

# 基于 Inception-BiGRU-Transformer 的测井曲线重构<sup>①</sup>



李文昊<sup>1</sup>, 李刚<sup>2</sup>, 高冉<sup>1</sup>, 孟杨<sup>1</sup>

<sup>1</sup>(东北石油大学 计算机与信息技术学院, 大庆 163318)

<sup>2</sup>(大庆油田有限责任公司 大庆油田第一采油厂, 大庆 163001)

通信作者: 李文昊, E-mail: lwh2011@126.com

**摘要:** 随着页岩油资源勘探开发的不断深入, 测井数据在储层评价中的重要性愈发突出. 然而, 由于测井设备故障、成本限制等因素, 常出现测井曲线缺失或异常的问题, 严重影响地质解释与资源开发的精度. 针对测井曲线缺失与异常问题, 通过引入 Transformer 编码器以增强全局特征表达, 并结合双向门控循环单元 (bidirectional gated recurrent unit, BiGRU) 的时序建模能力与 Inception 模块的多尺度特征提取能力, 设计了一种深度学习模型 IBT (Inception-BiGRU-Transformer), 该模型通过多尺度特征提取与时序建模机制, 有效提升了测井曲线的重构精度与稳定性. 在大庆古龙页岩油区 12 口井的实测数据集上开展了单目标与多目标测井曲线重构实验. 实验结果表明, IBT 模型在 RMSE、MAE、MAPE 和  $R^2$  等多项评价指标上均优于现有主流模型, 具备更强的预测精度与泛化能力. 消融实验进一步验证了各个模块在提升预测性能方面的有效性.

**关键词:** 测井曲线重构; Inception 模块; 双向门控循环单元 (BiGRU); Transformer 编码器; 深度学习; 页岩油

引用格式: 李文昊, 李刚, 高冉, 孟杨. 基于 Inception-BiGRU-Transformer 的测井曲线重构. 计算机系统应用, 2026, 35(1): 263-275. <http://www.c-s-a.org.cn/1003-3254/10056.html>

## Well Log Curve Reconstruction Based on Inception-BiGRU-Transformer

LI Wen-Hao<sup>1</sup>, LI Gang<sup>2</sup>, GAO Ran<sup>1</sup>, MENG Yang<sup>1</sup>

<sup>1</sup>(College of Computer & Information Technology, Northeast Petroleum University, Daqing 163318, China)

<sup>2</sup>(No.1 Oil Production Plant, Daqing Oilfield Co. Ltd., Daqing 163001, China)

**Abstract:** With the continuous advancement of shale oil exploration and development, well logging data has become increasingly important in reservoir evaluation. However, due to factors such as logging equipment failures and cost constraints, missing or abnormal well log curves frequently occur, which severely impact the accuracy of geological interpretation and resource development. To address the issues of missing and abnormal well log curves, a deep learning model termed Inception-BiGRU-Transformer (IBT) is proposed by integrating a Transformer encoder to enhance global feature representation, a bidirectional gated recurrent unit (BiGRU) for temporal modeling, and an Inception module for multi-scale feature extraction. This model effectively improves the reconstruction accuracy and stability of well log curves through its combined multi-scale feature extraction and sequential modeling mechanisms. Experiments are conducted on measured data from twelve wells in the Daqing Gulong shale oil region, involving both single-target and multi-target well log curve reconstruction tasks. The results demonstrate that the IBT model outperforms mainstream models in terms of RMSE, MAE, MAPE, and  $R^2$ , exhibiting superior predictive accuracy and generalization capability. Furthermore, ablation studies confirm the effectiveness of each component in enhancing the model's predictive performance.

① 基金项目: 黑龙江省政府与大庆油田首批“揭榜挂帅”科技攻关项目 (DQYT-2022-JS-750)

收稿时间: 2025-06-23; 修改时间: 2025-07-14, 2025-08-13; 采用时间: 2025-08-19; csa 在线出版时间: 2025-12-01

CNKI 网络首发时间: 2025-12-02

**Key words:** well log curve reconstruction; Inception module; bidirectional gated recurrent unit (BiGRU); Transformer encoder; deep learning; shale oil

随着非常规油气资源的不断开发,页岩油在我国能源结构中的地位日益突出.大庆古龙页岩油作为松辽盆地重点勘探开发区之一,具有资源储量丰富、埋藏深度适中、地质构造复杂等特点<sup>[1]</sup>.然而,在实际勘探开发过程中,受制于钻井成本、测井设备故障及人力资源限制,常出现测井曲线缺失、曲线采样稀疏或异常等问题.这种数据缺失不仅影响地层解释的准确性,还制约了后续储层评价和开发决策的科学性.因此,开展高精度测井曲线重构研究具有重要的现实意义.

传统测井曲线重构方法多依赖于地质先验知识或简单插值技术,难以充分捕捉复杂地层内部非线性关系,尤其在处理页岩油储层的非均质性、多尺度特征和时序依赖性方面表现不足.在油气田开发与地质勘探过程中,测井资料作为关键数据来源,在储层建模与油气资源评价中具有重要意义<sup>[2]</sup>.通过集成多种地球物理测井方法,不仅能够提升对储层参数的预测准确率,还能增强地质解释的可靠性,有助于构建精细的储层模型,推动油气资源的高效开发与利用<sup>[3]</sup>.在实际油气勘探过程中,由于成本控制、仪器性能及复杂地质环境等多种不确定性因素影响,测井数据常出现不完整或缺失的情况<sup>[4,5]</sup>.如何对缺失曲线进行高质量重构,已成为提升储层参数预测精度和加强测井信息利用率的重要课题.为了实现油气资源的高效开发,针对测井曲线中存在的大量非线性特征,近年来相关研究开始引入机器学习与深度神经网络等方法,以寻求更具适应性和泛化能力的建模策略<sup>[6-11]</sup>.

Akinnikawe等<sup>[2]</sup>探讨了应用多种主流机器学习方法对缺失测井数据进行预测的可行性,研究表明其结果在一定程度上可用于替代实际观测值,对油气勘探中的参数分析具有积极意义.Gowida等<sup>[12]</sup>构建了仿真平台,推动了测井数据驱动下的地层建模研究.Zhang等<sup>[3]</sup>和Chen等<sup>[9]</sup>基于长短期记忆网络(long short-term memory, LSTM)提出了一系列改进模型,包括多级结构和引入物理约束的方法,结合测井数据的空间特征和领域先验,有效提升了模型的地质一致性和预测稳定性.王俊等<sup>[13,14]</sup>借助门控循环单元(gated recurrent unit, GRU)构建了测井曲线间非线性关系的建模框架,

不仅实现了声波曲线和自然电位的生成,同时在孔隙度与饱和度等储层参数预测任务中也取得了良好的效果.尚福华等<sup>[15]</sup>探索将领域知识引入LSTM中,用于提升测井曲线的重构能力.实验表明,该方法在预测精度方面优于传统LSTM及其改进模型,体现了融合策略的有效性.Yang等<sup>[16]</sup>构建了一种融合多种深度学习模型,旨在捕捉测井数据之间的复杂依赖,强化对其时空特征的建模能力,从而提升石油勘探过程中数据的利用效率与准确性.

在本研究中,我们提出了一种融合多尺度特征提取、双向时序建模与全局注意力机制的深度神经网络模型IBT,用于实现大庆古龙页岩油区测井曲线的高精度重构.该模型结合了Inception模块的多尺度卷积结构、BiGRU的双向时序建模能力,以及Transformer编码器的全局依赖建模优势,能够有效捕捉测井曲线中蕴含的多维特征与复杂动态变化规律.通过对古龙地区测井数据的实验验证,结果表明所提出的方法在准确性与稳定性方面优于现有主流模型,为页岩油储层精细描述与智能测井补全提供了一种高效可靠的技术路径.

## 1 IBT模型结构设计与原理分析

### 1.1 IBT模型原理

针对测井曲线重构任务中存在的局部特征变化剧烈、跨尺度非线性关系复杂以及长距离依赖性显著等特点,本文提出了IBT深度学习模型,旨在实现对复杂测井曲线的高精度重构.在模块架构设计中,Inception模块负责提取多尺度特征,但测井曲线具有明显的顺序依赖性,因此需引入BiGRU进一步建模纵向(井深)变化的时序结构,避免特征之间因层次不当而丢失序列信息.随后Transformer用于增强长程上下文建模能力,弥补GRU类模型对远距离依赖表达不足的问题,实现多维特征间的全局耦合与精细调整.

