

页岩气核心参数预测的异构异质数据多模态融合算法

罗浚七¹, 汪敏¹, 乔豁通⁴, 邱毅², 张浩洋¹, 孙活³, 谢浩宇¹

(1. 西南石油大学电气信息学院, 成都 610500; 2. 西南石油大学理学院, 成都 610500; 3. 四川铁道职业学院机车车辆学院, 成都 610074; 4. 中国石油集团川庆钻探工程有限公司工程技术部, 成都 610056)

摘要: 不同于以图像为主导的传统多模态融合方法, 工业生产中生产数据常以结构化数据为主, 辅少量的图像数据, 但这两种异构数据都反映了页岩气核心参数特征, 因其在数据维度存在巨大差异, 导致异构数据难以实现特征融合。地层纵向结构化数据间存在异质性, 运用常规深度学习方法预测核心参数存在较大误差。针对以上问题, 提出一种异构异质数据多模态融合算法(Multi-modal fusion algorithm for heterogeneous data, MFH)。首先, 设计了异构数据多模态融合策略, 实现同一深度标签下的扫描电镜和测井参数数据特征对齐、提取和融合; 其次, 构建了异质数据特征拉近机制, 通过构建正样本对使模型学习到同工区地层间的强异质性以及横向的非线性关系; 最后, 提出了异构数据特征交换方法, 解决了丰富的测井数据与稀少的电镜图片的匹配问题, 实现对核心参数精确连续预测。实验结果与主流深度模型预测结果对比, 证明了本文方法具有实用性、有效性和可推广性。

关键词: 多模态融合; 特征拉近机制; 异构数据; 异质性; 注意力机制

中图分类号: TP183

文献标志码: A

Multi-modal Fusion Algorithm for Heterogeneous Data of Shale Gas Core Parameters Prediction

LUO Junqi¹, WANG Min¹, QIAO Huotong⁴, QIU Yi², ZHANG Haoyang¹, SUN Huo³, XIE Haoyu¹

(1. School of Electrical Engineering and Information, Southwest Petroleum University, Chengdu 610500, China; 2. School of Sciences of SWPU, Southwest Petroleum University, Chengdu 610500, China; 3. College of Railway Vehicle Engineering, Sichuan Railway College, Chengdu 610074, China; 4. CNPC Chuanqing Drilling Engineering Company Limited, Chengdu 610056, China)

Abstract: Unlike traditional multi-modal fusion methods that are predominantly image-based, production data in industrial manufacturing are primarily structured data, with a small amount of image features. However, both types of heterogeneous data reflect the core parameters of shale gas. Due to the significant difference in data dimensions, it is challenging to achieve feature fusion of heterogeneous data. Additionally, there is heterogeneity among the stratified structured data, leading to substantial errors in predicting core parameters using conventional deep learning methods. To address these issues, this paper proposes a multi-modal fusion algorithm for heterogeneous data (MFH). Firstly, a multi-modal fusion strategy for heterogeneous data is designed to align, extract, and merge features of scanning electron

基金项目: 国家自然科学基金(62006200); 中国石油-西南石油大学创新联合体科技合作项目(2020CX020000); 四川省科技计划支持项目(2022YFG0179)。

收稿日期: 2024-05-23; **修订日期:** 2024-08-15

microscopy and logging parameters under the same depth labels. Secondly, a mechanism for drawing heterogeneous data features closer is constructed to create positive sample pairs, enabling the model to learn about the strong heterogeneity between strata in the same work area and the lateral nonlinear relationships. Finally, a method for exchanging features of heterogeneous data is introduced to solve the matching problem between abundant logging data and scarce electron microscope images, achieving accurate and continuous prediction of core parameters. Experimental results, compared with predictions from mainstream deep models, prove the practicality, effectiveness, and extensibility of the proposed scheme.

Key words: multi-modal fusion; feature alignment mechanism; heterogeneous data; heterogeneity; attention mechanism

引言

多模态融合技术(Multimodality fusion technology, MFT)^[1]是模型在分析和识别任务时处理不同形式数据的过程。由于不同模态的表现方式不同,看待事物的角度也会不同,所以存在一些交叉互补的现象。合理处理多模态数据,就能得到丰富特征信息,其目标是建立能够处理和关联来自多种模态信息的模型。近年来多模态融合技术常用于自动驾驶、医学诊断等以图像数据为基础的情境,并取得显著进展。基于深度学习模型的常用方法包括多核学习(Multiple kernel learning, MKL)^[2]、概率图模型(Probabilistic graphical models, PGMs)^[3]和深度神经网络(Deep neural networks, DNNs)^[4]等。MKL在学习过程中同时使用多个核函数,来自不同源或模态的数据可以通过选择和组合核来进行有效整合,以增强分类或预测性能。阿尔茨海默病^[5]运用MKL融合多种医学图像更全面地捕捉到复杂的生物标志物。PGMs通过图形化方式直观地表达变量之间的关系,利用条件概率表(Conditional probability tables, CPTs)或概率函数表达变量之间的关系。有效利用数据空间和时间结构,适用于与时间相关的建模任务,还可将人类专家知识嵌入到模型中,增强了模型的可解释性,但是模型的泛化能力有限。DNNs是目前应用最广泛的方法之一。早期的视觉和听觉双模语音识别(Audio-visual speech recognition, AVSR)^[6],近期的神经网络方法通过使用循环神经网络(Recurrent neural network, RNN)^[7]、长短期记忆网络(Long short-term memory, LSTM)^[8]来融合时间多模态信息以及Transformer模型利用自注意力机制有效地捕捉不同模态间的相互关系和互补信息,以提高任务的准确性和效率。

