

# 基于双层 CNN-LSTM 的地质钻进过程钻速建模

孙皓<sup>1,2,3</sup>, 杨霄<sup>4</sup>, 王怡冰<sup>1,2,3</sup>, 马哲家祺<sup>1,2,3</sup>, 陆承达<sup>1,2,3</sup>, 吴俊东<sup>1,2,3\*</sup>

1. 中国地质大学(武汉) 人工智能与自动化学院, 湖北 武汉 430074
2. 复杂系统先进控制与智能自动化湖北省重点实验室, 湖北 武汉 430074
3. 地球探测智能化技术教育部工程研究中心, 湖北 武汉 430074
4. 中国地质大学(武汉) 未来技术学院, 湖北 武汉 430074

**摘要:** 钻速是表征钻进效率的关键指标, 其变化受多种钻进参数的共同影响, 具有显著的强耦合性和非线性特征。当前时刻的钻速状态, 不仅由该时刻的钻进参数和地层条件决定, 还与前若干时刻的钻速变化、钻进参数变化、钻进状态等密切相关, 呈现出明显的时间依赖与序列记忆特性。针对实际钻进数据中工况复杂、噪声较大以及传统模型难以有效反映长期时序依赖的问题, 本文以襄阳某井场实际钻进过程为研究对象, 提出一种基于双层 CNN-LSTM 的钻速建模方法。首先, 针对原始钻进数据多工况混杂的问题, 构建正常钻进工况识别与井段自动划分方法, 并结合异常数据清洗、分段滤波及尺度变换, 形成一套数据预处理方案。其次, 采用时滞互信息相关性分析方法, 对钻速与多种钻进参数之间的非线性及时序相关关系进行定量分析, 据此确定模型输入变量及时间窗口长度。在此基础上, 通过多尺度卷积特征提取与时序建模相结合, 构建一种双层 CNN 并联与 LSTM 串联的钻速模型。实验结果表明, 所提出的模型在实际钻进数据上的精度和稳定性均优于传统机器学习模型及单一结构深度学习模型, 能够有效反映钻进过程中钻速的时序变化规律, 为复杂钻进条件下的钻速建模提供一种可行的数据驱动方法。

**关键词:** 钻速建模; 钻进数据处理; 时滞互信息; 卷积神经网络; 长短期记忆网络

**中图分类号:** P634

**收稿日期:** 2026-2-12

## Dual-Layer CNN - LSTM-Based Rate of Penetration Modeling for Geological Drilling Processes

Sun Hao<sup>1,2,3</sup>, Yang Xiao<sup>4</sup>, Wang Yibing<sup>1,2,3</sup>, Ma Zhejiaqi<sup>1,2,3</sup>, Lu Chengda<sup>1,2,3</sup>, Wu Jundong<sup>1,2,3\*</sup>

1. School of Artificial Intelligence and Automation, China University of Geosciences (Wuhan), Wuhan 430074, China
2. Hubei Key Laboratory of Advanced Control and Intelligent Automation for Complex Systems, Wuhan 430074, China
3. Engineering Research Center of Geo-Detection Intelligence Technology, Ministry of Education, Wuhan 430074, China
4. School of Future Technology, China University of Geosciences (Wuhan), Wuhan 430074, China

**Abstract:** Rate of penetration (ROP) is a key indicator for evaluating drilling efficiency. Its variation is jointly influenced by multiple drilling parameters and exhibits strong coupling and pronounced nonlinear

**基金项目:** 深地国家科技重大专项 (2024ZD1003102); 高等学校学科创新引智计划 111 项目 (B17040); 中国地质大学(武汉)“地大学者”人才岗位科研启动经费资助 (项目编号 2023115); 中国地质大学(武汉)中央高校基本科研业务费专项资金资助项目 (CUG240634).

**作者简介:** 孙皓 (1999—), 男, 博士生, 从事地质钻进过程智能建模与优化等方面的研究。ORCID: 0009-0009-7753-5357. E-mail: haosun@cug.edu.cn

**\*通讯作者:** 吴俊东 (1992—), 博士, 教授, 从事欠驱动机器人控制、软体机器人建模与控制、非线性系统分析与控制等方面的研究。ORCID: 0000-0002-5268-2731. E-mail: jdwu@cug.edu.cn

characteristics. The ROP at the current time step is determined not only by the instantaneous drilling parameters and formation conditions, but also closely related to the historical evolution of ROP, drilling parameters, and drilling states over previous time steps, showing evident temporal dependence and sequence memory effects. To address the challenges posed by complex operating conditions, high noise levels in real drilling data, and the difficulty of traditional models in effectively capturing long-term temporal dependencies, this study investigates real drilling operations from a drilling site in Xiangyang and proposes a dual-layer CNN-LSTM-based ROP modeling method. First, to cope with the coexistence of multiple drilling conditions in raw data, a normal drilling condition identification and automatic well-section segmentation approach is developed. Combined with abnormal data cleaning, segment-wise filtering, and scale transformation, a systematic data preprocessing scheme is established. Second, a time-lagged mutual information analysis is employed to quantitatively analyze the nonlinear and temporal correlations between ROP and multiple drilling parameters, based on which the model input variables and the length of the time window are determined. On this basis, a ROP modeling framework is constructed by integrating multi-scale convolutional feature extraction with

temporal sequence modeling through parallel dual-layer CNNs cascaded with an LSTM network. Experimental results demonstrate that the proposed model achieves superior accuracy and stability on real drilling data compared with traditional machine learning models and deep learning models with single network structures. The results indicate that the proposed approach can effectively capture the temporal evolution characteristics of ROP during drilling operations, providing a feasible data-driven solution for ROP modeling under complex drilling conditions.

**Key words:** Rate of penetration modeling; drilling data processing; time-lagged mutual information; convolutional neural network; long short-term memory network

## 0 引言

钻速是描述钻进效率的重要指标之一，能够直接反映钻头—地层相互作用情况以及钻进过程的综合状态。在地质钻进、石油钻探等领域，建立精确的钻速模型对于钻进参数优化、工况识别及钻进智能控制具有重要意义（杜胜等，2026；陆承达等，2023；Gan *et al.*, 2023）。然而，实际钻进过程中地层条件复杂多变，钻速受多种钻进参数与地层特性的耦合作用影响，同时伴随显著的非线性、强时序相关性以及工况频繁切换等特征，使得钻速变化机理难以通过解析模型准确描述。因此，钻速的高精度建模一直是能源勘探领域中的关键问题之一。

传统钻速建模方法主要基于岩石力学与钻进机理分析，通过建立钻压、转速、岩石强度等参数与钻速之间的解析或半经验关系式实现钻速建模。李玮等(2013)通过分析牙轮钻头侵入井底岩石的力学特性，建立了钻速与井底压力、转速、钻头牙齿数等参数之间的关系模型。有学者从钻头破岩机制出发，分析钻头与岩石之间的相互作用，建立钻速的机理模型（刘军波等，2015；管志川等，2019）。这类方法物理意义明确，但往往依赖于理想化假设，对地层非均质性、钻进参数强非线性耦合以及现场复杂扰动的适应能力有限。

随着现场传感器系统的不断完善，钻进过程中能够获取大规模、多变量的监测数据为数据驱动建模方法提供了基础条件。近年来，机器学习与深度学习方法逐渐被引入钻速建模研究中。有学者为验证数据驱动模型的有效性，引入三种机理建模方法进行对比，实验结果表明，数据驱动建模方法在输出精度上要优于机理建模方法（Hegde *et al.*, 2017）。

