◀测井录井▶

doi:10.11911/syztjs.2022018

引用格式: 韩玉娇. 基于 AdaBoost 机器学习算法的大牛地气田储层流体智能识别 [J]. 石油钻探技术, 2022, 50(1): 112-118.

HAN Yujiao. Intelligent fluid identification based on the Adaboost machine learning algorithm for reservoirs in Daniudi Gas Field [J]. Petroleum Drilling Techniques, 2022, 50(1): 112-118.

基于 AdaBoost 机器学习算法的大牛地 气田储层流体智能识别

韩玉娇^{1,2}

(1. 页岩油气富集机理与有效开发国家重点实验室, 北京 102206; 2. 中国石化石油工程技术研究院, 北京 102206)

摘 要: 大牛地气田储层复杂, 矿物组分多样、储集空间复杂、非均质性强, 导致流体识别困难。为提高该气田复杂储层流体识别的准确率和解释效率, 以广泛发育的低阻气藏为主要研究对象, 采用 Adaboost 机器学习算法, 分别以逻辑分类、决策树等主流智能算法作为弱分类器, 集成了 4 类强分类器模型。基于低阻气藏成因机理分析优化了模型输入参数, 基于常规测井和试油、试采资料进行了参数优选, 并将上述模型应用到 6 口实际井资料中。结果显示, 其中以决策树为弱分类器集成的强分类器取得了最佳识别效果, 流体识别准确率达到 86.5%, F1 得分达到 86.6%。研究结果表明, 该方法可作为低阻气藏常规测井资料识别流体的有效手段, 为流体评价提供了新思路。

关键词: 复杂储层; 流体识别; 机器学习; 智能识别; 大牛地气田

中图分类号: TE927

文献标志码: A

文章编号: 1001-0890(2022)01-0112-07

Intelligent Fluid Identification Based on the AdaBoost Machine Learning Algorithm for Reservoirs in Daniudi Gas Field

HAN Yujiao^{1,2}

(1. State Key Laboratory of Shale Oil and Gas Enrichment Mechanisms and Effective Development, Beijing, 102206, China;
2. Sinopec Research Institute of Petroleum Engineering, Beijing, 102206, China)

Abstract: Complex reservoirs in Daniudi Gas Field are characterized by diverse mineral components, complex reservoir space, and strong heterogeneity, which make fluid identification difficult. To improve the accuracy rate and interpretation efficiency of fluid identification in complex reservoirs, Daniudi Gas Field, with its extensively developed low-resistance gas reservoirs, was taken as the main research object. Then, four strong classifier models were formed by the Adaboost machine learning algorithm with mainstream intelligent algorithms (such as logical classification and decision tree) as weak classifiers. The input parameters of the model were optimized based on the analysis of the genesis mechanism of the low-resistance gas reservoir, the parameters were optimized on the basis of conventional well logging, oil testing and production testing data, etc. The above model was applied to the data of 6 actual wells. The results showed that the strong classifier achieved the best identification effect by using the decision tree algorithm as the weak classifier, with the fluid identification accuracy of 86.5% and the F1 value up to 86.6%. The results indicates that this method is effective for identifying fluid with conventional logging data for low-resistance gas reservoirs, and providing new ideas for fluid evaluation.

Key words: complex reservoirs; fluid identification; machine learning; intelligent identification; Daniudi Gas Filed

收稿日期: 2021-09-07; 改回日期: 2022-12-27。

作者简介: 韩玉娇 (1990—), 女, 黑龙江哈尔滨人, 2013 年毕业于中国石油大学 (华东) 地质资源与地质工程专业, 2019 年获中国石油勘探开发研究院地质资源与地质工程专业博士学位, 助理研究员, 主要从事地球物理测井理论与方法、智能算法及软件开发方面的研究。E-mail: hanyj.sripe@sinopec.com。

基金项目: 国家重点研发计划项目“井筒稳定性闭环响应机制与智能调控方法”(编号: 2019YFA0708303)、国家自然科学基金项目“海相深层油气富集机理与关键工程技术基础研究”(编号: U19B6003)、中国石化科技攻关项目“超高温高压测井仪器及测量系统研发”(编号: P21081-4)联合资助。

