

doi: [10.12097/gbc.2024.03.037](https://doi.org/10.12097/gbc.2024.03.037)

基于测井参数的延川南气田煤层含气量预测模型

刘晓^{1,2}, 陈贞龙^{1,2}, 杨松^{1,2}, 李松³, 常闯³

LIU Xiao^{1,2}, CHEN Zhenlong^{1,2}, YANG Song^{1,2}, LI Song³, CHANG Chuang³

1. 中国石化临汾煤层气分公司, 山西 临汾 041000;
2. 中国石化深层煤层气勘探开发重点实验室, 江苏 南京 210011;
3. 中国地质大学(北京)能源学院, 北京 100083

1. Linfen Coalbed Methane Company, SINOPEC, Linfen 041099, Shanxi, China;
2. Key Laboratory of Deep CBM Exploration and Production, SINOPEC, Nanjing 210011, Jiangsu, China;
3. School of Energy Resources, China University of Geosciences (Beijing), Beijing 100083, China

摘要:【研究目的】煤层含气量是煤层气资源评价与开发的核心参数,但当前含气量预测模型普遍存在精度不足、泛化能力弱等问题,制约着煤层气的勘探开发。【研究方法】基于延川南气田煤层含气量的测井响应特征,利用MIV(Mean Impact Value)方法优选测井参数,引入BP神经网络与随机森林思想,建立高精度煤层含气量预测模型。【研究结果】相比传统的多元线性回归模型,BP神经网络模型与随机森林模型的预测精度有明显提升,其中随机森林模型预测精度更高。【结论】随机森林模型更适用于研究区煤层含气量的预测,基于模型预测结果,研究区煤层含气量的分布范围为4.84~21.83 m³/t,平均为11.63 m³/t;平面上,煤层含气量由东南向西北逐渐升高,变化规律与煤层埋深规律大体一致;纵向上,随着埋深的增大,煤层含气量逐渐升高,但含气量分布的离散程度增大。

关键词:含气量;测井参数;MIV;BP 神经网络;随机森林

创新点:利用MIV方法优选测井参数,引入机器学习思想提升煤层含气量预测模型精度。

中图分类号:P618.13 **文献标志码:**A **文章编号:**1671-2552(2025)05-0792-09

Liu X, Chen Z L, Yang S, Li S, Chang C. Logging prediction model of coal seam gas content in Southern Yanchuan gas field. Geological Bulletin of China, 2025, 44(5): 792–800

Abstract: [Objective] The coal seam gas content is a core parameter for resource assessment and development, but current gas content prediction models generally suffer from issues such as insufficient accuracy and weak generalization ability, which hinder the exploration and development of coalbed methane. [Methods] Based on the logging response characteristics of coal seam gas content in Southern Yanchuan gas field, the MIV (Mean Impact Value) method was utilized to optimize the logging parameters. The BP neural network and random forest algorithm were introduced to establish a high-precision coal seam gas content prediction model. [Results] Compared to the traditional multiple linear regression model, both the BP neural network and random forest models achieved notably higher prediction accuracy, with the random forest model performing even better. [Conclusions] The Random Forest model is more suitable for predicting the coalbed methane content in the study area. Based on the model's prediction, the distribution range of gas content in the gas field is 4.84~21.83 m³/t, with an average of 11.63 m³/t. Spatially, the gas content of coal seam increases gradually from southeast to northwest, and its variation law is generally consistent with the buried depth pattern of coal seam. Vertically, with the increase of buried depth, the gas content of coal seam increases gradually, but the dispersion degree of gas content distribution increases.

收稿日期: 2024-03-22; 修订日期: 2024-08-12

资助项目: 国家自然科学基金面上项目《深部煤层气赋存态调整分配及释放产出机制》(批准号: 42272195), 中国石油化工股份有限公司科技项目《华东探区深部煤层气富集规律与有效开发技术》(编号: P23205)、《深层煤炭地下气化关键技术研究》(编号: P22186)

作者简介: 刘晓(1982-), 男, 硕士, 高级工程师, 从事非常规煤层气勘探开发工作。E-mail: 47186025@qq.com

Key words: gas content; logging parameters; MIV; BP neural network; random forest

Highlights: The MIV method is utilized to optimize logging parameters, and machine learning concepts are introduced to enhance the accuracy of coalbed methane content prediction models.

中国煤层气资源丰富,有巨大的勘探开发潜力,煤层气产业已步入规模化发展阶段,在沁水盆地南部和鄂尔多斯盆地东缘形成了两大煤层气产业基地(许浩等, 2024)。而煤层含气量是表征煤储层特征的关键地质参数,是煤层气开发的基础,对资源量的估算、有利区块的优选及煤层气的生产布局具有重要意义(Li et al., 2023)。

煤心样品自然解吸获取的含气量数据精度高,但是成本高、耗时长、可获取数据信息量小(Ge et al., 2018; Hou et al., 2020)。关于煤层含气量预测已有大量研究成果,预测精度不断提高。以等温吸附为基础,结合水分、灰分对甲烷吸附的影响,建立了KIM 方程来计算煤层含气量(Kim, 1977)。经典的Langmuir 方程在预测煤层含气量方面得到了广泛应用,并衍生出多种变式(Hawkins et al., 1992; Song et al., 2017; Zhang et al., 2017),但是该方法受限于样品数量及经济成本。鉴于此,地球物理测井技术具备经济、快速、信息量大、数据连续等优点,被广泛应用于煤层含气量探测(Fu et al., 2009; Ghosh et al., 2014; Roslin and Esterle, 2015)。该技术揭示密度、电阻率等测井参数与煤层实测含气量存在较好的线性关系(Mullen, 1989; Wei et al., 2000), Shao et al.(2013)基于此构建了含气量测井预测模型。