经典机器学习方法不需要了解钻进过程中岩石内部复杂的力学关系，能够基于实际钻进数据建立有效的非线性模型（Barbosa *et al.*, 2019；Najjarpour *et al.*, 2022）。Kor 和 Altun (2020) 将支持向量回归（Support vector machine, SVR）方法与统计分析建模方法进行对比，仿真结果表明基于数据驱动的 SVR 方法要优于统计分析方法。Ahmed 等 (2019) 将机器学习建模方法，包括支持向量回归方法、BP 神经网络、最小二乘支持向量回归方法进行对比，结果表明最小二乘支持向量回归方法在模型精度方面优于其他方法。经典机器学习方法在一定程度上提高了钻速输出精度，但多数研究仍侧重于静态或短时建模，难以捕捉钻进过程中的长时序依赖特征。

钻进过程具有明显的时间依赖性，钻速不仅受当前钻进参数影响，还与历史参数状态密切相关。

传统循环神经网络在处理长时间序列时容易出现梯度消失或梯度爆炸，难以有效捕捉长期依赖关系，其改进模型长短期记忆网络 (Long short-term memory, LSTM) 解决了这一问题 (Pan *et al*, 2021)，在时间序列建模方面表现出较强优势，已被应用于钻速建模问题。然而，单一 LSTM 结构在高噪声、多尺度时序特征提取方面仍存在一定局限 (Zhu *et al*, 2022; 谷亚冰, 2023)。因此，将卷积神经网络 (Convolutional neural network, CNN) 等多种深度学习方法与 LSTM 融合，是改进单 LSTM 能力有限问题的有效手段。

此外，在钻速模型构建之前，有必要对原始钻进数据进行数据处理与工况识别，以剔除与钻速演变机理无关或具有强干扰性的工况数据，保证模型训练样本的一致性与有效性，为建模提供可靠的数据基础。现有研究中对钻进数据预处理、正常工况识别及井段划分的描述相对简化，不同工况数据混杂往往会削弱模型的泛化能力，影响钻速建模结果的可靠性。尽管有学者使用 LSTM 将深度序列等效为时间序列实现钻速建模 (Yuan *et al*, 2025; Bai *et al*, 2025)，但这一等效方式忽略了现场实际测量时深度的不连续特性，容易引入伪时序关系并造成数据样本之间的时序错配。因此，在钻速模型构建之前，数据处理与工况识别方法非常重要。

基于上述讨论，围绕钻速建模问题，本文以实际钻进过程为研究对象，从数据处理、模型结构设计等方面开展研究。本文的主要工作和创新点体现在两个方面：

(1) 提出一套基于经验和分段滤波的钻进数据预处理方案，通过正常钻进工况识别、异常井段剔除及分段滤波与尺度变换，提高了原始数据的有效性与一致性；

(2) 构建一种双层 CNN-LSTM 钻速模型，通过并联多尺度 CNN 提取多重数据特征，与 LSTM 时序网络相结合，提高了模型对复杂非线性与长期时序依赖关系的映射能力，仿真实验结果证明该方法的建模精度要优于经典机器学习等其他方法。

本文其余内容安排如下：第 1 章描述地质钻进过程，介绍钻速建模的机理背景，并设计钻速建模方案；第 2 章详细阐述数据处理流程及相关性分析方法；第 3 章给出双层 CNN-LSTM 钻速模型结构；第 4 章通过实际钻进数据对模型进行验证并与多种方法进行对比分析；第 5 章总结全文并对后续研究

工作进行展望。

## 1 钻进过程描述与钻速建模方案设计

为实现对钻速的有效建模，有必要从工程角度对地质钻进过程及其主要钻进参数进行系统分析，明确各参数在钻进过程中的物理含义及其对钻速变化的潜在影响。在此基础上，结合钻进数据的时序特性与建模需求，构建合理的钻速建模方案。

### 1.1 地质钻进过程描述

地质钻进过程是一个典型的多参数耦合、强非线性且具有显著时变特性的复杂工程。在钻进过程中，钻头在钻压与扭矩的共同作用下破碎地层岩石，钻柱系统在井眼约束条件下产生复杂的动力学响应。受地层岩性变化、井眼结构及操作参数调整等多种因素影响，钻进过程工况复杂且具有长时序影响，这使得钻速的精确建模存在较大挑战。

钻速作为衡量钻进效率的核心指标，反映了钻头破碎地层岩石的综合能力及钻进过程的综合状态，其变化受多种可测钻进参数的共同影响。地质钻进过程中可测参数及其对应的传感器位置分布如图 1 所示。

井深与钻位由绞车下放的拉绳长度测算，反映钻进过程的空间位置变化，不同井深对应的地层岩性和力学性质存在显著差异。随着井深增加，地层通常呈现出孔隙结构趋于致密、抗压强度提高、岩石可钻性降低等特征，从而对钻速产生抑制作用。因此，井深与钻位不仅是钻进过程的几何描述量，同时也隐含了地层条件变化的信息，对钻速具有间接但重要的影响。




图1 地质钻进过程中的传感器分布

Fig.1 Sensor distribution in the geological drilling process

钩载是地面测量得到的钻柱整体受力状态，而钻压是作用于钻头的有效轴向载荷。适当增大钻压有助于提高钻头对地层的破碎效率，但过大的钻压可能引发粘滑振动或钻柱屈曲等不利情况，导致钻速波动。转速和扭矩分别表征钻头旋转状态及破岩阻力，其变化受地层条件和钻柱动力学特性共同影响，与钻速之间存在复杂的非线性耦合关系。

此外，游车位置与游车速度反映绞车系统的运行状态，钻速通常由游车速度等比例计算得到，在工况切换或钻进参数调整过程中，游车速度的短时波动可能对钻速的计算产生间接干扰。钻井液泵量、泵压及立管压力主要表征钻井液循环系统的工作状态，对钻速的影响主要通过井底清洁效率和摩擦阻变化等间接途径体现。

在实际钻进过程中，上述参数并非独立作用，而是通过钻柱系统和钻头—地层相互作用形成高度耦合的动态系统并表现出明显的滞后效应，当前钻速不仅与当前时刻的操作参数有关，还与历史参数

状态密切相关。这种滞后效应使得钻速变化呈现出典型的时间序列特性。因此，钻速建模本质上属于多变量、非线性、强时序的动态系统建模问题，传统静态或低阶模型难以准确刻画其内在变化规律。

## 1.2 钻速建模方案设计

针对地质钻进过程复杂、参数强耦合以及状态变化频繁等特点，本文提出一种基于双层 CNN-LSTM 的钻速建模方案。该方案以襄阳某井场实测数据为基础，通过系统的数据预处理、参数时滞互信息相关性分析以及双层 CNN-LSTM 钻速建模方法，实现多参数改变对钻速变化的有效映射，整体建模方案如图 2 所示。

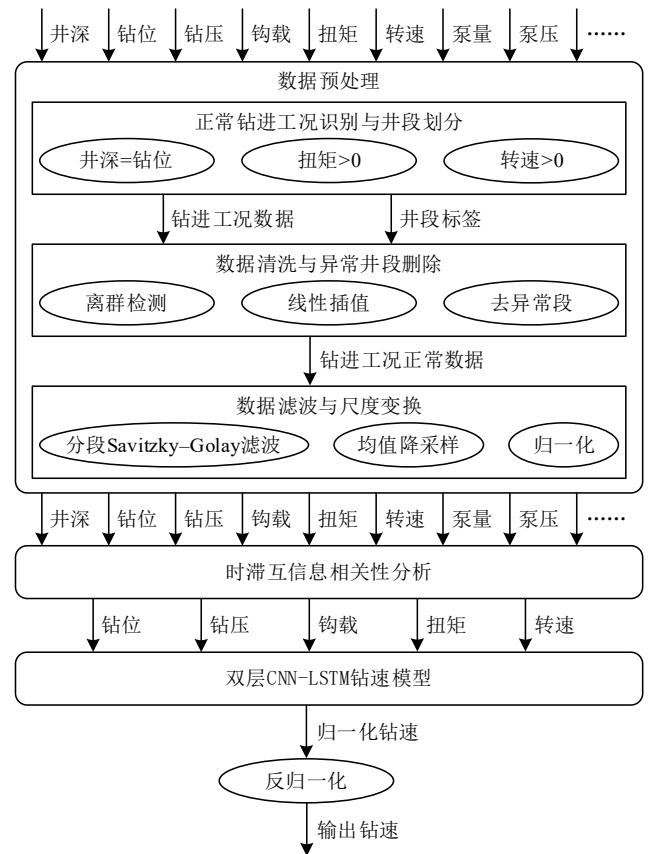


图2 钻速建模方案

Fig.2 ROP modeling scheme

井场原始数据通常存在噪声干扰、异常值及多工况混杂等问题，若直接用于模型训练，容易导致建模结果偏差。因此，在建模前需进行数据预处理。本文的数据预处理首先通过井深、钻位及扭矩、转速等关键参数的阈值判别，识别正常钻进工况并进行井段划分，剔除起下钻、停钻、扫孔等非

