

基于注意力机制的TCN-LSTM的页岩气产量递减动态预测研究

吴欣雨*, 吴俊豪, 陈志愿, 刘鸿宇

重庆科技大学石油与天然气工程学院, 重庆

收稿日期: 2026年9月7日; 录用日期: 2026年10月11日; 发布日期: 2026年10月22日

摘要

针对传统递减曲线模型在复杂生产动态刻画方面的局限, 以及常规机器学习方法对样本规模依赖较强、中长期外推能力不足的问题, 本文构建了融合时间卷积网络(TCN)、长短时记忆网络(LSTM)与注意力机制的ATT-TCN-LSTM页岩气产量预测模型。首先对油嘴调整、气举等生产制度造成的异常产量进行校正, 并采用小样本微量扰动方式扩充数据集; 随后结合随机森林与主成分分析(PCA)识别并降维地质、工程主控参数; 在此基础上, 采用AdamW优化器和余弦退火学习率完成模型训练, 并利用MSE、MAE和MAPE评价预测效果。结果表明, ATT-TCN-LSTM能够较好刻画页岩气井全生产周期的产量变化, 在拟合精度和中长期预测能力方面均优于基础LSTM和TCN-LSTM模型。研究形成的主控因素分析与时序预测方法可为页岩气单井动态配产和压裂参数优化提供参考。

关键词

页岩气, 产能预测, 主控因素, TCN-LSTM, 注意力机制

Research on Dynamic Prediction of Shale Gas Production Decline Based on an Attention-Based TCN-LSTM

Xinyu Wu*, Junhao Wu, Zhiyuan Chen, Hongyu Liu

School of Petroleum Engineering, Chongqing University of Science and Technology, Chongqing

Received: September 7, 2026; accepted: October 11, 2026; published: October 22, 2026

Abstract

In response to the limitations of traditional decline curve models in characterizing complex

*通讯作者。

文章引用: 吴欣雨, 吴俊豪, 陈志愿, 刘鸿宇. 基于注意力机制的 TCN-LSTM 的页岩气产量递减动态预测研究[J]. 地球科学前沿, 2026, 16(10): 1461-1472. DOI: 10.12677/ag.2026.1610129

production dynamics, as well as the strong dependence of conventional machine learning methods on sample size and insufficient ability to extrapolate in the medium to long term, this paper constructs an ATT-TCN-LSTM shale gas production prediction model that integrates temporal convolutional networks (TCN), long short-term memory networks (LSTM), and attention mechanisms. Firstly, the abnormal production caused by production regimes such as nozzle adjustment and gas lift is corrected, and the dataset is expanded using small sample micro disturbance method; Subsequently, random forest and principal component analysis (PCA) are combined to identify and reduce the dimensionality of geological and engineering control parameters; On this basis, the model was trained using the AdamW optimizer and cosine annealing learning rate, and the prediction performance is evaluated using MSE, MAE, and MAPE. The results show that ATT-TCN-LSTM can better characterize the production variations of shale gas wells throughout the entire production cycle, and is superior to the basic LSTM and TCN-LSTM models in terms of fitting accuracy and medium-to long-term prediction ability. The main controlling factor analysis and time series prediction methods developed in this study can provide reference for the dynamic production allocation and fracturing parameter optimization of single shale gas wells.

Keywords

Shale Gas, Production Capacity Prediction, Dominant Factors, TCN-LSTM, Attention Mechanism

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

页岩气作为重要的非常规天然气资源,其高效开发对保障天然气供应和优化能源结构具有重要意义。页岩气井生产过程受储层条件、压裂改造及生产制度等多种因素共同影响,因此,准确识别产能主控因素并预测产量变化,是开发方案设计、经济评价、压裂参数优化和排采制度制定的重要基础[1]-[4]。

页岩气产能受地质与工程参数共同控制。若将全部参数直接用于预测,不仅会增加模型复杂度,还可能因变量间的相关性和信息冗余影响模型的泛化能力。因此,在开展产量预测前,有必要分析各参数对产能的影响程度,并对相关特征进行筛选和重组。主控因素分析一方面能够明确不同地质、工程参数与产能之间的关系,另一方面也可为后续预测模型提供更具代表性的输入特征。

