

doi: 10.12097/gbc.2024.06.016

基于 SSMO-SSA-LGBM 算法的致密砂岩储层岩性识别

孙婧^{1,2}, 赵军龙^{1,2*}, 张雨辰^{1,2}, 金利睿^{1,2}, 崔文洁^{1,2}, 陈家鑫^{1,2}

SUN Jing^{1,2}, ZHAO Junlong^{1,2*}, ZHANG Yuchen^{1,2}, JIN Lirui^{1,2}, CUI Wenjie^{1,2}, CHEN Jiaxin^{1,2}

1. 西安石油大学地球科学与工程学院, 陕西 西安 710000;

2. 西安石油大学陕西省油气藏地质学重点实验室, 陕西 西安 710000

1. School of Earth Science and Engineering, Xi'an University of Petroleum, Xi'an 710000, Shaanxi, China;

2. Key Laboratory of Oil and Gas Reservoir Geology in Shaanxi Province, Xi'an University of Petroleum, Xi'an 710000, Shaanxi, China

摘要:【研究目的】现有岩性测井识别方法用于致密砂岩储层岩性识别时,存在岩性类别处理不均衡及敏感性不足问题。【研究方法】本文提出 SSMO-SSA-LGBM 模型,利用 SVM-SMOTE 过采样算法(简称 SSMO)对训练集中岩性数据较少的样本进行平衡化处理,得到新合成样本,并将其与原始训练集组成新训练集,用于训练和构建 LGBM 模型,由于 LGBM 模型训练时使用较多超参数,因此采用麻雀优化搜索算法 SSA 对其进行超参寻优以获得最佳参数组合。以甘肃华池油田 S 区延 10 致密砂岩测井数据为基础,训练构建 SSMO-SSA-LGBM 模型,采用 KNN、Adaboost、随机森林等模型进行对比。【研究结果】经 SSMO 模型平衡化后,LGBM 模型对少数类识别性能增强;SSA 算法全局优化搜索经较少次数迭代获得 LGBM 最优超参数;SSMO-SSA-LGBM 模型预测性能达到最优,在验证井上岩性识别结果与取心资料符合率较高。【结论】采用 SSMO 算法能有效解决岩性类别非均衡给岩性预测结果带来的不利影响,SSA 算法全局优化搜索经较少次数迭代获得 LGBM 算法最优超参数组合,使得模型预测性能达到最优,该模型在华池 S 区的应用效果较好。

关键词: SSMO-SSA-LGBM 算法;非均衡数据;岩性识别;致密砂岩储层;甘肃华池

创新点: 针对岩性预测中的类别非均衡问题,通过生成贴合少数类特征的合成样本增强模型学习效果,并结合 SSA 算法高效优化 LGBM 超参数,显著提升了模型预测性能。

中图分类号: P618.13; P631.8 文献标志码: A 文章编号: 1671-2552(2025)05-0935-14

Sun J, Zhao J L, Zhang Y C, Jin L R, Cui W J, Chen J X. Lithology identification of tight sandstone reservoirs based on SSMO-SSA-LGBM algorithm. *Geological Bulletin of China*, 2025, 44(5): 935-948

Abstract: [Objective] Existing lithology logging identification methods face challenges of imbalanced lithology class processing and insufficient sensitivity when applied to tight sandstone reservoirs. [Methods] This study proposes the SSMO-SSA-LGBM model. First, the SVM-SMOTE oversampling algorithm (abbreviated as SSMO) is used to balance samples with fewer lithology data in the training set by generating synthetic samples. These synthetic samples are combined with the original training set to form a new training dataset for constructing the LightGBM (LGBM) model. Given the numerous hyperparameters in LGBM, the Sparrow Search Algorithm (SSA) is employed to optimize hyperparameters and obtain the optimal combination. The model is trained using logging data from the Yan 10 tight sandstone reservoir in the Huachi S Block, and compared with KNN, Adaboost, Random Forest, and other models. [Results] After SSMO balancing, the LGBM model exhibits enhanced recognition performance for minority lithology classes. The SSA

收稿日期: 2024-10-16; 修订日期: 2025-01-13

资助项目: 国家自然科学基金《压力-应力耦合对前陆冲断带深层—超深层碎屑岩储层异常高原生孔隙的保存机制研究》(批准号: 42172164)

作者简介: 孙婧(1998-), 女, 在读硕士生, 从事测井地质综合研究, 测井资料处理与解释。E-mail: 19801360170@163.com

* 通信作者: 赵军龙(1970-), 男, 博士, 教授, 从事测井资料处理与解释、复杂油气藏测井评价工作。E-mail: zjl1970@163.com

algorithm achieves global optimization with fewer iterations, obtaining the optimal hyperparameters for LGBM. The SSMO-SSA-LGBM model demonstrates superior predictive performance, with lithology identification results on validation wells showing high consistency with core data. **[Conclusions]** The SSMO algorithm effectively mitigates the adverse effects of lithology class imbalance on prediction accuracy. The SSA algorithm efficiently identifies the optimal hyperparameter combination for LGBM through limited iterations, maximizing model performance. The proposed model achieves satisfactory application results in the Huachi S Block.

Key words: SSMO-SSA-LGBM algorithm; imbalanced data; lithology recognition; tight sandstone reservoir; Huachi, Gansu

Highlights: Addressing the class imbalance issue in lithology prediction, the method enhances model learning by generating synthetic samples that closely resemble minority class features, and combines the SSA algorithm to efficiently optimize LGBM hyperparameters, thereby significantly improving the model's predictive performance.

