

王新领,祝新益,张宏兵,等. 基于随机树嵌入的随钻测井岩性识别方法. 吉林大学学报(地球科学版), 2024, 54(2): 701-708. doi:10.13278/j.cnki.jjuese.20230193.

Wang Xinling, Zhu Xinyi, Zhang Hongbing, et al. Lithology Identification Method for Logging While Drilling Based on Random Tree Embedding. Journal of Jilin University (Earth Science Edition), 2024, 54 (2): 701 - 708. doi:10.13278/j.cnki. jjuese.20230193.

基于随机树嵌入的随钻测井岩性识别方法

王新领¹, 祝新益², 张宏兵², 孙博¹, 许可欣²

1. 中海油田服务股份有限公司物探事业部物探研究院特普数据中心(湛江), 广东 湛江 524057

2. 河海大学地球科学与工程学院, 南京 211098

摘要: 岩性识别是储层评价中的一项重要工作。随着机器学习方法的不断发展, 岩性的智能识别也成为热门研究方向。随钻测井技术目前已经得到了广泛的应用, 但是受限于高温高压的钻井作业条件, 随钻测井仪器只能测得少量测井参数。由于随钻测井参数较少, 直接输入机器学习模型无法充分挖掘其中的信息。对此, 本文将随机树嵌入引入随钻测井资料的岩性识别。该方法将低维随钻测井数据通过二叉树编码并转化为高维稀疏特征, 利用升维后的数据进行训练从而提升机器学习模型的判别能力。对比实验结果表明, 使用随机树嵌入的随机森林方法具有最佳的识别效果, 准确率和 F_1 值较直接使用随机森林分别提升了 3.16% 和 3.25%, 且优于梯度提升树、极随机树和粒子群优化支持向量机算法。

关键词: 机器学习; 随机树嵌入; 随机森林; 岩性识别; 随钻测井

doi: 10.13278/j.cnki.jjuese.20230193

中图分类号: TE121

文献标志码: A

Lithology Identification Method for Logging While Drilling Based on Random Tree Embedding

Wang Xinling¹, Zhu Xinyi², Zhang Hongbing², Sun Bo¹, Xu Kexin²

1. Data Processing Center (Zhan Jiang), COSL Geophysical R&D Institute, Zhanjiang 524057, Guangdong, China

2. School of Earth Science and Engineering, Hohai University, Nanjing 211098, China

Abstract: Lithology identification is an important task in reservoir evaluation. With the development of machine learning methods, intelligent lithology identification has become a popular research direction. Logging while drilling (LWD) technology has been widely used. However, in the actual production process, due to the high-temperature and high-pressure operating conditions, only a few logging parameters can be measured by LWD. Due to the small number of logging parameters, machine learning

收稿日期: 2023-08-09

作者简介: 王新领(1981—), 男, 硕士研究生, 工程师, 主要从事地震资料处理及解释方法方面的研究, E-mail: wangxinl@cosl.com.cn

通信作者: 祝新益(1999—), 男, 硕士研究生, 主要从事机器学习和测井解释方面的研究, E-mail: 211309080034@hhu.edu.com

基金项目: 国家自然科学基金项目(41374116); 国家级大学生创新创业训练计划项目(202310294028Z)

Supported by the National Natural Science Foundation of China (41374116) and the National Undergraduate Innovation and Entrepreneurship Training Program of China (202310294028Z)

model is not able to fully tap into the few parameters. To solve this problem, this paper introduced random tree embedding into LWD lithology identification. The low dimensional LWD data was encoded by the binary tree and transformed into high dimensional sparse features, and the upgraded data was used for training to improve the discriminative ability of the machine learning model. The comparative experiment results in this paper show that the random forest method with random tree embedding has the best recognition effect, the accuracy and F_1 value are improved by 3.16% and 3.25% respectively, compared with the direct use of random forest, and outperforms the gradient boosted tree, extremely random tree and particle swarm optimization support vector machine algorithms.

