

DOI:10.13232/j.cnki.jnju.2019.06.006

基于相带划分的孔隙度预测

段友祥¹, 柳 璠^{1*}, 孙歧峰¹, 李洪强^{1,2}

(1. 中国石油大学(华东)计算机科学与技术学院, 青岛, 266580;

2. 中国石化集团胜利石油工程有限公司钻井工艺研究院, 东营, 257000)

摘 要: 孔隙度是油藏储层特性评价的重要指标, 储层岩石组成成分不同, 其孔隙结构也相应存在差异. 研究沉积相对孔隙度影响这一重要因素, 提出一种基于相带划分的孔隙度预测方法, 首先利用阻抗数据、采用 k -means 聚类方法进行沉积相估计, 获得储层的相带空间展布特征, 然后对不同相带使用岭回归的方法对孔隙度进行预测. 与其他方法相比, 该方法较好地解决了因岩石物理特性意义不明确而造成的预测中的多解性问题, 提高了预测准确度. 使用实际区块油藏数据对该方法进行了实验验证, 实验结果表明, 该方法可以有效融合地质信息, 预测稳定性高, 受人为因素影响小, 预测的符合度明显高于支持向量回归等其他方法.

关键词: 阻抗数据, 沉积相, 孔隙度预测, k -means 方法, 岭回归

中图分类号: TE122.2

文献标识码: A

Porosity prediction based on sedimentary facies

Duan Youxiang¹, Liu Fan^{1*}, Sun Qifeng¹, Li Hongqiang^{1,2}

(1. College of Computer Science and Technology, China University of Petroleum (East China),

Qingdao, 266580, China; 2. Drilling Technology Research Institute of Shengli Petroleum Engineering

Corporation Limited, Sinopec (SLDTI), Dongying, 257000, China)

Abstract: Porosity is an important index for evaluating reservoir characteristics, and the pore structure varies with the composition of reservoir rocks. This paper studies the important factor of relative porosity of sedimentary facies, and proposes a method of porosity estimation based on facies. Firstly, the impedance data and k -means clustering method are used to estimate sedimentary facies, and the spatial distribution characteristics of reservoir facies zones are obtained. Then, the porosity of different facies zones is predicted by ridge regression method. Compared with other methods, this method solves the problem of multi-solution in prediction, which caused by the uncertainty of the meaning of rock physical properties, and improves the accuracy of prediction. Experiments on real reservoir data show that the method can effectively fuse geological information, it has high prediction stability, and is less affected by human factors. The prediction coincidence is significantly higher than that of support vector regression.

Key words: impedance data, sedimentary facies, porosity estimation, k -means method, ridge regression

孔隙度是岩石中所有孔隙空间体积之和与岩石总体积的比例, 是重要的岩石物理参数之

一^[1-3]. 准确获取孔隙度是进行油藏地层解释和建立地质模型的关键. 孔隙度不仅受控于岩

基金项目: “十三五”国家科技重大专项(2017ZX05009-001)

收稿日期: 2019-07-08

* 通讯联系人, E-mail: 1134494842@qq.com

石的孔隙结构,还与岩石的颗粒组分密切相关^[4],不同的沉积环境下,沉积对岩石形成的作用影响有很大差异.因此,进行相控模式下的孔隙度预测,即以沉积相、沉积特征等约束属性进行岩石孔隙度预测十分必要,也十分重要.

多年来,以岩石物理和地震反演^[4-7]为基础对储层孔隙度属性进行预测是主要的研究方向.近年来人工智能和机器学习方法有了大的发展,并在油气资源领域得到应用,利用机器学习方法的优势开展油藏储层评价成为一个研究热点.在地震属性数据基础上,师政等^[8]基于模糊C均值通过对地震属性聚类而分析岩相展布规律;郝茜茜等^[9]提出基于半监督核均值漂移聚类的地震相自动识别算法.特别是基于机器学习的储层参数回归模型研究也越来越多.Hampson et al^[10]提出使用多种地震属性来建立与孔隙度的关系,并通过多元线性回归以及非线性神经网络来计算工区的孔隙度分布;Helmy et al^[11]将模糊逻辑、SVM(Support Vector Machine)和神经网络进行集成,结合测井资料预测孔隙度;王昕旭^[12]提出将偏最小二乘回归法应用于孔隙度预测.其他的机器学习回归算法如支持向量回归(Support Vector Regression, SVR)^[13]、 k 近邻法^[14]、随机森林(Random Forest, RF)^[15]也被应用于储层预测中,并取得较好的效果.

