

基于长短期记忆网络的常见钻井工况识别方法研究

程柑溶¹, 段 正¹, 杨 周¹, 吴达越²

¹重庆科技大学石油与天然气工程学院, 重庆

²中国石油集团长城钻探钻井二公司, 辽宁 盘锦

收稿日期: 2026年7月7日; 录用日期: 2026年8月6日; 发布日期: 2026年9月10日

摘 要

为解决基于阈值设定和专家经验的钻井工况识别方法在时序建模与分类精度的局限, 本文提出了一种基于长短期记忆网络的钻井工况识别方法。该方法通过门控机制有效捕捉钻井过程中时序数据的长期依赖关系, 能够自动学习不同工况在时间维度上的变化趋势, 并通过堆叠多层LSTM单元增强特征提取能力, 并在LSTM输出端接入前馈全连接神经网络进行工况分类, 以学习最优模型参数。选用川渝地区10口已完钻的水平井的实时钻井数据, 对ANN、RNN、CNN、LSTM模型进行了性能测试, 结果表明: LSTM模型在所有评估指标上均表现出最优异的性能, 其精确率达到0.94, 精度和召回率均为0.95, 最终得到高达0.96的F1分数, 这充分说明了LSTM模型能够有效捕捉这些复杂的序列特征, 能够有效学习并记忆关键信息, 从而实现最准确的分类预测。该方法为钻井工况的精准识别提供了新的技术路线, 并对推动钻井监督智能化升级具有重要意义。

关键词

钻井工况, 门控机制, 长期依赖, LSTM模型

Study on the Identification of Common Drilling Operating Conditions Based on a Long Short-Term Memory Network

Ganrong Cheng¹, Zheng Duan¹, Zhou Yang¹, Dayue Wu²

¹School of Petroleum and Natural Gas Engineering, Chongqing University of Science and Technology, Chongqing

²No. 2 Drilling Company, CNPC Great Wall Drilling Engineering Co., Ltd., Panjin Liaoning

文章引用: 程柑溶, 段正, 杨周, 吴达越. 基于长短期记忆网络的常见钻井工况识别方法研究[J]. 矿山工程, 2026, 14(5): 1305-1315. DOI: 10.12677/me.2026.145129

Abstract

To address the limitations of drilling operating condition identification methods based on threshold settings and expert experience in terms of time-series modeling and classification accuracy, this study proposes a drilling operating condition identification method based on a long short-term memory (LSTM) network. Through its gating mechanism, the proposed method effectively captures the long-term dependencies in time-series drilling data and automatically learns the temporal variation patterns associated with different operating conditions. Multiple LSTM layers are stacked to enhance feature extraction, and a feedforward fully connected neural network is connected to the output of the LSTM network for operating condition classification and optimal model parameter learning. Real-time drilling data from 10 completed horizontal wells in the Sichuan-Chongqing region were selected to evaluate the performance of ANN, RNN, CNN, and LSTM models. The results show that the LSTM model achieves the best performance across all evaluation metrics, with a precision of 0.94, an accuracy and recall of 0.95, and an F1-score of 0.96. These results demonstrate that the LSTM model can effectively capture complex sequential features and learn and retain critical information, thereby achieving highly accurate classification. The proposed method provides a new technical approach for the accurate identification of drilling operating conditions and is of great significance for promoting the intelligent upgrading of drilling supervision.