钻进数据，保证样本工况一致性；其次，针对传感器异常与信号突变，采用离群检测与插值方法进行数据清洗，并删除异常井段，避免干扰模型训练；最后，通过滤波降低高频噪声影响，并进行归一化等尺度变换，消除量纲差异，提高模型训练的稳定性与可靠性。

数据预处理后需要对各钻进参数与钻速之间进行时滞互相关性分析，确定对钻速影响显著的关键参数及其对应的时间滞后结构，为后续动态模型的输入设计提供依据，避免盲目增加模型复杂度。

基于时滞互相关性分析的结果，构建双层 CNN-LSTM 的钻速模型。该模型通过双层卷积神经网络提取多变量时序数据中的局部特征，并利用长短期记忆网络描述钻速变化过程中的长期依赖关系，从而反映多参数与钻速的映射关系。

建模过程中，首先对输入参数构建统一的时间窗口，并对各变量进行归一化处理，以消除不同物理量量纲和数值尺度差异对模型训练的影响，提升网络训练的稳定性与收敛效率，随后通过模型训练实现对钻速映射关系的辨识。模型输出经反归一化处理后还原至实际物理量尺度，得到最终钻速输出结果，并通过多种评价指标对模型性能进行验证。

## 2 数据处理与相关性分析

井场实测钻进数据直接反映了钻进过程的真实运行状态，但不可避免地包含噪声干扰、异常工况以及测量误差等问题。若未经处理直接用于建模分析，容易导致模型学习到非物理或非代表性的特征，从而影响钻速输出结果的可靠性。因此，在开展钻速建模与相关性分析之前，有必要对原始数据进行系统的数据处理与筛选。

### 2.1 数据预处理

本文的数据预处理过程主要包括三个阶段：正常钻进工况识别与井段划分、数据清洗与异常井段删除，以及数据滤波与尺度变换。通过多层次的数据处理，尽可能保留钻进过程的真实动态特性，削弱噪声和异常数据对建模结果的影响。

#### 2.1.1 正常钻进工况识别与井段划分

在实际钻进作业中，井场数据中往往混杂着多种非钻进工况，如扫孔、冲孔、提钻、停钻以及异常卡钻等。这些工况下钻进参数的变化特征与正常钻进过程存在显著差异，若不加区分地纳入建模数

据集，将对钻速建模产生明显干扰。

结合钻进作业机理与井场参数特性，不同工况通常表现出如下特征：在扫孔和冲孔工况下，钻具处于提钻或悬空状态，钻位小于井深；在提拉岩心过程中，钻头未与井底接触，扭矩与转速通常接近于零；在钻头陷入泥浆等异常工况下，转速不为零而扭矩接近于零；在停钻过程中，扭矩输出为零，而转速可能由于惯性效应短时间内保持非零值。

基于上述分析，本文将正常钻进工况定义为满足以下基本条件的数据点：钻位与井深一致，表明钻头与井底处于接触状态；转速大于零，钻具处于旋转切削状态；扭矩大于零，表明钻头正在对地层施加破岩作用。仅保留同时满足上述条件的数据作为正常钻进数据，用于后续分析与建模。

此外，由于井深测量存在累积误差，且在每次重新开始钻进时通常会对井深进行重新设定，导致井深数据在局部范围内出现突变。为此，本文根据井深变化的浮动范围判断是否进入新的钻进区段，并据此对数据进行井段划分，为后续分段分析与处理提供依据。同时，为每个井段添加唯一标签，以便在数据清洗与数据滤波过程中进行区分。

井段划分为后续数据处理与建模提供了相对统一的时间和空间约束。在同一井段内分段滤波处理，可以有效避免跨井段滤波导致的边界失真。在异常剔除过程中，有利于基于井段统计特征识别局部异常，避免不同工况混杂导致的误判。在模型构建过程中，可保证训练样本在地层条件与工况上相对一致，提高模型训练与测试的稳定性。

#### 2.1.2 数据清洗与异常井段删除

在完成正常钻进工况筛选后，数据中仍可能存在局部异常值或异常数据段。例如，部分数据段中出现钻压小于零而钻位持续增大的情况，或钻速出现异常突增甚至小于零等现象。这类数据通常由传感器故障、信号丢失或通信异常等原因引起，不具有物理意义。

针对上述特殊情况，本文采用四分位距方法对各钻进参数进行离群值检测。对于被判定为离群值的数据点，首先将其从原始序列中删除，再采用线性插值方法进行补充，以保证时间序列的连续性。

进一步地，在井段层面进行异常性评估。对于某些井段，其离群值比例明显偏高，当某一井段中离群值占比超过 50% 时，认为该井段存在系统性数据采集异常。针对这类异常井段，本文不再对其进

行局部修复，而是直接对整段数据进行删除处理，以避免异常数据对模型训练产生整体性干扰。

通过上述步骤，能够在保留正常钻进数据主要特征的同时，有效剔除明显不符合物理规律的异常数据。

### 2.1.3 数据滤波与尺度变换

在完成数据清洗后，钻进参数序列中仍可能存在高频噪声和局部突变，这些因素不利于后续的相关性分析与模型训练。为此，本文进一步对数据进行滤波与尺度变换处理。

首先，基于井段划分结果，对各钻进参数采用分井段 Savitzky-Golay 滤波方法进行平滑处理。该方法能够在降低噪声的同时较好地保留信号的变化趋势和局部特性。

接下来，为进一步降低数据冗余并减少计算量，本文将原始 1 Hz 采样频率的数据降采样至 0.2 Hz。在降采样过程中，采用时间窗口内取均值的方式替代原始数据，从而在缩小数据规模的同时实现进一步的低通滤波效果。

最后，考虑到不同钻进参数在量纲和数值范围上的差异，为避免某些变量在相关性分析和模型训练中占据主导地位，本文对所有输入变量进行归一化处理。通过尺度统一，提升相关性分析结果的稳定性，并提高后续网络模型训练的收敛性能。

## 2.2 时滞互信息相关性分析

钻进过程具有显著的时序特性，钻速不仅与当前时刻的钻进参数有关，还受到历史参数状态的影响。因此，在构建钻速模型输入结构时，有必要同时考虑参数之间的非线性关系以及可能存在的时间滞后效应。

互信息是一种基于信息论的相关性度量方法，能够度量两个随机变量之间的统计依赖程度，其定义为变量联合概率分布与边缘概率分布之间的信息冗余量。对于随机变量  $X$  和  $Y$ ，互信息可表示为

$$I(X, Y) = \sum_x \sum_y p(x, y) \log \frac{p(x, y)}{p(x)p(y)} \quad (1)$$

其中， $p(x, y)$  为  $X$  和  $Y$  的联合概率分布， $p(x)$  和  $p(y)$  分别为其边缘概率分布。当两变量相互独立时，互信息取值为零，互信息值越大则表明变量间的统计相关性越强。与传统线性相关系数不同，互信息不依赖于线性假设，适用于复杂非线性系统的相关性分析。