近年来,机器学习方法逐渐应用于页岩气产量预测。相关研究主要集中在特征提取与筛选、不同机器学习模型的产量预测,以及机器学习结果与递减曲线分析(DCA)、数值模拟结果的对比等方面;同时,也有研究将时间序列特征与静态属性特征结合,以提高复杂生产动态条件下的预测精度[5]-[8]。

在此基础上,深度学习方法进一步拓展了页岩气产量预测的技术路径。传统循环神经网络(RNN)在处理长序列时容易出现梯度消失或梯度爆炸,LSTM通过门控结构增强了长期依赖信息的表达能力,但对局部变化和关键时段特征的识别仍存在不足[9]。TCN利用膨胀因果卷积扩大感受野,可有效提取多尺度时序特征,并具有良好的并行计算能力[10]-[12];注意力机制则能够根据输入序列自适应分配权重,使模型更加关注对预测结果影响较大的时间步[13]。因此,将TCN、LSTM与注意力机制结合,可同时利用多尺度特征提取、时序记忆和关键特征加权的优势。

Z井区深层页岩气储层非均质性较强,同一平台不同井之间产能差异明显,生产曲线总体呈现“初期峰值-快速递减-后期稳产”的阶段性特征[14]-[16]。地质参数(有效储层厚度、TOC、孔隙度、渗透率、裂缝夹角、裂缝强度、脆性指数等)和工程参数(用液强度、加砂强度等)均会影响产能表现[17]。针对

多参数之间存在相关性以及生产序列具有明显时序特征的问题, 本文首先采用随机森林对地质、工程参数进行重要性排序, 并结合相关性分析和 PCA 进行特征重组与降维; 随后构建 ATT-TCN-LSTM 模型, 将筛选后的静态特征与动态生产序列共同输入网络, 并与 LSTM、TCN-LSTM 模型进行对比, 以评价其在研究区页岩气产量预测中的适用性。

2. 数据收集与预处理

本研究收集了渝西地区 Z 井区五峰组 - 龙马溪组页岩储层的 17 口井的生产数据及地质参数, 包括孔隙度、渗透率、总有机碳含量(TOC)、有效储层厚度等; 工程参数包括加砂量、用液强度、压裂强度等。

为保证后续主控因素分析和产量预测所用数据的连续性与一致性, 首先对原始数据进行预处理, 主要包括缺失值处理、生产异常校正、数据标准化和小样本扰动扩充。其中, 数据预处理不仅关系到不同井之间样本尺度的一致性, 也直接影响后续特征重要性评价和时序模型训练的稳定性。页岩气生产数据通常同时包含储层自然递减规律与人为生产制度调整造成的波动, 若不加区分, 模型可能将制度变化误识别为储层响应特征。因此, 本文在尽量保持原始生产趋势的前提下开展数据清洗与校正, 使处理后的序列更能反映不同井的真实产能变化, 并为静态地质工程参数与动态生产数据的联合建模提供统一基础。

由于各井投产时间和生产周期不同, 部分日期存在产量缺失。对于生产序列中间的缺失值, 采用前一日有效产量进行填补; 对于生产初期的缺失值, 则采用后一日有效产量补齐, 以保证时间序列连续。考虑研究区有效井数及可用生产样本相对有限, 为减弱小样本条件下模型对局部样本的过度拟合, 并提高模型对生产数据轻微测量误差和日际波动的鲁棒性, 本文仅对训练集实施微量扰动数据扩充, 验证集和测试集均保持原始数据不变。具体处理流程为: 首先完成训练集、验证集和测试集划分, 并利用训练集统计量对输入特征进行标准化; 随后以标准化后的生产序列为基础, 在动态日产气输入项中叠加零均值高斯微扰:

$$x'_i = x_i + \varepsilon_i, \varepsilon_i \sim N(0, \sigma^2) \quad (1)$$

式中, x_i 为标准化后的原始日产气输入, x'_i 为扰动后样本, ε_i 为高斯随机扰动。本文取 $\sigma = 0.01$, 每个原始训练样本保留 1 份, 并额外生成 2 份扰动样本, 即训练集扩充倍数为 3。扰动过程中仅改变输入序列中的动态日产气特征, PCA 降维后的静态地质工程特征及对应预测标签保持不变, 以避免改变原始产量递减规律。数据扩充仅在训练集划分完成后进行, 从而避免增强样本进入验证集或测试集造成信息泄漏。

