

doi: 10.11720/wtyht.2024.2553

余永鹏,张广兵,黄自军,等.多源测井数据预测煤层工业组分和发热量模型研究[J].物探与化探,2024,48(1):185-193. http://doi.org/10.11720/wtyht.2024.2553

Yu Y P, Zhang G B, Huang Z J, et al. A prediction model of the industrial components and calorific values of coal seams based on multi-source log data [J]. Geophysical and Geochemical Exploration, 2024, 48(1): 185-193. http://doi.org/10.11720/wtyht.2024.2553

多源测井数据预测煤层工业组分和发热量模型研究

余永鹏¹,张广兵¹,黄自军²,闫建波¹,王嘉文¹,杨彦成¹,毛兴军¹

(1. 宁夏回族自治区煤炭地质局,宁夏银川 750002; 2. 宁夏煤炭勘察工程有限公司,宁夏银川 750002)

摘要: 煤层工业组分和发热量是评价煤质的基本依据,利用测井资料预测煤层工业组分和发热量可以弥补煤芯样试验分析的不足。利用宁夏某井田详查、勘探等不同阶段的数字测井和煤质化验数据,在研究煤质特征、测井响应特征和统计分析的基础上,建立了测井响应特征提取、样本集建立和数据处理方法与深度神经网络模型,通过对测试数据的预测结果和试验分析结果对比,验证了预测模型有效性。

关键词: 多源数据;地球物理测井;煤炭;工业组分;发热量;预测模型

中图分类号: P631

文献标识码: A

文章编号: 1000-8918(2024)01-0185-09

0 引言

煤的工业组分是评价煤质的最基本依据^[1],也是煤层气储层测井评价的重要内容^[2],煤层工业组分和发热量计算一直是煤层煤质评价的关键课题^[3]。煤层工业组分和发热量获取的直接方式是煤芯样试验分析,样品试验分析周期长,取样、存储和制样的过程对分析结果均有影响。当煤芯样品数不足时,也会影响区域性煤质评价。

利用测井数据预测煤层工业组分和发热量是弥补煤样分析不足的重要方法,孟召平等^[4]以河南新郑矿区赵家寨井田为依托,通过试验和统计分析建立了煤的工业分析指标与测井参数的相关关系及模型,邵先杰等^[5]采用枚举法标定出了煤样的工业组分含量、孔隙度、含气量以及密度和声波速度等参数,潘和平等^[6]利用体积模型法和回归分析法建立了煤储层固定碳、灰分、水分和挥发分的测井解释模型,也有一些研究者采用神经网络等方法建立了煤质测井解释模型^[7-12]。但前人的研究多以煤层气勘探开发为研究载体,测井参数多、数据质量高,

多集中于利用单一来源数据对特定煤层的煤质定量解释。以往以煤层定厚解释为目的的测井实际生产中,测井参数少,也较少有人利用仪器校验资料对数据进行适时校正并计算岩石密度,难以利用该测井数据进行定量解释评价。

以宁夏宁东煤田某井田延安组含煤地层为研究对象,利用详查、勘探阶段取得的数字测井和煤质化验数据,通过统计分析等方法研究了煤质特征。对测井响应特征进行了研究,分析了研究区测井响应的主要影响因素。建立了样本集中测井响应特征提取方法和数据预处理流程。在此基础上,建立了多源测井数据预测煤层工业组分和发热量的深度神经网络模型,通过对测试数据预测结果和试验分析结果对比分析,验证了模型有效性。

1 研究区地质概况

研究区位于宁夏回族自治区宁东煤田,井田内地形起伏不大,大部分为沙丘覆盖,多系风成垄状及新月形流动沙丘,间有被植被固定、半固定沙丘。

井田地表无基岩出露,根据钻孔揭露井田地层

收稿日期: 2022-11-08; 修回日期: 2023-01-08

基金项目: 宁夏自然科学基金项目(2021AAC03459, 2021AAC03462, 2022AAC05063)

第一作者: 余永鹏(1987-),男,工程师,2008年毕业于中国地质大学(武汉),主要从事地球物理和地质信息化工作。Email: yyp0527@126.com

通讯作者: 张广兵(1988-),男,工程师,主要从事煤田地面电法和煤田测井工作。Email: 262454161@qq.com

由老至新依次为:三叠系上统上田组(T_3s);侏罗系中统延安组(J_2y)、中统直罗组(J_2z)、上统安定组(J_3a);古近系渐新统清水营组(E_3q)和第四系(Q)。井田含煤地层为侏罗系中统延安组(J_2y),据钻孔揭露最小厚度 262.85 m,最大厚度 341.59 m,平均厚度 295.79 m,含煤层 25 层,平均总厚度 31.01 m,其中可采煤层 19 层。含煤地层沉积环境呈以河流作用为主的湖泊三角洲特征。

2 煤层煤质特征

研究区可采煤层以不粘煤为主,少量长焰煤,属

低灰、低硫、低磷、中高挥发分的高热值煤。如图 1 所示,研究区原煤试验煤样水分的质量分数(M_{ad})总体在 1.73%~19.29%,各煤层平均为 6.23%~9.40%;干燥基灰分的质量分数(A_d)总体在 3.28%~36.73%,各煤层平均为 8.45%~13.15%;干燥无灰基挥发分的质量分数(V_{daf})总体在 25.44%~43.34%,各煤层平均为 31.57%~35.47%;干燥基固定碳的质量分数(FC_d)在 38.56%~70.70%,各煤层平均为 54.62%~61.55%;发热量($Q_{gr,d}$)总体在 19.86~31.90 MJ/kg,各煤层平均为 26.82~28.83 MJ/kg。

