

基于ResNet残差神经网络识别的深部煤层显微组分和微裂缝分类

——以鄂尔多斯盆地石炭系本溪组8#煤层为例

刘大锰^{1,2}, 王子豪^{1,2}, 陈佳明^{1,2}, 邱峰^{1,2}, 朱凯^{1,2}, 高岭杰^{1,2}, 周柯宇^{1,2}, 许少博^{1,2}, 孙逢瑞^{1,2}

[1. 中国地质大学(北京)能源学院, 北京 100083; 2. 非常规天然气地质评价与开发北京市重点实验室, 北京 100083]

摘要:显微组分和微裂缝是煤储层重要的微观特征,影响煤储层产气能力和力学性质。采集鄂尔多斯盆地深部煤层气井石炭系本溪组8#煤层样品,运用ResNet残差神经网络识别方法,研究了显微组分和微裂缝发育特征。在煤样305个显微组分和65个微裂缝图样本研究的基础上,建立了基于残差神经网络识别的煤岩显微组分和微裂缝识别方法,并利用残差神经网络技术对镜下数据进行反演,构建了深部煤储层显微组分和微裂缝的识别和分类模型。结合地质特征和聚类算法结果联合验证,模型具有可靠性。显微组分预测准确率为0.90,微裂缝预测准确率为0.80,可以有效预测煤岩显微组分和微裂缝类型。模型识别与预测表明裂缝形态与显微组分具有相关关系。裂缝的发育与显微组分中的镜质组关系最大,裂缝类别和数量的预测结果与显微组分发育的相吻合。

关键词:分类模型;残差神经网络;显微组分;微裂缝;深部煤储层;煤层气;石炭系;鄂尔多斯盆地

中图分类号:TE122.2

文献标识码:A

Classification of macerals and microfractures in deep coal seams based on ResNet: A case study of the No. 8 coal seam of the Carboniferous Benxi Formation in the Ordos Basin

LIU Dameng^{1,2}, WANG Zihao^{1,2}, CHEN Jiaming^{1,2}, QIU Feng^{1,2}, ZHU Kai^{1,2}, GAO Lingjie^{1,2},
ZHOU Keyu^{1,2}, XU Shaobo^{1,2}, SUN Fengrui^{1,2}

[1. School of Energy Resources, China University of Geosciences (Beijing), Beijing 100083, China; 2. Beijing Key Laboratory of Unconventional Natural Gas Geological Evaluation and Development Engineering, Beijing 100083, China]

Abstract: Macerals and microfractures are identified as important microscopic characteristics of coal reservoirs, as they are factors affecting the reservoirs' gas production capacity and mechanical properties. Based on coal samples from the No. 8 coal seam of the Carboniferous Benxi Formation in deep coalbed methane wells in the Ordos Basin, we investigate the developmental characteristics of macerals and microfractures using a residual neural network (ResNet). With 305 maceral and 65 microfracture sample points from the sampled coal, we develop a ResNet-based methodology for identifying macerals and microfractures in coals, and construct an identification and classification model for macerals and microfractures in deep coal reservoirs through the inversion of microscopically observed data using the ResNet technique. The results indicate that the model is reliable, as jointly corroborated by geological characteristics and clustering algorithm-derived results. The model demonstrates a prediction accuracy of 0.90 for macerals and 0.80 for microfractures, enabling the effective prediction of macerals and microfractures in coals. The identification and prediction results of the model reveal correlations between fracture morphologies and macerals. Notably, the fracture formation is the most closely correlated with vitrinites in macerals, with the predicted fracture types and numbers agreeing well with macerals.

Key words: classification model, residual neural network (ResNet), maceral, microfracture, deep coal reservoir, coalbed methane, Carboniferous, Ordos Basin

收稿日期:2024-06-10;修回日期:2024-10-11。

第一作者简介:刘大锰(1965—),男,教授、博士研究生导师,煤层气储层地质学。E-mail: dmliu@cugb.edu.cn。

基金项目:国家自然科学基金项目(42130806)。

引用格式:刘大锰,王子豪,陈佳明,等. 基于ResNet残差神经网络识别的深部煤层显微组分和微裂缝分类[J]. 石油与天然气地质, 2024, 45(6): 1524–1536. DOI: 10. 11743/ogg20240602.

LIU Dameng, WANG Zihao, CHEN Jiaming, et al. Classification of macerals and microfractures in deep coal seams based on ResNet: A case study of the No. 8 coal seam of the Carboniferous Benxi Formation in the Ordos Basin [J]. Oil & Gas Geology, 2024, 45(6): 1524–1536. DOI: 10. 11743/ogg20240602.

地质问题常表现为分类问题和回归问题^[1-3]。深部煤储层特征因对于生气和采气能力的控制作用而成为研究的重点^[4-5]。显微组分是煤储层的微观组分单元,不同的组分受控于煤层原始沉积环境和沉积过程,决定煤层的微观力学性质并影响煤层的产气能力^[6-8]。微裂缝形成于沉积或构造作用,其实质是应力-应变下的微小损伤。微裂缝对于储层的渗透率、岩石力学性质和后续裂缝的萌发和扩展有重要的作用^[9-12]。显微组分和微裂缝的常规识别方法是通过显微镜直接观察,然而人工识别在大样本下可能存在稳定性不佳和效率不高的问题,因此需要一种更有效的显微组分和微裂缝分类识别方法。

机器学习包括传统机器学习算法和深度学习算法。对于如测试数据和测井数据的数字模型,以随机森林和支持向量机为代表的传统算法拥有较好的效果^[13-15],但在相对复杂的图片识别和分类问题中,深度学习具有明显的计算优势^[16-19]。神经网络的本质是不同层和神经元的排布模型,将以张量的形式表示的数据导入输入层,单次或多次连续输入的数据在层间传递,利用已经确定的数据分类反向训练整个网络参数^[20]。深度学习自从 Alex Krizhevsky 等人设计应用至今,基于神经网络的识别方法已经应用于成像测井反演、地震图像反演和镜下观察反演等众多领域^[21-27]。已有研究开展了关于神经网络对显微组分的分类识别,但研究成果多集中在算法分类和预测的准确率上,很少涉及算法实现的过程和结果的评价验证^[28]。另外,对于煤储层微观结构中微裂缝的识别研究较少,且对于分类的依据研究不足。