岩性识别对于建立地层格架、地层划分与对比、沉积微相分析、储层评价、储层参数模型建立、油藏描述等地质研究工作开展与分析尤为重要(陈钢花等, 2001; 冯翠菊等, 2004; 许风光等, 2006; 谷宇峰等, 2021a)。

地质研究中传统岩性识别方法主要有钻井取心、岩屑录井、地震属性分析, 以及地震反演、常规测井、成像测井等方法(王恒等, 2021; 程超等, 2022; 罗仁泽等, 2023)。钻井取心能够直接获取岩心资料, 但存在成本高、难以获取更多连续地质剖面信息的弊端(程超等, 2022)。岩屑录井对录井质量的依赖程度较高, 识别精度及效率较低且泛化能力差(马峥等, 2017)。地震反演岩性取决于岩性某一弹性参数范围或弹性参数交会分析存在大量重叠、预测结果存在较大不确定性(罗仁泽等, 2023)。常规测井资料用于岩性识别时, 测井数据往往存在大量冗余且岩性与测井参数之间关系具有模糊性、识别效果不佳。成像测井虽然直观、精度高, 但实际成像测井工作成本高、开展有限(程超等, 2022)。

岩性分类任务实质是多个指标数据的模式识别问题, 机器学习通过从大量冗余测井资料中建立识别模型, 实现岩性自动识别(张野等, 2018), 近年在岩性识别领域得到了快速发展。常用的有监督学习方法, 如 BP 神经网络、支持向量机、随机森林(张晗等, 2017; 韩启迪等, 2019; 石锁等, 2020; 刘凯等, 2022); 无监督学习, 如聚类分析(王宗俊等, 2021)。上述机器学习算法可与 GS 网格搜索算法、自适应增强等算法相结合, 进一步增强模型预测性能(Jiang et al., 2022; 李曦等, 2022; 张涛等, 2023)。以上机器学习算法在一定程度上提升了岩性识别效率, 但没有充分考虑到实际应用中, 受储集层非均质性影响、所获得的岩心数据样本较少(宋梓豪等, 2024; 赵逢达等, 2024)、常规测井曲线敏感性不足造成数据样

本集类别不平衡问题, 导致模型在训练时无法充分学习类别较少的数据特征而影响岩性识别效率。深度学习, 如 LSTM 循环神经网络、迁移学习、Transform 等算法, 擅长自动从原始数据中学习高级特征表示(武中原等, 2021; 许振浩等, 2021; He et al., 2023; 韩鑫豪等, 2024), 梯度提升学习同样也可以通过内部机制发现重要特征, 被应用于岩性识别研究(王恒等, 2021)。但周渊凯和刘祐(2024)提出深度学习模型对于数据不平衡、可解释性差及部署调试深度学习模型架构复杂, 导致其实用性不佳。王恒等(2021)采用梯度提升决策树的两种代表性算法——XGBoost 和 LGBM 算法开展岩性识别研究, 结果表明, 即使在数据集不平衡的情况下, 这两种算法在防止过拟合和保持模型可解释性等方面仍表现出良好的适用性。谷宇峰等(2021b)研究发现, XGBoost 在处理高维度海量数据时, 计算速度仍很慢, 相比之下, 基于特征的轻量化数据处理与直方图加速算法的 LGBM 算法可高效完成建模。苏赋等(2020)、Li et al.(2021)、罗仁泽等(2023)尝试利用 SMOTE 法、自适应合成采样法(ADASYN)、K-means 算法与 SMOTE 组合改进采样算法等解决岩性类别不平衡问题, 取得一定成效, 但这些方法本质上是相邻数据间线性插值, 没有充分考虑少数类别数据分布边界, 新合成数据能否真正表征少数类特征。因此, 缓解岩性识别中样本类别不平衡问题, 以及准确提取关键敏感曲线特征信息建立识别模型, 对于提升致密砂岩储层岩性识别准确率具有一定的研究价值。

针对上述问题, 本文利用一种基于 SVM 支持向量机与 SMOTE 过采样算法组成的 SVM-SMOTE (以下简称 SSMO)模型对岩性少数类样本进行平衡化处理, 提出 SSMO-SSA-LGBM 组合模型。基于华池 S 区实际测井数据, 依据常规测井对致密砂岩储层岩性反映原理及前人研究公式, 筛选出该区岩性敏感

测井曲线并总结不同岩性类型测井响应及特征分布;采用 SSMO 算法对少数类非均衡样本进行处理,实现平衡化;采用 SSA(麻雀优化搜索算法)全局搜索 LGBM(轻量级梯度提升机)模型最优超参数组合完成模型建模,与 KNN、随机森林、Adaboost 等算法分析对比,并在验证集上验证了 SSMO-SSA-LGBM 应用于致密砂岩储层岩性识别研究的可行性与优越性。

1 SSMO-SSA-LGBM 模型原理及岩性识别关键技术构建

1.1 SSMO 过采样技术

SSMO 算法是由张忠林等(2020)提出的基于支持向量机(SVM)的过采样算法,通过迭代合成样本并利用 SVM 决策边界指导样本生成,有效提升少数类样本的合成质量。通过 SVM 得到分类超平面,根据每个少数类样本到分类超平面距离赋予样本距离

权重,同时考虑少数类类间分布计算样本密度,赋予样本密度权重,通过距离权重及密度权重得到少数类样本选择权重,在此基础上运用 SMOTE 合成新样本。改善了合成样本的质量侧重于生成决策边界附近的合成样本,通过 SVM 决策边界,合成样本更具有代表性,能更好地表示少数类样本分布,具体算法步骤见图 1。

1.2 麻雀优化搜索算法 (SSA)

麻雀搜索算法(Sparrow Search Algorithm, SSA)是由 Xue and Shen(2020)提出的一种启发式搜索算法,该算法通过模仿麻雀觅食和反捕猎行为进行优化位置,从而找到全局最优解。

该方法将搜索空间划分为发现者、加入者和警戒者 3 个种群,依据不同种群的不同搜索行为寻找目标函数的全局最优解。麻雀搜索算法首先将个体按照适应度从优至差排序(本文研究中,适应度为准确率,根据准确率升序排序),发现者由适应度较优




图 1 SSMO 算法流程图

Fig. 1 SSMO algorithm flowchart

的个体组成。发现者、加入者与警戒者位置更新方法见公式(1)~(3)。

(1)发现者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \exp \left[-i / \alpha i_{ter_{max}} \right], & \text{if } R_2 < S_T \\ X_{i,j}^t + QL, & \text{if } R_2 \geq S_T \end{cases} \quad (1)$$

式中: $i_{ter_{max}}$ 为预设最大迭代次数; $x_{i,j}$ 为第 i 只麻雀在第 j 维中的位置; $\alpha \in (0, 1]$, 为均匀随机数; $R_2 \in [0, 1]$, 为警戒值; $S_T \in [0.5, 1]$, 为安全值; Q 为服从正态分布的随机数; L 为矩阵各元素为 1 的 $1 \times d$ 的矩阵。

