

引文: 孙伟峰, 卜赛赛, 张德志, 等. 基于DCC—LSTM的钻井液微量漏失智能监测方法[J]. 天然气工业, 2023, 43(9): 141-148.
SUN Weifeng, BU Saisai, ZHANG Dezhi, et al. DCC—LSTM based intelligent minor lost circulation monitoring method [J]. Natural Gas Industry, 2023, 43(9): 141-148.

基于 DCC—LSTM 的钻井液微量漏失智能监测方法

孙伟峰¹ 卜赛赛¹ 张德志² 李威桦¹ 刘凯² 戴永寿¹

1. 中国石油大学(华东)海洋与空间信息学院 2. 中国石油大学(华东)控制科学与工程学院

摘要: 钻井过程中发生钻井液漏失时, 现有的井漏智能监测方法, 难以获取长时数据序列特征, 无法实现对微量漏失的及时监测和预警, 进而容易导致更为严重的漏失发生。为此, 提出了一种结合扩张因果卷积网络(Dilated and Causal Convolution, DCC)特征映射能力和长短期记忆网络(Long Short-Term Memory, LSTM)时序特征提取能力的DCC—LSTM钻井液微量漏失智能监测方法, 弥补长短期记忆网络对于长期记忆衰减的不足, 实现了对钻井液微量漏失的准确监测和预测。研究结果表明: ① DCC—LSTM井漏智能监测模型利用扩张因果卷积网络提取监测参数的长时特征, 并将其映射为短序列表示, 利用长短期记忆网络处理特征短序列获取监测数据的长时变化趋势, 实现了微量漏失的准确监测; ②扩张因果卷积网络层数确定方法可以获得最佳网络层数, 得到的DCC网络结构使LSTM对长时序趋势信息的遗忘减少24%; ③与其他井漏监测方法相比, DCC—LSTM网络能够准确监测早期微量漏失, 井漏预警时间最长可提前26 min, 监测准确率由96.9%提升至99.4%, 漏报率由6.4%降低为1.1%。结论认为, 该方法能够获取监测参数的长时趋势变化特征, 经矿场试验验证与其他方法相比有明显优势, 为微量漏失监测和预测提供一种可行的方法, 对油气钻井井漏风险的防控具有重要指导意义。

关键词: 井漏; 微量漏失; 长时趋势特征; 智能监测; 扩张因果卷积网络; 长短期记忆网络

DOI: 10.3787/j.issn.1000-0976.2023.09.014

DCC—LSTM based intelligent minor lost circulation monitoring method

SUN Weifeng¹, BU Saisai¹, ZHANG Dezhi², LI Weihua¹, LIU Kai², DAI Yongshou¹

(1. College of Oceanography and Space Informatics, China University of Petroleum - East China, Qingdao, Shandong 266000, China;
2. College of Control Science and Engineering, China University of Petroleum - East China, Qingdao, Shandong 266000, China)

Natural Gas Industry, Vol.43, No.9, p.141-148, 9/25/2023. (ISSN 1000-0976; In Chinese)

Abstract: When lost circulation happens in the process of well drilling, the existing intelligent lost circulation monitoring methods can hardly obtain the long-term characteristics of data sequence and thus cannot realize the timely monitoring and prewarning of minor lost circulations, causing more serious lost circulation. In order to address this problem, this paper proposes a DCC—LSTM based intelligent minor lost circulation monitoring method which takes the advantage of the characteristic mapping capacity of Dilated and Causal Convolution (DCC) network and the sequential characteristic extraction capacity of Long Short-Term Memory (LSTM) network. This method makes up for the shortage of LSTM in long-term memory attenuation, and realizes the accurate monitoring and prediction of minor lost circulation. And the following research results are obtained. First, in the DCC—LSTM based intelligent minor lost circulation monitoring model, the long-term characteristics of monitoring parameters are extracted by using the DCC network and then mapped into a short data sequence, and the long-term variation trend of monitoring parameters is obtained by applying the LSTM network to process the characteristic short data sequence, so that the accurate monitoring of minor lost circulation is realized. Second, the optimal number of layers in the network can be obtained by using the method for determining the number of layers in the DCC network. The new structure of DCC network can reduce the long-term sequential trend information forgotten by LSTM by 24%. Third, compared with other lost circulation monitoring methods, the DCC—LSTM network can monitor early minor lost circulations accurately, with the advanced prewarning time increasing by 26 minutes, the monitoring accuracy rate increasing from 96.9% to 99.4%, and the false alarm rate decreasing from 6.4% to 1.1%. In conclusion, this method can acquire the long-term trend variation characteristics of monitoring parameters, and the field test demonstrates its obvious advantages over other methods. It provides a feasible method for the monitoring and prediction of minor lost circulation, and is of great significance to guiding the prevention and control of lost circulation risk during well drilling.