Key words: machine learning; random tree embedding; random forest; lithology identification; logging while drilling

0 引言

岩性识别是储层评价和地质建模的一项基础性工作,对油藏描述和油气勘察具有重要意义^[1-3]。传统岩性识别方法主要通过测井交会图结合专家经验进行,而随着人工智能技术的发展,岩性智能识别成为趋势^[4-5]。测井曲线中包含丰富的地质信息,以测井参数为输入,多种机器学习方法已经被应用于测井岩性识别工作并取得很好的识别效果^[6-8]。瞿晓婷等^[9]利用多层反向传播神经网络在复杂储层岩性识别方面取得了较好的应用效果;孙岩^[10]利用改进最邻近分类算法有效提高了潜山岩性识别精度;徐晗等^[11]使用随机森林(random forest, RF)算法进行了非开挖实时钻井条件下的地层岩性识别;Han等^[12]提出了多标签数据增广级联森林,构建了有效预测火成岩岩性、岩相和储层流体的多标签预测模型。

随钻测井在钻井过程中实时测量地层的测井参数。随钻测井技术可以减少泥浆侵入对测井参数的影响,并且可以指导地质导向,进行储层实时评价^[13-14]。但是由于高温高压的复杂井下钻井条件,且随钻测井仪器受钻铤限制,所以通常只能测得少量关键的测井参数^[15]。对比传统岩性识别使用的常规测井数据,随钻测井数据参数少,直接使用机器学习方法难以深入挖掘测井参数与岩性之间的非线性响应关系,测井参数的特征工程研究亟需展开。目前,针对测井参数方面的研究也有很多进展:Ren等^[16]使用主成分分析和改进模糊决策树进行了岩性识别研究;Wang等^[17]使用线性判别分析辅助神经网络进行成岩相预测。但是上述方法的研究对象都是常规测井数据,且方法都是进行降维操作,无法有效应用于随钻测井岩性识别任务。

针对上述问题,本文提出了一种基于随机树嵌入(random tree embedding, RTE)的随钻测井岩性识别方法。RTE^[18]使用二叉树对低维数据进行重新编码,完成无监督的特征转换,将低维数据映射至高维稀疏的特征空间,有利于分类模型的进一步判断。具有相似思路的支持向量机(support vector machine, SVM)算法^[19-20]使用核函数将数据映射至高维空间并寻找最佳分割平面。本文对比了使用RTE前后的RF算法、梯度提升树算法(gradient boosting decision trees, GBDT)和极随机树(extremely randomized trees, ET)算法,以及粒子群优化(particle swarm optimization, PSO)的SVM(PSO-SVM)算法,以证明RTE使用低维测井数据进行岩性识别的有效性,为随钻测井岩性识别的实际生产应用提供新思路。

1 研究方法

1.1 随机森林与极随机树

RF和ET都是基于决策树的集成算法^[21-22],都由一系列决策树构成,准确性高且泛化能力强,在包括岩性识别的各研究领域已经得到了广泛的应用。

RF使用bootstrap采样方法,有放回地采样并不断构建大量子集,并在子集中训练决策树,使得决策树之间是多样的,以保证RF模型具有较强的泛化能力。首先,构造一棵分类与回归树(classification and regression tree, CART),以最佳Gini指数进行叶节点的分割并不断生长。Gini指数(C_G)的计算如下:

$$C_G = \sum_{k=1}^K p_k (1 - p_k) = 1 - \sum_{k=1}^K p_k^2 \quad (1)$$

式中: K 为样本类别数; p_k 为样本属于第 k 类的概率。

ET具有更强的随机性,不进行随机采样和最

佳分裂点选择,而是随机选择特征进行划分,构建更大规模的基分类器以减小方差。

最终,训练得到的所有决策树的预测结果以投票的形式输出。通过对弱学习器(单一决策树)的集成,强学习器可以获得更加优秀的性能^[22]。

1.2 梯度提升树

GBDT^[23]是基于 Boosting 和 CART 的集成算法。与 Bagging 策略不同的是,Boosting 的基模型间存在联系。在层级训练过程中,每一层的基模型都会对前一层的错分样本赋予更高权重。令样本为 $\{x_i, y_i\} (i=1, 2, \dots, n)$, 迭代次数为 M 。GBDT 的关键是使用损失函数的负梯度拟合残差,常用的损失函数为对数似然损失函数:

$$L[y_i, F(x_i)] = \log\{1 + \exp[-y_i F(x_i)]\}。 \quad (2)$$

式中, $F(x_i)$ 为基决策树。对于第 m 次迭代,损失函数负梯度 r_{mi} 表示为

$$r_{mi} = - \left\{ \frac{\partial L[y_i, F_{m-1}(x_i)]}{\partial F_{m-1}(x_i)} \right\}_{F(x)=F_{m-1}(x)}。 \quad (3)$$

式中, $F_{m-1}(x_i)$ 为第 $m-1$ 次迭代得到的分类器。利用 r_{mi} 拟合一颗决策树,求得拟合最好的输出 c_i 使损失函数最小:

$$c_i = \operatorname{argmin} \sum_{i=1}^n L[y_i, F_{m-1}(x_i)]。 \quad (4)$$

最终得到的强学习器 $F_M(x)$ 表达式如下:

$$F_M(x) = F_{M-1}(x) + \alpha c_i。 \quad (5)$$

式中, α 为学习率。

1.3 粒子群优化的支持向量机

SVM 的目的是寻找一个最优超平面进行样本划分,所以本质上是一种二分类算法。目前,多分类 SVM 常采用“一对一”或者“一对多”的策略进行多类别分类。SVM 算法定义的函数距离 ξ 为

$$\xi = y_i (\omega^T x_i + b)。 \quad (6)$$

式中: ω 为超平面法向量; b 为标量偏差。为求得最佳分离平面,将求解转化为优化数学模型:

$$\min \frac{1}{2} \|\omega\|^2 \quad \text{s.t.}$$

$$y_i (\omega^T x_i + b) \geq 1, i=1, 2, \dots, n。 \quad (7)$$

SVM 对超参数敏感,特别是惩罚参数 C 和核函数参数 γ ,故确定最优超参数是获得优秀分类性能的关键。

PSO 是一种成熟的智能优化算法,采用模拟鸟类捕食的方式,每一个粒子表示一个可能解并对应

适应值。随着粒子速度和位置的更新,适应值同时更新,并获得个体极值和群体极值,即最优解位置。使用 PSO-SVM 是一种成熟稳定的参数优化策略,可以使得算法获得更高的分类性能。

1.4 随机树嵌入

RTE 是一种无监督的特征转换方法,通过二叉树编码将原本低维非线性特征映射至高维稀疏空间以改善分类器性能。与 RF 相似,使用 bootstrap 采样构建子集,并训练一系列无监督的二叉树索引。对于每一个样本实例,都可以表示为每棵二叉树叶节点的索引,RTE 索引过程如图 1 所示。最终,将索引编码进行拼接,转化得到稀疏高维的新特征。在完成所有样本的索引编码后,以新的矩阵形式输出,且此矩阵的维度 μ 可以表示为

$$\mu = 2n n_i d。 \quad (8)$$

式中, n_i 、 d 分别为二叉树的数目和树深。




图 1 RTE 索引过程示意图

Fig.1 Schematic diagram of RTE process

1.5 本文方法

由于随钻测井数据的低维特征,本文使用 RTE 对原本低维的数据进行特征转换,即对数据特征进行升维以提升基线模型的分类能力。将 RF、ET 和 GBDT 作为基线模型评估 RTE 的有效性;将 PSO-SVM 作为一种适用于低维数据的模型进行对比。

2 数据处理与模型构建

2.1 数据分析与预处理

为验证本文方法的可行性,我们选用来自珠江口盆地某研究区五口解释井内的 1 681 个岩性样本进行实验。该研究区内岩性被划分为五类,分别是泥岩、砂岩、粉砂岩、微晶灰岩和藻礁灰岩。其中,泥岩样本 784 个,砂岩样本 144 个,粉砂岩样本 237 个,微晶灰岩样本 169 个,藻礁灰岩样本 347 个。图