Keywords

Drilling Conditions, Gating Mechanism, Long-Term Dependency, LSTM Model

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

实现钻井作业的自动化与智能化,离不开对钻井工况的精确识别,这是其中核心技术环节之一[1]。通过实时捕捉并识别钻井过程中的不同工作模式[2],不仅能科学评估钻井作业时效,还能有效提升钻进效率,保障施工安全,为现场操作提供强有力的数据支持与决策依据[3]。传统的钻井工况识别主要依赖于检测录井数据的动态变化趋势,结合专家经验设定的阈值和判定规则进行工况划分。然而,这种传统的识别方式在实际运用中暴露出诸多不足,难以适应复杂多变的井下环境,灵活性和泛化能力较为有限[4],表现为规则逻辑判断过于繁琐,阈值边界不够清晰的问题,对于重要特征变化不明显的情况,基于阈值的识别方法往往难以确保较高的准确率。此外,要构建出一套能够适配各类钻井场景的通用阈值判断体系,也存在较大的挑战[5]。因此需要一种具备自主学习能力、能灵活适应各类工况变化的高效钻井工况识别方法[6]。在机器学习领域,孙挺及其团队[7]通过使用支持向量机(SVM)成功实现了钻井工况的智能化在线识别。刘胜娃等人[8]设计了一种基于决策树的智能钻井工况识别方法,该方法在推动油田实现智能化与数字化方面展现出一定的适用性与实用价值。王江萍等人[9]使用神经网络技术,用于诸如井壁坍塌、井漏、井涌、井喷等多种井下异常工况的智能检测。王正等团队[10]开发了一种融合一维神经网络、双向门控单元与注意力机制的识别模型,成功实现了对各类钻井工况高效精确区分。Yin Qishuai等人[11]为了能够降低人为干预对钻井工况识别结果的干扰,提出了一种基于程序逻辑的工况识别方法。

尽管上述钻井工况识别方法在处理许多分类问题和回归问题上表现出色，但当直接应用于钻井工况识别这类高度依赖时间序列数据的领域时，其内在的局限性便显现出来了。首先上述方法难以捕捉时间序列的动态性和长期依赖关系，其次高度依赖手动特征工程并且模型泛化能力相对较差。因此本文提出了一种基于 LSTM 的钻井工况识别方法[12]，LSTM 是一种改良型循环神经网络，其实际目的是解决模型在处理需要建立长时间跨度信息的任务时表现不佳的问题，使其在处理时间序列数据，尤其是区分和识别钻井工况等任务方面，展现出了显著的优势。

2. 钻井参数选取以及数据预处理

2.1. 钻井参数选取

在现代钻井过程中，数据采集系统(如综合录井仪、随钻测量系统 MWD/LWD 及井下传感器)能够采集到大量的实时工程参数。若不加筛选将全部参数作为深度学习模型的输入特征，不仅会造成特征冗余，还会增加计算负担、增加训练时间，从而限制模型的整体性能。因此，本文综合分析现有钻井工况识别相关文献并结合实际钻井过程的基础上，参考文献[11]的做法，专注于对工况识别更具敏感性和代表性的核心参数，最终选定钻头测深、井眼测深、游车位置、大钩载荷、钻压、转速、扭矩以及立管压力和时间作为模型的输入特征。

2.2. 数据清洗

录井传感器在采集原始数据时，常因环境干扰而引入部分异常值或缺失值，这类数据会干扰模型训练的稳定性 and 预测精度。因此，需要对原始数据进行清洗。

对于缺失值，根据数据的分布特性，采用线性插值法[13]进行填补；针对异常值，采用 3σ 原则法进行剔除， 3σ 原理计算公式如下：

$$\mu = \bar{x} = \frac{1}{L} \sum_{i=1}^L x_i \quad (2.1)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^L (x_i - \bar{x})^2}{L-1}} \quad (2.2)$$

式中： L 为时间序列长度， μ 和 σ 为 $\bar{x}$ 的均值和方差。当 $\mu - 3\sigma \leq x_i - \bar{x} \leq \mu + 3\sigma$ ，判定该时刻为正常值，反之为错误值，对其采用直接删除的方式进行处理。

此外，由于传感器采集的各特征数据在量纲和数值尺度上差异较大，容易导致模型对数值较大的特征过度敏感。为此，本文采用 Z-Score 标准化[14]方法对数据进行归一化处理，其公式如下：

$$Z = \frac{x - \mu}{\delta} \quad (2.3)$$

式中： Z 为标准后的结果； x 为传感器收集的原始数据； μ 为原始数据的平均值； δ 为原始数据的标准差。

2.3. 数据标识

在构建钻井工况识别模型中，选择独热编码[15]对数据集中的工况类别进行标注，这是一种将分类变量转换为深度学习模型易于处理的数值形式的关键预处理步骤。这些工况之间只代表状态的不同，而不存在任何内在的大小、顺序或级别关系。如果使用简单的整数编码会让模型误以为这些工况之间存在序数关系，而独热编码通过将每个工况映射到一个 N 维向量来解决此类问题，消除了类别之间顺序和大小差异，如表 1 所示。

