DOI:10. 19657/j. geoscience. 1000-8527. 202512140193

融合深度学习网络的地下储气库微震时序智能预测模型及其应用

刘新涛[1]，曹晓辉[2]，杜睿山[1,3,4,*]，孟令东[4]，马速超[5]

（1. 东北石油大学计算机与信息技术学院，黑龙江 大庆 163318；2. 中国联合工程有限公司，浙江 杭州 310000；3. 黑龙江省石油大数据与智能分析重点实验室，黑龙江 大庆 163318；4. 黑龙江省油气藏及地下储库完整性评价重点实验室，黑龙江 大庆 163318；5. 中国石油大庆油田工程建设有限公司，黑龙江 大庆 163318）

摘要：地下储气库动态安全运行离不开对注采扰动引起微震活动的准确预测。针对微震时序中存在的强非线性耦合、外部注采扰动的滞后效应以及多尺度演化模式难以精确建模的问题，本研究提出了一种融合扩展型长短期记忆网络（xLSTM）与Informer结构的微震时序预测模型。在数据处理环节，构建了包含注采速率、井口压力、温度等多源工程参数的特征集，并采用皮尔逊相关系数与互信息方法筛选关键驱动特征，以增强输入的代表性；在模型设计上，引入xLSTM以强化短期动态扰动与时滞响应的建模能力，同时采用Informer的稀疏自注意力机制与层次化蒸馏编码结构，实现对长周期依赖与全局演化趋势的高效捕捉。实验结果表明，所提方法在微震事件频次与能量预测任务中，平均绝对误差（MAE）、均方误差（MSE）以及平均绝对百分比误差（MAPE）均显著优于对比模型。此外将该模型应用于同区块不同储气库的注采条件下，数据验证表明，其在复杂工况下能够准确预测微震事件频次和能量的演化趋势。

关键词：xLSTM网络；Informer网络；时序预测；注意力机制；深度学习；地下储气库

中图分类号：P315；TP391；T631. 8；T618. 1；TE122. 3　　**文献标志码：**A　　**文章编号：**1000-8527(2026)01-0275-12

Intelligent Prediction Model for Microseismic Time Series in Underground Gas Storage Integrating Deep Learning Networks and Its Application

LIU Xintao[1], CAO Xiaohui[2], DU Ruishan[1,3,4,*], MENG Lingdong[4], MA Suchao[5]

(1. *School of Computer and Information Technology, Northeast Petroleum University, Daqing, Heilongjiang* 163318, *China*; 2. *China United Engineering Corporation Limited, Hangzhou, Zhejiang* 310000, *China*; 3. *Key Laboratory of Oil Big Data and Intelligent Analysis of Heilongjiang Province, Daqing, Heilongjiang* 163318, *China*; 4. *Key Laboratory of Oil and Gas Reservoir and Underground Gas Storage Integrity Evaluations, Daqing, Heilongjiang* 163318, *China*; 5. *PetroChina Daqing Oilfield Engineering Construction Company Limited, Daqing, Heilongjiang* 163318, *China*)

Abstract: The dynamic and safe operation of underground gas storage (UGS) relies on the accurate prediction of microseismic activity induced by injection and production disturbances. To address the challenges in modeling microseismic time series, including strong nonlinear coupling, lagged effects of external injection/production

收稿日期：2025-12-14；**修回日期：**2025-12-29；**编辑：**赵宇。

基金项目：黑龙江省科技创新基地项目“数智化油田信息感知与智能分析处理关键技术研究”（JD24A009）；东北石油大学人才引进科研启动经费资助项目（13051202402）。

作者简介：刘新涛，男，硕士研究生，1997年出生，研究方向为人工智能、机器学习。Email：2323647021@qq. com。

＊通信作者：杜睿山，男，副教授，博士，1977年出生，研究方向为人工智能、机器学习。Email：durs918@163. com。

引用格式：刘新涛，曹晓辉，杜睿山，等. 融合深度学习网络的地下储气库微震时序智能预测模型及其应用［J］. 现代地质，2026，40（1）：275-286. DOI：10. 19657/j. geoscience. 1000-8527. 202512140193.

LIU Xintao, CAO Xiaohui, DU Ruishan, et al. Intelligent Prediction Model for Microseismic Time Series in Underground Gas Storage Integrating Deep Learning Networks and Its Application［J］. GEOSCIENCE, 2026, 40（1）: 275-286. DOI: 10. 19657/j. geoscience. 1000-8527. 202512140193.

operations, and multi-scale evolution patterns, this study proposes a microseismic time series prediction model integrating an extended long short-term memory network (xLSTM) with the Informer architecture. In the data processing stage, a multi-source feature set comprising injection/production rates, wellhead pressure, temperature, and other engineering parameters was constructed, and key driving features were selected using Pearson correlation coefficients and mutual information to enhance input representativeness. In the model design, xLSTM was employed to strengthen the modeling of short-term dynamic disturbances and delayed responses, while Informer's sparse self-attention mechanism and hierarchical distillation encoding structure enabled efficient capture of long-term dependencies and global evolutionary trends. Experimental results demonstrate that the proposed method significantly outperforms benchmark models in predicting microseismic event frequency and energy in terms of mean absolute error (MAE), mean squared error (MSE), and mean absolute percentage error (MAPE). Moreover, when applied to injection/production conditions across different UGS reservoirs within the same block, data validation shows that the model can accurately predict the evolution of microseismic event frequency and energy under complex operational conditions.

Key words: xLSTM network; Informer network; time series prediction; attention mechanism; deep learning; underground gas storage

0 引 言

随着地下储气库在天然气季节调峰与战略储备中的大规模部署使用，其运行过程的安全性与地质稳定性问题逐渐成为学界与工业界关注的焦点。储气库在注采过程中频繁的压力与流量波动会引发储层内部的应力重分布，从而可能触发断层活化、岩石破裂及微震活动[1-2]。微震监测作为反映地层应力状态与潜在失稳风险的重要手段[3]，为储气库动态安全评估与风险预警提供了关键依据[4-5]。

储气库微震事件的形成通常受到多维注采参数因素的共同影响。这些参数不仅具有强烈的时变性与非平稳特性，而且其与微震响应之间存在明显的滞后效应[6-7]。若能够基于大量注采时序数据与历史微震时序数据挖掘其内部关联结构，实现对未来微震活动演化趋势的预测，将有助于提前识别储层不稳定迹象，预警潜在的诱发性地质风险[8-9]，对地下储气库运行安全与动态调控具有重要工程意义。

围绕注采操作与微震活动之间关系的定量研究，前期多依赖统计分析与经验性关联方法。如井岗等[10]研究通过对金坛盐穴储气库连续微震监测与注采记录，对注采操作与微震事件数之间的关系进行了初步关联性分析。随着机器学习技术在相关领域的应用，面向微震与诱发微震活动的数据驱动预测方法已逐步成为该方向的重要研究趋势。相关研究表明，将注采数据、井筒压力、流体注入量等工程参数纳入模型能够显著提升对地层力学响应的可解释性与可预测性[11]。Qin等[12]采用随机森林与XGBoost等方法构建了诱发地震预测模型；裴艳宇等[13]通过一维卷积神经网络实现了微震能级的时序预测；马佳骥等[14]利用改进型LSTM提升了多参数微震序列的建模能力；Bloemheuvel等[15]进一步将图神经网络引入微震预测中，以刻画多站点观测之间的空间关联。刘彩云等[16]基于AlexNet深度神经网络实现重力异常反演，为地质数据的智能处理提供了方法参考。薛瑞洁等[17]通过卷积神经网络完成磁异常反演，其特征提取思路可为微震时序数据处理提供借鉴。王永昌等[18]提出基于生成对抗网络的半监督地震波阻抗反演方法；张云骥等[19]基于机器学习测井反演开展宏观煤岩类型评价，为地质数据的智能处理与工程预测提供了方法参考。