2 显示了本次研究的所用数据的样本量,其中泥岩样本占比较大,数据呈现不均衡分布。所有样本数据均来自同一研究区,服从相同的数据空间分布。由于随钻测井仪器的限制,仅有自然伽马(GR)、电阻率(R_i)、密度(DEN)和井径(CAL)四个测井参数构成整体样本。样本进行随机划分,70%作为训练集,30%作为测试集。




图 2 岩性数据统计量分布

Fig.2 Statistical distribution of lithological data

不同的随钻测井参数具有量纲差异。为了降低量纲和奇异值的影响,保证模型能够更好地挖掘数据之间的信息,需要对随钻测井数据进行归一化预处理。最大最小值归一化是最常用的归一化方法之一,它将数据分布映射至 0~1 之间,其公式表述为

$$X' = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (9)$$

式中, X' 、 X_i 、 X_{\min} 、 X_{\max} 分别表示归一化后的数

据、原始数据、数据最小值和数据最大值。

2.2 模型构建

文中所有模型的参数设置都进行了优化以保证模型具有较好的应用效果。其中,网格搜索和交叉验证法用于确定 RTE、RF、GBDT 和 ET 的超参数;而对比的 SVM 算法对模型超参数的选择更加敏感,故我们使用了 PSO^[24] 对 C 和 γ 进行调整。各模型的超参数见表 1。

2.3 模型评价标准

岩性识别的本质是分类问题。为了对分类模型性能进行全面的评价,将准确率(A)、精确率(P)、召回率(R)和 F_1 分数四种指标作为评价的标准。这些评价指标可以综合反映出模型性能的优劣,每一个指标值越高则模型效果越好。模型评价指标的表达式如下:

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FN} + N_{FP} + N_{TN}}; \quad (10)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}; \quad (11)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}; \quad (12)$$

$$F_1 = 2 \frac{PR}{P + R} \quad (13)$$

式中, N_{TP} 、 N_{FN} 、 N_{FP} 、 N_{TN} 分别为真正类、假反类、假正类和真反类的样本数。

混淆矩阵可以直观地反映模型对每种类别的识别情况,常用于分类模型的性能评估。混淆矩阵为一个 $N \times N$ 阶矩阵(N 为类别数),行为预测结果,列为真实结果,每一列中的数值代表真实样本被预测为某一样本的比例,对角线上的数值代表了每种类别的准确率。

表 1 五种模型的超参数

Table 1 Parameters of five models

模型	弱学习器	最大树深	最小可分节点数	学习率	粒子数	迭代次数	核函数
RTE	100	5	2				
RF	80	6	5				
GBDT	5	3		0.1			
ET	60	8	5				
PSO-SVM					50	20	Ploy

3 结果与分析

3.1 随机树嵌入效果

由于随钻测井获得的参数少,直接使用无法达到较好的效果。RTE 将原本低维的随钻测井数据重新进行二叉树编码,并映射至高维的稀疏空间,这将更有利于模型的深入挖掘。为了更直观地展示模型的数据分布,图 3 使用主成分分析进行数据降维,并以第一和第二主成分绘制了数据分布图。从数据原始分布(图 3a)中可以看到,岩性数据间的重叠较多,样本边界较为模糊。从 RTE 升维后的主成分分布(图 3b)中可以看到数据分布发生了很大的变化:对比原始分布,岩性间的边界更加清晰,且相同岩性样本间的分布更加紧密;这将有利于模型的学习与分类。