Keywords: Lost circulation, Minor loss; Long-term trend characteristics; Intelligent monitoring; Dilated and Causal Convolution (DCC) network; Long Short-Term Memory (LSTM) network

基金项目: 国家自然科学基金项目“基于深度学习的深地叠前时空域地震子波提取方法研究”(编号: 42274159)。

作者简介: 孙伟峰, 1982年生, 教授, 博士研究生导师, 博士; 主要从事钻井风险智能预警方法研究工作。地址:(266580)山东省青岛市黄岛区长江西路66号。ORCID: 0000-0001-8381-6483。E-mail: sunwf@upc.edu.cn

0 引言

地层渗透率过高或孔隙过大导致钻井液流入地层的现象称为井漏^[1]，井漏是钻井过程中最常见的井下复杂问题之一。频繁发生的钻井液漏失，会增加钻井作业的非生产时间^[2]，钻井工程中因井漏而带来的经济损失占总成本的 25%~40%^[3]。据美国能源部报道，高压和高温钻井成本的 10%~20% 用于解决井漏问题^[4]。井漏的发生不仅会降低钻井效率，增加钻井成本，还会引起卡钻、井眼不稳定、完井后油气质量差等其他问题。因此，井漏的早期准确监测可提高钻井效率、减少非生产时间、降低安全事故发生概率，对于安全高效钻井具有重要意义。

井漏发生的直观表征是泥浆池液位下降，液位下降速度约为钻井液漏失速度。根据漏失严重程度，井漏可以分为微漏、小漏、中漏、大漏与严重漏失 5 类^[5-6]。漏失速度体现在监测参数的变化程度上，当漏失速度较大时，监测参数变化幅度大，现场人员或监测系统能够及时发现；而微量漏失发生时，监测参数变化缓慢，不易准确监测和发现。微漏发生后，若不及时发现并采取堵漏措施，钻井液漏失速度会逐渐增加，引起更为严重的漏失。

现有的井漏监测方法主要分为传统方法和智能方法两大类。传统方法包括泥浆池液位法、出入口流量差法等^[7]，现场人员根据监测参数的实时变化借助专家经验判断是否有井漏发生，该类方法人工成本高、主观性强、准确率低。因此，智能监测方法成为当前钻井风险监测领域的研究热点，越来越多的机器学习算法被应用于钻井风险的预测以及实时监测。例如，Aljubran 等^[8]采用随机森林实时监测井漏和溢流风险；孙金声等^[9]分析了人工神经网络、支持向量机^[10]等机器学习算法在井漏监测领域的应用。此外，决策树、K 最近邻分类算法（KNN）等^[11-15]也被引入到该领域用以提升井漏风险监测的实时性与准确性。井漏风险的判别依据是监测参数的趋势变化，而上述机器学习方法未能利用监测参数的时序依赖关系，因而监测准确率相对较低。与此相比，长短期记忆网络（LSTM）^[16]、门控循环单元（GRU）等能够获取监测参数数据序列在时间上的依赖关系，成为钻井风险监测领域内的主流方法。LSTM 和 GRU 解决了循环神经网络（RNN）因长期依赖带来的梯度消失和梯度爆炸的问题，GRU 作为 LSTM 网络内部结构的简化版，在一定程度上提高了模型的收敛速度，缩短了模型的训练时间，提高

了计算效率。考虑到 LSTM 模型的识别准确性优于 GRU，本文选择 LSTM 进行井漏风险监测。

微量漏失的表征需根据监测参数的长时变化趋势来获取，而传统循环神经网络在处理长时序列时存在信息遗忘，仅对于短序列的特征提取效果显著。因此，为利用循环神经网络实现对长时序列特征的提取，需将长序列处理为短序列。将长序列映射为短序列有两种方式，分别为下采样和多层一维卷积神经网络。下采样通过隔位取值来缩短序列长度，操作简单但会导致信息丢失；多层一维卷积神经网络提取特征的过程不存在信息丢失但模型计算复杂。扩张因果卷积网络（DCC）综合以上两种方式的优点，实现将长时序列映射为特征短序列。目前，DCC 网络在综合能源系统负荷修正预测^[17]、网络异常监测^[18]以及电力符合预测^[19]等领域已有广泛应用。为了准确监测微量漏失，本文提出了一种 DCC 与 LSTM 网络相结合的微量漏失智能监测方法。选取总池体积、立管压力与出口流量作为监测参数，利用 DCC 网络将监测参数的长时序列映射为特征短序列，采用 LSTM 网络处理得到的特征短序列以获取监测参数的长时依赖特性。DCC 网络弥补了 LSTM 网络长期记忆衰减的不足，DCC—LSTM 网络能够获取监测参数的长时趋势变化特征，实现对微量漏失的早期监测。

1 井漏智能监测原理与模型搭建

1.1 LSTM 记忆衰减分析

LSTM 是一种特殊的循环神经网络。与标准的 RNN 相比，LSTM 通过引入“门”机制来控制信息的流动，从而能够更好地处理长序列输入和输出，并且在处理长期依赖问题时具有更好的表现，图 1 为 LSTM 网络原理结构图。

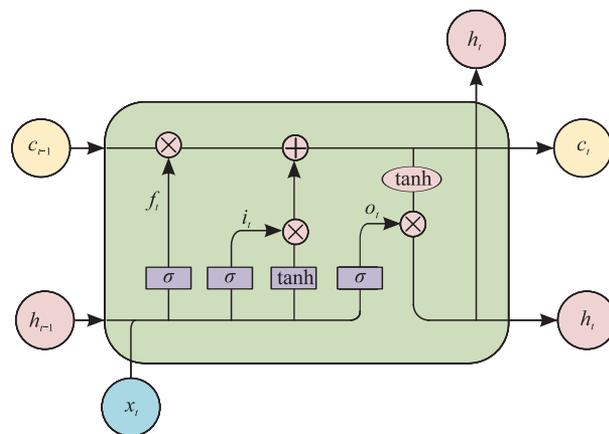


图 1 LSTM 网络原理结构图

其中, h_{t-1} 表示 $t-1$ 时刻的隐藏状态; c_{t-1} 表示 $t-1$ 时刻的细胞状态; x_t 表示 t 时刻的输入; f_t 表示遗忘门, i_t 表示输入门; o_t 表示输出门。