生产过程中油嘴尺寸调整、气举等生产制度变化会造成产量波动, 若直接使用原始数据, 可能干扰地质和工程因素与产能关系的识别。因此, 在剔除关井、开井等异常生产时段影响的基础上, 分析油嘴变化、气举措施与产量之间的关系, 并对生产数据进行校正。本文将各井日产气量统一校正至 8 mm 油嘴直径, 校正公式为:

$$Q_{\text{校正后}} = 8/D * Q_{\text{校正前}} + (8 - D)/D * |b| \quad (2)$$

式(2)基于油嘴直径与日产气量在相邻稳定生产阶段内近似满足局部线性关系的经验假设。考虑同一口井在较短生产时间内储层供气能力变化相对缓慢, 可将日产气量 Q 与油嘴直径 D 的关系近似表示为

$$Q = kD + b \quad (3)$$

式中, k 为油嘴变化引起的产量响应系数, b 为油嘴直径 - 日产气量线性拟合的截距。对于某一实际生产点(D, Q), 由式(3)可得

$$k = \frac{Q - b}{D} \quad (4)$$

当日产气量统一折算至 8 mm 油嘴条件时, 有

$$Q_8 = 8k + b \quad (5)$$

将式(4)代入式(5), 得到

$$Q_8 = \frac{8}{D}Q + \frac{D-8}{D}b \quad (6)$$

即为本文采用的油嘴统一校正关系。当拟合截距 $b < 0$ 时, 式(5)可进一步表示为

$$Q_8 = \frac{8}{D}Q + \frac{8-D}{D}|b|$$

与本文原采用的式(1)一致。参数 b 并非人为设定, 而是利用稳定生产阶段的油嘴直径 - 日产气量样本进行最小二乘线性回归获得。对于 n 组样本 (D_i, Q_i) , 拟合参数计算为

$$k = \frac{\sum_{i=1}^n (D_i - \bar{D})(Q_i - \bar{Q})}{\sum_{i=1}^n (D_i - \bar{D})^2}$$

$$b = \bar{Q} - k\bar{D}$$

其中, $\bar{D}$ 和 $\bar{Q}$ 分别为油嘴直径与日产气量的样本均值。

3. 主控因素分析

页岩气井产量受多种地质与工程因素共同影响, 不同参数的贡献程度及参数之间的相关性均可能影响预测模型的输入质量。为此, 本文首先利用随机森林(RF)对地质工程特征进行重要性排序, 识别对产能贡献较大的参数; 随后通过相关系数矩阵分析参数间的线性相关性, 并采用主成分分析(PCA)对存在信息重叠的变量进行重组降维, 为后续产量预测提供静态特征输入。

随机森林通过集成多棵决策树完成预测, 特征重要性可根据特征参与节点分裂时带来的不纯度降低程度进行评价。本文采用基于平均不纯度减少的变量重要性指标, 其计算过程如下。

对于单个决策树节点, 不纯度用于描述样本的混杂程度, 其计算公式为:

$$\text{Gini}(T) = 1 - \sum_{k=1}^K p_k^2 \quad (7)$$

其中, T 表示一个节点(或数据集), p_k 是节点中第 k 个类别的概率, K 是类别的总数。

对于特征 X_j , 可统计其在树中参与节点分裂所带来的不纯度下降量, 并据此得到变量重要性评分(VIM):

$$\text{VIM}_{\text{Gini}}(X_j) = \sum_{t \in \text{nodes split on } X_j} (\text{Gini}_{\text{parent}}(t) - \text{Gini}_{\text{left child}}(t) - \text{Gini}_{\text{right child}}(t)) \quad (8)$$