首先,测井曲线数据通常包含多种测井参数,不同参数之间存在显著的尺度差异,且曲线在井深方向呈现多尺度变化模式.为增强模型对不同尺度地质特征的感知能力,模型首先通过Inception模块对输入曲线

进行多分支并行卷积,利用不同感受野提取局部细粒度特征及全局趋势特征,形成丰富的多尺度特征表达。其次,Inception 模块提取的特征序列输入到 BiGRU 模块,通过前向与后向的门控递归机制捕获序列中的时间依赖性信息,有效建模测井曲线沿井深方向的动态演变规律,为提升后续时序建模阶段对原始特征信息的保持能力,模型在 Inception 模块与 BiGRU 模块之间设计了残差连接机制。通过将 Inception 输出特征映射后与 BiGRU 输出进行残差融合,增强了模型特征流动性,缓解了深层网络中的梯度消失问题,同时提升了特征多样性。在 BiGRU 模块之后,引入 Transformer 编码器中的位置编码,使 Transformer 编码器能够在序列建模过程中保持测井曲线中的顺序特征信息。接着通过 MHA 建模全局上下文信息,学习测井曲线中任意位置之间的非局部依赖关系;通过 FFN 强化特征的非线性表达能力,进一步提升模型对复杂地质响应的建模能力,同时使用残差连接和归一化操作保证训练稳定性,提升模型收敛速度。最后,输出经过全连接层映射至目标测井曲线,实现对测井曲线缺失段的重构预测。

## 1.2 IBT 模型结构

为有效捕捉测井曲线中的多尺度特征、序列依赖关系及全局上下文信息,本文构建了 IBT 网络结构,应用于测井曲线重构任务。模型整体包括 Inception 模块、BiGRU 模块和 Transformer 编码器模块这 3 个核心部分,其结构如图 1 所示。

首先,将测井数据以二维数据作为 IBT 网络模型的输入。输入部分的  $D_{1,1}$  表示第 1 个测井参数的第 1 次测井数据,  $D_{N,N}$  表示第  $N$  个测井参数的第  $N$  次测井数据。输入序列首先通过 Inception 模块提取局部多尺度特征。Inception 模块内部采用了  $1 \times 1$  的卷积核、 $3 \times 3$  的卷积核、 $5 \times 5$  的卷积核和  $3 \times 3$  的最大池化,提取不同感受野下的特征信息,拼接融合后形成特征序列。然后,将 Inception 模块提取的特征序列输入到 BiGRU 中,进一步学习测井数据在深度域的序列依赖关系。为了增强序列对 Inception 特征的保持能力,模型设计了 Inception 残差连接。与 BiGRU 输出做加法残差连接,提升特征多样性和信息流通能力。为保持序列的位置信息,模型采用位置编码,位置编码与 BiGRU 残差输出相加,位置编码后的序列输入至 Transformer 编码器,经过 MHA 输入残差连接和层归一化,再输入到 FFN

再次经过残差连接和层归一化,最后输出通过全连接层 Linear,最终生成对应的测井曲线重构值,完成对目标曲线的预测。

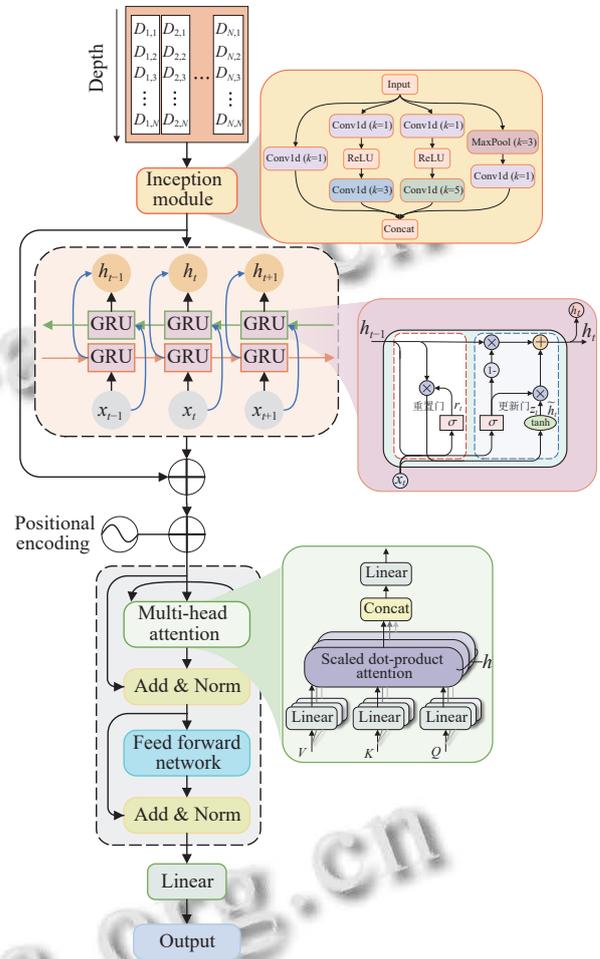


图 1 IBT 模型结构

## 1.3 关键模块原理

Inception 模块是 Szegedy 等<sup>[17]</sup>在 2015 年的 GoogLeNet 架构中首次提出的,主要解决卷积神经网络 (convolutional neural network, CNN) 中无法多尺度提取特征和参数量过大问题。本文使用的 Inception 模块结构如图 2 所示。其核心结构是在同一层网络结构中,并行使用  $1 \times 1$  卷积、 $3 \times 3$  卷积、 $5 \times 5$  卷积和  $3 \times 3$  最大池化,对输入的数据进行卷积或池化操作,提取出不同尺度的特征。

测井数据通常具备显著的时序特性,因此模型需充分捕捉时间维度上的动态变化。为此研究者引入了 GRU,其在保持时序建模能力的同时,有效克服了传统循环神经网络 (recurrent neural network, RNN) 中常见

的梯度消失问题<sup>[18]</sup>. GRU 内部结构如图 3 所示, GRU 内部隐藏层的定义如下.

$$z_t = \sigma(W_{xz}x_t + W_{hz}h_{t-1} + b_z) \quad (1)$$

$$r_t = \sigma(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \quad (2)$$

$$\tilde{h}_t = \tanh(W_{xh}x_t + r_t \odot h_{t-1} + W_{hh}h_{t-1} + b_h) \quad (3)$$

$$h_t = (1 - z_t) \odot \tilde{h}_t + z_t \odot h_{t-1} \quad (4)$$

其中,  $z_t$  表示更新门,  $r_t$  表示重置门,  $\sigma$  为 Sigmoid 激活函数,  $\odot$  为 Hadamard 积,  $W$  为系数矩阵,  $b_z$ 、 $b_r$ 、 $b_h$  为偏置,  $x_t$  是  $t$  时刻的输入,  $h_{t-1}$  是  $t-1$  时刻的隐藏状态,  $\tilde{h}_t$  是  $t$  时刻的候选隐藏状态,  $h_t$  是  $t$  时刻的输出隐藏状态.

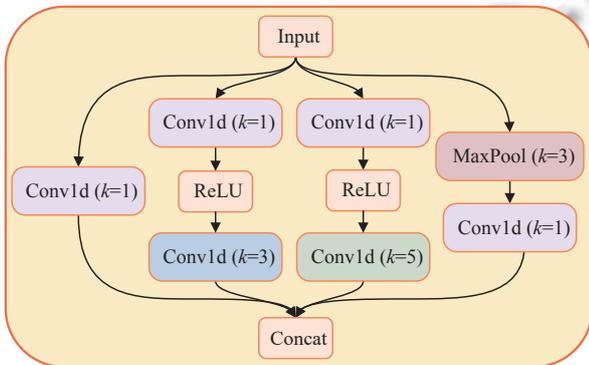


图 2 Inception 模块结构

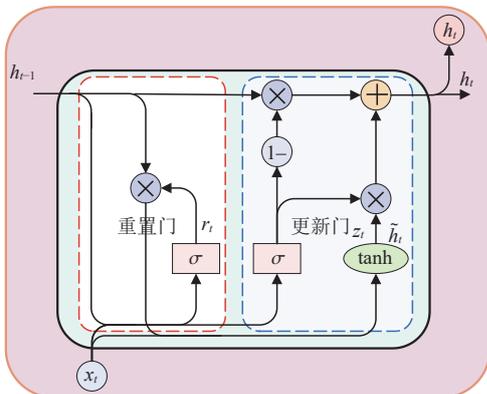


图 3 GRU 内部结构

对于测井数据这种前后依赖性显著的序列结构, 为增强时序感知能力, 引入了双向结构的 BiGRU, 该模型由两个 GRU 单元构成, 分别处理序列的正向与反向信息<sup>[19]</sup>. 如图 4 所示, 从而在时刻  $t$ , 其内部状态的更新机制可表示为:

$$\vec{h}_t = GRU(x_t, \vec{h}_{t-1}) \quad (5)$$

$$\overleftarrow{h}_t = GRU(x_t, \overleftarrow{h}_{t-1}) \quad (6)$$

$$h_t = W_{\vec{h}_t} \vec{h}_t + W_{\overleftarrow{h}_t} \overleftarrow{h}_t + b_t \quad (7)$$

其中,  $\vec{h}_t$  和  $\overleftarrow{h}_t$  分别为在  $t$  时刻前向与后向的信息流,  $W_{\vec{h}_t}$  和  $W_{\overleftarrow{h}_t}$  分别为  $t$  时刻前向与后向权值,  $b_t$  为隐藏层的偏置.