(2)加入者位置更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp \left[(X_{worst}^t - X_{i,j}^t) / i^2 \right], & \text{if } i > n/2 \\ X_{best}^t - \frac{1}{d} \sum_{j=1}^d |X_{i,j}^t - X_{best}^t| \cdot \text{rand}(\{-1, 1\}), & \end{cases} \quad (2)$$

式中: X_{best}^t 为当前种群中适应度最佳的麻雀个体, X_{worst}^t 为当前种群中具有最差适应度的麻雀。

(3)警戒者位置的更新公式为:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^{best} + \beta \cdot (X_{i,j}^t - X_{i,j}^{best}), & \text{if } f_i \neq f_g \\ X_{i,j}^t + K \cdot \left[(X_{i,j}^t - X_{i,j}^{worst}) / (|f_i - f_{worst}| + \varepsilon) \right], & \text{if } f_i = f_g \end{cases} \quad (3)$$

式中: β 为步长控制参数随机数且服从正态分布; $K \in [-1, 1]$, 为任意随机数; f_i 为当前麻雀个体的适应度; f_g 为当前全局最优适应度; f_{worst} 为当前全局最差适应度; ε 为较小常数。

1.3 LGBM 算法

LightGBM(Light Gradient Boosting Machine, LGBM)是微软 2016 年提出的高效 GBDT 框架,通过 Histogram 算法和 Leafwise 策略降低计算复杂度,实现快速训练与高并行性。(高兵等, 2022)。LGBM 通过将多个弱分类器提升为具有强分类效果的强分类器,具体提升公式见公式(4)。

$$h(x) = \sum_{i=1}^n L(y_i, y_i^t) + \sum_{i=1}^t \Omega(f_i) \quad (4)$$

式中: L 为损失函数, Ω 为正则项, y_i 为预测值, f_i 为弱分类器。模型通过损失函数及正则项来调控模型的精度和复杂度。模型通过负梯度来拟合损失,目标函数通过负梯度来拟合损失,目标函数通过泰勒展开式可以获得,见公式(5)。

$$h_t(x) = \sum_{i=1}^n L(y_i, y_i^{t-1}) + m_i f_i(x_i) + \frac{1}{2} m_i f_i^2(x_i) + \Omega(f_i) + C \quad (5)$$

式中: C 为常数项。

将目标函数简化之后可以获得公式(6)。

$$h_t(x) = \left[m_i f_i(x_i) + \frac{1}{2} m_i f_i^2(x_i) \right] + \Omega(f_i) \quad (6)$$

式中: $h_t(x)$ 为目标函数, L 为损失函数, Ω 为正则项, y_i 为预测值, f_i 为弱分类器。

1.4 基于 SSMO-SSA-LGBM 算法的岩性识别模型构建

首先,对训练集中少数类样本采用 SSMO 算法进行样本平衡化处理,生成新的合成少数类样本,使少数类样本达到均衡。其次,建立 LGBM 分类模型时,由于模型在学习过程中需要大量超参数参与模型训练效率,通过设置 SSA 算法中麻雀种群规模,迭代次数,发现者、警戒者比例、预警值等参数全局范围内搜索找到 LGBM 模型最佳参数,进而得到最优分类模型。本文遵循的 SSMO-SSA-LGBM 岩性识别流程见图 2。

2 实例分析及应用

2.1 研究区概况及数据来源

华池油田位于甘肃省庆阳市,坐落于庆西古河两岸古地貌上,地处鄂尔多斯盆地西南部天环坳陷、陕北斜坡 2 个一级构造单元之间,整体上呈现向西倾斜的单斜构造(图 3-a)。在三叠纪末期,印支运动导致华北地块西部鄂尔多斯盆地迅速抬升和剥蚀变形,对研究区目的层沉积产物作用明显, S 区见图 3-b,目的层延 10 储层顶部构造为西倾单斜背景上的差异压实作用形成一系列低幅鼻状隆起,目的层发育多种复杂岩性,形成了以构造为主、岩性为辅的储藏。本文实验数据来源于华池油田 S 区块延 10 致密砂岩储层。根据 S 区 4 口取心井 S1、S2、S3、S4 岩心资料及地质资料分析,可知研究区主要岩性有 7 种,分别为砂砾岩、粗砂岩、中砂岩、细砂岩、泥质粉砂岩、泥岩、炭质泥岩。

2.2 研究区测井参数敏感性分析及主要难点

现代常规测井方法可以分为岩性测井系列(自然电位测井 SP、自然伽马测井 GR、井径测井 CAL)、孔隙度测井系列(声波时差测井 AC、密度测井 DEN、中子测井 CNL)、电阻率测井系列(深、中、浅




图 2 SSMO-SSA-LGBM 岩性识别流程图

Fig. 2 SSMO-SSA-LGBM lithology identification process




图 3 鄂尔多斯盆地构造区域(a)及华池油田 S 工区概况(b)

Fig. 3 Overview of the structural area of the Ordos Basin (a) and the S work area of the Huachi Oilfield (b)

探测的普通视电阻率测井、侧向测井、感应测井) (赵军龙, 2008)。其中, 自然电位测井通过测量扩散作用引起的总电动势在井内的分压反映地层岩性信息, 井径测井基于不同岩性的井径变化信息为岩性解释提供依据, 自然伽马测井主要通过测量地下岩

层放射性元素的伽马射线强度反映地层岩性信息。声波时差测井利用不同岩性的声波传播差异进行岩性划分; 密度测井通过测量散射伽马射线计数率获取岩石密度信息进行岩性识别, 中子测井利用中子的减速特征开展孔隙度分析和岩性预测。电阻率测

井系列通过探测深、中、浅的电阻率变化反映其岩性特征。

基于上述测井方法对岩性反映的原理及研究区目的层测井曲线资料,筛选出研究区与岩性识别相关的 8 条测井曲线(SP、GR、CAL、AC、DEN、CNL、RT(RILD)、RILM)。为筛选出对研究区复杂岩性识别敏感的测井参数,参考宋梓豪等(2024)和孙兴刚等(2012)提出的流体敏感参数优选公式,开展研究区测井敏感参数选取,见公式(7)。

$$LS = \left| \frac{\bar{A}_m - (\bar{A}_1 + \dots + \bar{A}_n)/n}{\bar{A}_m} \right| \quad (7)$$

