

基于 CNN-BiLSTM-Attention 的油气井固井施工参数监测与预测研究

田军政¹, 谢雄武¹, 钱 坤¹, 刘长春², 马 业²

(1. 中海油田服务股份有限公司, 河北 廊坊 065000;

2. 南京航空航天大学 机电学院, 南京 210016)

摘要: 在深水、深井和超深井油气勘探领域, 油气井固井施工面临着作业危险高、劳动强度大等多重挑战, 导致油气井固井施工参数监测与进度预测难; 为了解决这些问题, 对基于云边协同和深度学习的油气井固井施工关键参数监测与进度预测进行了研究; 通过云边协同组网, 在现场采集和存储固井流量、压力、温度等数据, 并利用 MQTT 轻量化通讯协议网络进行远程传输; 研究基于 CNN-BiLSTM-Attention 网络的油气井固井施工进度预测数学模型, 通过 CNN 网络提取油气井固井施工进度的关键特征要素, 基于 BiLSTM 挖掘关键特征要素之间的关联关系, 运用 Attention 机制对重要特征进行权重分配, 以便抽取更加关键及重要的油气井固井施工进度信息; 经实验测试实现了油气井参数监测与预测的功能, 表明所提方法具有明显的预测精度优势, 且云边协同平台可以实时反映油气井固井施工过程中的各项关键参数。

关键词: 云边协同; CNN-BiLSTM-Attention; 油气井固井; 施工关键参数监测; 施工进度预测

Monitoring and Prediction of Oil and Gas Well Cementing Construction Parameters Based on CNN-BiLSTM-Attention

TIAN Junzheng¹, XIE Xiongwu¹, QIAN Kun¹, LIU Changchun², MA Ye²

(1. China Oilfield Services Limited, Langfang 065000, China;

2. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: In the fields of deep water, deep well, and ultra deep well oil and gas exploration, oil and gas well cementing construction faces multiple challenges such as high operational risks and high labor intensity, which makes it difficult to monitor and predict the parameters and progress of oil and gas well cementing construction; To address these issues, this paper studies a key parameter monitoring and progress prediction for oil and gas well cementing construction based on cloud edge collaboration and deep learning; Through cloud edge collaborative networking, data such as cementing flow rate, pressure, and temperature are collected and stored on-site, and remote transmission is carried out using message queuing telemetry transport (MQTT) lightweight communication protocol network; A mathematical model is presented to predict oil and gas well cementing construction progress based on convolutional neural network bi-directional long short-term memory attention (CNN-BiLSTM-Attention) network, the key feature elements of oil and gas well cementing construction progress are extracted through convolutional neural network (CNN) network, mining the correlations between key feature elements based on bi-directional long short-term memory (BiLSTM), and an Attention mechanism is used to allocate weights to important features and extract more critical and important information about oil and gas well cementing construction progress; Through experimental testing, the proposed method achieves the functions of monitoring and predicting oil and gas well parameters, with

收稿日期:2024-08-19; 修回日期:2024-10-10。

基金项目:中国航天科工集团基础科研项目(SCA24003)。

作者简介:田军政(1985-),男,大学本科,工程师。

通讯作者:刘长春(1995-),男,博士,助理教授。

引用格式:田军政,谢雄武,钱 坤,等. 基于 CNN-BiLSTM-Attention 的油气井固井施工参数监测与预测研究[J]. 计算机测量与控制, 2025, 33(2): 54-62.

significant advantages in prediction accuracy, and the cloud edge collaborative platform can display various key parameters in real-time during the cementing process of oil and gas wells.

Keywords: cloud edge collaboration; CNN-BiLSTM-Attention; oil and gas well cementing; key construction parameter detection; construction progress prediction

0 引言

在油气田勘探与开发领域,油气井固井作业的质量直接关联到油井后续运营周期的长短,其施工过程中各项参数的连续监控是确保固井成功率的关键因素之一^[1]。随着油气井构造日趋复杂,对固井工程质量标准的需求日益提升,这进而强调了施工参数数据精确性的至关重要性^[2]。然而,值得注意的是,当前多数固井监测设备的技术水平仍滞后于时代,大致相当于20世纪90年代的标准^[3]。这些设备普遍存在陈旧落后的问题,功能局限于基础的测量与显示,操作流程繁琐,耐用性不足,难以适应行业发展的新需求,缺乏必要的功能扩展能力,这在很大程度上限制了固井作业效率与质量的提升。