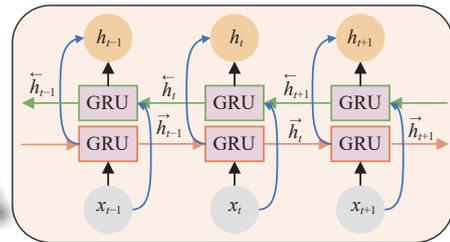


图 4 BiGRU 内部结构

Transformer 是 Vaswani 等<sup>[20]</sup>在 2017 年提出的一种基于自注意力机制的深度学习架构. 在测井曲线重构中, 使用 Transformer 编码器建立输入序列中任意位置之间的全局关联, 动态调整关注重点, Transformer 编码器通过位置编码 (positional encoding, PE)、多头注意力机制 (multi-head attention, MHA)、全连接前馈网络 (feed forward network, FFN)、层归一化 (layer normalization) 以及残差连接 (residual connection). 解决了不同的测井曲线对同一地层的特征响应存在差异的问题, 其结构如图 5 所示.

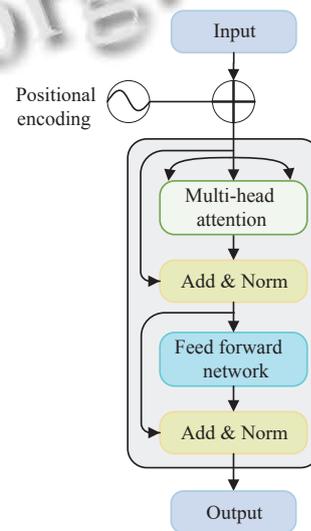


图 5 Transformer 编码器结构

MHA 机制通过多组注意力, 有效对输入特征进行加权处理, 提升了对关键特征的响应能力, 其结构如

图6所示. 具体表达式如下.

$$Attention(Q, K, V) = Softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (8)$$

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W^O \quad (9)$$

$$head_i = Attention(QW_i^Q, KW_i^K, VW_i^V) \quad (10)$$

其中,  $Q$  为查询向量,  $K$  为键向量,  $V$  为值向量,  $h$  为注意力头的数量,  $Q, K, V \in \mathbb{R}^{B \times L \times D}$ ,  $B$  为批大小,  $L$  为输入序列长度,  $D$  为输入特征维度,  $W^O$  是权值矩阵,  $head_i$  是第  $i$  个注意力头的计算结果,  $W_i^Q, W_i^K, W_i^V$  是输入向量投影到第  $i$  个注意力头的权值矩阵,  $\sqrt{d_k}$  为比例因子.

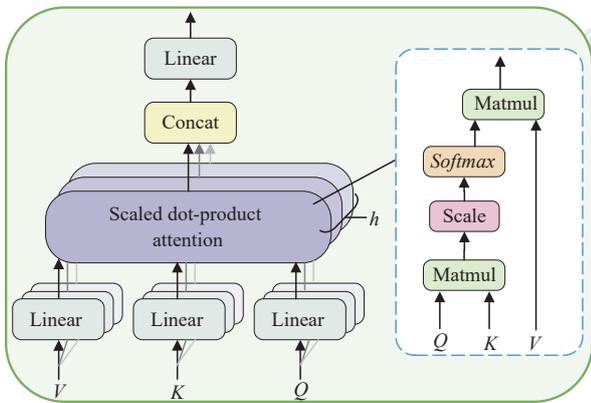


图6 多头注意力结构

#### 1.4 模块融合的地质物理意义

页岩油储层普遍具备成分细粒化、层理发育、多尺度非均质性以及受控于长程构造应力的变形响应等复杂地质特征, 测井曲线在此类储层中往往呈现出两种典型响应特征; 一方面存在由薄层夹杂、局部裂缝等引发的高频剧烈波动, 另一方面则表现为不同深度区段之间的远程耦合与协同响应. 这种“双重复杂性”对测井曲线建模提出了多维度的表达需求. IBT 模型通过 Inception、BiGRU 与 Transformer 这 3 种结构的串联融合, 分别对应对局部多尺度扰动、垂向序列依赖以及跨层远程响应的建模需求, 是针对页岩油储层复杂测井响应特性而设计的结构映射.

Inception 模块通过并行设置  $1 \times 1$ 、 $3 \times 3$  与  $5 \times 5$  卷积核及最大池化分支, 在同一层网络中实现对不同感受野下的特征同步提取, 能够有效应对页岩段中频繁出现的薄层灰质夹层、微裂缝、炭质条带等微观结构所引发的多尺度响应扰动. 该结构等价于一种对“薄层-中层-厚层”多级地质单元的多分辨率采样机制, 提升了

模型对局部地质细节的解析能力. BiGRU 采用双向时序建模机制, 适合对沿井深方向不断变化的测井数据进行表征与学习. 测井曲线沿井深方向蕴含沉积旋回与压实演化信息, BiGRU 能够同时建模测井数据沿井深方向的双向上下文依赖关系, 包括自上而下与自下而上的信息传递. 能够在完整沉积序列建模过程中, 同时考虑成因层序之间的继承性关系与上覆层段施加的压力对下伏地层物性特征的反馈影响, 从而增强模型对地层过渡带区域的响应能力, 尤其是在识别泥质页岩与泥岩互层等细粒互层界面的测井曲线趋势变化方面, 表现出更强的辨识能力. Transformer 编码器中的多头注意力机制具备跨层远程信息耦合能力, 能够有效捕捉测井曲线中不同深度位置之间的非局部关联. 在页岩油储层中, 由于断裂带、裂缝系统等构造因素的影响, 往往会导致电阻率或密度等测井响应在相距较远的井段同时发生变化, 表现为远程协同的响应模式. 该类变化通常源于断裂发育区的物质充填或深层流体迁移现象, Transformer 模型凭借其全局建模优势, 有助于识别这类复杂构造引起的测井异常联动特征. Transformer 编码器的自注意力可在任意深度建立强连接, 自动识别“物性呼应”区段, 弥补 RNN 对长程依赖捕捉不足的缺陷.

## 2 IBT 测井曲线重构流程

基于 IBT 的测井曲线重构流程如图7所示. 该流程主要可划分为以下 3 个步骤.

首先, 将输入的测井曲线数据根据要重构的测井数据与其他测井数据做相关性特征分析, 筛选出与需要重构的测井相关数据作为输入. 然后将相关性较大的测井数据进行归一化处理, 之后按照约 8:2 的比例划分训练集和测试集.

其次, 初始化 IBT 模型的网络参数, 利用训练集训练 IBT 模型, 使用均方误差 (MSE) 作为模型训练的损失函数. MSE 损失函数的表达式如式 (11) 所示. 通过损失函数的值检验模型训练效果, 并通过反向传播更新 IBT 模型网络中的参数. 同时使用 Adam 优化算法更新参数. 直到损失函数的值达到预期效果后保存模型.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (11)$$

其中,  $n$  为测井数据的数量,  $\hat{y}_i$  为第  $i$  个测井数据的预测值,  $y_i$  为第  $i$  个测井数据的真实值.

最后, 利用保存好的训练模型对测试集进行测井曲线重构预测, 并将预测结果反归一化, 得到重构后的测井数据.