为进一步提高煤层含气量模型的预测精度,机器学习理论方法被广泛应用,如 BP 神经网络、支持向量机、随机森林等(吴东平等, 2000; 孟召平等, 2008; 李泽辰等, 2018; 冯鹏等, 2022; 林魂等, 2023; 秦瑞宝等, 2023)。不同机器学习模型的算法原理、训练过程、处理能力、鲁棒性等均存在差异(陈涛等, 2021),不同研究区因煤层物性、储层条件及测井响应不同,使得预测模型具有地质针对性和地域特点(李丹丹等, 2022)。这些问题都影响着模型的预测精度。

本文以鄂尔多斯盆地东南缘延川南气田为例,通过相关性分析明确煤层含气量的测井响应特征,基于 MIV (Mean Impact Value)方法实现测井参数优选,选用 BP 神经网络及随机森林方法作为核心建模技术,并与多元线性回归方法进行对比,构建适用于

研究区的高精度煤层含气量预测模型,以期为研究区煤层气的勘探开发提供依据。

1 概况及数据来源

延川南气田位于鄂尔多斯盆地东南缘(刘晓, 2024),隶属于晋西挠褶带、渭北隆起和陕北斜坡的构造过渡区,整体为一走向南北、向西倾斜的宽缓单斜构造,中部西掌断裂带将研究区划分为谭坪和万宝山 2 个构造带(图 1)。主力煤层为下二叠统山西组的 2 号煤层,厚度大、连续性好,平均埋深 1300 m,由东部的谭坪构造带至西部的万宝山构造带埋深逐渐变大,总体上煤层埋深呈现西北深、东南浅的特点。

2 号煤层厚度为 2.88~6.73 m,平均约为 4.5 m。镜质组平均最大反射率为 1.96%~3.22%,整体处于贫煤、无烟煤阶段,对应煤岩生气高峰时期,并且随埋深的增加变质程度增大,平面上由东向西 R_o 逐渐增大。煤体结构以原生-碎裂煤为主,展布受断裂构造控制;一般含 1~2 层夹矸,局部地区发育 3 层夹矸,夹矸总厚 0~0.80 m,平均约为 0.35 m。煤层实测含气量的分布范围为 5.54~20.48 m^3/t ,平均为 11.67 m^3/t 。

本次统计了气田内 21 口探井煤心测试结果及对应各取样点的常规测井数据,包括密度、井径、声波时差、自然伽马、中子、浅侧向电阻率和深侧向电阻率,每口井根据样品深度的差异性,选取 2 组数据,进行异常值的检查及筛选,去掉 2 组数据,共 40 组测井数据用于后续分析。

2 煤层含气性测井响应

2.1 测井参数及含气量分布范围

统计的研究区煤层深度分布范围为 876.53~1497.18 m,平均 1074.62 m。各测井参数范围分布为(图 2):密度测井(DEN)为 1.20~2.03 g/cm^3 ,平均为 1.45 g/cm^3 ;井径测井(CAL)为 21.12~42.93 cm,平均为 27.06 cm;中子测井(CNL)为 27.71%~76.67%,平均为 50.59%;声波时差(DT)为 293.23~484.61 μs ,平均为 392.45 μs ;自然伽马(GR)为 32.41~130.58 API,

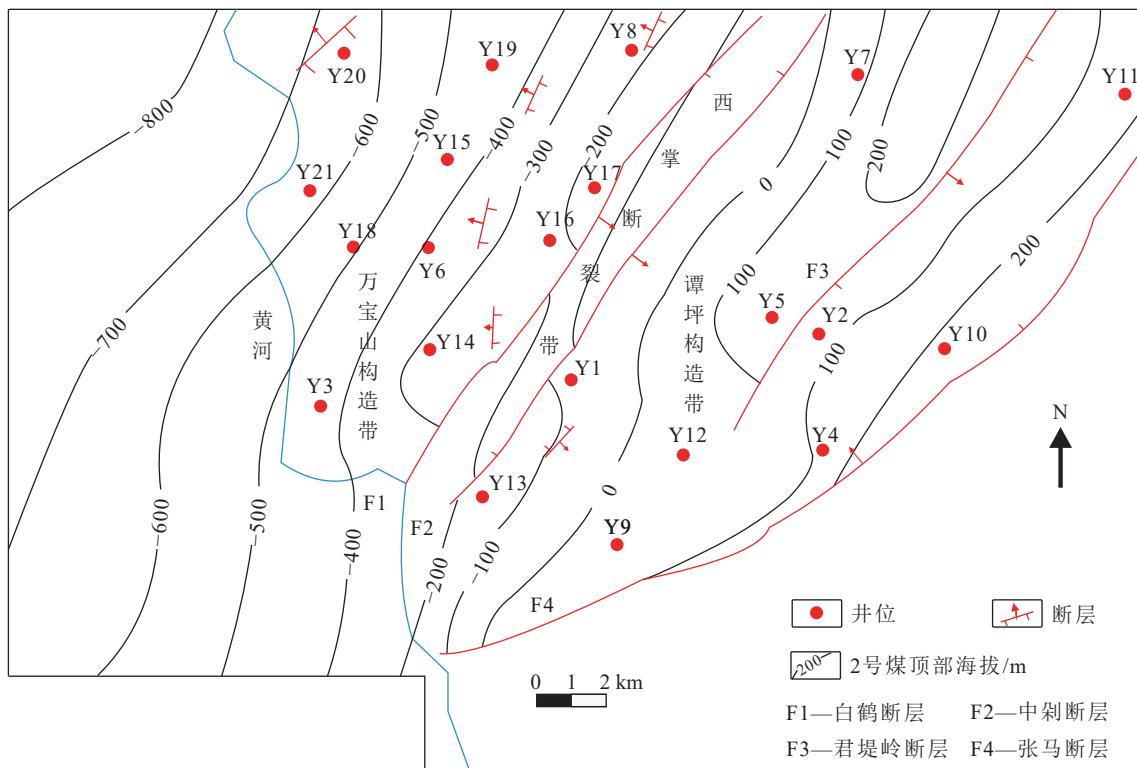


图 1 延川南区块构造纲要图(据常闻, 2023)