上述研究在注采-微震关系建模方面取得了重要进展，但在复杂储气库工况下实现高精度微震时序数据预测仍面临显著挑战[20]。统计模型主要依赖线性假设与弱平稳性条件，对于注采扰动引起的强非线性、多变量耦合和突变行为难以有效表征[21]。循环神经网络（LSTM、GRU等）虽然在捕捉短期时间依赖方面具有一定优势，但其固有的递归结构依赖链式反向传播机制，在长序列任务中容易受到梯度衰减及记忆衰退的限制，导致对长期滞后效应与跨尺度时间序列数据特征的识别能

力不足[22-23]，难以精准刻画储气库典型的长注采周期特征与延迟型微震响应机制之间的关系。

在储气库微震时序数据预测任务中，亟须能够同时关注短期扰动模式与长期演化规律的建模框架。为此，需要构建一种兼具捕获短期局部特征与长期依赖建模能力的多尺度预测体系。基于这一需求，本文尝试引入扩展型长短期记忆网络（xLSTM）[24]，通过增强记忆单元与改进门控机制，更有效地捕捉短周期注采扰动及其滞后效应；同时结合擅长长序列依赖建模的 Transformer 框架[25]，引入了其面向高效长时序预测的 Informer 网络[26]，通过 ProbSparse 稀疏注意力与蒸馏编码器结构，提升模型在超长序列下的远距离依赖提取能力与计算效率，从而有效捕捉跨周期响应特征。通过将 xLSTM 网络与 Informer 网络加以协同集成，实现对局部动态特征与跨尺度时序结构的联合建模[27]，从而充分发挥两类网络在短期扰动解析与长期依赖刻画方面的互补优势[28]，为储气库微震时序预测构建一个具备更高稳定性与预测精度的混合式深度学习框架。

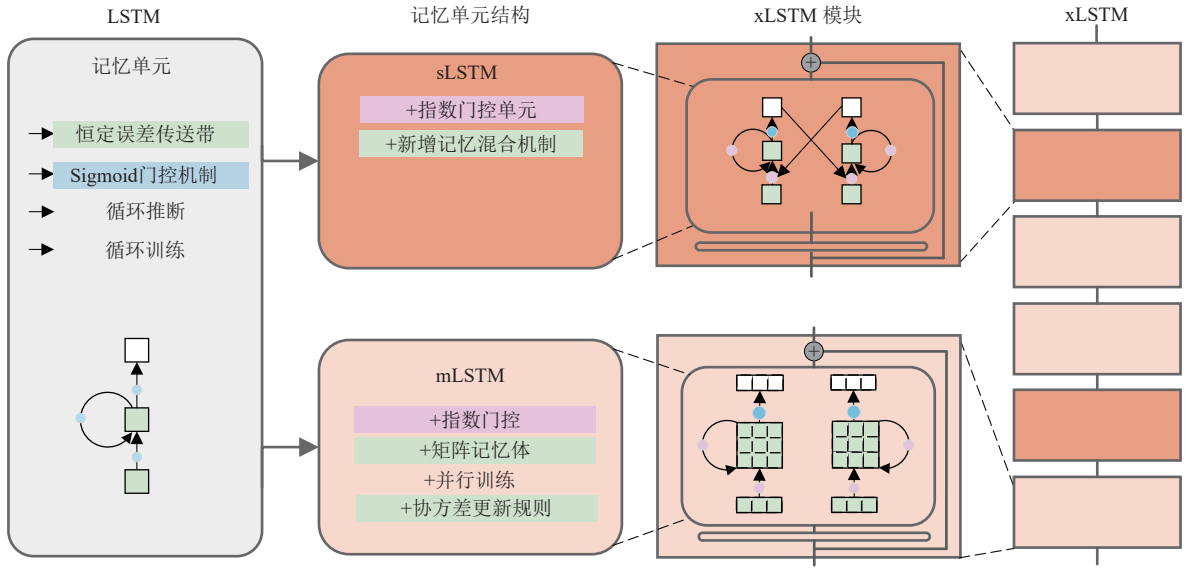


图 1　xLSTM 模型框架图

Fig. 1　Framework diagram of the xLSTM model

本研究的主要工作在于：

（1）构建多源时序融合特征体系，通过特征重要性分析筛选关键注采特征，为微震事件频次和能量的预测提供数据支撑；

（2）提出 xLSTM-Informer 混合预测架构，将扩展型 LSTM 与 Informer 联合用于储气库微震时序预测，实现短期非线性特征与长期依赖信息的协同建模；

（3）将该模型运用到同区块不同地质条件的储气库，通过对多周期注采数据和微震时序数据进行验证，评估模型在不同储层特性和注采策略下的预测性能。

1　数据预处理及相关性分析

1.1　数据来源与构成

实验数据来源于储气库注采作业现场的多源时序监测数据，包括两类核心数据：一是注采过程关键参数数据，涵盖注采井口压力、注/采气速率、储层压力、井口温度等，采样频率为 1 次/小时，记录时长为连续 24 个月；二是该区块的微震事件监测数据，包含单位时间内微震事件发生频次以及微震事件能量值的统计结果，数据由现场微震监测系统采集。

1.2　数据缺失与异常值处理

1.2.1　缺失值处理

针对注采参数时序数据（1 次/小时采样）展开完整性校验。以“时间戳”为基准，构建连续 2 个注采周期的标准时间序列框架，通过比对原始数据时间戳，识别缺失值。划分四个月的数据为一个时间段，基于储气库的实际运行规律，四个月的跨度能完整覆盖冬季高峰采气期或夏季稳定注气期，确保了段内工况的同质性，对于缺失率 < 2.5% 的时段采用“线性插值法”补全，确保时序数据的连续性；缺失率在［2.5%，5.0%）的时

段，结合缺失值的具体时间段，判断是否为注采平衡期，若非注采平衡期则结合同期同工况下的历史数据趋势，采用“邻近时段均值填充+趋势修正”方法补全，避免单一插值导致的偏差。缺失率计算公式为：

$$\text{缺失率} = \frac{\text{该时段缺失数据点数量}}{\text{该时段标准总数据点数量}} \times 100\% \tag{1}$$

对于时间序列中相邻两个有效数据点 x_t 和 x_{t+n}，中间第 $t+i$ 个的缺失点补全值为：

$$x_{t+i} = x_t + \frac{x_{t+n} - x_t}{n} \times i \tag{2}$$

基于缺失率 ≥ 5% 且非注采平衡期的数据丢失采用“邻近时段均值填充 + 趋势修正”方法，计算 m 个有效时段的均值 $\bar{x}_m$，结合同期同工况下的历史数据趋势斜率 k 修正，计算补全值为：

$$x' = \bar{x}_m + k \times \Delta t \tag{3}$$

式中，Δt 为待补全数据点与邻近时段基准点时间间隔，邻近时段基准点为“缺失段发生前最后一个有效采样点的时刻”，以此作为计算缺失数据时间偏差的起点。k 值计算通过历史同期滑动窗口的局部线性回归计算得到。