本文基于经典的残差网络模型 Resnet 进行图像识别与分类,结合分类结果和聚类分析方法,研究了煤岩显微组分和微裂缝发育模式,从地质分析的角度分析了识别结果的合理性,为深部煤层的微观特征识别和产气机理研究提供思路,为深部煤层气的高效开发提供一定借鉴。

1 样品采集与分析

鄂尔多斯盆地是目前煤层气开发的重要盆地之

一,也是深部煤层气探索的主力区域^[29]。鄂尔多斯盆地煤层含气面积达 $28 \times 10^4 \text{ km}^2$,煤层气资源量为 $10.72 \times 10^{12} \text{ m}^3$,其中深部煤层气占比 75%。石炭系本溪组 8#煤层全区发育较稳定且厚度较大,埋深在 2 000 ~ 3 000 m,是区域开发的主要层段^[30-31](图 1)。

此次研究的 34 个煤样取自鄂尔多斯盆地中、东部 5 口井本溪组 8#煤层,埋深 2 420 ~ 3 900 m;显微组分以镜质组为主,惰质组含量较高,灰分产率变化较大,煤样具有一定的代表性(表 1)。

2 模型与方法

2.1 显微组分和微裂缝类型

显微组分主要包括镜质组、惰质组和壳质组,以及以黏土矿物为主的无机组分^[6,32]。显微组分含量可以用于分析煤储层的沉积模式,其与煤的宏观煤岩类型相关,也决定着煤的细观力学性质^[7]。对于深部煤层,因其较高的变质程度和成熟度,壳质组发育极少。由于研究区本溪组 8#煤层壳质组样本仅集中记录于 M 井中,参与训练的样本点过少会导致模型在壳质组分类判断的泛化性能变差,因此在本文研究中,对于显微组分的分类和预测采用镜质组、惰质组、黏土矿物和黄铁矿构成的四分类模型。

对于显微组分的图像训练集进行标注是视觉处理的重要步骤。本文在针对不同的显微组分添加标签时遵循以下 2 个原则:① 将镜下大面积发育的镜质组、惰质组和黏土矿物图片样本选作训练集中的显微组分;② 把含有数量较少但特征显著的黄铁矿图片样本标注为黄铁矿,并作为训练集中的黄铁矿。图片的标注实质上是为了确保特征传递和分类的有效性,因此需要补充实际分类过程和分类以便进行可解释性和分类效果评价。显微组分发育显著的图样本点共计 305 个,其中镜质组 168 个,惰质组 96 个,黄铁矿 16 个,黏土矿物 25 个。

微裂缝是应力-应变产生的微缺陷。微裂缝的分布影响宏观裂缝的发育,同时宏观裂缝的发展又会产生新的伴生微裂缝。前人从成因的角度出发,基于形




图1 鄂尔多斯盆地及邻区构造位置与地层综合柱状图

Fig. 1 Structural map and composite stratigraphic column of the Ordos Basin and its adjacent areas

态等因素的综合分析将裂缝分为构造成因缝和原生沉积成因缝,这在宏观裂缝的识别中具有较好的效果^[33],但对于微裂缝的识别仍存在着形态、开度、位错和裂缝两侧边缘锐化或钝化的识别问题^[34]。目前,对于煤储层微裂缝的分类通常只关注裂缝形态^[35]。

微裂缝中,能够穿过多种显微组分且有开度的张开裂缝指示着更显著的应力效应^[36]。可将微裂缝分为以下3类:①穿组分缝,即能够穿过多种显微组分的裂缝;②短曲缝,长度短且开度几乎不可见,发育于单一显微组分中,到达其他显微组分边界时会发生明显弯折现象;③长直缝,为横穿整个镜下视野的单裂缝,开度小、弯曲程度低,能够穿过多个显微组分颗粒。本文在煤样中提取了微裂缝图样本点65个,包括穿组分缝8个,长直缝34个和短曲缝23个^[37]。

2.2 残差神经网络

神经网络结构包括输入层、中间层和输出层。对于预训练好的网络模型,输入层接受指定格式的数据输入,于中间层进行数据的卷积、池化和连接等操作。输出层经由激活函数运算后得出预测的分类,对于新的分类,有必要训练新的参数。本文采用经典的ResNet18网络结构,训练新的参数用于显微组分和微裂缝的分类评价,迁移学习的残差网络模型输出两种残差块(图2)。残差块的公式表述为^[38]:

$$y_n = h(x_n) + F(x_n, w_n) \quad (1)$$

式中: y_n 为向下一个残差块传递的数据; x_n 为传入残差块的数据; w_n 为偏置项; $h(x_n)$ 为此残差块的直接映射; x_n 传递转换; $F(x_n, w_n)$ 为此残差块的卷积网络处理 x_n

表1 鄂尔多斯盆地中、东部本溪组8#煤层煤样基本性质

Table 1 Fundamental properties of coal samples from the No. 8 coal seam of the Benxi Formation in the east-central Ordos Basin