区别于传统多模态融合任务,工业数据常以结构化数据为主,不同模态数据间存在异质性和异构性,如何将多模态融合技术运用于工业场景,成为了具有现实意义的重要课题。在能源需求不断增长的背景下,页岩气作为新兴能源备受关注。孔隙度^[9]、总有机碳含量^[10]等核心指标是页岩气选区与资源评价的关键指标。异构数据^[11]指的是在结构、类型、格式和来源上具有显著差异的数据集。这类数据包括结构化数据、半结构化数据和非结构化数据。传统页岩气核心参数预测方法是使用扫描电镜图像数据和测井参数结构化数据集进行预测。

扫描电镜^[12]可以显示出岩石中的孔隙、裂隙、裂缝等微观孔隙结构,即POR(Porosity),如图1(a~c)所示。根据图像中有机质面积占比计算出总有机碳含量,即TOC(Total organic carbon content),如图1(d~f)所示。通过微米CT扫描得到孔隙度二维灰度图像,实现从微观图像的角度直接对孔隙度进行分析。结合图像处理和机器学习算法,实现对页岩孔隙结构从单一到多尺度的同步表征。但单一扫描电镜分析存在局限性,岩心实验间断而非连续,不能实现核心参数的连续预测。而且,岩心分析实验成本高昂,电镜扫描图像通常是间断、少量、微观的图像数据。




图1 扫描电镜照片

Fig.1 Scanning electron micrograph images

地层纵横向非均质性强,导致测井参数结构化数据存在异质性^[13]。测井参数随井纵向深度变化,通常是连续、大量和宏观的结构化数据。钟海光等^[14]通过对测井参数相关性分析,选取铀含量、声波等测井参数建立多参数页岩储层参数模型,但该模型需要大量的训练参数,且由于地层小层间参数变化范围大,难以实现精确预测。深度学习方法可以预测页岩气核心参数,常使用的如一维卷积网络(One-dimensional convolutional neural network, 1D-CNN)核心参数预测方法。基于门控循环单元(Gated recurrent unit, GRU)^[15]和测井参数可以实现孔隙度参数预测,但传统深度学习模型只能学习到横向的测井参数与核心参数之间的非线性关系,而忽略了井深纵向数据间的强异质性。元学习^[16]中的孪生网络^[17]能够通过训练模型缩小损失函数,拉近输入特征的相似度。通过正样本输入使得模型学习到纵向非均质特性,解决地层纵向异质性问题。

鉴于以上分析,为实现异构数据间多模态数据融合,消除结构化数据纵向异质性,解决异构数据量差异大等问题,本文提出一种异构异质数据多模态融合算法(Multi-modal fusion algorithm for heterogeneous data, MFH)。

1 网络架构

MHF网络架构由异构数据多模态融合策略、异质数据特征拉近机制和异构数据特征交换方法3部分组成。图2展示了网络总体架构。图中, L_{MMD} 表示最大均值化差异损失函数, X_p^I 、 X_p^{II} 、 X_p^{III} 表示前馈神经网络每一层提取的数据特征。异构数据多模态融合策略由3部分组成:异构数据特征对齐、特征提取、特征融合。由于测井结构化数据与扫描电镜图像数据无法实现传统多模态一对一融合。本文设计了深度对齐机制,在测井数据与图像数据都存在的井深深度的实现特征对齐。然后运用卷积神经网络进行图像特征提取,运用前馈神经网络进行测井参数特征提取。最后设计了多模态数据融合方法,实现




图2 MHF网络架构

Fig.2 Framework of MFH

图像与测井参数特征在同一井深深度融合。

异质数据特征拉近机制^[18]借鉴元学习中正样本训练思想。由于地层纵向参数间存在强异质性,直接运用老旧井训练预测模型推广到目标工区会存在较大误差。因此,将预测新井作为锚点,将同一生产工区的老旧井作为正样本,采用最大均值差异(Maximum mean discrepancy, MMD)作为损失函数,提取前馈神经网络中每一层的特征差异性,并运用损失函数进行特征拉近,实现新工区核心参数的快速精确预测。

由于两种异构数据的样本数量和特征维度都相差很大,所以提出异构数据特征交换方法,将存在扫描电镜图像井深,运用异构数据多模态融合策略,实现多模态特征融合。然后将融合后的特征与前馈神经网络在该深度提取的测井参数进行特征交换。在不存在扫描电镜图像的深度,使用测井参数特征,得到整井的核心参数特征。

2 异构异质数据多模态融合算法

2.1 异构数据多模态融合策略

本节阐述异构数据多模态融合策略。该策略分为3部分:多模态特征对齐、多模态特征提取和多模态特征融合。

(1) 多模态特征对齐^[19]。扫描电镜图像是由岩心分析实验拍摄得到,岩心实验中的岩石样本具有深度标签,所以拍摄的扫描电镜照片反映了该深度的核心参数图像信息。测井参数运用地球物理测井法,每隔一定间距通过测量地球物理参数,反映岩石物性参数。扫描电镜图像和测井参数都具有深度标签,运用深度标签对齐可以将扫描电镜图像特征 X_z 与测井参数特征 X_t 进行融合,即

$$X_0 = \text{concat}[X_{\text{class}}; X_z; X_t] \quad (1)$$

式中: X_{class} 为特征分类标签; X_z 为扫描电镜图像特征; X_t 为测井参数特征; $\text{concat}[\cdot]$ 为特征拼接函数。

同时利用神经网络模型进行模态隐式对齐,引入相对位置偏差的多头注意力机制(Multihead self-attention with relative position bias, MSA)^[20]。其能更有效地理解序列中元素之间的依赖关系,从而提升了处理长序列或具有复杂结构的序列数据的性能。具有相对位置偏差的MSA构建分为以下3步:

第1步:相对位置偏差计算。假如输入序列长度为 n ,可以构成1个 $n \times n$ 的相对位置矩阵。其中输入特征元素 X_0 之间的相对位置关系由 a_{ij}^V 、 a_{ij}^K 表示,有

$$a_{ij}^V = W_{i-j}^V \quad (2)$$

$$a_{ij}^K = W_{i-j}^K \quad (3)$$

式中: a_{ij}^V 表示作用于值的相对位置偏差; a_{ij}^K 表示作用于键的相对位置偏差; W_{i-j}^V 、 W_{i-j}^K 表示相对位置索引 $i-j$ 处的可学习偏差参数。

第2步:自注意力机制计算。计算注意力分数 e_{ij} ,对两个输入元素 X_i 、 X_j 进行比较,同时还考虑到边的影响引入 a_{ij}^K 。

$$e_{ij} = \frac{X_i W^Q (X_j W^K + a_{ij}^K)^T}{\sqrt{d_z}} \quad (4)$$

式中: X_i 表示输入序列中位置 i 处的输入特征; X_j 表示输入序列中位置 j 的输入特征; W^Q 表示查询矩阵; W^K 表示键矩阵; d_z 表示注意力头的维度。

计算注意力权重 α_{ij} ,归一化注意力分数,使其变成概率分布,衡量不同输入对输出的贡献。

$$\alpha_{ij} = \frac{\exp(e_{ij})}{\sum_{k=1}^n \exp(e_{ik})} \quad (5)$$

式中 $\exp$ 为指数函数。

最后输入序列 $X=(X_1, X_2, \dots, X_n)$, 通过自注意力计算后得到新的序列 $X'=(X'_1, X'_2, \dots, X'_n)$ 。每一个输出元素 X'_i 都是经过线性变换的输入 X_i 的加权和, 即

$$X'_i = \sum_{j=1}^n \alpha_{ij} (X_j W^V + a_{ij}^V) \quad (6)$$

式中 W^V 为可学习权重参数。

第3步:多头注意力机制融合。多头注意力允许模型同时关注输入序列中不同位置和特征的关系, 从而提高了模型的表示能力。每个注意力头可以学习捕捉不同的特征和关系, 有助于更准确地表达输入数据。

$$Q_h = QW_h^Q, K_h = KW_h^K, V_h = VW_h^V \quad (7)$$

$$X'_h = \text{Attention}(W_h^Q, W_h^K, W_h^V) X \quad (8)$$

$$X_{\text{attention}} = [X'_1, X'_2, \dots, X'_h] W_0 \quad (9)$$

式中: W_0 矩阵的作用是将 h 个注意力机制获得的特征进行融合; Attention 为自注意力计算; Q 为查询向量; K 为键向量; V 为值向量; W_h^Q, W_h^K, W_h^V 为 Q, K, V 进行线性变换时所使用的权重矩阵。

对于扫描电镜图像信息与测井参数数值特征信息, 通过同一深度对齐机制实现特征对齐。再通过相对位置偏差的多头注意力机制, 模型可以自动学习对不同模态的表示进行对齐, 从而使模型更好地理解不同模态之间的关系。

(2) 多模态特征提取。针对扫描电镜图像运用卷积神经网络实现特征提取。本文设计3层的卷积网络^[21]: 第1层卷积层, 使用 3×3 的卷积核, 步长为2; 后两层的卷积层, 卷积核为 3×3 , 步长为1。然后将图像特征经过BN(Batch normalization)层^[22]进行归一化处理, 有助于加速神经网络的训练, 减少梯度消失问题, 提高模型的收敛速度和稳定性。为了克服梯度消失, 使用ReLU激活函数^[23], 加快模型训练速度。同时采用最大池化层^[24], 减少特征图的尺寸, 提取重要特征, 降低计算复杂度, 上述操作有助于模型的训练和泛化。扫描电镜图像经过卷积神经网络进行特征提取得到 X_z 。

本文设计多层的前馈神经网络^[25], 实现测井参数特征提取。前向传播通道由4个前向模块组成, 前向模块由全连接层、ReLU激活函数和Dropout层^[26]组成。将测井参数特征从低维映射到高维后, 提取结构化数据特征。测井参数经过前馈神经网络进行特征提取得到 X_t 。

(3) 多模态特征融合。基于神经网络的多模态融合方法如图3所示。首先将经过多模态特征对齐后的特征 X'_0 进行层归一化(Layer norm, LN)和残差连接后得到 X'_1 , 有

$$X'_1 = \text{LN}(X'_0) + X_0 \quad (10)$$

式中: X'_0 为经过MSA模块后的特征; $\text{LN}(\cdot)$ 表示归一化层; X_0 为式(1)中的拼接后特征。


X'_1 再经过多层感知机(Multi layer perceptron, MLP)和LN得到 X_1 , 有

$$X_1 = \text{MLP}(\text{LN}(X'_1)) + X'_1 \quad (11)$$

式中 $\text{MLP}(\cdot)$ 表示多层感知机。

然后将 X_1 再经过一次具有相对位置偏差的MSA和MLP以及归一化层得到 X_2 , 即

$$X'_2 = \text{MSA}(\text{LN}(X_1)) + X_1 \quad (12)$$



Layer norm: 层归一化

MLP: 多层感知器

DropPath: 路径丢弃层

Residual connection: 残差连接

图3 神经网络的多模态融合架构

Fig.3 Multi-modal fusion architecture of neural networks

$$X_2 = \text{MLP}(\text{LN}(X_2')) + X_2' \quad (13)$$

式中 $\text{MSA}(\bullet)$ 为具有相对位置偏差的多头注意力机制 $\text{MLP}(\bullet)$ 。将 X_1 和 X_2 进行拼接, 实现异构数据的多模态特征融合, 即

$$X_S = \text{concat}(X_1, X_2) \quad (14)$$

式中 $\text{concat}(\bullet)$ 为特征拼接函数。

运用深度融合机制, 可以将宏观-微观数据映射到同一纬度, 实现了多源数据拼接, 为参数预测提供更加多源的特征信息, 有效提高了目标参数的预测精度。

2.2 异质数据特征拉近机制

本节将阐述异质数据特征拉近机制, 其分为两部分: 双输入测井参数模型和正样本特征拉近。

(1) 双输入测井参数模型。该模型由 2 个相同结构的子网络组成, 以 2 个样本为输入, 输出其嵌入高维度空间的表征, 通过损失函数计算以比较两个样本的相似程度, 并最小化损失函数以实现特征拉近, 提高预测精度。