随着勘探开发对象日益复杂, 钻遇复杂储层的概率增大, 油(气)水关系复杂程度日益升高, 流体准确识别难度不断增大^[1-2]。核磁共振测井、成像测井等特殊测井技术能够提供更丰富的参数信息, 有利于流体识别, 但考虑到勘探成本, 特殊测井技术尚不能广泛应用于生产, 基于常规测井资料评价流体性质仍然是研究热点^[3-5]。此外, 复杂储层通常岩性多变、孔隙结构复杂, 同时伴有较强的非均质性, 导致常规测井数据受多因素影响, 其响应特征与流体性质之间存在多解性^[5]。对于复杂储层, 传统解释方法建立的流体线性识别模型通常识别准确率较低, 难以满足生产需要。在实际评价过程中, 为提高流体识别的准确率, 常需要对大量数据进行深入分析, 建立多类图版^[5-8], 但该方法解释效率低、主观性强, 且专业背景门槛高。

近年来, 人工智能兴起, 为解决此类问题提供了新思路。相比于传统测井评价方法, 人工智能具有处理数据信息量大、维度多、重视数据间关联性, 可实时高效交互动态分析, 同时保留测井专家的解释经验等优势。因此, 机器学习逐渐成为储层评价研究的热点^[9-11]。周雪晴等人^[12]应用双向长短期记忆网络(Bi-LSTM)建立了碳酸盐岩储层流体高精度识别模型。张银德等人^[13]结合测井和试采资料, 利用支持向量机方法准确识别了油、气和水层。C.Onwuchekwa^[14]对比了 K 临近、随机森林、支持向量机等 6 种智能算法在尼日尔三角洲 296 个油藏流体性质评估中的应用效果。王少龙等人^[15]实现了 BP 神经网络在储层流体中的信息自动化识别。周凡等人^[16]采用支持向量机算法, 建立了基于阵列感应测井数据的流体识别方法。谭茂金等人^[17]采用了 BP 神经网络、概率神经网络、决策树分类器等多种智能算法构建了分类委员会机器和回归委员会机器, 实现了储层流体的识别和储层参数的预测。上述方法在不同研究区具有一定的应用效果, 但仍存在一定的局限性: 在分类较多时, 决策树法的错误率较高; 神经网络方法中常用的是 BP 网络, 但对于最优参数和最优网络结构的确定尚无十分有效的解决方法, 如果训练样本过少, 容易出现过拟合问题, 导致准确率下降; 支持向量机算法在实际应用中, 经常遇到不平衡数据集或高精度要求等问题^[18]。

因此, 为更全面地挖掘学习算法能力, 保证稳定的学习性能, 笔者以大牛地气田低阻气藏这一具有代表性的复杂储层为研究对象, 将 AdaBoost

(adaptive boosting)算法应用于低阻气层的流体评价中, 基于地质成因优化了模型输入参数, 对不同基本分类器集成的机器学习算法进行了评价和优选, 以提高复杂储层流体识别的准确率和解释效率。

1 方法原理

AdaBoost 算法属 boosting 算法族, 其预测精准、算法简单, 在诸多领域都有成功应用, 尤其在处理分类问题和模式识别方面更为突出^[19-21]。其核心思想是通过调整样本分布和弱分类器权值, 自动从弱分类器空间中筛选出若干关键弱分类器, 集成为一个分类精度高的强分类器, 从而打破分类器在已有样本分布上的优势, 提高机器学习的泛化能力。

AdaBoost 算法迭代通过改变训练集中各样本的权重实现, 根据每次训练集中各样本是否分类正确及上次总体分类的准确率, 综合确定各样本的权重, 将修改过权重的新数据集送给下层分类器进行训练, 并将每次训练所得分类器融合起来, 形成最终的决策分类器(见图 1)。其具体流程如下:

图 1 Adaboost 算法基本思路

Fig.1 Basic flow of the AdaBoost algorithm

1) 确定一个弱学习算法和训练集: $\{(x_1, y_1), \dots, (x_n, y_n)\}$, $x_1 \in X$, $y_1 \in Y = \{-1, +1\}$, X 和 Y 表示某个域或实例空间。

2) 初始化样本训练集的权重分布。赋予各训练样本相同的初始权重, 即 $w_i = 1/n$, 则样本集的初始权重分布为:

$$D_1 = (w_1, w_2, \dots, w_n) = \left(\frac{1}{n}, \dots, \frac{1}{n} \right) \quad (1)$$

式中: D_1 为训练样本集的初始权重; $w_1, w_2, \dots, w_n$ 分别为每一个样本的初始权重; n 为训练集样本数量。

3) 使用带权重的样本训练集学习, 选取使误差率最低的阈值设计基本分类器, 得到基本分类器 $h_m(x)$:

$$h_m(x) : x \rightarrow \{-1, +1\} \quad m = 1, 2, \dots, T \quad (2)$$

样本训练集的分类误差率为:

$$e_m = \sum_{i=1}^n w_i^{(m)} [h_m(x_i) \neq y_i] \quad (3)$$

4) 弱分类器的权重为:

$$\alpha_m = L_T \left(\ln \frac{1 - e_m}{e_m} + \ln(R - 1) \right) \quad (4)$$

式中: L_T 为学习率; R 为分类数量。

弱分类器的误差率越低, 权重就会越大。

5) 更新样本的权重:

$$w_i^T = \frac{w_i^{T-1} \exp(\alpha_T F)}{Z_T} \quad (5)$$

其中, Z_T 为归一化因子, 其计算公式为:

$$Z_T = \sum_{i=1}^m w_i^T \quad (6)$$

采用 F 条件代表弱分类器的预测结果。如预测值和真实值相同, 即预测正确, 则 $F=0$, 代入式(6)后权重相对变小或不变。如预测值和真实值不同, 则预测错误, 此时 $F=1$, 代入式(6)后权重增大。因此, 可根据样本权重判断预测结果的准确性, 若样本权重增大, 则弱分类器预测错误, 此样本需要被其他弱分类器重点关注。

6) 将所有弱分类器用下式加权求和:

$$f(x) = \sum_{m=1}^T \alpha_m h_m(x) \quad (7)$$

得到最终分类器为:

$$H(x) = \text{sign}(f(x)) = \text{sign} \left(\sum_{m=1}^T \alpha_m h_m(x) \right) \quad (8)$$

式中: T 为迭代次数; α_m 为弱分类器的权重。

2 流体识别难点及主控因素

大牛地气田位于鄂尔多斯盆地伊陕斜坡北部东段, 局部构造不发育, 气田中高阻气层与低阻气层并存, 其中低阻气藏在上古生界广泛发育^[22-23]。上古生界典型流体参数见表1。从表1可以看出, 水层电阻率分布在 14.37~17.92 $\Omega \cdot \text{m}$, 电阻增大率为 0.96~1.23。低阻气层电阻率为 26.84~30.37 $\Omega \cdot \text{m}$, 电阻增大率为 1.79~2.02, 其不足水层电阻增大率的 3 倍。大量试气结果表明, 低阻气层也可形成高产, 如 2526~2556 m 井段, 试气无阻流量为 27 000 m^3/d , 不产水, 显示出良好的产能。