Fig. 1 Structural outline map of Southern Yanchuan area

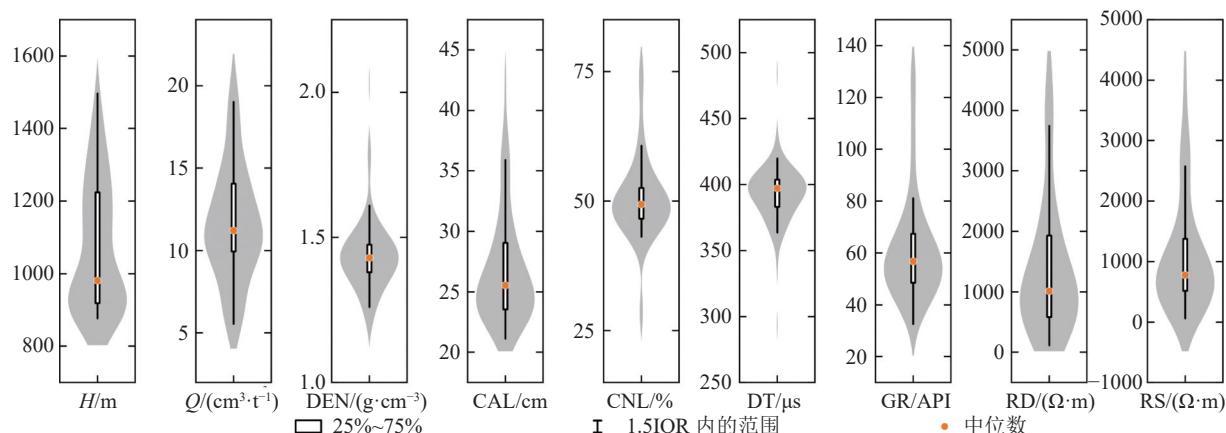


图 2 2号煤层测井参数及含气量分布范围

Fig. 2 Logging parameters and gas content distribution range of No.2 coal seam

平均为 63.18 API; 深侧向电阻率 (RD) 为 110.92~4910.31 $\Omega \cdot m$, 平均为 1450.41 $\Omega \cdot m$; 浅侧向电阻率 (RS) 为 59.71~4371.73 $\Omega \cdot m$, 平均为 1173.75 $\Omega \cdot m$ 。

2.2 煤层含气性测井响应特征

为具体分析延川南气田煤储层含气性的测井响应特征, 本次通过 Pearson 相关系数分析各常规测井参数与煤层含气量间的相关性, 据公式(1)可得到各参数间的相关系数(陈涛等, 2021):

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

式中: r 为 Pearson 相关系数; \bar{x} 、 \bar{y} 分别为测井曲线均值; x_i 、 y_i 为第 i 个样本对应的测井曲线数值。

计算结果(表 1)显示, 测井参数与煤层含气量、测井参数与测井参数之间的相关性差异较大(图 3), 不同测井参数对含气性的响应效果存在明显差异,

表1 2号煤层含气量与测井参数之间的相关系数

Table 1 The correlation coefficient between gas content and logging parameters of No.2 coal seam

参数	含气量	深度	DEN	GR	RD	RS	DT	CAL	CNL
含气量	1.00								
深度	0.48	1.00							
DEN	0.52	0.12	1.00						
GR	0.03	0.11	0.30	1.00					
RD	-0.58	-0.21	-0.31	-0.11	1.00				
RS	-0.58	-0.20	-0.29	-0.02	0.93	1.00			
DT	-0.53	-0.24	-0.67	-0.37	0.34	0.33	1.00		
CAL	-0.06	-0.09	-0.24	-0.15	0.09	-0.03	0.32	1.00	
CNL	-0.12	-0.17	-0.20	-0.45	0.24	0.13	0.42	0.69	1.00

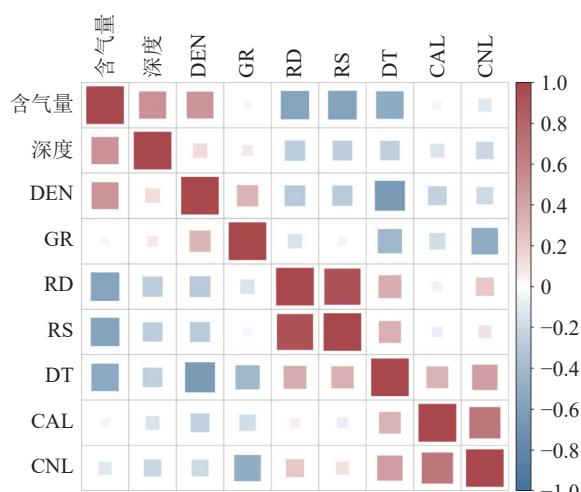


图3 2号煤层实测含气量与常规测井参数相关性热图

Fig. 3 The correlation heat map between measured gas content and conventional logging parameters in No.2 coal seam

因此测井参数的优选对煤层含气量的预测非常必要。

基于测井参数、含气量之间的相关性,结合煤储层的物理性质,简要做以下煤层含气量测井响应特征分析。

(1) 煤层含气量主要与煤吸附能力及保存条件有关。在研究区构造较简单的情况下,随煤层埋藏深度增大,煤吸附能力变强;煤层气保存能力增强,含气量随之增加(陈世达等, 2024)。延川南气田煤层埋深与含气量明显的正相关关系,随煤层埋深增大,含气量逐渐变高。

(2) 延川南气田密度测井参数与煤层含气量正相关。密度响应值随着煤层致密程度的增加而增大,相比谭坪构造带,万宝山构造带煤储层致密程度

大。液氮实验显示,万宝山构造带煤微小孔隙较发育。微小孔占比大,同体积煤提供的吸附位多。延川南区块煤层气以吸附气形式为主,游离气含量极低,因此密度测井参数与含气量呈正相关关系。

