

基于深度学习数据融合的测井数据精细表征

孙正心^{1,2}, 金衍^{1,2,3*}, 孟翰^{1,2}, 郭旭洋^{2,3}

1 中国石油大学(北京)人工智能学院, 北京 102249

2 中国石油大学(北京)油气资源与工程全国重点实验室, 北京 102249

3 中国石油大学(北京)石油工程学院, 北京 102249

* 通信作者, jiny@cup.edu.cn

收稿日期: 2024-12-08; 修回日期: 2024-12-27

基金项目: 国家自然科学基金面上项目“深层脆性页岩井壁失稳的化学断裂机理与控制研究”(52074314)资助

摘要 测井曲线记录钻井过程中地层的物理参数, 在研究岩石特性、评估油气藏资源及揭示储层分布等方面具有重要意义。随着油气勘探的深入, 隐蔽油气藏的复杂性不断增加, 而传统测井数据分辨率较低的局限性, 难以满足薄互层储层改造选点的需求, 亟待开发高分辨率的测井数据精细解释方法。本研究提出了一种基于ResNet50回归算法的储层预测模型。该模型将能够捕捉复杂垂向地质细节的纵向连续光学薄片数据, 与5种常规测井参数相结合, 提升储层分析的精度。通过对某井区二叠系地层的5个井段数据进行验证, 使用连续的570张地层图片样本与测井数据进行训练与预测, 模型将测井数据分辨率从12.5 cm提升至6.25 cm, 显著提高了测井数据的精度和分辨率。本研究使用3种公认的定量评估指标决定系数(R^2)、均方根误差(RMSE)和平均绝对误差(MAE)对模型性能进行了全面评估。结果表明, 该模型在声波时差(AC)、补偿中子(CNL)、电阻率(RT)和伽马(GR)参数的预测中表现较为准确, 平均误差低于0.094, 展示出模型在预测精度上的可靠性与优越性。然而, 在密度(DEN)参数的预测中, 模型在岩性变化较大或地质条件复杂的井段中受到了一定影响。

关键词 数据融合; 测井参数精细表征; ResNet50; 深度学习模型; 储层精细化建模

中图分类号: P618.13; P631.81

Fine characterization of logging data based on the deep learning data fusion

SUN Zhengxin^{1,2}, JIN Yan^{1,2,3}, MENG Han^{1,2}, GUO Xuyang^{2,3}

1 College of Artificial Intelligence, China University of Petroleum-Beijing, Beijing 102249, China

2 State Key Laboratory of Petroleum Resources and Engineering, China University of Petroleum-Beijing, Beijing 102249, China

3 College of Petroleum Engineering, China University of Petroleum-Beijing, Beijing 102249, China

Received: 2024-12-08; Revised: 2024-12-27

Abstract Well logging curves are essential for recording the physical parameters of formations during drilling, providing vital information for analyzing rock properties, evaluating hydrocarbon reservoirs, and understanding reservoir distribution. As oil and gas exploration continues to progress, the complexity of subtle and hidden reservoirs has increased, posing challenges for traditional exploration techniques. Despite their importance, conventional well logging data suffer from low resolution, which significantly limits their ability to address the requirements of detailed reservoir characterization. In particular, the inability

引用格式: 孙正心, 金衍, 孟翰, 郭旭洋. 基于深度学习数据融合的测井数据精细表征. 石油科学通报, 2025, 10(01): 75-86

SUN Zhengxin, JIN Yan, MENG Han, GUO Xuyang. Fine characterization of logging data based on the deep learning data fusion. Petroleum Science Bulletin, 2025, 10(01): 75-86. DOI: 10.3969/j.issn.2096-1693.2025.01.003

to precisely identify modification points in thin interbedded reservoirs remains a critical bottleneck in reservoir analysis. To overcome these limitations, developing high-resolution interpretation methods for well logging data has become an urgent priority in the field of reservoir analysis and geological exploration. This study proposes a novel reservoir prediction model based on the ResNet50 regression algorithm. By integrating vertically continuous optical thin-section data, which can capture fine-scale and complex vertical geological features, with five conventional well logging parameters, the proposed model aims to improve the resolution and accuracy of reservoir analysis. This combination leverages the strengths of image-based geological analysis and traditional well logging to deliver a more precise interpretation of subsurface formations. The model was validated using data collected from five intervals of the Permian formation in a specific well area. A total of 570 continuous geological image samples, combined with their corresponding well logging data, were utilized for model training and prediction. The results demonstrate that the model effectively enhances the resolution of well logging data, improving it from the traditional 12.5 cm to 6.25 cm. This significant improvement not only increases the precision of well logging interpretation but also provides a more detailed understanding of reservoir characteristics. The model's performance was rigorously evaluated using three widely recognized metrics: the coefficient of determination (R^2), root mean square error (RMSE), and mean absolute error (MAE). The results revealed that the model excels in predicting parameters such as acoustic time (AC), compensated neutron (CNL), resistivity (RT), and gamma ray (GR), achieving an average prediction error below 0.094. This highlights the model's reliability and superior performance in reservoir prediction tasks. However, challenges remain in predicting density (DEN), where the model's accuracy is impacted in intervals with significant lithological heterogeneity or complex geological conditions.

Keywords data fusion; fine characterization of logging parameters; ResNet50; deep learning model; fine reservoir modeling

DOI: 10.3969/j.issn.2096-1693.2025.01.003

0 引言

测井技术通过测量地层声学、电学和放射性等信号,推断储层地球物理特性,是精确定位和评估地下油气储集层的重要方法^[1-3]。通过对测井数据解释分析,可获取地层的岩相岩性及物性参数^[4-7]。经过测井数据的解析与地质信息的关联分析,能够深入理解井下地层特征,进而确定岩相分布,并据此推导出岩层介质的渗透率以及孔隙度等一系列关键物性参数^[8-11]。然而,随着油气勘探开发的深入,我国各大油田转向隐蔽油气藏,要求更高精度的储层预测,隐蔽油气藏的非均质性加剧,且常伴随薄互层以及低孔隙度、低渗透率储层的出现,薄储层成为勘探重点,但传统测井数据的精度不足^[12]。因此,亟待开发构建测井数据精细化表征模型来对测井数据重构从而提高测井数据分辨率,实现对地层密度、孔隙度和泥质含量等信息的精细化评价,为页岩油勘探开发提供了关键的地质解释和储层评价方法。

测井曲线的重构是提升油气勘探与开发效率的关键环节,常规的测井曲线的重构包括测井数据预测和补全,测井数据预测和测井数据补全虽然有一定的相似性,但在目标和应用场景上存在显著区别。测井数据预测通常是在已知部分测井数据的基础上,利用模型对未知区域的测井数据进行估算^[13-14]。而测井数据补全则侧重于对部分缺失或失真的测井数据进行修复,以恢复数据的完整性和连续性,确保测井数据的完整性和

后续分析的准确性。二者的关键区别在于预测关注的是“未知”数据的估计,而补全则是“修复”已有数据的缺失。这两种方法与测井数据精细化的目标密切相关。

在测井数据预测方面,杨静等^[15]基于长短期记忆(Long Short-Term Memory, LSTM)神经网络的测井数据预测建模框架能够高效地生成多源且复杂的测井曲线。王俊等^[16]与滕建强等^[17]则通过利用已钻地层段及其邻近区域的测井数据预测钻前的测井曲线。在此基础上,代保庆等^[18]在Att-LSTM(Attention-Long Short-Term Memory)模型中引入注意力机制,通过优化权重分配有效提高预测精度。此外,潘少伟等^[19]通过LSTM神经网络补全缺失的测井数据。同时,王锦涛等^[20]通过融合卷积神经网络与门控循环单元神经网络方法,有效提升了测井曲线预测的精度。