随着石油勘探与开发领域的持续深化推进,对固井工程的质量控制标准日益严格,这无疑为固井设计的优化及施工管理的精细化带来了更为复杂的挑战。在此背景下,对固井设计工作的科学性、精确性以及管理实践的有效性均提出了更为严苛的要求,促使相关领域的研究与实践必须不断革新,以应对不断提升的质量管控需求。流量^[4]、压力^[5]、温度^[6]等数据是固井作业中非常重要的技术参数。当前,数据采集与传输领域的主流技术涵盖LoRa^[7]、NB-IoT^[8]以及5G^[9]等多种方式。文献[10]中,研究者提出了一种基于LoRa技术的无线参数监测模块,该模块能够实现对各类数据的远程实时高效传输,有效攻克了以往数据采集存在的滞后性与不完整性难题。此外,文献[11]也采纳了LoRa技术,成功构建了节点仪监控系统的通信框架。LoRa技术之所以备受青睐,原因在于其具备卓越的抗干扰性能,同时模块功耗较低,并融入了空中唤醒机制,相较于单纯简化数据帧的做法,这些特性使得LoRa在实际应用中展现出更高的实用价值与优势。文献[12]采用NB-IoT技术对压力参数进行了采集并传输至了物联网云平台,实现对油气井固井管道压力的监测。文献[13]在油气井固井环境监测中,创新性地采用了窄带物联网(NB-IoT)技术,实现了对固井内部温度的精准采集与远程监控,为油气开采的安全性及效率提升提供了数据支持。文献[14]运用5G技术对矿井内部的关键参数,如压力、温度等信号进行了高效、实时地采集与传输,为矿井安全监测提供了技术支持。文献[15]提出了一种创新的智慧矿井物联架构,该架构深度融合了5G

通讯技术,旨在通过高速率、低延迟的网络连接,实现矿井内设备、人员与环境信息的实时采集、智能分析与协同控制,为矿井安全生产与高效管理提供强有力的技术支撑。然而,当前主流的监测模块在实际应用中普遍面临施工场地环境的制约,导致其长期监测准确性难以保障。加之,油气井固井施工现场往往存在设备安装条件欠佳的问题,这不仅增加了数据采集与监测的难度,还阻碍了数据的有效传输。鉴于这一现状,研发一种既便于携带、对安装条件要求低,又具备高效数据传输能力的油气井固井施工关键参数监测模块显得尤为迫切。

随着数据采集设备的多样化,大量油气井固井施工关键参数数据可以在短时间内产生。采用人工智能技术与大数据分析等手段,进行数据的有效挖掘、构建精确的数据模型以及实施深入的数据分析,发挥了至关重要的作用。文献[16]鉴于页岩油藏焖井开发过程中面临的合理焖井时长确定难、计算复杂度高等问题,创新性地运用机器学习技术进行参数模拟,成功实现了高精度的预测效果,其预测准确率高达94%,显著提升了预测的可靠性与实用性。文献[17]深入探索了机器学习在测井技术领域的广泛应用潜力,明确指出其在储层特征预测、合成测井曲线生成、测井相自动辨识等方面的关键性作用,为测井科学的智能化发展开辟了新路径。文献[18]巧妙融合循环神经网络RNN(Recurrent Neural Network)等先进机器学习算法,构建了石油钻井钻速预测系统,该系统不仅显著提升了钻井作业的效率,还有效缩短了钻井周期,对石油勘探开发效率的提升具有重要意义。文献[19]则聚焦于钻井事故预测与预防领域,揭示了机器学习在此方面的核心价值,通过其强大的数据分析能力,实现了对钻井风险的早期预警与有效管理。文献[20]在石油钻井溢流监测技术中引入机器学习理念,采用贝叶斯分类、Logistic回归及神经网络等多种算法对钻井数据进行深度学习与训练,构建了高效的溢流监测模型,实现了对钻井过程中溢流风险的精准预测与控制。文献[21]在油气井钻井压裂作业中,创新性地采用min-max归一化结合主成分分析法处理高维数据,以识别关键控制质量指标,并随后运用K-means聚类与KNN分类等机器学习算法建模,成功优化了致密气藏水力压裂施工参数,为压裂工程的高效实施提供了科学依据。文献[22]针对顺北油田X区

固井历史数据复杂多变的特点,采用机器学习中的神经网络模型进行固井质量预测,该方法有效克服了传统预测方法的局限性,为油田区块固井质量的精准评估与改进提供了有力支持。