表 1 大牛地气田上古生界典型流体参数

Table 1 Typical fluid parameters of the Upper Paleozoic in Daniudi Gas Field

井名	层位	井段/m	孔隙度, %	电阻率/($\Omega \cdot \text{m}$)	电阻增大率	产水量/ m^3	无阻流量/ ($10^4 \text{m}^3 \cdot \text{d}^{-1}$)	解释结论
X1	盒3	2219.6~2226.0	10.79	14.40	0.96	6.20	0	水层
X2	盒3	2605.4~2617.0	9.72	18.50	1.23	0.50	0	水层
	盒1	2526.1~2534.0	11.43	30.40	2.02			
X3	盒1	2535.5~2541.8	10.39	28.10	1.87	0	2.70	低阻气层
	山2	2543.9~2556.1	11.75	26.80	1.79			
X4	山2	2741.8~2752.0	11.12	37.50	2.53	0	2.06	低阻气层
X5	盒3	2697.1~2703.6	8.58	324.30	21.62	0	16.51	中高阻气层
X6	山2	2462.0~2478.4	6.69	66.89	4.46			
X7	山2	2486.0~2497.0	8.50	80.49	5.37	0	0.96	中高阻气层
X8	山1	2852.1~2858.9	9.64	17.92	1.19	6.34	2.50	含气水层
X9	盒3	2472.3~2479.3	11.92	16.33	1.09	3.72	微	含气水层

上古生界不同流体储层的电阻率和声波时差交会图见图2。由图2可知, 该区电性复杂, 不同流体测井响应差异不明显, 仅依靠传统电阻率方法将低估或遗漏低阻气层, 难以准确识别流体。

考虑到训练数据对智能模型的评价效果有较

大影响, 首先对低阻气层的成因进行分析, 选取对流体性质敏感的参数作为训练样本, 优化模型输入参数。深入分析相关地质、录井、岩心及试油资料, 得出大牛地气田上古生界低阻气层的主要成因为:

图 2 大牛地气田上古生界流体识别交会图

Fig. 2 Cross plot for fluid identification of the Upper Paleozoic in Daniudi Gas Field

- 1) 储层孔隙结构复杂, 相比于高阻气层以大孔为主, 低阻气层微孔普遍较为发育导致束缚水饱和度增大, 气层电阻率降低, 形成低阻气层。
- 2) 岩性变细、泥质与黏土所产生的附加导电作用导致形成低阻气层。
- 3) 微裂缝发育导致钻井液滤液侵入并驱替井壁附近岩石中的天然气, 使气层电阻率明显降低。
- 4) 储层沉积、成藏中后期地层水活动, 造成气、水层矿化度差异, 导致形成低阻气层。

3 流体识别模型

3.1 训练集与测试样本

孔隙结构复杂、岩石颗粒粒度小等因素导致束缚水饱和度高, 大量微孔导电, 这是形成低阻气层的主导因素。因此, 将对低阻油藏流体识别敏感的束缚水饱和度参数作为模型输入参数, 可提高模型

训练效果。对于导电矿物、钻井液侵入等其他低阻成因, 尝试利用智能算法从测井曲线中提取敏感参数, 实现对流体更好的表征。结合核磁共振、压汞和相渗等资料获得了大牛地气田上古生界束缚水饱和度和, 观察其与孔隙度的交会图(见图 3)可见, 采用幂函数的拟合趋势较符合实际地层含油气趋势, 拟合得到的经验公式为:

图 3 大牛地气田上古生界束缚水饱和度和孔隙度交会图
Fig.3 Cross plot of irreducible water saturation and porosity of the Upper Paleozoic in Daniudi Gas Field

$$S_{wi} = 175.24\phi^{0.6552} \quad (9)$$

式中: S_{wi} 为束缚水饱和度, %; ϕ 为孔隙度, %。

采用式(9)计算了研究区 26 口重点井的束缚水饱和度, 选取与流体性质相关性较高的 5 条测井曲线: 自然伽马 (GR)、自然电位 (SP)、声波时差 (AC)、密度 (DEN) 和深侧向电阻率 (RLLD) 曲线和 1 个解释参数 (孔隙度 (POR)) 作为模型输入参数, 共选取 397 个层累计 10342 个样本点, 不同流体储层测井响应特征值分布见表 2。

表 2 4 类储层的常规测井响应值分布

Table 2 Distribution of conventional log response eigenvalues of four types of reservoirs

