

面向盲井预测的多尺度时序融合网络密度测井曲线重构方法

刘帅骞

西京学院电子信息学院, 陕西 西安

收稿日期: 2026年6月21日; 录用日期: 2026年7月14日; 发布日期: 2026年7月24日

摘要

密度测井曲线(DEN)是储层评价、孔隙度估算和岩性解释的重要基础资料,但在实际测井过程中,受井眼条件、仪器故障或测井项目不完整等因素影响, DEN曲线常出现缺失或异常。为提高盲井条件下DEN曲线重构精度,本文提出一种多尺度TCN-ECA-BiGRU-Transformer网络,并将该任务构建为基于滑动窗口的中心点回归问题。模型以常规测井曲线、中心深度信息和电阻率比特征等9个可获得输入变量为基础,预测滑动窗口中心位置的DEN值。该模型融合了多尺度时序卷积和高效通道注意力机制,用于提取局部深度方向特征,引入残差BiGRU与跳跃融合结构,用于增强双向上下文表征能力,并采用基于RoPE位置编码的Transformer,以建模长距离深度依赖关系。实验基于大庆油田12口井的7394个有效样本开展,采用按井划分策略,并以T252井作为独立盲井测试集。结果表明,所提出模型的RMSE、MAE和 R^2 分别为0.0296 g/cm³、0.0198 g/cm³和0.9290,优于多种机器学习和深度学习基线模型。进一步的留一井交叉验证结果显示,模型的平均RMSE、MAE和 R^2 分别为0.0316 g/cm³、0.0213 g/cm³和0.9167。上述结果表明,所提出的时序建模框架能够有效提升盲井DEN曲线重构精度,可为测井曲线缺失段补全和异常曲线修复提供支持。

关键词

密度测井曲线重构, 盲井预测, 测井时序卷积网络, 高效通道注意力, 双向门控循环单元, Transformer, 大庆油田

A Multi-Scale Temporal Fusion Network for Density Log Reconstruction in Blind-Well Prediction

Shuaiqian Liu

School of Electronic Information, Xijing University, Xi'an Shaanxi

文章引用: 刘帅骞. 面向盲井预测的多尺度时序融合网络密度测井曲线重构方法[J]. 传感器技术与应用, 2026, 14(4): 741-755. DOI: 10.12677/jsta.2026.144071

Abstract

Density logs (DEN) are essential for reservoir evaluation, porosity estimation, and lithology interpretation, but they are often incomplete or abnormal owing to borehole conditions, tool failure, or limited logging programs. To improve blind-well DEN reconstruction, this study proposes a multi-scale TCN-ECA-BiGRU-Transformer network and formulates the task as sliding-window center-point regression. Nine available inputs, including conventional well logs, center-depth information, and a resistivity_ratio feature, are used to predict the DEN value at the window center. The model integrates multi-scale temporal convolution and efficient channel attention for local depth-wise feature extraction, residual BiGRU and skip fusion for bidirectional contextual representation, and a RoPE-based Transformer for long-range dependency modeling. Experiments were conducted on 7394 valid samples from 12 wells in the Daqing Oilfield, using well-wise splitting and an independent blind test on well T252. The proposed model achieved RMSE, MAE, and R^2 values of 0.0296 g/cm³, 0.0198 g/cm³, and 0.9290, respectively, outperforming machine-learning and deep-learning baselines. Leave-one-well-out validation yielded average RMSE, MAE, and R^2 values of 0.0316 g/cm³, 0.0213 g/cm³, and 0.9167. These results indicate that the proposed temporal modeling framework improves blind-well DEN reconstruction and can support missing-interval completion and anomalous-log repair.

Keywords

Density Log Reconstruction, Blind-Well Prediction, Well Logging Temporal Convolutional Network, Efficient Channel Attention, BiGRU, Transformer, Daqing Oilfield

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

密度测井曲线(Density Log, DEN)是储层评价、孔隙度估算、岩性识别和地质解释中常用的基础测井曲线之一[1][2], 准确且连续的密度信息能够为地层性质表征、储层质量评价以及综合地下地质解释提供重要依据。随着测井资料智能处理与解释方法的发展, 测井数据质量与曲线完整性对后续储层参数计算和地质解释结果的影响日益受到关注[3]-[5]。然而, 在实际测井过程中, 受井眼条件、仪器故障、环境干扰以及测井项目不完整等因素影响, 密度测井曲线可能出现缺失、畸变或异常测量等问题, 这些问题会降低测井数据的完整性和可靠性, 并可能进一步影响后续储层解释与参数计算的准确性。因此, 利用其他可获取的测井响应重构缺失或异常的 DEN 曲线, 对于提高测井资料可用性、支撑智能化储层评价具有重要的实际意义。

现有的密度测井曲线重构方法主要包括经验模型、统计回归方法、传统机器学习方法和深度学习方法等[6]-[8]。传统机器学习模型, 如随机森林、支持向量回归和梯度提升模型等, 能够在一定程度上刻画多条测井曲线与 DEN 之间的非线性关系。然而, 这类方法通常将每个深度点视为相互独立的样本, 主要关注点对点的特征映射关系。由于测井曲线沿深度方向连续分布, 目标深度处的密度响应不仅与该深度点处的测井响应有关, 还受到邻近深度区间内曲线形态和地层变化特征的约束。已有基于 U-Net 和 GRU

等深度序列模型的测井曲线重构研究表明, 充分利用深度方向的邻域信息有助于提升曲线重构效果[9][10]。忽略这种沿深度方向的序列信息, 可能会限制模型的重构精度, 尤其是在薄互层、岩性过渡带以及曲线突变明显的井段中表现更为突出。