在测井数据补全方面,张家臣等^[21]基于XG-BOOST的机器学习方法构建的模型相较于传统方法能够更精确稳定地重构测井曲线。针对声波测井曲线缺失或失真问题,刘建建等^[22]结合异步连续减半算法优化的LSTM模型,实现了高效精确的测井曲线补全技术。此外,混合集成学习模型的测井曲线生成方法结合了随机森林和极限梯度提升模型的优势,能够高效智能地补全缺失的测井曲线^[23]。Meng等^[24]基于条件去噪扩散概率模型的生成模型,在捕捉不确定性的同时填充所有缺失测井数据。上述研究表明,智能算法在测井数据优化方面取得了显著进展,为复杂的地质构造提供了前所未有的洞察和精确度^[25]。同时深度学习

习因其自组织、自学习和容错性的优点,能够有效地训练和测试储层特征,从而优化测井数据^[26-27]。

虽然预测和补全可以有效地改善数据质量,但它们往往受到分辨率的限制,通常无法达到更高的测井数据精度^[28]。精细化测井数据的目标不仅是提高数据的完整性,还在于提升数据的分辨率和预测的准确性,以便更精准地进行地层分析和储层评估^[29]。现有的测井数据重构方法多集中在 12.5 cm 的传统分辨率,而精细化目标则要求更高分辨率的数据,以便更精确地捕捉地层和储层的微观特征。

针对上述问题,本文提出测井数据精细解释方法,旨在将测井数据精度从 12.5 cm 进一步提升至更高的分辨率,并进一步提升测井数据在复杂地质条件下的应用效果。首先,通过纵向连续光学薄片观察岩石的微观结构特征,获取 7 cm 的地层信息。随后,基于薄片信息和测井数据,将真实的地层图像与其同深度的测井数据结合,以图像数据作为输入,测井数据作为输入图像的标签,构建 ResNet50 回归模型,在测试集效果达标后,通过预测集数据进行预测,从而实现高精度的测井数据预测与补全,保证精细化后的测井数据结果能够反映真实的地质信息,从而构建准确的精细化预测模型,对原始测井数据进行细化表征。本文的研究结果实现对测井数据精细化表征与预测,为储层精细化建模提供理论指导。

1 精细解释测井参数方法研究

本文通过选取二叠系地层某井的连续井段,以全尺寸岩心的岩板制作纵向上连续的光学大薄片,构建地层特征图片数据集。随后,基于 ResNet50 架构建立测井数据预测模型,通过图像数据预测电阻率(Resistivity, RT)、密度(Density, DEN)、伽马(Gamma, GR)、声波时差(Acoustic time, AC)和补偿中子(Compensated Neutron, CNL)5 种测井数据,获取以 6.25 cm 为间隔的精细化测井数据。

1.1 数据集构建

本文图像数据的处理流程旨在实现测井数据与光

学薄片图像的高效匹配,从而构建一个精细化的训练数据集。本研究选取了五个井段,共计 60 米深度范围的纵向连续岩板内制作的 570 张光学薄片图像(图 1)。

每张薄片的尺寸为 5cm×7cm,其纵向尺寸(7cm)小于测井数据 12.5cm 的分辨率。为实现光学薄片图像与测井数据的分辨率对齐,采取了图像拼接策略,将相邻两张图像沿纵向顺序拼接,生成包含 5cm×14cm 地层信息的组合图像。每个拼接后的图像覆盖 14cm 的地层深度范围,与其所在深度段的测井数据进行匹配。测井数据被选取为标签,包含此深度范围内的五种测井参数测量值。这种拼接与顺移策略确保了光学薄片图像与测井数据的精准匹配,为模型训练提供了精细化的地层信息输入,同时保留了测井数据在垂向上的连续性与特征分布规律。这种方法不仅提高了训练数据的质量,还为测井数据精细解释提供了更为丰富的输入基础。在预处理时将图像进行数据增强,通过 keras 算法与 pillow 算法对每张图像采用翻转平移、色彩调整等方法扩充数据集,将数据集数量从原始拼接后 285 张图片扩增至 4845 张图片,避免模型因样本过少而产生欠拟合的问题。预处理后的随机抽取数据中的 80% 也就是 3876 张图片作为训练集,余下的 20% 被划分为测试集,用于后续的模式训练和评估。为进一步提升数据的精细化预测结果,采用了图像位置顺移的策略,以一张单独的薄片为单位,将拼接位置沿纵向移动一张图像的深度(7 cm),再进行下一组图像的拼接。通过这种滑动窗口式的数据构建方法,可以在数据利用率最大化的同时,实现更高分辨率的测井数据匹配。

整体过程如图 2 所示,在目标深度,将图片对应其同深度下的测井数据值,依据上述方法确定数据集图像所对应标签,进行训练与预测,从而获得精细化后的结果。

1.2 基于 ResNet50 的非线性预测方法

ResNet50 是深度学习中一种广泛使用的图像分类图像特征提取算法。ResNet50 的核心创新在于引入了残差块,这些残差块通过“跳跃连接”解决了深层网络中的梯度消失问题,使得网络可以更有效地训练更




图 1 纵向连续光学大薄片(70 cm)

Fig. 1 Large longitudinal continuous optical sheet (70 cm)