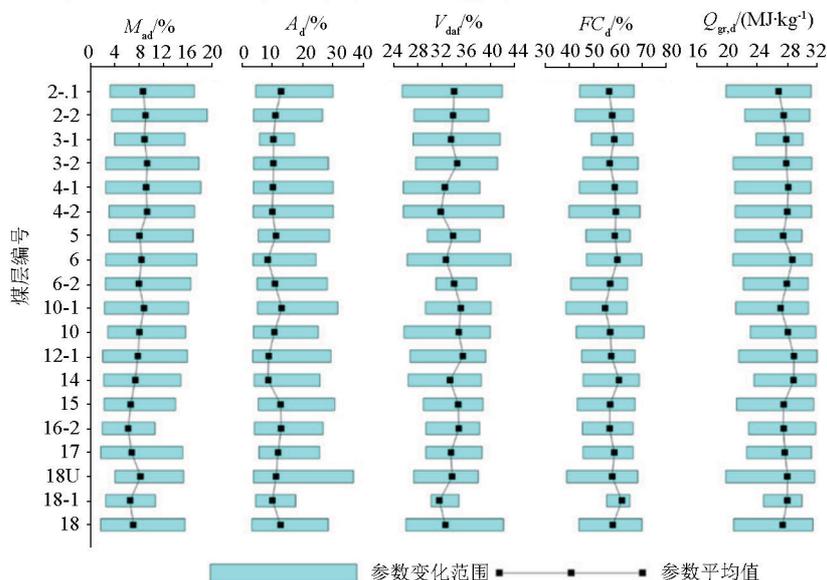


图 1 研究区可采煤层煤质特征

Fig. 1 The characteristic map of coal quality of mineable coal seams in the study area

通过对研究区煤质数据统计分析发现, A_d 与 FC_d 、 $Q_{gr,d}$ 均呈显著线性负相关关系(图 2a、b), V_{daf} 与 FC_d 呈显著线性负相关关系(图 2c)。

研究区夹矸 A_d 平均为 55.70%~87.07%,远高于煤层的 A_d 值。因采取的部分煤芯样混入了夹矸,

导致部分煤层 A_d 偏高,相应 $Q_{gr,d}$ 偏低。在统计分析中, A_d 平均值显得偏“小”, $Q_{gr,d}$ 平均值显得偏“大”(图 1)。混入夹矸的煤芯样煤质多具有“离群值”特征,可以用统计检验等方法剔除,降低其影响。

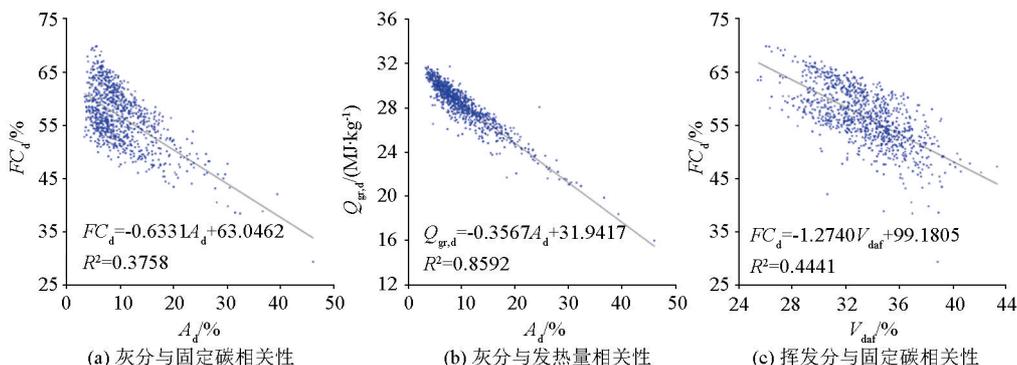


图 2 研究区煤质数据线性相关性

Fig. 2 The linear correlation diagram of coal quality data in the study area

3 煤层测井响应特征及主要影响因素

3.1 煤层测井响应特征

研究区含煤地层的岩层随岩石粒度由细变粗,岩石泥质含量逐渐减少,测井响应表现为:自然伽马数值逐渐减小,电阻率值逐渐增大,人工伽马数值逐渐增大,自然电位由零向负方向变化。

