

基于改进一维U-Net-BiLSTM的测井岩性识别方法研究

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11日; 录用日期: 2026年7月9日; 发布日期: 2026年7月17日

摘 要

针对测井岩性识别中深度上下文利用不足、类别分布不均衡以及随机样本划分易造成评价结果偏高等问题, 本文提出一种改进一维U-Net-BiLSTM岩性识别方法。以12口井7470条深度采样记录为研究对象, 选取CAL、GR、SP、LLD、LLS、AC、DEN和PEF等常规测井曲线作为基础输入, 并构造深浅电阻率比值、声波密度比值和伽马声波比值等辅助特征; 在数据清洗、缺失值插补、对数变换和归一化处理基础上, 采用按井划分方式构建训练集、验证集和独立测试集。所提模型以长度为64的多维测井序列窗口为输入, 实现窗口内各深度采样点的逐点岩性分类; 通过特征增强模块补充局部变化和统计特征, 利用多尺度一维卷积提取不同深度尺度下的测井响应模式, 并在瓶颈端结合BiLSTM和Transformer建模井深方向上下文关系, 同时通过注意力跳跃连接和DRSN解码模块融合多层级特征、抑制弱扰动。以J393和T251井作为独立测试井的实验结果表明, 本文模型在总体测试集上的Accuracy和Macro F1分别达到0.7565和0.6806, 优于SVM、MLP/BP、1D-CNN、LSTM、CNN-BiLSTM、Transformer、Vanilla 1D U-Net和Attention-TCN等对比模型。在分井测试结果中, 本文模型在J393井上的Accuracy和Macro F1分别为0.7838和0.7646, 在T251井上分别为0.7394和0.6495, 表明模型在不同测试井上均保持了较好的识别性能。岩性深度剖面对比进一步显示, 所提方法能够较好保持主要岩性层段的连续性, 在跨井岩性识别中具有较好的泛化能力和应用潜力。

关键词

测井岩性识别, 一维U-Net-BiLSTM, 按井划分, 类别不均衡

A Well-Log Lithology Identification Method Based on an Improved 1D U-Net-BiLSTM

Shuaiqian Liu

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

Received: June 11, 2026; accepted: July 9, 2026; published: July 17, 2026

Abstract

To address the problems of insufficient utilization of depth-wise contextual information, imbalanced lithology class distribution, and overestimated evaluation results caused by random sample splitting in well-log lithology identification, this study proposes an improved one-dimensional U-Net-BiLSTM lithology identification method. A dataset containing 7470 depth sampling records from 12 wells was used in this study. Conventional well-log curves, including CAL, GR, SP, LLD, LLS, AC, DEN, and PEF, were selected as the basic inputs, and auxiliary features such as the deep-to-shallow resistivity ratio, acoustic-density ratio, and gamma-ray acoustic ratio were constructed. After data cleaning, missing-value imputation, logarithmic transformation, and normalization, a well-wise splitting strategy was adopted to construct the training set, validation set, and independent test set. The proposed model takes a multidimensional well-log sequence window with a length of 64 as input and performs point-wise lithology classification for each depth sampling point within the window. Specifically, the feature enhancement module supplements local variation and statistical features, multi-scale one-dimensional convolutions are used to extract well-log response patterns at different depth scales, and BiLSTM and Transformer modules are combined at the bottleneck to model depth-wise contextual relationships. Meanwhile, attention-based skip connections and a DRSN decoding module are introduced to fuse multi-level features and suppress weak disturbances. Experimental results using wells J393 and T251 as independent test wells show that the proposed model achieves an overall Accuracy of 0.7565 and a Macro F1 of 0.6806 on the overall test set, outperforming comparison models including SVM, MLP/BP, 1D-CNN, LSTM, CNN-BiLSTM, Transformer, Vanilla 1D U-Net, and Attention-TCN. In the single-well test results, the proposed model achieves an Accuracy and Macro F1 of 0.7838 and 0.7646 on well J393, and 0.7394 and 0.6495 on well T251, respectively, indicating that the model maintains good recognition performance across different test wells. Lithology depth-profile comparisons further demonstrate that the proposed method can better preserve the continuity of major lithological intervals and has good generalization ability and application potential for cross-well lithology identification.

Keywords

Well-Log Lithology Identification, 1D U-Net-BiLSTM, Well-Wise Splitting, Class Imbalance

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

岩性识别是储层评价、油气勘探开发、地质建模和测井解释中的基础性工作，其结果直接影响储层类型划分、沉积相分析、有效储层预测以及后续开发方案制定。测井资料能够连续反映地下地层在井深方向上的物性、电性和放射性响应，是开展岩性解释的重要数据来源。已有研究表明，在页岩地层、火山岩储层和砂岩型铀矿钻孔等场景中，测井资料均是岩性识别与地层解释的重要依据[1]-[4]。传统岩性识别主要依赖测井解释人员结合自然伽马、电阻率、声波时差、密度等曲线特征进行人工判读，该方法对专业经验依赖较强。当井段较长、岩性组合复杂或薄互层发育时，人工解释不仅工作量较大，而且不同解释人员之间可能存在一定主观差异，影响岩性识别结果的一致性和稳定性。因此，利用机器学习和深度学习从测井曲线中自动提取岩性判别特征，对于提高测井解释效率和识别精度具有重要意义[5]-[7]。