综上所述,这些物联数据感知与大数据分析方法的深入研究可以提升油气井固井施工过程的透明化程度,有助于开创油气井固井施工大数据的新时代。但是,油气井固井施工过程中涉及的数据来源于多个传感器、设备和系统,数据格式多样,缺乏统一的数据标准和规范,导致数据集成难度大、成本高。此外,油气井固井施工关键参数繁杂,如何挖掘有效特征以保证预测的精度,是另一个需要解决的问题。因此,本文提出了一种基于云边协同和深度学习的油气井固井施工关键参数监测与控制方法,解决油气井固井施工现场关键参数采集传输难题的同时,有效提升油气井固井施工的效率 and 透明化程度,达到全面感知和预测趋势的新型油气井固井施工管理模式。

1 基于云边协同和深度学习的油气井固井施工关键参数监测与进度预测架构

基于上述文献的综合分析,本文提出了一种基于云边协同和深度学习的油气井固井施工关键参数监测与进度预测架构,如图 1 所示。

该架构包含由各类油气井固井施工设备组成的施工执行层、由各类传感器和物联网络装置组成的物联感知层、由油气井固井施工进度预测数学模型组成的数据分析层,以及实现油气井固井施工进度状态监测与预测的应用集成层。

1.1 工执行层

施工执行层作为油气井固井作业的关键层级,广泛集成了油气井固井平台设备、高精度测量仪器及专业施工设备等类型施工装置。这些装置紧密协作,共同构建了油气井固井的施工现场,通过对其运行参数的持续监测与分析,施工团队能够深入洞察施工现场的即时状态,包括环境参数、设备性能及作业效率等,进而精准把握施工进度,为施工决策提供科学依据,确保固井作业的安全、高效与高质量完成。

1.2 物联感知层

物联感知层的目的是打破制造系统中的“信息孤岛”,实时感知与分析油气井固井施工现场的数据,实现油气井固井施工现场内多源异构施工设备数据的实时感知,进而通过科学、高效的分析增强决策者对油气井固井现场的施工进度管控能力。其中,实时数据感知与分析指的是油气井固井施工现场中的物理设备通过状态读取或者部署传感器等方式实时感知自身和环境状态,并将这些数据通过物联网络装置传输到数据分析层进行




图 1 基于云边协同和深度学习的油气井固井施工关键参数监测与进度预测架构

分析和增值处理。

1.3 数据分析层

数据分析层的目的是通过实时数据感知和分析,油气井固井施工现场可以实现对施工设备运行状态、施工效率等关键指标的实时监测和分析。首先,对物联感知层内的相关施工设备和数据进行服务化封装并进行服务发布,便于后续数据处理分析时的精准调用。随后,进行油气井固井施工进度数学模型的构建和分析,挖掘出影响油气井固井施工进度的关键特征参数。最后,通过深度学习对施工进度的关键特征参数进行关联分析,并精准拟合出施工进度的预测模型。

1.4 应用集成层

应用集成层由数据存储单元、云端服务器、云端工业应用组成,是基于云边协同和深度学习的油气井固井施工关键参数监测与进度预测系统的数据中心、计算中心、服务中心,主要负责管理网络传输层上传的增值制造数据,包括任务、设备、边缘节点等。根据油气井固井施工进度数据分析结果,应用集成层通过网络传输层向底层物理设备发送控制指令、控制设备完成指定施工任务操作。同时,管理人员可以通过移动客户端或者 Web 服务端登录访问应用集成层,在网页中获取油气井固井施工进度信息、油气井固井施工进度预测信息、油

气井固井施工过程信息等。

2 关键支撑技术

2.1 基于云边协同的油气井固井施工关键参数采集与传输

在油气互联网时代, 制造商通过云平台为客户提供增值服务, 这不仅增加了企业的经济收益, 还可显著提升生产效率。然而, 为了确保增值服务的稳定运行, 云平台需要实时采集现场的油气井固井设备数据作为支撑。因此, 如何对分布式油气井固井的海量设备数据进行高效采集、传输与集成应用, 已成为成功实施云边协同驱动的油气井固井施工关键参数监测的关键技术。MQTT (Message Queuing Telemetry Transport, 消息队列遥测传输协议) 是一种基于发布/订阅模式的“轻量化”通讯协议, 针对低带宽、较差网络环境专门设计消息服务, 可以使用极少代码量实现物联网设备之间实时可靠的消息传输。因此, 通过 MQTT 可以将油气井固井作业现场产生的数据实时传输并汇聚至云端存储中心, 并将数据推流给工业应用。边缘智能网关通过通信接口与油气井固井异构装备建立连接, 并使用其内部的协议解析模块对不同设备搭载的异构通讯协议进行适配, 然后采集油气井固井作业现场数据。油气井固井施工关键参数主要由油气井固井设备的过程数据 (即进度、工作状态和剩余工作量)、相关传感器感知数据等组成, 如表 1 所示。

