

深度学习在井漏监测中的研究进展

李 存¹, 段 正¹, 安思旭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3日; 录用日期: 2026年8月5日; 发布日期: 2026年9月10日

摘 要

井漏是钻井作业中最常见的钻井事故之一, 受工况转换、传感器噪声以及井下复杂情况的影响, 传统的井漏监测方法通常难以及时、准确地识别风险。随着大数据与人工智能技术的发展, 基于深度学习的数字化、智能化井漏监测技术已成为当前发展的主流趋势, 其核心技术主要包括基于深度学习算法模型的构建和智能化监测系统的应用。文章通过分析井漏的成因和分类, 归纳了其发生的主要特点, 同时进一步阐述了循环神经网络、长短时记忆网络、门控循环单元在井漏监测中的应用现状与研究进展。与传统人工经验或阈值法相比, 通过应用深度学习算法可以更早、更稳定、更精准地从多维时序数据中识别异常变化, 捕捉各参数之间的协同变化模式, 准确识别复杂工况的转变, 从而降低误报与漏报, 提升预警的准确性。

关键词

井漏, 深度学习, 监测系统, 漏报, 误报

Research Progress of Deep Learning in Lost Circulation Monitoring

Cun Li¹, Zheng Duan¹, Sixu An¹, 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

Received: July 3, 2026; accepted: August 5, 2026; published: September 10, 2026

Abstract

Lost circulation is characterized by abrupt occurrence, strong coupling with drilling operations, and weak anomaly signals. Single-parameter threshold methods are therefore prone to false and missed

文章引用: 李存, 段正, 安思旭, 吴达越. 深度学习在井漏监测中的研究进展[J]. 矿山工程, 2026, 14(5): 1265-1271.

DOI: 10.12677/me.2026.145125

alarms under operating-mode transitions, sensor noise, and missing data. This paper reviews the application of recurrent neural networks (RNNs), long short-term memory networks (LSTMs), and gated recurrent units (GRUs) to lost circulation monitoring. The three architectures are compared in terms of model complexity, short- and long-term dependency modeling, noise robustness, computational cost, and scenario suitability. Key challenges in drilling time-series data, including noise and drift, missing records, class imbalance, and feature engineering, are then discussed together with commonly used solutions, such as filtering, interpolation, cost-sensitive learning, SMOTE, and feature-importance analysis. An end-to-end implementation pathway is proposed, covering data acquisition, edge preprocessing, standardized transmission, model inference, risk fusion, alarm delivery, and feedback-based model updating. The review indicates that RNNs are suitable for short windows and low-compute applications, LSTMs provide stronger long-term memory at higher computational cost, and GRUs offer a practical balance between accuracy and efficiency. Current studies remain limited by small numbers of wells, inconsistent labels, insufficient well-wise validation, and limited closed-loop field evaluation. Future work should emphasize multi-source data fusion, independent cross-well testing, lightweight and interpretable models, and long-term field deployment.

Keywords

Lost Circulation, Deep Learning, Monitoring System, Missed Detection, False Alarm

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

井漏是油气钻井过程中普遍存在的问题。一旦发生, 不仅会延长钻井周期, 造成大量钻井液及堵漏材料的损耗, 还可能诱发卡钻、井涌甚至井喷等一系列复杂事故, 在某些极端情况下还可能导致整口井报废。传统的井漏监测方法通常侧重于监测单一变量, 例如通过泥浆池的液面高度变化判断是否发生井漏。然而, 此类方法本质上属于被动响应, 只有当井漏发生时, 异常才可以被识别, 因而难以实现早期预警。近年来, 随着综合录井、计算机信息处理及各类智能化技术的不断进步, 智能预测与预警系统逐渐在油气井工程中推广运用。通过提前识别风险并发出预警, 可显著降低井漏发生的概率。与此同时, 深度学习技术的快速发展为井漏监测提供了新路径。借助对大量历史数据的学习, 深度学习模型能够自动提取关键特征, 实现对井漏事件的快速、准确识别。目前, 国内已陆续研发并部署若干智能井漏监测系统, 在实际应用中展现出良好的预测与预警能力。