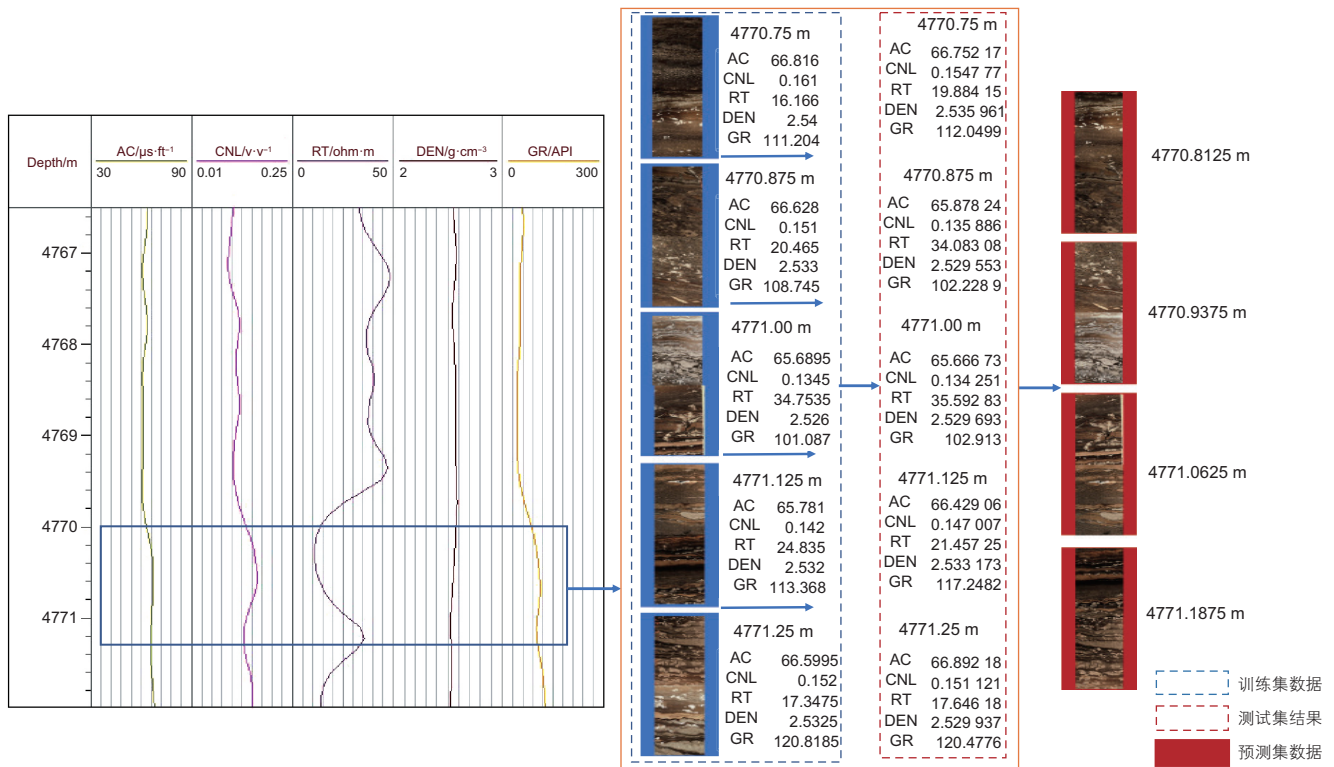


图 2 测井数据及对应深度的岩心图片数据

Fig. 2 Well logging data and core picture data of corresponding depth

深的层数。ResNet50 由 50 层的网络组成，能够提取图像的高级特征。本文在使用 ResNet50 作为骨干网络时，移除其最后的全连接层，以便将其作为特征提取器。这样，ResNet50 可以从输入图像中提取丰富的特征，这些特征可以用于各种后续的回归预测任务。本文所提出的深度学习网络架构融合特征提取与回归预测两大模块。在特征提取阶段，采用 ResNet50 模型 (图 3)，将其视为一个整体的特征提取器。在特征提取器内引入回归器模块，这个回归网络由一系列全连接层组成，旨在将 ResNet50 提取的高维特征映射到目标变量的空间，该回归器由 3 个全连接层构成，它们负责将提取的特征映射到最终的回归目标空间。模型首先由一个线性层构成，将来自特征提取器的 2048 维特征向量降至 1024 维，接着应用 ReLU 激活函数引入非线性。为防止过拟合，加入 Dropout 层随机丢弃部分神经元输出。第二个线性层进一步降维至 256 维，并再次应用 ReLU 激活函数，随后的 Dropout 层增强模型泛化能力。最后，第三个线性层将特征映射至 5 维输出空间，对应各测井标签的预测值。

该网络结构设计通过特征提取器捕捉图像对中的关键信息，利用 ResNet50 的深度卷积结构逐步提取从低级到高级的特征表示。回归器逐层处理这些特征，

将其映射到最终回归目标。通过结合 ResNet50 的强大特征提取能力与回归网络的映射能力，模型在复杂预测任务中表现优异。在训练过程中，通过误差执行反向传播并更新模型参数以优化性能，同时累积批次损失以计算训练集的平均损失。为防止过拟合，采用 30% 的 Dropout 率，初始学习率为 0.001，通过 Adam 优化器进行动态调整以自适应更新参数。模型在测试集验证损失最优时被保存。阶段禁用梯度计算，流程与训练阶段相似，最后计算验证集的平均损失以评估模型性能。最终，该网络能够根据输入图像及其对应的 5 种测井数据标签，输出包含电阻率 (RT)、密度 (DEN)、伽马 (GR)、声波时差 (AC) 和补偿中子 (CNL) 5 个回归值的预测向量。

在原始 ResNet50 中，去除全连接层，使得网络输出的特征向量不再受到分类任务的约束，而是作为中间特征直接传递给后续的回归模块，以保留更多特征信息供回归器使用。这些层协同工作，实现对图像特征的高效提取与深度学习。在训练过程中进行梯度归零，执行前向传播以计算预测结果，并应用均方误差 (MSE_{Loss}) 作为损失度量。计算真实标签 (y_i) 与预测值 (\hat{y}_i) 之间的误差， n 是为测井数据总数观测值的数量以评估模型的性能，损失函数方程如下：

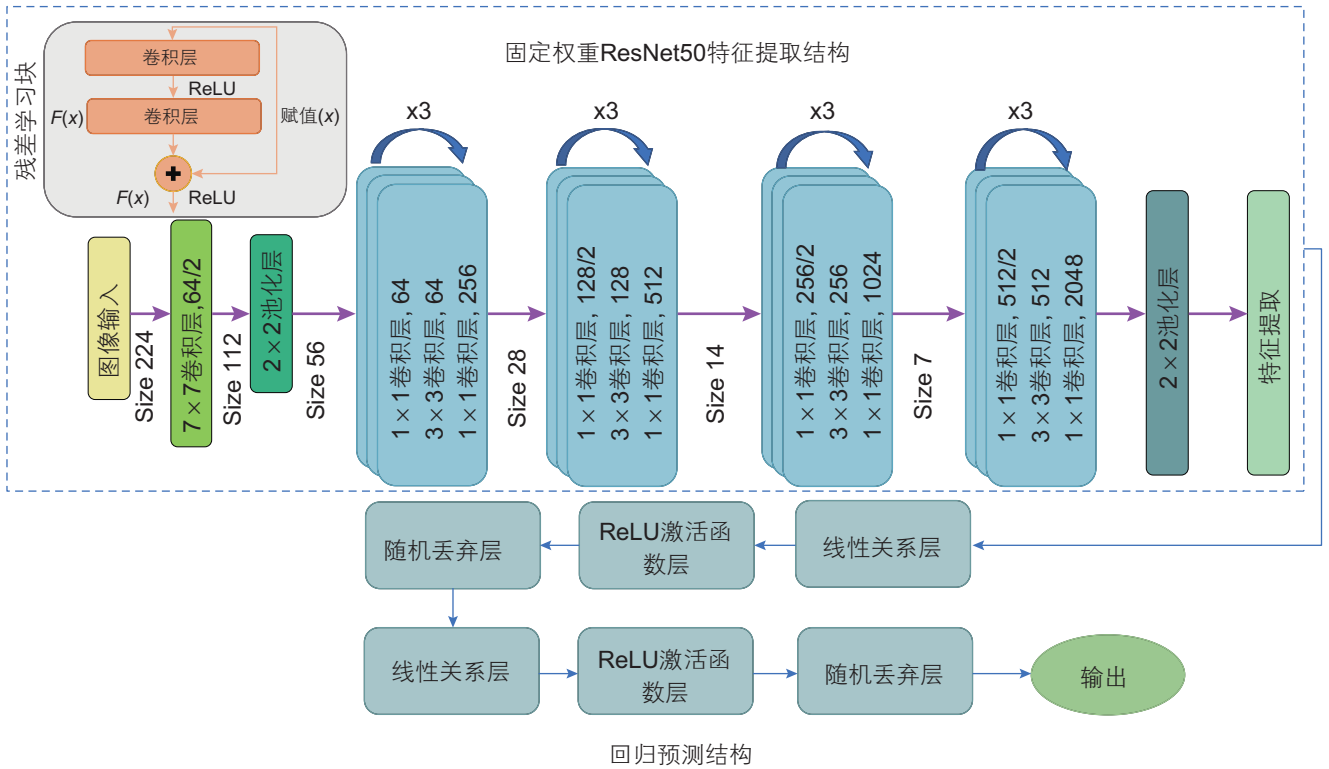


图3 整体模型架构图

Fig. 3 Overall model architecture diagram

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

1.3 模型评价指标

在实验中，为了全面而准确地评估预测模型的性能，采用了3个常用的评价指标： R^2 (决定系数)、RMSE(均方根误差)和MAE(平均绝对误差)进行整体评估。 R^2 是衡量回归分析效果的重要指标，用于评估模型预测值与实际值之间的符合程度。计算表示因变量的总变异程度。 R^2 的值越接近1，即残差平方和(模型预测值(\hat{y}_i)与实际值(y_i)之差的平方和)与总变差(实际值(y_i)与其平均值(\bar{y})之差的平方和)的比值越小，表示模型拟合度越好， R^2 的公式如下：