(3) 煤层电阻率受诸多因素影响,包括煤岩成分、煤变质程度、地层水、孔渗性等。电阻率测井数据与含气量关系复杂(孟召平等, 2020; 谌丽等, 2023)。研究区电阻率测井数据与含气量呈负相关关系,随电阻率增大,含气量逐渐变高(表1)。

(4) 地层岩石骨架及其孔隙充填物的物性决定声波时差的大小,煤层内部结构相对松散,声波在煤层中传播速度相对较低,时差较大。由于声波在不同相态介质中的传播速度差异较大,煤层气的存在使声波速度衰减,导致声波时差增大。然而,研究区煤层声波时差测井数据与含气量呈负相关,表明声波时差与含气量关系复杂,受岩石骨架、孔隙结构、气水赋存状态等条件影响较大。

由上述分析可知,测井数据包含复杂的地质信息及受其他条件影响而产生的噪声信息(王欣等, 2024),简单的线性相关分析不足以机器学习模型提供输入自变量优选的支撑,因此有必要应用技术方法实现测井参数类型的优选。

3 预测模型

3.1 测井参数优选

常用的特征维度降维方法有主成分分析法、因子分析法、平均值影响法等。其中,平均值影响法(Mean Impact Value)可有效反映输入自变量对因变量的影响,数值大小可以衡量自变量对因变量的模

型影响程度(杨勇等, 2015; 李琴等, 2016)。该方法通过控制单一变量原则, 分别等比例缩放每类自变量数据, 计算自变量数据放大和缩小情景下的模型输出结果之差, 记为该自变量的 MIV 值, 用以衡量所有自变量对因变量的影响程度。

分别分析各测井参数对煤层含气量的影响。结果显示, 各测井参数的 MIV 绝对值越大, 该参数对含气量的影响程度越大, 自变量与因变量间的函数关系越强(图 4)。根据计算结果, 研究区适用于煤层含气量建模的测井参数组合为 DEN、RD、RS、DT、H, 同时考虑到 RD、RS 对含气量的影响基本一致, 最终优选的模型自变量组合为 DEN、H、DT、R(RD 与 RS 均值)。

3.2 建模方法

3.2.1 BP 神经网络

BP 神经网络(Back Propagation Neural Network)是一种基于梯度下降算法的人工神经网络模型, 由输入层、隐藏层和输出层组成, 在训练过程中通过反向传播调整网络的权重和偏置, 优化网络的性能、实现数据的学习和预测(Rumelhart et al., 1986; Bharadwaj et al., 2021)。

BP 神经网络的迭代分为前向传播和反向传播 2 个阶段, 在前向传播阶段, 输入数据沿着网络逐层传递, 直至生成输出(公式(2)和(3));然后, 通过比较输出与期望输出, 计算误差(公式(4))。在反向传播阶段, 使用梯度下降算法(公式(5)), 根据梯度的方向和大小更新权重和偏置(公式(6)和(7))以最小化误差, 直到达到最大迭代次数或损失函数收敛, 迭代停止, 模型训练结束。

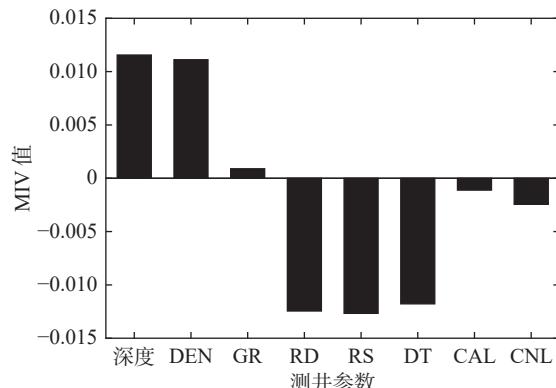


图 4 各测井参数对含气量模型的影响

Fig. 4 The influence of logging parameters on gas content modeling

$$Z = W \cdot X + b \quad (2)$$

$$A = f(Z) \quad (3)$$

$$L = \frac{1}{m} \sum_{i=1}^m L(y_i, \hat{y}_i) \quad (4)$$

$$\frac{\partial L}{\partial W} = \frac{1}{m} \sum_{i=1}^m \frac{\partial L(y_i, \hat{y}_i)}{\partial W} \quad (5)$$

$$W = W - \alpha \frac{\partial L}{\partial W} \quad (6)$$

$$b = b - \alpha \frac{\partial L}{\partial b} \quad (7)$$

式中: Z 表示神经网络中神经元输入的加权和; W 表示权重矩阵; X 为输入向量; b 为偏置; A 为激活输出; $f()$ 为激活函数; L 为损失函数; y_i 表示实际输出; \hat{y}_i 为预测输出; m 为样本数; α 为学习率。

对于煤层含气量的预测, BP 神经网络模型输入层节点 4 个(优选后的测井参数), 输出层节点 1 个(含气量值)。

3.2.2 随机森林法

随机森林(Random Forest)是基于集成学习思想将决策树集成并用于分类和回归的一种算法。随机森林采用 Bagging 的集成思想及 bootstrap 抽样技术, 从原始数据中有放回地随机抽取样本构建决策树, 由所有决策树组成随机森林(Dietterich, 2000)。

随机森林具有以下特点和优势(Breiman, 2001): 通过多个决策树的集成, 可以降低单个决策树的过拟合风险, 提高整体模型的泛化能力; 随机选择样本和属性可以提高决策树的多样性, 减少决策树之间的相关性; 对于大规模数据集, 训练和预测速度相对较快; 能够处理具有高维特征的数据, 且不需要对特征进行过多的预处理。

3.3 结果对比

建模过程中, 按照测试集和训练集 3 : 7 的比例从 40 个样本中随机选取 12 个测试样本, 余下样本作训练集。其中, 煤层埋深(H)、声波时差(DT)、密度测井(DEN)和深浅侧向电阻率测井均值(R)作为输入数据, 含气量作为输出数据。