Table 1. Labels and one-hot encoding for drilling operating conditions
表 1. 钻井工况对应标签和独热编码表

钻井工况	标签	独热编码	数据量	数据分布
起钻	1	1000000000000	3,106,460	9.82%
下钻	2	0100000000000	2,888,185	9.13%
旋转钻进	3	0010000000000	8,019,223	25.35%
滑动钻进	4	0001000000000	4,027,010	12.73%
循环	5	0000100000000	2,081,518	6.58%
接单根	6	0000010000000	3,059,009	9.67%
划眼	7	0000001000000	2,179,583	6.89%
倒划眼	8	0000000100000	2,138,459	6.76%
钻前准备	9	0000000010000	363,791	1.15%
静止	10	0000000001000	417,569	1.32%
向上洗井	11	0000000000100	1,208,419	3.82%
向下洗井	12	0000000000010	907,896	2.87%
其他	13	0000000000001	12,368,694	3.91%
总计	-	-	31,634,016	100%

2.4. 滑动窗口设计




Figure 1. Sliding window optimization
图 1. 滑动窗口优选

由于实际钻井过程中数据采集会不可避免受到噪声干扰和测量误差的影响，原始数据会出现波动，甚至在短时间内频繁切换多种工况，这显然不符合实际钻井作业现场的规律。为提升模型的稳定性和鲁棒性[16]，本文引入滑动窗口机制，将原本由单条数据独立判断的工况概率，转变为由窗口内多条数据工况决定。考虑到实时数据的采集频率为 1 HZ，结合各类钻井工况的普遍持续时间及现场工程师的经验，滑动窗口大小被设定在 20~60 之间[17]。为了进一步优化窗口长度，本文以每 5 个数据点为步长进行对比实验，评估不同窗口长度的识别准确率。如图 1 所示，测试结果表明，当滑动窗口设为 40 时，模型识别的准确率最高，因此最终选定该值作为最优的窗口长度。

3. 钻井工况识别方法研究与模型构建

3.1. 人工神经网络

人工神经网络(ANN)[18]是一种模拟生物神经机制的机器学习模型，由输入层、一个或多个隐藏层以及输出层组成。输入层接收钻井参数等原始数据，隐藏层通过神经元对加权输入进行非线性变换以提取特征，输出层则给出工况识别结果。ANN 通过前向传播计算预测值，并利用反向传播算法结合优化器不断调整权重与偏置，从而尽可能实现最小预测误差。其优势在于能够有效拟合非线性关系，具备一定的抗干扰能力且结构简单、训练效率较高，但在处理复杂时序任务时表现一般。ANN 网络的基本结构及各层之间的连接关系如图 2 所示。




Figure 2. ANN network architecture diagram

图 2. ANN 网络结构图

3.2. 循环神经网络




Figure 3. Recurrent neural network architecture diagram

图 3. 循环神经网络结构图

循环神经网络是一种专门处理序列数据的深度学习模型，其核心特点是神经元之间存在循环连接，使网络能够保留历史信息并利用时序依赖关系进行建模，其具体网络结构如图 3 所示。在钻井工况识别中，RNN 通过将当前时刻的输入与上一时刻的隐藏状态共同作为输入，实现对钻井参数时间序列的动态建模。其结构通常包括输入层、循环隐藏层和输出层，在该结构中，隐藏层的输出不仅参与前向传播，还通过内部反馈的形式作用于自身，形成“记忆”机制。

3.3. 卷积神经网络

卷积神经网络(CNN) [19]是一种擅长提取局部特征和空间模式的深度学习模型，最初被广泛应用于图像处理，近年来也被成功用于时间序列数据(如钻井参数)的分析。CNN 通过权值共享和局部连接机制，显著减少参数量，提升训练效率，并对输入数据中的平移、噪声等干扰具有较强的鲁棒性。虽然该网络更侧重于局部模型而非长程时序建模，但通过堆叠多层卷积或其他结构，也能有效捕捉钻井过程中的复杂动态特征。CNN 网络的基本结构如图 4 所示。