近年来, 序列深度学习模型已逐渐应用于测井曲线预测、重构及相关测井序列建模任务中。U-Net、GRU、LSTM 以及 CNN-LSTM 等模型能够从不同角度建模测井曲线的局部变化特征和序列上下文信息[9]-[12]。基于 Transformer-LSTM 融合模型的方法进一步通过自注意力机制增强了对长距离依赖关系的建模能力[13]。时间卷积网络则可以沿深度方向高效提取局部曲线变化模式[14]。此外, BiLSTM-Attention 等结构在测井岩性分类等序列建模任务中的应用也表明, 双向上下文建模与注意力机制对于提升测井序列特征表达能力具有一定价值[15]。然而, 仅依赖单一的序列建模机制, 往往难以同时刻画局部波动特征、双向上下文约束以及长距离深度依赖关系。基于 TCN 的模型虽然在提取局部波动特征方面具有优势, 但其全局依赖建模能力可能受到限制; 循环神经网络能够捕获上下文信息, 但在序列编码过程中, 局部峰谷等细节特征可能被弱化; Transformer 模型能够表征长距离关联关系, 但其性能在很大程度上依赖于局部特征和位置特征表示的质量。因此, 有效的 DEN 曲线重构模型应综合考虑局部多尺度曲线波动、双向上下文信息以及全局深度依赖关系。

针对上述问题, 本文提出了一种用于 DEN 曲线重构的多尺度时序深度学习模型。本文将重构任务构建为基于滑动窗口的中心点回归问题, 即以连续深度窗口内的多条可用测井曲线作为输入, 以窗口中心位置的 DEN 值作为预测目标。

2. 方法

2.1. 整体模型架构

针对密度测井曲线缺失或异常导致储层评价数据不完整的问题, 本文提出了一种用于 DEN 曲线重构的多尺度时序深度学习模型。考虑到测井曲线沿深度方向连续分布, 目标深度点处的密度响应不仅与该深度点处的多条测井曲线有关, 还与其上下邻近区间内的地层响应变化密切相关。具体而言, 以连续深度窗口内的多维测井响应作为输入, 以窗口中心位置的 DEN 值作为预测目标, 从而使模型能够利用目标深度上下两侧的上下文信息。

对于每个滑动窗口样本, 其输入可表示为:

$$X \in \mathbb{R}^{B \times L \times F} \quad (1)$$

其中, B 表示批次大小, L 表示窗口长度, F 表示输入特征数量。本文将窗口长度设置为 64, 并采用 9 个输入特征, 包括 CAL、GR、SP、LLD、LLS、AC、PEF、Depth_Mid 和 Resistivity_Ratio。其中, Depth_Mid 表示深度位置信息, Resistivity_Ratio 用于描述深、浅侧向电阻率之间的相对变化。

模型的整体架构如图 1 所示, 该框架主要由三个阶段组成: 滑动窗口测井序列构造、多尺度时序特征编码以及中心点 DEN 重构。首先, 利用滑动窗口从可用测井曲线中截取连续深度区间, 窗口中心位置对应待重构的目标深度, 而其周围的测井响应则为密度预测提供上下文约束。

在完成序列构造后, 输入特征首先通过线性投影层映射到统一的潜在特征空间。随后, 投影后的序列被输入至多尺度 TCN-ECA 模块, 该模块通过采用不同膨胀因子的时间卷积, 捕获局部曲线波动特征以及多尺度深度变化模式, ECA 机制进一步增强具有重要信息的通道响应, 并抑制相关性较弱的特征通道。在此基础上, 本文引入残差 BiGRU 模块, 用于建模沿深度方向的双向上下文依赖关系。其中, 前向 GRU 捕获由浅至深的测井响应变化对目标预测的影响, 后向 GRU 则捕获由深至浅的反向上下文信息。

为了在融合 BiGRU 所学习的上下文表征的同时保留 TCN-ECA 模块提取的局部特征, 本文采用跳跃

融合结构,融合后的特征进一步输入至基于 RoPE 的 Transformer 编码器,Transformer 编码器通过多头自注意力机制进一步建模滑动窗口内的全局深度依赖关系。

最后,提取 Transformer 输出序列中与窗口中心位置对应的隐藏表征,并将其输入至 MLP 回归头,以预测中心深度处的 DEN 值。随着滑动窗口沿深度方向逐步移动,一系列中心点预测结果被恢复至其对应的深度位置,形成最终重构的 DEN 曲线。