由于地层非均质性强, 老旧井与新井之间的数据差异大, 直接运用老旧井数据训练模型预测新井核心参数的预测偏差大。本文改进多模态特征提取中的前馈神经网络模型, 设计双输入测井参数网络。首先构建双输入数据集。将预测新井作为锚点, 同一工区老旧井作为正样本。从海量的测井参数中选取自然伽马(Natural Gamma ray, GR)、无铀伽马(K-Th Gamma ray, KTH)、声波(Acoustic travel time, AC)、补偿密度(Compensated density log, DEN)和铀(Uranium, U)作为测井参数, 实现对核心参数的预测。通过以上测井参数, 构建正样本数据集 $G_w(X_q) = \{x_q^i, y_q^i\}_{i=1}^n$, 其中 n 代表正样本数据集数量, $x_q^i = \{x_q^{i1}, x_q^{i2}, x_q^{i3}, x_q^{i4}, x_q^{i5}\}$ 代表第 i 行中 5 个数据参数, y_q^i 代表正样本核心参数真实值。构建锚点数据集 $G_w(X_p) = \{x_p^j\}_{j=1}^m$, 其中 m 代表锚点数据集数量, 没有核心参数标签, 需要进行核心参数预测。

然后设计 3 层的前馈神经网络作为测井参数特征提取模型的子网络。每一层都由全连接层、ReLU 激活函数和 Dropout 层组成。将特征映射到高维, 可以让网络有更多的参数来捕捉数据中的复杂关系和模式。在高维空间中, 数据点更可能是线性可分的, 这使得学习算法能够更容易地分类或回归。获得每一层映射后的正样本与锚点特征。

(2) 正样本特征拉近。模型中通过损失函数进行特征拉近的意义在于学习到一种特征表示, 使得相似的样本在特征空间中更加接近, 而不相似的样本则更加远离。同一工区具有类似的地层非均质性, 通过损失函数拉近, 可以使得模型学习到正样本的非均质特性, 提高新工区预测精度。

本文运用最大均值化差异 L_{MMD} 作为损失函数, 计算锚点与正样本之间的特征距离。

$$L_{\text{MMD}} = \frac{1}{n^2} \sum_{i=1}^n \sum_{i=1}^n k(x_q^i, x_q^i) + \frac{1}{m^2} \sum_{j=1}^m \sum_{j=1}^m k(x_p^j, x_p^j) - \frac{1}{nm} \sum_{i=1}^n \sum_{j=1}^m k(x_q^i, x_p^j) \quad (15)$$

式中: x_q^i 为正样本数据集; x_p^j 为锚点数据集; n 为正样本数据集数量; m 为锚点数据集数量; $k(\bullet)$ 表示核函数。

经过双输入测井参数网络 3 层特征提取, 获取每层样本对提取特征 (x_q', x_p') 、 (x_q'', x_p'') 、 (x_q''', x_p''') , 进行相似度计算。

$$L_S = \lambda_1 L_{\text{MMD}}(x_q', x_p') + \lambda_2 L_{\text{MMD}}(x_q'', x_p'') + \lambda_3 L_{\text{MMD}}(x_q''', x_p''') \quad (16)$$

式中 λ_1 、 λ_2 和 λ_3 为 0~1 之间的超参数。

本文的总体损失函数由均方损失函数计算出的融合拉近后的新井核心参数预测值与真实值的差异、最大均值化差异计算锚点与正样本的特征差异两部分构成。

$$L_{\text{total}} = L_{\text{mse}}(\hat{Y}, Y) + L_S \quad (17)$$

式中: $\hat{Y}$ 表示核心参数预测值; Y 表示核心参数真实值; L_{mse} 表示均方误差损失函数。

本文运用随机梯度下降法来迭代更新模型参数,以最小化损失函数。

$$\theta = \theta - \alpha \frac{\partial L_{\text{total}}}{\partial \theta} \quad (18)$$

式中: θ 表示需要更新的模型参数; α 为学习率用于调节 θ 的更新速度。

通过调节模型参数,约束损失函数达到最小,实现锚点与正样本之间的特征拉近,使得模型学习到同一工区地质特性,同时缩小预测值与真实值的差异,实现核心参数的精确预测。

2.3 异构数据特征交换方式

实际工业数据中,测井参数与扫描电镜两种异构数据,存在难以实现与测井参数之间进行一对一特征融合的少样本问题。本文提出异构数据特征交换方法,有效解决了不同数量级下测井数据与电镜图片匹配的问题。