Figure 4. Convolutional neural network architecture
图 4. 卷积神经网络

3.4. 长短期记忆网络




Figure 5. LSTM network architecture
图 5. LSTM 网络结构

长短期记忆网络是一种特殊的循环神经网络(LSTM)，它引入了“门控机制”这一核心设计，有效缓解了传统循环神经网络因梯度更新不稳定而导致对长时间信息记忆能力不足的问题[20]。其核心思想是通过精心设计的门控单元，在每个时间步动态调整信息的传递和更新。门控单元(遗忘门、输入门和输出门)协同工作，决定哪些信息应该被保留、哪些信息应该被丢弃、哪些应该输出，从而实现对时序信息的精准选择与利用[21]，其基本结构如图 5 所示。

3.5. 钻井工况识别模型构建

基于长短期记忆网络的钻井工况识别模型可以划分为四个主要组成部分：输入层、隐藏层、输出层以及神经网络训练过程。其中，输入层主要用于接收和预处理钻井实时参数；隐藏层负责对输入特征进行非线性变化与深层表征学习；输出层通过 softmax 函数，输出 13 种工况对应的概率值，概率最大的工况即为当面模型所识别出的工况；而网络训练部分则通过不断地前向传递和反向传播，持续更新并调整权重参数，实现模型优化，其中主要参数确定如表 2 所示，整体结构如图 6 所示。




Figure 6. Overall framework of the drilling operating condition recognition model
图 6. 钻井工况识别模型整体框架图

Table 2. Optimal hyperparameters and network architectures
表 2. 最优超参数及网络结构

选型	参数
隐藏层数目	20
每层节点数	60
输出层激活函数	Softmax 函数
隐藏层激活函数	Sigmoid 函数
优化器	NAdam
损失函数	CEE

4. 模型测试

本文基于川渝地区某区块 10 口已完钻的水平井实时钻井数据，共计 3,164,017 条记录，涵盖 13 种钻井工况。为构建适用于时序建模的训练与测试样本集，对每种工况采用欠采样策略，随机抽取 1000 段连续的时序数据，将 13 个类别抽取的数据合并后，共得到 13,000 个时序片段。随后，采用滑动窗口对这些片段进行处理，窗口长度和步长分别设为 40 和 2，经计算共生成 6481 个滑窗样本。从中随机选取 80% 作为训练集，其余 20% 作为测试集。




Figure 7. Comparison of loss functions among different models
图 7. 各模型损失函数对比




Figure 8. Comparison of performance metrics among different models
图 8. 各模型性能指标对比

本文进一步采用 10 折交叉验证，对上述提到的 ANN、RNN、CNN 和 LSTM 四种钻井工况识别模型进行训练与评估，对比分析各模型在 10 次实验中的准确率、精度、召回率和 F1 分数四项指标，并据此选择最优模型。最优模型训练的损失函数如图 7 所示，最优模型的测试结果如图 8 所示。相关计算公式如下：

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \tag{4.1}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{4.2}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{4.3}$$

$$\text{F1} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{4.4}$$

式中：Accuracy 为准确率；Precision 为精度；TP 为模型预测为正，实际也为正的样本数量；TN 为模型预测为负，实际也为负的样本数量；FP 为模型预测为正，实际为负的样本数量；FN 为模型预测为负，实际为正的样本数量。




Figure 9. Comparison of confusion matrices for different models on the 13-class classification task
图 9. 不同模型在 13 分类任务上的混淆矩阵对比

由图 7 可知, LSTM 的损失函数在少量迭代之后迅速下降,并在较短的时间内趋于稳定,表明模型在当前实验设置下具有较快的收敛速度和良好的优化特性。除此之外,由模型性能对比结果,可以得出 LSTM 模型在所有评估指标上均表现出最优异的性能,其精确率达到 0.91,最终得到高达 0.96 的 F1 分数,这充分说明了 LSTM 模型能够有效捕捉这些复杂的序列特征,能够有效学习并记忆关键信息,从而实现最准确的分类预测。为进一步探究最佳的 LSTM 模型的具体分类效果,本文通过对比分析四个模型在测试集上的混淆矩阵来进一步验证该方法的可行性,如图 9 所示。