针对时序型与关系型数据特点, 本文设计了适用于两种数据结构的传输与存储方案, 如图 2 所示。对于时序型数据, 本文使用 Telegraf 数据采集器向 MQTT 服务器订阅主题, 并将从主题中解析获取的制

造数据存储至 InfluxData 数据库。在此之前, 需要在 Telegraf 中对拟采集时序型 JSON 数据的测量、时间戳和标签等属性名称进行配置, 而字段名称则无需配置。Telegraf 是 InfluxDB 的数据采集工具。它用于监视和订阅时序型数据的 MQTT 消息主题并解析主题内容, 将主题中所包含的相关数据存储至时序型数据库中。时序型数据在数据库中的存储位置由 JSON 格式数据中的测量和标签的属性值确定。对于关系型数据, 本文使用 Node JS 服务向 MQTT 服务器订阅主题, 并将主题中包含的关系型数据存储至 MySQL 数据库。在部署完 MQTT 相关应用后, 边缘网关通过网络地址信息、身份验证信息与 EMQX 服务器建立连接。边缘应用程序将制造资源数据封装为 MQTT 消息, 指定消息的主题并进行发布。

2.2 基于深度学习的油气井固井施工进度预测模型构建

2.2.1 油气井固井施工进度特征选择

在油气井固井施工过程中, 生产过程复杂性的增加导致了大量生产数据的产生。为了充分利用施工数据并获得高精度的进度预测结果, 根据影响油气井固井施工进度的因素是否会随着加工时间而变化, 这些施工数据相互关联, 共同影响施工进度, 构成了施工进度的输入特征。本文分析归纳了其中可用来油气井固井施工情况的进度影响因素, 在数据归一化的基础之上, 利用 t-SNE 可以将高维数据映射到低维空间, 保持数据之间的相对距离, 提供更好的数据可视化和特征提取能力, 如图 3 所示。

表 1 油气井固井施工关键参数采集表示例

序号	参数名称	数据类型	单位	示例值	备注
1	井号	字符串	—	W001	唯一标识油气井
2	固井作业开始时间	时间戳	—	2024-06-01 08: 00: 00	作业开始的具体时间
3	当前作业进度	百分比	%	75	0%~100%表示作业完成度
4	水泥浆泵送速度	数值	m ³ /h	1. 5	水泥浆注入速度
5	水泥浆剩余量	数值	m ³	50	剩余待注入的水泥浆量
6	套管压力	数值	MPa	20	套管内的压力值
7	井口温度	数值	℃	60	井口处的温度
8	钻井液密度	数值	g/cm ³	1. 2	钻井液的密度
9	钻井液流量	数值	L/min	800	钻井液的循环流量
10	振动传感器读数	数值	g	0. 5	设备振动情况, 监测设备稳定性
11	电机电流	数值	A	100	电机工作电流, 反映负载情况
12	电机温度	数值	℃	50	电机工作温度, 防止过热
13	剩余工作量估计时间	时间	h	2	预计完成剩余工作所需时间
14	通讯协议类型	字符串	—	Modbus TCP	当前使用的通讯协议类型
15	通讯状态	字符串	—	正常	通讯连接状态, 如正常、断开等
16	异常情况记录	字符串	—	无记录	记录任何异常情况或警告信息




图 2 基于云边协同的油气井固井施工关键参数采集与传输技术方案




图 3 油气井固井施工进度特征选择结果

2.2.2 基于 CNN-BiLSTM-Attention 的网络模型构建

CNN-BiLSTM-Attention (Convolutional Neural Network-Bi-directional Long Short-Term Memory-Attention, 卷积神经网络-双向长短期记忆网络-注意力机制) 的模型结构如图 4 所示。首先, 利用卷积神经网络 (CNN) 对输入数据进行深层次的特征提取, 有效捕捉局部空间特征。随后, 这些特征被传递给双向长短期记忆网络 (BiLSTM), 以充分利用其序列建模能力, 分析并拟合合数据中的时序关联与依赖关系。为进一步增强模型对关键信息的敏感度, 注意力机制 (Attention) 通过对不同时间步的特征进行动态赋权, 使得 BiLSTM 模型能够




