

### 5 结 论

本文主要针对煤矿钻孔施工过程中工序识别智能化程度低,且现有方法在井下高粉尘、水汽等复杂环境中适应性差的核心问题,提出一种由惯性数据驱动的 BiLSTM 网络和 DMT 融合的钻孔工序识别方法,并基于井下实际钻孔场景的钻孔工序惯性响应数据完成对该方法的验证。实验结果表明本文所提方法能够有效识别钻孔工序,同时在复杂环境下的识别效果较为稳定。尽管当前

方法已表现出稳定的识别性能,为了提升方法的识别精度,未来研究仍需进一步面向钻具故障、强信号噪声等极端干扰条件开展优化研究工作,以提升该技术在实际应用中的普适性与可靠性。

### 参考文献

[ 1 ] 石智军,姚克,姚宁平,等.我国煤矿井下坑道钻探技术装备 40 年发展与展望 [J].煤炭科学技术,2020,48(4):1-34.  
SHI ZH J, YAO K, YAO N P, et al. 40 years of development and prospect on underground coal mine tunnel drilling technology and equipment in China [J]. Coal Science and Technology, 2020, 48(4): 1-34.

[ 2 ] 马斌,彭光宇.基于单目视觉的钻杆位姿识别技术研究 [J].煤田地质与勘探,2022,50(10):171-178.  
MA B, PENG G Y. Research on drill pipe pose recognition technology based on monocular vision [J]. Coal Geology & Exploration, 2022, 50(10): 171-178.

[ 3 ] 胡玮,王满利,张长森,等.基于退钻过程检测的矿井下钻杆计数方法研究 [J].煤炭学报,2025,50(S1):697-707.  
HU W, WANG M L, ZHANG CH S, et al. Research on drill rod counting method in mines based on drill withdrawal process detection [J]. Journal of China Coal Society, 2025, 50(S1): 697-707.

[ 4 ] YU Y C, ZHAO J H, YI CH H, et al. Drill-Rep: Repetition counting for automatic shot hole depth recognition based on combined deep learning-based model [J].

- Engineering Applications of Artificial Intelligence, 2023, 123: 106302.
- [ 5 ] 张富凯,孙一冉,武旭峰,等. 基于深度学习的煤矿钻杆实时计数方法 [J]. 煤炭科学技术, 2025, 53 (6): 493-504.
- ZHANG F K, SUN Y R, WU X F, et al. Real-time counting method of coal mine drill pipe based on deep learning [J]. Coal Science and Technology, 2025, 53 (6): 493-504.
- [ 6 ] TAN T J, GUO CH F, ZHANG G H, et al. Research and application of downhole drilling depth based on computer vision technique [J]. Process Safety and Environmental Protection, 2023, 174: 531-547.
- [ 7 ] 杜京义,党梦珂,乔磊,等. 基于改进时空图卷积神经网络的钻杆计数方法 [J]. 工矿自动化, 2023, 49(1): 90-98.
- DU J Y, DANG M K, QIAO L, et al. Drill pipe counting method based on improved spatiotemporal graph convolutional neural network [J]. Journal of Mine Automation, 2023, 49(1): 90-98.
- [ 8 ] 张栋,姜媛媛. 基于改进 MobileNetV2 的钻杆计数方法[J]. 工矿自动化, 2022, 48(10): 69-75.
- ZHANG D, JIANG Y Y. Drill pipe counting method based on improved MobileNetV2 [J]. Journal of Mine Automation, 2022, 48(10): 69-75.
- [ 9 ] 张栋,姜媛媛. 融合注意力机制与逆残差结构的轻量级钻机目标检测方法 [J]. 电子测量与仪器学报, 2022, 36(11): 201-210.
- ZHANG D, JIANG Y Y. Lightweight drilling rig target detection method combining attention mechanism and inverse residual structure [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (11): 201-210.
- [ 10 ] 王忠宾,司垒,魏东,等. 煤矿防冲钻孔机器人全自主钻进系统关键技术 [J]. 煤炭学报, 2024, 49(2): 1240-1258.
- WANG ZH B, SI L, WEI D, et al. Key technologies of fully autonomous drilling system for coal mine rock burst prevention drilling robot [J]. Journal of China Coal Society, 2024, 49(2): 1240-1258.
- [ 11 ] 朱钱祥,罗鹏平,王龙鹏,等. 基于层次分析法的智能钻机运行工序判识 [J]. 煤田地质与勘探, 2024, 52(3): 184-190.
- ZHU Q X, LUO P P, WANG L P, et al. Identification of intelligent drilling rig operation procedures based on analytic hierarchy process [J]. Coal Geology & Exploration, 2024, 52(3): 184-190.
- [ 12 ] 范海鹏. 基于数据特征解析的复杂地质钻进过程智能状态监测与评价方法 [D]. 武汉: 中国地质大学, 2023.
- FAN H P. Intelligent monitoring and assessment method for complex geological drilling process based on data characteristics decompositions [D]. Wuhan: China University of Geosciences, 2023.
- [ 13 ] ZHENG ZH, XU ZH L, MIN W, et al. Fault diagnosis based on feature clustering of time series data for loss and kick of drilling process [J]. Journal of Process Control, 2021, 102: 24-33.
- [ 14 ] 李飞,王一帆,吕方兴. 基于压缩感知的井下钻具状态预警方法研究 [J]. 石油机械, 2024, 52(9): 1-9.
- LI F, WANG Y F, LYU F X. Early warning method for downhole drilling tool state based on compressed sensing [J]. China Petroleum Machinery, 2024, 52(9): 1-9.
- [ 15 ] 胜亚楠. 基于井下参数测量的钻柱运动特征及异常状态分析方法 [J]. 石油地质与工程, 2024, 38(2): 108-111, 126.
- SHENG Y N. Analysis method of drill string motion characteristics and abnormal states based on downhole parameter measurement [J]. Petroleum Geology and Engineering, 2024, 38(2): 108-111, 126.
- [ 16 ] 黎育朋. 面向复杂地质钻进过程的故障检测与预警研究 [D]. 武汉: 中国地质大学, 2023.
- LI Y P. Research on fault detection and early warning for complex geological drilling process [D]. Wuhan: China University of Geosciences, 2023.
- [ 17 ] 魏东,李祖旭,司垒,等. 基于惯性测量单元的刮板输送机形态监测 [J]. 工矿自动化, 2023, 49(8): 37-52, 80.
- WEI D, LI Z X, SI L, et al. Shape monitoring of scraper conveyors based on inertial measurement units [J]. Journal of Mine Automation, 2023, 49(8): 37-52, 80.
- [ 18 ] 陶慧,贺国帅,杨金显,等. 基于 MIMU 的输电杆塔螺栓状态识别 [J]. 振动与冲击, 2023, 42(20): 98-104.
- TAO H, HE G SH, YANG J X, et al. Bolt state identification of transmission tower based on MIMU [J]. Journal of Vibration and Shock, 2023, 42(20): 98-104.
- [ 19 ] 李卓峰,孙铭会. 基于高采样率惯性测量单元的手部状态与手势识别 [J]. 浙江大学学报(工学版), 2023, 57(3): 503-511.
- LI ZH F, SUN M H. Hand state and gesture recognition based on high sampling rate inertial measurement unit [J]. Journal of Zhejiang University (Engineering Science), 2023, 57(3): 503-511.
- [ 20 ] 张明月. 人机交互中手势姿态估计与识别算法研究 [D]. 广州: 华南理工大学, 2023.