2. 井漏的成因与分类

根据漏失成因, 井漏主要可分为两类: 其一是当钻遇高渗透性地层或天然裂缝发育的层位时, 钻井液受井筒与地层之间的压差作用, 沿这些天然通道渗入地层; 其二是由于钻井液的密度设置不当, 导致井底液柱压力超过地层破裂压力, 从而压裂地层, 形成人工诱导的漏失通道, 引发钻井液漏失。

2.1. 按漏失速率分类

根据漏失速率, 井漏可以大致分为五大类, 分别为小漏、中漏、大漏和严重漏失。在实际钻井现场中, 这种分类方式能够较为直观地反应井漏的严重程度, 为快速判断漏失状况, 选取相应的处理措施提供重要参考, 其具体分类标准如表 1 所示。

Table 1. Classification of lost circulation by loss rate
表 1. 按漏失速率进行的井漏分类

漏失类型	小漏	中漏	大漏	严重漏失
漏失速度(m ³ /h)	5~15	15~30	30~60	>60

2.2. 按漏失严重程度分类

根据井漏发生位置所对应的漏失通道类型，可将井漏划分为四类：渗透性漏失、裂缝性漏失、溶洞性漏失和破裂性漏失。这种分类方式主要依据地层中流体渗流通道的成因与形态特征，有助于结合地层特性，选择合适的堵漏方案。其具体分类标准如表 2 所示。

Table 2. Classification of lost circulation by cause
表 2. 按漏失成因进行的井漏分类

漏失分类	漏失类型	漏失原因
自然漏失	渗透性漏失	岩层颗粒无胶结
	裂缝性漏失	岩层有裂缝
	溶洞性漏失	岩层有溶洞
人为漏失	破裂性漏失	施工不当，地层被压裂

3. 深度学习井漏预测模型

3.1. 循环神经网络

循环神经网络(RNN)是一类常用于处理序列数据的深度学习模型，其具体结构如图 1 所示。其核心特点是在隐藏层引入循环连接，使网络在处理当前时刻输入时能够融合前一时刻的隐藏状态，从而具备对历史信息的记忆能力。这一特性使其能够有效捕捉钻井过程中多参数的变化规律，为井漏监测与时序建模提供技术支撑。

循环神经网络的基本结构通常由输入层、循环隐藏层与输出层组成，在前向传播过程中，网络按时间步依次处理输入序列，更新隐藏状态并输出结果。在训练阶段，需将网络沿时间维度展开，并采用反向传播算法计算梯度以更新模型权重。然而，循环神经网络在处理长时序数据时，容易出现梯度消失或梯度爆炸问题，导致模型难以学习长期依赖关系。

在钻井实时数据建模过程中，RNN 已被证实具备从实时钻井数据中获取多个参数随时间变化的关联规律。涂思羽[1]等开展了基于深度学习的井漏智能监测方法研究，对循环神经网络与现有典型模型进行对比测试，结果表明循环神经网络在时序任务中表现更优。Tunkiel [2]等基于实时钻井日志，评估了重采样、欠采样以及缺失插补等数据预处理方法对 RNN 性能的影响，并提出了一套适用于现场实时数据处理与模型持续训练的方法，该方法为工程应用与跨场景迁移提供了可行的路径。Alkinani [3]等利用超过 2000 口井的钻井数据，选取钻井液性能参数(如塑性粘度、钻井液密度)与工程参数(如排量、转速、钻压、喷嘴流通面积等)作为输入，构建 RNN 预测模型，该模型在测试集上取得了较高的拟合效果，决定系数 R^2 约为 0.94，表明 RNN 能够在多参数耦合条件下构建非线性复杂关系。

循环神经网络擅长处理钻井时序数据，能自动学习参数的动态变化规律，但随着深度学习的发展，

研究人员发现 RNN 在处理长序列任务中存在明显的局限性。为此，一系列改进结构如长短期记忆网络和门控循环单元相继被提出。




Figure 1. Schematic structure of recurrent neural network
图 1. 循环神经网络结构图

3.2. 长短期记忆网络

长短期记忆网络作为改进型循环神经网络，有效解决了传统循环神经网络在处理长时序数据时的局限。具体表现为：循环神经网络在更新参数时，容易出现梯度消失或者梯度爆炸的现象，从而导致模型难以学习到相隔较远的历史信息，而 LSTM 通过在内部构建稳定的信息传递通道，能够在较长时间内保存有效信息，实现长期记忆。