其中, t 是以特征 X_j 作为分裂条件的树节点, $\text{Gini}_{\text{parent}}(t)$ 是父节点的基尼不纯度, $\text{Gini}_{\text{left child}}(t)$ 和 $\text{Gini}_{\text{right child}}(t)$ 分别是左子节点和右子节点的基尼不纯度。

进一步对森林中所有决策树的 VIM 进行平均, 得到特征 X_j 的总体重要性:

$$\text{Mean VIM}_{\text{Gini}}(X_j) = \frac{1}{N_{\text{trees}}} \sum_{i=1}^{N_{\text{trees}}} \text{VIM}_{\text{Gini},i}(X_j) \quad (9)$$

其中, N_{trees} 是随机森林中树的数量, $\text{VIM}_{\text{Gini},i}(X_j)$ 是第 i 棵树中特征 X_j 的 VIM 统计量。

随机森林重要性能够反映各参数对预测结果的相对贡献, 但重要性较低并不意味着该参数不含有效信息。与此同时, 地质和工程参数之间往往存在不同程度的相关性, 直接删除低重要性变量可能造成信息损失, 而将全部变量输入模型又可能引入冗余。因此, 在随机森林排序基础上进一步采用 PCA, 将相关变量线性组合为若干彼此正交的主成分, 在尽量保留原始信息的同时降低输入维度和共线性。随机森

林排序与 PCA 在本文中承担不同作用：前者用于识别各参数对产能的相对贡献，后者进一步考虑变量之间的协同变化和信息重叠，将多个相关原始指标转换为少量综合变量。二者联合使用能够避免单纯依据重要性阈值删除变量造成的信息损失，同时降低高维输入在小样本条件下带来的过拟合风险，使后续模型更加集中地学习具有代表性的综合特征。

对于包含 n 个样本、 p 个特征的数据，可表示为 $n \times p$ 维数据矩阵 X 。

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}$$

将数据 X 由 p 维降至 k 维时，PCA 主要包括以下步骤：① 对原始数据进行中心化或标准化处理；② 计算协方差矩阵；③ 求取协方差矩阵的特征值及对应特征向量；④ 按照特征值大小确定主成分，并将原始数据投影至选定的 k 维主成分空间。主成分个数依据累计方差贡献率确定。

4. 产能预测分析

4.1. 模型构建

在完成生产数据预处理和静态特征降维后，构建 ATT-TCN-LSTM 产量预测模型。模型利用 TCN 提取生产序列的多尺度时序特征，LSTM 进一步学习序列中的长期依赖关系，并通过注意力机制对不同时间步的信息进行加权，使网络更加关注对产量变化具有较大贡献的关键时段。为评价组合模型的有效性，本文设置 LSTM 和 TCN-LSTM 作为对照模型，在相同数据和训练条件下进行比较。

模型结构如图 1 所示。输入包括校正后的日产气序列(长度为 L_{in})和 PCA 降维后的静态特征。动态序列首先进入 TCN 层，通过多层膨胀因果卷积提取不同时间尺度的特征；TCN 输出随后输入 LSTM 层，以学习生产序列中的时序依赖关系。LSTM 各时间步的隐状态进入注意力层，经权重计算得到加权上下文向量；静态参数则通过独立的全连接分支映射为低维特征。最后，将动态上下文向量与静态特征向量拼接，经全连接层完成特征融合，并输出未来 L_{out} 个时间步的预测产量。




Figure 1. TCN-LSTM-ATT network structure

图 1. TCN-LSTM-ATT 网络结构

在完成生产数据预处理和静态特征降维后, 本文采用滑动时间窗口构建动态输入样本。动态生产序列首先输入 TCN 模块, 通过多层膨胀因果卷积提取不同时间尺度下的局部生产动态特征; 随后将 TCN 输出输入 LSTM 网络, 以进一步学习产量序列中的长期依赖关系; LSTM 各时间步的隐藏状态进入时间注意力模块, 经权重计算后获得加权时序上下文向量。PCA 获得的静态地质工程主成分则通过独立分支进行映射, 最终与动态时序特征进行融合, 并通过全连接层输出预测产量。