近年来,随着数据驱动方法的发展,支持向量机、随机森林、集成学习、CatBoost 等机器学习方法已被应用于测井岩性分类任务。例如,支持向量机及其改进方法被用于复杂岩性和火山岩等测井岩性识别任务[8] [9],随机森林方法在地区测井岩性识别中取得了一定应用效果[10],面向非均衡数据的 ADASYN-CatBoost 方法和改进集成学习方法也被用于提升复杂岩性识别能力[11] [12]。这类方法能够在一定程度上建立测井响应与岩性类别之间的非线性映射关系,但其特征表达能力和深度序列建模能力相对有限。随后,卷积神经网络、循环神经网络、长短期记忆网络、注意力机制以及自编码器等深度学习模型逐渐被引入测井资料解释中。其中,深度卷积自编码器模型被用于岩性分类与识别任务[13],CNN 与 LSTM 结合的模型能够同时利用局部曲线形态和序列依赖关系[14],CNN-GRU、BiLSTM、BiLSTM-Attention 和增强多头注意力机制等模型进一步提高了测井曲线深度方向特征的表达能力[15]-[18]。此外,MSCNN-GRU 等多尺度序列模型也被用于测井曲线补全与岩性识别任务,体现出多尺度特征提取和序列建模在测井解释中的应用潜力[19]。上述方法推动了测井岩性识别由人工特征驱动向深度特征学习转变,但在复杂跨井识别条件下仍有改进空间。

现有测井岩性识别研究仍面临若干问题。首先,测井曲线沿井深方向连续变化,单个深度点的岩性不仅与该点测井响应有关,也与其上、下邻近地层的曲线变化趋势密切相关,单点分类方法难以充分利用深度上下文信息。其次,实际测井数据中不同岩性类别样本数量往往不均衡,多数类岩性容易主导模型训练过程,仅采用 Accuracy 评价模型性能可能掩盖少数类岩性的识别不足。最后,在薄互层、岩性过渡段和测井响应相近的岩性类别之间,模型容易出现边界偏移和局部错判。因此,岩性识别模型不仅需要提高整体分类正确率,还需要具备较好的深度序列建模能力、类别均衡识别能力和跨井泛化能力。

2. 数据集与预处理

2.1. 数据集说明

本文采用多井测井岩性数据集开展岩性识别实验。数据集包含 12 口井、7470 条深度采样记录,每条记录由井深信息、常规测井曲线和岩性标签组成。原始数据字段包括 TopDepth、BotDepth、_CAL、_GR、_SP、_LLD、_LLS、_AC、_DEN、_PEF、Lith_Section 和 Well,其中 TopDepth 表示采样点顶部深度,BotDepth 表示采样点底部深度,Well 表示井名,Lith_Section 为岩性类别标签。

数据集岩性类别包括泥岩、粉砂质泥岩、泥质粉砂岩、粉砂岩和油页岩 5 类。不同岩性在样本数量和累计厚度上存在明显差异,如图 1 所示。泥岩样本数量最多,共 3636 个样本,累计厚度占比为 58.2%;粉砂岩、粉砂质泥岩和泥质粉砂岩分别具有一定数量的样本分布,而油页岩仅有 85 个样本,累计厚度占比为 1.6%。这表明该数据集具有较明显的类别不均衡特征。

2.2. 数据清洗与特征构造

为降低异常值和缺失值对模型训练的影响,本文首先对原始测井数据进行清洗。对输入测井曲线中的明显异常值进行处理,小于 0 或等于-9999 的测井值被视为无效值,井径_CAL 中小于或等于 0 的数值、密度_DEN 中小于 1 的数值也被视为异常值并置为空值。随后,按照井名和深度对数据进行排序,以保持同一口井内测井曲线沿深度方向的连续性,对于每口井内部存在的缺失测井值,采用线性插值方法进行补全,对于插值后仍存在的残余缺失值,则使用对应测井曲线的中位数进行填补,该处理方式能够在尽量保留井内深度变化趋势的同时,减少异常测井值对模型训练过程的干扰。

不同岩性的测井响应分布如图 2 所示,各曲线含义如表 1 所示。从箱线图可以看出,不同岩性在 GR、LLD、LLS、AC、DEN 等曲线上具有一定差异,这说明常规测井曲线中包含可用于岩性区分的有效信息,但不同类别之间仍存在分布重叠,特别是粉砂质泥岩、泥质粉砂岩和粉砂岩等相近岩性之间的测井响应




Figure 1. Lithology sample counts and cumulative thickness proportions of the dataset

图 1.数据集岩性样本数量与累计厚度占比

Table 1. Description of input well-log curve features

表 1. 测井曲线输入特征说明

特征	含义	主要作用
CAL	井径	反映井眼变化及井壁稳定性
GR	自然伽马	反映泥质含量，辅助区分砂泥岩
SP	自然电位	反映渗透性及岩性变化
LLD	深侧向电阻率	反映深部地层电性响应
LLS	浅侧向电阻率	反映近井地带电性响应
AC	声波时差	反映岩石骨架和孔隙结构特征
DEN	密度	反映岩石体积密度差异
PEF	光电吸收截面指数	辅助表征矿物组成差异