本文在研究分析相关文献的基础上,重点关注相带对孔隙度影响因素,提出了融合相带信息的孔隙度预测方法,即首先利用聚类方法进行相带划分,然后利用回归模型进行孔隙度预测.将此方法与支持向量回归(SVR)方法对比显示该方法在一定程度上提高了预测的精度,并在孔隙度横向预测上提供可靠的依据.

1 基本思路

孔隙度是油气勘探和生产过程中油藏储层分析研究的一个重要参数.影响岩石孔隙度的因素有很多,其中沉积物的属性和特征(如一致性或序列等)是一个重要的影响因素.相是沉

积环境及在该环境中形成的沉积岩(物)特征的综合,因此准确的相划分及研究和分析是孔隙度预测的重要基础.

聚类是将抽象对象的集合分成由类似的对象组成的多个类的过程,相的划分可用聚类方法实现,其中基本和常用的是理论可靠、算法简单、收敛速度快的 k -means算法^[16].通过研究和分析已知阻抗数据的基本特征和孔隙度的关系影响,确定采用岭回归(Ridge Regression, RR)模型,可以获得理想的孔隙度预测精度.

1.1 k -means聚类 一般情况下,根据钻井数据进行沉积相划分时,对地质人员专业知识要求较高,且对于少井的区域利用有限的钻井数据和地质经验很难进行沉积相的识别. k -means聚类算法作为一种自组织、自学习和高精度划分的分类方法可以较好地解决这一问题.

k -means算法的核心思想是通过不断地迭代,在满足式(1)的条件下,将 n 个已知阻抗数据 $x_j(j=1, \dots, n)$ 构成的数据集分成 k 个类别 $C_i(i=1, \dots, k)$,使得类内对象具有较高的相似度,类间对象的相似度较低,生成的类尽可能紧凑和独立^[17].从式(1)可知,目标函数 E 就是每个数据点与其所在类的类中心的距离总和.算法通过多次迭代得到更小而稳定的 E 值,以此来寻求更好的聚类方案,当 E 收缩到极小值时,会产生更好的聚类效果:

$$\arg \min E = \sum_{i=1}^k \sum_{x_j \in C_i} (x_j - C_i)^2 \quad (1)$$

具体算法略.

1.2 岭回归 回归是一种由少量部分因果数据建立总体因果关系模型的方法.岭回归^[18]是一种通过放弃最小二乘法的无偏性,以损失部分信息、降低精度为代价获得回归系数更为符合实际、更可靠的回归方法,对病态数据的拟合要优于最小二乘法.

岭回归的代价函数如式(2):

$$\min_{\beta \in R^D} J(\beta) = \min_{\beta \in R^D} \frac{1}{2n} \left(\sum_{i=1}^n (y_i - \epsilon - f(x_i; \beta))^2 + \lambda \|\beta\|^2 \right) \quad (2)$$

其中, β 是系数向量, λ 是调节参数, ϵ 是高斯观测噪声.

岭回归的代价函数也是一个凸函数, 利用梯度等于 0 的方式, 使用标记样本集训练可求得全局最优解, 如式(3), 最终得到岭回归模型的最优系数向量 $\hat{\beta}$:

$$\hat{\beta} = (X^T X + \lambda I)^{-1} X^T Y \quad (3)$$

其中,

$X = (x_1, x_2, \dots, x_n)^T$, $Y = (y_1, y_2, \dots, y_n)^T$
 I 为 n 维单位向量. 求得最优参数向量后, 即确定了预测模型, 可以利用该模型对未标记样本集(体素的孔隙度)进行预测.

但需要说明的是, 岭回归是假设数据是独立同分布的, 不考虑数据之间的空间关系, 输入输出之间存在的线性相关关系只能保持在相同的相中, 因此在多相环境下, 直接使用岭回归是很不准确的^[19]. 为了克服岭回归的限制, 需要考虑样本之间的空间关系, 即相邻的样本趋向于属于相同的相, 因此可应用相同的线性关系, 同时每个体素上推断相的类型.