图 4 基于 CNN-BiLSTM-Attention 的油气井固井施工进度预测模型结构

自动聚焦于更为重要的特征维度。最终, 通过注意力权重与 BiLSTM 输出的加权融合, 模型生成了更加精准且富含信息量的输出结果。

注意力机制通过动态调整权重分配策略, 以增强重要特征, 避免无关信息对最终结果造成影响, 确保模型输出的准确性和鲁棒性。

首先使用打分函数, 其表达式为:

$$s_i = \tanh(\mathbf{W}_h h_i + b_h) \quad (1)$$

然后利用 softmax 函数进行归一化, 得到每组输入向量的权重 α_i 如下所示:

$$\alpha_i = \frac{\exp(s_i v)}{\sum \exp(s_i v)} \quad (2)$$

$$h_i^* = \sum_{i=1}^n \alpha_i h \quad (3)$$

$$y_i = \sigma(\mathbf{W}_y h_i^* + b_y) \quad (4)$$

其中: $\mathbf{W}_y$ 为注意力机制 Attention 的权重, b_y 为注意力机制 Attention 的偏差。v 为注意力值, h_i^* 为 t 时刻注意力机制 Attention 层的输出, α_i 为权重系数。Attention 层对各特征赋予不同的权重, 评估预测值与时间序列数据的相似度, 并应用 softmax 函数计算注意力得分, 以优化权重分配。

在 CNN 架构中, 特征提取模块核心由卷积层与池化层交替堆叠构成, 旨在无损地揭示数据内在的深层特征。此过程首先通过对预处理数据进行巧妙的一维向量拼接, 形成结构化序列, 随后采用滑动窗口机制遍历该序列, 逐帧转换为高维特征图。通过卷积核与局部数据区域的逐元素相乘后求和, 辅以激活函数, 实现特征的层次化提取与增强, 卷积过程的计算公式描述如下:

$$y_j^l = f(\sum_{i \in N_m} x_{i,j}^{l-1} \otimes \omega_{i,j}^l + b_j^l) \quad (5)$$

其中: y_j^l 是第 l 层中的第 j 卷积导出子图, $x_{i,j}^{l-1}$ 代表第 $(l-1)$ 层的第 I 个卷积输出特征子图。 N_m 代表输入特征子图的集合。 $\otimes$ 代表矩阵之间的卷积运算。 $\omega_{i,j}^l$ 表示卷积核。 b_j^l 代表第 l 层第 j 个输出特征子图的偏差值。除此之外, $f(\cdot)$ 代表激活函数, 详细描述如下:

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (6)$$

池化层作为卷积神经网络中的重要组成部分, 旨在应对卷积操作后特征维度激增的挑战, 通过有效的下采样策略, 在显著缩减数据处理负荷的同时, 确保关键信息的保留与凝练。此过程不仅实现了数据的降维处理, 还促进了模型对生产进度变化等关键特征的敏锐捕捉, 有效缓解了过拟合现象。具体而言, 池化层的计算涉及选取局部区域, 应用如最大池化或平均池化等操作, 以概括性的方式聚合信息, 进而提升模型的泛化能力。池化层的计算过程如下:

$$y_j^{l+1} = f[\mathbf{W}_j^{l+1} \text{down}(x_j^l) + c_j^{l+1}] \quad (7)$$

其中: $\mathbf{W}_j^{l+1}$ 和 c_j^{l+1} 分别表示第 $l+1$ 层中的第 j 个权重值和偏差。本文使用最大化池化 (max-pool) 作为池化函数 $\text{down}(\cdot)$ 。

CNN 提取的特征通过双向 LSTM 全连接, 用于回归预测, 具体过程如下: 层 σ 的输出是一个向量, 其中所有元素的值都在 $[0, 1]$ 之间, 表示保存了历史信息。其中 '0' 表示不保留任何信息, '1' 表示可以保留所有信息。遗忘门使用层 σ 实现状态更新时的信息选择。

$$f_i = \sigma[\mathbf{W}_f \cdot (h_{i-1}, x_i) + b_f] \quad (8)$$

在信息筛选与更新的复杂机制中, σ 层扮演着决策者的角色, 甄别需纳入更新的信息类型; 而 $\tanh$ 层则作为内容生成器, 负责构建这些选定信息的具体更新内容。二者协同工作, 在输入门架构下实现了对更新信息的选择与构造, 具体计算方法如下:

$$\begin{cases} i_t = \sigma[\mathbf{W}_i \cdot (h_{t-1}, x_t) + b_i] \\ \tilde{C}_t = \tanh[\mathbf{W}_c \cdot (h_{t-1}, x_t) + b_c] \end{cases} \quad (9)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (10)$$

在 LSTM 模型中, 输入张量由双重维度构成: 一方面, 包含针对特定指标 x_b 的预测估值, 另一方面, 则融合了数据集内的信息 x_w 。通过 LSTM 层对特征关联关系的挖掘, 这些输入值被转化为富含时序动态特性的隐藏向量表示, 为后续分析提供了强有力的数据支撑。LSTM 层将输入值转换为隐藏向量的计算过程如下所示:

$$\begin{cases} h_b^t = G(x_b, h_b^{t-1}) \\ h_w^t = G(x_w, h_w^{t-1}) \end{cases} \quad (11)$$