1.2.2 异常值处理

基于 3σ 原则识别统计异常：计算注入流量的均值 μ 和标准差 σ，基于历史统计值，将超出 $[\mu - \sigma,\ \mu + \sigma]$ 范围的数值标记为统计异常。异常值处理采用前后各 5 个时间点的滑动均值替换策略。该窗口长度在对不同窗口规模进行对比实验后确定的：当窗口长度过小时难以有效抑制孤立异常点，过大时则会过度平滑真实的短期波动。实验表明窗口长度为 5–7 时模型性能最优，综合平滑效果与动态保持能力，本文选取 5 作为最终窗口长度。对于异常数据点 x_t，将其值替换为：

$$x_t' = \frac{1}{10}\left(\sum_{i=1}^{5} x_{t-i} + \sum_{i=1}^{5} x_{t+i}\right) \tag{4}$$

1.3 相关性分析

微震事件的发生与注采作业参数密切相关，在微震事件预测中，若纳入过多与微震响应无显著关联的非关键参数，不仅会增加模型训练时间、延缓收敛速度，还可能因冗余信息干扰导致预测精度下降。因此，深入分析各类参数与微震事件的内在联系，筛选出核心影响因素，是构建高效预测模型的关键前提。本实验利用皮尔逊相关系数，量化分析注采参数特征与微震事件关键指标的线性关联强度，筛选核心影响因素，其计算公式如下：

$$r_{X,Y} = \frac{\sum_{1}^{n}(X_i - \bar{X}) \times (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^{n}(X_i - \bar{X})^2}\sqrt{\sum_{i=1}^{n}(Y_i - \bar{Y})^2}} \tag{5}$$

式中，X 代表待分析参数，Y 代表微震事件特征，n 为样本数量，$\bar{X}$、$\bar{Y}$ 分别为参数 X_i 与微震指标 Y_i 的样本均值，通过计算 $r_{X,Y}$ 的绝对值大小，判断参数与微震事件的关联程度：$|r_{X,Y}| \geq 0.7$ 为强相关，$0.3 \leq |r_{X,Y}| < 0.7$ 为中等相关，$|r_{X,Y}| < 0.3$ 为弱相关，弱相关参数作为非关键因素剔除，以优化预测模型的输入特征集。

为刻画注采参数与微震响应之间存在的非线性依赖关系，引入互信息（Mutual Information，MI）作为补充相关性度量指标。互信息能够衡量变量之间的任意统计依赖关系，而不局限于线性形式。采用基于 k 近邻估计的互信息方法，计算各注采参数与微震时序之间的互信息值，并据此对特征的重要性进行排序与筛选。特征筛选的分工与决策流程如下：①当参数同时满足 $|r| < 0.3$ 且 MI 低于设定阈值时，判为非关键参数剔除；②当 MI 较高但 $|r|$ 偏低时，将其视为主要非线性驱动因素，仍予以保留；③当二者均较高时，判为关键参数优先纳入模型输入。对微震事件关键指标与注采参数的关联性进行量化分析，所得分析结果如表 1 所示。

表 1 注采参数与微震时序的皮尔逊相关系数与互信息对比

Table 1 Comparison of Pearson correlation coefficients and mutual information between injection–production parameters and microseismic time series

注采参数	皮尔逊相关系数|r|	互信息系数 MI
注/采气速率	0.87	0.69
井口压力	0.57	0.62
井口温度	0.38	0.34
储层压力	0.79	0.84

结果表明，注/采气速率、井口压力与储层压力在互信息分析中仍表现出较高依赖强度，说明其不仅具有显著线性相关性，同时还存在明显非线性耦合关系；井口温度的互信息值较低，其对微震活动的影响相对较弱，但是仍可能通过与其他注采参数的耦合效应间接影响地层应力演化过程。该结果与皮尔逊相关性分析形成互补，有助于更全面刻画注采扰动与微震响应之间的关系。

2　微震时序预测模型构建

2.1　xLSTM模型

扩展型长短期记忆网络（xLSTM）是在LSTM基础上改进的一种结构，其核心创新在于引入门控线性单元（Gated Linear Unit，GLU）与增强记忆模块（Memory Augmentation Unit），优化传统LSTM的门控机制。

结构设计上，xLSTM通过多尺度记忆单元的模块化集成，进一步提升了对复杂时序数据的建模适配性，该架构包含两种核心单元：标量LSTM（simple layer-wise LSTM，sLSTM）和矩阵LSTM（multiple layer-wise LSTM，mLSTM）。其中，sLSTM通过优化传统LSTM的更新方式，采用结构化门控机制与非线性信息融合策略，使其能够更敏锐地响应输入序列中的局部突变与短期波动。

sLSTM通过解耦记忆更新与引入归一化门控策略，强化模型对序列中短期波动与局部突变的捕捉能力。对于一个时间步t，其输入为x_t，上一时刻的隐状态为h_{t-1}，输入门、遗忘门、输出门分别为i_t、f_t、o_t，其公式如下：

$$i_t = \exp(a_i^t x_t + b_i h_{t-1} + c_i) \tag{6}$$

$$f_t = \sigma(a_f^T x_t + b_f h_{t-1} + c_f) \quad \text{或} \ \exp(a_f^T x_t + b_f h_{t-1} + c_f) \tag{7}$$

$$o_t = \exp(a_o^T x_t + b_o h_{t-1} + c_o) \tag{8}$$

式中：a_i，a_f，a_o为对应输入x_t与输入门、遗忘门、输出门的权重向量；b_i，b_f，b_o为上一时刻隐藏状态h_{t-1}的对应权重；c_i，c_f，c_o为偏置项。

由于指数激活函数可能输出较大的数值，容易造成数据溢出的现象，借助稳定状态m_t对门控机制进行调控以规避该问题，在向前传递时，公式（10）改进后的i_t'，f_t'不会改动损失函数关于模型参数的导数计算结果。

$$\begin{cases} m_t = \max(\lg f_t + m_{t-1}, \lg i_t) \\ i_t' = \exp(\lg i_t - m_t) \\ f_t' = \exp(\lg f_t + m_{t-1} - m_t) \end{cases} \tag{9}$$

mLSTM则采用矩阵形式组织记忆状态，并结合协方差更新方法，能够有效捕获多变量之间的动态交互与协变关系，从而提升对复杂耦合特征的建模性能。xLSTM引入的指数型门控机制通过对历史状态信息进行非线性放大或抑制，使模型能够在长时间序列中更有效地保留早期注采扰动所引起的累积效应，从而有助于刻画储气库系统中普遍存在的注采扰动与微震响应之间的时间滞后现象。其矩阵内存结构突破了传统标量记忆的限制，通过矩阵形式对多源输入特征进行联合存储与更新，从而能够显式建模井口压力、注采量及其变化速率之间的交互关系。这使模型在工况调整或注采强度突变阶段，具备更强的能力捕捉压力波动突变及其引发的非线性微震响应模式。

整体上，xLSTM以模块化方式将sLSTM与mLSTM组合为基本构建块，并借助残差连接堆叠为深层网络，形成一种具备较强时序建模能力的深度神经网络架构。

2.2　Informer模型

Informer模型是针对长序列时间序列预测（LSTF）提出的创新模型，其通过对Transformer架构的改进，通过ProbSparse自注意力机制、自注意力蒸馏机制和生成式解码器三大核心技术，从计算效率、特征提取和预测模型三方面实现突破。