在此基础上，引入时间滞后因素，可构建时滞互信息分析方法 (Ji *et al*, 2021)。考虑钻进过程的时序特性，在互信息计算中引入时间滞后参数  $\tau$ ，可得到  $Y$  与  $X$  之间的时滞互信息，其表达式为

$$I(X, Y, \tau) = \sum_{x_t} \sum_{y_{t+\tau}} p(x_t, y_{t+\tau}) \log \frac{p(x_t, y_{t+\tau})}{p(x_t)p(y_{t+\tau})} \quad (2)$$

其中， $x_t$  表示参数  $X$  在时刻  $t$  的取值， $y_{t+\tau}$  表示参数  $Y$  在时刻  $t+\tau$  的取值。通过改变时间滞后  $\tau$ ，可以分析  $Y$  与  $X$  在不同时间尺度下的非线性依赖关系。

## 3 双层 CNN-LSTM 钻速模型结构

针对钻进过程钻速受多参数耦合影响、且具有显著时间相关性的特点，本文构建了一种双层 CNN-LSTM 钻速动态建模模型。该模型通过卷积神经网络提取多变量钻进参数中的局部时序特征，并利用长短期记忆网络反映钻速变化过程中的长期依赖关系，实现对钻速变化规律的有效建模。

### 3.1 模型整体架构设计

本文提出的钻速模型由双层并联 CNN 模块与单层 LSTM 模块串联构成，模型整体结构如图 3 所示。网络输入为经预处理后的多变量钻进参数时序数据，输出为对应时刻的钻速输出值。

在模型结构设计中，首先通过双层 CNN 对输入数据进行并行特征提取，分别获取不同时间尺度下的局部变化特征；随后将提取到的多尺度特征进行拼接，输入至 LSTM 网络，以反映钻速随时间变化的动态特性，最后经全连接层输出钻速结果。

该结构兼顾了模型表达能力与计算效率，既能够充分挖掘多变量钻进数据中的关键信息，又避免了网络结构过深带来的训练困难。

### 3.2 双层 CNN 特征提取机制

卷积神经网络的核心在于卷积层，其通过局部感受野和权值共享机制，能够有效提取时序数据中的局部相关特征。在钻速建模问题中，不同钻进参数在不同时间尺度上对钻速的影响存在差异，单一尺度的卷积操作难以全面表征其动态特性。

为此，本文采用双层 CNN 并联结构，分别设置 3 核和 7 核两个不同大小的卷积核，对同一输入数据进行并行卷积运算。通过这种方式，模型能够同时获得两种时间尺度的时序特征，为后续时序建模

提供更加丰富的信息输入。

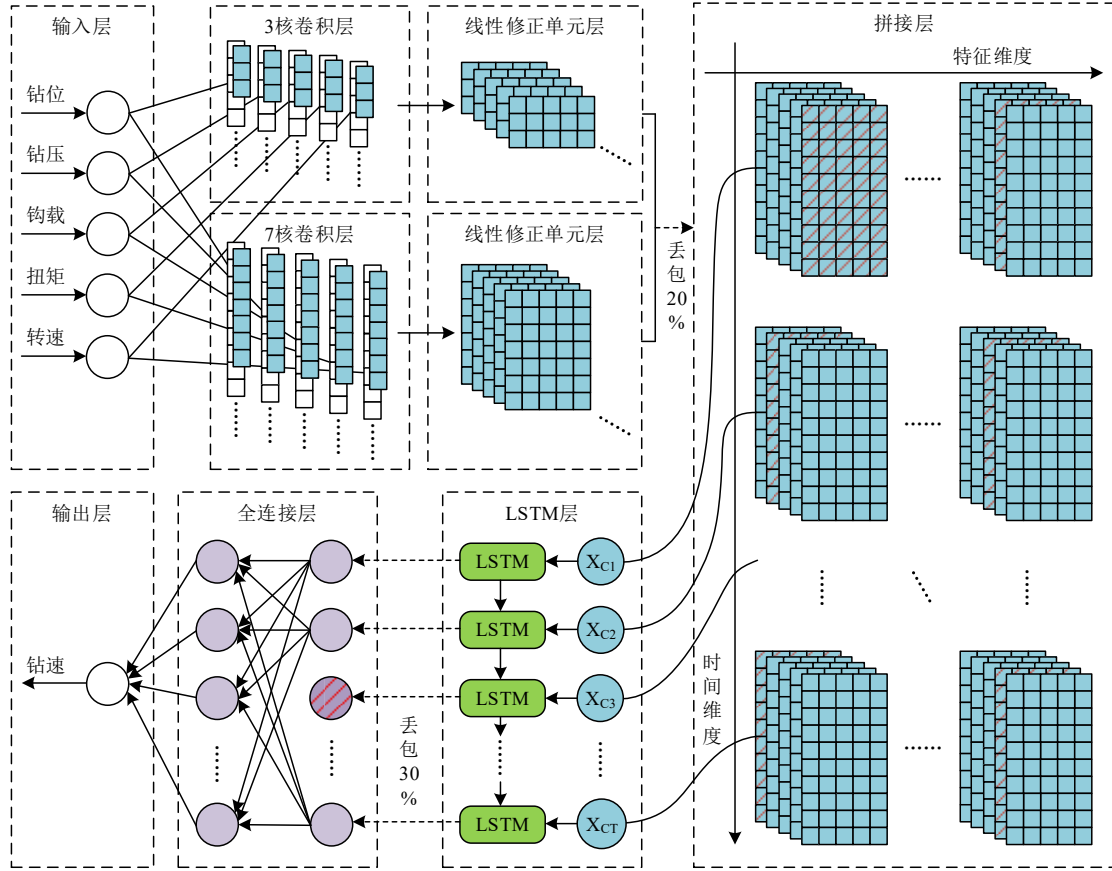


图3 双层 CNN-LSTM 钻速模型网络结构

Fig. 3 Network architecture of the dual-layer CNN - LSTM ROP model

卷积操作后，引入线性修正单元对特征进行非线性映射，从而增强模型对复杂非线性关系的表达能力。随后，对不同卷积通道的输出特征拼接，形成统一的特征表示，并作为 LSTM 网络的输入。

相比单一 CNN 结构，双层 CNN 并联设计在显著提升特征多样性的同时，并未大幅增加模型计算复杂度，有利于在保证钻速建模精度的前提下提高训练与推理效率。

### 3.3 LSTM 时间序列建模原理

LSTM 作为循环神经网络的一种改进结构，通过引入门控机制显著增强了对长期依赖信息的建模能力。在 LSTM 网络中，每一个时间步均通过门控机制对信息选择性传递，其核心在于对当前状态  $C_t$  的更新与维护。具体而言，LSTM 的基本单元由遗忘门、输入门和输出门构成，结构如图 4 所示。

在时刻  $t$ ，遗忘门用于决定历史细胞状态信息的保留程度，其输出可表示为

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_{C_t}] + b_f) \quad (3)$$

其中， $x_{C_t}$  为当前时刻 CNN 特征输入， $h_{t-1}$  为上一时刻的隐含状态， $\sigma(\cdot)$  表示 Sigmoid 激活函数， $W_f$  和  $b_f$  分别为遗忘门的权重矩阵和偏置项。 $f_t$  的取值范围为  $[0,1]$ ，用于控制历史状态  $C_{t-1}$  的遗忘比例。

输入门用于控制当前时刻新信息写入细胞状态的比例，其计算过程为

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_{C_t}] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_{C_t}] + b_c) \quad (5)$$