差异并非完全线性可分。因此，岩性识别模型需要同时利用多条测井曲线及其沿深度方向的变化特征，而不能仅依赖单一曲线或单点测井值进行判断。

考虑到电阻率类曲线和部分测井响应可能具有较大的动态范围，本文对_LLD、_LLS 和_PEF 进行log₁₀对数变换，以削弱极端值对模型参数更新的影响，提升不同测井曲线之间的数值可比性。在此基础上，进一步构造 3 个具有物理含义的比率特征，包括深浅侧向电阻率比值、声波密度比值和伽马声波比值。深浅侧向电阻率比值用于表征深浅探测范围内电阻率响应的相对变化，能够反映流体性质、侵入影响及岩性差异；声波密度比值用于刻画声波传播特征与岩石密度之间的关系；伽马声波比值则从泥质含量响应和声波响应的相对关系出发，增强模型对砂泥岩差异的表达能力。经过上述特征构造后，模型输入维度由 8 维扩展为 11 维。

在特征归一化方面，本文先在单井内部对测井特征进行标准化处理，以减弱不同井之间测井量纲和幅值差异的影响，随后在样本构建阶段，使用训练井数据拟合 RobustScaler，并将同一缩放规则应用于验证井和测试井。由于 RobustScaler 对异常值相对不敏感，该方法有助于提高跨井输入特征分布的一致性。同时，使用窗口级归一化，使每个输入窗口内部的测井序列具有更稳定的数值范围，从而降低局部幅值差异对序列分类模型训练的影响。




Figure 2. Boxplots of well-log curves for different lithologies
图 2. 不同岩性的测井曲线箱线图

2.3. 按井划分与样本构建

为避免随机划分导致相邻深度样本同时出现在训练集和测试集中，从而造成数据泄漏和模型性能虚高，本文采用按井划分方式构建训练集、验证集和测试集。具体而言，训练井包括 G43、G921、G933、G96、T252、X78、X73 和 G39，验证井包括 J392 和 G94，测试井包括 J393 和 T251。测试井在模型训练、参数更新和模型选择过程中均不可见，仅用于最终评价模型在独立井上的岩性识别能力。因此，该划分方式比随机样本划分更接近实际盲井预测场景，能够更合理地检验模型跨井泛化能力。

不同井的岩性样本数和比例构成如图 3 所示。可以看出，不同井之间的岩性组合并不完全一致，部分井以泥岩为主，部分井中粉砂岩或过渡岩性占比较高，油页岩则在各井中整体分布较少。这种井间岩性组成差异说明，模型在测试井上的预测并不是简单地重复训练集中相同分布下的分类规律，而需要面对不同井之间测井响应和岩性组合变化带来的泛化挑战。因此，在本文实验中采用独立测试井 J393 和 T251 进行评价，能够更好地反映模型在跨井岩性识别任务中的实际应用能力。

在样本构建方面，本文采用长度为 64 的滑动窗口将连续测井曲线划分为序列样本。与单点分类方法不同，本文模型输入为一个包含 64 个连续深度采样点的多维测井序列，输出为该窗口内每个深度采样点对应的岩性类别，实现序列到序列的逐点岩性识别。训练阶段滑动窗口步长设置为 4，以减少样本高度重叠带来的冗余，验证和测试阶段步长设置为 1，以保证对整口井深度序列进行更细致、连续的预测。通过这种样本构建方式，模型能够同时利用目标深度点及其上下邻近地层的测井响应信息，从而更好地刻画岩性沿井深方向的连续变化特征。

3. 改进一维 U-Net-BiLSTM 岩性识别方法

3.1. 模型总体结构

针对测井曲线沿井深方向连续变化、岩性类别边界不清晰以及跨井识别难度较高等问题，本文构建了一种改进一维 U-Net-BiLSTM 岩性识别模型。模型以滑动窗口测井序列为输入，以窗口内各深度




Figure 3. Lithology sample counts and proportional composition of different wells
图 3. 不同井的岩性样本数和比例构成

采样点的岩性类别为输出，属于序列到序列的岩性分类方法，与单点分类方法不同，模型不仅利用当前深度点的测井响应，还综合考虑其上、下邻近深度范围内的曲线变化特征，从而增强模型对连续地层响应和岩性过渡关系的表达能力。

本文模型总体结构如图 4 所示。模型输入为长度为 64 的多维测井序列，输入通道由常规测井曲线和构造特征共同组成。原始测井曲线包括 CAL、GR、SP、LLD、LLS、DEN、AC 和 PEF，同时引入深浅电阻率比值、声波密度比值和伽马声波比值等比率特征，使输入特征维度扩展为 11 维。经过特征增强




Figure 4. Overall architecture of the improved 1D U-Net-BiLSTM lithology identification model
图 4. 改进一维 U-Net-BiLSTM 岩性识别模型总体结构图

模块后，输入序列被映射为适合深度网络处理的高维表示。随后，模型采用一维 U-Net 编码 - 解码结构进行多尺度特征提取：编码端通过逐级下采样提取不同深度尺度下的测井响应特征；瓶颈端结合卷积块、BiLSTM 和 Transformer 模块进一步建模深度方向上下文关系；解码端通过逐级上采样恢复序列长度，并利用注意力跳跃连接融合浅层细节信息与深层语义信息。最后，分类头通过 1×1 一维卷积和 Softmax 函数输出窗口内每个深度点对应各岩性类别的概率分布。