储层类型	测井响应值	自然伽马/API	中子, %	密度/(g·cm ⁻³)	声波时差(μs·m ⁻¹)	深电阻率/(Ω·m)	孔隙度, %	束缚水饱和度, %
中高阻气层	范围	40.7~78.6	15.1~17.3	2.30~2.48	197.8~242.2	41.8~445.1	8.4~17.4	26.9~43.4
	均值	58.9	16.4	2.41	218.7	112.7	15.3	29.3
低阻气层	范围	44.2~73.8	8.4~14.2	2.33~2.53	214.2~263.8	16.7~46.1	6.7~12.4	33.79~50.4
	均值	63.4	11.8	2.44	242.5	29.1	10.1	38.5
含气水层	范围	44.6~74.3	11.7~16.1	2.42~2.49	222.2~249.7	10.7~31.8	6.3~15.4	29.2~52.4
	均值	62.3	13.9	2.45	236.5	21.1	11.3	35.8
水层	范围	46.3~84.5	6.3~13.4	2.40~2.54	205.2~262.8	10.5~28.2	5.2~14.6	30.25~59.5
	均值	68.6	9.9	2.46	238.8	15.8	9.2	40.9

不同测井其特征取值范围不同, 如某一特征的特征方差远大于其他特征的特征方差, 它将会在算法学习中占据主导位置, 导致学习器不能按期望学习其他特征, 这将导致最后模型收敛速度慢甚至不收敛, 因

此, 需要对此类特征数据进行标准化, 处理公式为:

$$Z = \frac{x-\mu}{\sigma} \quad (10)$$

式中: x 为特定测井特征值; Z 为标准化后的测井特征值;

μ 为所有特征样本的均值; σ 为所有特征样本的标准差。

经处理后的数据符合标准正态分布, 即均值为 0, 标准差为 1。综合专家解释结论和试油试采结果, 将中高阻气层、低阻气层、含气水层和水层等 4 类储层分别特征标注为 1、2、3 和 4。选取全部样本的 70% 作为数据集建立流体识别模型, 剩余 30% 作为验证集验证模型效果。

3.2 储层流体识别模型与实例验证

AdaBoost 模型主要对基本分类器进行集成, 结合不同基本分类器的原理差异, 选取逻辑回归、决策树、支持向量机和人工神经网络 4 种基本分类器。利用数据集样本对模型不断迭代优化, 最终确定各监督模型的最优参数值(见表 3)。

表 3 4 个监督模型的重要参数和最优参数值

Table 3 Important parameters and their optimal values of four supervision models

机器学习模型	优化参数	搜索范围	最优参数
逻辑回归(LR)	正则化策略	11/12	12
	惩罚参数 C	0.1~10	1.693
决策树(DT)	树的最大深度	基尼系数 / 信息熵	信息熵
	特征选择准则	0~10	3
支持向量机(SVM)	核函数的 γ 参数	0.1~10	2.015
	惩罚参数 C	0.1~100	15
神经网络(NN)	最大层数	3~8	4
	最大隐层数量	10~200	100

采用预测准确率和 F1 得分 2 参数评估算法模型效果。其中 F1 得分为精确率和召回率的调和平均, 当精确率和召回率发生冲突时, 可利用 F1 得分综合评价分类模型的效果。训练结束后, 采用验证集数据验证模型效果, 结果见图 4 和表 4 所示。由图 4 和表 4 可知, 基于 Adaboost 算法将弱分类器联级成强分类器, 其预测准确率较单一分类器有明显提升。但基本分类器的选取对算法准确率有较大影响, 其中以决策树为基本分类器集成的强分类器的预测准确率达 86.5%, 预测效果最好, F1 得分最高。

表 4 不同模型的流体识别结果

Table 4 Fluid identification results from different models

试油试采结果	总层数/个	AB-LR模型		AB-DT模型		AB-SVC模型		AB-NN模型	
		正确样本/个	符合率, %	正确样本/个	符合率, %	正确样本/个	符合率, %	正确样本/个	符合率, %
中高阻气层	23	23	100	23	100	23	100	23	100
低阻气层	38	26	68.4	31	81.6	28	73.7	23	78.9
含气水层	28	17	60.7	23	82.1	21	75.0	30	78.6
水层	30	23	76.7	26	86.7	24	80.0	22	76.7