煤样编号	深度/m	工业组分含量/%				显微组分含量/%			
		水分	灰分	挥发分	固定碳	镜质组	壳质组	惰质组	黏土矿物
Q1	3 260.12	0.89	12.94	7.64	78.53	72.19	0	21.63	6.18
Q2	3 261.67	0.60	31.51	8.97	58.92	70.62	0	23.72	5.66
Q3	3 262.43	0.56	36.09	9.33	54.02	72.21	0	9.58	18.21
Q4	3 263.18	0.79	9.66	8.07	81.48	78.59	0	15.54	5.87
M1	2 425.20	0.48	32.83	15.57	51.12	58.67	2.33	38.00	1.00
M2	2 425.97	0.65	22.84	12.75	63.76	45.33	0	40.67	4.00
M3	2 426.99	0.98	12.69	12.16	74.17	49.00	17.00	31.00	3.00
M4	2 427.64	0.65	17.38	15.70	66.27	66.67	2.67	31.33	1.33
M5	2 428.39	0.65	12.23	11.95	75.17	52.33	2.00	44.67	1.00
M6	2 428.99	0.79	21.46	11.81	65.94	57.33	1.67	39.67	1.33
M7	2 429.62	1.09	11.04	11.54	76.33	32.00	16.00	47.67	4.33
M8	2 430.25	0.66	42.17	11.93	45.24	52.00	4.33	41.67	2.00
M9	2 430.72	0.98	35.42	11.88	51.72	54.33	3.67	33.00	9.00
M10	2 431.47	0.93	16.46	11.89	70.72	39.67	23.33	28.00	9.00
M11	2 432.34	0.79	19.43	11.96	67.82	57.33	5.33	33.33	4.00
M12	2 432.97	0.70	17.47	12.84	68.99	44.00	17.33	31.67	7.00
M13	2 433.79	0.72	17.63	13.13	68.52	38.00	15.67	38.00	8.33
L1	3 861.00	0.31	6.14	10.54	83.01	61.33	0	38.34	0.33
L2	3 863.40	0.50	3.81	9.70	85.99	83.67	0	16.00	0.33
L3	3 864.24	0.38	13.88	10.77	74.97	44.33	0	52.67	2.00
J1	3 400.83	0.58	26.33	13.82	59.27	59.82	0	28.83	11.35
J2	3 401.70	0.73	9.43	12.43	77.41	50.20	0	43.6	6.20
J3	3 402.44	0.63	5.29	13.23	80.85	60.40	0	37.92	1.68
J4	3 403.42	0.64	13.60	12.13	73.63	72.64	0	19.00	8.36
J5	3 403.80	0.72	11.98	11.01	76.29	38.48	0	56.36	5.15
J6	3 404.57	0.32	19.80	13.20	66.68	52.88	0	28.84	18.27
J7	3 405.60	0.41	24.37	13.58	61.64	70.16	0	13.77	16.07
B1	3 274.15	0.63	20.04	9.14	70.19	79.95	0	12.72	7.33
B2	3 274.48	0.40	29.58	9.41	60.61	62.13	0	17.46	20.41
B3	3 274.75	0.45	38.89	9.68	50.98	62.07	0	37.07	0.86
B4	3 274.98	0.24	37.50	10.64	51.62	44.93	0	2.64	52.43
B5	3 277.27	0.30	23.67	12.10	63.93	67.49	0	17.67	14.84
B6	3 277.55	0.43	16.46	13.08	70.03	91.28	0	1.55	7.17
B7	3 277.81	0.33	27.20	9.87	62.60	80.72	0	3.92	15.36

传递转换。

ResNet18网络是典型的残差网络模型,目的是通过学习上两层网络结构的结果特征来避免出现网络退化的情况^[38]。即使残差为0,残差网络性能也不会下降,而实际上残差绝对值总大于0,这也会使得堆积层在输入特征基础上学习到新的特征,从而拥有更好的性能。ResNet18网络典型结构为两个通过激活函数(ReLu)输出的残差块,结合残差结构输出激活层(+ReLu)并向前传递。两个残差块中,一种为输入和输出形状相同的残差块,包括采取卷积核(Conv)为3、填充为1的两个卷积层进行处理(图2a);另一种为输

入和输出形状不同的残差块,采用1×1的卷积核对输入进行一个卷积变化(图2b)。

3 结果与讨论

3.1 可视化训练

利用显微组分样本和微裂缝样本分别训练残差神经网络模型。显微组分训练模型包括245个训练样本点,其中镜质组135个,惰质组77个,黄铁矿13个和黏土矿物20个。微裂缝训练模型包括54个




图2 ResNet18网络残差块结构

Fig. 2 Residual block structures of ResNet18

a. 输入和输出形状相同的残差块; b. 输入和输出形状不同的残差块

训练样本点,其中穿组分缝7个,长直缝28个和短曲缝19个。训练模型前需要先进行数据的标准化,而后通过更改网络参数的方式完成模型,并通过测试集验证模型的预测准确度。为了检验模型的泛化程度,在可视化和后续置信度分析中均采用不同井、不同样

本的多种显微组分进行分析。选取部分测试集中的显微组分图片(图3),结合后续可视化过程,可以反映模型的性能。图4展示了部分测试集标准化过程可视化结果。

根据模型准确率在100个轮次中的训练结果,设定学习率为0.01,并依据预测准确率提升来更新并保存模型。模型预测标准化后9个样本点的权重分析如图5所示,置信度的高值指示着预测的分类。对全连接的输出矩阵来说,其本质是一个通过激活函数的得分矩阵,而矩阵本身包含所有分类的数值。其中,得分矩阵的高值,即最大概率对应的类别为输入数据的分类类别,也为最终预测结果^[39]。如图5可视化过程显示,根据高值预测的结果是显微组分的分类。除了150号和166号样本点,其余样本点的预测结果均正确。根据镜下观察结果,150号和166号样本点表现为惰质组和镜质组两种显微组分均有发育,但最终识别为发育较少组分的问题。结合图5中两个样本的置信度来看,有明显的双峰特征,可见其学习到了两种组分的特征,并在识别中形成了干扰。对于其余样本,多数均以单一高峰值测试出了正确的发育组分。16号样本点存在黏土矿物峰偏高的现象,155号样本点存在