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

由于MSE对异常值较为敏感，因此在数据中存在异常值时，其评估结果可能会受到一定影响。为了消除MSE对异常值的敏感性，采用RMSE作为评估指标，RMSE的公式如下：

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

RMSE是MSE的平方根。通过计算RMSE值，可以更直观地了解模型的预测准确度和误差分布情况。RMSE值越小，说明预测值与观测值之间的差异越小，模型的预测准确度越高。

MAE反映了预测值与真实值之间的绝对误差的平均水平，它平等地考虑了所有的单个预测误差的大小，而不考虑误差的方向，MAE的公式如下：

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

MAE的值越小，表示模型的预测准确性越高。

R^2 值高意味着预测趋势一致，但它不一定能反映误差的大小，因此不能单独评估精度。RMSE评估模型精度，并且由于其标准化的性质，能够提供更具直观性的误差分析。其值越小，表示模型的预测精度越高。MAE较为直观地反映了模型预测的平均误差。 R^2 、RMSE、MAE都在不同程度上反映了模型的预测精度。 R^2 专注于评估拟合度，而RMSE和MAE则分别衡量误差的大小，其中RMSE对大误差更加敏感，MAE则提供了对所有误差的平均评估。综上所述， R^2 、RMSE和MAE这3个评价指标在实验中被综合运用，以全面而准确地评估预测模型的性能。它们衡量了模型预测结果与实际值之间的差异；而稳定性则通过对比这些指标在不同数据集上的变化来间接反映。

2 结果与分析

2.1 测试集结果

在对分析测试集结果时,通过 R^2 、RMSE和MAE这3个评价指标可以看出,模型对五个测井参数(AC、CNL、RT、DEN、GR)的预测性能展现了较为清晰的差异性。整体来看,模型对AC、CNL和RT参数的预测效果最为优异,其中AC的RMSE为0.0478,MAE为0.0249, R^2 为0.9459,表明模型能够准确预测AC参数的变化;CNL的RMSE和MAE分别为0.0473和0.0311,且 R^2 高达0.9556,是所有参数中最高的,显示了模型对CNL的拟合能力最强;AC通常用于反映地层的孔隙度、弹性性质以及岩石的波速特征;而CNL参数则多用于反映地层的孔隙度及水饱和度等特征。由于它们与岩性、孔隙度和地层流体性质之间有较强的相关性,模型能够较好地捕捉这些地质信息。RT的RMSE和MAE最低,分别为0.0420和0.0264,且 R^2 为0.9516,同样表现出较高的预测精度。

相比之下,模型对GR参数的预测表现略有不足,其RMSE为0.0499,MAE为0.0216,其中MAE为所有参数中最低,说明预测误差较小,但 R^2 为0.8852,相对较低,表明模型在捕捉GR参数的变化趋势时存在一定局限性。这可能与GR参数在地质层位、沉积环境及矿物成分等方面的较强指示性有关。然而,测试集中的GR预测结果出现了明显下降,表明GR参数虽然能较好地反映地层的矿物成分和沉积环境,但在不同井段的复杂地质条件下,GR参数本身的分辨率和其对细粒度岩性、局部变化的敏感性较低,导致模型并未完全学习GR参数的变化特征^[31]。模型对DEN参数的预测表现最差,其RMSE为0.0772,MAE为0.0600,均为所有参数中最高,且 R^2 仅为0.7929,显著低于其他参数,表明模型对DEN参数的预测误差相对较大。密度曲线通常用于反映地层的密度变化,受岩石类型、孔隙度以及流体饱和度的影响较大且探测深度较浅。由于密度受这些因素的综合影响较大,且

表1 测试集结果分析

Table 1 Analysis of test set results

TEST	RMSE	MAE	R^2
AC	0.0478	0.0249	0.9459
CNL	0.0473	0.0311	0.9556
RT	0.0420	0.0264	0.9516
DEN	0.0772	0.0600	0.7929
GR	0.0499	0.0216	0.8852

不同地质条件下密度的变化可能较为复杂,因此模型在预测DEN时可能未能充分捕捉到这些复杂的地质特征,导致其预测精度较低^[32]。综合来看,模型对AC、CNL和RT参数的预测效果优异,但对GR和DEN参数的表现仍有优化空间。

2.2 分段结果分析

在本文中,共对5个井段的数据进行分析,不同井段处于不同的地层深度,而不同深度的地层特性差异较大。这些地层特性直接影响测井数据的表现,使得针对不同井段的测井数据预测效果存在差异。由于每个井段的地质背景和测井曲线的特征差异,模型针对5个井段的5种测井参数的表现各有不同。

本文通过 R^2 、MAE和RMSE3个评价指标对模型的预测效果进行了系统分析,并结合不同井段间的比较,明确了模型在各井段的表现差异及其成因。

在 R^2 值方面,不同井段间的预测效果表现出显著差异。其中,在井段内分析,井段9、15和21的测井参数预测效果较优。井段9中DEN和GR的 R^2 值分别达到0.9060和0.9104,表明在此井段内,模型能够有效捕捉地层特征并对这些参数进行准确预测。相对而言,井段12的CNL参数的 R^2 值最低,仅为0.7689,反映出预测效果较差,可能是由于井段间地质条件的变化显著,特别是岩性、孔隙度和流体性质的复杂性导致CNL的变化规律难以被准确拟合。

在MAE分析中,井段间的预测误差同样表现出显著差异。井段9的RT和DEN参数的MAE值较小,分别为0.0337和0.0493,表明在该井段内,模型的预测误差相对较低,预测效果较好。相比之下,井段12的CNL参数MAE值高达0.1040,反映出预测误差较大,这可能是由于井段间孔隙度分布的不均匀性加剧了预测难度。此外,在井段21内,RT和DEN的MAE值相对较高,分别为0.1460和0.1661,这表明该井段内的复杂地质条件可能对模型预测的精度产生了较大影响。

在RMSE值的比较中,井段9的DEN和GR的RMSE值分别为0.0677和0.0613,显示出较小的预测误差,表明井段内地层条件较为均匀,孔隙度和矿物成分变化相对简单,模型对测井数据的拟合能力较强。相比之下,井段12的CNL参数RMSE值为0.1316,预测误差显著增大,可能与该井段的孔隙度分布复杂性和流体特征变化有关。此外,在井段21内,RT和DEN的RMSE值分别为0.1857和0.1924,预测误差较大,这可能反映了井段间岩性与孔隙度分布的不均匀性对模型拟合能力的制约。