首先,老旧井正样本测井数据经过双输入测井参数网络特征提取得到测井参数特征,表示为

$$\mathbf{h}_q^i = f_1(\mathbf{X}_q^i) \quad (19)$$

式中: $\mathbf{X}_q^i$ 表示正样本井在深度 i 处的测井数据特征; $f_1(\bullet)$ 表示双输入测井参数模型。

然后在存在扫描电镜深度的情况下,提取出的测井参数特征 $\mathbf{h}_q^i$ 与该深度下的图像特征数据 $\mathbf{X}_z^j$ 进行少样本特征融合,获得深度 j 下的融合后的特征 $\mathbf{X}_s^j$,即有

$$\mathbf{X}_s^j = f_2(\mathbf{h}_q^i, \mathbf{X}_z^j) \quad (20)$$

式中: $f_2(\bullet)$ 表示异构数据多模态融合策略模块; $\mathbf{h}_q^i$ 表示深度 j 下的测井数据特征; $\mathbf{X}_z^j$ 表示深度 j 下的扫描电镜图像特征。

将融合后的特征通过MLP映射到与测井参数特征相同维度,有

$$\mathbf{h}_{q'}^j = \text{MLP}(\mathbf{X}_s^j) \quad (21)$$

最后根据深度索引 j ,将融合后的特征 $\mathbf{h}_{q'}^j$ 交换同一深度的测井参数特征 $\mathbf{h}_q^j$,得到整井融合后的特征 $\mathbf{X}_{\text{total}}$ 。将核心参数特征经过全连接层分类得到核心参数预测结果,有

$$\text{Predict} = \text{Linear}(\mathbf{X}_{\text{total}}) \quad (22)$$

式中: $\text{Linear}(\bullet)$ 表示线性层; $\mathbf{X}_{\text{total}}$ 表示预测井数据特征。

3 实验结果与分析

3.1 数据集和评价指标

实验采用6个真实页岩气测井储层数据集,进行3组实验。实验1利用L1井、L2井、L3井、L4井测井参数与页岩图像作为正样本建模,实现对N1井核心参数预测。实验2利用N1井、N2井、N3井、L1井测井参数与页岩图像作为正样本建模,实现对L2井核心参数预测。实验3利用N1井、N2井、N3井、L1井测井参数与页岩图像作为源域建模,实现对L3井核心参数预测,以验证本文方法的有效性。详细井信息见表1。

根据文献[27],选用均方误差(Mean square error, MSE)、平均绝对误差(Mean absolute error, MAE)和相对误差(Mean absolute percentage error, MAPE)作为评价指标,综合衡量模型的预测性能。3个指标的值越小,表示预测值与真实值之间的距离越相近,预测效果越好。

表1 实验数据信息表

井名	地层	深度范围/m
L1	龙一1 ⁴ -五峰组	4 048.61~4 158.84
L2	龙一1 ⁴ -五峰组	3 968.75~4 052.27
L3	龙一1 ⁴ -五峰组	3 714.87~3 755.75
L4	龙一1 ⁴ -五峰组	3 992.18~4 049.85
N1	龙一1 ⁴ -五峰组	3 700.75~3 764.25
N2	龙一1 ⁴ -五峰组	4 299.37~4 332.00
N3	龙一1 ⁴ -五峰组	2 935.620~2 962.835

$$\text{MSE} = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

(23)

$$\text{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i|$$

(24)

$$\text{MAPE} = \frac{1}{m} \sum_{i=1}^m \frac{|y_i - \hat{y}_i|}{y_i} \times 100\%$$

(25)

式中: y_i 为样本真实值; $\hat{y}_i$ 为样本预测值。

为了更好地验证本文算法的实用性、有效性和可推广性,将本文方法与主流机器学习算法进行了对比,即与基于卷积网络的页岩气地质“甜点”参数预测和深度神经网络进行了对比试验。本文与主流深度学习模型采用完全相同的实验参数设置。网络参数初始化状态相同,样本批量大小(batch_size)=50,使用随机梯度下降算法(Stochastic gradient descent, SGD)^[28]对网络结构进行优化,初始学习率设置为0.001,激活函数选用ReLU。

3.2 实验分析

3.2.1 N1井核心参数预测(实验1)

源域数据集由L1井、L2井、L3井和L4井的结构化测井参数以及扫描电镜构建。运用源域数据集进行预测模型训练,将完成训练的预测模型,对目标域数据N1井龙一¹₄小层-五峰组进行储层参数预测。本文方法与基于卷积网络的页岩气地质核心参数预测和深度神经网络进行了3组对比试验:(1)不添加扫描电镜结果对比;(2)与卷积网络结果对比;(3)与深度神经网络结果对比。

表2是N1井的孔隙度和总有机碳含量预测评估结果,以总有机碳含量的MAE为例,本文方法MAE为0.394,比无扫描电镜法MAE降低0.049,比CNN网络降低0.233,比DNN网络MAE降低0.27。本文方法预测结果全部优于3个只运用测井数据的预测结果,表明了将扫描电镜作为多模态特征加入模型的必要性,证明扫描电镜也反映了核心参数微观特征。

3.2.2 L2井核心参数预测(实验2)

源域数据集由L1井、N1井、N2井和N3井的结构化测井参数以及扫描电镜构建。运用源域数据集进行预测模型训练,将完成训练的预测模型,对目标域数据的L2井龙一₁亚段4小层-五峰组进行储层参数预测。本文方法与基于卷积网络的页岩气地质“核心”参数预测和深度神经网络进行了3组对比试验:(1)不添加扫描电镜结果对比;(2)与卷积网络结果对比;(3)与深度神经网络结果对比。

表3是L2井的孔隙度和总有机碳含量预测评估结果,以孔隙度的MAE为例,本文方法MAE为0.391,比无扫描电镜法MAE降低0.042,比CNN网络MAE降低0.288,比DNN网络MAE降低0.35。本文方法预测结果全部优于3个只运用测井数据的预测结果,表明将扫描电镜作为多模态特征加入模型的必要