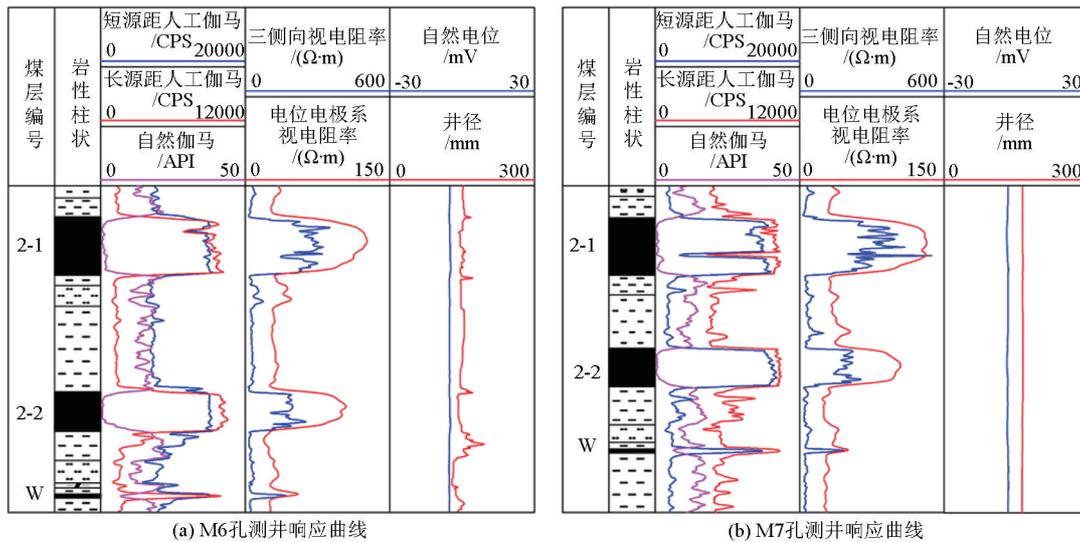


图3 研究区煤层测井响应特征

Fig. 3 The logging response characteristics of coal seams in the study area

利用测井数据预测煤层工业组分和发热量重点是建立测井响应特征与煤层工业组分和发热量的关系。测井响应特征提取是关键,一般以对应煤层段的测井曲线幅值作为测井响应特征值;也可在测井曲线上以一定间隔进行采样,以采样点的平均值作为测井响应特征值^[4,9]。研究区的测井数据采样间隔均为0.05 m。为了提取更丰富的测井数据特征,以对应煤层段各测井曲线幅值的最大幅值、最小幅值、平均值、中间值、均方根为该煤层的测井响应特征值。

3.2 测井响应主要影响因素

测井响应是地层、钻孔、仪器等多种因素叠加的综合反映,所以在研究测井响应特征与煤层工业组分和发热量的关系时,研究测井响应的影响因素是必要的。

3.2.1 测量方法对测井响应的影响

测量方法对测井响应的影响主要是电极排列方式、极距、收发距等因素不同造成测井响应差异。如图3所示,两种人工伽马方法因源距不同,造成曲线特征有较大差异;两种视电阻率测量方法(三侧向测井、A0.1M 电位电极系法)因装置类型不同,产生

煤层相对围岩具有低密度、低放射性、中—高电阻率的特点,在人工伽马和视电阻率曲线上为明显高值异常反应,自然伽马曲线为显著低值异常,自然电位多为负异常。但不同区域的沉积环境不同,同一煤层的结构、顶底板岩性、物理性质、工业组分等要素存在差异,测井曲线形态、特征、幅值等方面也会不一致(图3),这也就是利用测井数据预测煤层工业组分和发热量的物理基础。

的视电阻率曲线响应特征明显不同。在实际生产研究中,正是利用了不同测量方法的响应差异,针对性地解决了不同地质问题,如三侧向电阻率纵向分辨率较高、探测深度大,但电位电极系法对厚层划分更有利;补偿密度法正是利用了长、短源距间响应差异,是一种精度更高的测量岩石密度方法。因此,测井方法使用目的不同,响应也存在明显差异,所有测井曲线均应作为定量预测的依据。

3.2.2 数据多源性特征的影响

地质勘查是分阶段进行的。研究区内先后实施了多次地质勘查工作,本次研究工作采用其中的两次勘查成果,间隔10余年,仪器设备和操作人员均不同,获得的地球物理测井数据存在差异。图4、表1分别为研究区典型测井曲线响应幅值频率直方对比图和特征统计,4种典型测井曲线的幅值范围和分布特征均存在一定差异。其中自然伽马和三侧向视电阻率差异相对较小,说明两次测井的方法技术和设备具有一定的一致性;人工伽马观测的是射线脉冲计数值,两种方法的两次数据均有显著差异,该差异明显为放射源强度差异造成的。所以,不同来源测井数据间存在系统性差

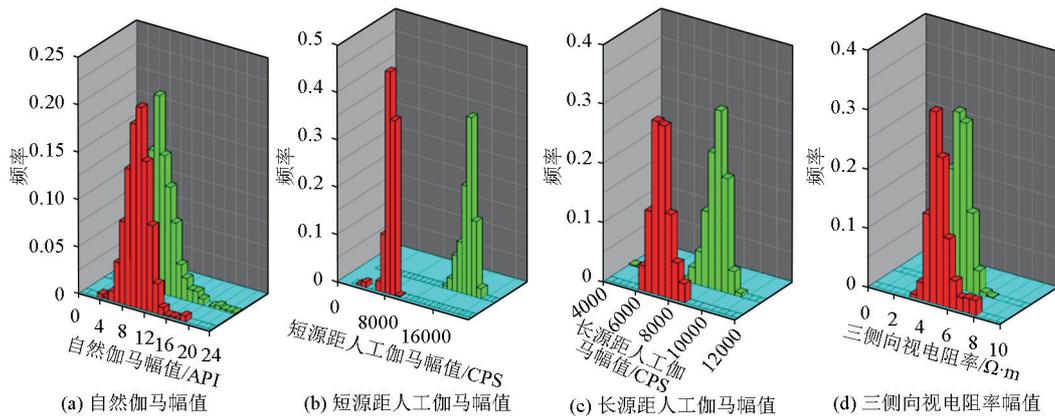


图4 研究区典型测井曲线幅值频率直方对比

Fig. 4 The amplitude frequency histogram of typical logging curves in the study area

表1 研究区典型测井曲线幅值特征统计

Table 1 The statistical table of amplitude characteristics of typical logging curves in the study area