LSTM 的基本单元由记忆细胞与门控结构组成，其具体结构如图 2 所示。门控机制可依据当前输入与历史信息，自动调控信息的写入、保留与输出，使模型在处理这类强噪声、多参数耦合的钻井实时数据时，能更稳定地学习井漏相关特征，如池体积下降、流量差增大、井底压力降低等变化趋势。




Figure 2. Schematic structure of long short-term memory network
图 2. 长短期记忆神经网络结构图

在井漏的监测与预警研究中，通常将连续一段时间内的工程参数序列作为输入，输出井漏发生的概率或风险级别。Aljubran [4]等基于历史井的地面数据开展大规模时序建模，选取了钻压、勾载、扭矩、

立管压力、入口/出口流量、钻速、转盘转速等参数,以 0.2 Hz 的频率形成窗口样本,并通过窗口归一化等数据预处理手段提升模型在跨井作业的泛化能力。结果表明, LSTM 在测试集上达到约为 92.45% 的准确率、91.49% 的精确率、68.62% 的召回率与 78.42% 的 F1 分数,充分体现了 LSTM 在井漏时序特征学习方面的优异性能。

3.3. 门控循环单元

门控循环单元(GRU)同样作为改进的循环神经网络,在越来越多的应用场景中,可以逐渐平替甚至取代长短期记忆网络。其优势主要体现在模型结构更简单、参数量更少,不仅训练效率更高,收敛速度更快,同时对硬件内存的要求更低,在保证模型预测精度的前提下,有效节省计算机的算力,其具体结构如图 3 所示。

门控循环单元的核心在于其独特的门控机制,GRU 通过更新门与重置门控制历史信息对当前状态的影响程度:更新门决定保留多少历史信息并更新多少新信息,重置门则控制对历史信息的遗忘程度。

基于 GRU 的监测模型通常采用滑动窗口将连续的钻井参数序列切分为时间片段作为输入,并输出井漏发生概率、风险等级或异常评分。通过门控机制,模型能够自动弱化泵启停、起下钻等工况造成的干扰,更聚焦于井漏相关异常的变化趋势。

国内研究中,针对池体积与出口流量易受开停泵干扰而误报的问题,孙伟峰等[5]提出了一种基于 GRU 的井漏监测方法,并利用 23 口井的现场监测数据进行了验证。结果表明,该方法的准确率高达 94.25%,误报率降低至 1.12%。在国外研究中,Mardanirad [6]等基于 20 口井共计 65,376 条记录构建井漏分类数据集(无漏、渗漏、部分漏失、严重漏失、完全漏失等),并将 GRU 用于漏失等级识别,结果表明 GRU 在该类大规模现场数据上的分类精度可达约 94%,验证了其在井漏事件严重程度识别中的可靠性。




Figure 3. Schematic structure of gated recurrent unit

图 3. 门控循环单元结构图

3.4. RNN、LSTM 与 GRU 比较分析

为避免仅以单篇文献的准确率判断模型优劣,表 3 从结构复杂度、时间依赖、抗噪能力、计算成本和场景适用性等方面进行相对比较。这里的“高、低”指在输入维度、隐藏单元和网络层数相近时的结构性差异,实际结果仍受数据质量、样本量、窗口长度和超参数设置影响。

综合来看,模型选择应结合监测任务需求与数据特征进行权衡。对于钻井工况相对稳定、数据规模较小且对长期依赖信息要求不高的场景,可优先采用结构简单、计算成本较低的 RNN 模型;对于需要开展全过程实时监测,并充分捕捉钻井时序数据长期依赖关系的场景,GRU 模型更具适用性。

Table 3. Comparison of RNN, LSTM and GRU for lost circulation monitoring
表 3. RNN、LSTM 与 GRU 在井漏监测中的比较

模型	结构与相对复杂度	长期依赖	短期变化捕捉	抗噪与工况干扰	训练成本	适用井漏场景
RNN	单一递归状态；参数量最低	弱	强	较弱，易受异常点影响	低	短窗口、稳定钻进
LSTM	三类门控；细胞状态；参数量最高	强	强	较强，能选择性保留信息	高	慢漂移型井漏、多阶段工况、较长预警窗口
GRU	两类门控；复杂度介于 RNN 与 LSTM 之间	较强	强	较强，结构更紧凑	中	实时在线监测、频繁滑动窗口