其中， $\tilde{C}_t$  表示候选状态，用于描述当前输入所携带的新信息。

在遗忘门和输入门的共同作用下，状态更新为

$$C_t = f_t \odot C_{t-1} \oplus i_t \odot \tilde{C}_t \quad (6)$$

其中， $\odot$  表示 Hadamard 乘积。该更新机制使得 LSTM 能够在时间维度上有选择地保留对系统演化具有重要意义信息，同时抑制无关或冗余特征的累积。

输出门用于决定当前时刻隐含状态的输出，其表达式为

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_{C_t}] + b_o) \quad (7)$$

$$h_t = o_t \odot \quad (8)$$

由此得到的隐含状态  $h_t$  作为当前时间步的输出，并传递至下一时刻参与后续计算。

通过上述门控机制，LSTM 能够在时间序列建模过程中有效缓解传统循环神经网络中梯度消失或爆炸问题，实现对长期时序依赖关系的稳定建模。

在钻速建模过程中，钻进数据通常包含数万条连续采样的钻进参数记录。结合第 2 章中基于时滞互信息的相关性分析结果可知，钻速建模问题具有长期时序相关性特征。因此，采用 LSTM 网络对 CNN 提取的特征序列进行建模，能够有效反映钻速随时间变化的内在动态规律。

### 3.4 模型正则化与训练策略

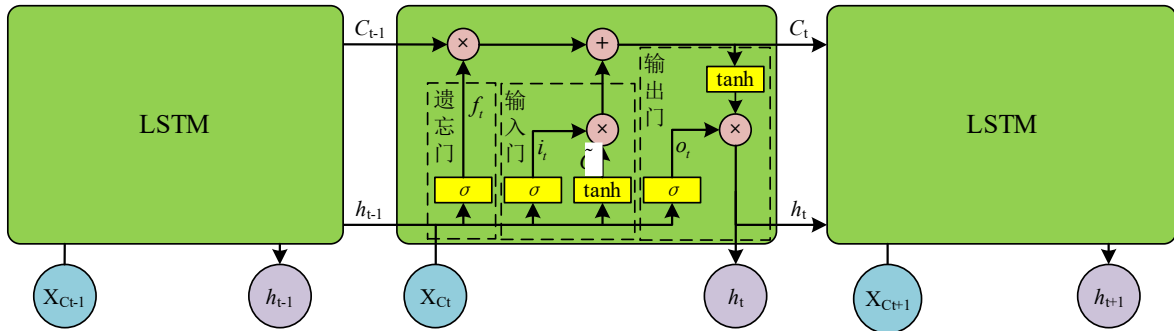


图 4 LSTM 结构图

Fig. 4 Structure of the LSTM unit

## 4 钻速模型实验设置与结果讨论

为验证所提出钻速建模方法在实际钻进数据上的有效性，本章基于襄阳某井场实测钻进数据，开展钻速模型的仿真实验与结果分析工作。首先，对实验数据来源和数据处理流程进行说明，确保模型训练与验证数据的合理性与一致性；随后，通过实验数据相关性分析进一步验证模型输入变量选取及时间窗口设置的合理性。在此基础上，开展双层 CNN-LSTM 钻速模型的仿真实验，并对模型输出性能进行定量评估。最后，通过与多种典型钻速建模方法的对比分析，从精度和稳定性等方面讨论所提出方法的优势与不足。

### 4.1 实验设置与数据处理

本文实验数据选自襄阳某井场 164m - 266m 实际钻进过程的现场监测数据，原始采样频率为 1 Hz。原始数据共包含 279485 组观测样本，覆盖正常

为提升模型的泛化能力并保证训练过程的稳定性，本文在网络中引入丢包层与学习率衰减机制。

丢包层通过在训练过程中随机舍弃部分神经元输出，有效削弱特征之间的局部依赖关系，从而降低模型对训练数据的过拟合风险。在本文模型中，丢包层分别作用于 CNN 特征输出与 LSTM 隐含层，有助于提升模型在不同井段和工况下的输出结果鲁棒性。

此外，为兼顾模型训练速度与参数收敛稳定性，本文采用学习率衰减机制对网络训练过程进行调节。在训练初期设置较大的学习率，以加快模型参数的收敛速度；随着训练的进行，逐步降低 CNN 和 LSTM 的学习率，使网络参数能够稳定逼近最优解，从而提高模型输出精度与训练可靠性。

钻进、停钻、扫孔、冲孔等多种典型钻进工况，能够较全面地反映实际钻进过程中参数变化特征。

由于现场监测数据为离散采样，根据现场数据的特性，实际处理中将“钻位与井深一致”这一条件选取误差范围  $\pm 0.0001\text{m}$ ，并按照井深变化的浮动范围大于  $0.01\text{m}$  作为井段划分条件。按照第 2 章提出的正常钻进工况识别规则，对原始数据进行工况筛选与数据清洗后，获得正常钻进数据共 139402 组，识别得到连续正常钻进井段 8 段。

为降低噪声干扰并减少样本冗余，在井段内对数据进行分段 Savitzky-Golay 滤波处理，数据滤波前后的数据数值分布如图 5 所示。最后，将采样频率由 1 Hz 降至 0.2 Hz，最终用于模型训练与验证的数据量为 27816 组。

由图 5 中可以看出，经过分段 Savitzky-Golay 滤波处理后，各主要钻进参数的概率分布形态整体保持一致，未发生明显偏移，这表明滤波过

程未改变数据的统计特性。

扭矩、钻压和钩载的原始数据分布呈现出一定程度的展宽和长尾特征，反映了钻进过程中局部突变和高频波动的存在。滤波处理后，其分布曲线更加集中，极端值出现频率明显降低，但主峰位置基