针对传统自注意力机制$O(L^2)$的计算复杂度问题，ProbSparse自注意力机制利用权重的长尾分布特性，通过Query稀疏性度量筛选出Top-u个贡献显著的活跃Query进行计算，将计算复杂度降至$O(L\lg L)$，在保留关键依赖信息的同时大幅降低计算负担，其计算公式为：

$$M(\boldsymbol{Q},\boldsymbol{K}) = \ln \sum_{j=1}^{L_k} \frac{q_i \boldsymbol{K}_j^T}{\sqrt{d}} - \frac{1}{L_k} \sum_{j=1}^{L_k} \frac{q_i \boldsymbol{K}_j^T}{\sqrt{d}} \tag{10}$$

$$Attention(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \text{Soft max}\left(\frac{\bar{\boldsymbol{Q}}\boldsymbol{K}^T}{\sqrt{d}}\right) \tag{11}$$

其中：L_k为矩阵$\boldsymbol{K}$的长度；q_i为矩阵$\boldsymbol{Q}$的第i行。$\bar{\boldsymbol{Q}}$为公式（11）计算稀释度后的Top-u个查询结果组成的向量矩阵。

自注意力蒸馏机制通过1D卷积层与最大池化操作，对编码器输出层进行层次化蒸馏，使序列长度逐轮减半，既压缩了冗余信息，又强化了关键特征表达，从j层到$j+1$层的蒸馏操作过程公式如下：

$$X_{j+1}^t = \text{MaxPool}(\text{ELU}(\text{Conv1d}(Attention(X_j^t)))) \tag{12}$$

其中：X_j^t为时间步t时第j层编码器的输出，Conv1d表示时间序列上的一维卷积操作，ELU为激活函数，最后进行MaxPool步长为2的最大池化操作，通过Conv1d卷积层和MaxPool池化层降低注意力的时间复杂度，自注意力蒸馏机制结构如图2所示。

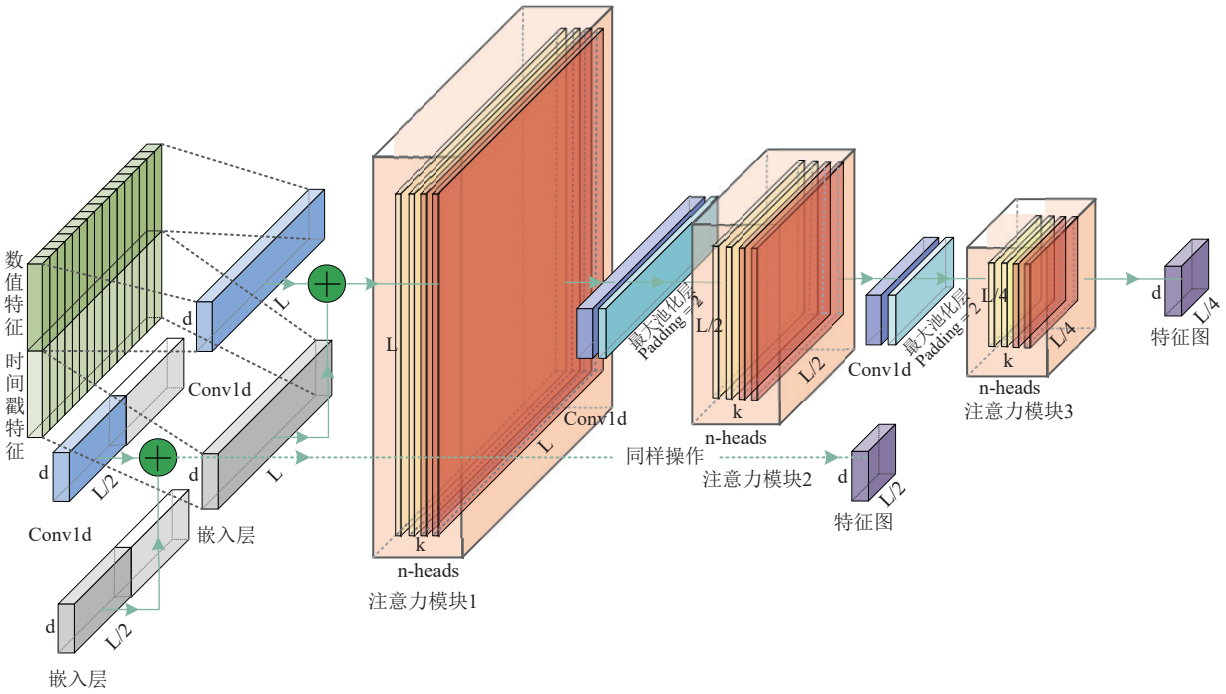


图2 编码器自注意力蒸馏机制

Fig. 2 Encoder self-attention distillation mechanism

生成式解码器摒弃传统 Transformer 模型的 step-by-step 逐点式预测模型，采用带掩码的多注意力机制避免信息泄露，能够一次性生成所有未来时间步的预测结果：

$$X_{de} = \mathrm{Concat}(X_{token}, X_0) \tag{13}$$

$$\bar{Y} = \mathrm{FCN}(\mathrm{Decoder}(X_{de})) \tag{14}$$

其中：X_{token} 为历史序列数据，X_0 为待预测值填充标记。全连接层（FCN）将解码器的输出映射到预测所需的维度，Informer 模型框架图如图 3 所示。

2.3 xLSTM-Informer 网络预测框架

针对注采参数数据的时变性与非平稳特征，以及传统预测方法难以有效捕捉二者长序列依赖关系的问题，本文采用基于 xLSTM 与 Informer 网络并行的微震时序数据预测方法（图 4）。该方法挖掘注采参数与微震的内在关联，实现微震时序数据的精准预测。

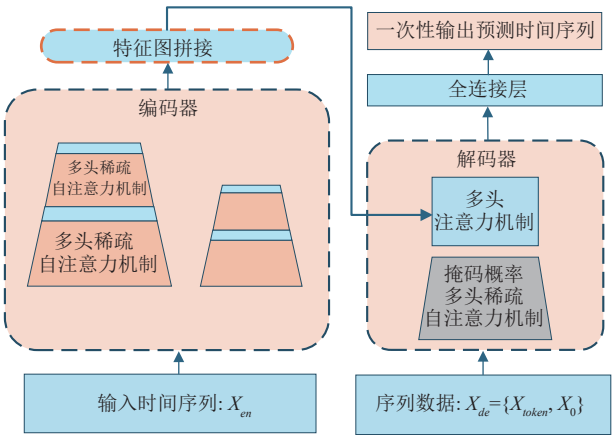


图3 Informer 模型框架图

Fig. 3 Framework of the Informer model

首先对注采参数与微震事件相关时序数据进行预处理，消除量纲差异与数据噪声。其次模型先通过 xLSTM 对预处理后的注采参数数据与微震时序数据进行初步编码，借助其改进的门控机制强化长程信息记忆能力，减少早期关键特征的丢失。

xLSTM 与 Informer 采用并行架构对微震时序数据预测，xLSTM 独立建模注采参数与微震事件的时序特征，输出针对性的特征序列；Informer 则依托 ProbSparse 自注意力机制高效捕捉注采参数与微震事件间的跨时间步全局依赖，同时结合自注意力蒸馏机制压缩冗余信息，进一步强化关键时序模式，其编码器输出经残差连接与层归一化处理，既缓解了深度网络的梯度消失问题，又保留了注采参数-微震时序数据耦合的核心特征。

为充分融合两路特征信息，采用基于门控加权的特征融合策略，而非简单拼接或固定权重叠加。首先对 xLSTM 分支与 Informer 分支输出的特征分别进行线性映射，使其投影到相同的特征维度空间，以保证后续融合与解码过程中的结构一致性与数值稳定性。该维度对齐操作避免了由于特