4. 钻井时序数据的处理难题与处理方法

钻井时序异常检测的难点并不只在模型结构。噪声、缺失、标签稀缺、工况切换和跨井分布差异都会干扰模型提取数据特征。Zamanzadeh Darban 等人[7]提出了数据质量、评估方式和泛化能力是深度学习模型在时序异常检测中需要重点关注的问题。

4.1. 数据噪声处理

钻井数据噪声主要来自传感器振动、电磁干扰、人为操纵及泵冲波动。常用处理方法包括中值滤波、低通滤波、Savitzky-Golay 平滑及数据标准化。滤波窗口不宜过大，否则可能抹去井漏初期的微弱变化。

4.2. 正负样本不平衡

井漏样本数据中，正常数据通常远多于井漏数据，导致模型可能出现过拟合现象。Mardanirad 等[6]记录的数据中正常工况数据约占 75.8%，这一占比在连续监测中往往更高。常用方法包括类别权重、代价敏感损失、焦点损失、事件级欠采样及 SMOTE 过采样[8]。SMOTE 应仅在训练集内使用，并尽量在相同工况或相邻特征空间内生成样本，避免合成不符合物理过程的跳变。

5. 结语

(1) 近年来，深度学习为井漏监测提供了新的研究思路。循环神经网络、长短期记忆网络和门控循环单元等模型能够从钻井序列数据中自动学习井漏相关特征及其变化规律，相较传统人工经验和阈值判断方法，在复杂工况下具有更高的识别精度与更强的非线性表达能力，有助于实现井漏事件的快速、准确预警。

(2) 随着数字化钻井的发展，井漏监测正从单一参数报警向智能化、集成化监测系统转变。通过将深度学习模型与数据采集、传输、存储、分析和报警平台相结合，可实现井漏风险的实时监测、分级预警和可视化展示，辅助现场人员更及时、准确地识别工况异常，提升对风险的应对能力。未来，深度学习与智能监测系统的进一步融合将成为井漏监测的重要发展方向。

参考文献

- [1] 涂思羽, 彭平安, 蒋元建. 基于深度学习的井下环境异常工况智能识别技术研究[J]. 中国安全生产科学技术, 2018, 14(11): 58-63.
- [2] Tunkiel, A.T., Sui, D. and Wiktorski, T. (2022) Impact of Data Pre-Processing Techniques on Recurrent Neural Network Performance in Context of Real-Time Drilling Logs in an Automated Prediction Framework. *Journal of Petroleum Science and Engineering*, **208**, Article 109760. <https://doi.org/10.1016/j.petrol.2021.109760>

-
- [3] Alkinani, H.H., Al-Hameedi, A.T.T. and Dunn-Norman, S. (2021) Data-Driven Recurrent Neural Network Model to Predict the Rate of Penetration. *Upstream Oil and Gas Technology*, 7, Article 100047. <https://doi.org/10.1016/j.upstre.2021.100047>
 - [4] Aljubran, M., Ramasamy, J., Albassam, M. and Magana-Mora, A. (2021) Deep Learning and Time-Series Analysis for the Early Detection of Lost Circulation Incidents during Drilling Operations. *IEEE Access*, 9, 76833-76846. <https://doi.org/10.1109/access.2021.3082557>
 - [5] 孙伟峰, 李威桦, 王健, 等. 基于 C#与 Python 混合编程的钻井溢漏风险智能识别平台[J]. 实验技术与管理, 2021, 38(11): 166-172.
 - [6] Mardanirad, S., Wood, D.A. and Zakeri, H. (2021) The Application of Deep Learning Algorithms to Classify Subsurface Drilling Lost Circulation Severity in Large Oil Field Datasets. *SN Applied Sciences*, 3, Article No. 785. <https://doi.org/10.1007/s42452-021-04769-0>
 - [7] Zamanzadeh Darban, Z., Webb, G.I., Pan, S., Aggarwal, C. and Salehi, M. (2024) Deep Learning for Time Series Anomaly Detection: A Survey. *ACM Computing Surveys*, 57, 1-42. <https://doi.org/10.1145/3691338>
 - [8] Chawla, N.V., Bowyer, K.W., Hall, L.O. and Kegelmeyer, W.P. (2002) SMOTE: Synthetic Minority Over-Sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357. <https://doi.org/10.1613/jair.953>