然而, LSTM 网络在处理长时数据序列时, 细胞状态中的信息以指数速率衰减^[18]。假设 t_0 时刻之后网络没有外部输入, 即当 $t > t_0$ 时, $x_t = 0$, 并忽略信息通过隐藏状态的泄露。在此条件下, 细胞状态 c_t 为:

$$c_t = f_t \cdot c_{t-1} = c_0 e^{\log(f_0)(t-t_0)} \quad (1)$$

式中 $f_0 = \sigma(b)$, c_0 表示 t_0 时刻的细胞状态; c_t 随时间以系数为 $\log(f_0)$ 的指数形式衰减, c_t 取值越趋向于 c_0 , 表示 t 时刻保留 t_0 时刻的信息越多。时间步长为 $0 \sim 200$ 时的衰减结果如图 2 所示, A、B 两点的的时间步长相差 30, 但对初始信息的记忆相差 24%, B 点对初始信息的记忆只有 16%。

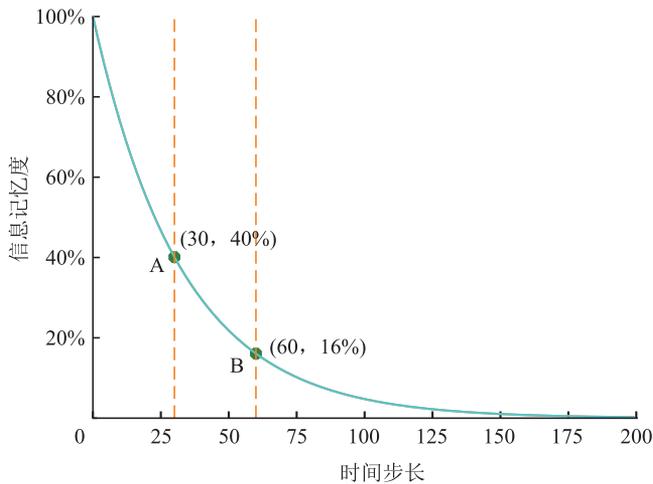


图 2 LSTM 中信息记忆度随时间步长的衰减趋势图

LSTM 网络采用特殊的门控机制, 通过记忆门来保存过去时刻的信息并将其传递到下一时刻, 具有获取序列时序依赖特性的性能, 因此 LSTM 网络适合应用于监测井漏。但是, 由于 LSTM 网络存在遗忘门, 随着输入序列长度的增加, 过去长时信息将会被遗忘, LSTM 网络处理长时序列时存在时序依赖特性获取不足的问题, 无法直接利用其监测微量漏失的发生。因此, 如何用短序列表达长序列特征来获取监测参数的时序依赖性成为解决微量漏失监测的关键问题。

1.2 DCC 捕获长期序列特征性能分析

扩张因果卷积网络是一种基于时序的卷积神经网络, 是在一维卷积网络的基础上引入扩张因子, 用以提取更长时间范围的趋势特征, 并且可以将长时数据序列映射为特征短序列。

图 3 为扩张因子 d 为 1、2、4 且卷积核为 3 时扩张因果卷积示意图。其中, 输入序列 $x=[x_1, \dots, x_l]$, 经过 3 层扩张因果卷积网络输出特征向量 $y=[y_1, \dots, y_{l_1}]$ 。长为 l 的数据序列输入到扩张因果卷积网络中, 该网络将输入数据序列特征映射到长为 l_1 的序列上。

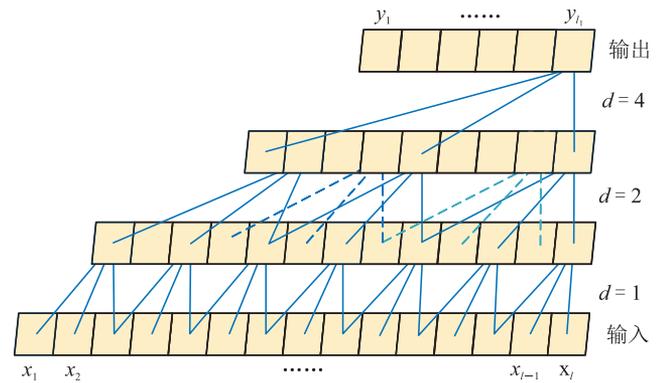


图 3 扩张因果卷积示意图

当一维时间序列 x 输入到扩张因果卷积网络时, 序列元素 s 上的扩张卷积计算 F 定义为:

$$F(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i} \quad (2)$$

式中 d 表示扩张因子; k 表示卷积核大小; $s - d \cdot i$ 表示该卷积计算为因果卷积。

扩张因果卷积网络可以保证特征提取过程无信息丢失, 且可以实现将长时序列映射为特征短序列, 解决 LSTM 在提取时序依赖特性时存在的长时遗忘问题, 进而获取监测参数的长时趋势变化特征, 解决微量漏失难监测的问题。

1.3 基于 DCC—LSTM 的井漏监测模型构建

1.3.1 模型结构

DCC 与 LSTM 网络在处理时序数据时具有不同的优势, 在处理长时序列时可以实现优势互补, 从而实现长时序列特征的提取。本文为实现微量漏失的准确监测, 构建了基于 DCC—LSTM 的井漏监测模型, 模型结构如图 4 所示。该模型首先利用 DCC 网络实现长时序列映射为特征短序列, LSTM 依据特征短序列来提取长时序列特征, 弥补了 LSTM 网络长期记忆衰减的不足, 从而实现了长期时序特征的提取, 达到微量漏失准确监测的目的。

基于 DCC—LSTM 的井漏监测模型由输入层、隐藏层和输出层 3 部分构成, 输入层为 3 个监测参数的时间序列输入, 实现数据接收并传递到隐藏层; 隐藏层由 DCC 网络、LSTM 网络、全连接层以及 Softmax 函数串接而成。DCC 网络实现将长时序列特征映射