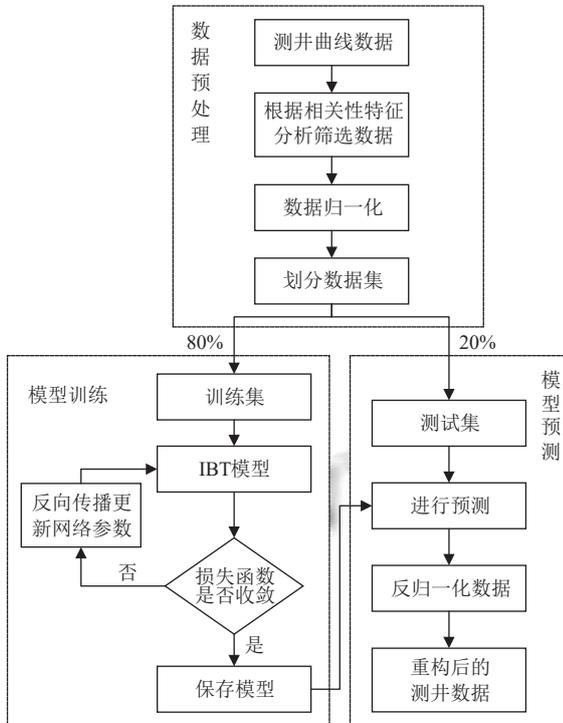


图7 IBT 测井曲线重构流程

### 3 实验及结果分析

#### 3.1 实验数据集

本文采用的测井数据集来自大庆古龙页岩油区, 包含了 12 口井的测井数据. 为统一标识, 将实验用井命名为 A1-A12, 对应数据集记为 A. 作为模型输入的重要依据, 每口井均包含 8 条关键测井曲线, 分别为声波时差 (AC, 单位:  $\mu\text{s}/\text{ft}$ )、密度 (DEN, 单位:  $\text{g}/\text{cm}^3$ )、自然伽马 (GR, 单位: API)、自然电位 (SP, 单位: mV)、井径 (CAL, 单位: in)、补偿中子 (CNL, 单位: %)、浅侧向电阻率 (LLS, 单位:  $\Omega \cdot \text{m}$ )、深侧向电阻率 (LLD, 单位:  $\Omega \cdot \text{m}$ ). 数据集 A 总共包含 121 847 组数据, 将数据集按照大致 8:2 的比例划分训练集和测试集, 每一组数据的采样间隔为 0.125 m, 具体的数据集 A 相关信息如表 1 所示. 为了充分利用现有的数据集全面评估 IBT 模型的效果, 本文在数据集 A 上进行缺失测井曲线单目标 CNL 重构实验和缺失测井曲线多目标 AC、DEN 重构实验.

表 1 测井曲线数据集 A 相关信息

井名	深度 (m)	采样间隔 (m)	样本数
A1	1250-2461	0.125	9689
A2	1210-2561	0.125	10809
A3	1030-2579.625	0.125	12398
A4	1010-2467.875	0.125	11664
A5	1976-2553.5	0.125	4621
A6	1114-2569	0.125	11641
A7	1120-2547.125	0.125	11418
A8	1000-2477.25	0.125	11819
A9	1050-2391	0.125	10729
A10	1010-2421.125	0.125	11290
A11	1274-2047	0.125	6184
A12	1260-2458	0.125	9585

#### 3.2 相关性分析

为深入了解 CNL、AC、DEN 与其他测井曲线之间的线性关系, 并为模型输入特征的选择和预测目标的合理性提供依据, 本文在 IBT 模型训练前, 对样本数据进行皮尔逊相关性分析, 并以热力图形式展示相关系数矩阵. 皮尔逊相关系数 ( $R$ ) 的计算公式如下:

$$R = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})(y_i - \bar{y})}{\sqrt{\left( \sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 \sum_{i=1}^n (y_i - \bar{y})^2 \right)}} \quad (12)$$

其中,  $\bar{\hat{y}}$  为样本预测值的平均值,  $\bar{y}$  为样本真实值的平均值.

单目标 CNL 曲线重构的相关性分析如图 8 所示, CNL 曲线与 AC、CAL、SP 测井曲线间存在明显的正相关性关系, CNL 曲线与 GR、DEN、LLS、LLD 测井曲线间存在明显的负相关性关系, 这说明 CNL 测井曲线的变化趋势可由上述曲线提供一定的预测信息, 为后续 CNL 重构任务提供了数据支撑.

为实现 AC 与 DEN 曲线的多目标联合重构, 分别对这两条测井曲线与其他输入曲线的相关性进行了分析. 如图 9 展示了 AC 曲线的相关性矩阵, 其与 CNL、CAL 具有较强的正相关关系, 而与 LLS、LLD 呈现一定负相关; 同时根据经验也说明 GR 与 SP 对 AC 预测具有一定贡献. 如图 10 为 DEN 曲线的相关性矩阵, 显示其与 GR、SP、LLS、LLD 存在较强相关性, 而与 CNL 和 CAL 呈现较强负相关.

总体来看, 在进行单目标 CNL 曲线重构时选取 AC、CAL、GR、SP、DEN、LLS、LLD 作为输入特征. 在进行多目标 AC 与 DEN 曲线重构时选取 CNL、CAL、GR、SP、LLS、LLD 作为输入特征.

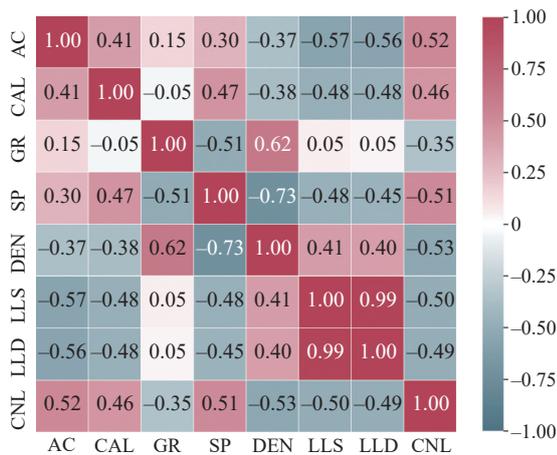


图8 CNL与其他测井曲线皮尔逊相关系数矩阵



图9 AC与其他测井曲线皮尔逊相关系数矩阵

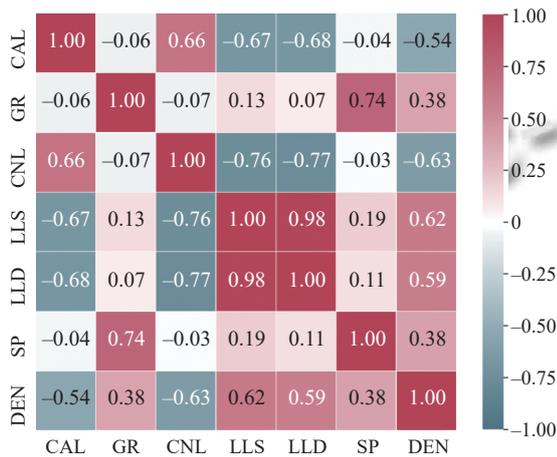


图10 DEN与其他测井曲线皮尔逊相关系数矩阵

### 3.3 实验设置与评价指标

本文所提出的测井曲线重构模型采用IBT网络结构,为了充分发挥各模块的特征提取能力和序列建模能力,并保证模型在训练过程中具备良好的收敛性和

泛化性能,经过多次实验最终得到的模型结构参数,具体设置如下。

因为实验需要进行单目标预测和多目标预测,所以输入维度根据所选取的测井曲线特征数量动态赋值,在模型运行时自动确定,确保不同实验方案下的灵活性和兼容性.隐藏层维度设置为512.较大的隐藏层维度有助于提升模型对复杂特征的表达能力,特别是在Inception模块的多尺度特征提取和BiGRU层的深层序列建模中效果显著. BiGRU层数设置为2层,采用双向GRU结构,有利于捕获序列中前向和后向的依赖关系,增强模型对测井曲线上上下文信息的建模能力. Transformer编码器中多头注意力机制的头数设置为8,通过多头机制实现不同子空间的特征交互,提升序列内部不同位置之间的相关性建模效果. Dropout比例设置为0.2,合理的随机失活机制有助于缓解模型过拟合风险,增强模型的泛化能力.学习率设置为0.001,采用较小的初始学习率可有效避免训练过程中的震荡,促进模型平稳收敛.批量大小设置为64,综合考虑模型复杂度和计算资源,选择合适的batchsize以平衡训练速度和模型性能.序列长度设置为100,能够覆盖大部分测井曲线中的典型地质变化尺度,保证模型对不同深度区间的有效感知能力.模型实验训练150轮,实验过程中观察到模型在150轮训练过程中收敛稳定,并能够获得较优的预测性能。