式中: $\bar{A}_m$ 表示砂砾岩测井曲线 A 的平均测井响应值(本次选取测井响应特征不明显的砂砾岩为量纲标准); $\bar{A}_1 \dots \bar{A}_n$ 为其余岩性测井响应 A 的平均值; n 为研究区致密砂岩岩性个数; LS 为岩性敏感程度,其值越高代表测井曲线 A 对岩性敏感程度越高。

研究区不同测井曲线敏感系数统计直方图见图 4。敏感系数从高至低依次为 GR、AC、DEN、RT、SP、CNL、RILM、CAL。本次选择 GR、AC、DEN、RT、SP、CNL 6 条测井曲线用于岩性分类识别。

将优选的 6 项测井响应参数与取心井岩心资料结合分析,得到部分代表段取心井研究区致密砂岩储层目的层真实岩性测井响应特征分布图(图 5)。对于 6 类测井响应特征数值范围进行统计,建立研究区典型岩性数值范围统计库(表 1)及特征分布箱线图(图 6)。




图 4 研究区测井曲线敏感系数直方图

Fig. 4 Histogram of sensitivity coefficient of logging curves in the study area

SP—自然电位测井; GR—自然伽马测井; CAL—井径测井;
AC—声波时差测井; DEN—密度测井; CNL—中子测井

由图 6 可知,自然伽马、自然电位及声波时差区分砂岩类与泥岩类较好,其中自然伽马对于重合度较高的 4 类砂岩类较其余测井响应更敏感(图 6-a~c); 声波时差对于砂砾岩识别效果较好(图 6-c); 密度及原状地层电阻率对识别泥质粉砂岩与泥岩识别较好,与其余岩性区分度较高(图 6-d, f)。由表 1 可知,砂砾岩、粗砂岩、中砂岩、细砂岩 4 类砂岩,以及泥质粉砂岩、泥岩、炭质泥岩测井响应范围均有较多的重合部分,仅利用单一测井曲线只能简单对个别岩类进行区分。

为了探讨测井曲线交会法识别岩性效果,本次采用三维交会图进行岩性识别图版绘制。选取 GR、AC、CNL 及 SP、DEN、RT 建立 2 组两两交互的三维交会图(图 7)。由图 7 可知,上述 7 种岩性测井数据点在三维图版中重合区域较多,三维交会图仅能清晰划分砂砾岩、粗砂岩、中砂岩、细砂岩这 4 类砂岩类与泥质粉砂岩、泥岩、炭质泥岩界线,但是对于更进一步精确识别效果不理想。笔者认为,研究区岩性识别难点主要在于致密砂岩储层岩性种类复杂多样,且不同岩性测井响应敏感性不同、区分度不足。图 7 中各岩性类别之间的数据存在严重不均衡,进一步加大了岩性识别困难。因此,需要利用有效的机器学习算法处理数据集非均衡问题,以及更精确地挖掘岩性与测井曲线敏感参数之间的非线性关系,建立有效的岩性-测井响应识别关系,获得识别精度较高的分类模型。

2.3 数据预处理及划分

将岩性类别和分类编码分别对应 0—砂砾岩、1—粗砂岩、2—中砂岩、3—细砂岩、4—泥质粉砂岩、5—泥岩、6—炭质泥岩。取心井 S1、S2、S3、S4 设为训练井,这 4 口探井取心测井数据及对应的岩性数据组成学习样本,K1 井设为验证井,即该井资料组成预测样本。其中,建模样本共 1008 个,按 8:2 比例组建训练样本总共 805 组,测试集样本 203 组。训练集、测试集的划分结果如表 2 所示。为了解决不同测井响应之间属性值差异过大问题,采用归一化处理对测井曲线数据集进行预处理。从表 2 可以看出,与其他类别相比,0—砂砾岩、1—粗砂岩、6—炭质泥岩类别数量较少,容易导致模型在训练过程中学习到的特征少,影响模型对上述 3 种少数类岩性识别效果,因此需要对少数类样本进行均衡化处理。




图 5 S 区块部分代表井段致密砂岩储层岩性测井响应特征

Fig. 5 The lithological logging response characteristics of the tight sandstone reservoir represented by the S block in the well section

表 1 研究区典型岩性测井响应数值范围

Table 1 Typical lithological logging response numerical range in the dataset of the study area

岩性	SP/mV	GR/API	AC/(μs·m ⁻¹)	DEN/(g·cm ⁻³)	CNL/%	RT/(Ω·m)
砂砾岩	25.6~38.0	36.8~61.3	218.6~235.7	2.54~2.74	12.34~18.43	62.95~87.64
粗砂岩	17.1~44.8	40.7~67.6	223.0~254.5	2.45~2.69	11.12~22.57	59.14~116.70
中砂岩	13.7~39.8	25.8~69.1	238.8~251.2	2.48~2.68	11.24~26.67	58.94~164.74
细砂岩	18.8~49.71	51.2~89.8	220.3~251.7	2.42~2.68	10.44~24.91	61.15~99.58
泥质粉砂岩	42.1~78.8	72.3~139.9	235.0~278.4	2.50~2.67	11.98~33.36	17.31~63.70
泥岩	94.3~51.5	68.6~170.9	240.1~293.0	2.19~2.70	14.22~37.29	10.12~39.86
炭质泥岩	62.4~73.5	114.6~128.7	252.4~264.4	2.56~2.65	22.98~26.96	81.71~91.24

2.4 评价指标

混淆矩阵可直观衡量分类模型的性能,统计了不同类别样本的分类情况(王增帅, 2022)。其中,行代表真实类别,列代表样本的预测类别,多数类被定义为负类,少数类被定义为正类。正类样本预测为正类,表示为真正例(TP, True Positive);负类样本预测结果为正类,表示为假正例(FP, False Positive);正类样本预测结果为负类,表示为假反例(FN, False Negative);负类样本预测结果为负类,表示真反例(TN, True Negative)。本次实验采用以下指标检