测井方法	自然伽马/API		短源距人工伽马/CPS		长源距人工伽马/CPS		三侧向视电阻率/($\Omega \cdot m$)	
	最小值	均值	最小值	均值	最小值	均值	最小值	均值
对比内容	最大值	方差	最大值	方差	最大值	方差	最大值	方差
详查阶段	3.97	10.05	13584	17109.20	4356	9169.26	2.70	4.97
	23.32	2.66	19100	1038.68	10424.70	680.22	7.19	0.60
勘探阶段	3.56	10.08	3186	8094.60	6043	7266.61	3.25	5.14
	18.68	2.03	9226	733.03	8679	524.10	7.85	0.82

异,直接进行测井响应定量解释会对结果产生较大影响。

3.2.3 煤层厚度对测井响应的影响

受仪器分辨率和体积效应影响,测井信号反映的不是记录点的真实物理性质。当煤层厚度小于仪器分辨率时,测井响应幅值降低,无法呈现真实地层物性特征。地层越薄,影响越明显,如图3中“W”煤层为典型薄煤层测井响应特征。

在消除薄煤层对测井响应影响方面,前人利用小波变换^[13-14]、HHT变换^[15]等方法对测井数据处理以减少“薄层效应”的影响,但绝大多数都集中于提高纵向分辨率的研究上;也有一些研究利用数值模拟等方式^[16-17]校正测井曲线,以“还原”测井响应特征。无论采用哪种方式都难以达到采用测井响应对薄层定量解释的目的。“薄层效应”与煤层厚度呈反比,利用测井数据对煤层工业组分和发热量进行预测时,需要以煤层厚度倒数作为输入特征。

3.2.4 孔内环境对测井响应的影响

钻孔的孔内环境(如井径、泥浆、泥饼、地层温度等)对测井响应影响较大,会造成数据偏差,其中钻孔孔径的影响最为重要。当钻孔孔径扩大时,声波、人工伽马等测井数据的幅值会升高,电阻率、自然伽马等测井数据的幅值会降低^[18-19]。目前利用数值计算进行校正的方法较多,结果基本能满足生产需要。但校正并不能完全消除孔径影响,在利用

测井数据进行定量预测时,钻孔孔径也应作为考虑因素。

4 预测模型建立

4.1 样本集建立

大量研究工作表明,煤层的工业组分和测井参数之间具有相关性。前人利用测井数据通过多元线性回归方法计算煤层工业组分时,一般在理论分析或相关分析基础上选取相关性密切的参数建立多元线性回归模型^[3,8]。

提取样本数据时,对有煤芯样试验分析的煤层,提取对应煤层深度段测井参数(自然伽马、长源距人工伽马、短源距人工伽马、A0.1M 电位电极系视电阻率、三侧向视电阻率、自然电位、井径)的响应特征,与煤层厚度共同组成样本的36个输入特征,分别与煤层工业组分(M_{ad} 、 A_d 、 V_{daf} 、 FC_d)和发热量($Q_{gr,d}$)组成5组初始样本集。不同来源的数据单独建立样本集。

对样本集的数据预处理主要有2个方面:一是利用“箱形图”剔除工业组分和发热量数据中的离群点,减少离群点对数据分布特征影响;二是为了减少同一测井参数的多源性差异和不同参数的量纲差异,对不同来源数据分别进行归一化。数据预处理完成后,合并形成样本集。

为减少煤层宏观结构对煤质和测井数据的影响,本研究仅采用了对单层煤采样的煤质化验结果,与相应测井数据组成样本集。剔除离群值后的样本集数量为 938 个,如表 2 所示。

表 2 样本集样本数量统计

Table 2 The statistical table of sample quantity of sample set

数据源	初始样本集 样本数量/个	剔除离群点后 样本数量/个
详查阶段	482	453
勘探阶段	521	485
合计	1003	938

4.2 样本数据相关性分析

如图 5 所示为样本集测井归一化数据与工业组分和发热量线性相关系数热度,其中 M_{ad} 、 FC_d 和 $Q_{gr,d}$ 与部分样本特征具有相关性,多数特征线性相关系数在 ± 0.2 以上,部分接近 ± 0.5 ; A_d 和 V_{daf} 与测井数据相关性较弱,基本都在 ± 0.1 以下。煤质参数间的相关性与前文研究基本一致, A_d 与 FC_d 和 $Q_{gr,d}$ 有强线性相关性; V_{daf} 和 FC_d 有强相关性,和 $Q_{gr,d}$ 有

弱相关性。

4.3 预测模型建立

煤的工业组分和发热量由煤层自身性质决定,与煤层宏观结构没有直接关系。测井响应不仅与煤层自身的性质有关系,还与煤层宏观结构及孔内环境有关系。因此煤层工业组分和发热量与测井响应之间的关系比较复杂,利用测井数据预测煤层工业组分和发热量,需优先采用非线性预测方法更好,本文采用在人工智能领域应用较广泛的深度神经网络算法进行预测。

神经网络在地球物理等方面的应用由来已久^[20-21],通常而言,随着层数增加,神经网络表示能力也随之增强,但实际情况下优化函数易陷入局部最优解^[22]。2006 年, Hinton 通过多层神经网络逐层训练方式优化局部最优解问题^[23],逐渐发展成了深度神经网络。深度神经网络的本质是通过构建许多隐藏层的网络结构来学习更复杂的函数映射关系,利用逐层特征变换,提升分类或预测准确性^[24-25]。