对 LSTM 在各时间步输出的隐藏状态 h_t , 注意力权重计算过程可表示为:

$$e_t = W_2 \tanh(W_1 h_t + b_1) + b_2 \quad (10)$$

$$\alpha_t = \frac{\exp(e_t)}{\sum_{j=1}^{L_{in}} \exp(e_j)} \quad (11)$$

$$c = \sum_{t=1}^{L_{in}} \alpha_t h_t \quad (12)$$

式中, e_t 为第 t 个时间步的注意力得分, α_t 为经 Softmax 归一化后的注意力权重, 满足 $\sum \alpha_t = 1$, c 为经注意力加权后的时序上下文向量。通过该过程, 模型能够根据不同生产阶段的动态变化, 自适应调整各历史时间步对当前预测结果的贡献程度。

4.2. 模型优化

模型训练过程中, 对输入窗口长度、LSTM 隐藏单元数、TCN 通道数、注意力模块及 Dropout 比率等超参数进行调整, 以兼顾预测精度和训练稳定性。数据集共包含 5512 个数据点。考虑各井生产周期存在差异, 数据集按照生产时序划分, 并在后续预测试验中设置训练集、验证集和测试集。各对比模型统一采用 AdamW 优化器, 初始学习率设为 0.001, 并使用余弦退火策略调整学习率; 同时采用早停策略, 根据验证集损失确定最优模型参数。在训练过程中, AdamW、余弦退火学习率和早停策略共同用于提高参数优化的稳定性。AdamW 通过权重衰减抑制参数过度增长, 余弦退火使模型在训练前期保持较快搜索速度、后期以较小步长逼近较优参数区域; 早停则根据验证集损失及时终止无效迭代。对于本文相对有限的数据规模, 上述设置有助于降低过拟合风险, 并保证不同模型在相近训练条件下进行公平比较。

4.3. 模型评估

采用平均绝对误差(MAE)、均方根误差(RMSE)和平均绝对百分比误差(MAPE)评价模型预测性能。三项指标分别反映预测误差的平均绝对水平、较大误差的敏感程度以及相对误差水平。

MAE 计算公式为

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

RMSE 可表示为

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

MAPE 可表示为

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (15)$$

式中, 真实值为实际产量, 预测值为模型输出产量, 样本数量为 n 。MAE、RMSE 和 MAPE 越小, 说明模型预测结果与实际值越接近。

最终模型采用前 5 天历史日产气量作为动态输入窗口，LSTM 设置 2 层、隐藏单元数 64；TCN 通道数 64、卷积核大小 3、膨胀率依次为 1、2 和 4；Dropout 取 0.2。优化器采用 AdamW，初始学习率为 0.001，并结合余弦退火策略调整学习率(见表 1)。18 口井均按照各自生产时间顺序划分训练集、验证集和测试集，比例约为 70%:15%:15%，对应 4347、956 和 963 个样本。标准化参数仅由训练数据确定，验证集用于模型选择和早停，测试集仅用于最终评价，从而避免测试信息泄漏。

训练过程中最大迭代轮数设置为 800，并采用早停策略控制过拟合；当验证集损失连续 40 轮未获得改善时终止训练并恢复验证集表现最优的模型参数。上述设置与前述网络结构共同构成统一的 ATT-TCN-LSTM 训练方案。

Table 1. ATT-TCN-LSTM model architecture
表 1. ATT-TCN-LSTM 模型架构

参数	值
输入窗口大小(时间步长)	5
LSTM 层数	2
LSTM 隐藏层大小	64
TCN 通道数	64
TCN 卷积核大小	3
TCN 膨胀率	1, 2, 4
注意力头数	1 (单头注意力)
Dropout 比率	0.2
最终输出大小	1
激活函数	ReLU
优化器	AdamW
学习率	0.001
学习率调度	CosineAnnealingLR
训练轮数	800 (早停耐心 40)