验模型分类性能,如准确率(Accuracy)、精准度(Precision)、召回率(Recall)、敏感性(Sensitivity)、F1 值(F1-score)。具体计算方式参考公式(8)~(11):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (8)$$

$$Precision = \frac{TP}{TP + FP} \quad (9)$$

$$Recall = \frac{TP}{TP + FN} \quad (10)$$




图 6 研究区测井曲线敏感参数特征分布箱线图

Fig. 6 Box plot of characteristic distribution of sensitive logging curves in the study area

a—自然伽马;b—自然电位;c—声波时差;d—密度;e—中子;f—原状地层电阻率

$$F1 = \frac{2 \cdot \text{Recall} \cdot \text{Precision}}{\text{Recall} + \text{Precision}} \quad (11)$$

2.5 基于 SSMO-SSA-LGBM 模型岩性识别流程

2.5.1 参数设置及实验环境

首先,对训练集中少数类样本 0—砂砾岩、1—粗砂岩、6—炭质泥岩采用 SSMO 算法进行样本平衡化处理,生成新的合成少数类样本,使少数类样本达到均衡。这些新合成样本与原始 80% 训练集用

于 LGBM 模型训练与建模,合成样本仅在训练阶段使用,测试阶段则使用真实的 20% 测试集进行评估测试。SSA 优化算法中麻雀种群规模设置为 80 个,迭代次数设置为 30 次,发现者比例设置为 70%,警戒者比例设置为 30%,预警值为 0.6。按上述参数进行模型参数设置,找到 LGBM 模型全局最优解作为模型最佳参数进行训练、测试集测试及应用验证。

本次实验的软件环境为 64 位 Windows 10 操作系统;本次实验开发平台为 Jupyter Notebook;开发语言为 Python 3.7。

2.5.2 识别结果

图 8 对比了使用 SSMO 算法平衡化前后的 LGBM 模型 F1 值混淆矩阵结果。F1 能较好地综合考虑精确率与召回率 2 个指标,从而更全面地评价模型对于多数类和少数类的预测精度。图 8-a 表示未使用 SSMO 算法的 SSA-LGBM 模型预测数据集中的 3 种少数类,如砂砾岩、粗砂岩及炭质泥岩预测结果的 F1 值分别为 72.7%、80%、66.7%,而对于多数类,如中砂岩、细砂岩、泥质粉砂岩及泥岩预测结果的 F1 值分别为 92.3%、93.3%、83.9% 和 92.3%,少数类较多数类的 F1 值偏低。图 8-a 中未使用 SSMO 模型的 SSA-LGBM 模型在砂砾岩及炭质泥岩岩性预测结果 F1 值不理想,验证了岩性类别数据不平衡对机器学习岩性识别具有不利影响。图 8-b 为采用了 SSMO 算法的 SSA-LGBM 模型,可以看出 3 种少数类的 F1 值都得到了提升:砂砾岩从 72.7% 提升至 92.3%,提升了 19.6%;粗砂岩的 F1 值从 80% 提升至 92.9%,提升了 12.9%;炭质泥岩 F1 值提升较明显,从 67% 提升至 90.9%,提升了 23.9%,证实 SSMO 算法能够有效提升 LGBM 模型对于少数类岩性识别性能,同时,SSMO-SSA-LGBM 模型对于多数类整体的识别精度也得到了提升,具有较好的鲁棒性。

SSMO-SSA-LGBM 模型在测试集上预测值与真实值整体趋势对比如图 9 所示。从图 9 可以看出,SSMO-SSA-LGBM 模型预测值与真实值整体趋势一致,两者拟合效果较好,模型预测精度效果良好,预测结果可信度高。

2.5.3 同类算法性能对比

在明确 SSMO 模型和 SSA 模型对于 LGBM 模型预测性能有明显提升之后,为了增强验证效果,本文加入了 KNN、随机森林、Adaboost 等模型进行性能对比。为了保证所有验证模型在预测时达到最佳,本文采用 SSMO 模型和 SSA 模型对 KNN、随机森林、Adaboost 进行平衡化及参数优化处理。4 种模型经 SSA 算法优化后使用的超参数组合见表 3,各模型在测试集上的综合预测指标对比见表 4,各模型预测值与岩性真实值标签误差见图 10。

图 8 中横坐标岩性标签误差表示模型预测值与

真实值岩性类别标签差值绝对值,若预测值与真实值相符,即二者差值的绝对值为 0,若二者差值绝对值不为 0,表示模型预测值与真实值不符(谷宇峰等, 2021b)。从表 4、图 8 可知,SSMO-SSA-KNN 模型、SSMO-SSA-随机森林模型预测误差较大,各项指标不理想,印证模型预测效果不佳,对致密砂岩储层不同岩性区分度容易混淆,区分能力较弱。SSMO-SSA-Adaboost 模型的预测误差集中对于少数类识别不佳。SSMO-SSA-LGBM 模型预测误差最少,对于各岩性识别能力较强,尤其是少数类岩性的识别,模型整体精确率、召回率和 F1 值均达到 95% 以上,在所有模型中表现最优。从表 4 时间代价看,LightGBM 模型基于梯度提升决策树(GBDT)框架,通过 leaf-wise 生长策略与直方图算法迭代生成基学习器,相较于随机森林的全特征并行局限性与 Adaboost 的串行迭代缺陷,其采用特征捆绑与直方图加速技术使得模型在数据集测试中展现显著效率优势。

3 讨论

3.1 非均衡数据对岩性识别的影响

测井数据集存在的岩性类别不平衡问题给分类器造成的负面影响不容忽视,分类模型更容易学习多数类岩性样本特征模式,对于少数类样本特征学习不充分,导致少数类岩性难以被模型有效捕捉。在实例分析中,本文对比了数据非均衡处理前后的 LGBM 模型 F1 值,经过 SSMO 算法处理后,实例中各岩性分类 F1 值均有较大提升,其中,少数类岩性预测精确率提升效果显著。说明 SSMO 算法考虑了少数类样本到超平面距离所赋予的距离权重,充分考虑少数类样本类内平衡,再依据选择权重选择样本运用 SMOTE,生成更贴近少数类特征的新合成样本,使模型对于少数类样本特征得到充分学习。有效改善不平衡数据分类结果偏向于多数类,使分类模型整体具备更好的稳健性。对于类似岩性识别研究具有一定参考价值。