M_{ad}	0.19	-0.22	-0.26	-0.21	-0.17	-0.2	0.052	-0.0036	1	-0.23	-0.23	-0.097	0.11
A_d	-0.084	-0.051	0.09	-0.072	0.12	0.17	-0.1	0.061	-0.23	1	-0.43	0.27	-0.89
FC_d	-0.32	0.03	0.41	-0.45	0.28	0.34	-0.11	-0.019	-0.23	-0.43	1	-0.65	0.19
V_{daf}	0.072	0.066	0.059	0.13	-0.002	-0.36	0.0012	0.028	-0.097	0.27	-0.65	1	-0.16
$Q_{gr,d}$	0.19	0.088	-0.19	0.21	-0.23	-0.28	0.1	-0.055	0.11	-0.89	0.19	-0.16	1
	煤层 厚度	短源距人 工伽马	长源距人 工伽马	自然 伽马	三侧向 电阻率	视电 阻率	自然 电位	井径	M_{ad}	A_d	FC_d	V_{daf}	$Q_{gr,d}$

图 5 研究区测井归一化数据与煤的工业组分和发热量线性相关系数热度

Fig. 5 The linear correlation coefficient heat diagram of normalized logging data and the industrial components and calorific value of coal in the study area

本文构建深度神经网络模型使用多层全连接层构建,全连接层每一神经元节点都与上一层的所有节点连接,可以有效地提取前一层特征。如图 6 所示为深度神经网络结构,网络结构共有 7 层,即:

输入层 1 层,输入层的节点数为 36 个,为样本对应深度 7 条测井曲线的特征值(每条曲线 5 个,即最大幅值、最小幅值、平均值、中间值、均方根)和煤层厚度倒数组成。隐藏层 5 层,其中的 4 层隐藏层均为全连接层,激活函数为线性整流函数(rectified linear unit,简称“ReLU”),节点数均为 36 个;为减少过拟合问题,在模型中设置了 1 层随机失活(Dropout)层,失活率为 0.3。输出层 1 层,输出层的节点数为 1 个,为煤层工业组分和发热量参数,即对每个参数独立建立模型、独立预测。

通过大量不同参数的预测结果进行对比分析,获得了适合于研究区的模型训练和预测参数,如表 3 所示。

基于图 5 中测井归一化数据与煤的工业组分和发热量的线性相关性研究成果,煤质参数 M_{ad} 、 FC_d 和 $Q_{gr,d}$ 采用上述模型直接预测即可。煤质参数 A_d 和 V_{daf} 可采用 2 种方式预测,择优选择结果:一是采用上述模型预测;二是“分步预测”,即建立 A_d 、 V_{daf} 与 FC_d 、 $Q_{gr,d}$ 的多元线性回归模型(见表 4),然后利用 M_{ad} 、 FC_d 和 $Q_{gr,d}$ 的预测结果和多元线性回归模型再预测 A_d 、 V_{daf} 。

数据预处理、模型建立与数据预测均以 Anaconda3 环境下的 Spyder 为开发平台,以 Python 为开发语言,以 TensorFlow、Keras 等深度学习框架和工

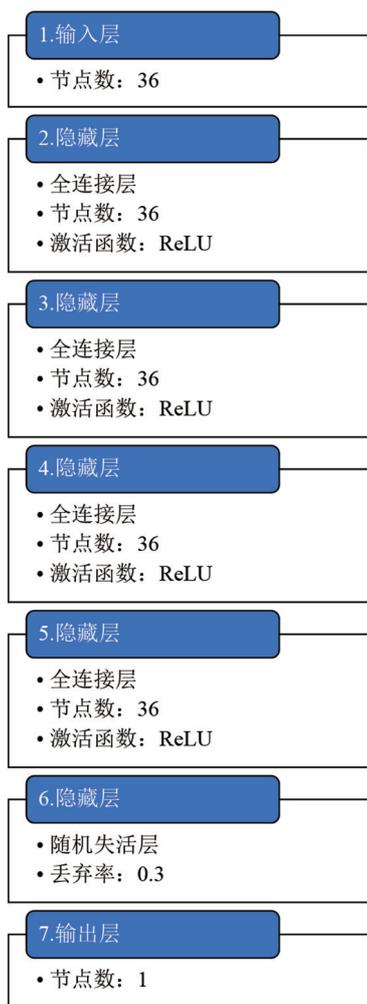


图6 深度神经网络结构

Fig. 6 The deep neural network structure diagram

表3 深度神经网络主要配置参数

Table 3 The main configuration parameters of deep neural network

预测参数	优化算法	损失函数	批大小	训练次数
M_{ad}	Adam	mae	16	2000
A_d	Adam	mae	8	2000
V_{daf}	Adam	mae	8	2000
FC_d	Adam	mae	8	2000
$Q_{gr,d}$	Adam	mae	8	2000

表4 煤层 A_d 、 V_{daf} 预测多元线性回归模型

Table 4 The multivariate linear regression model for predicting A_d and V_{daf} in coal seams

参数	预测方程
灰分	$A_d = -0.2256 \times FC_d - 1.9919 \times Q_{gr,d} + 79.1617$
挥发分	$V_{daf} = -0.3574 \times FC_d - 0.0162 \times Q_{gr,d} + 54.2128$

具辅助完成,功能丰富,接口方便,便捷性明显^[26]。

5 预测效果验证

对样本集中的 938 个样本按照一定比例随机分为训练集、验证集和测试集,其中训练集 656 个,占 69.94%;验证集 197 个,21.00%;测试集 85 个,占 9.06%。训练集和验证集参与模型训练,测试集完全不参与模型训练。

图 7 和表 5 分别为测试集预测结果与煤芯样试验分析结果对比图和统计表,分析可得:采用深度神经网络对煤层工业组分和发热量的预测结果与试验分析结果曲线图、变化范围、平均值基本一致,能达