如图 5 所示, 基于多元线性回归的煤层含气量预测模型的预测性能在数据不均衡时效果较差。基于 BP 神经网络的煤层含气量模型训练集与测试集的相关系数分别为 0.834 与 0.750(图 6), 基于随机森林算法的煤层含气量模型训练集与测试集的相关系数分别为 0.949 与 0.811(图 7), 均具有良好的预

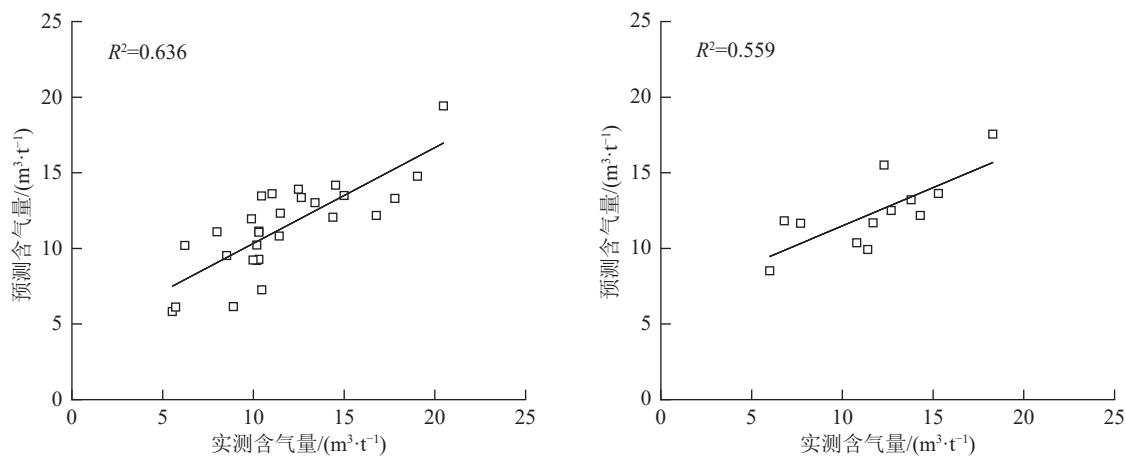


图5 基于多元线性回归的煤层预测含气量与实测含气量交会图

Fig. 5 Crossplot of predicted and measured gas content of coal seam based on multiple linear regression

a—训练部分线性回归模型; b—测试部分线性回归模型

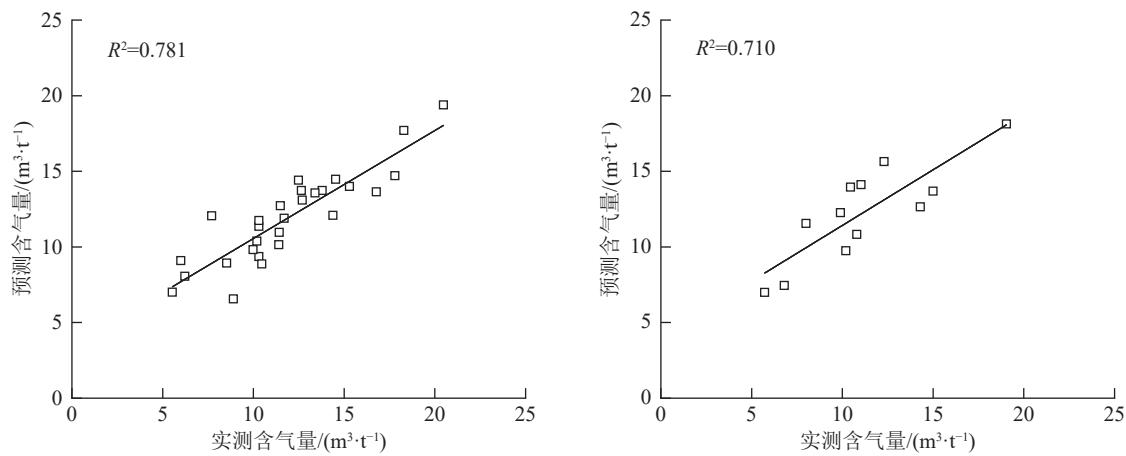


图6 基于BP神经网络的煤层预测含气量与实测含气量交汇图

Fig. 6 Crossplot of predicted and measured gas content of coal seam based on BP neural network

a—训练部分BP神经网络模型; b—测试部分BP神经网络模型

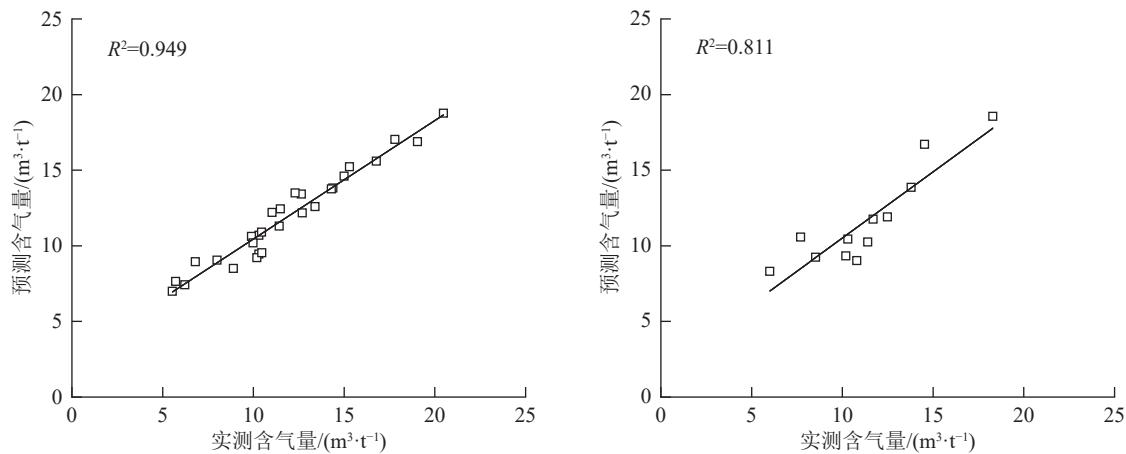


图7 基于随机森林算法的煤层预测含气量与实测含气量交汇图

Fig. 7 Crossplot of predicted and measured gas content of coal seam based on random forest algorithm

a—训练部分随机森林模型; b—测试部分随机森林模型

测能力。因此,基于机器学习算法建模对于反演测井参数与煤层含气量间隐含的复杂非线性映射函数关系非常有效(图6、图7),证明引入机器学习方法会使煤层含气量的预测精度变高。