从图 9 可以看出, CNN 的混淆矩阵主对角线亮度较高,但非对角线出现了更多颜色稍亮的单元格,这说明 CNN 虽然可以提取关键特征,但在区分某些特征相似的类比能力略有不足; RNN 的混淆矩阵性能明显下降,其对角线亮度显著降低,这清晰地反应了 RNN 在处理复杂时序任务时的局限性,导致其在多个类别都出现了较为明显的混淆,区分能力有限; ANN 的混淆矩阵的主对角线亮度微弱,大量亮色单元散布在非对角线区域,这直观地表明了, ANN 模型无法学习到有效的分类边界,其预测结果带有很大的随机性; LSTM 的混淆矩阵呈现出一条高度集中的亮黄色对角线,非对角线区域几乎全是深色,这表明 LSTM 具有较低的误分类率,而且在区分各个具体类别时也表现出极高的置信度和鲁棒性。

综上, LSTM 模型凭借其对长时间依赖序列的建模能力,在 13 类钻井工况中均保持高识别精度和低误分类率,表现出优秀的鲁棒性和泛化能力。该模型不仅适用于本研究区块,也具备向其他区块推广的潜力,可为钻井现场人员提供智能化,自动化的工况识别工具,有助于提升钻井效率和作业安全性。

5. 结论与建议

(1) 本研究的核心结论是:长短期记忆网络是实现高精度钻井工况智能识别的优秀模型。通过与 ANN、RNN 及 CNN 的系统性对比, LSTM 模型凭借其独特的门控机制,能够最有效地捕捉钻井数据中复杂的长距离时序依赖关系。实验结果表明,其在各项评估指标中全面领先, F1 分数高达 0.96,混淆矩阵也验证了其在区分各类工况时极低的误判率。研究证实,精确捕捉时序特征是该任务成功的关键,而 LSTM 在此方面展现出卓越的能力。

(2) 尽管 LSTM 在理论验证中表现出色,但其在实际钻井现场大规模推广应用之前,仍需要证实并解决其固有的局限性。未来研究应聚集于以下几点:

① 实时性与计算成本问题: LSTM 模型较为复杂,计算量大,现场的部分计算机的性能可能难以满足其要求。未来优化方向应着重于模型轻量化,在保证核心精度的前提下,开发出更高效、更易于现场部署的简化版模型。

② 可解释性问题: LSTM 作为一种黑箱模型,其决策过程缺乏直观的物理意义,难以获得现场工程师的完全信任。之后的研究应该去尝试结合可解释技术,提升其在工业场景中的可信度。

③ 现场应用问题:为确保工况识别结果在实际钻井作业中的可靠性与持续优化,应将智能模型与实时监测系统集成,并建立“自动识别和人工复核”的人机协同机制。此外,建议加快 LSTM 等先进神经网络架构与钻井工程场景的深度融合,重点发展适用于边缘设备或现场终端的轻量化模型。

参考文献

- [1] 李雷,韩烈祥,姚建林. 参数耦合在粒子冲击钻井智能决策系统中的应用[J]. 钻采工艺, 2020, 43(3): 4-6, 45, 1.
- [2] Yang, X., Wu, M., Lu, C., Li, W., Chen, L. and Du, S. (2024) Prediction of Rate of Penetration Based on Drilling Conditions Identification for Drilling Process. *Neurocomputing*, 579, Article ID: 127439. <https://doi.org/10.1016/j.neucom.2024.127439>
- [3] 永旺,李坤,管志川,等. 降低井底岩石抗钻能力的钻速提高方法研究及钻头设计[J]. 石油钻探技术, 2024, 52(3): 11-20.