2 具体方法

根据研究的基本思路, 以地震、测井资料为基础的储层孔隙度预测的基本流程如图 1. 首先是数据准备, 即对地震数据及测井数据利用地震反演技术进行阻抗反演, 得到阻抗数据, 通过岩心分析及测井解释计算得到井点孔隙度数据. 然后是数据归一化处理、基于 k -means 的相带划分、回归模型的建立、孔隙度预测等四大步骤. 下面分别详细介绍四个步骤.

2.1 数据的归一化处理 数据分析中, 不同的属性有不同的量纲和量纲单位, 会增加数据分析的难度、影响分析结果的准确性, 因此无量纲的归一化处理是必须的, 目的是将有量纲的表达式变换为无量纲的表达式, 使各指标处于同一标准数量级, 以解决属性之间的可比性问题, 从而可以进行综合对比评价. 常见的归一化处理方法有最值归一化方法、标准分数归一化方法和中值归一化方法. 本文使用标准分数归一

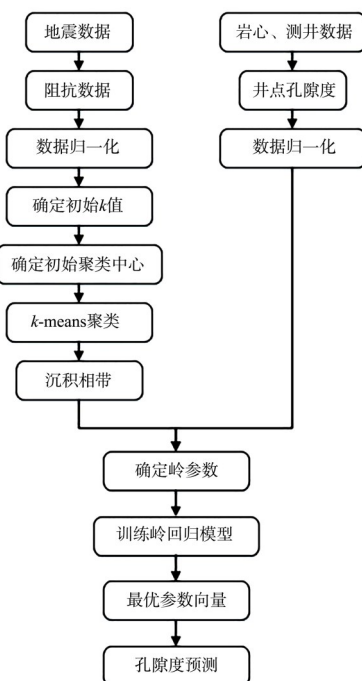


图 1 孔隙度预测流程图

Fig. 1 Flow chart of porosity prediction

法使处理的数据符合均值为 0, 标准差为 1 的标准正态分布, 见式(4):

$$X' = \frac{X - \mu}{\sigma} \quad (4)$$

其中, X 是数据样本, μ 为数据样本的均值, σ 为数据样本的标准差.

2.2 基于 k -means 的相带划分 这一步是为了较准确地获得没有井控制的区域的相带信息. 将阻抗数据切片作为输入数据, 采用聚类中的 k -means 算法进行训练, 最终得到划分的沉积相带.

根据 k -means 算法的基本思想可知, 该算法的关键是聚类数 k 值和初始聚类中心的确定.

2.2.1 初始 k 值的确定 在实际应用中, k 值的确定比较难, 而且, 不一定 k 值越大, 聚类越精细, 预测效果越好. 轮廓系数旨在将样本与其所在簇的相似程度和与其他簇的相似程度进行比较. 轮廓系数最高的簇的数量表示 k 值的最佳选择. 因此本文使用轮廓系数确定初始 k 值, 该值处于 $-1 \sim 1$, 值越大表示聚类效果越好. 计算步骤见算法 1.

算法1 计算轮廓系数

输入:阻抗样本 $D = \{(x_i) \in \mathbb{R}^D\}_{i=1}^n$,划分的簇 C_k
 $(k=1, 2, \dots, K)$
 输出:轮廓系数
 ① $i=0$;
 ② Repeat:
 ③ $i=i+1$;
 ④ 计算样本 x_i 到所属相带中所有其他样本 x_j 的平均距离 a_i ; /* $a_i = \frac{1}{m} \sum_{j=1}^m \|x_j - x_i\|^2$ */
 ⑤ for $k=1, 2, \dots, K$
 ⑥ 计算样本 x_i 到其他相带 C_k 中所有样本 x_j 的平均距离 b_k ; /* $b_{ik} = \frac{1}{m} \sum_{j=1}^m \|x_j - x_i\|^2$ */
 ⑦ 更新样本 x_i 与所有相带 $C_k (k=1, 2, \dots, K)$ 的平均距离的最小值,记为 b_i ; /* $b_i = \min_{j=1, 2, \dots, k} b_{ij}$ */
 ⑧ End for
 ⑨ 计算样本 x_i 的轮廓系数 S_i ; /*

$$S_i = \frac{b_i - a_i}{\max(a_i, b_i)}$$
 */
 ⑩ Until: $i=n$;
 ⑪ 所有样本的轮廓系数取平均值即为当前聚类的总体轮廓系数 S . /* $S = \frac{1}{n} \sum_{i=1}^n S_i$ */

2.2.2 初始聚类中心的确定 质心是各个类别中的中心位置. k -means 是将离散的许多数据点利用 K 个质心进行聚类. 随机选取质心容易造成聚类过程中收敛速度慢或者达到局部最优的结果. 因此,考虑使用 k -means++ 选择初始聚类中心替代随机选择质心. 基本思想是使初始的聚类中心之间的相互距离尽可能远. 具体见算法2.