对比分析发现,基于随机森林算法的预测模型优于基于BP神经网络的预测模型,究其原因,主要受2种机器学习算法适用条件及鲁棒性的影响。BP神经网络适用于处理大规模和复杂的数据集,但训练时间和计算资源消耗较大;而随机森林适用于中等规模的数据集,并且在解释性和鲁棒性方面有一定优势。同时,BP神经网络对于噪声数据和异常值较敏感,可能存在过拟合或欠拟合,因此在模型准确度上,对于含气量测井预测模型相对较小规模的数据集及不可避免的噪声数据与异常值,基于随机森林算法的预测模型优于基于BP神经网络的预测模型。

除拟合度外,亦可通过均方根误差(RMSE)对比模型预测能力,衡量模型预测结果与实测值的接近程度。模型预测效果越好,均方根误差值越小,其计算公式如下:

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (p_i - m_i)^2}{n}} \quad (8)$$

式中: p_i 为模型预测数据; m_i 为实测数据; n 为用于网络训练或测试的样本数量。

各模型RMSE计算结果见表2。随机森林训练集和测试集的均方根误差分别为1.071和1.584,BP神经网络训练集和测试集的均方根误差分别为1.718和2.213,多元线性回归训练集和测试集的均方根误差分别为2.238和2.383。对比可知,随机森林模型的预测精度较高,多元线性回归模型难以反映测井参数与煤层含气量之间的复杂关系,在数据不均衡时泛化能力较差,预测结果与真实值误差相对较大。

综合对比各模型的拟合度和均方根差,随机森林模型优于BP神经网络模型,机器学习模型优于多元线性回归模型。相比其他2种模型,随机森林模型既能有效反映测井参数与煤层含气量之间的复杂关系,又不需要大量的实际测试数据,且具有受噪声影响小、训练速度快、解释性、鲁棒性较优等特点,更适用于构建煤层含气量预

表2 煤层含气量预测模型的预测精度评价指标

Table 2 Evaluation index of prediction accuracy for the coal seam gas content prediction model

模型指标	BP神经网络		随机森林		多元线性回归	
	训练集	测试集	训练集	测试集	训练集	测试集
R^2	0.781	0.710	0.949	0.811	0.636	0.559
RMSE	1.718	2.213	1.071	1.584	2.238	2.383

测模型。

3.4 实例应用

采用建立的随机森林模型,对研究区其他点位的煤层含气量进行预测,结合实测数据,绘制了2号煤层含气量的平面分布图(图8)(同一井位取数据点均值)和垂向分布图(图9)。统计实测数据和预测数据,煤层含气量分布范围为4.84~21.83 m³/t,平均11.63 m³/t。

平面上,煤层含气量由东南向西北逐渐升高,以西掌断裂带为分界线,谭坪构造带煤层含气量普遍小于12.00 m³/t,万宝山构造带含气量普遍大于12.00 m³/t,变化规律与煤层埋深规律大体一致。

垂向上,在研究区煤层埋深范围内,煤层含气量与煤层埋深呈正相关关系(图9)。

4 结 论

(1)测井参数与煤储层含气量之间的相关性差异较大,不同测井参数对含气量的影响较复杂,煤层含气量测井响应特征明显,具备基于测井参数建立含气量预测模型的基础。

(2)简单的多元线性回归模型预测结果较差,难以反映测井参数与煤储层含气量之间的复杂关系,BP神经网络模型与随机森林模型的预测精度有明显提升。其中,随机森林模型预测精度更高,具有受噪声影响小、训练速度快、解释性、鲁棒性较优等特点,更适用于研究区煤储层含气量的预测。

(3)应用随机森林模型对气田其他点位煤层含气量进行了预测。气田含气量的分布范围为4.84~21.83 m³/t,平均为11.63 m³/t,平面上煤层含气量由东南向西北逐渐升高,纵向上随着埋深的增大,煤含气量逐渐升高。