3.2 验证井识别结果对比

为进一步验证 SSMO-SSA-LGBM 对于新井处理能力与实际应用效果,将模型用于研究区 K1 井 1735~1835 m 深度段作为验证井段,同时与其他 3 种模型的岩性识别结果进行对比。从图 11 可知,SSMO-SSA-LGBM 模型识别符合率最高,K1 井段取




图 7 研究区岩性识别三维交会图

Fig. 7 Three dimensional intersection charts for lithology identification in the research area

a—GR-AC-CNL 交会图; b—SP-DEN-RT 交会图

表 2 训练集和测试集划分结果

Table 2 Division Results of Training Set and Test Set

岩性类型	类别标签	岩心数据	训练样本	
			训练集	测试集
砂砾岩	0	22	15	7
粗砂岩	1	51	38	13
中砂岩	2	244	198	46
细砂岩	3	248	195	53
泥质粉砂岩	4	177	148	29
泥岩	5	252	203	49
炭质泥岩	6	14	8	6

心段总厚度为 41.5 m, 识别岩性与取心岩性相符合厚度为 39.8 m, 符合率较高。表明 SSMO-SSA-

LGBM 模型能够解决 S 区致密砂岩储层岩性识别存在的岩性类别不均衡及敏感性不足问题, 算法本身采用直方图算法决定最优分裂点, 能自动高效处理各岩性测井响应分类特征, 在粗砂岩与中砂岩接触界面岩性过渡带测井曲线特征较相似的情况下, SSMO-SSA-Adaboost 模型容易出现误判, 而 SSMO-SSA-LGBM 模型能精准识别, 识别效果与实际岩性贴切, 识别效果更出色, 预测结果能够作为岩性纵向解释分析的可靠依据。

4 结 论

(1) 针对甘肃华池油田 S 区致密砂岩储层不同岩性类别取心数量不均且测井响应对岩性类别敏感性不足的问题, 提出 SSMO-SSA-LGBM 模型。依




图 8 LGBM 在测试集上使用 SSMO 算法前后的岩性识别结果混淆矩阵

Fig. 8 Confusion matrix of lithology recognition results before and after using SSMO algorithm on the test set for LGBM

a—SSA-LGBM 模型未使用 SSMO 算法前混淆矩阵结果; b—SSA-LGBM 模型使用 SSMO 算法后混淆矩阵结果




图 9 SSMO-SSA-LGBM 模型测试集预测值与真实值对比
Fig. 9 Comparison between predicted and true values in the test set of the SSMO-SSA-LGBM model

据常规测井曲线对不同岩性响应特征及参考前人敏感性参数研究公式依次优选 GR、AC、SP、CNL、DEN、RT 六条测井曲线作为岩性识别工作的核心测井资料。SSMO 算法有效处理少数类岩性样本不均衡问题,采用麻雀优化搜索算法 SSA 对 LGBM 模型进行超参寻优,获得最佳参数组合,使得模型预测性能达到最优。

(2)研究表明,经 SSMO 算法采样处理后,少数类砂砾岩 F1 值提升了 19.6%、粗砂岩 F1 值提升了 12.9%、炭质泥岩 F1 值提升了 23.9%,岩性分类效果明显提升;SSA 模型高效搜寻全局最优解,SSMO-

表 3 各模型使用优化参数

Table 3 Optimization parameters used in various models

模型	KNN	随机森林	Adaboost	LGBM
SSA优化后各模型	metric= euclidean	n_estimators=530	n_estimators=509	boosting_type=GBDT
超参数组合	n_neighbor=5	max_depth=10	learning_rate=0.013	num_leaves=31
	weights= uniform	min_sam_spl=5	algorithm=SAMME	n_estimators=510
		min_sam_leaf=1	base_estimator= CART	learning_rate=0.016

注: metric(距离度量方法); n_neighbor为邻居数量; weights为权重函数; n_estimators为估计器数量(迭代次数); max_depth为决策树最大深度; min_sam_spl为决策树内部节点分裂所需最小样本数; min_sam_leaf为决策树最小叶节点数; base_estimator为基分类器, Adaboost模型默认 base_estimator为CART决策树; Adaboost模型algorithm默认为SAMME; learning_rate为学习率; LGBM默认boosting_type为GBDT; num_leaves为每棵树叶节点数目

表 4 各对比模型在测试集上综合预测结果

Table 4 Comprehensive prediction results of various comparison models on the test set

模型	精确率/%	召回率/%	F1值/%	计算时间/s
SSMO-SSA-KNN	83.77	81.52	82.16	657.423
SSMO-SSA-随机森林	89.21	88.95	88.47	722.337
SSMO-SSA-Adaboost	91.14	90.73	90.25	719.774
SSMO-SSA-LGBM	95.54	94.67	95.13	716.425




图 10 各对比模型在测试集上岩性标签误差结果图

Fig. 10 Error results of lithology and lithology labels for various models

a—SSMO-SSA-Adaboost; b—SSMO-SSA-LGBM; c—SSMO-SSA-随机森林; d—SSMO-SSA-KNN




图 11 各模型岩性识别结果岩性综合柱状图

Fig. 11 Comprehensive column chart of lithology identification results for each model

SSA-LGBM 模型在测试集上预测值与真实值拟合度较高, 与同类型算法相比, LGBM 模型在性能预测和效率上具备较好的平衡性。

(3)SSMO 算法能够解决数据非均衡给岩性预测结果带来的不利影响, 生成更贴近于少数类特征的新合成样本, 模型对于少数类样本特征学习充分, 预测结果提升明显。在 K1 验证井上, SSMO-SSA-LGBM 模型总体符合率最高, 验证该模型应用于致密砂岩储层岩性类别不均衡及敏感性不足问题下岩性识别研究的可行性, 可为同类问题解决提供参考。