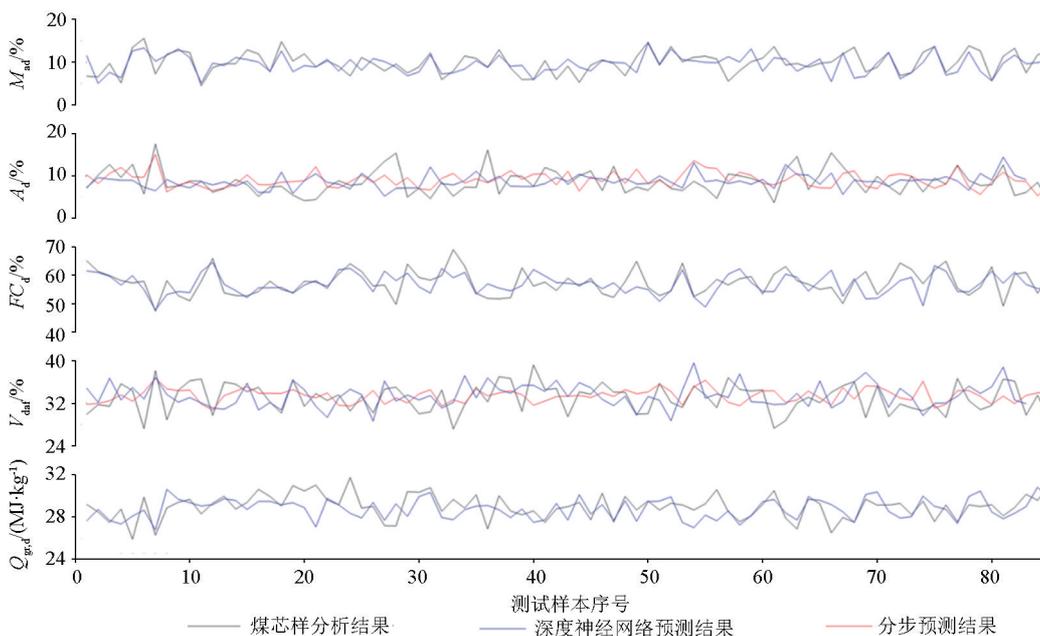


图7 测试集样本预测结果与煤芯样试验分析结果对比

Fig. 7 The comparison diagram of prediction results of test set samples and analysis results of coal core samples

到预期目标,对实际工作具指导意义;对采用 2 种方法预测的 M_{ad} 、 A_d ，“分步预测”误差相对较小,选择该结果为预测结果。

对于预测的 5 项煤质参数, M_{ad} 均方根误差 2.14%, 平均绝对误差 1.62%, 平均相对误差 18.34%; A_d 均方根误差 3.06%, 平均绝对误差 2.41%, 平均相对误差 26.89%; FC_d 均方根误差 3.66%, 平均绝对误差 2.88%, 平均相对误差 5.08%; V_{daf} 均方根误差 2.90%, 平均绝对误差 2.30%, 平均相对误差 6.89%; $Q_{gr,d}$ 均方根误差 1.18%, 平均绝对误差

0.90%, 平均相对误差 3.14%。所有预测结果均可满足生产需要。

对不同参数预测结果横向对比, A_d 预测结果相对较差。其原因为研究区煤层属于低灰分煤, 部分夹矸不规律地混入煤芯样后, 使试验分析结果与真实结果出现较大的不规律差异。通过剔除离群值等数学方法也不能完全消除其影响。测井数据虽是煤层原位状态下的响应, 但通过样本训练的方式并不能消除煤层中混入夹矸对煤层灰分的影响, 所以用测井数据预测 A_d 时的误差较大。

表 5 测试集中预测结果与样品分析结果对比误差

Table 5 The list of errors in comparison between prediction results and sample analysis results in the test set

煤质参数	样品分析结果 ($\frac{\text{最大值}-\text{最小值}}{\text{平均值}}$)	预测结果 ($\frac{\text{最大值}-\text{最小值}}{\text{平均值}}$)	均方根 误差/%	平均绝 对误差/%	平均相对 误差/%	备注
$M_{ad}/\%$	15.60-4.48 9.89	14.48-5.02 9.53	2.14	1.62	18.34	
		15.04-5.36 9.09	3.06	2.41	26.89	分步预测
$A_d/\%$	17.49-3.76 8.60	19.02.21-4.85 8.60	3.61	2.62	29.55	
		64.51-47.76 56.94	3.66	2.88	5.08	
$FC_d/\%$	69.05-47.38 57.44	36.71-30.68 33.39	2.90	2.30	6.89	分步预测
		39.08-28.29 33.40	3.42	2.58	7.78	
$V_{daf}/\%$	39.16-27.14 32.92	30.78-26.78 28.73	1.18	0.90	3.14	
		31.70-25.91 28.96				
$Q_{gr,d}/(\text{MJ} \cdot \text{kg}^{-1})$	31.70-25.91 28.96	30.78-26.78 28.73	1.18	0.90	3.14	

6 结论

1) 研究区以不粘煤为主, 属低灰、低硫、低磷, 中高挥发分, 高热值煤。煤质数据中, A_d 与 FC_d 、 $Q_{gr,d}$ 均显著线性负相关关系, V_{daf} 与 FC_d 呈显著线性负相关关系。因煤芯采样时混入夹矸影响, 出现部分 A_d 偏高、 $Q_{gr,d}$ 偏低现象。

2) 利用深度神经网络等大数据技术预测煤层工业组分时, 提取测井数据的最大幅值、最小幅值、平均值、中间值和均方根值作为测井响应特征是一种有效方法。将各测井方法响应特征和煤层厚度倒数共同组成样本特征效果较好。