算法2 k -means++方法选择质心

输入:阻抗样本 $D = \{(x_i) \in \mathbb{R}^D\}_{i=1}^n$,类别数目 K
 输出: K 个簇的质心 C
 ① $C = \Phi$; /*初始化质心*/
 ② $i=0$; /*初始化质心个数*/
 ③ $C = C \cup \{c_1\}$; /*从样本 D 中随机选取一个样本 x_j 作为第一个质心 c_1 ,并划入向量 C 中*/
 ④ Repeat:

⑤ $i=i+1$;
 ⑥ for $j=1, 2, \dots, n$
 ⑦ 计算样本 x_j 到 C 中所有质心距离之和 d_j ; /*

$$d_j = \sum_{k=1}^m \|x_j - c_k\|^2 (1 \leq m \leq K)$$
 */
 ⑧ 更新最大值 $d_{\max} = \max_{\mu=1, 2, \dots, j=2} d_{\mu}$,记录下

标 μ ;

⑨ End for
 ⑩ $C = C \cup \{c_i\}$; /*选择距离之和 d 最大的样本点 x_{μ} 作为第 i 个质心 c_i ,并划入集合 C 中*/
 ⑪ Until: $i=K$

2.3 预测模型的训练和确定 划分相带完成后,使用岭回归的方法对不同的相带经过训练得到不同的孔隙度拟合公式(即预测模型). 训练过程见算法3.

算法3 k -means+RR方法

输入:标签数据 $S = \{(x_i, y_i) \in \mathbb{R}^D \times \mathbb{R}\}_{i=1}^n$,未标签数据 $\mu = \{(x_i) \in \mathbb{R}^D\}_{i=n+1}^{n+m}$
 输出:未标签样本 μ 的类别 π 和孔隙度预测结果 y
 ① 所有数据归一化处理;
 ② 调用算法1,得到初始化分类数目 K ;
 ③ 调用算法2,获得初始化聚类中心 $c_i (i=1, 2, \dots, K)$;
 ④ 使用 k -means 算法将标签样本中的阻抗数据 $x_i (i=1, 2, \dots, n)$ 划分为 K 个沉积相带 $\pi_j (j=1, 2, \dots, K)$;
 ⑤ $j=0$;
 ⑥ Repeat:
 ⑦ $X = \Phi$;
 ⑧ $Y = \Phi$;
 ⑨ $j=j+1$;
 ⑩ for $i=1, 2, \dots, n$;
 ⑪ If $x_i.label = \pi_j$ then $X = X \cup \{x_i\}$ and $Y = Y \cup \{y_i\}$; /*如果样本 x_i 的类别标签为 π_j ,则将阻抗样本加入 X 中以及将该样本孔隙度标签加入 Y 中*/
 ⑫ End if
 ⑬ End for
 ⑭ 设定岭参数 λ ;
 ⑮ 对该相带内的样本进行岭回归训练得到该相带下的最优参数向量 $\hat{\beta}_j$; /* $\hat{\beta}_j = (X^T X + \lambda I)^{-1} X^T Y$ */
 ⑯ Until: $j=K$

2.4 孔隙度预测 利用训练得到预测模型(由最优参数向量 $\hat{\beta}$ 决定)对未标签样本 μ 进行孔隙度估计,得到最终预测结果 $y=(y_{n+1}, \dots, y_{n+m})^T$.


3 实验及分析

为了验证该方法的可靠性和准确性,本文使用 Lima et al^[19]位于巴西近海沿岸的真实碳酸盐储层进行实验. 该储层占地面积约 100 ha, 深度 460 m, 是沉积岩层的一部分, 其沉积模型如图 2 所示. 它包含一个碳酸盐台地, 其逐渐变浅的周期与沉降、盐体构造和海平面振荡密切相关, 包括 $313 \times 549 \times 74$ 个声阻抗样本和四口井, 存在三个相. 阻抗输入切片如图 3 所示. 实验得到的结果与利用传统的地质统计学方法, 即协克里金方法得到的预测结果作为参考进行对比验证.