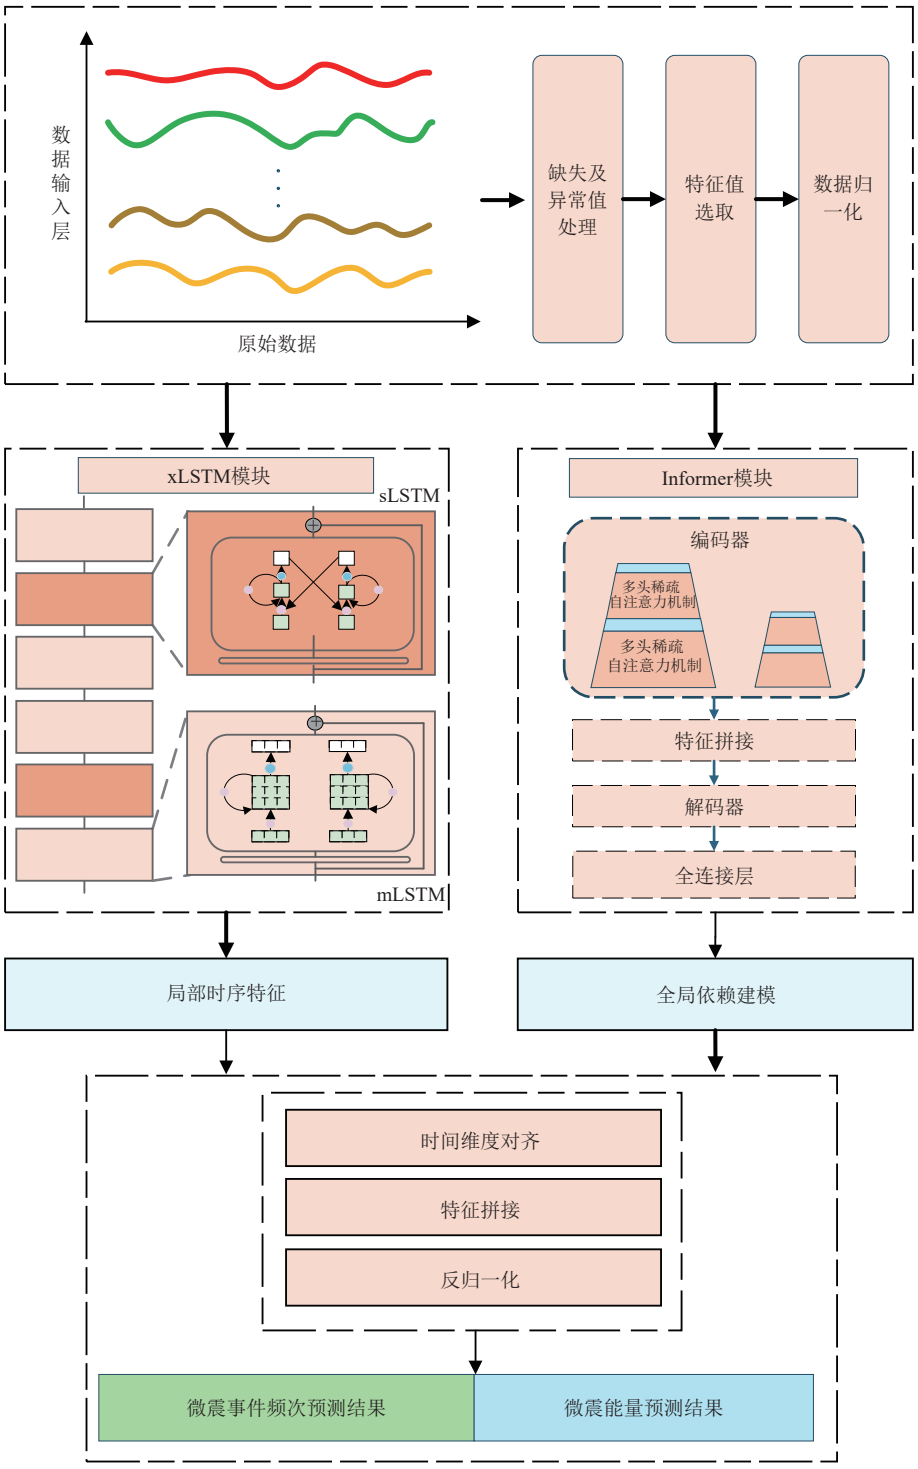


图 4　微震时序预测模型框架

Fig. 4　Framework of the Microseismic Time Series Prediction Model

征尺度不一致而引入的训练不稳定问题。

在完成维度对齐后将两路特征进行拼接，引入门控机制自适应学习不同时间步下两路特征的重要性权重。该门控机制本质上是一个轻量级的非线性映射模块，其输出为介于 0 与 1 之间的权重系数，用于动态调节 xLSTM 特征与 Informer 特征在融合结果中的占比。最终融合特征由两路特征按权重加权求和得到，使模型能够在不同时间段灵活地侧重局部动态模式或全局演化趋势，并通过反归一化操作将模型输出从标准化空间映射回原始物理量空间，恢复微震特征在实际工程意义上的数值尺度，从而获得最终的预测结果。

本文系统分析了xLSTM与Informer并行融合机制在时序建模中的优势，与传统序列式融合展开对比。并行融合以“同步计算、独立建模、协同整合”为核心，打破模块间串行依赖，其时间复杂度经Informer稀疏注意力与xLSTM并行化记忆模块优化后趋近于$O(N)$，优于序列式融合的累积性高复杂度，且能充分适配并行硬件架构，该机制通过缩短信息传递路径实现误差局部化，有效规避了序列式融合的信息衰减与误差累积问题。

3 实验结果及可视化分析

3.1 性能评价指标

为了评估模型的性能，本文采用了以下评估指标：MAE（mean absolute error）、MSE（mean square error）、MAPE（mean absolute percentage error）其计算公式如下：

$$\mathrm{MAE}=\frac{1}{n}\sum_{i=1}^{n}\left|y_i-\hat{y}_i\right| \tag{15}$$

$$\mathrm{MSE}=\frac{1}{n}\sum_{i=1}^{n}(y_i-\hat{y}_i)^2 \tag{16}$$

$$\mathrm{MAPE}=\frac{1}{n}\sum_{i=1}^{n}\frac{\left|y_i-\hat{y}_i\right|}{y_i} \tag{17}$$

其中：n为待预测的数据个数，y_i为微震数据的真实值，$\hat{y}_i$为预测的微震数据值。

3.2 实验环境及模型超参数设置

所有实验在统一软硬件环境下完成。硬件环境为Intel Core i9-14900处理器、NVIDIA GeForce RTX 5070显卡（8 GB显存）、32 GB内存，操作系统为Windows 11。软件环境包括Python 3.12.7、PyTorch 2.9.0等。

本实验将预处理后的时序数据集按时间先后顺序划分为训练集、验证集和测试集，划分比例为8∶1∶1。其中，训练集用于模型参数学习，验证集用于超参数调优及防止过拟合，测试集用于评估模型在未知数据上的泛化性能。所有输入参数均经过归一化处理，以消除量纲差异对模型训练的影响。

表2所列参数是在验证集上结合网格搜索与经验调优方式确定，在保证模型性能的同时兼顾计算效率与工程可行性。最终采用的超参数配置在多个重复实验中表现出较好的稳定性，因此被选为本文的默认设置用于后续实验与对比分析。