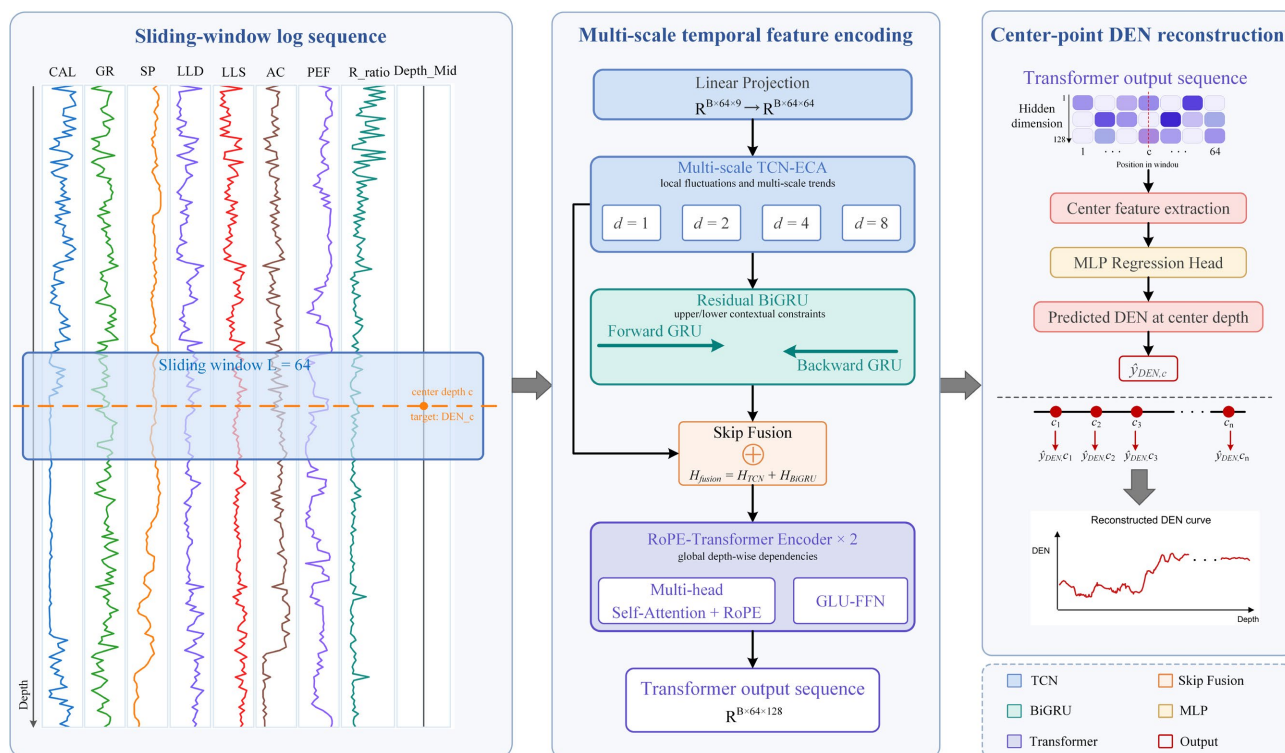


Figure 1. Overall architecture of the proposed model

图 1. 模型整体架构图

如图 1 所示,所提出模型采用“序列到中心点”的重构策略。滑动窗口输入为模型提供局部深度邻域信息,多尺度时序特征编码模块用于提取并融合局部、双向和全局序列表征,中心点重构模块则输出目标深度处的 DEN 值。随着滑动窗口沿深度方向移动,预测得到的中心点值被恢复至其对应的深度位置,从而获得重构后的 DEN 曲线。

2.2. 多尺度时序特征提取与序列建模

2.2.1. 多尺度 TCN-ECA 特征提取

测井曲线具有明显的深度序列特征,不同岩性组合、薄互层、层界面以及局部异常响应,在曲线上表现为不同尺度的波动特征。对于 DEN 曲线重构而言,模型不仅需要捕获相邻深度点之间的短程变化,还需要识别较大深度区间内的整体变化趋势。若仅采用固定尺度的卷积结构,模型的特征感知范围容易局限于单一邻域尺度,难以同时适应局部突变特征和渐变趋势特征。因此,本文首先构建多尺度 TCN-ECA 模块,用于提取不同深度尺度下的局部时序响应。

多尺度 TCN-ECA 模块的结构如图 2 所示。该模块以线性投影后的特征作为输入:

$$H_{proj} \in R^{B \times 64 \times 64} \quad (2)$$




Figure 2. Structure of the multi-scale TCN-ECA module

图 2. 多尺度 TCN-ECA 模块结构

随后, 输入特征依次经过四个 TCN-ECA 残差块。四个残差块的膨胀率分别设置为 1、2、4 和 8, 对应的输出通道数分别为 64、64、128 和 128。随着膨胀率逐层增大, 模型能够在较浅的网络深度下获得更大的感受野, 从而同时捕获相邻深度点之间的局部波动, 以及距离较远深度点之间的趋势关联 [12]。

对于第 i 个 TCN-ECA 残差块, 其输出可表示为:

$$H^{(i)} = \text{TCN-ECA}_{d_i} \left(H^{(i-1)} \right) \quad (3)$$

其中, d_i 表示第 i 个残差块的膨胀率。由于前两个 TCN-ECA 块的输出通道数为 64, 而后续融合要求不同尺度的特征具有统一的通道维度, 因此本文采用 1×1 卷积将前两个阶段的输出映射至 128 维, 后两个阶段的输出已为 128 维, 因此采用恒等映射进行处理。随后, 对四个层级的尺度特征进行平均融合, 并采用 LayerNorm 稳定特征分布, 得到最终的多尺度时序特征:

$$H_{tcn} = \text{LayerNorm} \left(\frac{1}{4} \sum_{i=1}^4 \phi_i \left(H^{(i)} \right) \right) \quad (4)$$

其中, ϕ_i 表示通道对齐映射, 当输出通道数为 64 时, ϕ_i 为 1×1 卷积映射, 当输出通道数已为 128 时,

ϕ_i 为恒等映射。最终输出为:

$$H_{tcn} \in \mathbb{R}^{B \times 64 \times 128} \quad (5)$$

在单个 TCN-ECA 残差块内部, 主分支由两层膨胀一维卷积组成, 且每层卷积后均依次连接 WeightNorm、GELU 激活函数和 Dropout。其中, 膨胀卷积能够扩大模型的感受野, WeightNorm 有助于稳定训练过程, GELU 则增强了模型的非线性表征能力。为缓解深层网络训练过程中的梯度衰减问题, 并保留输入特征中的原始信息, 每个 TCN-ECA 块均设置了残差分支。当输入通道数与输出通道数相同时, 残差分支采用恒等映射; 当二者通道数不一致时, 则采用 1×1 卷积进行维度匹配。

此外, 为提高模型对关键通道信息的利用能力, 本文在 TCN 残差块中引入 ECA 通道注意力机制。ECA 模块首先通过全局平均池化为每个通道生成全局描述符, 随后利用一维卷积建模相邻通道之间的局部交互关系, 并通过 Sigmoid 函数生成通道权重, 最终对输入特征进行逐通道重标定。