3) 在数据预处理中, 对煤质数据通过“箱形图”剔除离群数据是一种较有效方法。

4) 对差异性较大的多源测井数据, 对不同数据源分别进行归一化处理后, 再合并成样本集, 能有效消除多源数据引起的测井响应差异。

5) 利用深度神经网络预测煤层工业组分和发

热量是一种有效方法, 对于和测井响应线性相关性较高的 M_{ad} 、 FC_d 和 $Q_{gr,d}$, 采用深度神经网络预测效果较好。

6) 对于与测井数据线性相关性较低的 A_d 和 V_{daf} , 先建立 A_d 、 V_{daf} 与 FC_d 、 $Q_{gr,d}$ 间的多元线性回归模型, 然后基于 M_{ad} 、 FC_d 和 $Q_{gr,d}$ 的预测结果和多源线性回归模型再预测 A_d 、 V_{daf} 是一种相对有效的方法。

参考文献 (References):

- [1] 杨孟达. 煤矿地质学[M]. 北京: 煤炭工业出版社, 2000.
Yang M D. Coal mining geology [M]. Beijing: China Coal Industry Publishing House, 2000.
- [2] 杨东根, 范宜仁, 邓少贵, 等. 利用测井资料评价煤层煤质及含气量的方法研究——以和顺地区为例[J]. 勘探地球物理进展, 2010, 33(4): 262-265, 227.
Yang D G, Fan Y R, Deng S G, et al. Logging evaluation for coal quality and gas content: A case study in Heshun region [J]. Progress in Exploration Geophysics, 2010, 33(4): 262-265, 227.
- [3] 钱玉萍, 张国华. 煤层工业组分的测井评价方法研究及应用[J]. 海洋石油, 2021, 41(3): 48-51, 71.

- Qian Y P, Zhang G H. Research and application of logging evaluation method for industrial components of coalbed[J]. *Offshore Oil*, 2021, 41(3): 48-51, 71.
- [4] 孟召平, 朱绍军, 贾立龙, 等. 煤工业分析指标与测井参数的相关性及其模型[J]. *煤田地质与勘探*, 2011, 39(2): 1-6.
Meng Z P, Zhu S J, Jia L L, et al. Relationship between approximate analysis of coal and log parameters and its models[J]. *Coal Geology & Exploration*, 2011, 39(2): 1-6.
- [5] 邵先杰, 孙玉波, 孙景民, 等. 煤岩参数测井解释方法——以韩城矿区为例[J]. *石油勘探与开发*, 2013, 40(5): 559-565.
Shao X J, Sun Y B, Sun J M, et al. Logging interpretation of coal petrologic parameters: A case study of Hancheng Mining Area[J]. *Petroleum Exploration and Development*, 2013, 40(5): 559-565.
- [6] 潘和平, 黄智辉. 煤层煤质参数测井解释模型[J]. *现代地质*, 1998, 12(3): 447-451.
Pan H P, Huang Z H. Log interpretation model of determining coalbed coal quality parameters[J]. *Geoscience*, 1998, 12(3): 447-451.
- [7] 刘同庆. 煤质工业分析测井解释及三维建模研究[J]. *煤炭技术*, 2021, 40(9): 71-75.
Liu T Q. Study on well logging interpretation and 3D modeling for coal quality industry analysis[J]. *Coal Technology*, 2021, 40(9): 71-75.
- [8] 高鉴东, 傅雪海, 刘爱华, 等. 沁水盆地和顺15#煤层煤质参数的测井响应预测[J]. *西安科技大学学报*, 2015, 35(1): 50-55.
Gao J D, Fu X H, Liu A H, et al. Logging response prediction of 15# coalbed coal quality parameters in Heshun area Qingshui Basin[J]. *Journal of Xi'an University of Science and Technology*, 2015, 35(1): 50-55.
- [9] 吴蒙, 秦云虎, 王晓青, 等. 任家庄煤矿煤层煤质测井响应及其预测模型[J]. *吉林大学学报: 地球科学版*, 2022, 52(2): 633-643.
Wu M, Qin Y H, Wang X Q, et al. Log response of coal quality and its prediction model in Renjiashuang Coal Mine[J]. *Journal of Jilin University: Earth Science Edition*, 2022, 52(2): 633-643.
- [10] 王安龙, 孙小琴, 谢学恒, 等. 利用测井资料计算煤层含气量及工业组分方法研究[J]. *油气藏评价与开发*, 2011, 1(s1): 69-73.
Wang A L, Sun X Q, Xie X H, et al. The method of calculating gas content and industrial components of coalbed by using well logging data[J]. *Reservoir Evaluation and Development*, 2011, 1(s1): 69-73.
- [11] 潘和平, 刘国强. 应用BP神经网络预测煤质参数及含气量[J]. *地球科学*, 1997, 22(2): 210-214.
Pan H P, Liu G Q. Applying back-propagation artificial Neural Networks to predict coal quality parameters and coalbed gas content[J]. *Earth Science*, 1997, 22(2): 210-214.
- [12] 陈钢花, 董维武. 遗传神经网络在煤质测井评价中的应用[J]. *测井技术*, 2011, 35(2): 171-175.
Chen G H, Dong W W. Application of genetic neural network to coal quality evaluation based on log data[J]. *Well Logging Technology*, 2011, 35(2): 171-175.
- [13] 朱吉昌. 测井曲线小波分析方法的改进及其在地层对比中的应用[D]. 北京: 中国地质大学(北京), 2016.
Zhu J C. Improvement of wavelet transform for well log curve and application to stratigraphic correlation[D]. Beijing: China University of Geosciences (Beijing), 2016.
- [14] 陈世达. 黔西多煤层煤层气储渗机制及合层开发技术对策[D]. 北京: 中国地质大学(北京), 2020.
Chen S D. Permeable-storage mechanism and the development technical countermeasures for coalbed methane in multi-seams in Western Guizhou [D]. Beijing: China University of Geosciences (Beijing), 2020.
- [15] 覃瑞东, 潘和平, 郭博, 等. 基于Hilbert-Huang变换的测井曲线自动分层方法[J]. *地质科技情报*, 2017, 36(2): 258-264.
Qin R D, Pan H P, Guo B, et al. Automatic stratification of well logging curves with Hilbert-Huang Transform[J]. *Geological Science and Technology Information*, 2017, 36(2): 258-264.
- [16] 滕俊. 利用成像测井资料提高常规测井薄层分辨率的方法研究[D]. 荆州: 长江大学, 2014.
Teng J. Method study on using imaging logging data to improve the conventional logging resolution in thin layers share [D]. Jingzhou: Yangtze University, 2014.
- [17] 王欣, 潘雨舟. 薄层电阻率的测井响应校正方法研究[J]. *油气藏评价与开发*, 2015, 5(4): 55-57.
Wang X, Pan Y Z. Research on log response correction method of sheet resistivity[J]. *Reservoir Evaluation and Development*, 2015, 5(4): 55-57.
- [18] 张兴涛, 王艳, 李伟峰. 测井数据井眼干扰误差校正方法[J]. *延安大学学报: 自然科学版*, 2015, 34(2): 39-41.
Zhang X T, Wang Y, Li W F. Correction method of borehole interference error in logging data [J]. *Journal of Yanan University: Natural Science Edition*, 2015, 34(2): 39-41.
- [19] 田志杰. 测井资料环境校正、标准化处理程序设计与实现[D]. 北京: 中国地质大学(北京), 2006.
Tian Z J. Design and implementation of environmental correction and standardization processing program for logging data [D]. Beijing: China University of Geosciences(Beijing), 2006.
- [20] 吴国培, 张莹莹, 张博文, 等. 基于深度学习的中心回线瞬变电磁全区视电阻率计算[J]. *物探与化探*, 2021, 45(3): 750-757.
Wu G P, Zhang Y Y, Zhang B W, et al. The calculation of full-region apparent resistivity of central loop TEM based on deep learning[J]. *Geophysical and Geochemical Exploration*, 2021, 45(3): 750-757.
- [21] 王蓉, 熊杰, 刘倩, 等. 基于深度神经网络的重力异常反演[J]. *物探与化探*, 2022, 46(2): 451-458.
Wang R, Xiong J, Liu Q, et al. Inversion of gravity anomalies based on a deep neural network[J]. *Geophysical and Geochemical Exploration*, 2022, 46(2): 451-458.
- [22] 周楚天, 刘攀. 基于深度神经网络的水文频率分析[J]. *水文*, 2022, 42(6): 1-6.
Zhou C T, Liu P. Hydrological frequency analysis based on deep neural networks [J]. *Journal of China Hydrology*, 2022, 42(6): 1-6.
- [23] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-