本保持不变，说明滤波主要抑制了异常波动和测量噪声，局部离散现象得到缓解，而未削弱参数的有效变化范围。

转速数据在原始状态下表现出较为明显的离散特征和尖峰分布，这与现场钻进过程中频繁的参数

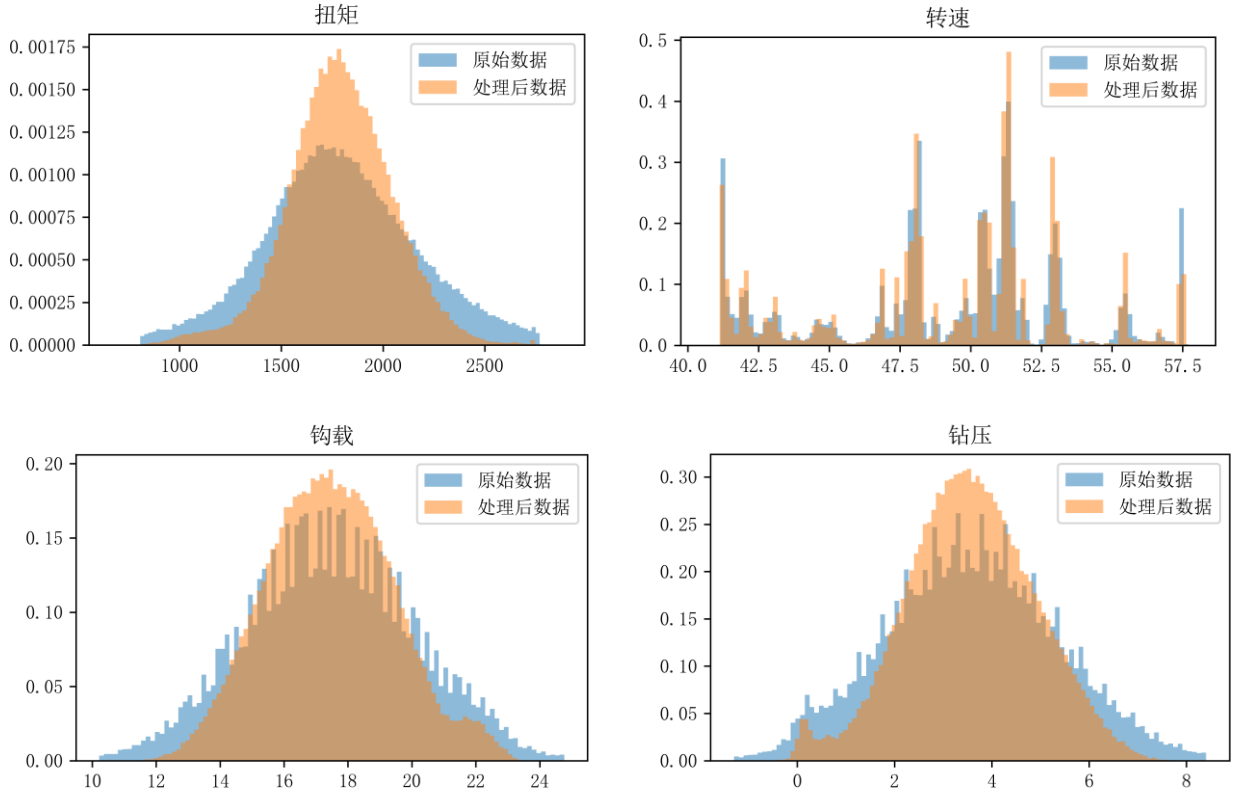


图 5 滤波前后数据数值分布图

Fig.5 Data distributions before and after filtering

调整和工况切换有关。经滤波处理后，其多峰特征仍然保留，说明滤波过程并未消除转速变化所反映的真实工况差异。

总体来看，分段 Savitzky - Golay 滤波有效削弱了钻进参数中的高频噪声和局部突变，使各参数分布更加集中和平滑，同时保持了原始数据的整体分布形态和物理变化特征，为后续的相关性分析和深度学习模型训练提供了稳定、可靠的数据基础。

#### 4.2 实验数据相关性分析

根据处理后的数据集，结合本文 2.2 节中公式 (2)，以钻速作为目标变量  $Y$ ，钻位、钻压、钩载、转速、扭矩等钻进参数作为  $X$ ，计算钻速与其他钻进参数之间在不同时间滞后条件下的互信息值，分析结果热力图如图 6 所示。由热力图可知，钻速与钻位、钻压、钩载、转速和扭矩等参数之间均存在

显著的非线性相关关系，但不同参数的互信息强度及其随时间滞后的变化规律存在明显差异。总体来看，钻位与钻速在前 30 个时间步的时间滞后范围内保持 1.185 以上的互信息水平，且互信息值平缓衰减，表明钻速变化与钻进空间位置及其变化过程具有较强的长期关联特征。钻压和钩载与钻速的互信息值在前 10 个时间步的时间滞后范围内保持 0.700 以上的互信息系数值，且在第 3 个时间步的滞后处达到互信息系数峰值，分别为 0.757 和 0.760。同时，扭矩与钻速的互信息值在前 14 个时间步的滞后范围内保持 0.649 以上，在第 5 个时间步的滞后处达到峰值。钻压、钩载、扭矩三个量的时滞相关性结果表明，力学参数对钻速的影响更偏向于短时动态作用。此外，转速与钻速之间的互信息值整体高于钻压和扭矩，在第二个时间步的时间滞后出现明显峰值 1.052，且互信息系数随时间的增大，衰减

较为平缓，甚至在 30-60 个时间步的滞后范围内存在新的相关性峰值，反映出旋转参数对钻速的影响更偏向于长时动态作用。虽然随着时间滞后的进一步增大，各参数与钻速之间的互信息值整体呈下降趋势，但该结果仍表明钻速与上述钻进参数直接有着不可忽视的滞后响应特征。

此外，由于钻速由游车速度随时间变化计算得到，游车速度在零时滞条件下与钻速表现出非常高的相关性。游车位置与井深及钻位在实际钻进过程中具有一致的变化趋势，三者之间主要存在尺度差异，因此其相关性变化规律基本一致。考虑到钻位直接反映钻头位置，本文选择钻位作为物理位置输

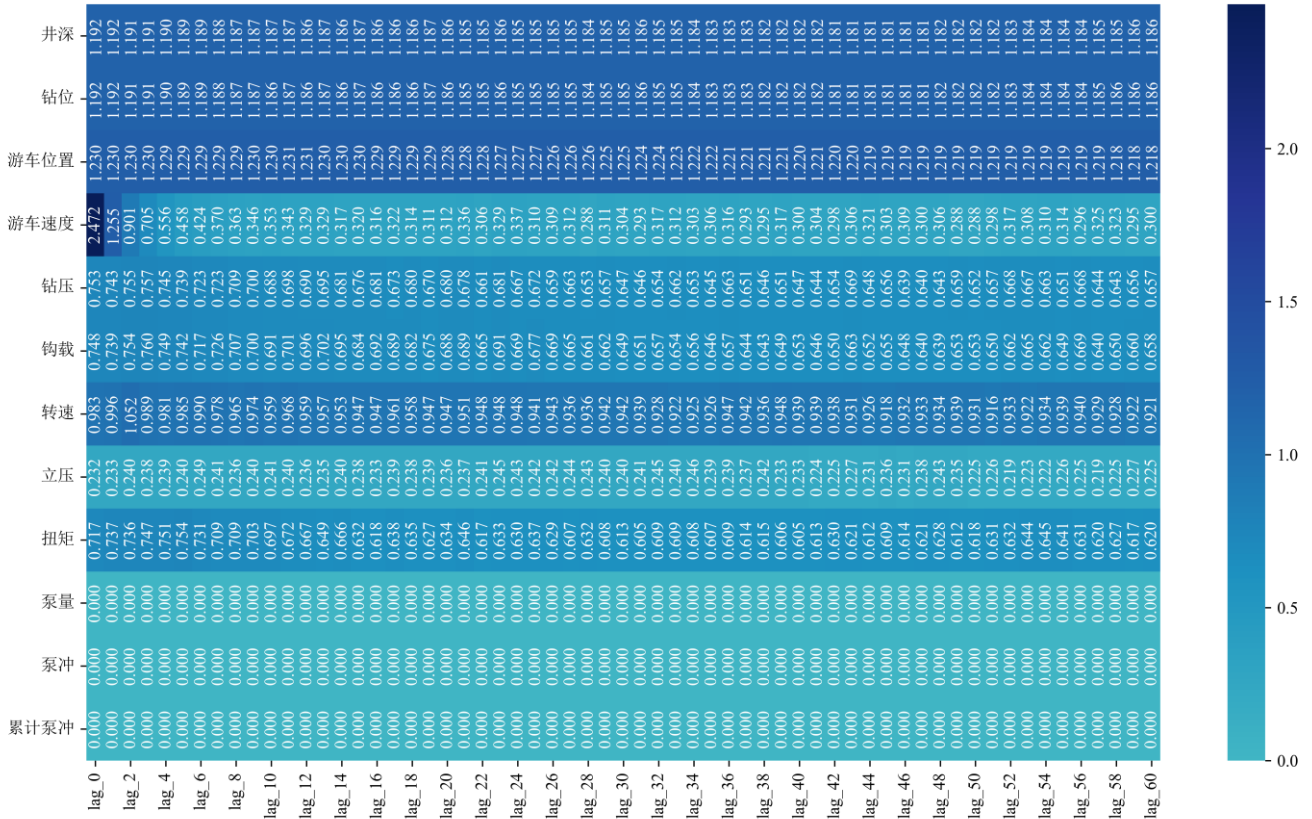


图 6 钻速时滞互信息相关性分析热力图

Fig.6 Heatmap of time-lagged mutual information between ROP and drilling parameters