2.2.2. BiGRU-Transformer 序列建模与特征融合

经过多尺度 TCN-ECA 模块后, 模型已经获得了包含局部波动特征和多尺度趋势信息的时序表征。然而, 卷积结构主要侧重于局部邻域模式的提取, 对于目标点上下两侧的上下文关系以及更长距离的深度依赖关系, 仍需要进一步建模。由于本文采用中心点预测策略, 窗口中心位置的 DEN 值不仅受到其上部深度点测井响应的影响, 也受到其下部连续地层响应变化的约束。因此, 本文进一步引入残差 BiGRU 模块, 对测井序列进行双向上下文编码。

BiGRU 由前向 GRU 和后向 GRU 组成, 因此 BiGRU 的前向和后向隐藏状态表示为:

$$\bar{h}_t = \text{GRU}_f(h_t, \bar{h}_{t-1}) \quad (6)$$

$$\bar{h}_t = \text{GRU}_b(h_t, \bar{h}_{t+1}) \quad (7)$$

随后, 将两个方向的隐藏状态进行拼接, 得到双向表征:

$$h_t^{\text{bi}} = [\bar{h}_t; \bar{h}_t] \quad (8)$$

其中, 前向和后向隐藏状态分别表示第 t 个深度位置在两个方向上的隐状态, 双向表征项表示拼接后的特征表示。为保证 BiGRU 输出维度与后续模块保持一致, 本文通过残差映射和 LayerNorm 得到如下表征:

$$H_{\text{bigru}} \in \mathbb{R}^{B \times 64 \times 128} \quad (9)$$

随后, 模型将 H_{BiGRU} 与来自 TCN-ECA 模块的跳跃特征 H_{TCN} 进行融合, 形成同时包含局部卷积特征和双向上下文信息的序列表征:

$$H_{\text{fuse}} = \text{LayerNorm}(H_{\text{bigru}} + \psi(H_{\text{tcn}})) \quad (10)$$

其中, ψ 表示维度匹配映射。当二者维度一致时, 该映射可视为恒等变换, 该跳跃融合结构能够避免 BiGRU 在序列编码过程中对局部峰谷变化产生过度平滑, 使模型在捕获上下文依赖关系的同时, 保留 TCN 所提取的局部曲线细节。

在跳跃融合之后, 本文进一步采用 Transformer Encoder Block 对窗口内不同深度位置之间的全局依赖关系进行建模。与常规 Transformer 编码器相比, 本文在自注意力子层中引入 RoPE 位置编码, 使注意力计算能够显式感知序列中不同深度位置之间的相对关系。具体而言, 融合后的特征首先经过 LayerNorm 处理, 随后通过 Q 、 K 和 V 线性投影划分为四个注意力头。每个注意力头的维度为 32, 并对 Q 和 K 施加 RoPE 旋转位置编码, 多头自注意力计算可表示为:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (11)$$

其中, Q 、 K 和 V 分别表示查询矩阵、键矩阵和值矩阵, $d_k = 32$ 表示单个注意力头的维度。RoPE 作用于 Q 和 K , 用于增强模型对深度顺序和相对位置关系的表征能力。经过自注意力子层后, 输出结果进一步通过线性投影和 Dropout 处理, 并通过残差连接与输入相加。

随后, 模型进入前馈子层。本文采用 GLU-FFN 结构替代常规的两层前馈网络, 以增强非线性门控表征能力。该模块首先将 128 维特征映射至 512 维, 随后通过 GLU 门控机制得到 256 维有效表征, 最后再通过线性层将 256 维特征映射回 128 维。

前馈子层同样采用 LayerNorm、Dropout 和残差连接, 以保证深层训练过程的稳定性。经过 Transformer 编码后, 输出序列表征为:

$$Y \in \mathbb{R}^{B \times 64 \times 128} \quad (12)$$

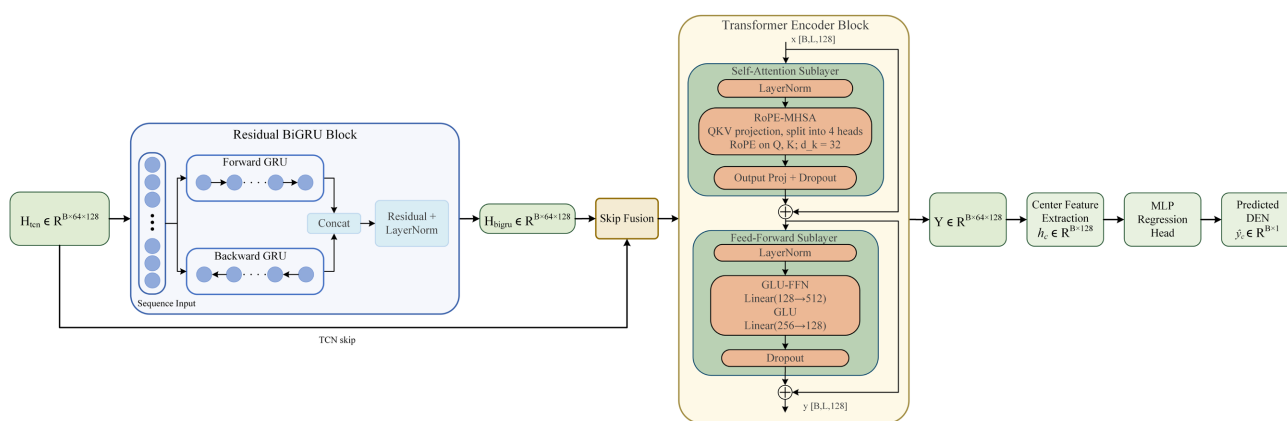


Figure 3. Structure of the BiGRU-Transformer module and center-point prediction head