图3 鄂尔多斯盆地中、东部不同煤样显微组分可视化镜下照片

Fig. 3 Microscopic images of macerals from various coal samples in the east-central Ordos Basin

a. 黄铁矿, 14号样本点, 煤样L3, 反射光; b. 黄铁矿, 15号样本点, 煤样Q2, 反射光; c. 黄铁矿, 16号样本点, 煤样Q3, 反射光; d. 镜质组, 138号样本点, 煤样M11, 反射光; e. 镜质组, 146号样本点, 煤样M12, 反射光; f. 惰质组, 150号样本点, 煤样M13, 反射光; g. 镜质组, 151号样本点, 煤样M13, 反射光; h. 惰质组, 155号样本点, 煤样Q1, 反射光; i. 镜质组, 166号样本点, 煤样Q4, 反射光




图4 鄂尔多斯盆地中、东部不同煤样标准化显微组分图像

Fig. 4 Standardized maceral images from various coal samples in the east-central Ordos Basin

a. 黄铁矿, 14号样本点, 煤样L3; b. 黄铁矿, 15号样本点, 煤样Q2; c. 黄铁矿, 16号样本点, 煤样Q3; d. 镜质组, 138号样本点, 煤样M11; e. 镜质组, 146号样本点, 煤样M12; f. 惰质组, 150号样本点, 煤样M13; g. 镜质组, 151号样本点, 煤样M13; h. 惰质组, 155号样本点, 煤样Q1; i. 镜质组, 166号样本点, 煤样Q4

镜质组峰偏高的现象,但最终预测结果仍正确。结合可视化分析,认为模型具有较好识别性能(图5)。

3.2 测试评价

设置准确率0.80作为训练循环终止标准,训练后的神经网络分别用于开展微裂缝分类和显微组分分类。深度学习自身对于过拟合的抵抗能力会受到训练集和训练次数的影响。同步建立损失函数曲线,微裂缝分类于79次达到0.80的准确率,模型训练速度快,训练轮次少,根据准确率曲线和损失函数曲线趋势,整体上过拟合程度较低。显微组分分类于87次达到0.80的准确率,由于显微组分样本数量较微裂缝

更大,反映其模型训练速度更快,训练轮次更少,根据准确率曲线和损失函数曲线趋势,整体上过拟合程度同样较低。显微组分和微裂缝测试准确率和损失函数可视化如图6所示。

建立神经网络预测模型,设置学习率为0.01,训练轮次100次以内,记录保存最高准确率模型。显微组分预测结果如表2所示。分类模型常用准确率、精确率、召回率和F1值(准确率和召回率的加权平均值)等指标来评价预测结果。显微组分预测准确率为0.90,精确率为0.94,召回率为0.92,F1值为0.93。整体预测效果较好,反映了较好的模型性能。




图5 鄂尔多斯盆地中、东部残差神经网络模型预测不同煤样显微组分样本置信度可视化柱状图

Fig. 5 Confidence levels of sampled maceral predictions based on the ResNet model from coal samples in the east-central Ordos Basin
a. 14号样本点, 煤样L3; b. 15号样本点, 煤样Q2; c. 16号样本点, 煤样Q3; d. 138号样本点, 煤样M11; e. 146号样本点, 煤样M12; f. 150号样本点, 煤样M13; g. 151号样本点, 煤样M13; h. 155号样本点, 煤样Q1; i. 166号样本点, 煤样Q4

微裂缝预测结果如表3所示。微裂缝预测准确率为0.80,精确率为0.51,召回率为0.56,F1值为0.53。微裂缝预测指标中,准确率较高,而其他指标数值均较低。从计算原理分析,精确率、召回率和F1值均明显受到穿组分缝影响。在本研究中,微裂缝整体数据较少,穿组分缝仅有一个预测样本点且预测错误,即量化表现为穿组分缝的预测100%错误,因此严重影响了3个指标的性能。这种因1个样本点变化而引起剧烈震荡的指标显然是不合理的。因此在本研究中,微裂缝的性能评价以准确率为相对可靠指标。整体上显微组分从数据规模带来的泛化性能和准确率,都要好于微裂缝。微裂缝的预测效果相对略差,但0.80的准确率也说明预测结果具有一定的可靠性。

造成显微组分和微裂缝两个模型准确率差异的主

要原因包括:①微裂缝整体样本数不足,实际用于预测和测试的样本点均较少;②裂缝的形态相差巨大,这为预测模型的泛化性能造成了较大的影响。此外,裂缝发育具有明显的显微组分选择性,尤其在镜质组中发育较多,这对于训练来说,产生了裂缝和镜质组的学习影响,表现为微裂缝整体模型准确率相对较低。显微组分在模型的泛化性能和预测的准确率上表现较好,这主要归结于数据集的充分性和显微组分在镜下特征的相似性,整体准确率为0.90。

微裂缝和显微组分二者模型可靠度都较高。观察显微组分分类的网络关注区域可见,正确预测样本模型的注意力也会集中在不同的位置。其中,图7b和图7d聚焦于预测组分本身的关注模式,图7a和图7g聚焦在反选区域中的模式,图7c聚焦在错误的显微组




图 6 鄂尔多斯盆地中、东部煤样显微组分和微裂缝测试准确率和损失函数可视化曲线

Fig. 6 Curves showing the accuracy and loss functions of maceral and microfracture tests from coal samples in the east-central Ordos Basin

a. 微裂缝测试准确率;b. 显微组分测试准确率;c. 微裂缝测试损失函数值;d. 显微组分测试损失函数值

表 2 鄂尔多斯盆地中、东部煤样残差网络模型显微组分分类混淆矩阵

		预测显微组分个数			
		惰质组	黄铁矿	镜质组	黏土矿物
实际显微组分个数	惰质组	12	0	4	0
	黄铁矿	0	3	0	0
	镜质组	2	0	31	0
	黏土矿物	0	0	0	8
准确率		0.90			
精确率		0.94			
召回率		0.92			
F1 值		0.93			

表 3 鄂尔多斯盆地中、东部煤样残差网络模型微裂缝分类混淆矩阵

		预测微裂缝个数		
		短曲缝	长直缝	穿组分缝
实际微裂缝个数	短曲缝	3	1	0
	长直缝	0	6	0
	穿组分缝	1	0	0
准确率		0.80		
精确率		0.51		
召回率		0.56		
F1 值		0.53		