图 4 不同模型的预测准确率与 F1 得分

Fig.4 Prediction accuracy and F1 value of different models

以研究区 X1 井和 X2 井为例, 说明以决策树为基本分类器的强分类器模型(AB-DT)的流体识别结果(见图 5)。X1 井所示层段孔隙度为 8%~15%, 上部 11 号层电阻率均值约为 90 $\Omega \cdot m$, 为典型高阻气层, 智能模型识别和专家结论均为气层; 下部井段自然电位呈负异常, 电阻率为 30~40 $\Omega \cdot m$, 为低阻-高孔储层, 12 号、13 号层束缚水饱和度均较高, 约 70%, 智能模型识别结果为低阻气层, 试气结果显示不产水, 产气量为 14200 m^3/d , 与智能模型识别结果一致。X2 井所示层段孔隙度为 5%~9%, 物性相对较差, 电阻率均值约 200 $\Omega \cdot m$, 该井 2771.0~2786.0 m 井段多层合试, 产气量 5800 m^3/d , 产水量 23000 m^3/d 。4 号、5 号层智能模型识别结果为含气水层, 与专家解释结论和试油结果均较为一致, 模型应用效果较好。

4 结论与建议

1) 结合研究区储层流体性质识别难点与主控因素, 优化模型输入参数, 采用 Adaboost 迭代算法联级弱分类器, 可提高机器学习模型的预测准确度。

2) 针对大牛地气田低阻气藏流体识别问题, 以决策树作为弱分类器集成的强分类器取得了最佳识别效果, 平均识别准确率高达 86.5%, 展现了机器学习

图 5 最优智能模型流体识别效果

Fig.5 Fluid identification results from the optimal intelligent model

习等智能算法在提高储层评价效率和解释符合率方面的潜力。

3) 目前测井行业的人工智能主要以数据为驱动, 在今后的研究中, 除攻关算法外, 还应深入分析评价难题的成因机理, 优选模型输入参数, 同时加强测井知识图谱和专家经验库的建立, 注重多源多尺度信息的融合, 建立地质成因约束下的智能模型。

参 考 文 献

References

[1] 张海涛, 郭笑锴, 杨小明, 等. 姬塬地区低对比度油层成因机理与流体识别方法 [J]. 测井技术, 2019, 43(5): 542-549.
ZHANG Haitao, GUO Xiaokai, YANG Xiaoming, et al. Genesis mechanism and fluid identification of low contrast reservoirs in Jiyuan area[J]. Well Logging Technology, 2019, 43(5): 542-549.

[2] 张峰, 罗少成, 李震, 等. 四川盆地茅口组岩溶缝洞型储层有效性测井评价 [J]. 石油钻探技术, 2020, 48(6): 116-122.
ZHANG Feng, LUO Shaocheng, LI Zhen, et al. Logging evaluation

on the effectiveness of karst fractured-vuggy reservoirs in the Maokou Formation, Sichuan Basin[J]. *Petroleum Drilling Techniques*, 2020, 48(6): 116-122.

[3] 张丛秀, 郝晋美, 刘治恒, 等. 基于测录井资料的环西—彭阳地区延安组储层流体性质识别方法研究 [J]. *石油钻探技术*, 2020, 48(5): 111-119.
ZHANG Congxiu, HAO Jinmei, LIU Zhiheng, et al. A study on the logging-based identification method for reservoir fluid properties of the Yan'an Formation in the Huanxi-Pengyang[J]. *Petroleum Drilling Techniques*, 2020, 48(5): 111-119.

[4] 陈四平, 谭判, 石文睿, 等. 涪陵页岩气优质储层测井综合评价方法 [J]. *石油钻探技术*, 2020, 48(4): 131-138.
CHEN Siping, TAN Pan, SHI Wenrui, et al. A comprehensive logging evaluation method for high quality shale gas reservoirs in Fuling[J]. *Petroleum Drilling Techniques*, 2020, 48(4): 131-138.