- 507.
- [24] 余凯,贾磊,陈雨强,等. 深度学习的昨天、今天和明天[J]. 计算机研究与发展,2013,50(9):1799-1804.
Yu K, Jia L, Chen Y Q, et al. Deep learning: Yesterday, today, and tomorrow [J]. Journal of Computer Research and Development, 2013, 50(9): 1799-1804.
- [25] 孙志军,薛磊,许阳明,等. 深度学习研究综述[J]. 计算机应用研究,2012,29(8):2806-2810.
Sun Z J, Xue L, Xu Y M, et al. Overview of deep learning [J]. Application Research of Computers, 2012, 29(8): 2806-2810.
- [26] 周永章,王俊,左仁广,等. 地质领域机器学习、深度学习及实现语言[J]. 岩石学报,2018,34(11):3173-3178.
Zhou Y Z, Wang J, Zuo R G, et al. Machine learning, deep learning and Python language in field of geology [J]. Acta Petrologica Sinica, 2018, 34(11): 3173-3178.

A prediction model of the industrial components and calorific values of coal seams based on multi-source log data

YU Yong-Peng¹, ZHANG Guang-Bing¹, HUANG Zi-Jun², YAN Jian-Bo¹,
WANG Jia-Wen¹, YANG Yan-Cheng¹, MAO Xing-Jun¹

(1. Coal Geology Bureau of Ningxia Hui Autonomous Region, Yinchuan 750002, China; 2. Ningxia Coal Exploration and Engineering Co., Ltd., Yinchuan 750002, China)

Abstract: The industrial components and calorific values of coal seams serve as an important basis for the evaluation of coal quality, and the prediction of them based on log data allows for overcoming the deficiency in the experimental analysis of coal core samples. This study collected data from digital logs and coal quality analysis at different stages (e. g., detailed survey and exploration) of a coal field in Ningxia. Based on the investigation of the coal quality and log responses, as well as statistical analysis, this study developed the methods for extracting log response characteristics, establishing sample sets, and processing data and established a deep neural network-based prediction model. Then, it confirmed the validity of the prediction model by comparing the predicted results of testing data with the results from the experimental analysis.

Key words: multi-source data; geophysical logging; coal; industrial component; calorific value; prediction model

(本文编辑:王萌)