分上,因此整体预测错误。总的来说,模型的判断位置和预测结果相吻合,以正确的选择为主。

3.3 结果验证

深部煤储层相较于浅部形成过程更加复杂,对储层特征预测过程的验证也更加重要,包括控制微裂缝和显微组分形成的地质作用和算法,都可以用于验证预测模型的可靠性。近些年,神经网络模型广泛应用于地质领域,在预测分类方面具有精度高的

优点,但因其本身的预测集和训练集都是人工选取的,因而还需要其他方法进行多方面的验证^[40]。新方法的引入会引起准确率本身出现不确定性,可采用两种或以上的方法进行对比验证的思路来确定模型的效率。弱相关性参数方法的联合运用可以大大地提高模型的准确率。

3.3.1 分类自验证

结合显微组分和微裂缝的分类预测进行相互验证。如图 8 所示,11 个裂缝样本点中有 8 个镜下显微




图7 鄂尔多斯盆地中、东部煤样残差神经网络模型显微组分分类过程模型注意力可视化图像

Fig. 7 Attention visualization during maceral classification based on the ResNet model from coal samples in the east-central Ordos Basin
a. 黄铁矿, 16号样本点显微组分, 反选区域注意力集中; b. 黏土矿物, 22号样本点显微组分, 正选区域注意力集中; c. 镜质组, 75号样本点显微组分, 正选区域注意力集中; d. 镜质组, 80号样本点显微组分, 正选区域注意力集中; e. 惰质组, 84号样本点显微组分, 正选区域注意力集中; f. 惰质组, 89号样本点显微组分, 正选区域注意力集中; g. 镜质组, 93号样本点显微组分, 反选区域注意力集中; h. 镜质组, 154号样本点显微组分, 正选区域注意力集中; i. 镜质组, 166号样本点显微组分, 正选区域注意力集中

组分被预测为镜质组(其中包括7个长直缝和1个短曲缝),余下的3个惰质组裂缝均为短曲缝。分类模型中,裂缝的发育与显微组分中的镜质组关系最大,尤其是长直缝,多表现为在镜质组组分中的长直穿透,到达组分边界后停止。从类别和数量上看,微裂缝的分类预测都与显微组分的相吻合。两种分类方法可以互相验证,并反映出较好的预测性能。

3.3.2 分类模型依据

对于通常认为的惰质组氧化/野火成因和镜质组还原凝胶化成因,根据裂缝的形成原理分析,从宏观割理到微观伴生裂缝,都应当形成于同一应力-应变作用下的损伤,而惰质组在这个过程中主要受到上层的氧化或野火作用^[8,41]。因此,穿组分缝应该是由成岩作用过程中或结束后的构造作用产生的。长直缝包括单条长直缝发育和多条不同方向长直缝交织的模式。其中,网状交织的多条缝在镜下呈相同的发育特征,且

集中于镜质组中。这种形态类似、发育集中、光学性质统一的缝体系,有明显的内生成因特征,表现出成煤过程中的镜质组成缝特点。而单条长直缝直接反映的是组分脆性差异,因此对于单条长直缝,需要结合宏观裂缝发育模式以及周边组分共同的裂缝发育模式分析其成因。对于短曲缝的发育,控制因素更加复杂多样,具体需要结合包括差异流动性下煤组分的压实形态、周边区域不同裂缝发育模式以及多尺度裂缝形态空间耦合等多因素综合分析。

整体来看,从穿组分缝到短曲缝,除了构建分类时的尖端应变能和形态差异外,裂缝发育成因依次变得更加复杂,整体上也表现为从显著构造作用到构造-沉积复合作用的趋势。分类模型在形态、成因和应变能机理上均有可分性,分类具有可靠性。

3.3.3 基于聚类分析的验证

聚类分析是根据在数据中发现的描述对象及其关




图8 鄂尔多斯盆地中、东部煤样残差网络模型预测显微组分和微裂缝发育类别关系三角图与对应镜下照片

Fig. 8 Ternary diagram showing the relationships between macerals and microfracture types predicted using the ResNet model and corresponding microscopic images for various microfractures from coal samples in the east-central Ordos Basin

a. 镜质组, 12号样本点微裂缝, 长直缝发育; b. 镜质组, 9号样本点微裂缝, 长直缝发育; c. 镜质组, 2号样本点微裂缝, 长直缝发育; d. 镜质组, 3号样本点微裂缝, 短曲缝发育; e. 显微组分与微裂缝发育关系三角图; f. 镜质组, 6号样本点微裂缝, 长直缝发育; g. 惰质组, 18号样本点微裂缝, 短曲缝发育; h. 惰质组, 7号样本点微裂缝, 短曲缝发育; i. 镜质组, 22号样本点微裂缝, 长直缝发育

系的信息,将数据对象分组^[42]。组内对象之间相似,而不同组中的对象不同。组内相似性越大,组间差距越大,说明聚类效果越好。对于ResNet18网络模型,将图像数据导入K-means聚类算法中进行聚类分析。K-means聚类依据的是欧氏距离分析,其弱点在于需要人工给出聚类个数进行自动划分。但对于本研究中的分类算法验证而言,结合对比分类预测结果的混淆矩阵认为,在已知分类类别数的情况下该方法具有良好的适用性。

如表4所示,选取3分类作为目标聚类数,最终残差网络分类模型和聚类分类模型的相关准确率为0.70,作为监督和无监督学习相互验证的准确度较好。聚类模型实际预测准确率虽较低,但对于穿组分缝的预测正确,也具有一定的分析意义。因此结

表4 鄂尔多斯盆地中、东部煤样分类和聚类模型微裂缝测试混淆矩阵

Table 4 Confusion matrix for microfracture tests based on the classification and clustering models from coal samples in the east-central Ordos Basin