5. 结果

5.1. 主控因素分析结果

随机森林特征重要性排序结果见图 2。不同地质工程参数对产能的贡献程度存在明显差异，其中含气量的重要性占比最高，为 18.24%；吸附气、加砂强度和游离气分别为 12.20%、11.43%和 9.30%。结果表明，储层含气性和压裂改造强度是影响研究区页岩气产能的重要因素。脆性指数、TOC、总液量和压裂液量等参数也具有一定贡献，因此不宜仅依据重要性排序直接删除贡献较低的变量。

相关系数矩阵(图 3)显示，不同地质与工程参数之间存在不同程度的线性相关性。加砂量、压裂液量、加砂强度和总液量等工程参数之间相关程度较高；含气量与吸附气、游离气及 TOC 等储层参数之间也存在一定相关性。说明原始特征中存在信息重叠，若全部直接输入预测模型，可能增加模型复杂度并影响小样本条件下的泛化能力。因此，在随机森林排序和相关性分析的基础上，进一步采用 PCA 对原始特征进行重组降维。




Figure 2. Feature importance ranking
图 2. 特征重要性排序




Figure 3. Correlation matrix
图 3. 相关系数矩阵




Figure 4. PCA principal component variance contribution rate and cumulative contribution rate
图 4. PCA 主成分方差贡献率及累计贡献率

PCA 结果见图 4。PC1、PC2、PC3 和 PC4 的方差贡献率分别为 45.10%、17.96%、13.30%和 10.64%，前 4 个主成分的累计方差贡献率为 86.99%，超过本文设定的 85%信息保留阈值。因此，选取 PC1-PC4 作为后续预测模型的静态特征输入，将原始 14 维地质工程参数压缩为 4 维相互正交的综合变量。若采用 90%的累计贡献率标准，则需保留前 5 个主成分，累计贡献率为 92.25%。考虑样本规模和模型输入维度，本文最终保留前 4 个主成分。




Figure 5. The loading matrix of the first four principal components
图 5. 前 4 个主成分载荷矩阵

主成分载荷矩阵见图 5。PC1 在加砂量、总液量和压裂液量上的载荷较高，主要表征压裂施工规模；PC2 主要受可压裂段长、用液强度和脆性指数影响，反映储层可压裂性与施工强度的综合特征；PC3 主要包含用液强度、孔隙度和游离气等信息；PC4 则主要与脆性指数、TOC 和可压裂段长有关。进一步计算主成分与产能的 Pearson 相关系数，PC1 与产能的相关系数为 0.820，呈较强正相关。最终将 PC1-PC4 与校正、标准化后的动态生产序列共同作为 ATT-TCN-LSTM 的输入，以减少冗余信息对网络训练的影响。

5.2. 产能预测结果

将预处理后的生产数据按 7:1.5:1.5 划分为训练集、验证集和测试集，并采用早停策略保存验证集损失最低时的模型参数，随后开展滚动预测。为保证模型对比的一致性，LSTM、TCN-LSTM 和 ATT-TCN-LSTM 采用相同的输入特征、时间窗口、训练轮数、优化器和学习率调度方式。

不同模型的训练损失变化如图 6 所示。三类模型在训练初期损失均快速下降，随后逐渐趋于稳定。基础 LSTM 的损失整体较高，达到稳定状态所需轮次较多；TCN-LSTM 引入时域卷积后，收敛速度有所提高，稳定损失低于 LSTM。ATT-TCN-LSTM 下降速度较快，并在约 40 轮时达到较低且稳定的损失水平，随后触发早停。三类模型的损失曲线均未出现持续反弹或明显振荡，表明训练过程总体稳定。由图 7 及后续预测结果可见，各模型均能反映产量总体变化趋势，其中 ATT-TCN-LSTM 与实测曲线吻合程度较高，对产量峰值和递减拐点的跟踪效果更好。