图 3. BiGRU-Transformer 模块与中心点预测头的结构

BiGRU-Transformer 模块和中心点预测头如图 3 所示, 通过残差 BiGRU、跳跃融合以及 RoPE-Transformer 的联合建模, 模型能够在多尺度局部特征的基础上, 进一步捕获目标点邻域的上下文关系以及窗口内部的全局依赖关系。该结构不仅能够保留曲线局部峰值和谷值等细节特征, 还能够增强模型对跨区间连续变化趋势的建模能力, 从而为后续中心点 DEN 预测提供更加充分的序列特征表征。

2.3. 密度测井曲线重构输出与模型训练

经过多尺度 TCN-ECA、残差 BiGRU 和 Transformer 编码后, 模型获得了窗口内各深度位置对应的高维隐藏表征。由于本文将密度测井曲线重构定义为中心点回归任务, 因此输出阶段并不同时预测整个窗口内所有深度点的 DEN 值, 而是提取窗口中心位置的隐藏向量作为回归输入。设 Transformer 的输出为:

$$Y = [y_1, y_2, \dots, y_{64}] \quad (13)$$

其中, y_t 表示第 t 个深度位置的隐藏表征。窗口中心位置记为:

$$c = \left\lfloor \frac{L}{2} \right\rfloor \quad (14)$$

则中心点特征可表示为:

$$h_c = Y_{:,c,:} \in \mathbb{R}^{B \times 128} \quad (15)$$

随后, 将中心点特征输入至 MLP 回归头, 输出该窗口中心深度点处的 DEN 预测值:

$$\hat{y}_c = f_{\text{reg}}(h_c) \quad (16)$$

其中, f_{reg} 表示由全连接层、非线性激活函数和 Dropout 组成的回归预测头, $\hat{y}_c$ 表示中心点 DEN 预测值。随着滑动窗口沿深度方向依次移动, 每个窗口输出一个中心点预测值。将所有窗口的中心点预测结果按照其对应的深度位置进行汇总和还原, 即可得到完整的 DEN 重构曲线。

在模型训练过程中, 本文采用回归损失函数约束预测 DEN 值与实测 DEN 值之间的误差。为了提高模型对局部异常值和测井噪声的鲁棒性, 本文采用 Huber 损失作为主要优化目标。当误差较小时, Huber 损失具有平方损失平滑优化的特点, 当误差较大时, 其惩罚形式会转变为线性惩罚, 从而降低异常值对模型训练的影响。其定义如下:

$$\mathcal{L}_{\text{Huber}} = \begin{cases} \frac{1}{2}(y - \hat{y})^2 & |y - \hat{y}| \leq \delta \\ \delta|y - \hat{y}| - \frac{1}{2}\delta^2 & |y - \hat{y}| > \delta \end{cases} \quad (17)$$

其中, y 表示实测 DEN 值, $\hat{y}$ 表示模型预测值, δ 表示误差分段阈值。为进一步约束预测输出的幅值范围, 本文在 Huber 损失的基础上加入轻量化幅值惩罚项。整体损失函数表示为:

$$\mathcal{L} = \mathcal{L}_{\text{Huber}} + \lambda \mathcal{L}_p \quad (18)$$

$$\mathcal{L}_p = \frac{1}{N} \sum_{i=1}^N \max(|\hat{y}_i| - \tau, 0) \quad (19)$$

其中, λ 表示惩罚项权重, τ 表示幅值阈值, N 表示一个批次中的样本数量。该损失设计在保持连续曲线回归精度的同时, 能够提高模型对异常扰动和局部极端预测结果的鲁棒性。

模型训练采用 AdamW 优化器, 并结合 warmup 与余弦退火学习率调度策略, 以提高训练初期的稳定性和后期的收敛效果。训练过程中, 以验证集损失作为模型选择依据。当验证损失在连续若干轮内未出现明显改善时, 提前终止训练, 以降低模型过拟合风险。同时, 在训练阶段对输入序列施加轻量化数据增强, 包括高斯噪声扰动、随机通道遮蔽和尺度扰动, 用于模拟实际测井数据中可能存在的噪声、局部异常以及曲线幅值变化, 从而增强模型在盲井重构场景下的鲁棒性。

3. 数据与实验设计

3.1. 数据集、输入特征与预处理

本文采用大庆油田公开测井数据集开展密度曲线重构实验。该数据集包含 G39、G43、G94、G96、G921、G933、J392、J393、T251、T252、X73 和 X78 共 12 口井的测井记录, 原始样本共 7470 条, 覆盖不同深度段的多条常规测井曲线及对应岩性分段信息。密度曲线 DEN 是储层评价、孔隙度估算和岩性解释中的重要基础曲线, 但在实际测井过程中容易受到井眼环境、仪器状态及采集条件影响而出现缺失或异常。

原始测井曲线主要包括井径 CAL、自然伽马 GR、自然电位 SP、深侧向电阻率 LLD、浅侧向电阻率 LLS、声波时差 AC、光电吸收截面指数 PEF 和密度 DEN。为增强模型对深度方向变化趋势的感知能力, 本文进一步根据井段顶深和底深构造中心深度特征:

$$\text{Depth_Mid} = \frac{\text{TopDepth} + \text{BotDepth}}{2} \quad (20)$$

同时，为表征深、浅侧向电阻率之间的相对差异，构造电阻率比值特征：

$$\text{R_ratio} = \frac{\text{LLD}}{\text{LLS} + \varepsilon} \quad (21)$$

其中， ε 为防止分母为零而设置的极小常数。最终，模型输入特征包括 CAL、GR、SP、LLD、LLS、AC、PEF、Depth_Mid 和 R_ratio 共 9 个变量，输出目标为 DEN。