因为测井数据具有不同的数据范围,为了消除不同测井曲线量纲和数值范围差异对模型训练的影响,本文采用最大最小归一化方法对输入特征进行标准化处理.其归一化公式如式(13)所示:

$$X = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (13)$$

其中,  $X$  为归一化后的测井数据,  $X_i$  为原始数据,  $X_{\max}$ 、 $X_{\min}$  分别为该特征的最大值和最小值。

模型训练完成后,需将归一化后的预测结果还原为原始物理量纲,反归一化的计算公式如式(14)所示:

$$Y = Y_{\text{pre}}(Y_{\max} - Y_{\min}) + Y_{\min} \quad (14)$$

其中,  $Y_{\text{pre}}$  表示模型输入的归一化预测值,  $Y$  为反归一化后的真实预测值,  $Y_{\max}$ 、 $Y_{\min}$  为目标测井曲线的最大值与最小值。

同时为了评估测井曲线重构的准确性和其在不同模型中的表现,本文引入均方根误差(RMSE)、平均绝

对误差 (*MAE*)、平均绝对百分比误差 (*MAPE*) 和决定系数 ( $R^2$ ) 这 4 个评价指标. 上述指标从误差幅度、相对偏差和拟合程度等维度综合衡量预测效果, 能够较全面地反映模型在重构任务中的性能优劣. 4 个评估指标的公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

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

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (18)$$

### 3.4 单目标 CNL 测井曲线重构

本节针对 CNL 测井曲线开展单目标回归重构实验, 评估多种深度神经网络模型在测井数据预测任务中的表现. 实验基于数据集 A 进行, 选取 A2 和 A9 两口井作为测试集, 其余 10 口井作为训练集. 在训练阶段, 模型以完整的多条测井曲线 (CAL、GR、SP、LLS、LLD、AC、DEN) 为输入, 构建 CNL 曲线的预测模型. 各模型在测试井上的预测误差与拟合表现如表 2 所示.

表 2 单目标 CNL 测井曲线重构各模型预测对比

井名	模型名称	RMSE	MAE	MAPE (%)	$R^2$
A2	CNN	2.6942	2.2274	8.5312	0.6187
	LSTM	2.0378	2.2274	5.6700	0.7818
	GRU	2.2445	1.7687	6.6710	0.7353
	BiGRU	1.9634	1.4817	5.7380	0.7975
	Inception-LSTM	1.7737	1.3496	5.1130	0.8347
	IBT	1.4366	1.0255	3.8381	0.8916
A9	CNN	2.2945	1.7738	7.8374	0.8159
	LSTM	1.9472	1.5129	6.7758	0.8674
	GRU	2.1427	1.6707	7.6377	0.8395
	BiGRU	1.5924	1.2946	5.6740	0.9113
	Inception-LSTM	1.4803	1.1524	5.0665	0.9234
	IBT	1.1600	0.9035	3.9611	0.9529

在 A2 井上, IBT 模型预测精度最高, *RMSE* 为 1.4366, *MAE* 为 1.0255, *MAPE* 为 3.8381%,  $R^2$  为 0.8916, 其预测曲线与真实值高度吻合, 能够准确还原井深区间内的非线性波动与趋势变化. Inception-LSTM 模型表现次之 ( $R^2$  为 0.8347), 具备较好的拟合能力. BiGRU

和 LSTM 模型在捕捉整体趋势方面表现较为稳定, 但在高波动区段存在一定偏离 ( $R^2$  为 0.7975 与 0.7818). GRU 模型的  $R^2$  为 0.7353, 略低于前述模型. CNN 模型性能最弱, *RMSE* 为 2.6942,  $R^2$  为 0.6187, 表明其对复杂测井响应特征建模能力有限.

在 A9 井上, 各模型整体拟合效果优于 A2 井, 且差异更为明显. IBT 模型仍表现最优, *RMSE* 为 1.1600, *MAE* 为 0.9035, *MAPE* 为 3.9611%,  $R^2$  为 0.9529, 不仅准确还原了主要趋势, 在剧烈变化区段亦具备较强的细节拟合能力. Inception-LSTM 和 BiGRU 模型分别达到  $R^2$  为 0.9234 与 0.9113, 表现稳定具备较强的时序建模能力. 相比之下, GRU、LSTM 与 CNN 的预测结果波动较大, *RMSE* 的结果分别为 2.1427、1.9472 和 2.2945, 拟合效果在剧烈变化区间出现一定程度的滞后或过度平滑, CNN 模型  $R^2$  为 0.8159, 在所有模型中依旧最低.

为了更加直观地展示各模型对 CNL 曲线预测效果的差异, 图 11 展示了 A9 井的原始测井曲线以及 CNL 预测结果. 其中, 图 11(a) 显示了 7 条原始测井曲线 (包括 CAL、GR、SP、LLS、LLD、AC 和 DEN), 反映了该井在不同深度的地质响应特征; 图 11(b) 展示了 6 种模型 (CNN、LSTM、GRU、BiGRU、Inception-LSTM 和 IBT) 对 CNL 曲线的预测结果与真实值的对比. 在图 11(b) 中, 蓝色曲线表示 CNL 的真实测量值, 红色曲线表示模型预测结果. 可观察到, IBT 模型所预测的 CNL 曲线与真实值最为接近, 尤其在 1200–1800 m 深度范围内的细节波动和趋势变化均被较好地捕捉与拟合.

综上, IBT 模型在 A2 和 A9 两口测试井中均展现出最优的预测性能, 能够有效地捕捉 CNL 曲线的非线性变化特征与深层时序依赖关系, 具有良好的泛化能力和地质适应性. Inception-LSTM 与 BiGRU 模型同样具有较强的建模潜力, 传统模型 CNN 和 LSTM 在复杂地层环境下表现不佳, 难以满足高精度重构要求.

### 3.5 多目标 AC 和 DEN 测井曲线重构

在数据集 A 上进行了多目标 AC 和 DEN 测井曲线的回归预测实验. 取 A2 和 A9 作为测试集, 其余 10 口井作为训练数据集. AC 是孔隙度识别和计算中的关键测井参数, 对于非常规油气资源的定量评价具有重要意义; DEN 测井曲线则常用于岩性识别与孔隙度计算. 因此, 本节选取 AC 和 DEN 作为多目标回归

预测的目标测井曲线. 实验中, 输入特征为 CNL、CAL、GR、SP、LLS 和 LLD 这 6 条常规测井曲线, 输出目标为 AC 和 DEN 曲线. 分别采用 6 种深度学习模型 (CNN、LSTM、GRU、BiGRU、Inception-LSTM 和

IBT) 对缺失曲线进行多目标联合重构. 在测试阶段, 分别对两口测试井的预测误差进行计算, 并对每种模型的结果取平均值作为整体性能评估. AC 与 DEN 的预测误差指标与拟合表现如表 3 和表 4 所示.

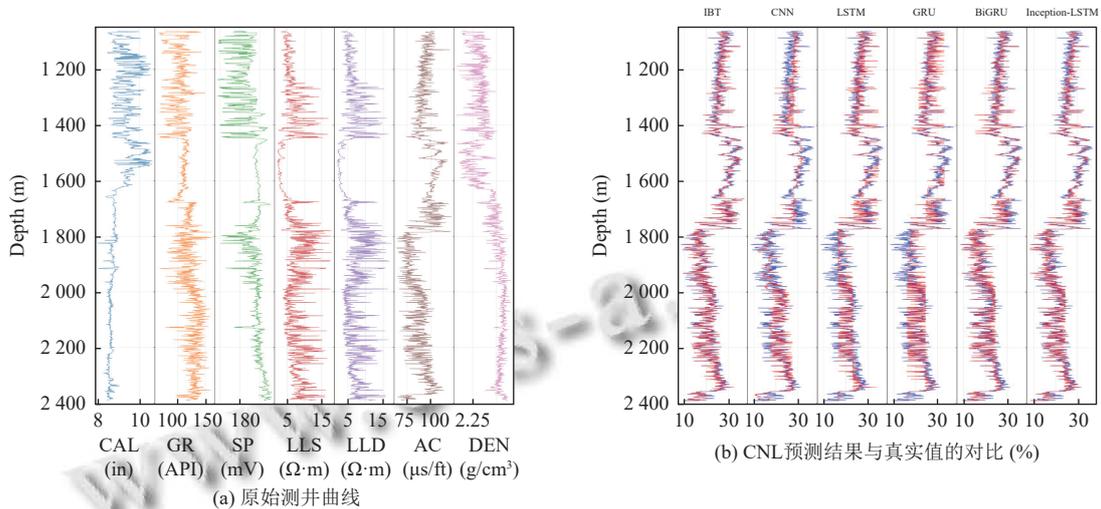


图 11 A9 测井曲线预测图

表 3 多目标 AC 测井曲线重构各模型预测对比

井名	模型名称	RMSE	MAE	MAPE (%)	R <sup>2</sup>
A2	CNN	6.0817	4.9909	5.0962	0.5442
	LSTM	5.1860	4.0835	4.1907	0.6686
	GRU	4.8733	3.7953	3.8996	0.7074
	BiGRU	4.3254	3.3628	3.4699	0.7695
	Inception-LSTM	3.7143	2.7592	2.8679	0.8300
	IBT	2.7304	1.8013	1.8668	0.9081
A9	CNN	6.1768	4.5278	5.1780	0.6597
	LSTM	4.0621	3.1048	3.4058	0.8528
	GRU	4.9482	3.9561	4.3829	0.7816
	BiGRU	3.6809	2.8937	3.1639	0.8791
	Inception-LSTM	3.3071	2.5686	2.8140	0.9024
	IBT	2.2654	1.6731	1.8297	0.9542