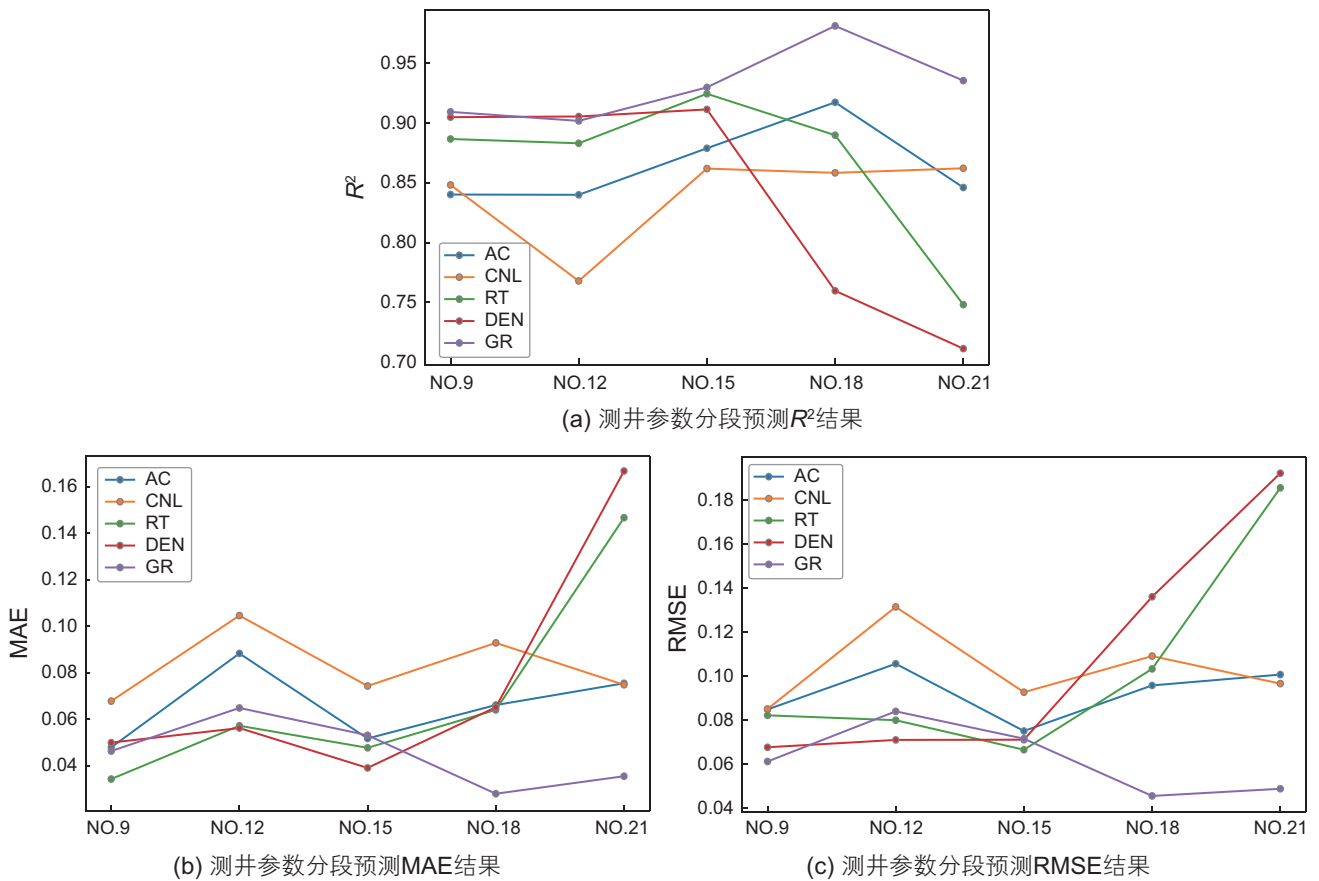


图 4 测井参数分段预测评价结果

Fig. 4 Prediction and evaluation results of segmented logging parameters

综上所述，模型在不同井段间的预测效果差异显著，主要受地质条件、岩性变化、孔隙度分布及流体性质等因素的影响。总体来看，在地质条件相对均匀和简单的井段(如井段 9 和 15)中，针对 5 种参数，模型表现均较佳；而在复杂地质环境下(如井段 12 和 21)，尤其是对 CNL、RT 和 DEN 等参数的预测，模型的误差有所增大。

2.3 ResNet-regression 算法与 ViT-MLP 算法对比分析

为进一步分析本文算法效果，本文方法与 ViT-MLP 算法^[30]进行对比，Vision Transformer(ViT)算法在自然语言处理和视觉任务中取得了显著成果，而多层感知器(MLP)结构则在分类和回归问题中表现出色^[33]。然而，在地层图片信息复杂的情境下，基于 ViT 算法的特征提取与 MLP 结构的预测效果并不理想。虽然在训练过程中可以达到收敛的效果如图 5，但是在进行测试时，测试集结果的 R^2 均为负值，与标签值对比效果如图 6 所示。

ViT 算法通过将图像分割成多个小块(patch)，并将每个小块投影为固定长度的向量送入 Transformer 进

行处理。然而，在地层图片中，许多关键特征可能仅占据图像的极小部分，ViT 的 patch 大小可能无法精确捕捉这些局部特征。MLP 结构依赖于输入特征的有效表示。但由于 ViT 算法在提取地层图片特征时存在上述挑战，导致输入到 MLP 的特征表示可能不充分或存在噪声。这会影响 MLP 的预测性能，使其难以准确分类或回归。MLP 结构在训练过程中容易过拟合，特别是在输入特征维度较高且数据量有限的情况下。地层图片信息复杂，特征维度高，而可用的训练样本可能相对较少。这增加了 MLP 过拟合的风险，导致模型在测试集上的表现不佳。MLP 结构相对简单，缺乏复杂的特征提取和表示能力。在地层图片信息复杂的情境下，MLP 可能无法有效捕捉图像中的复杂特征和关系，导致模型泛化能力弱，预测效果不佳。

而 ResNet-regression 算法则展示了优秀的预测趋势效果，在模型通过测试集验证效果良好后，并收敛如图 7 所示，将其应用于精细化测井数据的预测。经过模型预测后的精细化测井数据展现出更高的分辨率能够捕捉到原始数据中未能显现变化，如图 8 所示。