在数据预处理阶段，首先对关键输入曲线和目标曲线进行缺失值检查，删除无法参与监督训练的无效样本。随后，采用物理范围约束与四分位距法相结合的方式对异常值进行处理。物理范围约束主要用于剔除明显违背测井物理意义的记录，例如 DEN 超出常规岩石密度范围、GR 小于 0、AC 小于等于 0 或 CAL 小于等于 0 等；四分位距法则用于进一步识别统计分布中的相对异常点。经过清洗后，最终保留 7394 条有效样本。为消除不同测井曲线量纲差异对模型训练的影响，本文对输入特征进行标准化处理，标准化参数仅由训练集计算，并应用于验证集和测试集，以避免测试信息泄露，模型输出后再反标准化至原始 DEN 量纲，用于评价指标计算和曲线对比分析。

3.2. 数据划分与评价指标

首先按照井名对数据进行分组，并在每口井内部依据中心深度 Depth_Mid 进行升序排列，以保证测井序列与真实深度方向一致。随后，在单井内部采用固定长度滑动窗口构造样本，本文窗口长度设置为 64，即每个输入样本由连续 64 个深度点的多维测井特征组成。对于每个窗口，选取窗口中心位置对应的 DEN 值作为监督标签，使模型能够同时利用目标点上方和下方的测井响应信息进行密度曲线重构。该中心点预测策略能够减弱窗口边界效应，并增强模型对局部曲线形态、层段变化和深度方向连续性的表达能力。

在样本生成过程中，训练集和验证集采用步长为 4 构造窗口，以提高样本利用率并控制相邻窗口之间的重叠程度；测试集采用步长为 1 构造窗口，以尽可能覆盖测试井中的连续深度点，便于后续恢复完整的盲井 DEN 预测曲线。按照上述策略，最终构建训练序列 1265 个、验证序列 288 个、测试序列 515 个。

数据划分方面，本文采用按井划分策略，为提高实验评价的可靠性，本文将 G39、G43、G921、G933、G94、G96、J392、T251 和 X78 共 9 口井作为训练集，将 J393 和 X73 作为验证集，将 T252 作为独立测试井。

本文采用均方根误差、平均绝对误差和决定系数作为模型评价指标，RMSE 定义为：

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (22)$$

MAE 定义为：

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (23)$$

决定系数 R^2 定义为：

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (24)$$

其中， y_i 表示真实 DEN 值， $\hat{y}_i$ 表示预测 DEN 值， $\bar{y}$ 表示真实值均值， N 表示测试样本数量。RMSE 对

较大误差更加敏感,可反映模型在局部异常段的误差放大情况,MAE 表示平均绝对偏差,能够直观衡量整体预测误差, R^2 用于评价模型对真实 DEN 变化趋势的解释能力, RMSE 和 MAE 越小, R^2 越接近 1, 说明模型重构效果越好。

3.3. 对比模型与消融实验设计

为验证本文所提多尺度时序深度学习模型在密度曲线重构任务中的有效性,本文设置传统机器学习模型、单一深度学习模型和组合式序列模型作为对比基线。所有模型均采用相同的数据清洗结果、输入特征、训练/验证/测试并划分和评价指标,以保证实验比较的公平性。

传统机器学习模型选取 Random Forest 和 XGBoost 作为代表。Random Forest 具有较强的非线性拟合能力和抗噪声能力,可作为集成树模型基线,XGBoost 通过梯度提升机制增强复杂非线性关系表达能力,适合处理多变量回归任务。由于传统机器学习模型不能直接处理三维序列输入,实验中将窗口样本转换为适合其输入形式的二维特征表达。

深度学习对比模型选取 LSTM、GRU、BiGRU 和 TCN 等序列模型,LSTM 和 GRU 能够建模深度方向上的序列依赖关系,其中 GRU 结构相对简洁,训练效率较高,BiGRU 能够同时利用目标点前后两侧的上下文信息,与本文中心点预测任务较为匹配,TCN 则通过卷积结构提取局部时序模式,能够捕捉测井曲线在不同深度邻域内的变化特征。通过与上述模型对比,可以从传统非线性回归、单向序列建模、双向序列建模和卷积时序建模等角度评价本文模型的重构能力。

为进一步分析模型各组成部分对重构性能的贡献,本文设计消融实验。消融实验以完整模型为基准,分别去除或替换关键模块,并保持数据划分、训练策略和评价指标一致。具体包括去除多尺度时序特征提取模块、去除 BiGRU 双向序列建模模块、去除注意力或特征增强模块,以及去除残差连接等结构。通过比较完整模型与不同消融模型在盲井测试集上的 RMSE、MAE 和 R^2 变化,可以定量分析各模块对密度曲线重构精度、局部误差控制和整体趋势保持能力的影响。最终,本文从整体性能对比和模块贡献分析两个层面验证所提方法的有效性与合理性。

4. 结果与讨论

4.1. 不同模型的密度曲线重构精度对比

为评价本文模型在未知井密度曲线重构任务中的性能,选取 Random Forest、XGBoost、LSTM、BiGRU、TCN、Transformer、CNN-LSTM 及多种组合式深度学习模型作为对比对象。所有模型均采用相同的输入特征、预处理流程、训练/验证/测试并划分和评价指标,并在 T252 盲井测试集上进行评估。评价指标包括 RMSE、MAE 和 R^2 ,其中 RMSE 和 MAE 越小表示预测误差越低, R^2 越接近 1 表示模型对真实 DEN 曲线变化趋势的拟合能力越强。