致谢: 谨向审稿专家致以诚挚谢意, 感谢他们提出的宝贵改进意见, 使本文方法论的严谨性及结论可靠性得到显著提升。

References

Chen G H, Wu W S, Mao K Y. 2001. Identification of lithology using

geological micro resistivity scanning images[J]. Petroleum Exploration and Development, (2): 53-55,110-111,120 (in Chinese with English abstract).
Cheng C, Li P Y, Chen Y, et al. 2022. Research progress of reservoir logging evaluation based on machine learning[J]. Progress in Geophysics, 37(1): 164-177 (in Chinese with English abstract).
Feng C J, Wang J Y, Feng Q F. 2004. Method of identifying igneous rock lithology using logging data[J]. Journal of Northeast Petroleum University, (4): 9-11,109-110 (in Chinese with English abstract).
Gao B, Zheng Y, Qin J, et al. 2022. Network intrusion detection algorithm based on sparrow search algorithm and improved particle swarm optimization algorithm[J]. Journal of Computer Applications, 42(4): 1201-1206 (in Chinese with English abstract).
Gu Y F, Zhang D Y, Bao Z D. 2021. Lithology prediction of tight sandstone reservoirs using the PSO-GBDT: A case study of the Chang 4+5 members in the Western Jiyuan Oilfield[J]. Bulletin of Mineralogy, Petrology and Geochemistry, 40(3): 624-634 (in Chinese with English abstract).
Gu Y F, Zhang D Y, Bao Z D. 2021. Lithology identification in tight

- sandstone reservoirs using CRBM-PSO-XGBoost[J]. *Oil & Gas Geology*, 42(5): 1210–1222 (in Chinese with English abstract).
- Gu Y F, Zhang D Y, Bao Z D, et al. 2021. Lithology prediction of tight sandstone formation using GS-LightGBM hybrid machine learning model[J]. *Bulletin of Geological Science and Technology*, 40(4): 224–234 (in Chinese with English abstract).
- Han Q D, Zhang X T, Shen W. 2019. Application of support vector machine based on decision tree feature extraction in lithology classification[J]. *Journal of Jilin University(Earth Science Edition)*, 49(2): 611–620 (in Chinese with English abstract).
- Han X H, He Y S, Chen J, et al. 2024. Research on rock lithology intelligent identification based on Swin Transformer[J]. *Modern Electronics Technique*, 47(7): 37–44 (in Chinese with English abstract).
- He Y W, Li W R, Dong Z Z, et al. 2023. Lithologic identification of complex reservoir based on PSO-LSTM-FCN algorithm[J]. *Energies*, 16(5): 21–35 (in Chinese with English abstract).
- Jiang J, Fang L, Zhang H B, et al. 2022. Adaptive multiexpert learning for lithology recognition[J]. *SPE Journal*, 27(6): 3802–3813.
- Li J, Liu, K. Zhou, et al. 2021. An improved deep forest model combining adaptive synthetic sampling for automatic lithology identification[C]//China Automation Congress (CAC): 1215–1220.
- Li X, Fan X Y, Wang Z F, et al. 2022. 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*, 37(2): 617–626 (in Chinese with English abstract).
- Liu K, Zou Z K, Wang Z Z, et al. 2022. Intelligent identification and prediction of lithology of volcanic reservoirs based on machine learning[J]. *Special Oil & Gas Reservoirs*, 29(1): 38–45 (in Chinese with English abstract).
- Luo R Z, Tuo J J, Ni H L, et al. 2023. Logging lithology identification method based on improved ensemble learning[J]. *Geophysical Prospecting for Petroleum*, 62(2): 212–224 (in Chinese with English abstract).
- Ma Z, Zhang C L, Gao S C. 2017. Lithology identification based on principal component analysis and fuzzy recognition[J]. *Lithologic Reservoirs*, 29(5): 127–133 (in Chinese with English abstract).
- Shi S, Yu J F, Cao H T, et al. 2020. Reservoir lithology identification based on SVM using radial basis function: An example of Upper Paleozoic clastic rocks in Dongpu sag[J]. *China Sciencepaper*, 15(1): 112–118, 136 (in Chinese with English abstract).
- Song Z H, Gong H Y, Ran A H, et al. 2024. Lithology logging identification of volcanic rock based on ADASYN-GS-XGBOOST hybrid model[J]. *Marine Origin Petroleum Geology*, 29(2): 188–196 (in Chinese with English abstract).
- Su F, Ma L, Luo R Z, et al. 2020. Research and application of logging lithology identification based on improve multi-class twin support vector machine[J]. *Progress in Geophysics*, 35(1): 174–180 (in Chinese with English abstract).
- Sun X G, Wei W, Li H M. 2012. Fluid sensitivity analysis of petrophysical parameters[J]. *Petroleum Reservoir Evaluation and Development*, 2(1): 37–40, 49 (in Chinese with English abstract).
- Wang H, Jiang Y N, Zhang X, et al. 2021. Lithology identification method based on gradient boosting algorithm[J]. *Journal of Jilin University(Earth Science Edition)*, 51(3): 940–950 (in Chinese with English abstract).
- Wang Z Q, Dong H C, Fan T E, et al. 2021. Logging lithofacies analysis based on unsupervised learning[J]. *Geophysical Prospecting for Petroleum*, 60(3): 403–413 (in Chinese with English abstract).
- Wang Z S. 2022. Research on imbalanced data classification based on ensemble learning[D]. Master's Thesis of Beijing Jiaotong University (in Chinese with English abstract).
- Wu Z Y, Zhang X, Zhang C L, et al. 2021. Lithology identification based on LSTM recurrent neural network[J]. *Lithologic Reservoirs*, 33(3): 120–128 (in Chinese with English abstract).
- Xu F G, Deng S G, Fan Y R, et al. 2006. Overview of the progress in logging evaluation of igneous reservoirs[J]. *Petroleum Reservoir Evaluation and Development*, (4): 239–243, 11.
- Xu Z H, Ma W, Lin P, et al. 2021. Intelligent lithology identification based on transfer learning of rock images[J]. *Journal of Basic Science and Engineering*, 29(5): 1075–1092 (in Chinese with English abstract).
- Xue J K, Shen B. 2020. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. *Systems Science and Control Engineering*, 8(1): 22–34.
- Zhang H, Lu S F, Li W H, et al. 2017. Application of $\Delta\text{Log}R$ technology and BP neural network in organic evaluation in the complex lithology tight stratum[J]. *Progress in Geophysics*, 32(3): 1308–1313 (in Chinese with English abstract).
- Zhang Y, Li M C, Han S. 2018. Automatic identification and classification in lithology based on deep learning in rock images[J]. *Acta Petrologica Sinica*, 34(2): 333–342 (in Chinese with English abstract).
- Zhang T, Li Y P, Liu X Y, et al. 2023. Lithology interpretation of deep metamorphic rocks with well logging based on APSO-LSSVM algorithm[J]. *Progress in Geophysics*, 38(1): 382–392 (in Chinese with English abstract).
- Zhang Z L, Feng Y B, Zhao Z K. 2020. Oversampling method for unbalanced datasets based on SVM[J]. *Computer Engineering and Applications*, 56(23): 220–228 (in Chinese with English abstract).
- Zhao F D, Han Z M, Fu X F, et al. 2024. LogDiffusion: A method of lithology identification based on diffusion probability model[J]. *Progress in Geophysics*: 1–19[2024-09-22] (in Chinese with English abstract).
- Zhao J L. 2008. Principles of logging methods[M]. Shaanxi People's Education Press(in Chinese).
- Zhou Y K, Liu H. 2024. Deep learning based lithology recognition of well logging data[J]. *Uranium Geology*, 40(2): 336–345(in Chinese with English abstract).