随后, 在并行的 LSTM 隐藏层架构下, 实施了精细的特征拼接操作。这一过程旨在融合两个独立 LSTM 层各自捕捉的序列特性, 通过横向的特征组合与增强, 构建出更为全面且丰富的特征表示, 为后续分析提供了多维度的信息支撑:

$$h' = [h_b^t \mid h_w^t] \quad (12)$$

继并行 LSTM 隐藏层的特征拼接之后, 全连接层作为信息整合的关键一环, 深入挖掘并提炼隐藏于数据之中的深层特征。通过全连接网络的广泛连接与权重调整, 实现了对特征信息的非线性变换与高级抽象, 为后续的任务处理提供基础:

$$\mu = F_1(h') \quad (13)$$

其中: F_1 是全连接层的传递函数。目标函数可以定义为均方根误差 (RMSE), 详细描述如下:

$$L_1 = RMSE = \sqrt{\frac{1}{U} \sum_{i=1}^U (PP_i^{\text{actual}} - PP_i^{\text{predicted}})^2} \quad (14)$$

其中: PP_i^{actual} 表示施工进度真实值, $PP_i^{\text{predicted}}$ 表示施工进度预测值。

最后, 输出层的油气井固井施工进度预测结果为如

下线性回归过程:

$$\hat{y} = \omega \cdot F_2(\mu) + b \quad (15)$$

其中: $\hat{y}$ 油气井固井施工进度预测值, ω 为权重值, $F_2(\mu)$ 为线性回归拟合出的函数, b 为整体函数的偏置。

3 验证环境与结果分析

3.1 实验环境及参数描述

3.1.1 实验环境描述

图 5 左侧展示了真实的油气井固井作业现场, 旨在为数据采集提供实际应用的背景。右侧数据采集系统, 集成了高精度传感器阵列, 专用于实时捕获主轴振动强度、电机表面温度波动以及工作电流变化等关键性能指标, 这些数据通过高性能数据采集卡进行高频、高精度采样, 并利用 RS485 工业级通信协议与工控机实现稳定、可靠的数据传输。随后, 在工控机中运用数据预处理技术, 最终提炼出高质量的油气井固井质量数据集, 为后续的施工效果评估、质量监控及进度预测模型的构建提供坚实的数据支撑。

3.1.2 实验参数描述

用 CNN-BiLSTM-Attention 算法进行固井质量预测模型训练, 算法在 Python 语言环境下的油气井固井施工进度预测模型参数如表 2 所示。采用 4 层结构的 CNN-BiLSTM-Attention 网络模型, 将 CNN 输入层的输入变量数设定为 6; BiLSTM 输出层的输出变量数为 1; 隐含层神经元个数设置为 50; CNN 层采用 tanh 激活函数, BiLSTM 层采用 tanh 激活函数, 全连接层 1 求解 Attention 权重, 其激活函数为 Sigmoid, 全连接层 2 将 BiLSTM 的输出数值和 Attention 权重相乘, 其激

活函数为 Softsign; CNN 层起到特征提取的作用, BiLSTM 层是挖掘提取的特征之间的关联关系, 拟合出相应的函数, 而 tanh 激活函数在理论上可以提供更平滑的梯度, tanh 的输出范围在 $[-1, 1]$, 是 0 中心的, 有助于保持数据的稳定性, 且其导数在 0 附近较大, 有利于梯度传播和模型收敛。当全连接层 1 的输出需要作为后续层 (如另一个全连接层, 即文中的全连接层 2) 的输入时, Sigmoid 通常是一个合适的选择。在需要稳定梯度传播和避免梯度消失问题的情况下, Softsign 的平滑特性有助于保持网络的稳定性和性能, 有利于模型获得更加精准的油气井施工进度预测值, 因此全连接层 2 采用激活函数 Softsign。设置最大迭代次数为 1 000 次, 学习速率设置为 0.000 1。

表 2 基于 CNN-BiLSTM-Attention 的油气井固井施工进度预测模型参数描述

模型参数	设置值	参数描述
Num_CNN	6	CNN 输入层的输入变量数
Num_BiLSTM	1	双向 LSTM 输出层的输出变量数
Act_CNN	tanh	CNN 层采用的激活函数
Act_BiLSTM	tanh	双向 LSTM 层采用的激活函数
Act_FC1	Sigmoid	全连接层 1 的激活函数
Act_FC2	Softsign	全连接层 2 的激活函数
Epoch	1 000	最大迭代次数
Learning_rate	0.000 1	模型的学习率