3.2 对比初始分类器

图 4 和表 2 展示了三种常用的集成分类器(RF、GBDT 和 ET)在使用 RTE 前后的实际使用效果。使用 RTE 升维后,所有模型的使用效果均得到明显提升,验证了该方法的有效性。其中:RF 的实际使用效果在三种模型中最佳,初始准确率达到 84.36%,在应用了 RTE 后,RTE + RF 准确率为 87.52%,提升了 3.16%,且 F_1 提升了 3.25%;ET + RTE 的效果改善最明显,准确率的提升达到了 7.32%;GBDT + RTE 也有较明显的效果提升,各项评价指标增幅都在 1.4% 以上。这些结果均表明,RTE 的升维方法可以有效地用于提升基础分类器对低维数据的分类准确率,这使得随钻测井岩性识

别的精确度有了明显改善。

3.3 对比 PSO - SVM

进一步地,将识别效果最佳的 RF + RTE 与 PSO - SVM 进行对比。PSO - SVM 过程见图 5。最终,SVM 的优化参数为: $C = 7.06, \gamma = 0.23$ 。PSO - SVM 的实验结果准确率为 86.34%,优于 RF、GBDT 和 ET 模型。可见,SVM 较常规机器学习模型,在较低维参数的随钻测井岩性识别中能够获得更好的分类效果。RF + RTE 的整体准确率较 PSO - SVM 高 1.18%,且岩性识别的整体效果更佳。

图 6 为 PSD - SVM 和 RET + RF 预测结果的混淆矩阵,对混淆矩阵的分析可以进一步获得每一种岩性的具体预测情况。混淆矩阵的纵坐标表示样本的真实岩性,横坐标表示预测岩性,理想状态下(即所有预测结果均为正确的状态)的对角线单元应均为 100%。可以看到 PSO - SVM 的岩性预测效果并不稳定,特别是粉砂岩的召回率仅有 73.44%,粉砂岩样本更易被错误地预测为泥岩;在砂岩的预测中 PSO - SVM 表现出一定优势(图 6a)。而 RF + RTE 的预测准确率更加均衡,在泥岩、粉砂岩和微晶灰岩的预测中效果均优于 PSO - SVM,且整体准确率更高;同时可以发现,即使是在岩性样本不均衡的情况下,RF + RTE 的预测效果表现也是非常均衡的,可见样本不均衡的影响对该方法的干扰较小(图 6b)。

3.4 实际应用效果

为了可以更加直观地显示各个模型的实际应用效果,选取了一口实际井进行可视化实验。选取井

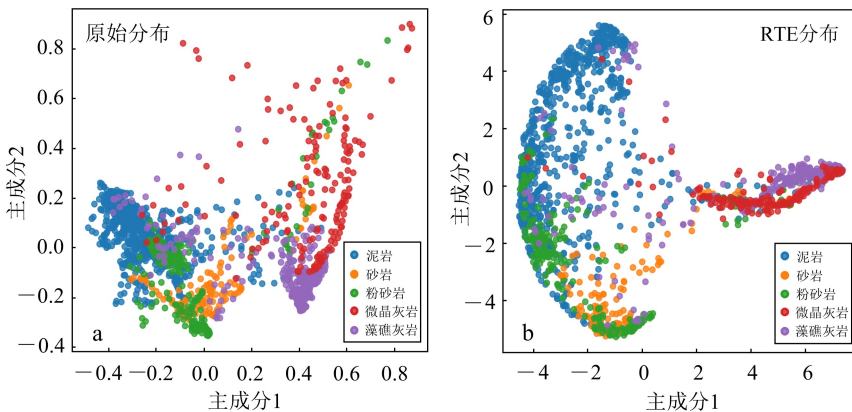


图 3 数据原始分布(a)和 RTE 分布(b)的主成分图

Fig.3 Principal component diagrams of initial distribution (a) and RTE distribution (b) of data