为短序列, LSTM 网络接收特征短序列并提取时序依赖特性, 全连接层将 LSTM 网络计算得到的特征空间映射为样本标记空间。输出层输出模型监测结果。

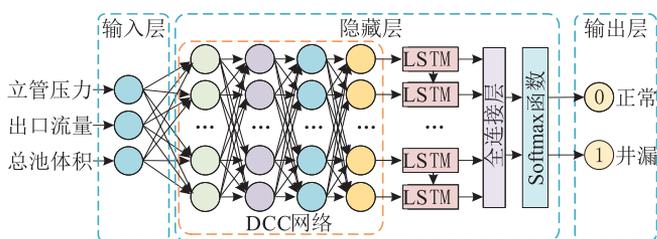


图 4 DCC-LSTM 融合网络结构图

为了提升模型的收敛速度, 选择 Softmax 函数作为全连接层的激活函数。Softmax 函数的计算公式为:

$$\text{Soft max}(z_i) = \frac{e^{z_i}}{\sum_{c=1}^C e^{z_c}} \quad (3)$$

式中 z_i 表示输入向量的第 i 元素; z_c 表示输入向量的第 c 个元素; C 表示向量的元素个数。

Softmax 函数是将模型的预测结果转化为指数函数表示, 保证概率的非负性, 转化后的结果除以所有转化后结果之和, 将每个单元的输出压缩到 0 和 1 之间, 即表示发生正常和井漏的概率, 两概率之和为 1, 选择概率较大的输出作为监测结果。

1.3.2 网络层级

网络层级会影响监测模型的准确率和计算复杂程度, 为了确定最适用的井漏监测模型, 本文提出一种 DCC 网络层数确定方法。DCC 网络层数的确定与单层 DCC 网络对输入序列长度的要求有关, 单层 DCC 网络对输入序列长度 (L) 的要求受卷积核大小 (k) 与扩张因子 (d) 两个因素的影响。它们之间的关系需满足:

$$L \geq (k-1) \cdot d + 1 \quad (4)$$

根据单层 DCC 网络对输入序列长度的要求, 推出 DCC 网络层数 (n) 与输入序列长度 (l) 的关系, 具体计算方法如:

$$l \geq \sum_{i=1}^n (k-1) \cdot d_i + 1 \quad (5)$$

式中 n 表示 DCC 网络层数; d_i 表示第 i 层 DCC 网络的扩张因子。当确定了卷积核大小与扩张因子时, 可根据式 (5) 计算得到 DCC 网络层数的设定范围 $[1, \dots, n]$ 。

为进一步确定 DCC 网络层数, 本文推导了 DCC 网络层数与输出特征序列长度的关系, 如:

$$l_1 = l - \sum_{i=1}^n (k-1) \cdot d_i \quad (6)$$

式中 l_1 表示输出特征序列长度; l 表示输入数据序列长度, 由式 (6) 可得: l_1 随网络层数 n 的增大而减小。

LSTM 网络随输入序列长度的增加存在记忆信息的遗忘, 对于短序列的信息记忆优于长序列。因此在确定 DCC 网络层数时, 应缩短输出的特征序列长度, 即选择 n 的最大值作为 DCC 网络层数。为了验证这一结论, 结合本文确定的样本长度、卷积核大小与扩张因子, 利用式 (5) 计算出 DCC 网络层数 n 为 1、2、3、4, 分别将不同层数的 DCC 网络与 LSTM 网络组合。为了验证提出的 DCC 网络层数确定方法的有效性以及构建的井漏智能监测模型的工程适用性, 采用现场采集的实际钻井数据, 对包含不同 DCC 网络层数的 DCC-LSTM 模型进行训练与测试, 不同组合模型的监测准确率随迭代次数的变化趋势如图 5 所示。可见, 采用 4 层 DCC 网络时, 组合模型的性能最优。

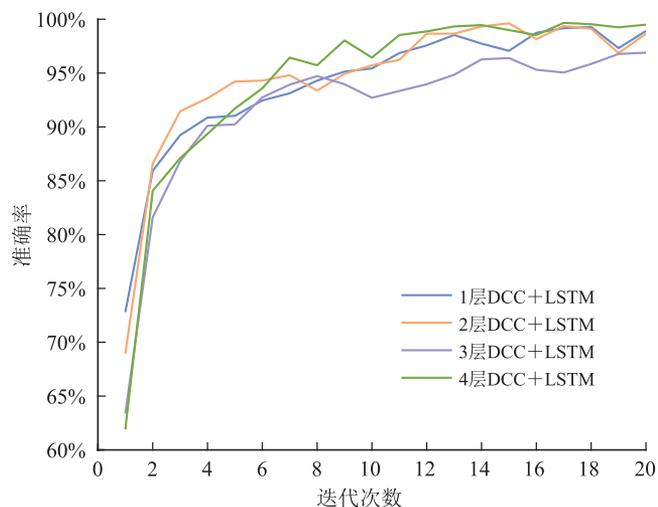


图 5 不同组合模型的准确率变化曲线图

当在 4 层 DCC 网络后串接 1 层 LSTM 网络时井漏监测准确率最高可达 99.88%, 增加 LSTM 网络层数时, 模型性能不会有很大的提升且会增加模型的计算复杂度, 综合考虑模型的计算复杂度与监测性能, LSTM 网络层数确定为 1。