结合 MAE、RMSE 和 MAPE 评价结果(表 2)可见，ATT-TCN-LSTM 在测试井上的误差指标总体低于对照模型。LSTM 具有较强的时序记忆能力，但对短期产量波动的刻画相对有限；TCN-LSTM 利用卷积结构增强了多尺度时序特征提取能力，但未对不同生产时段的重要程度进行区分。ATT-TCN-LSTM 在此基础上引入注意力机制，对关键时间步进行自适应加权，从而兼顾长期递减趋势与局部产量变化。从两口测试井的评价结果看，组合模型的优势并非只体现在单一误差指标，而是在不同误差度量下呈现较一致的改善趋势，说明模型对总体递减趋势和局部波动的刻画具有一定稳定性。注意力机制能够在 LSTM 时序记忆基础上重新分配不同时间步的贡献权重，使模型在保留长期生产信息的同时增强对关键变化阶段的响应能力，这与图 7 中预测曲线和实测曲线的吻合特征相互印证。




Figure 6. Variation in training loss functions across different models

图 6. 不同模型训练损失函数变化




Figure 7. Prediction results of Well Z7
图 7. Z7 井预测结果

Table 2. Prediction effect
表 2. 预测效果

模型	Z7			Z4		
	MAE	RMSE	MAPE (%)	MAE	RMSE	MAPE (%)
ATT-TCN-LSTM	0.623	2.708	6.55	0.088	0.0181	2.09
TCN-LSTM	0.683	2.737	6.95	0.148	0.0405	3.41
LSTM	0.726	2.84	7.59	0.093	0.0209	2.23

6. 结论

本文以渝西地区 Z 井区五峰组 - 龙马溪组页岩气井为研究对象,在对原始生产数据进行缺失值处理、生产制度影响校正及标准化处理的基础上,综合考虑储层地质条件、压裂工程参数和动态生产数据,采用随机森林与主成分分析方法开展产能主控因素识别及特征降维,并构建 ATT-TCN-LSTM 产能预测模型。通过与 LSTM、TCN-LSTM 模型的预测结果进行对比,分析不同模型对页岩气生产动态的表征能力,主要得到以下认识:

- 1) 页岩气产能受储层含气性与压裂工程参数共同控制,不同参数对产能的影响程度存在明显差异。随机森林特征重要性排序结果表明,含气量的重要性占比最高,为 18.24%,吸附气、加砂强度和游离气的重要性占比分别为 12.20%、11.43%和 9.30%,是影响研究区页岩气产能的主要因素。脆性指数、TOC、总液量及压裂液量等参数同样具有一定贡献。总体来看,排名靠前的参数既包括含气量、吸附气和游离气等反映储层气体赋存条件的地质参数,也包括加砂强度等反映储层改造程度的工程参数,说明研究区页岩气产能并非受单一因素控制,而是储层品质与压裂改造共同作用的结果。
- 2) 地质与工程参数之间存在不同程度的相关性,采用 PCA 能够在保留主要信息的同时降低输入变量的维度和共线性。相关性分析表明,加砂量、压裂液量、加砂强度和总液量等工程参数之间具有较明显的相关关系,部分储层参数之间也存在一定的信息重叠。在此基础上采用 PCA 对原始参数进行降维,PC1、PC2、PC3 和 PC4 的方差贡献率分别为 45.10%、17.96%、13.30%和 10.64%,累计方差贡献率达到

86.99%，能够保留原始参数中的大部分信息。主成分载荷分析进一步表明，不同主成分分别表征压裂施工规模、储层可压裂性、储层物性及含气性等综合信息，其中 PC1 与产能的 Pearson 相关系数达到 0.820。最终采用前 4 个主成分替代原始高维参数作为静态特征输入，在减少冗余信息的同时保留了不同地质工程因素对产能的综合影响。