设输入测井窗口为：

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

其中， $L = 64$ 表示窗口长度， $C = 11$ 表示输入特征维度。模型输出为：

$$P \in \mathbb{R}^{L \times K} \quad (2)$$

其中， K 为岩性类别数， $P_{i,k}$ 表示第 i 个深度采样点属于第 k 类岩性的预测概率。最终岩性类别由最大概率对应的类别确定：

$$\hat{y}_i = \arg \max_k P_{i,k} \quad (3)$$

因此，本文方法不是对窗口中心点进行单点预测，而是对整个窗口内的深度序列进行逐点岩性识别，更适合描述岩性在井深方向上的连续分布特征。

3.2. 特征增强与多尺度编码模块

测井曲线具有明显的深度序列属性，不同岩性通常表现为多条测井曲线在局部形态、变化趋势和相对幅值上的综合差异。仅直接使用原始测井值作为模型输入，可能难以充分表达岩性边界、薄互层和局部突变等复杂信息。为此，本文在模型前端设置特征增强模块，对输入测井序列进行特征扩展。

特征增强模块主要从三个角度构造序列特征。首先，保留原始测井曲线，以提供各深度点的基础地球物理响应。其次，引入一阶差分和二阶差分特征，用于描述测井曲线沿深度方向的变化速度和局部弯曲程度。一阶差分能够反映相邻深度采样点之间的响应变化，二阶差分则有助于刻画局部突变和层段转换特征。再次，引入滑动均值和滑动标准差，用于表达局部窗口内测井响应的平均水平和波动强度。滑动均值可以减弱局部噪声影响，滑动标准差则能够反映岩性变化区域的曲线离散程度。此外，模块中加入可学习位置编码，使模型能够感知不同采样点在窗口序列中的相对位置，避免仅依赖通道特征而忽略深度顺序信息。

在完成特征增强后，模型进入 U-Net 编码端。编码端采用多尺度空洞卷积块提取深度方向特征。与普通一维卷积相比，空洞卷积能够在不显著增加参数量的情况下扩大感受野，使模型同时关注近邻深度点和相对较长范围内的层段变化。由于测井响应既可能在岩性边界处出现快速变化，也可能在连续层段内呈现缓慢变化，仅使用单一尺度卷积难以兼顾不同厚度地层的响应特征。因此，本文在编码块中设置不同感受野的卷积分支，并通过特征融合获得多尺度表示。

从图 4 可以看出，编码过程沿深度方向逐级下采样，序列长度由 64 依次变为 32、16 和 8，通道数则逐渐增加。这样的设计使浅层编码特征更侧重于局部曲线形态和岩性边界细节，深层编码特征更侧重于层段级语义信息和相对稳定的岩性组合特征。通过多尺度编码，模型能够从不同深度尺度上理解测井曲线变化，为后续上下文建模和岩性分类提供更充分的特征基础。

3.3. BiLSTM 上下文建模与注意力跳跃连接

岩性识别不仅依赖某一深度点的测井响应，还与其上覆和下伏地层的连续变化密切相关。例如，在岩性过渡段或薄互层发育区域，单个深度点的测井响应可能与相邻岩性具有相似特征，容易造成分类混

淆。为了利用井深方向的上下文信息，本文在 U-Net 瓶颈端引入 BiLSTM 模块，对编码后的深层特征进行双向序列建模。

BiLSTM 由正向 LSTM 和反向 LSTM 组成，能够同时从浅到深和从深到浅两个方向提取序列依赖关系。对于测井岩性识别任务而言，正向分支可以学习上覆地层到当前深度点的变化趋势，反向分支可以补充下伏地层对当前深度点的约束信息。两类上下文信息共同作用，有助于模型在岩性边界、层段转换和曲线响应相近区域作出更稳定的判断。相比仅依赖卷积结构的局部特征提取方式，BiLSTM 更适合描述测井曲线沿深度方向的连续演化特征。

在 BiLSTM 之后，模型进一步通过 Transformer 模块补充全局依赖建模能力。BiLSTM 侧重于顺序递推关系，而 Transformer 中的自注意力机制能够从整体窗口范围内衡量不同深度位置之间的相关性，二者结合可以使瓶颈特征同时包含局部连续上下文和较长范围的层段关联信息，从而提高模型对复杂测井响应模式的表达能力。

在解码阶段，U-Net 通常通过跳跃连接将编码端特征传递到解码端，以弥补下采样造成的细节损失。然而，简单拼接浅层特征和深层特征可能引入冗余响应，尤其是在测井曲线存在局部噪声、非岩性因素扰动或不同尺度特征不一致时，直接融合可能影响岩性边界判断。为此，本文采用注意力残差融合方式对多层级特征进行自适应选择。该结构将不同尺度的编码特征、瓶颈特征以及解码过程中的中间特征统一映射到目标尺度，并通过注意力权重计算不同来源特征的重要性，这样既能保留浅层曲线细节，又能突出深层语义信息，使解码端在恢复序列长度的同时获得更有效的跨层特征表达。

3.4. DRSN 解码模块与分类输出

解码端的主要作用是将瓶颈层获得的深层语义特征逐步恢复到原始窗口长度，并结合跳跃连接传递的浅层细节信息，生成每个深度采样点的岩性预测结果。在测井数据中，浅层特征往往包含丰富的局部曲线形态信息，但同时也可能包含井眼环境、测量误差和局部异常值引起的弱响应扰动。若这些弱扰动在解码阶段被不断放大，可能会影响岩性边界附近和薄互层区域的分类稳定性。

为增强解码阶段对有效特征的表达能力，本文在浅层解码模块中引入 DRSN 结构。DRSN 的核心思想是通过可学习软阈值机制对特征响应进行收缩处理。对于卷积提取到的特征，首先根据通道统计信息生成自适应阈值，然后对幅值较小的弱响应进行抑制，对幅值较大的有效响应进行保留。其基本形式可表示为：

$$\tilde{x} = \text{sign}(x) \cdot \max(|x| - \tau, 0) \quad (4)$$

其中， x 表示输入特征， τ 表示由网络自适应学习得到的阈值， $\tilde{x}$ 表示收缩后的特征。该机制的设计目的在于降低弱噪声响应对分类结果的干扰，同时保留对岩性边界和层段变化更有判别意义的强响应特征。