表2 实验1预测结果

Table 2 Prediction results of experiment 1

井号	参数	方法	MAE	MSE	MAPE/%
N1井	POR	本文方法	0.371	0.235	12.059
		无扫描镜	0.424	0.283	13.705
		CNN	0.458	0.323	13.382
		DNN	0.547	0.454	17.989
	TOC	本文方法	0.394	0.272	22.594
		无扫描镜	0.443	0.325	23.967
		CNN	0.627	0.893	29.789
		DNN	0.664	0.984	34.406

表3 实验2预测结果

Table 3 Prediction results of experiment 2

井号	参数	方法	MAE	MSE	MAPE/%
L2井	POR	本文方法	0.391	0.344	10.592
		无扫描镜	0.433	0.467	12.174
		1D-CNN	0.679	0.642	19.027
		DNN	0.741	0.719	19.957
	TOC	本文方法	0.902	1.077	47.356
		无扫描镜	1.009	1.315	52.087
		1D-CNN	1.160	1.522	47.436
		DNN	1.154	1.517	48.488

性,证明扫描电镜也反映了核心参数微观特征。

3.2.3 L3井核心参数预测(实验3)

源域数据集由L1井、N1井、N2井和N3井的结构化测井参数以及扫描电镜构建。运用源域数据集进行预测模型训练,将完成训练的预测模型,对目标域数据L3井龙一₁亚段4小层-五峰组进行储层参数预测。本文的方法与基于卷积网络的页岩气地质“核心”参数预测和深度神经网络进行了3组对比试验:(1)不添加扫描电镜结果对比;(2)与卷积网络结果对比;(3)与深度神经网络结果对比。

表4是L3井的孔隙度和总有机碳含量预测评估结果。以孔隙度的MAE为例,本文方法MAE为0.391,比无扫描电镜法MAE降低0.042,比CNN网络MAE降低0.288,比DNN网络MAE降低0.35。本文方法预测结果全部优于3个只运用测井数据的预测结果,表明将扫描电镜作为多模态特征加入模型的必要性,证明扫描电镜也反映了核心参数微观特征。

3.2.4 实验结果分析

本文对3组实验的实验结果进行分析总结。由实验结果可以看出:本文方法设计实验证明扫描电镜能为核心参数预测提供更加丰富的微观结构信息;使用扫描电镜的核心参数预测精度高于未使用扫面电镜的预测精度,同时与CNN网络与DNN网络算法相比较,本文方法取得了更加优异且稳定的预测性能。但表2和表4的实验结果显示,本文实验结果优势并不明显,主要存在以下几个原因:

(1)页岩气核心参数预测井为超深层井,井深达数千米,井下情况复杂且难以预测。本文提出的多模态融合方法,只能在一定程度上提高核心参数预测精度,面对井下其他未知问题,还需更加深入研究。

(2)异构数据纬度差异大,井深数千米,测井参数间隔0.125 m,扫描电镜照片间隔数10 m。预测结果主要受测井参数数据影响,扫描电镜只能起到辅助修正作用,所以相较于直接运用测井参数进行预测的CNN、DNN模型实验结果优势不明显。

(3)地层存在纵向异质性问题。本文提出双输入测井参数模型,用于解决此问题,但双输入模型的正样本对必须存在相同类别属性。但由于井数据稀缺,实验1和实验3中,正样本对中的4口井与预测井并不完全属于同一工区,导致模型没有完全学习到预测井工区的地层异质性,所以没有达到更好的预测精度。

(4)扫描电镜照片数据稀缺,本文虽然运用数据增强方法,但卷积神经网络在少样本情况下,对旋转、缩放等几何变换的图像处理能力较差。如果使用ResNet和VIT模型进行扫描电镜图像特征提取,能更好地捕捉微观孔隙结构。

3.3 可视化实验分析

3.3.1 实验结果对比图

图4和图5分别为N1井、L3井参数预测结果对比图。黄色柱状图为岩心实测核心参数,黑色曲线代表CNN网络预测结果,蓝色曲线代表DNN网络预测结果,绿色曲线代表运用测井参数预测结果,红色曲线代表本文方法。本文方法预测曲线与岩心数据最为贴合,一致性最好。

表4 实验3预测结果

Table 4 Prediction results of experiment 3					
井号	参数	方法	MAE	MSE	MAPE/%
L3井	POR	本文方法	0.553	0.527	17.263
		无扫描镜	0.959	1.322	28.744
		1D-CNN	0.758	0.803	18.409
		DNN	0.815	0.901	19.279
	TOC	本文方法	0.522	0.565	19.842
		无扫描镜	0.547	0.842	21.013
		1D-CNN	0.829	0.835	27.394
		DNN	0.844	0.866	27.593




图4 N1井核心参数预测对比图

Fig.4 Comparison chart for N1 well core parameter prediction




图5 L3井核心参数预测对比图

Fig.5 Comparison chart for L3 well core parameter prediction

3.3.2 样本对特征分布可视化

为直观表示双输入双输入测井参数网络,实现正样本对之间的特征拉近,学习到纵向核心参数之间的异质性,本节对实验过程进行可视化,从数据集散点图和损失函数优化方面阐述特征拉近过程。

图6和7分别是N1井和L2井的孔隙度、总有机碳含量的测井参数变化过程。以图6举例说明,图6(a1,b1)分别是N1井的孔隙度、总有机碳含量的损失函数;图6(a2,b2)分别是N1井的孔隙度、总有机碳含量的初始特征分布。蓝色圆点代表老旧井测井参数特征,红色圆点代表预测井测井参数特征。红色和蓝色圆点重叠面积越大说明数据分布差异越小。图6(a3,b3)是N1井训练30个epoch的特征分布;图6(a4,b4)是N1井训练50个epoch的特征分布;图6(a5,b5)是N1井完成训练后的特征分布。随着网络迭代训练,损失值逐渐减少且收敛,双输入数据特征数据分布逐渐减小,证明了双输入测井参数网络可以拉近异质性数据。