入。在本数据集对应的实际钻进过程中，受钻井液泵压和泵量测量异常的影响，钻井液相关参数与钻速之间未表现出稳定的统计相关关系，立管压力与钻速之间仅呈现出较弱的相关性。基于上述分析结果，本文在后续模型构建中未将立压、泵量、泵冲这类钻井液相关参数作为网络输入。

综合分析结果表明，钻速建模问题具有明显的多变量、非线性及时序相关特征，且不同钻进参数对钻速的影响具有不同的时间尺度。这一结果为后续建立钻速时序网络模型提供了理论依据，同时为模型输入变量类型与时间窗口结构的设计提供了定量参考，避免输入选择的随意性。

### 4.3 钻速模型仿真实验结果

基于时滞互信息相关性分析结果，本文选取钻

位、钻压、钩载、扭矩和转速作为模型输入变量，输入形式为前 60 个时间步的多变量序列，模型输出为当前时间步的钻速输出值。除图 3 设定的网络参数外，网络超参数配置如表 1 所示。此外，选用 Adam 优化器调整网络权重，学习率衰减策略为每 100 轮衰减 50%。

表 1 网络超参数配置

Table1 Hyperparameter Configuration of the Network

| 超参数类型     | 数值    |
|-----------|-------|
| 卷积通道数     | 64    |
| LSTM 隐层维数 | 128   |
| 训练轮次      | 300   |
| 学习率初值     | 0.001 |

所构建的双层 CNN-LSTM 钻速模型在测试集上的输出结果如图 7 所示,可以看出模型输出的钻速曲线整体上能够较好地跟踪实际钻速的变化趋势,在稳定钻进阶段和钻速突变区间均具有较好的拟合效果。结果表明,所提出的双层 CNN-LSTM 模型在钻速建模精度和整体拟合能力方面均表现良好,能够有效反映钻进过程中的非线性与时序特征。

需要指出的是,在局部时间段内,原始钻速数据中仍可观察到明显的尖峰和突变现象,模型在这些时刻的输出误差相对较大。该类尖峰并不完全来源于真实地层性质的突变,而往往与钻进过程中的瞬态工况变化及测量方式有关。一方面,在调整钻压或转速等操作过程中,游车速度会在短时间内发




图 7 钻速建模输出结果图

Fig.7 Output results of the ROP model

生剧烈波动,而钻速通常由游车位置或游车速度经差分或换算得到,此类计算方式对高频噪声和瞬态扰动较为敏感,容易在原始钻速序列中引入非物理意义的瞬时峰值。另一方面,现场传感器在高振动、高冲击工况下可能出现短时信号失真或采样异常,从而进一步放大钻速的瞬态波动。

此外,这类尖峰通常持续时间较短,且缺乏与钻压、转速、扭矩等关键钻进参数的同步变化特征,表现出明显的孤立性和非连续性。从建模角度看,该类突变难以通过历史时序信息进行有效建模,也不具备稳定的物理驱动机制,因此对模型整体趋势学习的贡献有限。综合来看,模型在尖峰处的钻速输出偏差主要反映了钻进过程的强非平稳性及测量噪声的客观存在,而非模型结构或建模方法本身的不足。

#### 4.4 钻速建模方法对比与结果讨论

为验证所提出模型结构的有效性与必要性,本节基于 4.1 节处理后的数据和 4.2 节选取的输入变

量,采用相同的数据集和输入变量,进一步从模型类型与网络结构两个层面开展对比实验。一方面,将本文所提出方法与经典机器学习算法 BP 神经网络和 SVR 进行对比;另一方面,在深度学习框架下,对比 LSTM、单层 CNN-LSTM 与本文方法的建模性能,论证双层 CNN 并联的必要性。

首先选取 BP 神经网络和 SVR 作为对比方法,输出对比结果如图 8 所示。从结果可以看出,BP 神经网络在稳态钻进阶段能够大致反映钻速变化趋势,但在钻速突变区间和局部波动阶段存在明显滞后和幅值偏差,难以准确反映钻速的变化过程。这主要是由于 BP 神经网络以静态映射为主,难以有效建模钻进过程中的时序依赖关系。相比之下,SVR 模型的钻速输出结果波动剧烈,与真实钻速偏差较大,在多个时间区间甚至出现明显失真现象。

在深度学习框架下,进一步对比 LSTM、单层 CNN-LSTM 与本文方法,钻速输出结果如图 9 所示。从整体趋势来看,LSTM 模型已能够较好地捕捉钻速的时序变化规律,相比 BP 和 SVR,输出精度和稳定性均有明显提升。然而,在钻速快速变化或存在尖峰的区间,LSTM 仍存在一定程度的过平滑现象,对局部特征的响应不够敏感。

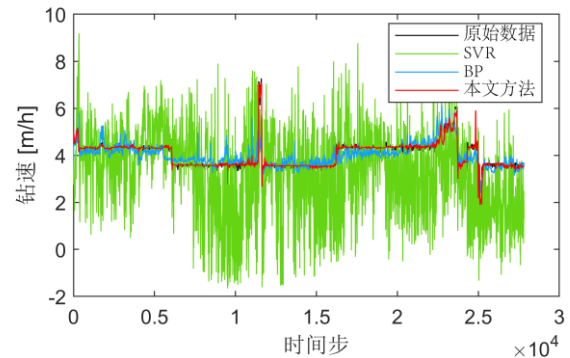


图 8 钻速建模机器学习方法对比

Fig.8 Comparison of machine learning methods for ROP modeling

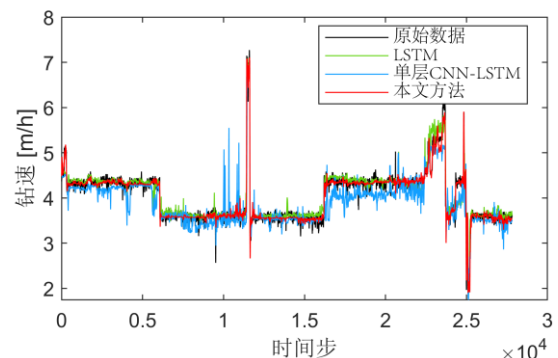


图 9 钻速建模深度学习对比

Fig.9 Comparison of deep learning methods for ROP modeling

引入 CNN 结构后, CNN-LSTM 模型在性能上得到进一步改善。单层 CNN-LSTM 通过卷积操作对多变量时间序列进行局部特征提取, 增强了模型对钻进参数组合模式的识别能力, 使输出结果在钻速突变区间的拟合效果有所提升。但在平稳钻进阶段, 单层 CNN-LSTM 存在异常突变和幅值偏差现象, 说明单层卷积在特征表达能力上仍存在不足。

为对不同模型的输出性能进行定量评估, 本文选取均方误差 (Mean-square error, MSE)、平均绝对误差 (Mean absolute error, MAE) 和决定系数 ( $R^2$ ) 作为评价指标, 其定义如下:

$$\text{MSE} = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2 \quad (8)$$

$$\text{MAE} = \frac{1}{T} \sum_{t=1}^T |y_t - \hat{y}_t| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{t=1}^T (y_t - \hat{y}_t)^2}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad (10)$$

其中,  $y_t$  为  $t$  时刻真实钻速值,  $\hat{y}_t$  为模型输出值,  $\bar{y}$  为真实钻速均值,  $T$  为样本时间步长。

其中, MSE 反映输出值与真实值之间误差平方的平均程度, 能够有效衡量模型对钻速突变段或剧烈波动段的拟合能力, 适用于评估模型整体精度及稳定性; MAE 表示误差绝对值的平均水平, 具有物理量纲一致、对异常值敏感度相对较低的特点, 能够直观反映模型输出的钻速平均偏差; 决定系数  $R^2$  用于衡量模型对真实钻速方差的解释能力, 其取值范围为  $(-\infty, 1]$ , 数值越接近 1 表明模型对钻速变化趋势的映射能力越强。