- ZHANG M Y. Research on hand pose estimation and recognition algorithm in human-computer interaction [D]. Guangzhou: South China University of Technology, 2023.
- [21] ABRO M E G, ABDALLAH M A. Observer-driven LQR and FOLQR control for enhanced stability of underactuated 2-DOF helicopter [J]. Instrumentation, 2025, 12(1): 60-69.
- [22] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法 [J]. 仪器仪表学报, 2023, 44(4): 19-27.
- WEI W, LYU Y, QI X Y, et al. State prediction method for power plant fans based on CNN-LSTM-AM dynamic ensemble model [J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.
- [23] 乔琦, 王红军, 马康, 等. 基于改进的 DenseNet-ViT 联合网络和迁移学习的燃气轮机转子故障诊断 [J]. 电子测量与仪器学报, 2024, 38(11): 40-47.
- QIAO Q, WANG H J, MA K, et al. Fault diagnosis of gas turbine rotor based on improved DenseNet-ViT hybrid network and transfer learning [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(11): 40-47.
- [24] 王雷, 何坤, 李宗帅, 等. 基于 BiLSTM-Attention 的迁移学习变工况故障识别方法研究 [J]. 电子测量与仪器学报, 2023, 37(7): 205-212.
- WANG L, HE K, LI Z SH, et al. Research on transfer learning-based variable-condition fault identification method using BiLSTM-Attention [J]. Journal of Electronic Measurement and Instrumentation, 2023,

37(7): 205-212.

- [25] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, ArXiv preprint arXiv: 1706.03762, 2017.

## 作者简介



**陈旭** (通信作者), 2020 年于安徽理工大学获得学士学位, 现为安徽理工大学博士研究生, 主要研究方向为信号处理与数据分析。

E-mail: tykechen@ aust. edu. cn

**Chen Xu** (Corresponding author) received his B. Sc. degree from Anhui University of Science and Technology in 2020. Now he is a Ph. D. candidate at Anhui University of Science and Technology. His main research interests include signal processing and data analysis.



**郑晓亮**, 2018 年于安徽理工大学获得博士学位, 现为安徽理工大学教授、博士生导师, 主要研究方向为状态识别与诊断。

E-mail: zhengxl@ aust. edu. cn

**Zheng Xiaoliang** received his Ph. D. degree from Anhui University of Science and Technology in 2018. Now He is a professor and Ph. D. supervisor at Anhui University of Science and Technology. His main research interests include condition recognition and diagnosis.