模型训练最大迭代次数设定为200次，并引入早停机制：若验证集损失在连续20个Epoch内未显著下降，则提前停止训练并保存最优模型权重。

表2 模型关键超参数及设置

Table 2 Key hyperparameters and configurations of the models

超参数类型	xLSTM网络	Informer网络
Learning rate	3e-4	1e-4
Batch size	64	64
Look-back Window	336	336
Dropout	0.1	0.2
Hidden dim	128	/
N_heads	/	8
Optimizer	AdamW	AdamW

3.3 微震事件预测实验结果分析

为验证所提出的xLSTM-Informer模型在实际储层监测中的应用潜力，本节将结合注采全周期内微震事件的统计规律，重点聚焦于三个高敏感且对储层稳定性具有挑战性的工况场景，深入分析其预测性能，并与单一模型进行对比验证。

注气末期（图5）：该阶段储层压力接近饱和，应力集中显著，易导致微震事件频发，活动强度和波动性增大。在事件频次高波动区域，xLSTM-Informer预测值与真实值的贴合度最高。它能够有效地捕捉到频次上的尖峰和低谷，展现出极佳的瞬时预测能力。相比之下，xLSTM预测值在高频波动区域表现出一定的滞后性，未能完全捕获尖锐的峰值。Informer预测值虽然总体趋势相似，但在局部波动上，其预测误差相对较大，鲁棒性稍显不足。

采气初期（图6）：采气初期压力迅速下降，导致应力卸载和重新分布，微震活动具有明显的过渡性和非线性特征。在事件频次从高位快速下降的区域，xLSTM-Informer表现出更快的响应速度，预测曲线下降斜率更接近真实值，有效地避免了明显的滞后误差。

提升注气参数阶段（图7）：短期内生产参数的剧烈提升会对储层应力场和孔隙压力场造成快速扰动，微震事件频次可能迅速攀升至异常高值。在事件频次最高峰附近，xLSTM-Informer的预测值最接近真实值，成功捕获了速率提升导致的异常高频微震事件活动。

综合三类工期的量性指标对比结果（表3），xLSTM-Informer模型在MAE、MSE与MAPE三类指标上均实现40%～70%的误差降低，证实其能够同时捕捉短期局部动态、长期依赖结构与多变

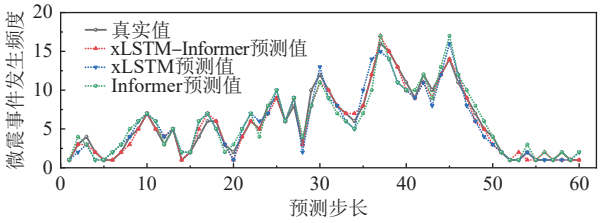


图5　注气末期

Fig. 5　Final stage of gas injection

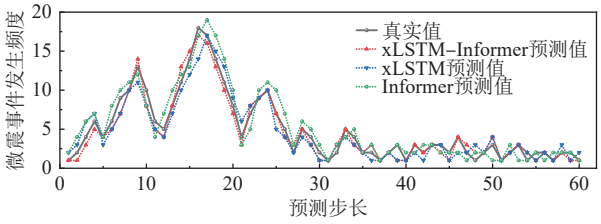


图6　采气初期

Fig. 6　Preliminary stage of gas extraction

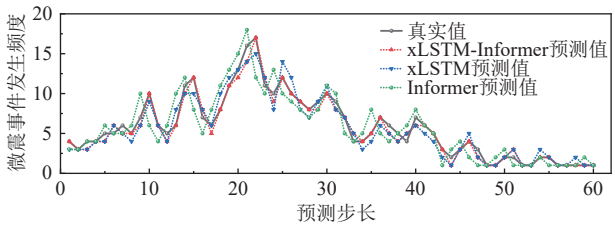


图7　提升注气参数

Fig. 7　Improving injection-production parameters

表3　不同工期预测与单一模型实验结果对比

Table 3　Comparison of different construction duration predictions with single-model experimental results

工期	预测模型	MAE	MSE	MAPE(%)
注气末期	xLSTM	0.817	1.151	20.21
	Informer	0.802	1.033	18.61
	xLSTM-Informer	0.383	0.417	10.45
采气初期	xLSTM	1.083	1.851	19.19
	Informer	0.916	1.483	15.24
	xLSTM-Informer	0.633	0.766	8.38
提升注气参数	xLSTM	1.316	2.117	20.66
	Informer	0.833	1.124	15.86
	xLSTM-Informer	0.413	0.433	7.53

量交互特性，从而实现对非平稳微震时序数据预测的任务。整体而言，融合模型具备更好的稳定性、泛化性和对复杂注采扰动的适应能力。

为验证模型性能差异的统计显著性，本文对不同模型在测试集上的逐样本预测误差采用配对t检验进行显著性分析，显著性水平设为0.05。

表4给出了不同模型预测误差差异的显著性检验结果（Hybrid为xLSTM-Informer模型）。可以看出，在不同工期与不同评价指标下，xLSTM-Informer相较于xLSTM与Informer的性能提升均达到统计显著水平（$p<0.05$），模型具有统计可靠性。

表4　显著性检验结果

Table 4　Results of Significance Tests

工期	对比模型对	t统计量	p值
注气末期	Hybrid vs xlstm	7.842	< 0.001
	Hybrid vs Informer	6.515	0.0012
采气初期	Hybrid vs xlstm	8.231	< 0.001
	Hybrid vs Informer	5.974	0.0028
提升注	Hybrid vs xlstm	9.105	< 0.001
采参数	Hybrid vs Informer	7.228	< 0.001

3.4　微震能量预测实验结果分析

根据对周期内微震能量的统计（图8），注采全周期内微震能量变化规律，储层微震活动呈现出明显的特征。在统计时间内的平稳期，能量多维持在较低水平，能量大小约维持在最高2×10^5 J，但在某些时点会出现瞬时峰值，最高可达约8.5×10^5 J。特别是在储层稳定性具有挑战性的提升注气参数阶段、注气末期和采气初期工况下，微震活动显著增强，表现为密集的、持续时间较长的高能量震群，其峰值能量频繁触及或超过8×10^5 J，表明这三个阶段储层应力状态变化剧烈，是微震能量释放最为集中的高敏感时期。

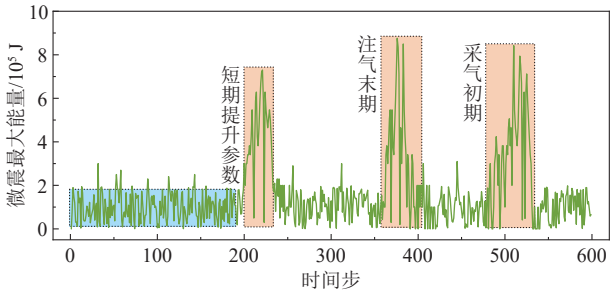


图8　生产周期内微震能量统计

Fig. 8　Statistics of microseismic energy during the production cycle

为验证所提模型在微震能量预测方面的性能，进行不同混合模型的对比实验，图9所示为xLSTM-Informer模型与其他三种复合模型（LSTM-Transformer、RNN-Informer、LSTM-Informer）在微震能量预测任务中的对比结果。

结果表明，各模型在不同程度上能够刻画微震时序的变化规律，但xLSTM-Informer模型的预测曲线与真实值的贴合度最高，尤其在捕捉数据序列中的峰值和谷值时，xLSTM-Informer模型展现出显