本文在浅层的 d1 和 d2 解码阶段使用 DRSN-CB 模块，而在更深层的 d3 和 d4 阶段仍采用标准卷积块。这样的设置主要考虑到浅层解码特征更接近最终输出，包含更多局部细节和边界信息，同时也更容易受到局部波动影响；在该阶段引入软阈值收缩，有助于提高输出岩性序列的平滑性和边界表达能力。需要说明的是，本文未对 DRSN 模块进行独立消融实验，因此不单独评估其对性能提升的贡献，该模块仅作为整体结构模块对性能提升的独立贡献。

最终，解码端输出恢复为与输入窗口相同的序列长度。分类头采用 1×1 一维卷积将解码特征映射到岩性类别空间，并通过 Softmax 函数得到每个深度采样点属于各岩性类别的概率。由于 1×1 卷积仅在通道维度上完成类别映射，不改变深度序列长度，因此能够保持输入窗口与输出岩性序列之间的一一对应关系。模型训练时，以窗口内全部深度点的真实岩性标签作为监督信号，使网络学习从多维测井序列到

岩性序列的端到端映射关系。

4. 实验设计

4.1. 实验设置

本文以长度为 64 的滑动窗口构建测井序列样本，模型输入为多维测井曲线序列，输出为窗口内各深度采样点对应的岩性类别。为保证不同模型之间的可比性，所有深度学习模型均基于相同的数据划分、输入特征和预处理结果进行训练与测试，训练过程中采用的主要参数设置如表 2 所示。

Table 2. Main experimental parameter settings

表 2. 主要实验参数设置

参数	取值
窗口长度	64
Batch size	64
初始学习率	5×10^{-4}
Weight decay	1×10^{-3}
最大训练轮数	300
Early stopping patience	65
优化器	AdamW
学习率调度策略	Cosine Annealing

4.2. 对比模型

为全面评价本文方法的识别性能，选取 SVM、MLP/BP、1D-CNN、Vanilla 1D U-Net、LSTM、CNN-BiLSTM、Transformer、Attention-TCN 对比模型说明如表 3 所示。

Table 3. Settings of comparison models

表 3. 对比模型设置

模型类型	对比模型	作用
传统机器学习	SVM	基础分类器对比
浅层神经网络	MLP/BP	非序列神经网络对比
卷积模型	1D-CNN	局部特征提取对比
编码器 - 解码器模型	Vanilla 1D U-Net	基础 U-Net 结构对比
序列模型	LSTM	深度方向时序建模对比
融合序列模型	CNN-BiLSTM	局部卷积与双向序列建模对比
注意力/时序模型	Transformer、Attention-TCN	注意力建模与时序卷积对比
本文模型	Ours	改进一维 U-Net-BiLSTM

4.3. 评价指标

本文采用 Accuracy 和 Macro F1 作为主要评价指标，并结合 Precision、Recall 和 F1-score 对不同岩性类别的识别效果进行辅助分析，评价指标说明如表 4 所示。

Table 4. Description of evaluation metrics
表 4. 评价指标说明

指标	含义	作用
Accuracy	总体分类准确率	衡量整体预测正确比例
Precision	查准率	衡量预测为某类样本的可靠性
Recall	召回率	衡量某类真实样本被识别出的比例
F1-score	Precision 与 Recall 的调和平均	综合评价单类识别效果
Macro F1	各类别 F1-score 的宏平均	适合类别不平衡条件下的综合评价

综上，Accuracy 用于评价模型整体识别正确率，Macro F1 用于评价模型对各岩性类别的均衡识别能力，二者结合能够更全面地反映模型在独立测试井上的分类性能。

5. 结果与分析

5.1. 总体识别性能对比




Figure 5. Comparison of Accuracy and Macro F1 among different models on the J393 well, T251 well, and overall test set
图 5. 不同模型在 J393、T251 单井及总体测试集上的 Accuracy 与 Macro F1 对比

图 5 给出了不同模型在 J393、T251 两口测试井以及总体测试集上的 Accuracy 和 Macro F1 对比结果。从整体趋势来看，不同模型在两项指标上表现出较明显差异，说明模型结构对测井岩性识别效果具有重要影响。传统机器学习模型 SVM 以及浅层神经网络 MLP/BP 虽然能够利用测井曲线特征进行基本分类，但其对井深方向上下文信息的建模能力有限，难以充分表达岩性层段在纵向上的连续变化特征。

与传统模型相比深度学习方法能够从测井序列中自动提取更具判别性的非线性特征。其中，1D-CNN 能捕捉局部窗口内的曲线变化模式，但对长距离上下文关系的表达能力有限；LSTM 能建模序列依赖关系，但缺少多尺度局部特征提取结构。CNN-BiLSTM 同时利用局部卷积特征和双向序列信息，总体表现

优于单一卷积或单一循环网络。Vanilla 1D U-Net 通过编码 - 解码结构保留多尺度特征，在逐点分类任务中具有一定优势；Attention-TCN 则利用时序卷积和注意力机制增强了深度方向特征表达能力。




Figure 6. Comparison of Accuracy and Macro F1 of different models on the overall test set