附中文参考文献

陈钢花, 吴文圣, 毛克宇. 2001. 利用地层微电阻率扫描图像识别岩

- 性[J]. 石油勘探与开发, (2): 53–55, 110–111, 120.
- 程超, 李培彦, 陈雁, 等. 2022. 基于机器学习的储层测井评价研究进展[J]. 地球物理学进展, 37(1): 164–177.
- 冯翠菊, 王敬岩, 冯庆付. 2004. 利用测井资料识别火成岩岩性的方法[J]. 东北石油大学学报, (4): 9–11, 109–110.
- 高兵, 郑雅, 秦静, 等. 2022. 基于麻雀搜索算法和改进粒子群优化算法的网络入侵检测算法[J]. 计算机应用, 42(4): 1201–1206.
- 谷宇峰, 张道勇, 鲍志东. 2021a. PSO-GBDT 识别致密砂岩储集层岩性研究——以姬塬油田西部长 4+5 段为例[J]. 矿物岩石地球化学通报, 40(3): 624–634.
- 谷宇峰, 张道勇, 鲍志东, 等. 2021b. 利用 GS-LightGBM 机器学习模型识别致密砂岩地层岩性[J]. 地质科技通报, 40(4): 224–234.
- 韩启迪, 张小桐, 申维. 2019. 基于决策树特征提取的支持向量机在岩性分类中的应用[J]. 吉林大学学报(地球科学版), 49(2): 611–620.
- 韩鑫豪, 何月顺, 陈杰, 等. 2024. 基于 Swin Transformer 的岩石岩性智能识别研究[J]. 现代电子技术, 47(7): 37–44.
- 罗仁泽, 庾娟娟, 倪华玲, 等. 2023. 基于改进集成学习的测井岩性识别方法研究[J]. 石油物探, 62(2): 212–224.
- 李曦, 范翔宇, 王兆峰, 等. 2022. 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, 37(2): 617–626.
- 刘凯, 邹正银, 王志章, 等. 2022. 基于机器学习的火山岩岩性智能识别及预测[J]. 特种油气藏, 29(1): 38–45.
- 马峥, 张春雷, 高世臣. 2017. 主成分分析与模糊识别在岩性识别中的应用[J]. 岩性油气藏, 29(5): 127–133.
- 石锁, 余继峰, 曹慧涛, 等. 2020. 基于高斯核 SVM 的储层岩性识别——以东濮凹陷上古生界碎屑岩为例[J]. 中国科技论文, 15(1): 112–118, 136.
- 宋梓豪, 巩红雨, 冉爱华, 等. 2024. 基于 ADASYN-GS-XGBOOST 混合模型的火山岩测井岩性识别[J]. 海相油气地质, 29(2): 188–196.
- 苏赋, 马磊, 罗仁泽, 等. 2020. 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, 35(1): 174–180.
- 孙兴刚, 魏文, 李红梅. 2012. 岩石物理参数的流体敏感性分析[J]. 油气藏评价与开发, 2(1): 37–40, 49.
- 王恒, 姜亚楠, 张欣, 等. 2021. 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), 51(3): 940–950.
- 王宗俊, 董洪超, 范廷恩, 等. 2021. 基于无监督学习的测井岩相分析技术及其应用[J]. 石油物探, 60(3): 403–413.
- 王增帅. 2022. 基于集成学习的不平衡数据分类问题研究[D]. 北京交通大学硕士学位论文.
- 武中原, 张欣, 张春雷, 等. 2021. 基于 LSTM 循环神经网络的岩性识别方法[J]. 岩性油气藏, 33(3): 120–128.
- 许风光, 邓少贵, 范宜仁, 等. 2006. 火成岩储层测井评价进展综述[J]. 油气藏评价与开发, (4): 239–243, 11.
- 许振浩, 马文, 林鹏, 等. 2021. 基于岩石图像迁移学习的岩性智能识别[J]. 应用基础与工程科学学报, 29(5): 1075–1092.
- 张晗, 卢双舫, 李文浩, 等. 2017. ΔLogR 技术与 BP 神经网络在复杂岩性致密层有机质评价中的应用[J]. 地球物理学进展, 32(3): 1308–1313.
- 张涛, 李艳萍, 刘晓宇, 等. 2023. 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, 38(1): 382–392.
- 张野, 李明超, 韩帅. 2018. 基于岩石图像深度学习的岩性自动识别与分类方法[J]. 岩石学报, 34(2): 333–342.
- 赵逢达, 韩滋民, 付晓飞, 等. 2024. LogDiffusion: 一种基于扩散概率模型的岩性识别方法[J/OL]. 地球物理学进展: 1–19 [2024-09-22].
- 赵军龙. 2008. 测井方法原理[M]. 西安: 陕西人民教育出版社.
- 张忠林, 冯宜邦, 赵中恺. 2020. 一种基于 SVM 的非均衡数据集过采样方法[J]. 计算机工程与应用, 56(23): 220–228.
- 周渊凯, 刘祐. 2024. 基于深度学习方法的测井岩性识别研究[J]. 铀矿地质, 40(2): 336–345.