在 DCC-LSTM 井漏监测模型的基础上结合监测数据的预处理、模型训练建立了基于 DCC-LSTM 的井漏智能监测方法, 其流程图如图 6 所示。主要包含监测数据的预处理和井漏监测模型的构建两个模块。其中, 监测数据的预处理由监测参数的选取、样本长度的确定、异常值剔除和归一化处理构成, 井漏监测模型的构建与训练由基于 DCC-LSTM 的井漏监测模型的构建、DCC 与 LSTM 网络层数的确定以及监测模型的训练 3 个功能单元组成。

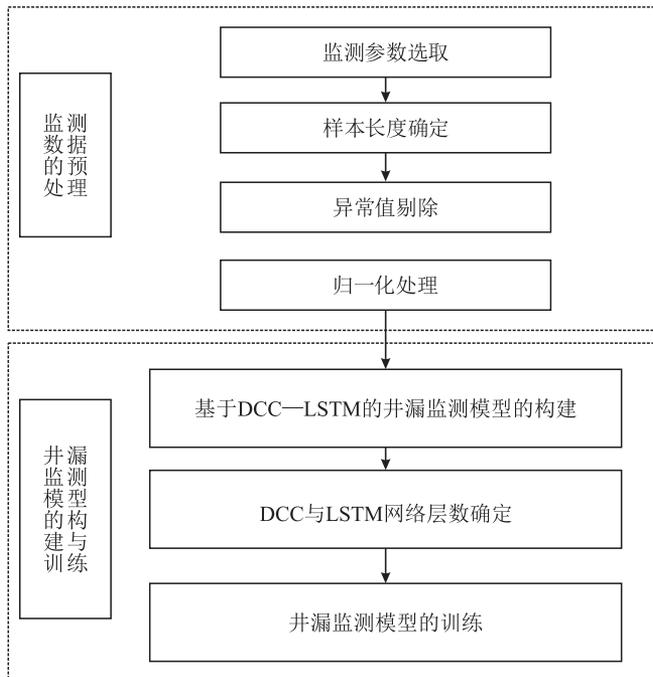


图 6 井漏监测方法流程图

1.4 监测数据的预处理

1.4.1 监测参数选取与样本长度确定

正常钻进情况下，泵入钻杆内的钻井液量与井筒中循环返出的钻井液量保持平衡，泥浆池液面基本稳定不变。当井漏发生时，井筒内的钻井液漏入地层，出口流量即钻井液返出量减小，泥浆池液面下降。随着钻井液不断漏入地层，钻井液从井底上返时的环空压耗减小，从而导致立管压力下降。因此，选择将出口流量、泥浆池体积和立管压力作为井漏监测参数。

钻进过程中，随着井深增加，井筒内钻井液需不断补充，钻井液的正常消耗量 (V) 与钻进速度 (v) 和井筒半径 (r) 之间存在 $V = \pi r^2 \cdot v$ 的关系。根据最大钻进速度 12 m/h 与常用井筒半径 350 mm 计算得到钻井液的最大正常消耗速度约为 4.62 m³/h。同时，考虑到钻井液渗入地层的消耗，泥浆池体积在 6 min 内将下降 0.5 m³，故将 0.5 m³ 作为井漏的判别阈值。钻进速度与地层性质有关，钻进过程中，钻杆并非匀速钻进，钻井液的正常消耗量是动态变化的。考虑到钻井液的正常消耗，在设定样本标签时，将泥浆池体积下降量大于钻井液正常消耗量的样本标记为“井漏”，否则样本标记为“正常”，利用标记样本对 DCC—LSTM 井漏智能模型进行训练。经分析本文实验所采用的钻井数据，采样间隔为 6 s，即 6 min 内可捕获每个监测参数的 60 个数据点，因此本文样本

长度确定为 60。

1.4.2 异常值剔除与归一化处理

异常值剔除是将超出参数正常变化范围的值剔除，归一化处理是将不同监测参数归一到同一量纲。首先采用 3σ 准则^[20] 识别异常值，其次利用异常值前的两个值的均值来代替异常值。

由于监测参数利用不同传感器采集，参数值范围在 0 ~ 1 000 之间不等，不同的监测参数特征尺度及量纲不同，而深度神经网络对于输入特征的尺度比较敏感，因此对这些输入特征数据采用最大最小值方法进行归一化处理，将数据归一到 0 ~ 1 之间。归一化计算方法为：

$$X^* = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

其中， X^* 表示归一化后的数据， X 表示原始数据； X_{\min} 、 X_{\max} 分别表示数据中的最小值和最大值。

1.5 基于 DCC—LSTM 的井漏监测模型的训练

为了有效划分训练集和测试集，提高模型的训练效率和性能，本文对获取到的井漏数据集分别按照 9:1、8:2、7:3、6:4 等 4 种常用的比例划分为训练集与测试集，利用训练集对模型进行训练，利用测试集对模型进行测试，根据模型监测准确率选择划分比例。由表 1 中的结果可以看出，当训练集与测试集比例为 8:2 时，模型的监测准确率最高，因此本文选取 8:2 为数据集划分比例。

表 1 不同数据集划分比例结果对比表

训练集与测试集比	6:4	7:3	8:2	9:1
井漏监测准确率	62.5%	73.2%	77.0%	64.4%

由于井漏监测数据与自然语言处理领域数据相似，都具有时序依赖性，因此，自然语言处理领域主流的 Adam 优化器在井漏监测领域也同样适用，该优化器既能适应稀疏梯度，又能缓解梯度震荡的问题。

为了节省内存和训练时间，同时考虑到模型的输出标签为整数，因此选择 sparse_categorical_crossentropy 为损失函数，计算公式如下：

$$loss = -\frac{1}{2} \sum_{i=1}^2 [y_i \log(Y_i) + (1 - y_i) \log(1 - Y_i)] \quad (8)$$