		分类预测结果个数		
		短曲缝	长直缝	穿组分缝
聚类预测结果个数	短曲缝	2	1	0
	长直缝	2	5	0
	穿组分缝	0	1	0
准确率		0.70		

合混淆矩阵展示无预设3分类聚类划分与微裂缝分类样本较接近,可见本研究选取的分类模型相对可靠。

4 结论

1) 构建显微组分四分类模型共计305个图样本,显著微裂缝发育共计65个图样本。利用新训练的ResNet18网络参数开展显微组分和微裂缝分类。其中显微组分准确率为0.90,微裂缝准确率为0.80,残差神经网络可以有效预测显微组分和微裂缝的类型。

2) 针对深部煤储层微观特征神经网络的图片处理过程、测试置信度过程和注意力集中机制进行了可视化分析。多数样本预测置信度表现为单峰,即模型预测为单一组分或微裂缝发育模式,反映出较好的网络模型训练效果。神经网络注意力多集中在图中重要的显微组分和微裂缝上,体现了模型预测的高可信度。

3) 利用显微组分和微裂缝预测结果互相验证,7个镜质组样本预测为长直缝,1个预测为短曲缝,惰质组样本点均预测为短曲缝,说明裂缝形态与显微组分之间存在一定关系。在成因验证上,从穿组分缝到短曲缝,缝形态和成因逐渐复杂,分类体现了形态和成因的变化。结合K-means聚类分析,聚类算法和分类算法模型整体趋势接近,模型具有可靠性。

参 考 文 献

- [1] 罗情勇,钟宇宁,李美俊,等. 前寒武纪—早古生代沉积岩显微组分分类、成因及演化[J]. 石油与天然气地质, 2023, 44(5): 1084–1101.
LUO Qingyong, ZHONG Ningning, LI Meijun, et al. Classification, origins, and evolution of macerals in the Precambrian-Eopaleozoic sedimentary rocks[J]. Oil & Gas Geology, 2023, 44(5): 1084–1101.
- [2] 周三栋,刘大锰,蔡益栋,等. 低阶煤吸附孔特征及分形表征[J]. 石油与天然气地质, 2018, 39(2): 373–383.
ZHOU Sandong, LIU Dameng, CAI Yidong, et al. Characterization and fractal nature of adsorption pores in low rank coal[J]. Oil & Gas Geology, 2018, 39(2): 373–383.
- [3] 蔡益栋,杨超,李倩,等. 煤层气储层相对渗透率试验及数值模拟技术研究进展[J]. 煤炭科学技术, 2023, 51(增刊1): 192–205.
CAI Yidong, YANG Chao, LI Qian, et al. Research progress of relative permeability experiment and numerical simulation technique in coalbed methane reservoir[J]. Coal Science and Technology, 2023, 51(S1): 192–205.
- [4] HAN Qiuchan, LIU Jingjing, HOWER J C, et al. Fire activities and their impacts on local ecosystems in the southern Ordos Basin during the Middle Jurassic: Evidence from pyrogenic PAHs and petrography of inertinite-rich coal [J]. Palaeogeography, Palaeoclimatology, Palaeoecology, 2024, 636: 111972.
- [5] LI Song, QIN Yong, TANG Dazhen, et al. A comprehensive review of deep coalbed methane and recent developments in China [J]. International Journal of Coal Geology, 2023, 279: 104369.
- [6] 代世峰,唐跃刚,姜尧发,等. 煤的显微组分定义与分类(ICCP system 1994)解析 I: 镜质体[J]. 煤炭学报, 2021, 46(6): 1821–1832.
DAI Shifeng, TANG Yuegang, JIANG Yaofa, et al. An in-depth interpretation of definition and classification of macerals in coal (ICCP system 1994) for Chinese researchers, I: Vitrinite [J]. Journal of China Coal Society, 2021, 46(6): 1821–1832.
- [7] 蔡益栋,贾丁,邱峰,等. 基于纳米压痕的煤岩微观力学特性及其影响因素剖析[J]. 煤炭学报, 2023, 48(2): 879–890.
CAI Yidong, JIA Ding, QIU Feng, et al. Micromechanical properties of coal and its influencing factors based on nanoindentation [J]. Journal of China Coal Society, 2023, 48(2): 879–890.
- [8] 邵龙义,周家民, JONES T P, 等. 煤中惰质组及其古环境意义: 来自 AI 和大数据分析的启示[J]. 中国科学: 地球科学, 2024, 54(6): 1806–1829.
SHAO Longyi, ZHOU Jiamin, JONES T P, et al. Inertinite in coal and its geoenvironmental significance: Insights from AI and big data analysis [J]. Science China Earth Sciences, 2024, 54(6): 1806–1829.
- [9] 邓泽,王红岩,姜振学,等. 深部煤储层孔裂隙结构对煤层气赋存的影响——以鄂尔多斯盆地东缘大宁-吉县区块为例[J]. 煤炭科学技术, 2024, 52(8): 106–123.
DENG Ze, WANG Hongyan, JIANG Zhenxue, et al. Influence of deep coal pore and fracture structure on occurrence of coalbed methane: A case study of Daning-Jixian Block in eastern margin of Ordos Basin [J]. Coal Science and Technology, 2024, 52(8): 106–123.
- [10] SUN Fengrui, LIU Dameng, CAI Yidong, et al. A micro-macro coupled permeability model for gas transport in coalbed methane reservoirs[J]. Energy, 2023, 284: 128604.
- [11] 贾承造,庞雄奇,宋岩. 论非常规油气成藏机理: 油气自封闭作用与分子间作用力[J]. 石油勘探与开发, 2021, 48(3): 437–452.
JIA Chengzao, PANG Xiongqi, SONG Yan. The mechanism of unconventional hydrocarbon formation: Hydrocarbon self-containment and intermolecular forces [J]. Petroleum Exploration and Development, 2021, 48(3): 437–452.
- [12] 傅雪海,齐琦,程鸣,等. 煤储层渗透率测试、模拟与预测研究进展[J]. 煤炭学报, 2022, 47(6): 2369–2385.
FU Xuehai, QI Qi, CHENG Ming, et al. Review of research on test, simulation and prediction of coal reservoir permeability [J]. Journal of China Coal Society, 2022, 47(6): 2369–2385.
- [13] MAXWELL K, RAJABI M, ESTERLE J. Automated classification of metamorphosed coal from geophysical log data using supervised machine learning techniques [J]. International Journal of Coal Geology, 2019, 214: 103284.
- [14] ZHAO Jier, GE Xinmin, FAN Yiren, et al. A genetic algorithm-