图 4 各模型预测准确率柱状图

Fig.4 Bar charts of prediction accuracy for each model

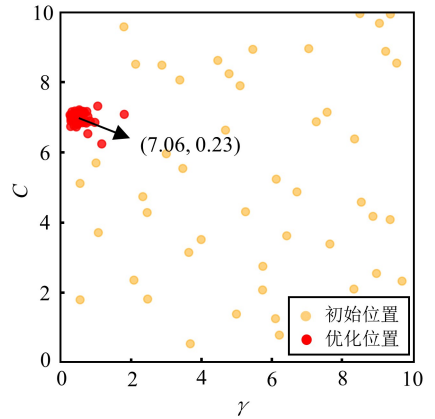


图 5 PSO-SVM 超参数图示

Fig.5 Graphic representation of hyperparameter of PSO-SVM

表 2 RTE 对不同模型的效果提升

Table 2 Improvement effect of RTE on different models

模型	准确率/%	精确率/%	召回率/%	F ₁ /%
RF	84.36	85.10	84.43	84.18
RF+RTE	87.52	87.64	87.42	87.43
GBDT	83.56	84.06	83.66	82.80
GBDT+RTE	85.35	85.52	85.35	85.21
ET	79.41	80.93	79.36	78.03
ET+RTE	86.73	87.02	86.73	86.78

段深度为 2 138.0 ~ 2 202.5 m, 五种岩性均有相应的发育。图 7 是实际应用各方法岩性识别结果的可视化。通过对比发现, RF+RTE 的识别效果较其他模型更好, 更接近实际的岩性解释情况; 特别是在黑色虚线区域, 对比模型均表现不佳, 岩性识别效果易出现混淆, 而 RF+RTE 模型仍能具有较良好的表现。

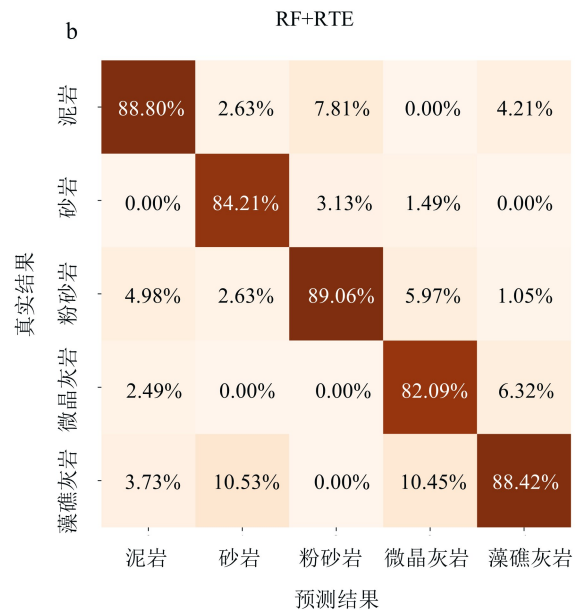



图 6 PSO-SVM(a)与 RET+RF(b)预测结果的混淆矩阵

Fig.6 Confusion matrix of prediction results of PSO-SVM (a) and RET+RF (b)




图 7 各模型实际预测结果可视化

Fig.7 Visualization of actual prediction results of each model

4 结论

1)随钻测井受实际条件限制,测得的测井参数较少,直接使用机器学习模型进行岩性识别效果不理想。随机树嵌入方法可以将低维的随钻测井数据重新编码至高维稀疏的空间,从而提升模型的使用效果。

2)对比实验结果表明,随机树嵌入方法可以有效提高随钻测井岩性识别机器学习模型的准确率。其中,随机树嵌入的随机森林方法效果最佳。

3)进一步对比粒子群优化支持向量机算法,随机树嵌入的随机森林模型性能表现更加稳定,为随钻测井的岩性精确识别提供了一种新方法。

参考文献 (References):

[1] Zhu X Y, Zhang H B, Ren Q, et al. An Automatic Identification Method of Imbalanced Lithology Based on Deep Forest and K-Means SMOTE[J]. *Geoenergy Science and Engineering*, 2023, 224: 211595.

[2] Han R Y, Wang Z W, Wang W H, et al. Lithology Identification of Igneous Rocks Based on XGboost and Conventional Logging Curves: A Case Study of the Eastern Depression of Liaohe Basin[J]. *Journal of Applied Geophysics*, 2021, 195: 104480.