图6 N1井损失曲线与特征分布可视化

Fig.6 Visualization of well N1 loss curve and characteristic distribution




图7 L2井损失曲线与特征分布可视

Fig.7 Visualization of well L2 loss curve and characteristic distribution

3.4 消融实验

为验证双输入测井参数模型的有效性,本文将单输入前馈神经模型与双输入测井参数模型进行对比试验。表5是N1井的消融实验结果,表6是L2井的消融实验结果,表7是L3井的消融实验结果。经过预测结果对比分析,双输入测井参数网络预测效果明显更优,证明了特征拉近对提高核心参数预测精度和纵向数据特征拉近具有有效性。

表 6 L2井消融实验结果

Table 6 Ablation test results for well L2					
井号	参数	网络架构	MAE	MSE	MAPE/%
L2井	POR	本文网络	0.391	0.344	10.592
		前馈网络	0.619	0.423	18.236
	TOC	本文网络	0.902	1.077	47.356
		前馈网络	1.057	1.209	58.631

表 5 N1井消融实验结果

Table 5 Ablation test results for well N1					
井号	参数	网络架构	MAE	MSE	MAPE/%
N1井	POR	本文网络	0.371	0.235	12.059
		前馈网络	0.507	0.320	16.594
	TOC	本文网络	0.394	0.272	22.594
		前馈网络	0.499	0.379	31.459

表 7 L3井消融实验结果

Table 7 Ablation test results for well L3					
井号	参数	网络架构	MAE	MSE	MAPE/%
L3井	POR	本文网络	0.553	0.527	17.263
		前馈网络	0.661	0.747	18.779
	TOC	本文网络	0.522	0.565	19.842
		前馈网络	0.844	0.866	27.593

3.5 对比实验

由于测井参数与扫描电镜数据在数据纬度上差异巨大,不可能实现一一对应,所以本文提出异构数据特征交换方法,对页岩气核心参数进行连续预测。在同时存在两种异构数据深度的情况下,将经过多模态融合架构的融合特征与该深度双输入测井参数模型提取到的测井参数特征进行交换。本文还使用了自编码融合交换和注意力机制交换2种方法与本文方法对比,实验结果如表8~10所示。

表 8 N1井对比实验结果

Table 8 Comparative experimental results for well N1					
井号	参数	方法	MAE	MSE	MAPE/%
N1井	POR	本文方法	0.371	0.235	12.059
		自编码	0.428	0.293	13.907
		注意力	0.432	0.298	13.836
	TOC	本文方法	0.394	0.272	22.594
		自编码	0.414	0.296	22.895
		注意力	0.408	0.282	22.080

表 9 L2井对比实验结果

Table 9 Comparative experimental results for well L2					
井号	参数	方法	MAE	MSE	MAPE/%
L2井	POR	本文方法	0.391	0.344	10.592
		自编码	0.409	0.295	11.594
		注意力	0.414	0.298	11.901
	TOC	本文方法	0.902	1.077	47.356
		自编码	0.989	1.144	53.341
		注意力	0.891	1.112	45.918

从实验结果分析得知3种异构数据的特征交换方法对实验结果的影响并不明显;相反本文的异构数据特征交换方法效果大部分优于自编码特征交换和注意力机制交换。以表10(L3井预测POR)为例,本文方法比自编码特征交换法MAPE降低1.596%,比注意力机制法MAPE降低9.95%。导致实验结果差异不明显主要有以下两个因素:(1)MHF网络架构模型由两个异构数据特征子模型和多模态特征融合框架构成,模型结构

表 10 L3井对比实验结果

Table 10 Comparative experimental results for well L3					
井号	参数	方法	MAE	MSE	MAPE/%
L3井	POR	本文方法	0.553	0.527	17.263
		自编码	0.605	0.538	18.859
		注意力	0.956	1.163	27.213
	TOC	本文方法	0.522	0.565	19.842
		自编码	0.578	0.496	23.904
		注意力	0.524	0.639	19.084

本身已经非常复杂,且融合框架模块已经运用过相对位置偏差的MSA,如果在特征交换部分再运用注意力机制等复杂的特征交换方法可能会导致模型出现冗余、过拟合等现象;(2)异构数据特征交换并非MHF网络框架的主体结果,异构数据多模态融合策略和异构数据特征拉近机制才是影响实验结果的主要关键因素,所以基于模型轻量化等考虑,在不同异构数据特征交换方法对实验结果影响差异不大的情况下,可以使用本文的异构数据特征交换方法。

4 结束语

本文将多模态融合算法运用于实际工业生产中,设计了异构异质数据多模态融合算法,实现了测井结构化数据与扫描电镜图像数据两种异构数据匹配融合,同时运用双输入测井参数网络特征拉近解决了结构化数据间存在强异质性问题。通过真实工业数据集证明了MFH算法在测井数据处理领域,尤其是页岩气储层甜点区判断方面的可行性和优越性。未来研究工作主要包括以下3个方面:(1)进一步优化多模态特征提取模块,如Transformer等;(2)扩大正样本数据,使模型充分学习到地层数据异质性,提高模型泛化能力;(3)将异构异质数据多模态融合算法应用于其他以结构化数据为基础的实际工业领域。

参考文献:

- [1] LAHAT D, ADALI T, JUTTEN C. Multimodal data fusion: An overview of methods, challenges, and prospects[J]. *Proceedings of the IEEE*, 2015, 103(9): 1449-1477.
- [2] YEH Y R, LIN T C, CHUNG Y Y, et al. A novel multiple kernel learning framework for heterogeneous feature fusion and variable selection[J]. *IEEE Transactions on Multimedia*, 2012, 14(3): 563-574.
- [3] SUTTON C, MCCALLUM A. An introduction to conditional random fields[J]. *Foundations and Trends in Machine Learning*, 2012, 4(4): 267-373.
- [4] NGIAM J, KHOSLA A, KIM M, et al. Multimodal deep learning[C]//*Proceedings of ICML*. Bellevue, Washington, USA: [s.n.], 2011, 11: 689-696.
- [5] LIU F, ZHOU L, SHEN C, et al. Multiple kernel learning in the primal for multimodal Alzheimer's disease classification[J]. *IEEE Journal of Biomedical and Health Informatics*, 2013, 18(3): 984-990.
- [6] AFOURAS T, CHUNG J S, SENIOR A, et al. Deep audio-visual speech recognition[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 44(12): 8717-8727.
- [7] GROSSBERG S. Recurrent neural networks[J]. *Scholarpedia*, 2013, 8(2): 1888.
- [8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735-1780.
- [9] ANOVITZ L M, COLE D R. Characterization and analysis of porosity and pore structures[J]. *Reviews in Mineralogy and Geochemistry*, 2015, 80(1): 161-164.
- [10] DAI J, ZOU C, DONG D, et al. Geochemical characteristics of marine and terrestrial shale gas in China[J]. *Marine and Petroleum Geology*, 2016, 76: 444-463.
- [11] KUMAR G, BASRI S, IMAM A A, et al. Data harmonization for heterogeneous datasets: A systematic literature review[J]. *Applied Sciences*, 2021, 11(17): 8275.
- [12] 宋党育, 何凯凯, 吉小峰, 等. 基于CT扫描的煤中孔裂隙精细表征[J]. *天然气工业*, 2018, 38: 41-49.
SONG Dangyu, HE Kaikai, JI Xiaofeng, et al. Fine characterization of pores and fractures in coal based on a CT scan[J]. *Natural Gas Industry*, 2018, 38: 41-49.
- [13] LI H, REYNOLDS J F. On definition and quantification of heterogeneity[J]. *Oikos*, 1995, 73(2): 280-284.
- [14] QIN Z, XU T. Shale gas geological "sweet spot" parameter prediction method and its application based on convolutional neural network[J]. *Scientific Reports*, 2022, 12(1): 15405.
- [15] ZHANG Z, WANG Y, WANG P. On a deep learning method of estimating reservoir porosity[J]. *Mathematical Problems in Engineering*, 2021(1): 6641678.

- [16] VANSCHOREN J. Meta-learning[J]. Automated Machine Learning: Methods, Systems, Challenges, 2019: 35-61.
- [17] CHEN X, HE K. Exploring simple siamese representation learning[C]//Proceedings of Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2021: 15750-15758.
- [18] 汪敏, 杨桃, 唐洪明, 等. 迁移深度神经网络的页岩总孔隙度预测[J]. 西南石油大学学报(自然科学版), 2023, 45: 69-79.
WANG Min, YANG Tao, TANG Hongming, et al. Prediction for total porosity of shale based on transfer deep neural network[J]. Journal of Southwest Petroleum University (Science & Technology Edition), 2023, 45: 69-79.
- [19] KARPATY A, FEI-FEI L. Deep visual-semantic alignments for generating image descriptions[C]//Proceedings of Computer Vision and Pattern Recognition. Boston, Massachusetts, USA: IEEE, 2015: 3128-3137.
- [20] NIU Z, ZHONG G, YU H. A review on the attention mechanism of deep learning[J]. Neurocomputing, 2021, 452: 48-62.
- [21] ALZUBAIDI L, ZHANG J, HUMAIDI A J, et al. Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions[J]. Journal of Big Data, 2021, 8: 1-74.
- [22] BA J, KIROUS J K, HINTON G E. Layer normalization[C]//Proceedings of the 33rd International Conference on Machine Learning (ICML 2016). New York, USA: PMLR, 2016: 1-8.
- [23] BANERJEE C, MUKHERJEE T, PASILIAO JR E. An empirical study on generalizations of the ReLU activation function [C]//Proceedings of Proceedings of the 2019 ACM Southeast Conference. Columbia, South Carolina, USA: Association for Computing Machinery, 2019: 164-167.
- [24] WU H, GU X. Max-pooling dropout for regularization of convolutional neural networks[C]//Proceedings of Neural Information Processing: 22nd International Conference, ICONIP 2015. Istanbul, Turkey: Springer, 2015: 46-54.
- [25] SVOZIL D, KVASNICKA V, POSPICHAL J. Introduction to multi-layer feed-forward neural networks[J]. Chemometrics and Intelligent Laboratory Systems, 1997, 39(1): 43-62.
- [26] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting[J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [27] HODSON T O. Root mean square error (RMSE) or mean absolute error (MAE): When to use them or not[J]. Geoscientific Model Development Discussions, 2022, 15(14): 5481-5487.
- [28] BOTTOU L. Stochastic gradient descent tricks[M]. 2nd ed. Berlin, Germany; Springer, 2012: 421-436.

作者简介:



罗浚七(2000-),男,硕士研究生,研究方向:数据挖掘,E-mail:luojqzzz7@163.com。



汪敏(1980-),通信作者,女,教授,博士生导师,研究方向:机器学习、数据挖掘、主动学习,E-mail:Wang-min@swpu.edu.cn。



乔懿通(1989-),男,工程师,研究方向:钻井工艺安全。




邱毅(1979-),男,副教授,硕士生导师,研究方向:光电材料计算、激光光学、机器学习。



张浩洋(2000-),男,硕士研究生,研究方向:智能算法应用。



孙活(1983-),男,副教授,研究方向:信息技术、深度学习。



谢浩宇(2000-),男,硕士研究生,研究方向:图像识别。

(编辑:刘彦东)