式中 $loss$ 表示损失值； y_i 表示第 i 类别的真实标签； Y_i 表示预测值。

网络模型中的卷积核大小、扩张因子等关键参数参考文献 [21] 中的参数设定，得到表 2 中网络模型的参数集合。由表 2 可以得到，4 层 DCC 网络的

卷积核大小均为 3，扩张因子分别为 1、2、4、8 且均为 2 的指数幂，其神经元个数依次递减，LSTM 网络包含 16 个神经元，最终由全连接层输出二分类结果。

表 2 模型参数设定表

类型	输出维度	参数设定
Input Layer	(60, 3)	—
Conv1D	(58, 64)	Kernel_size=3, d=1, filter=64
Conv1D	(54, 32)	Kernel_size=3, d=2, filter=32
Conv1D	(46, 16)	Kernel_size=3, d=4, filter=16
Conv1D	(30, 8)	Kernel_size=3, d=8, filter=8
LSTM	(30, 16)	Units=16
Flatten	(480)	—
Dense	(2)	Units=2

2 井漏监测实验与结果分析

2.1 数据来源

根据某油田现场实际获取到的 10 口井的录井数据，生成 4 827 个样本，每一个样本包含池体积、出口流量和立管压力各 60 个数据点，并按照漏速是否大于 5 m³/h 的标准把数据划分为常规漏失和微量漏失，从中提取出微量漏失样本共 2 982 个。部分井漏样本记录如表 3 所示。

表 3 部分井漏记录表

井号	漏速/(m ³ ·h ⁻¹)	用途
B338-X45	2	训练
BX-691	5	训练
BYP5	7	训练
⋮	⋮	⋮
L988-2	8.3	验证
L988-1	5.3	验证

2.2 实验结果与分析

2.2.1 模型评价指标

为了对比不同模型的井漏识别性能，采用监测准确率 Acc 和漏报率 FNR 两个指标对模型进行评价。将井漏样本看作负样本，正常样本看作正样本。具体计算公式如下。

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$FNR = \frac{FN}{TP + FN} \quad (10)$$

其中 TN 、 FP 分别表示将正常样本划分正确和错误的样本个数； FN 、 TP 表示将风险样本划分错误和正确的样本个数。

2.2.2 微量漏失监测对比实验

为了验证 DCC—LSTM 模型对于微量漏失监测的准确性，利用微漏数据，分别采用人工神经网络 ANN、支持向量机 SVM、决策树等井漏智能监测方法与 DCC—LSTM 网络模型进行对比实验分析。

本文选取了表 3 中漏失速度小于 5 m³/h 的 4 口井生成的 2 982 个微漏风险样本，对井漏监测领域常用机器学习算法与 DCC—LSTM 网络模型进行训练与测试。实验结果如图 7 所示，DCC—LSTM 网络对微量漏失的监测准确率高达 99.4%，优于 KNN、决策树等机器学习算法的识别准确率，且漏报率仅有 1.1%。该实验验证了 DCC—LSTM 网络模型对于微量漏失监测的有效性。

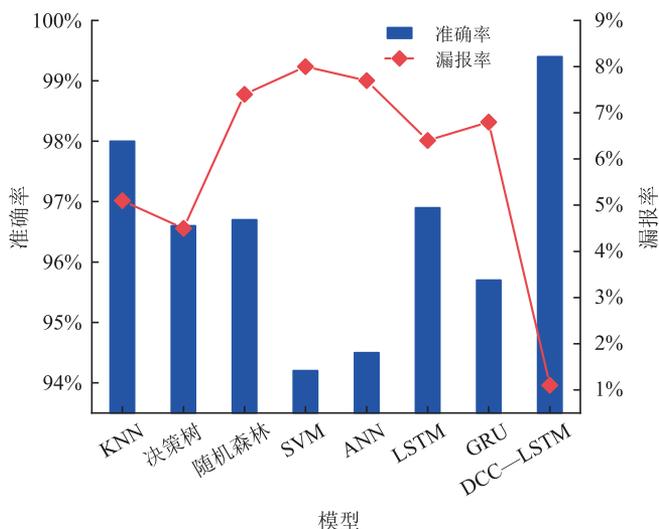


图 7 不同模型对微量漏失监测结果对比图

2.2.3 井漏监测对比实验

DCC—LSTM 网络模型对于常规漏失同样具有较高的监测准确率，采用 10 口井获取到的 4 827 个样本分别用 LSTM、GRU 以及 DCC—LSTM 网络模型进行训练与测试，并将监测准确率作为模型的评估指标。为了确定最优迭代次数，本文选取迭代次数分别为 20、40 和 60 对不同的网络模型进行训练，其测试结果如表 4 所示。结果表明，在不同的训练批次下，DCC—LSTM 网络的监测准确率均为最高，当训练 60 批次时已达到最高准确率为 99.88%，同时由图 8 可得 DCC—LSTM 网络模型的收敛速度最快。对于 LSTM 网络监测不到的微量漏失案例，DCC—LSTM 网络可

表 4 不同迭代次数的模型监测准确率对比表

迭代次数	模型	准确率
20	GRU	94.33%
	LSTM	97.54%
	DCC—LSTM	99.38%
40	GRU	98.15%
	LSTM	98.52%
	DCC—LSTM	99.51%
60	GRU	98.15%
	LSTM	99.02%
	DCC—LSTM	99.88%