由表 1 可知,本文模型取得最优重构结果, RMSE、MAE 和 R^2 分别为 0.0296 g/cm³、0.0198 g/cm³ 和 0.9290。与表现最接近的 BiGRU-Transformer 相比,本文模型的 RMSE 降低约 12.0%,MAE 降低约 4.1%, R^2 由 0.9081 提高至 0.9290,说明其在降低预测误差和拟合 DEN 曲线变化趋势方面均具有优势。

从单一模型看,LSTM、TCN 和 Transformer 的表现均低于组合式模型。其中,LSTM 受限于单向序列建模,难以充分利用目标深度点前后上下文信息;TCN 能够提取局部深度邻域内的曲线变化,但全局趋势建模能力不足;Transformer 具有较好的长程依赖建模能力,但单独使用时对局部波动和多尺度测井响应的刻画仍不充分。BiGRU 通过双向结构增强了上下文表达,性能明显优于 LSTM,说明双向序列信息对中心点密度预测具有积极作用。

组合式模型整体优于多数单一模型,表明局部特征提取、序列上下文建模和全局依赖建模之间具有

互补性。其中，BiGRU-Transformer 和 TCN-Transformer 均取得较好结果。然而，Vanilla TCN-BiGRU-Transformer 性能较差，说明简单堆叠多个模块并不能必然提升精度，合理的特征传递、融合方式和训练稳定性同样重要。

Table 1. Comparison of density log reconstruction performance among different models for the T252 blind well

表 1. 不同模型在 T252 盲井上的密度曲线重构性能对比

Model	RMSE	MAE	R ²
Random Forest	0.0784	0.0570	0.5446
XGBoost	0.0754	0.0558	0.5784
BiGRU-Transformer	0.0337	0.0207	0.9081
BiGRU	0.0356	0.0245	0.8970
TCN-Transformer	0.0356	0.0239	0.8968
Transformer	0.0369	0.0208	0.8896
CNN-LSTM	0.0428	0.0222	0.8514
TCN-BiGRU	0.0483	0.0312	0.8106
TCN	0.0493	0.0360	0.8028
LSTM	0.0527	0.0355	0.7741
Vanilla TCN-BiGRU-Transformer	0.0642	0.0468	0.6654
Ours	0.0296	0.0198	0.9290

图 4 进一步展示了不同模型在 RMSE、MAE 和 R² 上的差异。总体来看，本文模型在误差指标和拟合优度上均表现最佳，表明 DEN 曲线重构不仅是单点非线性回归问题，还依赖局部测井响应、深度连续性和跨层段变化趋势的联合建模。




Figure 4. Comparison of RMSE, MAE, and R² among different models for the T252 blind well

图 4. 不同模型在 T252 盲井上的 RMSE、MAE 和 R² 对比

4.2. 盲井重构效果与局部曲线形态分析

定量评价指标能够反映模型整体预测误差，但对于测井曲线重构任务而言，仅依靠 RMSE、MAE 和 R² 仍不足以全面评价模型的应用价值。实际工程中更关注预测曲线是否能够保持真实测井曲线的连续变化趋势、峰谷位置和局部形态特征。因此，本节进一步以 T252 盲井为对象，对本文模型的整井预测曲线和局部放大曲线进行分析。

图 5 给出了 T252 井真实 DEN 曲线与本文模型预测 DEN 曲线的对比结果。从整体趋势看, 预测曲线与真实曲线在深度方向上具有较好的一致性, 模型能够较准确地跟踪 DEN 曲线的高值段、低值段和缓慢变化段。预测结果未出现明显的整体偏高或整体偏低现象, 说明模型在盲井条件下不存在显著系统性偏差。同时, 预测曲线整体连续性较好, 没有出现大幅度非物理振荡, 表明模型能够在保持曲线平滑性的同时恢复主要的密度变化趋势。




Figure 5. Comparison between the measured DEN curve and the DEN curve predicted by the proposed model for well T252
图 5. T252 井真实 DEN 曲线与本文模型预测 DEN 曲线对比

从曲线形态看, 本文模型对 DEN 曲线整体起伏具有较强跟踪能力。在密度值缓慢变化井段, 预测曲线与真实曲线基本一致; 在波动较明显井段, 模型也能较好捕捉变化方向和峰谷位置, 说明其能够利用滑动窗口上下文信息表征深度方向上的连续变化规律。

图 6 进一步展示了 T252 井典型局部井段的放大结果。可以看出, 本文模型在局部起伏明显区域仍能较好保持真实曲线的峰谷位置, 对局部高值和低值响应较为接近。该结果表明, 多尺度时序特征提取有助于捕捉不同深度尺度下的局部变化, 双向序列建模和全局依赖建模则进一步增强了上下文信息利用能力。




Figure 6. Enlarged comparison between the measured DEN curve and the predicted DEN curve in a local interval of well T252

图 6. T252 井局部井段真实 DEN 曲线与预测 DEN 曲线放大对比

总体来看, T252 盲井曲线对比结果表明, 本文模型不仅在统计指标上取得较优结果, 而且能够生成与真实 DEN 曲线形态较一致的连续预测曲线, 该结果说明本文方法具有较好的盲井适用性, 可为密度曲线缺失段补全、异常段修复以及后续储层参数解释提供数据基础。

4.3. 误差分析与跨井泛化验证

为进一步分析模型预测误差特征, 图 7 给出了 T252 盲井的残差分布及预测值 - 真实值散点图。可以看出, 残差主要集中在零值附近, 大部分样本误差较小, 说明模型整体不存在明显系统性偏高或偏低现象。少量较大残差主要出现在曲线快速变化或局部非平稳井段, 表明局部突变仍是 DEN 曲线重构的主要误差来源。