- [4] 李威明, 侍德益, 王浩, 等. 钻井过程中井漏预警方法研究[J]. 石化技术, 2025, 32(10): 228-230.
- [5] Yasseri, S. (2017) Drilling Risk Identification, Filtering, Ranking and Management. *International Journal of Coastal and Offshore Engineering*, 1, 17-26. <https://doi.org/10.18869/acadpub.ijcoe.1.1.17>
- [6] 胡志强, 杨进, 王磊, 等. 钻井工况智能识别与时效分析技术[J]. 石油钻采工艺, 2022, 44(2): 241-246.
- [7] 孙挺, 赵颖, 杨进, 等. 基于支持向量机的钻井工况实时智能识别方法[J]. 石油钻探技术, 2019, 47(5): 28-33.
- [8] 刘胜娃, 曹湘华. 基于决策树的钻井工况智能识别方法[J]. 新型工业化, 2022, 12(1): 28-30.
- [9] 江萍, 孟祥芹, 鲍泽富. 应用神经网络技术诊断钻井事故[J]. 西安石油大学学报(自然科学版), 2008(2): 99-102, 121.
- [10] 王正, 宋先知, 李洪松, 等. 基于 1dCNN-BiGRU 和注意力机制的钻井工况智能识别方法[J]. 石油科学通报, 2025, 10(5): 926-940.
- [11] Yin, Q., Yang, J., Zhou, B., Jiang, M., Chen, X., Fu, C., et al. (2018) Improve the Drilling Operations Efficiency by the Big Data Mining of Real-Time Logging. *SPE/IADC Middle East Drilling Technology Conference and Exhibition*, Abu Dhabi, 29-31 January 2018, SPE-189330-MS. <https://doi.org/10.2118/189330-ms>
- [12] 闫铁, 许瑞, 刘维凯, 等. 中国智能化钻井技术研究发展[J]. 东北石油大学学报, 2020, 44(4): 15-21, 6.
- [13] Yin, Q., Yang, J., Tyagi, M., Zhou, X., Hou, X. and Cao, B. (2021) Field Data Analysis and Risk Assessment of Gas Kick during Industrial Deepwater Drilling Process Based on Supervised Learning Algorithm. *Process Safety and Environmental Protection*, 146, 312-328. <https://doi.org/10.1016/j.psep.2020.08.012>
- [14] Yin, Q., Yang, J., Tyagi, M., Zhou, X., Hou, X., Wang, N., et al. (2021) Machine Learning for Deepwater Drilling: Gas-Kick-Alarm Classification Using Pilot-Scale Rig Data with Combined Surface-Riser-Downhole Monitoring. *SPE Journal*, 26, 1773-1799. <https://doi.org/10.2118/205365-pa>
- [15] Bengio, Y., Simard, P. and Frasconi, P. (1994) Learning Long-Term Dependencies with Gradient Descent Is Difficult. *IEEE Transactions on Neural Networks*, 5, 157-166. <https://doi.org/10.1109/72.279181>
- [16] Arnaout, A., Fruhwirth, R., Esmael, B. and Thonhauser, G. (2012) Intelligent Real-Time Drilling Operations Classification Using Trend Analysis of Drilling Rig Sensors Data. *SPE Kuwait International Petroleum Conference and Exhibition*, Kuwait City, 10-12 December 2012, SPE-163302-MS. <https://doi.org/10.2118/163302-ms>
- [17] 殷启帅, 杨进, 曹博涵, 等. 基于长短期记忆神经网络的深水钻井工况实时智能判别模型[J]. 石油钻采工艺, 2022, 44(1): 97-104.
- [18] Ben, Y.X., James, C. and Cao, D. (2019) Development and Application of a Real-Time Drilling State Classification Algorithm with Machine Learning. *Proceedings of the 7th Unconventional Resources Technology Conference*, Denver, 22-24 July 2019, URTEC-2019-253-MS. <https://doi.org/10.15530/urtec-2019-253>
- [19] 罗鸣, 李盛阳, 彭巍, 等. 基于深度卷积特征重构的井漏事故预测[J]. 计算机仿真, 2023, 40(7): 82-88.
- [20] 檀朝东, 陈培堯, 杨亚少, 等. 时序示功图驱动的抽油机井结蜡预测及清蜡效果评价[J]. 石油钻采工艺, 2022, 44(1): 123-130.
- [21] Lee, K., Lim, J., Yoon, D. and Jung, H. (2019) Prediction of Shale-Gas Production at Duvernay Formation Using Deep-Learning Algorithm. *SPE Journal*, 24, 2423-2437. <https://doi.org/10.2118/195698-pa>