图 6.不同模型在总体测试集上的 Accuracy 与 Macro F1 对比

从图 6 总体测试结果看，本文模型取得了最优综合性能，总体 Accuracy 达到 0.7565，总体 Macro F1 达到 0.6806，在所列对比模型中均为最高。相比 Attention-TCN，本文模型的 Overall Acc 从 0.7440 提升至 0.7565，Overall Macro F1 从 0.6405 提升至 0.6806，相比 Vanilla 1D U-Net，本文模型在总体准确率和宏平均 F1 上也均有提升。

在各类深度学习基线模型中，Transformer 模型的识别性能未表现出明显优势。其原因可能与测井岩性识别任务的数据规模、序列长度和特征结构有关。一方面，本文数据集总样本量相对有限，且采用按井划分方式进行训练和测试，测试井在模型训练过程中不可见，因此模型不仅需要学习测井曲线与岩性之间的非线性映射关系，还需要具备较强的跨井泛化能力。纯 Transformer 主要依赖自注意力机制从数据中学习不同深度位置之间的相关关系，当训练样本规模有限、岩性类别分布不均衡且井间响应存在差异时，模型容易受到样本分布变化的影响，难以充分学习稳定的局部岩性响应模式。

另一方面，测井曲线岩性识别具有明显的局部连续性和多尺度变化特征。岩性边界、薄互层和过渡段往往表现为 GR、AC、DEN、电阻率等曲线在局部深度范围内的连续变化或突变。相比纯 Transformer，卷积结构具有更强的局部特征提取能力，能够更直接地捕捉邻近深度点之间的曲线形态变化；BiLSTM 则能够进一步建模井深方向的正反向连续依赖关系。本文模型通过多尺度一维卷积提取局部与层段级测井响应特征，并结合 BiLSTM 和 Transformer 进行上下文建模，因此在小样本、类别不均衡和跨井测试条件下表现更稳定。换言之，Transformer 基线表现相对不足并不说明自注意力机制无效，而是表明在本文任务中，单独使用自注意力结构缺少局部卷积归纳偏置和连续序列建模约束，难以充分适应测井曲线岩性

识别的局部 - 全局联合判别需求。

5.2. 单井识别结果分析




Figure 7. Comparison of Accuracy and Macro F1 among different models on well J393

图 7. J393 井不同模型 Accuracy 与 Macro F1 对比

为了进一步分析模型在不同测试井上的泛化能力，本文分别统计了 J393 和 T251 两口测试井的单井识别结果。图 7 展示了 J393 井上不同模型的 Accuracy 和 Macro F1 对比结果。从图中可以看出，本文模型在 J393 井上取得了最优识别性能，Accuracy 为 0.7838，Macro F1 为 0.7646，两个指标均高于其他对比模型。

从模型类型上看，SVM、MLP/BP 等方法在 J393 井上的 Macro F1 相对较低，说明其对部分类别的识别存在不足。1D-CNN 和 LSTM 分别侧重局部特征和序列关系，但单独使用时难以同时兼顾岩性边界细节和上下文约束。Vanilla 1D U-Net 和 Attention-TCN 在 J393 井上的表现相对较好，说明多尺度结构和时序建模对该井岩性识别具有积极作用。

图 8 展示了 T251 井上的单井识别结果。与 J393 井相比，T251 井上各模型的 Macro F1 整体偏低，说明该井岩性识别难度更大。本文模型在 T251 井上的 Accuracy 为 0.7394，Macro F1 为 0.6495，在对比模型中表现最优。虽然 T251 井上的 Macro F1 低于 J393 井，但本文模型仍保持了较高的总体识别水平，说明其不同测试井之间具有一定稳定性。

J393 和 T251 两口井的结果差异表明，不同井之间的测井响应特征、岩性组合、层段厚度以及岩性边界发育情况可能存在明显差异。对于跨井岩性识别任务而言，模型不仅需要学习训练井中的曲线 - 岩性对应关系，还需要具备迁移到未参与训练井的泛化能力，T251 井结果相对偏低，可能与该井岩性组合更

复杂、薄互层发育程度更高或测井响应重叠更明显有关。在这种情况下，单纯依赖局部曲线特征的模型容易出现类别混淆，而本文模型通过综合利用局部多尺度特征和上下文序列信息进行建模。




Figure 8. Comparison of Accuracy and Macro F1 among different models on well T251

图 8. T251 井不同模型 Accuracy 与 Macro F1 对比

5.3. 岩性深度剖面预测结果分析

除数值指标外，岩性深度剖面对比能够更直观地反映模型预测结果是否符合测井解释中的层段连续性要求。图 9 给出了 J393 井真实岩性列与不同模型预测岩性列随深度变化的对比结果。图中纵轴为 Depth，不同颜色代表不同岩性类别。与单一 Accuracy 或 Macro F1 指标相比，深度剖面图能够直接观察模型是否在连续岩性段保持稳定预测，是否在岩性边界或薄互层发育区出现频繁错判，因此具有更强的地质解释意义。

从 J393 井剖面对比结果可以看出，不同模型在深度方向上的预测连续性存在明显差异。部分传统模型和浅层模型容易出现局部零散预测，即在真实岩性相对连续的井段中出现较多不连续色块，说明模型对岩性层段整体结构的保持能力不足。卷积类和序列类深度学习模型能够在一定程度上改善这一问题，但在薄互层或岩性快速变化区域仍可能出现边界偏移和局部错判。相比之下，本文模型在整体剖面上更接近真实岩性列，能够较好保持主要岩性段的连续分布特征，并在部分岩性变化位置表现出更稳定的追踪能力。