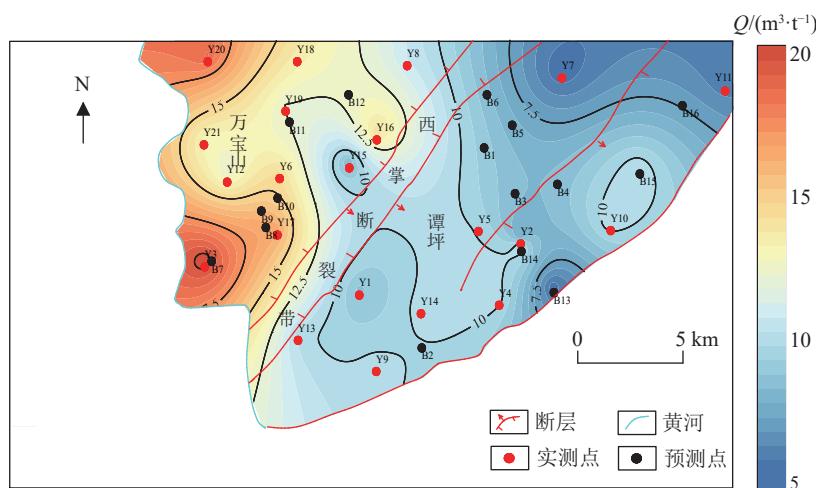


图8 研究区2号煤层含气量平面等值线图

Fig. 8 The gas content plane contour map of No.2 coal seam in the study area

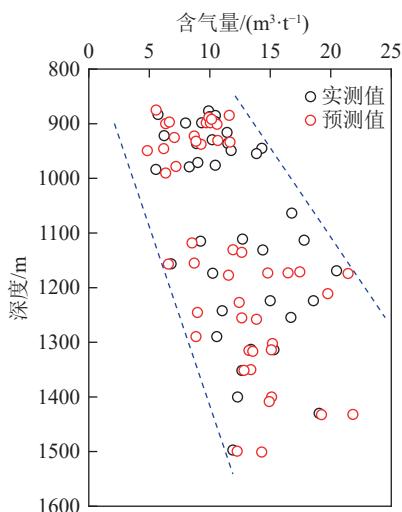


图9 研究区2号煤层含气量随埋深的变化

Fig. 9 The variation of gas content in No.2 coal seam with buried depth in the study area

References

- Bharadwaj P K B, Kanagachidam-baresan G R. 2021. Pattern recognition and machine learning.
- Breiman. 2001. Random Forests [J]. *Mach-Learn*, 45(1): 5–32.
- Chang C, Li S, Tang D Z, et al. 2023. In-situ stress calculation for coal reservoirs based on log parameters: A case study of the southern Yanchuan block [J]. *Coal Geology & Exploration*, 51(5): 23–32 (in Chinese with English abstract).
- Chen S D, Hou W, Tang D Z, et al. 2024. Effects of depth on gas-bearing properties of coal reservoirs and their coupling relationships with coalbed methane accumulation [J]. *Coal Geology & Exploration*, 52(2): 52–59 (in Chinese with English abstract).
- Chen T, Zhang Z S, Zhou X Q, et al. 2021. Prediction model of coalbed methane content based on well logging parameter optimization [J]. *Coal Geology & Exploration*, 49(3): 227–235 (in Chinese with English abstract).
- Dietterich T G. 2000. Ensemble methods in machine learning [C]//Proc International Work Shop on Multiple Classifier Systems.
- Feng P, Li S, Tang D Z, et al. 2022. Application of support vector machine in prediction of coal seam stress [J]. *Geoscience*, 6(5): 1333–1340 (in Chinese with English abstract).
- Fu X, Qin Y, Wang G, et al. 2009. Evaluation of gas content of coalbed methane reservoirs with the aid of geophysical logging technology [J]. *Fuel*, 88: 2269–2277.
- Ge X, Liu D, Cai Y, et al. 2018. Gas content evaluation of coalbed methane reservoir in the Fukang area of Southern Junggar Basin, Northwest China by multiple geophysical logging methods [J]. *Energies*, 11: 1867.
- Ghosh S, Chatterjee R, Paul S, et al. 2014. Designing of plug-in for estimation of coal proximate parameters using statistical analysis and coal seam correlation [J]. *Fuel*, 134: 63–73.
- Hawkins J M, Schraufnagel R A, Olszewski A J. 1992. Estimating coalbed gas content and sorption isotherm using well log data [C]//SPE Annual Technical Conference and Exhibition. SPE: SPE-24905-MS.
- Hou X, Liu S, Zhu Y, et al. 2020. Evaluation of gas contents for a multi-seam deep coalbed methane reservoir and their geological controls: In situ direct method versus indirect method [J]. *Fuel*, 265: 116917.
- Kim A G. 1977. Estimating methane content of bituminous coalbeds from adsorption data [M]. Department of the Interior, Bureau of Mines.
- Li D D, Wang Z G, Jiang W P, et al. 2022. Approach study on coal gas content quantitative assessment based on well logging parameters—a case study of coal No. 15 in Shouyang block [J]. *Coal Geology of China*, 34(8): 34–40 (in Chinese with English abstract).
- Lin H, Sun X Y, Song X X, et al. 2023. A model for shale gas well production prediction based on improved artificial neural network [J]. *Petroleum Reservoir Evaluation and Development*, 13(3): 467–473 (in Chinese with English abstract).
- Li Q, Liu Y S, Huang Z Q, et al. 2016. Exploring mechanism and numerical simulation of rock breaking process using PDC bit [J]. *Mechanical Science and Technology*, 35(2): 203–209 (in Chinese with English abstract).