3) ATT-TCN-LSTM 能够较好地描述页岩气生产过程中长期递减趋势与局部产量波动。模型利用 TCN 提取不同时间尺度下的生产动态特征，并通过 LSTM 进一步学习生产序列中的时序依赖关系，在此基础上引入注意力机制，对不同生产阶段的时序信息进行自适应加权。损失函数变化表明，三种模型在训练初期均表现出较快的损失下降过程，随后逐渐趋于稳定，其中 ATT-TCN-LSTM 收敛速度较快，并在约 40 轮附近达到较低且稳定的损失水平。与基础 LSTM 和 TCN-LSTM 相比，该模型在产量峰值、递减拐点以及后期产量变化等位置与实测曲线具有更好的吻合程度，表明 TCN、LSTM 和注意力机制的组合能够改善模型对不同生产阶段特征的提取能力。

4) 模型对比结果进一步验证了 ATT-TCN-LSTM 在研究区页岩气产能预测中的适用性。从 MAE、RMSE 和 MAPE 等评价指标来看，ATT-TCN-LSTM 整体预测误差低于对照模型，与实测生产曲线的变化趋势具有较好的一致性。相较于单一 LSTM 主要依赖循环结构提取时序信息，TCN 的引入扩大了模型对长时间序列特征的感受范围，而注意力机制能够进一步突出对当前预测结果贡献较大的关键生产阶段，从而提高模型对复杂生产动态的表征能力。结果表明，将多尺度时序特征提取、长期依赖学习和自适应权重分配相结合，可用于研究区页岩气井产能动态预测。

参考文献

- [1] 宋建贵, 李红. 页岩气地质特征及产能影响因素分析[J]. 内蒙古煤炭经济, 2021(1): 213-214.
- [2] 黄华. 涪陵页岩气田水平井测试产量的地质控制因素探讨[J]. 资源环境与工程, 2023, 37(4): 405-441.
- [3] 朱良. 页岩气地质特征及其产能影响因素分析[J]. 化工设计通讯, 2016, 42(4): 256.
- [4] 张廷山, 陈雷, 梁兴, 等. 昭通国家级页岩气示范区五峰组——龙马溪组页岩气富集地质主控因素[J]. 天然气工业, 2023, 43(4): 93-102.
- [5] 李庆辉, 陈勉, Fred P-Wang, 等. 工程因素对页岩气产量的影响——以北美 Haynesville 页岩气藏为例[J]. 天然气工业, 2012, 32(4): 54-59+123.
- [6] 刘历历. 渝西区块深层页岩气体积压裂工艺参数优化[D]: [硕士学位论文]. 重庆: 重庆科技学院, 2023.
- [7] 洪亚飞, 王建忠, 孙强. 焦石坝页岩气储层产能影响因素分析[J]. 非常规油气, 2016, 3(5): 73-78.
- [8] 徐小明, 周明, 熊巍, 等. 页岩气产能影响因素分析[J]. 石油化工应用, 2013, 32(9): 10-12+17.
- [9] 万成祥. 海相页岩自封闭机理及控制因素——以四川盆地龙马溪组为例[D]: [博士学位论文]. 北京: 中国石油大学, 2023.
- [10] 王乾宇, 吴飞鹏, 孙秋分, 等. 页岩气产能预测方法的优选与评价[J]. 断块油气田, 2023, 30(4): 559-565+578.
- [11] 游妙妍. 页岩气藏产能影响因素综合研究[D]: [硕士学位论文]. 南昌: 南昌大学, 2024.
- [12] 李成威. 页岩气压裂井产能预测新方法[J]. 辽宁化工, 2021, 50(7): 1005-1008+1014.
- [13] 于希宁, 牛成林, 李建强. 基于决策树和专家系统的短期电力负荷预测系统[J]. 华北电力大学学报(自然科学版), 2005, 32(5): 57-61.
- [14] 王欣, 尹留志, 方兆本. 股票价格成份指数编制方法研究[J]. 预测, 2009, 28(3): 57-60+64.
- [15] Breiman, L. (2001) Random Forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/a:1010933404324>
- [16] 杜续, 冯景瑜, 吕少卿, 等. 基于随机森林回归分析的 PM2.5 浓度预测模型[J]. 电信科学, 2017, 33(7): 66-75.
- [17] 纪磊, 李菊花, 肖佳林. 随机森林算法在页岩气田多段压裂改造中的应用[J]. 大庆石油地质与开发, 2020, 39(6): 168-174.