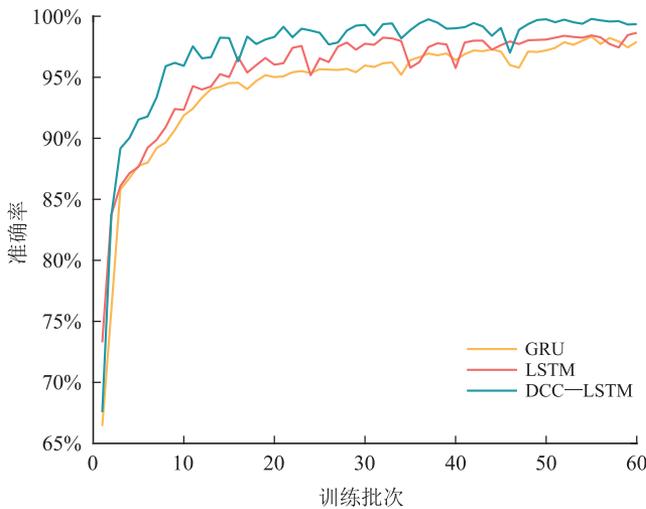


图 8 训练集准确率变化曲线图

以对其进行准确识别，因而监测准确率得到了提升。

2.3 案例分析

2021 年 1 月，L988-1 井发生多次井漏事故，造成巨大经济损失。为确保建立模型的工程适用性，利用 L988-1 井两次微量漏失发生时对应的钻井数据对模型进行测试，结果表明，DCC—LSTM 网络及时监测到了两次微漏风险。以 L988-1 井的一次井漏事故作为案例进行分析，将 LSTM 和 DCC—LSTM 的监测井漏的时刻与现场人员发现井漏的时刻进行对比，结果如图 9 所示，对于现场人员以及 LSTM 网络无法监测到的漏失量较小的情况，基于 DCC—LSTM 的井漏智能监测方法能够准确及时监测到。

L988-1 井现场工况记录说明，2021 年 1 月 7 日 03:20 时刻，钻进时发现泥浆池体积从 57.37 m³ 下降到 56.45 m³。从图 9 中可以看出，在 02:45 到 03:15 时刻，池体积下降了 1.3 m³，平均漏速为 2.6 m³/h。由于井漏早期漏失速度较小，现场人员不易察觉，

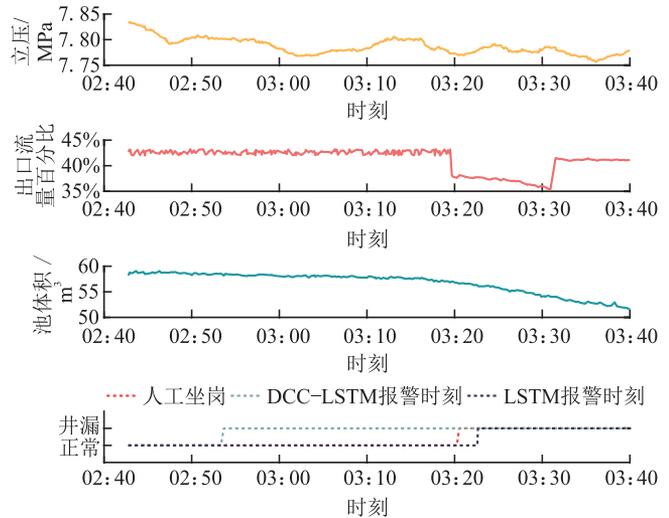


图 9 L988-1 井的 3 种方式井漏监测对比图

于 03:20 时刻才发现井漏。LSTM 网络未能及时监测到井漏的发生，导致 03:15 时刻后，漏速增加为 16.8 m³/h。与之相比，DCC—LSTM 网络根据监测数据在 6 min 内的变化趋势捕获到微量漏失发生时监测参数的表征，于 02:54 时刻监测到井漏发生，比现场观测提前 26 min，这对于及时堵漏、减少钻井液漏失具有积极意义。

3 结论与建议

1) 扩张因果卷积网络 DCC 能够对监测参数进行特征映射处理，将长时序映射为特征短序列，使得监测参数趋势变化更明显，适用于对缓变监测参数长时变化特征的提取。

2) 对于确定尺寸的卷积核，DCC 特征映射输出特征序列的长度由输入序列的长度与 DCC 网络层数共同决定。利用提出的一种基于数理统计的 DCC 网络层数确定方法得到的 DCC 网络结构使 LSTM 对长时序趋势信息的遗忘减少了 24%。

3) 结合 DCC 的特征映射能力和 LSTM 的时序特征提取能力，构建了 DCC—LSTM 井漏智能监测模型。LSTM 通过 DCC 输出的特征短序列可获取长时序的趋势特征，二者优势互补，井漏监测实验结果表明，DCC—LSTM 网络对微量漏失监测的准确率高达 99.4%，实现了微量漏失的准确监测。

4) 井漏监测受到现场钻井工况、条件等多因素的综合影响，如何在保证识别准确率的前提下减少因现场施工等因素导致的误报，是井漏监测方法能够在现场实际应用必须解决的关键问题，也是当前正在开展的研究工作。