这种精细化处理使得测井数据在地质特征识别和




图5 ViT-MLP训练结果

Fig. 5 Results of ViT-MLP training

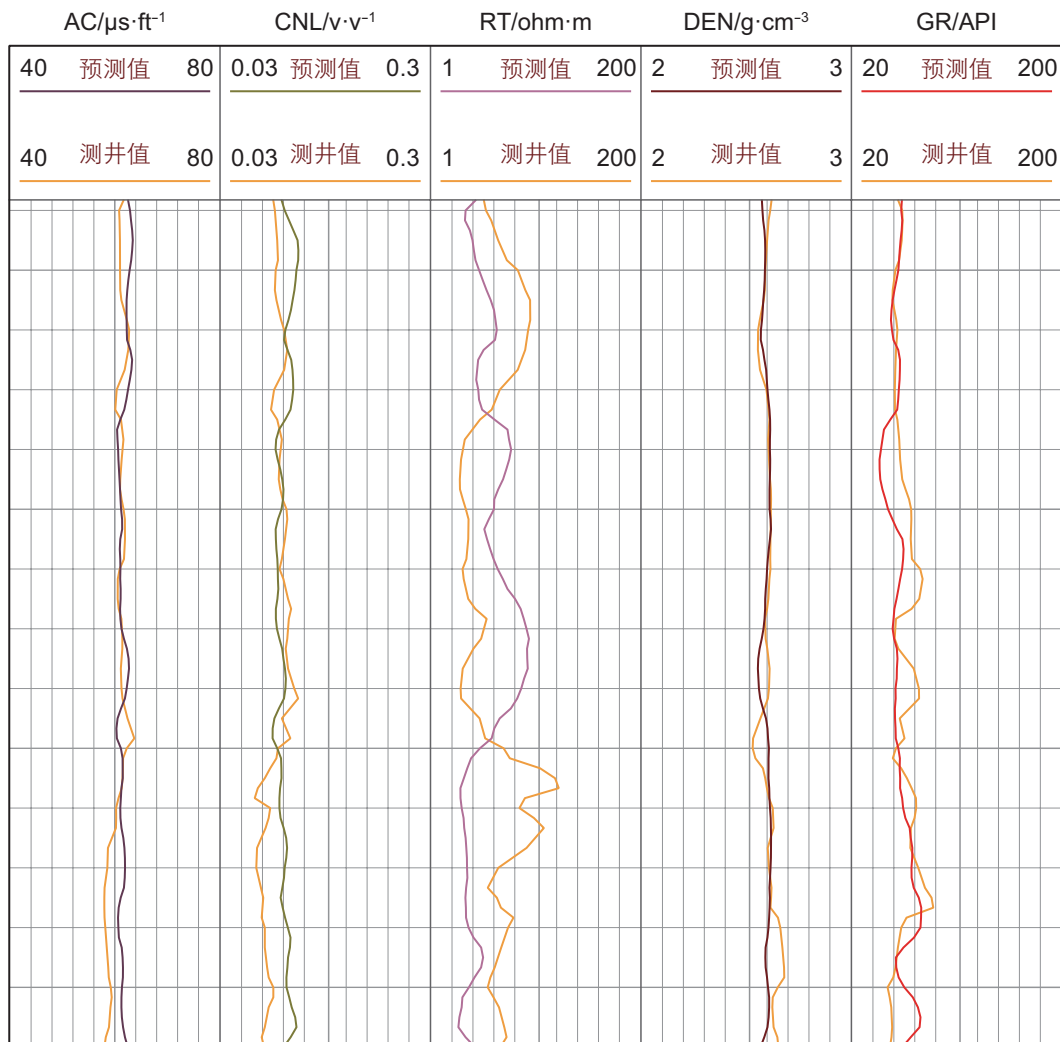


图6 ViT-MLP预测结果

Fig. 6 Prediction results of ViT-MLP

储层评价中更具实用价值。精细化后的测井数据与原始数据的整体趋势基本保持一致。这表明模型在细节增强的同时，未偏离原始数据的基本特征和趋势，确保了预测结果的可靠性。通过精细化处理，测井数据在油藏描述、储层建模和生产预测等方面的应用价值显著提升。模型的高精度预测能力为后续的地质分析和决策提供了坚实的基础。总之，模型在精细化测井数据上的成功应用，不仅验证了其在测试集上的优异表现，也为实际地质应用提供了更为精确和可靠的数据支持。

在对比 ViT-MLP 算法和 ResNet50 回归算法的应用效果时，明显发现 ViT-MLP 算法在处理测井数据预测问题时表现出泛化能力较弱的缺陷，导致预测精度不佳。相比之下，本文所构建的 ResNet50 回归算法凭借其深层卷积网络架构，成功弥补了这些不足。

首先，ResNet50 利用残差块结构，可以有效地缓解深度网络中的梯度消失问题，同时增强特征传递能力，确保模型能够深入提取图像的多层次信息。其次，卷积操作能够高效捕捉局部特征，使得模型在处理复杂地质背景和多样化测井曲线时依然表现出色。此外，ResNet50 在与回归模块结合后，进一步优化了图像到数值预测的映射过程，成功将高维图像特征转换为准确可靠的预测结果。ResNet50 回归算法在预测精度和泛化能力上均优于 ViT-MLP 模型，其在测井数据预测问题上的表现更具鲁棒性和适应性。特别是在应对复杂地质环境、异质性较强的岩性分布时，ResNet50 能够充分挖掘图像中的潜在信息，为解决测井数据预测问题提供了更加有效的方法。因此，该方法更加适合

用于处理图像预测测井数据的问题，具有显著的应用价值。

与此同时，如表 2 所示，从模型参数量来看，ViT-MLP 的参数量明显少于 ResNet50，仅为其约 28.7%，表明 ViT-MLP 模型在存储需求和参数优化方面具有一定的优势。尽管 ViT-MLP 的参数量更少，但是在算力需求方面，ViT-MLP 模型的计算复杂度略高于 ResNet50 回归模型。在处理同样的数据量的情况下两者总推理时间非常接近，差距可以忽略不计。在内存使用上，ViT-MLP 的内存占用显著高于 ResNet50 回归算法，在资源有限的环境下，ResNet50 回归模型具有更高的实用性。

总结两种方法结果后，可以发现，ResNet50 回归算法更具有有效性，在通过二维图像数据预测三维地层数据时，模型在声波时差与补偿中子两个参数的预测效果较好但密度、泥质含量和电阻率 3 个参数的预测准确率稍低，但也展现出了良好的预测能力。首先，二维图像数据本身具有局限性。它只能提供地层在某一平面或截面上的信息，而无法全面反映地层在三维空间中的复杂结构和变化。这种信息的缺失导致了在预测三维地层数据时的不确定性，进而影响了密度、泥质含量和电阻率等参数的预测准确性。其次，地层本身的复杂性和多样性也是导致预测结果差异性的重要原因。地层中的岩性、构造、沉积环境等因素都会对密度、泥质含量和电阻率等参数产生影响。而这些因素在二维图像数据中往往难以被完全捕捉和表达，从而导致了预测结果的差异性。最后，数据的质量和准确性也是影响预测结果的重要因素。尽管在数据处