表 2 给出了不同模型的定量评价结果。可以看出, 本文方法在三项指标上均取得最优结果, 其 MSE 和 MAE 最小,  $R^2$  最高, 说明该模型在误差控制和整体拟合能力方面均具有明显优势。LSTM 方法次之, 而 BP 和 SVR 方法的性能明显落后, 尤其是 SVR, 其 MSE 和 MAE 显著高于其他模型, 且  $R^2$  为负值, 表明该模型在当前数据集上未能建立有效的输入—输出映射关系。这一结果说明, 在钻进过程这种强非线性、强时变且受多因素耦合影响的复杂系统中, SVR 方法对数据分布和参数敏感性较高, 钻速拟合能力受限。

表 2 五种建模方法评价指标对比

Table2 Comparison of evaluation metrics for five ROP modeling methods

| 建模方法        | MSE      | MAE      | $R^2$   |
|-------------|----------|----------|---------|
| BP          | 0.13722  | 0.25317  | 0.56254 |
| SVR         | 3.513    | 1.4924   | -10.2   |
| LSTM        | 0.03227  | 0.11369  | 0.89712 |
| 单层 CNN-LSTM | 0.077719 | 0.19799  | 0.75223 |
| 本文方法        | 0.011548 | 0.074203 | 0.96319 |

总体来看, 传统机器学习方法难以同时兼顾钻速数据的非线性特征与长时间序列依赖性, 难以满足高精度钻速建模的需求, 这也从侧面验证了引入深度学习模型的必要性。而 LSTM 虽能够有效建模钻速的时间依赖性, 但在复杂工况下对局部特征的提取能力有限。引入单层卷积结构后, 其整体误差仍高于纯 LSTM 模型, 说明单层卷积在特征表达能力上仍存在不足。

相比之下, 双层 CNN-LSTM 模型在各类工况下均表现出更优的输出性能。双层卷积结构能够逐层提取更高层次的时序特征表示, 在抑制噪声干扰的同时增强了对钻速变化关键模式的捕捉能力, 使得 LSTM 网络能够基于更具判别性的特征序列进行时序建模。这一结构在稳态钻进阶段和钻速突变阶段均展现出更好的拟合能力。

## 5 结论

本文针对实际钻进过程中钻速建模面临的数据噪声大、工况复杂及时序依赖显著等问题, 提出一种基于双层 CNN-LSTM 的钻速建模方法, 并结合数据处理与井段划分策略, 对模型有效性进行了验证。主要结论如下:

(1) 通过引入正常钻进工况识别与井段划分方法, 能够有效剔除非钻进工况及异常数据对模型训练的干扰, 为钻速建模提供结构清晰、物理一致性较强的数据基础;

(2) 时滞互信息相关性分析结果表明, 钻速与钻位、钻压、钩载、扭矩和转速等参数之间存在显著的非线性及时序相关关系, 验证了采用时序深度学习模型进行钻速建模的合理性;

(3) 双层 CNN-LSTM 模型通过多尺度卷积特征提取与 LSTM 时序建模的结合, 在输出精度与稳定性方面均优于传统机器学习模型及单一结构深度学

习模型,能够较好反映钻进过程中的钻速变化。

尽管本文方法在实验结果上取得了较好的效果,但仍存在一定不足。钻井液泵量泵压等扰动因素在现场条件下未能直接测量,其对钻速的影响尚未在模型中得到充分体现。此外,模型目前主要针对单井眼数据进行建模,对跨区域数据的适应能力仍需进一步研究。后续研究将从以下几个方面展开:一是引入多井场数据,构建具有更强泛化能力的钻速模型;二是结合钻进机理模型或物理约束,探索数据驱动与机理模型融合的钻速建模方法;三是进一步拓展模型在钻进参数优化和智能控制中的应用,为钻进系统提供更可靠的决策与控制支持。

## References

- Gan C, Wang X, Wang L, Cao W, Liu K, Gao H, Wu M, 2023. Multi-source information fusion-based dynamic model for online prediction of rate of penetration (ROP) in drilling process. *Geoenergy Science and Engineering*, 230: 212187.
- Hegde C., Daigle H., Millwater H., and Gray K., 2017. Analysis of rate of penetration (ROP) prediction in drilling using physics-based and data-driven models. *Journal of Petroleum Science and Engineering*, 159: 295-306.
- Barbosa L. F. F. M., Nascimento A., Mathias M. H., and Jr J. A. d C., 2019. Machine learning methods applied to drilling rate of penetration prediction and optimization - A review. *Journal of Petroleum Science and Engineering*, 183: 106332.
- Najjarpour M., Jalalifar H., and Norouzi-Apourvari S., 2022. Half a century experience in rate of penetration management: Application of machine learning methods and optimization algorithms - A review. *Journal of Petroleum Science and Engineering*, 208: 109575.
- Kor K., and Altun G., 2020. Is Support Vector Regression method suitable for predicting rate of penetration?. *Journal of Petroleum Science and Engineering*, 194: 107542.
- Ahmed O. S., Adeniran A. A., and Samsuri A., 2019. Computational intelligence based prediction of drilling rate of penetration: A comparative study. *Journal of Petroleum Science and Engineering*, 172: 1-12.
- Pan H., Su T., Huang X., Wang Z., 2021. LSTM-based soft sensor design for oxygen content of flue gas in coal-fired power plant. *Transactions of the Institute of Measurement Control*, 43 (1): 78-87.
- Zhu Z., Song X., Zhang R., Li G., Han L., Hu X., Li D., Yang D., Qin F., 2022. A Hybrid Neural Network Model for Predicting Bottomhole Pressure in Managed Pressure Drilling. *Applied Sciences*, 12 (13): 6728.
- Yuan Q., He M., Chen Z., Liu, M., Chen X., 2025. A real-time prediction method for rate of penetration sequence in offshore deep wells drilling based on attention mechanism-enhanced BiLSTM model. *Ocean Engineering*, 325: 120820.
- Bai K., Sheng M., Zhang H., Fan H., Pan S., 2025. Real-time drilling torque prediction ahead of the bit with just-in-time learning. *Petroleum Science*, 22: 430-441.
- Ji C., Ma F., Wang J., Wang J., Sun W., 2021. Real-Time Industrial Process Fault Diagnosis Based on Time Delayed Mutual Information Analysis. *Processes*, 9(6): 1027.

## 中文参考文献

- 杜胜, 马天宇, 黄澄, 吴云龙, 范海鹏, 2026. 基于联邦字典学习的地质钻进过程智能监测. 地球科学. doi: 10.3799/qkx.2026.002.
- 陆承达, 甘超, 陈略峰, 陈鑫, 曹卫华, 吴敏, 2023. 地质钻进过程智能控制研究进展与发展前景. 煤田地质与勘探, 51 (9): 31-43.
- 李玮, 李亚楠, 陈世春, 丛长江, 霍明宇, 杨斌, 2013. 井底牙轮钻头的钻速方程及现场应用. 中国石油大学学报(自然科学版), (3): 74 - 77.
- 刘军波, 韦红术, 赵景芳, 张辉, 张日鹏, 2015. 考虑钻头转速影响的新三维钻速方程. 石油钻探技术, (1): 52 - 57.
- 管志川, 呼怀刚, 王斌, 孙美伟, 刘永旺, 许玉强, 2019. 基于机械比能与滑动摩擦系数的 PDC 破岩效率实验. 中国石油大学学报(自然科学版), 43 (5): 92 - 100.
- 谷亚冰, 2023. 基于井底钻压的自动送钻系统钻压实时预测与控制. 西安: 西安石油大学.