3.2 基于云边协同的油气井固井施工关键参数采集与传输平台

图 6 展示了基于云边协同框架下的油气井固井施工关键参数的高效采集与实时传输成果。该主界面不仅集成了参数监测系统, 实时反映施工过程中的井底压力参数、水泥浆注入速率参数、井筒内及水泥浆的温度参数、监测套管与井壁等的位移振动参数各项关键指标。

首先, 系统能够实时显示井底压力的即时数值, 并绘制出历史演变趋势图, 帮助技术人员快速识别压力波动, 及时采取调整措施。其次, 系统通过实时监测并展示水泥浆注入速率的即时数值及历史变化趋势, 为施工人员提供了精确控制流量的依据。然后, 系统能够实时采集并展示这些温度数据, 帮助判断固结反应进程, 确保固井质量。最后, 系统通过数据分析, 提供即




图 5 油气井固井施工关键参数采集及进度预测实验环境



图 6 基于云边协同的油气井固井施工关键参数采集与传输平台

时的位移与振动数据及其历史演变趋势, 为安全施工提供保障。此外, 平台依托云边协同的强大能力, 深度描绘施工任务的详尽概况, 确保信息的全面性与时效性。施工进度预测值能够在线即时展示, 为相关人员精确调控施工节奏、科学规划后续计划提供了坚实的数据支撑与决策依据。

3.3 基于 CNN-BiLSTM-Attention 的油气井施工进度预测结果

在基于云边协同的油气井固井施工关键参数采集与传输平台的基础上, 基于 CNN-BiLSTM-Attention 的油气井施工进度预测模型可以获得大量的油气井施工历史与实时参数, 作为预测模型的输入, 便于预测模型的训练与更新。图 7 展示了基于 CNN-BiLSTM-Attention 架构的油气井施工进度预测模型在训练过程中的损失变化趋势。




图 7 基于 CNN-BiLSTM-Attention 的油气井施工进度预测模型训练结果

服务股份有限公司提供, 包含某油气井固井实际施工过程中全生命周期的采集数据。在初始的 600 个 Epoch 内, 模型面临较大的学习挑战, 损失值居高不下且未显现出明显的收敛迹象。然而, 随着训练迭代至 800 个 Epoch 之后, 模型逐渐进入稳定状态, 损失值趋于平稳并达到收敛条件, 预示着模型已有效学习到了油气井施工进度

的复杂时序特征。在图 8 所呈现的基于 CNN-BiLSTM- Attention 的油气井施工进度预测模型的验证结果中, 通过对比实际施工进度(真实值)和预测走势在随机选取的 20% 验证集上的表现, 可以清晰地观察到两者间的高度一致性, 这不仅彰显了模型对油气井施工进度复杂动态变化的深刻理解, 也强有力地证明了模型成功捕捉到了施工进度与输入特征之间错综复杂的关联关系。




图 8 基于 CNN-BiLSTM-Attention 的油气井施工进度预测模型预测结果

3.4 对比实验分析

为了全面评估所提 CNN-BiLSTM- Attention 模型在油气井施工进度预测任务中的效能, 将其与一系列主流深度学习方法(包括 CNN、BiLSTM、LSTM、DBN、DAE 等)进行了深入的比较分析。

图 9 直观展示了这些模型在预测精确度方面的量化对比结果, 其中, 基于 CNN-BiLSTM-Attention 的预测模型以其显著的优势脱颖而出, 不仅在精度上实现了对比方法的最优水平, 还有力验证了本方法在处理复杂施工进度预测任务时的卓越性能与优越性。

4 结束语

针对深水、深井及超深井油气勘探中油气井固井施工面临的高风险、高劳动强度及进度监测与预测难题, 创新性地提出了一种基于云边协同与深度学习技术的油气井固井施工关键参数监测与进度预测方法。该方法通过云边协同组网技术, 实现了现场数据的实时采集、存储与远程传输, 有效利用了 MQTT 轻量化通讯协议提




图9 对比算法结果分析

升了数据传输效率与稳定性。在数据处理与分析层面,采用 CNN-BiLSTM-Attention 混合模型,综合了卷积神经网络 (CNN) 在特征提取上的优势、双向长短期记忆网络 (BiLSTM) 在时间序列关联分析中的特长,以及注意力机制 (Attention) 在关键信息聚焦上的能力,构建了一个高精度的油气井固井施工进度预测模型。该方法不仅提升了施工参数监测的实时性与准确性,还显著增强了施工进度预测的科学性与可靠性,为油气勘探领域的高效、安全作业提供了有力支持。