表 4 多目标 DEN 测井曲线重构各模型预测对比

井名	模型名称	RMSE	MAE	MAPE (%)	R <sup>2</sup>
A2	CNN	0.0603	0.0442	1.8187	0.4859
	LSTM	0.0545	0.0407	1.6683	0.5803
	GRU	0.0575	0.0432	1.7677	0.5313
	BiGRU	0.0518	0.0392	1.6046	0.6201
	Inception-LSTM	0.0480	0.0359	1.4655	0.6737
	IBT	0.0299	0.0212	0.8648	0.8733
A9	CNN	0.0705	0.0514	2.1700	0.7192
	LSTM	0.0683	0.0497	2.0945	0.7368
	GRU	0.0622	0.0450	1.8790	0.7815
	BiGRU	0.0594	0.0438	1.8470	0.8008
	Inception-LSTM	0.0550	0.0421	1.7557	0.8290
	IBT	0.0377	0.0259	1.0903	0.9196

在 A2 井的重构实验中, IBT 模型在 AC 曲线预测中取得最优表现, 其预测误差指标为  $RMSE$  为 2.7304,  $MAE$  为 1.8013,  $MAPE$  为 1.8668%, 决定系数  $R^2$  为 0.9081, 能够准确还原曲线整体趋势与细节波动. Inception-LSTM 和 BiGRU 模型次之,  $R^2$  分别为 0.8300 和 0.7695, 虽能捕捉主要变化, 但在高频波动与局部极值还原方面略显不足. 传统模型 CNN 和 GRU 表现较弱, CNN 的  $R^2$  仅为 0.5442, 存在明显的预测偏差. 在 DEN 曲线预测方面, IBT 模型同样展现出最优性能,  $RMSE$  为 0.0299,  $MAE$  为 0.0212,  $MAPE$  为 0.8648%,  $R^2$  达到 0.8733, 预测曲线与真实值高度一致. Inception-LSTM 与 BiGRU 分别取得  $R^2$  为 0.6737 和 0.6201, 拟合能力尚可; CNN 和 GRU 模型在该井上的  $R^2$  分别为 0.4859 和 0.5313, 精度相对较低.

在 A9 井的预测任务中, IBT 模型在 AC 曲线重构中再次取得最优结果, 其  $RMSE$  为 2.2654,  $MAE$  为 1.6731,  $MAPE$  为 1.8297%,  $R^2$  高达 0.9542, 体现出良好的泛化能力与复杂结构建模能力. Inception-LSTM 与 BiGRU 分别取得  $R^2$  为 0.9024 和 0.8791, 性能紧随其后. 而 CNN 与 GRU 模型的  $R^2$  分别为 0.6597 和 0.7816, 预测曲线存在一定程度的偏移或过度平滑. 在 DEN 曲线的预测中, IBT 模型再次展现优越性能,  $RMSE$  为 0.0377,  $MAE$

为0.0259, *MAPE*为1.0903%,  $R^2$ 为0.9196,能够较好地还原密度曲线的整体变化与局部波动. Inception-LSTM与BiGRU模型表现稳定,  $R^2$ 分别为0.8290和0.8008. 而CNN和GRU在该井上的预测精度仍相对较低,  $R^2$ 分别为0.7192和0.7815,表现出一定程度的拟合误差.

为进一步直观展示多模型在多目标测井曲线重构中的表现,图12展示了A2井的预测对比图.图12(a)为原始测井输入曲线(包括CAL、GR、SP、LLS、LLD和CNL),图12(b)为各模型对AC曲线的预测结果,图12(c)则为对DEN曲线的预测结果.其中蓝色曲线为

真实值,红色曲线为各模型预测值.从图12(b)可观察到,IBT模型的AC预测曲线最接近真实曲线,尤其在1200–1800 m及2100–2300 m范围内的波动趋势能够精准捕捉;而CNN、GRU等模型在该深度段表现出一定程度的偏离或过度平滑.图12(c)中DEN的预测也显示出类似规律,IBT不仅整体趋势拟合优良,在局部峰值与谷值还原方面也具备更强表达能力.综上所述,IBT模型在多目标AC与DEN测井曲线的重构任务中显著优于其他模型,在多个评价指标中均取得最佳性能,体现出其对多尺度空间特征和时间序列依赖关系的强建模能力,具有良好的泛化能力和实际应用潜力.

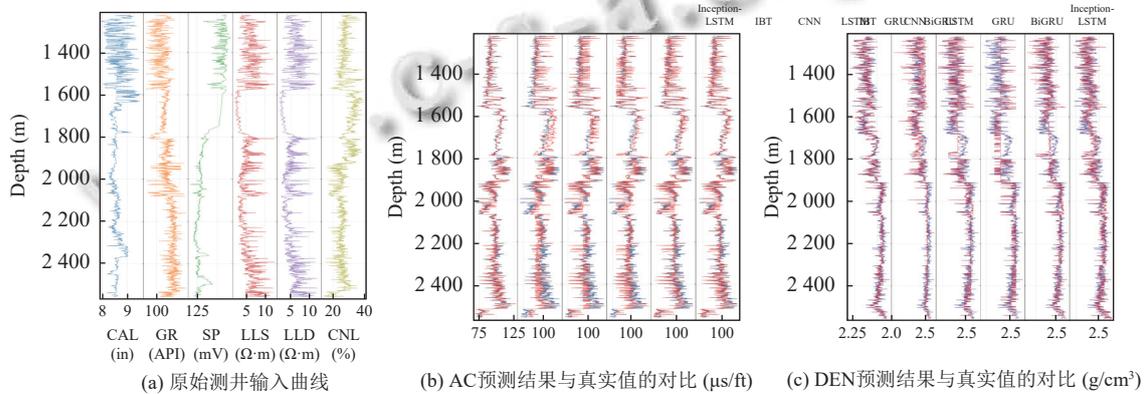


图12 A2测井曲线预测

### 3.6 消融实验

为评估IBT模型中各核心模块(Inception、BiGRU与Transformer编码器)对测井曲线重构性能的实际贡献,设计消融实验.通过逐一移除这3个模块构建不同子模型,并在测试井A2上进行多目标回归预测(目标为AC和DEN曲线),从而验证各组件对模型预测精度与拟合能力的影响.本节共构建了以下3种模型,IB(移除Transformer模块,仅保留Inception+BiGRU)、IT(移除BiGRU模块,仅保留Inception+Transformer)、BT(移除Inception模块,仅保留BiGRU+Transformer).模型预测误差(*RMSE*、*MAE*、*MAPE*)与拟合系数 $R^2$ 的具体结果如表5所示,并通过图13与图14进一步展示各模型在A2井上AC与DEN的预测真实值与预测值的散点对比关系.

从表5中可以看出,完整的IBT模型在AC与DEN预测中均取得最优性能,其中AC的 $R^2$ 达到0.9540, DEN的 $R^2$ 为0.9253,显著高于其他消融模型;移除Transformer编码器模块后的IB模型在AC预测中 $R^2$

下降至0.9052,在DEN中为0.8414,显示Transformer编码器有助于捕捉长程依赖信息;移除BiGRU模块后的IT模型在AC预测中 $R^2$ 为0.9044, DEN为0.8098,略逊于IB,说明BiGRU在时序建模中的作用更强;移除Inception模块后的BT模型性能下降最为明显,AC预测的 $R^2$ 仅为0.7645, DEN为0.8366,说明Inception模块对多尺度地质信息的提取至关重要;同时,在所有模型中,IBT的*RMSE*、*MAE*、*MAPE*值最小,说明本文模型不仅拟合能力强,而且预测误差低,表现最为稳定.