[5] 李义, 周全, 张伟. 陆丰凹陷文昌组储层流体性质识别方法研究 [J]. *海洋石油*, 2020, 40(1): 70-73.
LI Yi, ZHOU Quan, ZHANG Wei. Study on identification method of reservoir fluid properties of Wenchang Formation in Lufeng Sunken[J]. *Offshore Oil*, 2020, 40(1): 70-73.

- [6] 张艺, 李道清, 仇鹏, 等. 基于岩性分类的火山岩储层流体识别方法: 以克拉美丽气田石炭系火山岩为例 [J]. 西安石油大学学报(自然科学版), 2020, 35(6): 22-29.
ZHANG Yi, LI Daoqing, QIU Peng, et al. Study on fluid identification method of volcanic reservoir based on lithology classification: a case study of carboniferous volcanic rocks in Kelamei Gasfield[J]. Journal of Xi'an Shiyu University(Natural Science), 2020, 35(6): 22-29.
- [7] 王月莲, 袁士义, 宋新民, 等. “无侵线法”流体识别技术在低渗透低电阻率油藏中的应用 [J]. 石油勘探与开发, 2005, 32(3): 88-90.
WANG Yuelian, YUAN Shiyi, SONG Xinmin, et al. Non-intrusion line method for fluid identification and its application in low permeability and low resistivity reservoirs[J]. *Petroleum Exploration & Development*, 2005, 32(3): 88-90.
- [8] 孙卫涛, 熊繁升, 曹宏, 等. 致密储层复杂流体模型及其适用性分析 [J]. 石油物探, 2021, 60(1): 136-148.
SUN Weitao, XIONG Fansheng, CAO Hong, et al. Analysis of complex fluid model and its applicability in tight reservoirs[J]. *Geophysical Prospecting for Petroleum*, 2021, 60(1): 136-148.
- [9] WU P Y, JAIN V, KULKARNI M S, et al. Machine learning-based method for automated well-log processing and interpretation [R]. SEG-2018-2996973, 2018.
- [10] 程超, 李培彦, 陈雁, 等. 基于机器学习的储层测井评价研究进展 [J/OL]. 地球物理学进展: 1-15. (2021-05-31)[2021-09-06]. <http://kns.cnki.net/kcms/detail/11.2982.P.20210529.1525.014.html>.
CHENG Chao, LI Peiyan, CHEN Yan, et al. Research progress of reservoir logging evaluation based on machine learning[J/OL]. *Progress in Geophysics*: 1-15. (2021-05-31)[2021-09-06]. <http://kns.cnki.net/kcms/detail/11.2982.P.20210529.1525.014.html>.
- [11] 孙挺, 赵颖, 杨进, 等. 基于支持向量机的钻井工况实时智能识别方法 [J]. 石油钻探技术, 2019, 47(5): 28-33.
SUN Ting, ZHAO Ying, YANG Jin, et al. Real-time intelligent identification method under drilling conditions based on support vector machine[J]. *Petroleum Drilling Techniques*, 2019, 47(5): 28-33.
- [12] 周雪晴, 张占松, 朱林奇, 等. 基于双向长短期记忆网络的流体高精度识别新方法 [J]. 中国石油大学学报(自然科学版), 2021, 45(1): 69-76.
ZHOU Xueqing, ZHANG Zhansong, ZHU Linqi, et al. A new method for high-precision fluid identification in bidirectional long short-term memory network[J]. *Journal of China University of Petroleum(Edition of Natural Science)*, 2021, 45(1): 69-76.
- [13] 张银德, 童凯军, 郑军, 等. 支持向量机方法在低阻油层流体识别中的应用 [J]. 石油物探, 2008, 47(3): 306-310, 314.
ZHANG Yinde, TONG Kaijun, ZHENG Jun, et al. Application of support vector machine method for identifying fluid in low-resistivity oil layers[J]. *Geophysical Prospecting for Petroleum*, 2008, 47(3): 306-310, 314.