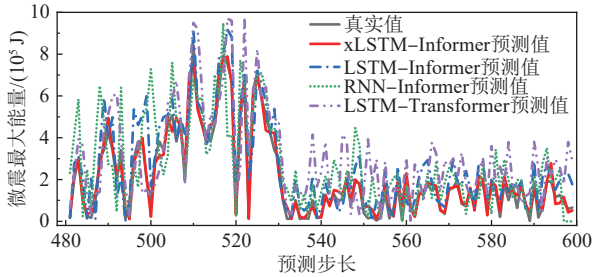


图 9 不同模型能量预测值

Fig. 9 Energy prediction values of different models

著的优越性，预测偏差明显小于其他复合模型。

利用 MAE、MSE、MAPE 对不同预测模型的微震能量预测结果进行量化对比，图 10 的量化对比结果显示，在微震能量预测任务中，xLSTM-Informer 模型在所有评估指标上均表现出最佳性能，其平均绝对误差、均方误差和平均绝对百分比误差分别达到最低值 0.413%、0.173% 和 7.473%。这表明 xLSTM-Informer 模型能够以最高的精度和稳定性预测微震能量，显著优于 LSTM-Transformer（MAE 1.131%，MSE 2.811%，MAPE 17.237%）、RNN-Informer（MAE 1.179%，MSE 2.392%，MAPE 14.341%）以及 LSTM-Informer（MAE 0.751%，MSE 0.971%，MAPE 12.942%）等模型，证实了该模型在储气库周期注采的过程中，能够有效捕捉长注采周期的全局依赖，以及短周期扰动的局部特征。

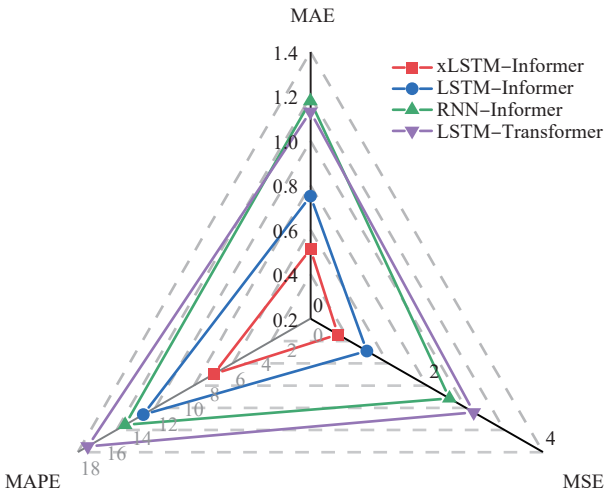


图 10 对比不同模型下微震能量（10^5 J）预测

Fig. 10 Comparison of microseismic energy（10^5 J） prediction under different models

4 模型工程应用与验证

为避免单一区域注采周期数据导致模型过拟合，进一步验证模型的泛化能力，选取同储气库不同地质区块。其储层埋深更大、有效孔隙度与渗透率相对较低，储层非均质性更为显著；同时，该区块在注采上表现为更大的注采强度波动范围。对其连续注采周期内的数据，开展延伸应用实验，确保模型满足实际运行的工程需求。

基于该区块监测两个注采周期内统计的数据，剔除注采设备异常导致的尖峰噪声数据 139 条，并用滑动区间插值法将数据填充，确保时序数据的连续性。对该区块不同采样间隔的数据进行统一时间间隔重采样，实现多源数据的时序对齐。

将归一化后的多源时序数据，依托 xLSTM-Informer 模型完成该区块内的微震时序数据预测，从微震事件发生频次和微震能量预测结果方面对模型进行评价（图 11）。在微震事件频度上，能有效预测事件频发的高峰期，以及捕捉该区块微震能量的异常波动特征；在能量维度，模型对高能量微震事件的预测偏差控制在 10% 以内，能够较精准地还原区块内微震能量的演化规律。

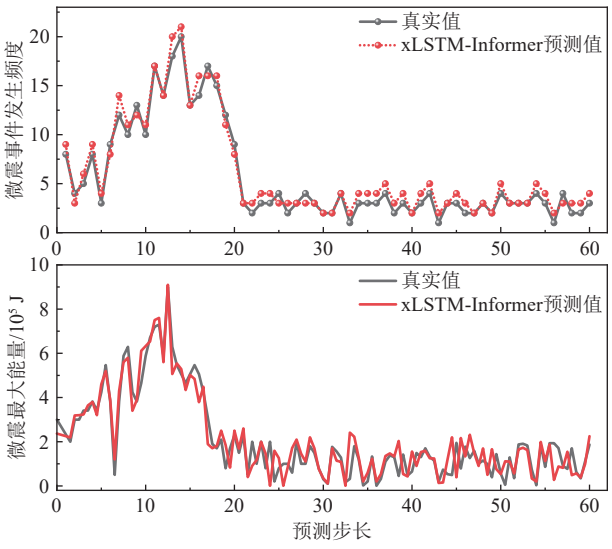


图 11 微震事件频率（次）与能量预测（10^5 J）结果对比

Fig. 11 Comparison between measured and predicted results of microseismic event frequency （times） and energy（10^5 J）

从拟合优度分析（图 12），微震事件频次与能量预测值和实测值的 R^2 分别为 0.92 和 0.89，均满足工程应用阈值。在不同注采周期及不同地质区块数据的对比实验中，所提出模型表现出较高的预测精度。这一方面得益于 xLSTM-Informer 混合结构在多尺度时序特征建模方面的优势，另一方面也依赖于储气库长期运行过程中积累的大规模、

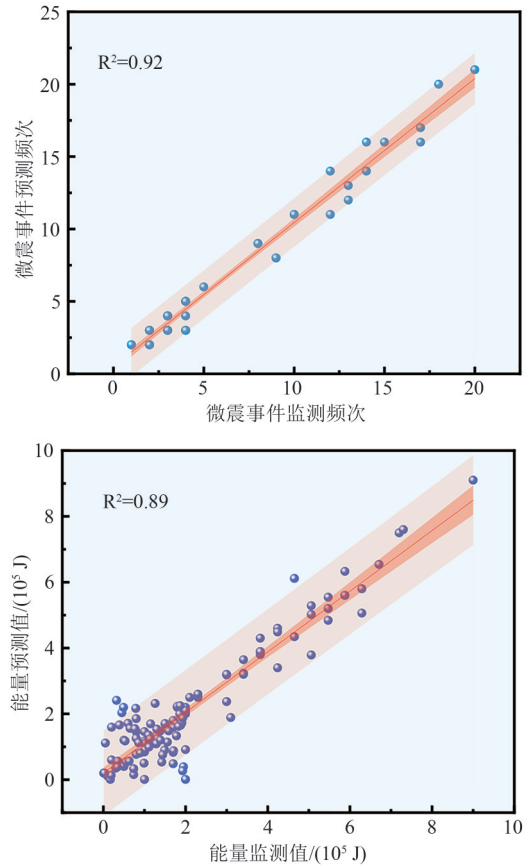


图 12　微震事件频次和能量拟合结果

Fig. 12　Fitting results of microseismic event energy and frequency

多周期注采与微震监测数据，为模型训练与参数学习提供了充分的数据支撑，从而有效提升了预测结果的稳定性与可靠性。

不同类型储气库（如含水层型储气库）在储层结构、应力演化路径及流体－岩石相互作用机制等方面存在显著差异，这可能导致微震响应特征的分布发生变化，从而影响模型的跨地质背景泛化能力。未来工作可引入多类型储气库数据，开展跨地质背景对比验证，并结合迁移学习或领域自适应方法，进一步评估和提升模型在不同地质条件下的适用性与泛化能力。