图 7 ResNet-regression 训练结果

Fig. 7 Results of ResNet-regression training

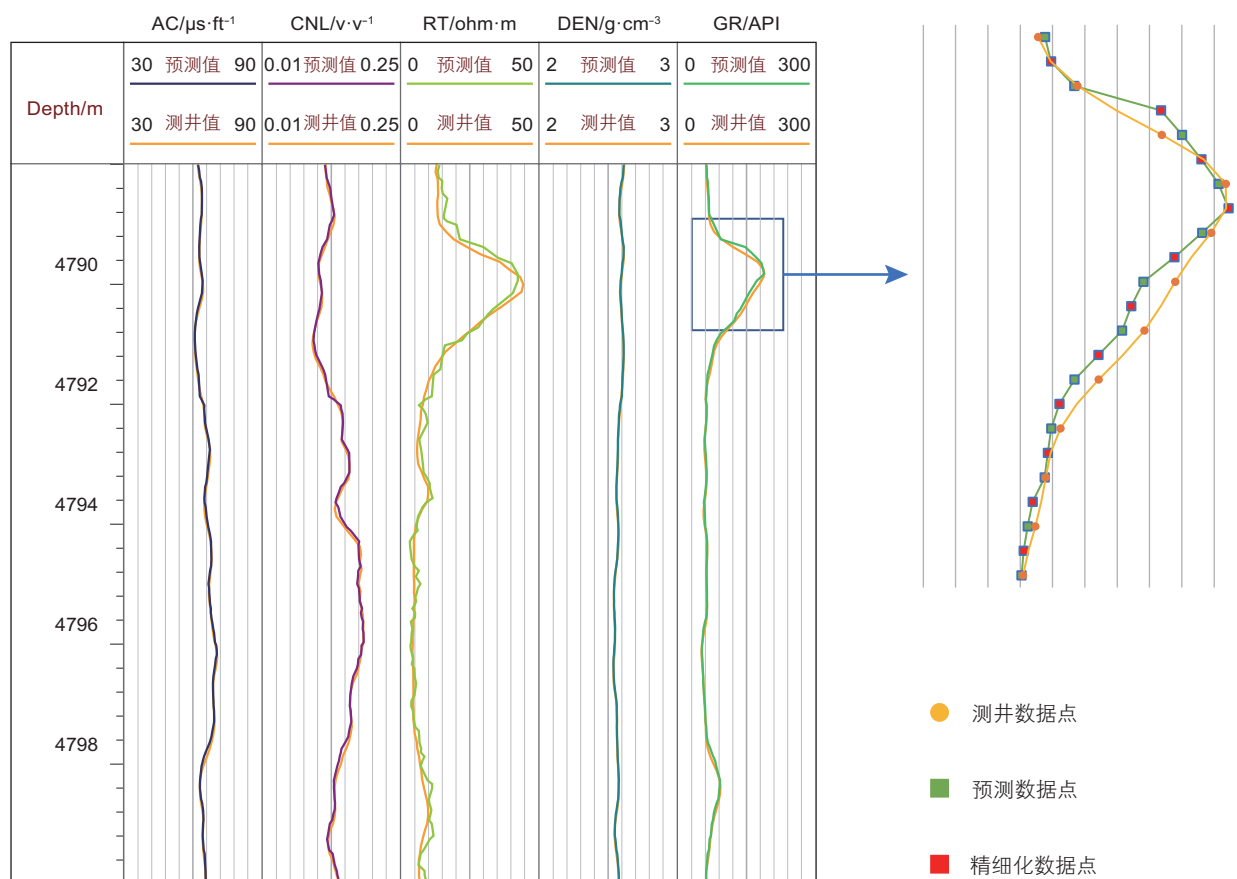


图8 精细化预测结果

Fig. 8 Refined prediction results

表2 ResNet50 回归算法与 ViT-MLP 模型性能对比表

Table 2 Performance comparison table of ResNet50 regression algorithm and ViT-MLP Model

指标	ResNet50	ViT-MLP
参数总量/Parameters	27 969 101	8 028 618
浮点运算/GFLOPs	264.571	287.793
推理时间/s	126.5634	125.96
内存占用/MB	228.18	1173.89

理过程中已经尽可能地减少噪声的出现,但与三维地层数据之间存在不匹配的情况,亦可能导致预测结果的差异性。

综上所述,通过二维图像数据预测三维测井数据时,预测结果基本可靠,能够实现测井数据精细解释的目的,但是针对密度、泥质含量和电阻率预测的差异性可能源于二维图像数据的局限性、地层本身的复杂性和多样性以及数据的质量和准确性等多种因素。

3 结论

1) 本文将纵向连续光学薄片与测井数据特征相结

合,构建了一个基于ResNet50算法的回归方法的测井数据精细解释模型。该模型通过对地层图片和测井数据的综合分析,实现了对测井数据的精细化表征预测,将测井数据的分辨率从12.5 cm提升到了6.25 cm。

2) 基于ResNet50算法构建测井数据精细解释,不仅提高了测井数据的精度,还进一步得到更精细化的地层信息。本方法在五种常规测井数据的预测中平均绝对误差低于0.067,说明模型在预测精度上表现优异,具有可靠性。该模型不仅提升了数据预测的准确性,还为地质分析提供了更精确的地层信息,能够为后续的地质分析和决策提供更具价值的数

据支持。

3) 本研究构建的模型对声波时差(AC)、伽马

(GR)、电阻率(RT)和补偿中子(CNL)4个参数的预测较为准确。而密度(DEN)参数的预测中,模型在岩性变化较大或地质条件复杂的井段中受到显著影响,预

测精度相对较低。因此,未来将针对复杂地质条件下的岩性不均匀性和流体分布多样性问题开展模型优化研究,以进一步提高模型在复杂环境中的预测能力。

参考文献

- [1] LAI J, WANG G, WANG S, et al. A review on the applications of image logs in structural analysis and sedimentary characterization[J]. *Marine and Petroleum Geology*, 2018, 95: 139–166.
- [2] FENG Q F, XIAN Y X, HOU X L, et al. Logging identification method of depositional facies in Sinian Dengying Formation of the Sichuan Basin[J]. *Petroleum Science*, 2021, 18 (4): 1086–1096.
- [3] FENG C, FENG Z Y, MAO R, et al. Prediction of vitrinite reflectance of shale oil reservoirs using nuclear magnetic resonance and conventional log data[J]. *Fuel*, 2023, 339: 127422.
- [4] ALIZADEH N, RAHMATI N, NAJAFI A, et al. A novel approach by integrating the core derived FZI and well logging data into artificial neural network model for improved permeability prediction in a heterogeneous gas reservoir[J]. *Journal of Petroleum Science and Engineering*, 2022, 214: 110573.
- [5] JIA W H, ZONG Z Y, QIN D W, et al. Integrated well-log data and seismic inversion results for prediction of hydrocarbon source rock distribution in W segment, Pearl River Mouth Basin, China[J]. *Geoenergy Science and Engineering*, 2023, 230: 212–233.
- [6] KIM S, HONG Y, LIM J, et al. Improved prediction of shale gas productivity in the Marcellus shale using geostatistically generated well-log data and ensemble machine learning[J]. *Computers & Geosciences*, 2023, 181: 105452.
- [7] TUNKIEL A T, SUI D, WIKTORSKI T. Impact of data pre-processing techniques on recurrent neural network performance in context of real-time drilling logs in an automated prediction framework[J]. *Journal of Petroleum Science and Engineering*, 2022, 208(E): 109760.
- [8] RADWAN A E, WOODD A, RADWAN A A. Machine learning and data-driven prediction of pore pressure from geophysical logs: A case study for the Mangahewa gas field, New Zealand[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2022, 14(6): 1799–1809.
- [9] ZHAO X B, CHEN X J, HUANG Q, et al. Logging-data-driven permeability prediction in low-permeable sandstones based on machine learning with pattern visualization: A case study in Wenchang A Sag, Pearl River Mouth Basin[J]. *Journal of Petroleum Science and Engineering*, 2022, 214: 110517.
- [10] KIM N, SHIN H, LEE K. Feature engineering process on well log data for machine learning-based SAGD performance prediction[J]. *Geoenergy Science and Engineering*, 2023, 229: 212057.
- [11] KUMAR T, SEELAM N K, RAO G S. Lithology prediction from well log data using machine learning techniques: A case study from Talcher coalfield, Eastern India[J]. *Journal of Applied Geophysics*, 2022, 199: 104605.
- [12] 赵文智, 朱如凯, 刘伟, 等. 中国陆相页岩油勘探理论与技术进展[J]. *石油科学通报*, 2023, 04: 373–390. [ZHAO W Z, ZHU R K, LIU W, et al. Advances in theory and technology of non-marine shale oil exploration in China[J]. *Petroleum Science Bulletin* 2023, 8(4): 373–390.]
- [13] DAS G, MAITI S. A machine learning approach for the prediction of pore pressure using well log data of Hikurangi Tuaheni Zone of IODP Expedition 372, New Zealand[J]. *Energy Geoscience*, 2024, 5(2): 100227.
- [14] SHI F, LIAO H L, QU F T, et al. Collaborative-driven reservoir formation pressure prediction using GAN-ML models and well logging data[J]. *Geoenergy Science and Engineering*, 2024, 242: 213271.
- [15] 杨静, 陈云天, 蒋春碧. 测井曲线生成问题的机器学习建模范式——以长宁威远地区页岩井为例[J]. *中国海上油气*, 2021, 33(1): 76–84. [YANG J, CHEN Y T, JIANG C B. Machine learning modeling paradigm for log curve generation problems: Taking shale gas wells in Changning-Weiyuan area as examples[J]. *China Offshore Oil and Gas*, 2021, 33(1): 76–84.]
- [16] 王俊, 曹俊兴, 刘哲胥, 等. 基于长短期记忆网络的钻前测井曲线预测方法[J]. *成都理工大学学报(自然科学版)*, 2020, 47(2): 227–236. [WANG J, CAO J X, LIU Z L, et al. Method of well logging prediction prior to well drilling based on long short term memory recurrent neural network[J]. *Journal of Chengdu University of Technology (Science & Technology Edition)*, 2020, 47(2): 227–236.]
- [17] 滕建强, 邱萌, 杨明任, 等. 基于门控循环单元神经网络的测井曲线预测方法[J]. *油气地质与采收率*, 2023, 30(1): 93–100. [TENG J Q, QIU M, YANG M R, et al. Logging curve prediction method based on GRU[J]. *Petroleum Geology and Recovery Efficiency*, 2023, 30 (1): 93–100.]
- [18] 代保庆, 彭家琼, 张天环, 等. 基于Attention机制的LSTM测井曲线预测方法[J]. *测井技术*, 2023, 47(2): 167–175. [DAI B Q, PENG J Q, ZHANG T H, et al. LSTM logging curve prediction method based on Attention mechanism[J]. *Well Logging Technology*, 2023, 47(2): 167–175.]
- [19] 潘少伟, 王朝阳, 张允, 等. 基于长短期记忆神经网络补全测井曲线和混合优化XGBoost的岩性识别[J]. *中国石油大学学报(自*