表5 A2井的IBT消融实验对比分析

测井曲线	模型名称	<i>RMSE</i>	<i>MAE</i>	<i>MAPE</i> (%)	$R^2$
AC	IB	3.2593	2.5069	2.7605	0.9052
	IT	3.2743	2.4992	2.7537	0.9044
	BT	5.1387	4.2021	4.5311	0.7645
	IBT	2.2704	1.6656	1.8286	0.9540
DEN	IB	0.0530	0.0395	1.6486	0.8414
	IT	0.0580	0.0413	1.7412	0.8098
	BT	0.0538	0.0389	1.6279	0.8366
	IBT	0.0364	0.0252	1.0576	0.9253

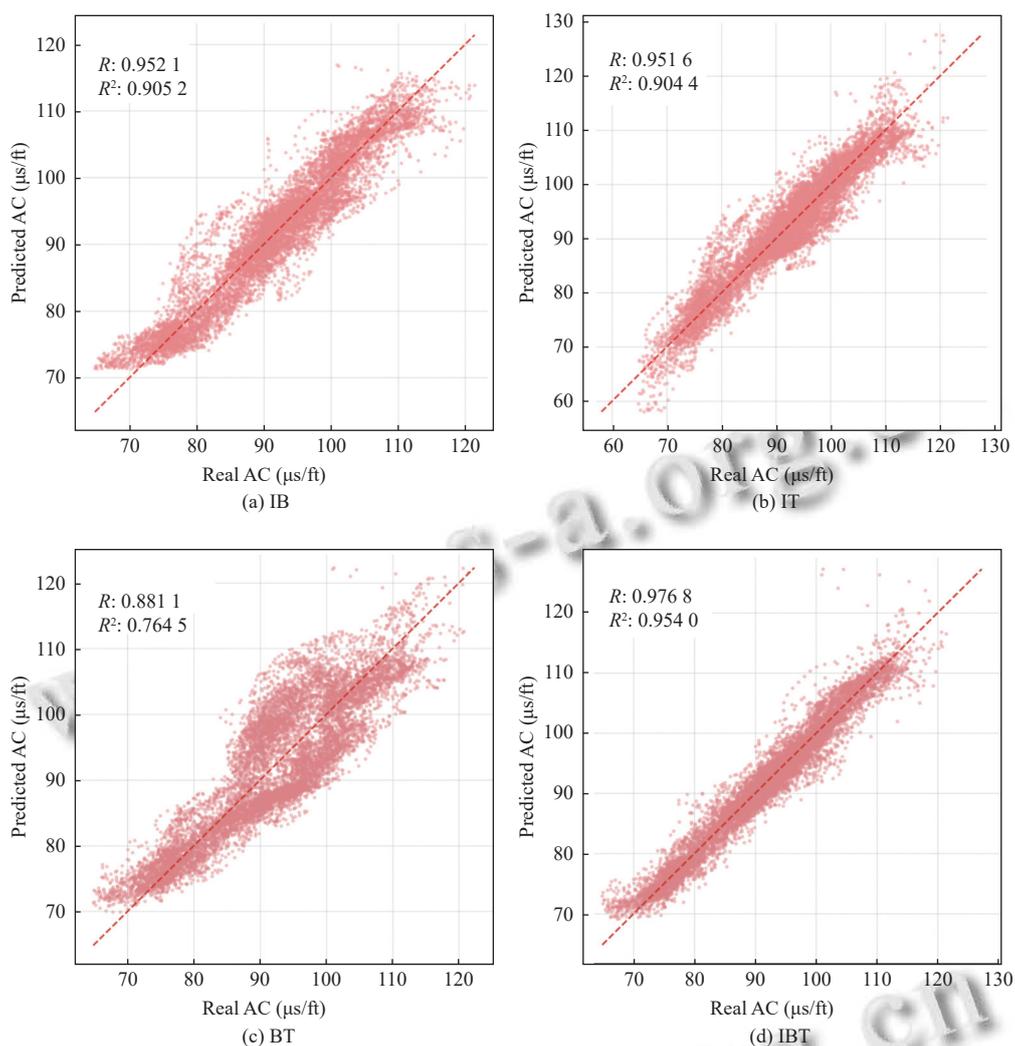


图 13 A2 井 AC 测井曲线的真实值和预测值散点图

图 13 进一步直观展示了各模型对 AC 曲线的拟合表现: IBT 模型 (图 13(d)) 预测点分布最为密集, 紧贴理想对角线, 说明模型预测值与真实值高度一致; IB 与 IT 模型 (图 13(a)、(b)) 点相对较为集中, 但边缘区域存在一定偏差; BT 模型 (图 13(c)) 预测点分布最为分散, 误差较大, 说明 Inception 缺失严重削弱了模型的特征提取能力。

图 14 直观展示了 DEN 曲线的预测效果: IBT 模型 (图 14(d)) 仍表现出最强拟合能力, 点整体沿对角线高度聚集; IB 与 BT 模型 (图 14(a)、(c)) 在  $2.3\text{--}2.6\text{ g/cm}^3$  范围内拟合效果尚可, 但在低密度区间偏差明显; IT 模型 (图 14(b)) 在多个区段存在较大离散, 拟合效果最差。

从地质特征角度看, Inception 模块所具备的多尺度感受野能够适应页岩储层中复杂的非均质结构 (如

夹层、裂缝带等), 提升模型对细粒尺度地质特征的表达能力。BiGRU 则针对测井数据沿深度方向的连续性与趋势变化建模, 尤其适用于多周期沉积序列的拟合。Transformer 编码器强化了全局依赖建模能力, 在页岩储层存在横向突变或深层潜伏异常响应时, 仍能保持预测稳定性。三者协同作用有效应对了页岩地层的“非线性+多尺度+远程相关”三重挑战。

综上, IBT 模型在各模块协同作用下显著提升了测井曲线重构的预测精度与稳定性。Inception 模块增强了模型对地质数据多尺度特征的捕捉能力, BiGRU 提升了时序建模表现, 而 Transformer 编码器则有效拓展了模型对长程依赖关系的建模能力。三者的融合使 IBT 模型在多目标重构任务中具备更强的泛化与表达能力。

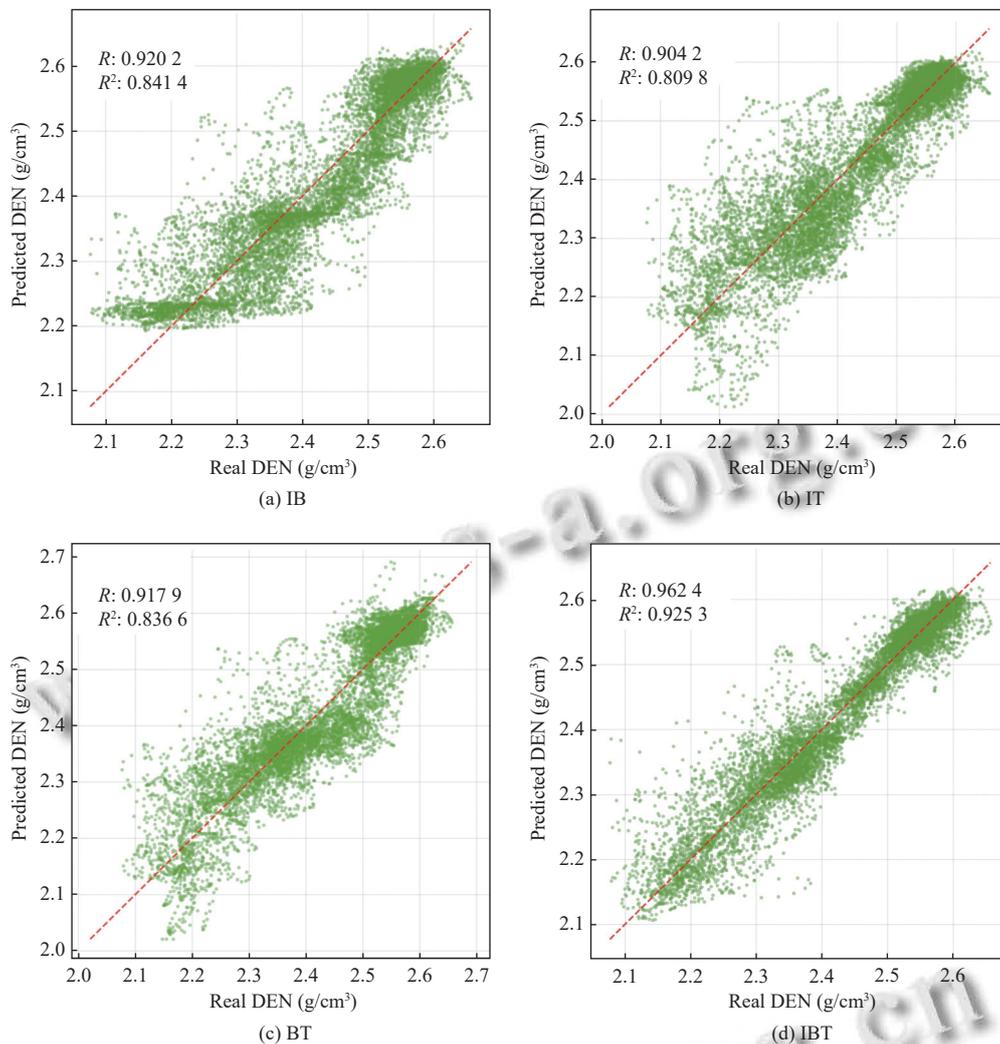


图 14 A2 井 DEN 测井曲线的真实值和预测值散点图

### 3.7 模型计算效率与工程实用性分析

尽管 IBT 模型在测井曲线重构任务中表现出优异的预测精度与泛化能力,但其结构中融合了 Inception、BiGRU 与多头注意力机制等计算模块,计算复杂度相较传统方法显著提高.因此,评估模型的训练时间、推理效率与部署成本,对其在实际工程场景中的应用可行性具有重要意义.