图 10 展示了 T251 井的岩性深度剖面对比结果。与 J393 井相比，T251 井深度范围更大，样本数量更多，岩性变化可能更加复杂。从图中可以看出，不同模型在该井上的预测差异更加明显。部分模型在连续层段中出现较多离散预测，说明其对井深方向岩性连续性的约束不足；部分模型虽然能够识别主要岩性段，但在岩性边界附近仍存在一定偏移，反映出薄层变化和过渡带仍是测井岩性识别中的难点。



Figure 9. Comparison of true lithology and lithology predictions of different models along depth in well J393

图 9. J393 井真实岩性与不同模型预测岩性随深度变化的剖面对比

本文模型在 T251 井上仍能够保持相对较好的预测连续性和层段一致性,说明其不仅依赖单点测井响应进行分类,而是能够结合窗口内上下文信息进行综合判断。在实际应用中,岩性解释并不是孤立地判断某一个采样点,而是需要结合上下层位变化、曲线形态趋势以及邻近层段响应特征进行连续解释。

模型在薄互层、岩性边界和测井响应相近的岩性之间仍可能发生错判,这类区域通常对应岩性快速变化或测井曲线响应过渡段,不同岩性在 GR、电阻率、声波时差、密度等曲线上可能表现出重叠特征,后续研究可进一步结合岩性先验约束、层序信息或更精细的边界损失函数,以提高模型对薄层和过渡段的识别能力。

5.4. 类别不均衡处理分析

由于本文数据集中不同岩性类别样本数量差异明显,其中油页岩样本数量较少,容易导致模型训练过程偏向多数类岩性。前文数据统计已表明,油页岩仅占较小比例,数据集具有明显类别不均衡特征。为进一步验证不同不均衡处理策略对岩性识别结果的影响,本文在保持模型结构、数据划分、输入特征和训练参数一致的条件下,对普通交叉熵损失、加权交叉熵损失、Focal Loss、少数类过采样结合交叉熵




Figure 10. Comparison of true lithology and lithology predictions of different models along depth in well T251

图 10. T251 井真实岩性与不同模型预测岩性随深度变化的剖面对比

Table 5. Comparison of recognition performance under different class imbalance handling strategies

表 5. 不同类别不均衡处理策略的识别性能对比

不均衡处理策略	Overall Acc	Macro F1	泥质粉砂岩 F1	泥岩 F1	油页岩 Recall	油页岩 F1	粉砂岩 F1	粉砂质 泥岩 F1
CE	0.7346	0.6232	0.4252	0.8854	0.4286	0.5000	0.7778	0.5275
WCE	0.7304	0.6594	0.4173	0.8778	0.7143	0.6667	0.7759	0.5592
Focal Loss	0.7513	0.6431	0.4508	0.8843	0.4286	0.5455	0.8226	0.5122
Oversampling + CE	0.7503	0.5757	0.4171	0.8863	0.1429	0.2500	0.8088	0.5163
Ours	0.7534	0.6743	0.4724	0.8931	0.7143	0.6667	0.8012	0.5382

损失以及本文采用的联合损失策略进行对比实验，结果如表 5 所示。

由表 5 可以看出，普通 CE 的 Overall Acc 为 0.7346，Macro F1 为 0.6232，油页岩 Recall 和 F1 分别为 0.4286 和 0.5000，说明在类别分布不均衡条件下，模型容易受到多数类样本主导，对少数类岩性的识别能力不足。WCE 将油页岩 Recall 和 F1 提高至 0.7143 和 0.6667，但 Overall Acc 略有下降，表明单纯类别加权虽然能够增强少数类关注程度，但可能影响整体分类稳定性。Focal Loss 的 Overall Acc 达到 0.7513，但 Macro F1 低于 WCE 和本文方法，说明其对难分类样本有一定改善作用，但类别均衡识别能力仍有限。

少数类过采样结合 CE 的 Overall Acc 为 0.7503，但 Macro F1 仅为 0.5757，油页岩 Recall 和 F1 分别下降至 0.1429 和 0.2500，说明简单重复采样并未稳定提升少数类识别效果。相比之下，本文联合损失策略取得了最优综合性能，Overall Acc 和 Macro F1 分别达到 0.7534 和 0.6743，同时在油页岩 Recall、油页岩 F1、泥质粉砂岩 F1 和泥岩 F1 上均表现较好，说明该策略能够在保持整体识别性能的同时，提高模型对少数类和易混淆岩性的均衡识别能力。

为进一步分析数据层面过采样策略的影响，本文以油页岩为主要少数类对象，对包含油页岩采样点的训练窗口设置 2、4、8 和 12 四种过采样倍数。该操作仅作用于训练集，验证井和测试井保持原始类别分布不变，以保证实验结果能够反映模型在真实跨井预测场景下的泛化能力，结果如表 6 所示。

Table 6. Effect of window-level oversampling intensity for oil shale on recognition performance
表 6. 油页岩窗口级过采样强度对识别性能的影响