5　结　论

本文针对地下储气库注采过程中微震活动时序非平稳性强、多源注采参数耦合复杂以及长期依赖关系难以有效刻画的问题，提出了一种融合扩展型长短期记忆网络（xLSTM）与 Informer 结构的微震时序预测模型，并在储气库运行数据上开展了系统的模型应用与验证研究。

（1）构建了面向储气库注采扰动的多源时序特征体系。综合考虑注采量、井口压力、运行时间等工程参数与微震事件频次及能量演化特征，通过统一的时序对齐与特征组织方式，为微震时序预测提供了稳定可靠的数据基础。

（2）提出了 xLSTM-Informer 混合预测框架。利用 xLSTM 对微震时序中非线性动态特征与短-中期依赖关系的刻画能力，并引入 Informer 在长时序建模与全局依赖捕捉方面的优势，有效缓解了传统循环神经网络在长时间跨度预测中存在的梯度衰减和信息遗失问题。

（3）通过不同注采周期和不同地质区块数据的对比实验，验证了所提出模型在微震事件频次与能量预测任务中的有效性。结果表明，xLSTM-Informer 模型在预测精度和趋势一致性方面效果显著，能够较好地反映注采扰动条件下微震活动的演化规律。

在综上所述，融合 xLSTM 与 Informer 的微震时序预测模型能够有效提升储气库注采条件下微震活动的预测能力。未来研究中，可进一步引入地质构造、储层物性等物理约束信息，或结合图神经网络等方法，增强模型对空间相关性与复杂地质条件下微震响应机制的刻画能力。

参考文献：

[1] 王成虎，高桂云，贾晋，等. H 储气库注采诱发应力场及断层滑动趋势变化[J]. 天然气工业，2020，40(10)：76－85.

[2] 李波，金胜，叶高峰，等. 中亚造山带东段岩石圈电性结构特征及其构造涵义[J]. 现代地质，2023，37(1)：15－30.

[3] 廖伟，魏路路，罗海涛，等. 微地震监测在油气藏型储气库地质体完整性评价中的应用[J]. 石油地球物理勘探，2023，58(4)：913－921.

[4] 周远剑，高广亮，张浩，等. 微地震监测在地下储气库运营中的应用进展[J]. 地质力学学报，2025，31(4)：673－689.

[5] 关露凝，江国明. 福建仙游地区高精度地震震源定位及深部断裂特征[J]. 现代地质，2023，37(1)：40－47.

[6] BURTONSHAW E J，PALUSZNY A，MOHAMMADPOUR A，et al. Effects of mechanical properties of the underburden on induced seismicity along a basement fault during hydrogen storage in a depleted reservoir[J]. iScience，2024，27(8)：110553－110553.

[7] 程天赦，杨文静，滕超，等. 内蒙古西乌旗早泥盆世 I 型石英闪长岩的发现及其地质意义[J]. 现代地质，2023，37(6)：1624－1633.

[8] 曾帅，马志刚，赵聪，等. 青藏高原东部大渡河流域太平桥乡古滑坡群复活特征多源遥感识别[J]. 现代地质，2023，37(4)：994－1003.

[9] SHAPIRO A S, DINSKE C, LANGENBRUCH C, et al. Seismogenic index and magnitude probability of earthquakes induced during reservoir fluid stimulations[J]. The Leading Edge, 2010, 29(3): 304 - 309.

[10] 井岗,李龙,巴金红,等. 实时微地震监测金坛盐穴储气库稳定性[J]. 西南石油大学学报(自然科学版),2018, 40(5): 140 - 146.

[11] YU P, DEMPSEY D, RINALDI P A, et al. Association between injection and microseismicity in geothermal fields with multiple wells: data-driven modeling of Rotokawa, New Zealand, and Húsmúli, Iceland[J]. Journal of Geophysical Research. Solid Earth, 2023, 128(4). DOI: 10. 1029/2022JB025952.

[12] QIN Y, CHEN T, MA X, et al. Forecasting induced seismicity in Oklahoma using machine learning methods[J]. Scientific Reports, 2022, 12(1): 9319.

[13] 裴艳宇,杨小彬,传金平,等. 一维卷积神经网络特征提取下微震能级时序预测[J]. 工程科学学报,2021, 43(7): 1003 - 1009.

[14] 马佳骥,马春驰,曾俊,等. 基于LSTM多变种模型的岩爆微震参数预测研究[J]. 地下空间与工程学报,2022, 18(5): 1481-1494.

[15] BLOEMHEUVEL S, VAN DEN HOOGEN J, JOZINOVIĆ D, et al. Graph neural networks for multivariate time series regression with application to seismic data[J]. International Journal of Data Science and Analytics, 2023, 16(3): 317 - 332.

[16] 刘彩云,李梦迪,熊杰,等. 重力异常AlexNet深度神经网络反演[J]. 现代地质,2023,37(1):164 - 172.

[17] 薛瑞洁,熊杰,张月,等. 基于卷积神经网络的磁异常反演[J]. 现代地质,2023,37(1):173 - 183.

[18] 王永昌,刘彩云,熊杰,等. 基于生成对抗网络的半监督地震波阻抗反演[J]. 现代地质,2024,38(6):1585 - 1593.

[19] 张云骥,李倩,蔡益栋,等. 基于机器学习测井反演的宏观煤岩类型评价——以鄂尔多斯盆地佳县区块本溪组8号煤为例[J]. 现代地质,2025,39(5):1427 - 1436.

[20] ZHOU Y, LI C, ZHANG H, et al. Experimental study on microseismic monitoring of depleted reservoir-type underground gas storage facility in the Jidong Oilfield, North China[J]. Energies, 2025, 18(14): 3762.

[21] KIRÁLY J F, OBERHAUSER H. Kernels for Sequentially Ordered Data. [J]. Journal of Machine Learning Research, 2019, 20(31): 1-45.

[22] FATIMA W S S, RAHIMI A. A Review of Time-Series Forecasting Algorithms for Industrial Manufacturing Systems [J]. Machines, 2024, 12(6): 380.

[23] CHIEN H Y S, TUREK J S, BECKAGE N, et al. Slower is better: revisiting the forgetting mechanism in LSTM for Slower information decay [J]. arXiv preprint arXiv: 2105. 05944, 2021.

[24] BECK M, PÖPPEL K, SPANRING M, et al. xlstm: Extended long short-term memory[J]. Advances in Neural Information Processing Systems, 2024, 37: 107547 - 107603.

[25] CHEN X, QIU P, ZHU W, et al. Sequence complementor: Complementing transformers for time series forecasting with learnable sequences[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2025, 39(15): 15913 - 15921.

[26] ZHOU H, ZHANG S, PENG J, et al. Informer: Beyond efficient transformer for long sequence time-series forecasting[C]// Proceedings of the AAAI conference on artificial intelligence. 2021, 35(12): 11106 - 11115.

[27] CHEN Y, LI C, ZHAO X. TSGformer: A unified temporal-spatial graph transformer with adaptive cross-scale modeling for multivariate time series[J]. Systems, 2025, 13(8): 688.

[28] LAI G, CHANG W C, YANG Y, et al. Modeling long-and short-term temporal patterns with deep neural networks[C]//The 41st international ACM SIGIR conference on research & development in information retrieval. 2018: 95 - 104.