[3] Wang W H, Wang Z W, Han R Y, et al. Lithology Classification of Volcanic Rocks Based on Conventional

Logging Data of Machine Learning: A Case Study of the Eastern Depression of Liaohe Oil Field[J]. *Open Geosciences*, 2021, 13(1): 1245 - 1258.

[4] 付光明,严加永,张昆,等.岩性识别技术现状与进展[J]. *地球物理学进展*, 2017, 32(1): 26 - 40.

Fu Guangming, Yan Jiayong, Zhang Kun, et al. Current Status and Progress of Lithology Identification Technology[J]. *Progress in Geophysics*, 2017, 32(1): 26 - 40.

[5] 张强,李家金,王毛毛,等.基于改进主成分分析法的测井曲线岩性分层技术[J]. *吉林大学学报(地球科学版)*, 2022, 52(4): 1369 - 1376.

Zhang Qiang, Li Jiajin, Wang Maomao, et al. Logging Curve Rock Layering Technology Based on Improved Principal Component Analysis [J]. *Journal of Jilin University (Earth Science Edition)*, 2022, 52 (4): 1369 - 1376.

[6] 王恒,姜亚楠,张欣,等.基于梯度提升算法的岩性识别方法[J]. *吉林大学学报(地球科学版)*, 2021, 51(3): 940 - 950.

Wang Heng, Jiang Yanan, Zhang Xin, et al. Lithology Identification Method Based on Gradient Boosting Algorithm [J]. *Journal of Jilin University (Earth Science Edition)*, 2021, 51(3): 940 - 950.

[7] 牟丹,张丽春,徐长玲,等.三种经典机器学习算法在火山岩测井岩性识别中的对比[J]. *吉林大学学报(地球科学版)*, 2021, 51(3): 951 - 956.

Mou Dan, Zhang Lichun, Xu Changling, et al. Comparison of Three Classical Machine Learning Algorithms for Lithology Identification of Volcanic Rocks Using Well Logging Data[J]. *Journal of Jilin University (Earth Science Edition)*, 2021, 51(3): 951 - 956.

[8] 杨朝义,朱乾坤,揭绍鹏,等.云南普朗铜矿并孔测井资料综合应用[J]. *物探与化探*, 2023, 47(1): 14 - 21.

Yang Chaoyi, Zhu Qiankun, Jie Shaopeng, et al. Comprehensive Application of Borehole Log Data of the Pulang Copper Deposit, Yunnan Province [J]. *Geophysical and Geochemical Exploration*, 2023, 47 (1): 14 - 21.

[9] 瞿晓婷,张蕾,冯宏伟,等.面向复杂储层的非均衡测井数据的岩性识别[J]. *地球物理学进展*, 2016, 31(5): 2128 - 2132.

Qu Xiaoting, Zhang Lei, Feng Hongwei, et al. Lithology Identification for Imbalanced Logging Data on Complex Reservoirs [J]. *Progress in Geophysics*, 2016, 31(5): 2128 - 2132.