过采样倍数	Overall Acc	Macro F1	泥质粉砂岩 F1	泥岩 F1	油页岩 Recall	油页岩 F1	粉砂岩 F1	粉砂质泥岩 F1
2	0.7304	0.6344	0.3846	0.8788	0.5714	0.6154	0.7890	0.5042
4	0.7440	0.6576	0.3410	0.8903	0.7143	0.7143	0.7932	0.5495
8	0.7429	0.6232	0.4206	0.8795	0.5714	0.5333	0.8000	0.4828
12	0.7482	0.6683	0.3610	0.8846	0.7143	0.7692	0.8179	0.5089

由表 6 可以看出，窗口级过采样强度对模型性能具有影响，2 倍过采样时，模型 Macro F1 为 0.6344，油页岩 F1 为 0.6154，说明低强度过采样对少数类识别有一定帮助，但提升有限，4 倍过采样后，Macro F1 提高至 0.6576，油页岩 Recall 和 F1 均达到 0.7143，表明适度增加含油页岩窗口的采样概率有助于缓解多数类主导问题。

当过采样倍数提高到 8 时，Macro F1 降至 0.6232，油页岩 F1 也降至 0.5333，说明过采样强度并非越高越好。过高的窗口级重复采样可能使模型过度关注少数类所在的局部层段，从而削弱其对其他过渡岩性和跨井层段变化规律的泛化能力。12 倍过采样取得了本组过采样实验中的最高 Overall Acc、Macro F1 和油页岩 F1，分别为 0.7482、0.6683 和 0.7692，但泥质粉砂岩 F1 仅为 0.3610，说明其虽然强化了油页岩识别，但对部分砂泥过渡岩性的判别稳定性仍有影响。

总体来看，单纯数据层面的窗口级过采样能够改善油页岩等少数类岩性的识别效果，但性能对采样倍数较为敏感，且容易引起不同类别之间的指标波动。相比之下，本文联合损失策略在 Overall Acc、Macro F1 和少数类识别效果之间取得了更好的平衡，验证了其在跨井岩性识别任务中的有效性。

参考文献

- [1] 陈秀娟, 冯镇涛, 曾芙蓉, 等. 页岩地层测井岩性识别技术发展现状[J]. 新疆石油地质, 2024, 45(6): 742-752.
- [2] 张莹, 潘保芝. 支持向量机与微电阻率成像测井识别火山岩岩性[J]. 物探与化探, 2011, 35(5): 634-638, 642.

- [3] 尚亚洲, 张兆辉, 许多年, 等. 基于随机森林的火山岩岩性测井识别——以准噶尔盆地滴西地区石炭系为例[J]. 物探与化探, 2024, 48(4): 1025-1036.
- [4] 段忠义, 肖昆, 杨亚新, 等. 松辽盆地砂岩型铀矿钻孔岩性的测井识别[J]. 地球物理学进展, 2023, 38(6): 2490-2501.
- [5] 安鹏, 曹丹平. 基于深度学习的测井岩性识别方法研究与应用[J]. 地球物理学进展, 2018, 33(3): 1029-1034.
- [6] 李建国, 张卫东, 刘冠男. 深度学习在测井岩性识别中的应用[J]. 科技创新与应用, 2015(14): 21-22.
- [7] 曾锐, 邵燕林, 黄宇, 等. 基于深度学习的测井岩性智能识别[J]. 科学技术与工程, 2025, 25(30): 12804-12812.
- [8] 宋延杰, 张剑风, 闫伟林, 等. 基于支持向量机的复杂岩性测井识别方法[J]. 大庆石油学院学报, 2007(5): 18-20, 46, 118-119.
- [9] 苏赋, 马磊, 罗仁泽, 等. 基于改进多分类孪生支持向量机的测井岩性识别方法研究与应用[J]. 地球物理学进展, 2020, 35(1): 174-180.
- [10] 马东来, 蔡煜琦, 孙远强. 基于随机森林算法的塔然高勒地区测井数据岩性识别[J]. 世界核地质科学, 2023, 40(1): 43-50, 67.
- [11] 许方颖, 邹艳红, 易卓炜, 等. 基于非均衡数据的 ADASYN-CatBoost 测井岩性智能识别——以胶西北招贤金矿床为例[J]. 黄金科学技术, 2023, 31(5): 721-735.
- [12] 罗仁泽, 庾娟娟, 倪华玲, 等. 基于改进集成学习的测井岩性识别方法研究[J]. 石油物探, 2023, 62(2): 212-224.
- [13] 张树义, 王波, 马尽文. 基于深度卷积自编码器的岩性分类与识别[J]. 信号处理, 2023, 39(1): 11-19.
- [14] 张凤博, 马雪玲, 董珍珍, 等. 基于 CNN 和 LSTM 的机器学习模型在测井岩性识别的应用[J]. 西安石油大学学报(自然科学版), 2024, 39(5): 96-103, 133.
- [15] 张晓峰, 庞春阳, 胡锐, 等. 基于 CNN-GRU 的复杂岩性识别方法研究与应用[J]. 测井技术, 2023, 47(6): 662-670.
- [16] 陈钢花, 张寓侠, 王军, 等. 双向长短时记忆神经网络在滩坝砂储层岩性识别中的应用[J]. 测井技术, 2023, 47(3): 319-325.
- [17] 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.
- [18] 王婷婷, 王振豪, 李方, 等. 基于增强多头注意力机制的 Optuna-BiGRU 测井岩性识别[J]. 地球科学与环境学报, 2024, 46(1): 127-142.
- [19] 王婷婷, 王振豪, 赵万春, 等. 基于 MSCNN-GRU 神经网络补全测井曲线和可解释性的智能岩性识别[J]. 石油地球物理勘探, 2025, 60(1): 1-11.