- 然科学版), 2022, 46(3): 62–71. [PAN S W, WANG, Z Y, ZHANG Y, et al. Lithology identification based on LSTM neural networks completing log and hybrid optimized XGBoost[J]. Journal of China University of Petroleum (Edition of Natural Science), 2022, 46(3): 62–71.]
- [20] 王锦涛, 文晓涛, 何易龙, 等. 基于CNN-GRU神经网络的测井曲线预测方法[J]. 石油物探, 2022, 61(2): 276–285. [WANG J T, WEN X T, HE Y L, et al. Logging curve prediction based on a CNN-GRU neural network[J]. Geophysical Prospecting for Petroleum, 2022, 61(2): 276–285.]
- [21] 张家臣, 邓金根, 谭强, 等. 基于XGBoost的测井曲线重构方法[J]. 石油地球物理勘探, 2022, 57(3): 697–705+496. [ZHANG J C, DENG J G, TAN Q & SHI L. Logging curve reconstruction method based on XGBoost[J]. Petroleum geophysical exploration, 2022, 57(3), 697–705 + 496.]
- [22] 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. [LIU J J, ZHOU J, YU W D, et al. Acoustic log curve reconstruction based on hyperparameter optimized LSTM [J]. Geophysical Prospecting for Petroleum, 2024, 63(5): 1061–1074.]
- [23] 王宵宇, 廖广志, 肖立志, 等. 基于混合集成学习模型的测井曲线生成方法[J]. 测井技术, 2024, 48(4): 416–427. [WANG X Y, LIAO G Z, XIAO L Z, et al. Well log generation based on hybrid ensemble learning model[J]. Well Logging Technology, 2024, 48(4): 416–427.]
- [24] MENG H, LIN B, ZHANG R, & JIN Y. A missing well-logs imputation method based on conditional denoising diffusion probabilistic models[J]. SPE Journal, 2024, 1–16.
- [25] LIU W, CHEN Z, HU Y, et al. A systematic machine learning method for reservoir identification and production prediction[J]. Petroleum Science, 2023, 20 (1): 295–308.
- [26] ZHAN W, CHEN Y, LIU Q, et al. Simultaneous prediction of petrophysical properties and formation layered thickness from acoustic logging data using a modular cascading residual neural network (MCARNN) with physical constraints[J]. Journal of Applied Geophysics, 2024, 224: 105362.
- [27] WOOD D A. Brittleness index predictions from Lower Barnett Shale well-log data applying an optimized data matching algorithm at various sampling densities[J]. Geoscience Frontiers, 2021, 12 (6): 101087
- [28] 郭智, 杨少春, 贾爱林, 等. 薄砂层多开发层系油田测井精细解释方法[J]. 石油学报, 2013, 34(6): 1137–1142. [GUO Z, YANG S C, JIA A L, et al. Fine log interpretation for oilfields with thin sands and multiple developed layer systems[J]. ACTA PETROLEI SINICA, 2013, 34(6): 1137–1142.]
- [29] 马天寿, 张东洋, 陆灯云, 等. 地质力学参数智能预测技术进展与发展方向[J]. 石油科学通报, 2024, 9(3): 365–382. [MA T S, ZHANG D Y, LU D Y, et al. Progress and development direction of intelligent prediction technology of geomechanical parameters[J]. Petroleum Science Bulletin, 2024, 9(3): 365–382.]
- [30] EHAB E. Feature fusion vision transformers using MLP-Mixer for enhanced deepfake detection[J]. Neurocomputing, 2024, 598: 128128, [31]张瑞, 潘保芝, 杨雪, 等. 脉冲中子源密度测井进展[J]. 地球物理学进展, 2015, 30(6): 2596–2602. [ZHANG R, PAN B, YANG X, et al. Pulsed neutron source density logging progress[J]. Progress in Geophysics (in Chinese), 30(6): 2596–2602.]
- [32] 赵显令, 王贵文, 周正龙, 等. 地球物理测井岩性解释方法综述[J]. 地球物理学进展, 2015, 30(3): 1278–1287. [ZHAO X L, WANG G W, ZHOU Z L, et al. 2015. A review of lithology interpretation methods using geophysical well logs[J]. Progress in Geophysics (in Chinese), 2015, 30(3): 1278–1287.]
- [33] 王正, 宋先知, 李根生, 等. 基于MLP-CNN的固井质量智能评价方法[J]. 石油科学通报, 2024, 9(5): 724–736. [WANG Z, SONG X Z, LI G S, et al. Intelligent evaluation method for cementing quality based on MLP-CNN[J]. Petroleum Science Bulletin, 2024, 9(5): 724–736.]

(编辑 付娟娟)

第一作者: 孙正心 (1995年—), 博士研究生, 研究方向为油气工程信息化与智能化, szxzg95@163.com。

通讯作者: 金衍 (1972年—), 博士, 教授, 研究方向为石油工程岩石力学、井壁稳定与水力压裂, 油气工程信息化与智能化等, jinyincup@126.com。