预测值与真实值散点整体分布在 1:1 参考线附近, 说明模型预测结果与真实 DEN 值具有较高一致

性。相比单一模型，本文方法通过多尺度局部特征提取和深度方向上下文建模，能够更稳定地保持曲线整体趋势并降低局部预测误差。




Figure 7. Residual distribution and predicted-versus-measured scatter plot for well T252
图 7. T252 井的残差分布和预测值与真实值散点图

为分析模型各组成模块对重构性能的贡献，本文进一步开展消融实验。以完整模型为基准，分别去除 ECA 通道特征增强模块、Transformer 全局依赖建模模块、BiGRU 双向序列建模模块、多尺度特征提取模块和跳跃连接结构，并保持数据划分、训练策略和评价指标一致，消融实验结果如表 2 所示。

Table 2. Ablation experiment results
表 2. 消融实验结果表

Model	RMSE	MAE	R ²
ECA	0.0377	0.0242	0.8845
Transformer	0.0406	0.0246	0.8665
BiGRU	0.0300	0.0202	0.9267
Multi-Scale	0.0360	0.0237	0.8945
Skip Connection	0.0307	0.0188	0.9235
Ours	0.0296	0.0198	0.9290

由表 2 可知，完整模型取得最优综合性能。去除 Transformer 后性能下降最明显，RMSE 升至 0.0406 g/cm³，R² 降至 0.8665，说明全局依赖建模对捕捉密度曲线长程趋势和层段关联具有关键作用。去除 ECA 和多尺度特征提取模块后，RMSE 分别升至 0.0377 g/cm³ 和 0.0360 g/cm³，表明通道特征增强和多尺度局部建模均有助于提升关键测井响应的表达能力。

相比之下，去除 BiGRU 和跳跃连接后性能变化较小，说明二者主要起到上下文补充和特征传递增强作用。总体来看，本文模型的性能提升并非依赖单一模块，而是多尺度特征提取、通道增强、双向上下文建模和全局依赖建模协同作用的结果。

除 T252 固定盲井测试外, 本文进一步采用逐井留一验证考察模型在不同井上的泛化能力, 结果如表 3 所示。

Table 3. Leave-one-well-out cross-validation results
表 3. 留一井交叉验证结果

测试井	RMSE	MAE	R ²
G39	0.0296	0.0218	0.9357
G43	0.0212	0.0156	0.9605
G921	0.0268	0.0198	0.9440
G933	0.0408	0.0294	0.8717
G94	0.0317	0.0228	0.9254
G96	0.0232	0.0172	0.9610
J392	0.0253	0.0175	0.9415
J393	0.0248	0.0148	0.9527
T251	0.0269	0.0189	0.9342
T252	0.0354	0.0242	0.8982
X73	0.0451	0.0282	0.8460
X78	0.0486	0.0251	0.8292
Mean ± Std	0.0316 ± 0.0090	0.0213 ± 0.0048	0.9167 ± 0.0450

参考文献

[1] 谢冰, 张锋, 王含, 等. 超热中子-伽玛双探测器的地层密度测井方法研究[J]. 同位素, 2026, 39(2): 122-131.

[2] 陈志强, 赵玉孟, 安智轩. 测井曲线岩性识别方法分析[J]. 内蒙古石油化工, 2026, 52(1): 53-56.

[3] 罗功伟, 安小平, 姚卫华, 等. 非常规油气储层测井智能解释应用现状与发展趋势[J]. 石油科学通报, 2025, 10(5): 908-925.

[4] 韩宏伟, 王继晨, 康宇, 等. 测井智能处理与解释方法现状与展望[J]. 三峡大学学报(自然科学版), 2022, 44(6): 1-14.

[5] 陈秋生. 基于人工智能的测井设备数据处理与解释方法研究[J]. 石化技术, 2024, 31(10): 125-127.

[6] 范翔宇, 孟凡, 邓娟, 等. 基于自动机器学习的测井曲线重构技术[J]. 天然气工业, 2024, 44(9): 38-54.

[7] 宋真谊, 张宏兵, 祝新益, 等. 基于随机森林 MDA 算法的测井曲线重构方法[J/OL]. 吉林大学学报(地球科学版): 1-9. <https://www.cnki.net/Resolution/Handler?doi=10.13278/j.cnki.jjuese.20250065>, 2026-05-26.

[8] 黎子豪, 蒋恕. 基于机器学习和 SHAP 算法的声波测井曲线重构及可解释性分析[J]. 地质科技通报, 2025, 44(1): 321-331.

[9] 李枫林, 刘怀山, 杨熙镭, 等. 基于 U-Net 神经网络的声波测井曲线重构[J]. 中国海洋大学学报(自然科学版), 2023, 53(8): 86-92+103.

[10] 王俊, 曹俊兴, 尤加春. 基于 GRU 神经网络的测井曲线重构[J]. 石油地球物理勘探, 2020, 55(3): 510-520+468.

[11] 刘建建, 周军, 余卫东, 等. 基于超参数优化 LSTM 的声波测井曲线生成技术[J]. 石油物探, 2024, 63(5): 1061-1074.

[12] 李洪玺, 陈明江, 张显坤, 等. 基于贝叶斯优化 CNN-LSTM 的密度测井曲线重构方法[J]. 测井技术, 2025, 49(2): 198-208.

[13] 季帅良, 曾滨鑫. 基于 Transformer-LSTM 融合模型的密度测井曲线重构方法[J]. 录井工程, 2025, 36(2): 15-23.

[14] 尹艳霞. 基于时间卷积网络的测井曲线补全算法研究与应用[D]: [硕士学位论文]. 西安: 西安石油大学, 2025.

[15] 付启凡, 张凤奇, 宋立军, 等. 基于 BiLSTM-Attention 模型的页岩储层岩性测井分类方法[J]. 天然气地球科学, 2026, 37(1): 191-206.