参 考 文 献

- [1] 王建国, 万建仓, 沈慧. 钻井工程[M]. 北京: 石油工业出版社, 2008: 286-291.
WANG Jianxue, WAN Jiancang, SHEN Hui. Drilling engineering[M]. Beijing: Petroleum Industry Press, 2008: 286-291.
- [2] REHM B, SCHUBERT J, HAGSHENAS A, et al. Managed pressure drilling[M]. Houston: Gulf Publishing Company, 2009.
- [3] LÉCOLIER E, HERZHAFT B, ROUSSEAU L, et al. Development of a nanocomposite gel for lost circulation treatment[C]//SPE European Formation Damage Conference, Sheveningen: SPE, 2005: SPE-94686-MS.
- [4] ABBAS A K, BASHIKH A A, ABBAS H, et al. Intelligent decisions to stop or mitigate lost circulation based on machine learning[J]. Energy, 2019, 183: 1104-1113.
- [5] 孙金声, 白英睿, 程荣超, 等. 裂缝性恶性井漏地层堵漏技术研究进展与展望[J]. 石油勘探与开发, 2021, 48(3): 630-638.
SUN Jinsheng, BAI Yingrui, CHENG Rongchao, et al. Research progress and prospect of plugging technologies for fractured formation with severe lost circulation[J]. Petroleum Exploration and Development, 2021, 48(3): 630-638.
- [6] 邓云. 裂缝性漏失地层钻井设计研究[J]. 西部探矿工程, 2022, 34(7): 66-67.
DENG Yun. Research on drilling design of fractured leakage formation[J]. West-China Exploration Engineering, 2022, 34(7): 66-67.
- [7] 李宜君. 基于专家系统和长短期记忆网络的钻井风险监测方法研究与应用[D]. 青岛: 中国石油大学(华东), 2020.
LI Yijun. Research and application of drilling risk monitoring method based on expert system and long short-term memory network[D]. Qingdao: China University of Petroleum(East China), 2020.
- [8] ALJUBRAN M, RAMASAMY J, ALBASSAM M, et al. Deep learning and time-series analysis for the early detection of lost circulation incidents during drilling operations[J]. IEEE Access, 2021, 9: 76833-76846.
- [9] 孙金声, 刘凡, 程荣超, 等. 机器学习在防漏堵漏中研究进展与展望[J]. 石油学报, 2022, 43(1): 91-100.
SUN Jinsheng, LIU Fan, CHENG Rongchao, et al. Research progress and prospects of machine learning in lost circulation control[J]. Acta Petrolei Sinica, 2022, 43(1): 91-100.
- [10] SABAH M, TALEBKEIKHAH M, AGIN F, et al. Application of decision tree, artificial neural networks, and adaptive neuro-fuzzy inference system on predicting lost circulation: A case study from Marun oil field[J]. Journal of Petroleum Science and Engineering, 2019, 177: 236-249.
- [11] 张欣, 田英英, 韩泽龙, 等. 基于机器学习算法的井漏预测与诊断理论模型研究[J]. 钻探工程, 2022, 49(2): 58-66.
ZHANG Xin, TIAN Yingying, HAN Zelong, et al. Research on lost circulation prediction and diagnosis theoretical model based on machine learning algorithm[J]. Drilling Engineering, 2022, 49(2): 58-66.
- [12] 蔺研锋, 闵超, 代博仁, 等. 基于动态特征和深度神经网络
- 的钻井漏失事故预测[J]. 西安石油大学学报(自然科学版), 2022, 37(3): 64-69.
LIN Yanfeng, MIN Chao, DAI Boren, et al. Prediction of drilling leakage accident based on dynamic features and deep neural network[J]. Journal of Xi'an Shiyu University (Natural Science Edition), 2022, 37(3): 64-69.
- [13] HOU Xinxin, YANG Jin, YIN Qishuai, et al. Lost circulation prediction in South China Sea using machine learning and big data technology[C]//Offshore Technology Conference, Houston: OTC, 2020: OTC-30653-MS.
- [14] KHODNENKO I, IVANOV S, PERETS D, et al. Detection of lost circulation in drilling wells employing sensor data using machine learning technique[J]. Procedia Computer Science, 2019, 156: 300-307.
- [15] NEIL D, PFEIFFER M, LIU S C. Phased LSTM: Accelerating recurrent network training for long or event-based sequences[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona: Curran Associates Inc., 2016: 3889-3897.
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [17] 李文武, 张鹏宇, 石强, 等. 基于聚合混合模态分解和时序卷积神经网络的综合能源系统负荷修正预测[J]. 电网技术, 2022, 46(9): 3345-3353.
LI Wenwu, ZHANG Pengyu, SHI Qiang, et al. Correction prediction of integrated energy system load based on aggregated mixed mode decomposition and TCN[J]. Power System Technology, 2022, 46(9): 3345-3353.
- [18] 谭天, 叶倩, 孙艳杰. 基于时域卷积神经网络的网络异常检测[J]. 通信技术, 2021, 54(3): 705-710.
TAN Tian, YE Qian, SUN Yanjie. Network anomaly detection based on temporal convolutional neural network[J]. Communications Technology, 2021, 54(3): 705-710.
- [19] 吴嘉雯, 谭伦农. 基于VMD-PCA和TCN模型的短期电力负荷预测[J]. 现代电子技术, 2022, 45(17): 173-179.
WU Jiawen, TAN Lunnong. Short-term power load forecasting based on variational mode decomposition-principal component analysis and temporal convolutional network[J]. Modern Electronics Technique, 2022, 45(17): 173-179.
- [20] 李承运, 田生虎, 方会咏, 等. 一种基于 3σ 原则的发动机怠速评判方法[J]. 小型内燃机与车辆技术, 2021, 50(3): 26-29.
LI Chengyun, TIAN Shenghu, FANG Huiyong, et al. A method for engine idle speed control evaluation based on 3σ principle[J]. Small Internal Combustion Engine and Vehicle Technique, 2021, 50(3): 26-29.
- [21] BAI Shaojie, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-04-19)[2023-02-15]. <https://arxiv.org/abs/1803.01271>.

(修改回稿日期 2023-07-17 编辑 王 斌)



本文互动