- driven support vector machine to discriminate the kerogen type using conventional geophysical logging data[J]. AAPG Bulletin, 2023, 107(11): 1837-1849.
- [15] 侯贤沐, 王付勇, 宰芸, 等. 基于机器学习和测井数据的碳酸盐岩孔隙度与渗透率预测[J]. 吉林大学学报(地球科学版), 2022, 52(2): 644-653. doi:10.13278/j.cnki.jjuese.20210151. HOU Xianmu, WANG Fuyong, ZAI Yun, et al. Prediction of Carbonate Porosity and Permeability Based on Machine Learning and Logging Data[J]. Journal of Jilin University (Earth Science Edition), 2022, 52(2): 644-653.
- [16] WANG Yingda, BLUNT M J, ARMSTRONG R T, et al. Deep learning in pore scale imaging and modeling[J]. Earth-Science Reviews, 2021, 215: 103555.
- [17] 段太忠, 张文彪, 何治亮, 等. 塔里木盆地顺北油田超深断溶体深度学习地质建模方法[J]. 石油与天然气地质, 2023, 44(1): 203-212. DUAN Taizhong, ZHANG Wenbiao, HE Zhiliang, et al. Deep learning-based geological modeling of ultra-deep fault-karst reservoirs in Shunbei Oilfield, Tarim Basin[J]. Oil & Gas Geology, 2023, 44(1): 203-212.
- [18] 冯雪健, 沈永星, 周动, 等. 基于CT数字岩心深度学习的煤裂隙分布识别研究[J]. 煤炭科学技术, 2023, 51(8): 97-104. FENG Xuejian, SHEN Yongxing, ZHOU Dong, et al. Multi-scale distribution of coal fractures based on CT digital core deep learning[J]. Coal Science and Technology, 2023, 51(8): 97-104.
- [19] 李美霖, 芮杰, 金飞, 等. 基于改进YOLOX的遥感影像目标检测算法[J]. 吉林大学学报(地球科学版), 2023, 53(4): 1313-1322. LI Meilin, RUI Jie, JIN Fei, et al. Remote Sensing Image Target Detection Algorithm Based on Improved YOLOX[J]. Journal of Jilin University (Earth Science Edition), 2023, 53(4): 1313-1322.
- [20] ZHOU Qiang, LEI Zhengdong, CHEN Zhewei, et al. Shale oil production predication based on an empirical model-constrained CNN-LSTM[J]. Energy Geoscience, 2024, 5(2): 100252.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [22] 刘彦锋, 段太忠, 黄渊, 等. 沉积过程模拟驱动下的深度学习地质建模方法[J]. 石油与天然气地质, 2023, 44(1): 226-237. LIU Yanfeng, DUAN Taizhong, HUANG Yuan, et al. Deep learning-based geological modeling driven by sedimentary process simulation[J]. Oil & Gas Geology, 2023, 44(1): 226-237.
- [23] 董维强, 孟召平, 沈振, 等. 基于循环神经网络的煤层气井产气量预测方法研究[J]. 煤炭科学技术, 2021, 49(9): 176-183. DONG Weiqiang, MENG Zhaoping, SHEN Zhen, et al. Research on coalbed methane well gas production forecast method based on cyclic neural network[J]. Coal Science and Technology, 2021, 49(9): 176-183.
- [24] 王培珍, 余晨, 薛子邯, 等. 基于迁移学习的煤岩壳质组显微组分识别模型[J]. 煤炭科学技术, 2022, 50(1): 220-227. WANG Peizhen, YU Chen, XUE Zihan, et al. Transfer learning based identification model for macerals of exinite in coal[J]. Coal Science and Technology, 2022, 50(1): 220-227.
- [25] 李素华, 余洋, 李蓉, 等. 神经网络反演在火山岩储层预测中的应用[J]. 石油地球物理勘探, 2023, 58(2): 392-402. LI Suhua, YU Yang, LI Rong, et al. Application of neural network inversion in prediction of volcanic rock reservoir[J]. Oil Geophysical Prospecting, 2023, 58(2): 392-402.
- [26] 斯扬, 蔡明俊, 张家良, 等. 基于自组织神经网络及K最近邻算法的储层渗流屏障定量识别方法[J]. 中国石油大学学报(自然科学版), 2023, 47(4): 35-47. SI Yang, CAI Mingjun, ZHANG Jialiang, et al. Quantitative identification method of reservoir flow barriers based on self-organizing neural network and K-nearest neighbor algorithm[J]. Journal of China University of Petroleum (Edition of Natural Science), 2023, 47(4): 35-47.
- [27] 林年添, 张栋, 张凯, 等. 地震油气储层的小样本卷积神经网络学习与预测[J]. 地球物理学报, 2018, 61(10): 4110-4125. LIN Niantian, ZHANG Dong, ZHANG Kai, et al. Predicting distribution of hydrocarbon reservoirs with seismic data based on learning of the small-sample convolution neural network[J]. Chinese Journal of Geophysics, 2018, 61(10): 4110-4125.
- [28] 胡晋玮, 奚峥皓, 徐国忠, 等. 基于DeeplabV3+改进的煤岩显微组分组自动化测试模型[J]. 煤田地质与勘探, 2023, 51(10): 27-36. HU Jinwei, XI Zhenghao, XU Guozhong, et al. An improved automated testing model for maceral groups in coals based on DeeplabV3+[J]. Coal Geology & Exploration, 2023, 51(10): 27-36.
- [29] 郭旭升, 周德华, 赵培荣, 等. 鄂尔多斯盆地石炭系-二叠系煤系非常规天然气勘探开发进展与攻关方向[J]. 石油与天然气地质, 2022, 43(5): 1013-1023. GUO Xusheng, ZHOU Dehua, ZHAO Peirong, et al. Progresses and directions of unconventional natural gas exploration and development in the Carboniferous-Permian coal measure strata, Ordos Basin[J]. Oil & Gas Geology, 2022, 43(5): 1013-1023.
- [30] 张雷, 边利恒, 侯伟, 等. 深部煤储层孔隙结构特征及其勘探意义——以鄂尔多斯盆地东缘大宁—吉县区块为例[J]. 石油学报, 2023, 44(11): 1867-1878. ZHANG Lei, BIAN Liheng, HOU Wei, et al. Pore structure characteristics and exploration significance of deep coal reservoirs: A case study of Daning-Jixian block in the eastern margin of Ordos Basin[J]. Acta Petrolei Sinica, 2023, 44(11): 1867-1878.
- [31] 赵喆, 徐旺林, 赵振宇, 等. 鄂尔多斯盆地石炭系本溪组煤岩气地质特征与勘探突破[J]. 石油勘探与开发, 2024, 51(2): 234-247, 259. ZHAO Zhe, XU Wanglin, ZHAO Zhenyu, et al. Geological characteristics and exploration breakthroughs of coal rock gas in Carboniferous Benxi Formation, Ordos Basin, NW China[J].