未来,随着物联网、大数据、云计算及人工智能技术的持续进步,油气井固井施工的智能化水平将进一步提升。一方面,可以探索更加先进的传感器技术,以实现更多元化、更细化施工参数的全面监测,为深度学习模型提供更丰富、更高质量的数据支撑;另一方面,可以进一步优化深度学习模型的结构与算法,比如引入更复杂的网络架构、强化学习机制等,以提升模型在复杂环境下的适应性与预测精度。

参考文献:

- [1] 王占峰. 提升油气井固井施工质量的技术探究 [J]. 西部探矿工程, 2022, 34 (11): 81-82.
- [2] 曾义金. 中国石化深层超深层油气井固井技术新进展与发展建议 [J]. 石油钻探技术, 2023, 51 (4): 66-73.
- [3] MOHAMMADPOOR M, TORABI F. Big data analytics in oil and gas industry: an emerging trend [J]. Petroleum, 2020, 6 (4): 321-328.
- [4] MERIBOUT M, AZZI A, GHENDOUR N, et al. Multi-phase flow meters targeting oil & gas industries [J]. Measurement, 2020, 165: 108111.
- [5] SLIEM M H, FAYYAD E M, ABDULLAH A M, et al. Monitoring of under deposit corrosion for the oil and gas industry: a review [J]. Journal of Petroleum Science and Engineering, 2021, 204: 108752.
- [6] COLLINS W, ORBACH R, BAILEY M, et al. Monitoring methane emissions from oil and gas operations [J]. Optics Express, 2022, 30 (14): 24326-24351.
- [7] NARAYANA C L, SINGH R, GEHLOT A. Performance evaluation of LoRa based sensor node and gateway architecture for oil pipeline management [J]. International Journal of Electrical and Computer Engineering (IJECE), 2022, 12 (1): 974-982.
- [8] QUAMAR M M, KHAN K A, KHALID M. Narrowband-IoT based integrated framework for monitoring pipeline condition in oil and gas industry [C] // 2023 International Conference on Control, Automation and Diagnosis (IC-CAD). IEEE, 2023: 1-6.
- [9] MAHESAN K V, WONGCHAI A, TAMIZHSELVAN C, et al. Automation industry in cyber physical systems based on 4G IoT networks for operation controlling and monitoring management [J]. Optik, 2023, 272: 170308.
- [10] 杨庆伟, 王志杰, 邓卓湘, 等. 基于 LoRa 技术的无线流量计在寒区供暖系统的应用 [J]. 科学技术创新, 2019 (6): 179-180.
- [11] 乐强, 张怀, 袁久春, 等. 基于 LoRa 技术的节点仪监控系统研究 [J]. 石油管材与仪器, 2022, 8 (6): 32-37.
- [12] 路敬伟, 王志桥, 彭朝霞, 等. 基于 NB-IoT 技术的天然气管道泄漏监测系统 [J]. 化工自动化及仪表, 2024, 51 (2): 222-226.
- [13] 郑慧君, 彭勇, 梁月华, 等. 基于 NB-IoT 的地下管廊环境监测系统设计 [J]. 科学技术创新, 2024 (5): 82-85.
- [14] 彭登. 基于 5G 专网的智慧煤矿建设方案研究 [J]. 通信与信息技术, 2024 (3): 67-70.
- [15] 何治东, 李东辉. 基于 5G 通信的智慧矿山物联网架构研究 [J]. 通讯世界, 2024, 31 (5): 28-33.
- [16] 杨红梅, 薛敏, 杨决, 等. 基于机器学习的页岩油藏合理焖井时间预测 [J]. 西安石油大学学报 (自然科学版), 2022, 37 (2): 65-72.
- [17] 王清媛, 黄全舟. 浅析机器学习在石油测井领域的研究进展 [J]. 清洗世界, 2021, 37 (3): 120-122.
- [18] 张维罡. 基于机器学习算法的石油钻速研究 [J]. 化工管理, 2021 (20): 89-90.
- [19] ASSI K. Traffic crash severity prediction-A synergy by hybrid principal component analysis and machine learning models [J]. International Journal of Environmental Research and Public Health, 2020, 17 (20): 7598.
- [20] 肖宏亮. 基于机器学习的石油钻井流监测研究与应用 [D]. 北京: 北京邮电大学, 2020.
- [21] 樊毅龙. 基于机器学习的致密气藏水力压裂施工参数优化设计 [D]. 北京: 西安石油大学 2021.
- [22] 杜冬楠, 郑双进, 赫英状, 等. 基于 LM 优化神经网络的固井质量预测方法—以顺北油田 X 区块为例 [J]. 石油地质与工程, 2021, 35 (3): 123-126.