- [14] ONWUCHEKWA C. Application of machine learning ideas to reservoir fluid properties estimation[R]. SPE 193461, 2018.
- [15] 王少龙, 杨斌, 赵倩, 等. BP神经网络在复杂储层流体识别中的应用 [J]. 石油化工应用, 2018, 37(7): 45-48.
WANG Shaolong, YANG Bin, ZHAO Qian, et al. Application of BP neural network in recognition of complex reservoir fluids[J]. *Petrochemical Industry Application*, 2018, 37(7): 45-48.
- [16] 周凡, 姜洪福, 王立艳, 等. 基于阵列感应测井的支持向量机流体识别方法 [J]. 中国海洋大学学报(自然科学版), 2011, 41(增刊1): 317-323.
ZHOU Fan, JIANG Hongfu, WANG Liyan, et al. Application of array induction logging and support vector machine to fluid identification[J]. *Periodical of Ocean University of China*, 2011, 41(supplement1): 317-323.
- [17] 谭茂金, 白洋, 王谦, 等. 当非常规油气遇到人工智能: 多源数据驱动下非常规油气测井智能解释方法研究进展 [C]//2019年油气地球物理学学术年会论文集, 南京: 中国地球物理学会油气地球物理专业委员会, 2019: 615.
TAN Maojin, BAI Yang, WANG Qian, et al. When unconventional oil and gas encounter artificial intelligence-the research progress of intelligent interpretation methods for unconventional oil and gas logging driven by multi-source data[C]//Proceedings of 2019 Annual Academic Conference on Oil and Gas Geophysics, Nanjing: Professional Committee of Oil and Gas Geophysics of China Geophysical Society, 2019: 615.
- [18] 张晓龙, 任芳. 支持向量机与AdaBoost的结合算法研究 [J]. 计算机应用研究, 2009, 26(1): 77-78.
ZHANG Xiaolong, REN Fang. Study on combinability of SVM and AdaBoost algorithm[J]. *Application Research of Computers*, 2009, 26(1): 77-78.
- [19] SCHAPIRE R E. The boosting approach to machine learning: an overview[M]//DENISON D D, HANSEN M H, HOLMES C C, et al. *Nonlinear estimation and classification*. New York: Springer, 2002: 149-171.
- [20] 曹莹, 苗启广, 刘家辰, 等. AdaBoost算法研究进展与展望 [J]. 自动化学报, 2013, 39(6): 745-758.
CAO Ying, MIAO Qiguang, LIU Jiachen, et al. Advance and prospects of AdaBoost algorithm[J]. *Acta Automatica Sinica*, 2013, 39(6): 745-758.
- [21] 杨笑, 王志章, 周子勇, 等. 基于参数优化AdaBoost算法的酸性火山岩岩性分类 [J]. 石油学报, 2019, 40(4): 457-467.
YANG Xiao, WANG Zhizhang, ZHOU Ziyong, et al. Lithology classification of acidic volcanic rocks based on parameter-optimized AdaBoost algorithm[J]. *Acta Petrolei Sinica*, 2019, 40(4): 457-467.
- [22] 张郁哲, 程时清, 史文洋, 等. 多层合采并产量劈分方法及在大牛地气田的应用 [J]. 石油钻采工艺, 2019, 41(5): 624-629.
ZHANG Yuzhe, CHENG Shiqing, SHI Wenyang, et al. Commingled producing well production split method and its application in Daniudi Gasfield[J]. *Oil Drilling & Production Technology*, 2019, 41(5): 624-629.
- [23] 郭振华, 赵彦超. 大牛地气田致密砂岩气藏低阻气层成因分析 [J]. 石油天然气学报, 2007, 29(3): 246-249, 512-513.
GUO Zhenhua, ZHAO Yanchao. Genetic analysis on low-resistivity gas zones of tight sandstone reservoirs in Daniudi Gas Field[J]. *Journal of Oil and Gas Technology*, 2007, 29(3): 246-249, 512-513.