- Petroleum Exploration and Development, 2024, 51(2): 234–247, 259.
- [32] 徐亮, 杨威, 姜振学, 等. 四川盆地川西坳陷三叠系须家河组页岩有机孔演化及成因[J]. 石油与天然气地质, 2022, 43(2): 325–340.
- XU Liang, YANG Wei, JIANG Zhenxue, et al. Evolution and genesis of organic pores in Triassic Xujiahe Formation shale, western Sichuan Depression, Sichuan Basin [J]. Oil & Gas Geology, 2022, 43(2): 325–340.
- [33] 丁文龙, 许长春, 久凯, 等. 泥页岩裂缝研究进展[J]. 地球科学进展, 2011, 26(2): 135–144.
- DING Wenlong, XU Changchun, JIU Kai, et al. The research progress of shale fractures[J]. Advances in Earth Science, 2011, 26(2): 135–144.
- [34] 杜涛, 曲希玉, 王清斌, 等. 渤中19-6凝析气田孔店组砂砾岩储层压实成岩裂缝垂向演化特征[J]. 吉林大学学报(地球科学版), 2023, 53(1): 17–29.
- DU Tao, QU Xiyu, WANG Qingbin, et al. Vertical Evolution Characteristics of Compaction Diagenetic Fractures in Glutenite Reservoirs of Kongdian Formation in Bozhong 19-6 Condensate Gas Field[J]. Journal of Jilin University (Earth Science Edition), 2023, 53(1): 17–29.
- [35] 李松, 汤达祯, 许浩, 等. 应力条件制约下不同埋深煤储层物性差异演化[J]. 石油学报, 2015, 36(增刊1): 68–75.
- LI Song, TANG Dazhen, XU Hao, et al. Evolution of physical differences in various buried depth of coal reservoirs under constraint of stress[J]. Acta Petrolei Sinica, 2015, 36(S1): 68–75.
- [36] 武鹏飞, 梁卫国, 廉浩杰, 等. 大尺寸煤岩组合体水力裂缝越界形成缝网机理及试验研究[J]. 煤炭学报, 2018(5): 1381–1389.
- WU Pengfei, LIANG Weigu, LIAN Haojie, et al. Mechanism and experimental investigation of the formation of hydro-fracture system by fracturing through the interface of large-size coal-rock [J]. Journal of China Coal Society, 2018(5): 1381–1389.
- [37] 刘云鹏, 邓辉, 黄润秋. 板裂结构岩石力学试验及破裂断口微观形貌特征分析[J]. 岩石力学与工程学报, 2015, 34(增刊2): 3852–3861.
- LIU Yunpeng, DENG Hui, HUANG Runqiu. Mechanical test of slab-rent structure rock and mesoscopic morphology analysis of rupture surface [J]. Chinese Journal of Rock Mechanics and Engineering, 2015, 34(S2): 3852–3861.
- [38] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016. Los Alamitos, CA: IEEE Computer Society, 2016: 770–778.
- [39] 封强, 潘保芝, 韩立国. 基于卷积降噪自编码器和Softmax回归的微地震定位方法[J]. 地球物理学报, 2023, 66(7): 3076–3085.
- FENG Qiang, PAN Baozhi, HAN Ligu. Microseismic source location method based on convolutional denoising auto-encoder and Softmax regression[J]. Chinese Journal of Geophysics, 2023, 66(7): 3076–3085.
- [40] HU Song, WANG Xiaochang, WANG Jin, et al. Quantitative evaluation of fracture porosity from dual laterlog based on deep learning method[J]. Energy Geoscience, 2023, 4(2): 100064.
- [41] 杨博, 田继军, 冯烁, 等. 准噶尔盆地东部中侏罗世煤中记录的古野火事件[J]. 煤炭科学技术, 2022, 50(7): 261–270.
- YANG Bo, TIAN Jijun, FENG Shuo, et al. Wildfires recorded in Middle Jurassic coals in Eastern of Junggar Basin in Xinjiang, China [J]. Coal Science and Technology, 2022, 50(7): 261–270.
- [42] 孔强夫, 杨才, 李浩, 等. 基于图论聚类和最小临近算法的岩性识别方法——以四川盆地西部雷口坡组碳酸盐岩储层为例[J]. 石油与天然气地质, 2020, 41(4): 884–890.
- KONG Qiangfu, YANG Cai, LI Hao, et al. A lithology recognition method based on multi-resolution graph-based clustering and K-nearest neighbor: A case study from the Leikoupo Formation carbonate reservoirs in western Sichuan Basin [J]. Oil & Gas Geology, 2020, 41(4): 884–890.

(编辑 张玉银)