- [10] 孙焱. 基于改进 KNN 算法的潜山复杂岩性测井识别方法[J]. 特种油气藏, 2022, 29(3): 18-27.
Sun Kui. Logging Identification Method of Complex Lithology in Buried Hill Based on the Improved KNN Algorithm[J]. Special Oil & Gas Reservoirs, 2022, 29(3): 18-27.
- [11] 徐晗, 姚孔轩, 程丹仪, 等. 基于非开挖随钻检测系统与随机森林的地层岩性识别[J]. 地质科技通报, 2021, 40(5): 272-280.
Xu Han, Yao Kongxuan, Cheng Danyi, et al. Stratigraphic Lithology Identification Based on No-Dig Logging While Drilling System and Random Forest [J]. Bulletin of Geological Science and Technology, 2021, 40(5): 272-280.
- [12] Han R Y, Wang Z W, Wang W H, et al. Multi-Label Prediction Method for Lithology, Lithofacies and Fluid Classes Based on Data Augmentation by Cascade Forest [J]. Advances in Geo-Energy Research, 2023, 9(1): 25-37.
- [13] 滕建强, 邱萌, 杨明任, 等. 基于门控循环单元神经网络的测井曲线预测方法[J]. 油气地质与采收率, 2023, 30(1): 93-100.
Teng Jianqiang, Qiu Meng, Yang Mingren, et al. Logging Curve Prediction Method Based on GRU[J]. Petroleum Geology and Recovery Efficiency, 2023, 30(1): 93-100.
- [14] 杨超超, 王红发, 张颜伊, 等. 随钻测井地质导向技术在水平井钻井中的应用[J]. 测井技术, 2022, 46(5): 625-631, 637.
Yang Chaochao, Wang Hongfa, Zhang Yanyi, et al. Application of Geosteering Technology Based on Logging While Drilling in Horizontal Well[J]. Well Logging Technology, 2022, 46(5): 625-631, 637.
- [15] 陈刚, 汪凯斌, 蒋必辞, 等. 随钻测井中岩性识别方法的对比及应用[J]. 煤田地质与勘探, 2018, 46(1): 165-169.
Chen Gang, Wang Kaibin, Jiang Bici, et al. Comparison and Application of LWD Lithology Identification Method [J]. Coal Geology & Exploration, 2018, 46(1): 165-169.
- [16] Ren Q, Zhang H B, Zhang D L, et al. Lithology Identification Using Principal Component Analysis and Particle Swarm Optimization Fuzzy Decision Tree [J]. Journal of Petroleum Science and Engineering, 2023, 220: 111233.
- [17] Wang Y, Lu Y. Diagenetic Facies Prediction Using an LDA-Assisted SSOM Method for the Eocene Beach-Bar Sandstones of Dongying Depression, East China [J]. Journal of Petroleum Science and Engineering, 2021, 196: 108040.
- [18] Geurts P, Ernst D, Wehenkel L. Extremely Randomized Trees[J]. Machine Learning, 2006, 63(1): 3-42.
- [19] 张涛, 李艳萍, 刘晓宇, 等. 基于自适应粒子群优化最小二乘支持向量机的深层变质岩测井岩性识别[J]. 地球物理学进展, 2023, 38(1): 382-392.
Zhang Tao, Li Yanping, Liu Xiaoyu, et al. Lithology Interpretation of Deep Metamorphic Rocks with Well Logging Based on APSO-LSSVM Algorithm [J]. Progress in Geophysics, 2023, 38(1): 382-392.
- [20] 苏赋, 马磊, 罗仁泽, 等. 基于改进多分类孪生支持向量机的测井岩性识别方法研究与应用[J]. 地球物理学进展, 2020, 35(1): 174-180.
Su Fu, Ma Lei, Luo Renze, et al. Research and Application of Logging Lithology Identification Based on Improve Multi-Class Twin Support Vector Machine [J]. Progress in Geophysics, 2020, 35(1): 174-180.
- [21] 王光宇, 宋建国, 徐飞, 等. 不平衡样本集随机森林岩性预测方法[J]. 石油地球物理勘探, 2021, 56(4): 679-687.
Wang Guangyu, Song Jianguo, Xu Fei, et al. Random Forests Lithology Prediction Method for Imbalanced Data Sets [J]. Oil Geophysical Prospecting, 2021, 56(4): 679-687.
- [22] 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.
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.
- [23] Breiman L. Random Forests[J]. Machine Learning, 2001, 45(1): 5-32.
- [24] 李曦, 范翔宇, 王兆峰, 等. 基于 PSO-SVM 的测井岩性识别方法研究: 以南图尔盖盆地 K 油田古生界 (Pz) 储层为例[J]. 地球物理学进展, 2022, 37(2): 617-626.
Li Xi, Fan Xiangyu, Wang Zhaofeng, et al. Logging Lithology Identification Method Research Based on PSO-SVM: A Case Study of Paleozoic (Pz) Reservoir in K Oil Field, South Turgay Basin, Kazakhstan [J]. Progress in Geophysics, 2022, 37(2): 617-626.