- English abstract).
- Li S, Qin Y, Tang D Z, et al. 2023. A comprehensive review of deep coalbed methane and recent developments in China[J]. *International Journal of Coal Geology*, 279: 104369.
- Liu X. 2024. Comparison of seam network morphology in coal reservoirs under different fracturing scales: A case of Yanchuan CBM Gas Field[J]. *Petroleum Reservoir Evaluation and Development*, 14(3): 510–518 (in Chinese with English abstract).
- Li Z C, Du W F, Hu J K, et al. 2018. Interpretation method of gas content in logging of Linxing block in Ordos Basin[J]. *Coal Journal*, 43(S2): 490–498 (in Chinese with English abstract).
- Meng Z P, Tian Y D, Li G F. 2020. Geology theory and method of coalbed methane development[M]. Beijing: Science Press (in Chinese with English abstract).
- Meng Z P, Tian Y D, Lei Y. 2008. Prediction models of coal bed gas content based on BP neural networks and its applications[J]. *Journal of China University & Mining and Technology*, (4): 456–461. (in Chinese with English abstract).
- Mullen M J. 1989. Coalbed Methane Resource evaluation from wireline logs in the northeastern San Juan Basin: A case study[C]//SPE Rocky Mountain Petroleum Technology Conference/Low-Permeability Reservoirs Symposium. SPE: SPE-18946-MS.
- Qin R B, Ye J P, Li L, et al. 2023. Artificial-intelligence and machine-learning models of coalbed methane content based on geophysical logging data: A case study in Shizhuang South Block of Qinshui Basin, China[J]. *Geophysical Prospecting for Petroleum*, 62(1): 68–79 (in Chinese with English abstract).
- Rumelhart, D E, Hinton, G E, Williams R J. 1986. Learning representations by back propagating errors[J]. *Nature*, 323(6088): 533–536.
- Roslin A, Esterle J S. 2015. Electro facies analysis using high-resolution wireline geophysical data as a proxy for inertinite-rich coal distribution in Late Permian Coal Seams, Bowen Basin[J]. *International Journal of Coal Geology*, 152: 10–18.
- Shao X, Sun Y, Sun J, et al. 2013. Log interpretation for coal petrologic parameters: A case study of Hancheng mining area, Central China[J]. *Petroleum Exploration and Development*, 40: 599–605.
- Shen L, Wang C Z, Ning C Q, et al. 2023. Well-log lithofacies classification based on machine learning for Chang-7 member in Longdong area of Ordos Basin[J]. *Petroleum Reservoir Evaluation and Development*, 13(4): 525–536 (in Chinese with English abstract).
- Song J, Su X, Wang Q, et al. 2017. A new method for calculating gas content of coal reservoirs with consideration of a micro-pore overpressure environment[J]. *Natural Gas Industry B*, 4: 182–188.
- Wang X, Han J Q, Zan L, et al. 2024. Logging evaluation of shale oil in the second member of Funing Formation of Qintong Sag, Subei Basin[J]. *Petroleum Reservoir Evaluation and Development*, 14(3): 364–372 (in Chinese with English abstract).
- Wei L, Zhang Y, Li W. 2000. Research on the method of electric character logging in the third series coal of Baoqing area[J]. *Coal Technology*, 19: 36–50.
- Wu D P, Yue X Y, Wu C P. 2000. Application of neural network technology in coalbed gas logging evaluation[J]. *Fault Block Oil and Gas Fields*, 7(5): 48–49 (in Chinese with English abstract).
- Xu H, Tang D Z, Tao S, et al. 2024. Differences in geological conditions of deep and shallow coalbed methane and their formation mechanisms[J]. *Coal Geology & Exploration*, 52(2): 33–39 (in Chinese with English abstract).
- Yang, Y, Shao B, Wang, et al. 2015. Dynamic crushing mechanism of well-wall in engraving stage of sidetracking based on Lagrange explicit algorithm[J]. *Journal of Coal Society*, 40(7): 1491–1497 (in Chinese with English abstract).
- Zhang R, Liu S. 2017. Experimental and theoretical characterization of methane and CO₂ sorption hysteresis in coals based on Langmuir desorption[J]. *International Journal of Coal Geology*, 171: 49–60.

附中文参考文献

- 常闯, 李松, 汤达祯, 等. 2023. 基于测井参数的煤储层地应力计算方法研究——以延川南区块为例[J]. *煤田地质与勘探*, 51(5): 23–32.
- 陈世达, 侯伟, 汤达祯, 等. 2024. 煤储层含气性深度效应与成藏过程耦合关系[J]. *煤田地质与勘探*, 52(2): 52–59.
- 陈涛, 张占松, 周雪晴, 等. 2021. 基于测井参数优选的煤层含气量预测模型[J]. *煤田地质与勘探*, 49(3): 227–235.
- 冯鹏, 李松, 汤达祯, 等. 2022. 支持向量机在煤层地应力预测中的应用[J]. *现代地质*, 36(5): 1333–1340.
- 李丹丹, 王振国, 降文萍, 等. 2022. 基于测井参数的煤层含气量定量评价方法研究——以寿阳区块15煤为例[J]. *中国煤炭地质*, 34(8): 34–40.
- 林魂, 孙新毅, 宋西翔, 等. 2023. 基于改进人工神经网络的页岩气井产量预测模型研究[J]. *油气藏评价与开发*, 13(4): 467–473.
- 李琴, 刘永升, 黄志强, 等. 2016. PDC钻头切削破岩机理及数值模拟研究[J]. *机械科学与技术*, 35(2): 203–209.
- 刘晓. 2024. 不同压裂规模下煤储层缝网形态对比研究——以延川南煤层气田为例[J]. *油气藏评价与开发*, 14(3): 510–518.
- 李泽辰, 杜文凤, 胡进奎, 等. 2018. 鄂尔多斯盆地临兴区块测井含气量解释方法[J]. *煤炭学报*, 43(S2): 490–498.
- 孟召平, 田永东, 李国富. 2020. 煤层气开发地质学理论与方法[M]. 北京: 科学出版社.
- 孟召平, 田永东, 雷旸. 2008. 煤层含气量预测的BP神经网络模型与应用[J]. *中国矿业大学学报*, (4): 456–461.
- 秦瑞宝, 叶建平, 李利, 等. 2023. 基于机器学习的煤层含气量测井评价方法——以沁水盆地柿庄南区块为例[J]. *石油物探*, 62(1): 68–79.
- 谌丽, 王才志, 宁从前, 等. 2023. 基于机器学习的鄂尔多斯盆地陇东地区长7段岩相测井识别方法[J]. *油气藏评价与开发*, 13(4): 525–536.
- 王欣, 韩建强, 眭灵, 等. 2024. 苏北盆地溱潼凹陷阜宁组二段页岩油测井评价研究[J]. *油气藏评价与开发*, 14(3): 364–372.
- 吴东平, 岳晓燕, 吴春萍. 2000. 神经网络技术在煤层气测井评价中的应用[J]. *断块油气田*, 7(5): 48–49.
- 许浩, 汤达祯, 陶树, 等. 2024. 深、浅部煤层气地质条件差异性及其形成机制[J]. *煤田地质与勘探*, 52(2): 33–39.
- 杨勇, 邵兵, 王风锐, 等. 2015. 基于Lagrange显式算法的井壁侧钻过程动态破碎规律[J]. *煤炭学报*, 40(7): 1491–1497.