在统一实验条件下(训练轮数 150 轮,使用 NVIDIA RTX 4080 Super GPU),对 6 类代表性模型进行了训练耗时与推理延迟的对比实验.如表 6 所示,CNN 模型结构最简单、并行性强,训练最快( $\approx 0.75$  h), $R^2$  范围为 0.486–0.816,适合快速部署与简单场景,但对复杂储层的拟合能力有限.LSTM 模型在保持时序建模能力的同时具备较低计算负担( $\approx 1.2$  h), $R^2$  范围为 0.580–0.867,适用于对精度有中等要求的工程任务.GRU 模

型收敛速度快,训练耗时大致在 1.4 h, $R^2$  范围为 0.531–0.840,适合处理非平稳测井数据.BiGRU 模型双向建模能有效捕获上下文信息,训练耗时大致在 1.8 h, $R^2$  范围为 0.620–0.911,适合时序相关性强的储层数据建模.Inception-LSTM 模型融合多尺度卷积与时序特征建模,训练耗时大致在 2.3 h, $R^2$  范围为 0.674–0.923,在精度与效率之间取得较好平衡,适合需要多尺度特征提取的复杂场景.IBT 模型训练耗时最长( $\approx 4.0$  h),但拟合精度最高( $R^2$  范围为 0.873–0.954),特别是在页岩油储层这种非均质性强、层理结构复杂的环境下,展现出更强的实用价值.因此 IBT 的部署成本是可接受的.

## 4 结论与展望

本文针对页岩油勘探中常见的测井曲线缺失问题,提出了 IBT 深度神经网络模型,实现了测井曲线的高

精度重构. 通过融合 Inception 模块的多尺度特征提取能力、BiGRU 的双向时序建模能力及 Transformer 编码器的全局注意力机制, IBT 模型能够全面捕捉测井数据中的非线性关联和序列依赖. 在大庆古龙页岩油区的实际数据上开展的单目标 CNL、多目标 AC 与 DEN 测井曲线预测实验中, IBT 模型在 RMSE、MAE、MAPE 和  $R^2$  等评价指标上均优于其他对比模型. 消融实验表明, 这 3 大模块对模型性能均有显著提升, 验证了其设计合理性与有效性. 未来可将该模型进一步拓展至更多测井参数的联合预测.

表 6 各模型训练效率与工程适配性对比分析

模型	$R^2$	训练时长 (h)	工程场景简述
CNN	0.486–0.816	≈0.75	快速部署, 简单场景
LSTM	0.580–0.867	≈1.2	中等精度需求
GRU	0.531–0.840	≈1.4	收敛快, 适合非平稳数据
BiGRU	0.620–0.911	≈1.8	双向建模, 适合序列场景
Inception-LSTM	0.674–0.923	≈2.3	多尺度+时序特征建模
IBT	0.873–0.954	≈4.0	适用复杂储层建模

## 参考文献

- 孙龙德, 刘合, 何文渊, 等. 大庆古龙页岩油重大科学问题与研究路径探析. 石油勘探与开发, 2021, 48(3): 453–463. [doi: 10.11698/PED.2021.03.02]
- Akinnikawe O, Lyne S, Roberts J. Synthetic well log generation using machine learning techniques. Proceedings of the 2018 SPE/AAPG/SEG Unconventional Resources Technology Conference. Houston: URTEC, 2018. URTEC-2877021-MS. [doi: 10.15530/urtec-2018-2877021]
- Zhang DX, Chen YT, Meng J. Synthetic well logs generation via recurrent neural networks. Petroleum Exploration and Development, 2018, 45(4): 629–639. [doi: 10.1016/S1876-3804(18)30068-5]
- Shan LQ, Liu YC, Tang M, et al. CNN-BiLSTM hybrid neural networks with attention mechanism for well log prediction. Journal of Petroleum Science and Engineering, 2021, 205: 108838. [doi: 10.1016/j.petrol.2021.108838]
- 王俊瑞, 梁力文, 邓强, 等. 基于多元回归模型重构测井曲线的方法研究及应用. 岩性油气藏, 2016, 28(3): 113–120. [doi: 10.3969/j.issn.1673-8926.2016.03.015]
- Zhang HY, Wu WS, Song XY. Well logs reconstruction based on deep learning technology. IEEE Geoscience and Remote Sensing Letters, 2024, 21: 7501205. [doi: 10.1109/LGRS.2024.3354210]
- Li J, Xu T, Zhang WT, et al. A borehole porosity prediction method with focusing on local shape. Geoenergy Science and Engineering, 2023, 228: 211933. [doi: 10.1016/j.geoen.2023.211933]
- Bai Y, Tan MJ, Shi YJ, et al. Regression committee machine and petrophysical model jointly driven parameters prediction from wireline logs in tight sandstone reservoirs. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5900409. [doi: 10.1109/TGRS.2020.3041366]
- Chen YT, Zhang DX. Physics-constrained deep learning of geomechanical logs. IEEE Transactions on Geoscience and Remote Sensing, 2020, 58(8): 5932–5943. [doi: 10.1109/TGRS.2020.2973171]
- Wang J, Cao JX, Yuan S, et al. Spatiotemporal synergistic ensemble deep learning method and its application to S-wave velocity prediction. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 8024705.
- Zhou W, Zhao HH, Li XCZ, et al. Missing well logs reconstruction based on cascaded bidirectional long short-term memory network. Expert Systems with Applications, 2025, 259: 125270. [doi: 10.1016/j.eswa.2024.125270]
- Gowida A, Elkatatny S, Al-Afnan S, et al. New computational artificial intelligence models for generating synthetic formation bulk density logs while drilling. Sustainability, 2020, 12(2): 686. [doi: 10.3390/su12020686]
- 王俊, 曹俊兴, 尤加春, 等. 基于门控循环单元神经网络的储层孔渗饱参数预测. 石油物探, 2020, 59(4): 616–627. [doi: 10.3969/j.issn.1000-1441.2020.04.012]
- 王俊, 曹俊兴, 尤加春. 基于 GRU 神经网络的测井曲线重构. 石油地球物理勘探, 2020, 55(3): 510–520.
- 尚福华, 卢玉莹, 曹茂俊. 基于改进 LSTM 神经网络的测井曲线重构方法. 计算机技术与发展, 2022, 32(6): 198–202. [doi: 10.3969/j.issn.1673-629X.2022.06.033]
- Yang WB, Xia KW, Fan SR. Oil logging reservoir recognition based on TCN and SA-BiLSTM deep learning method. Engineering Applications of Artificial Intelligence, 2023, 121: 105950. [doi: 10.1016/j.engappai.2023.105950]
- Szegedy C, Liu W, Jia YQ, et al. Going deeper with convolutions. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston: IEEE, 2015. 1–9. [doi: 10.1109/CVPR.2015.7298594]
- Zhao ZN, Yun SN, Jia LY, et al. Hybrid VMD-CNN-GRU-based model for short-term forecasting of wind power considering spatio-temporal features. Engineering Applications of Artificial Intelligence, 2023, 121: 105982. [doi: 10.1016/j.engappai.2023.105982]
- 张朝龙, 罗来劲, 刘惠汉, 等. 基于增量能量法和 BiGRU-Dropout 的锂电池健康状态估计. 电子测量与仪器学报, 2023, 37(1): 167–176. [doi: 10.13382/j.jemi.B2205773]
- Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 6000–6010.

(校对责编: 张重毅)