首先, 通过计算轮廓系数确定划分的类别数 k . 图 4 是 k 值取 2~10 时轮廓系数的变化情况. 轮廓系数越大, 聚类效果越好. 当 k 为 2 时, 轮廓系数最大, 所以在本实验中设定 $k=2$.

然后, 利用 k -means 方法进行相估计, 结果如图 5 所示. 其中, 黄色的为砂岩相, 蓝色的为页岩相. 可以看出, k -means 方法得到的沉积相估计结果符合地质规律, 能够大致勾画出相带的轮廓, 清晰地分离出页岩相和砂岩相.

最后, 分别利用本文提出的 k -means+RR



(A) terrigenous tidal plain, (B) wackstones, (C) oolitic grainstones, (D) peloidal packstones, (E) oncolytic packstones, (F) wackstones (open sea)

图 2 沉积模型

Fig. 2 Depositional model




图 3 阻抗输入切片

Fig. 3 Impedance input slice




图 4 轮廓系数分析

Fig. 4 Silhouette coefficient analysis




图 5 相估计

Fig. 5 Facies estimation

方法以及 MeanShift+RR 方法、SVR 方法、岭回归方法等进行孔隙度预测实验,并从平均绝对误差(Mean Absolute Error, *MAE*)、均方差(Mean Square Error, *MSE*)、中位数绝对偏差(Median Absolute Deviation, *MADE*)、确定性相关系数(R^2)四个方面对比各方法的性能。*MAE*用于凸显异常值的情况, *MSE*是预测数据和实际数据对应点误差的平方和的均值, *MADE*是单变量数据集中样本差异性的稳健度量, R^2 是预测结果与实际数据的拟合情况。实验结果如图6和表1。图6a是实际的孔隙度,图6b是 *k*-means+RR 方法预测的孔隙度,图6c是 MeanShift+RR 方法预测的孔隙度,图6d是 SVR 方法预测的孔隙度,图6e是岭回归方法预测的孔隙度。可以看出,SVR、岭回归方法预测的孔隙度低值(蓝色部分)并不符合实际结果(图6d和图6e),而相控法则能较准确地预测孔

隙度(图6b和图6c)。从表1可知, *k*-means+RR 方法更接近于真实值, R^2 达到0.90,而 *MSE*相对比回归方法来说也更低,当消除异常点的干扰时, *k*-means+RR 方法的 *MADE*比 SVR 和 RR 方法小接近一半。因此可以看出 *k*-means+RR 的性能更优。

同时,把四种方法的预测结果与传统地质统计学方法得到的结果进行交叉对比,如图7所示。其中,图7a是 *k*-means+RR 与地质统计学的预测结果交汇图,图7b是 MeanShift+RR 与地质统计学的预测结果交汇图,图7c是 SVR 与地质统计学的预测结果交汇图,图7d是 RR 与地质统计学的预测结果交汇图。可以看出, *k*-means+RR 方法的相关系数达到0.92,高于其他三种方法与地质统计学方法之间的相关系数。因此,本文提出的 *k*-means+RR 方法得到的结果与地质统计学的结果更为吻合。

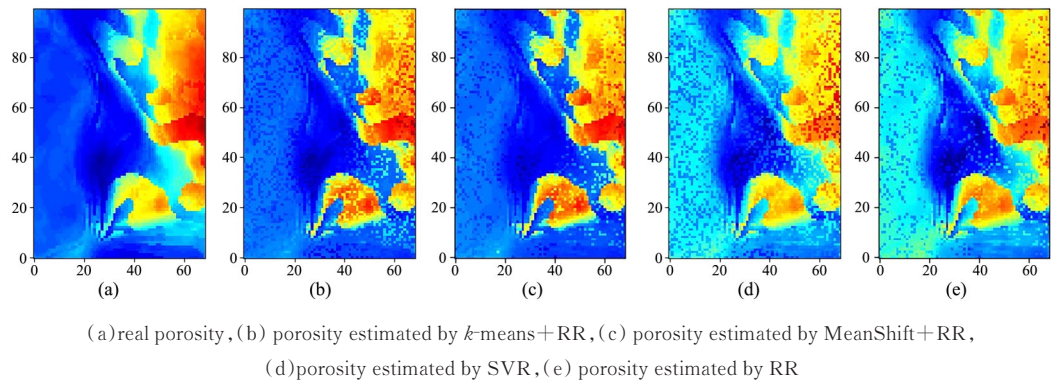
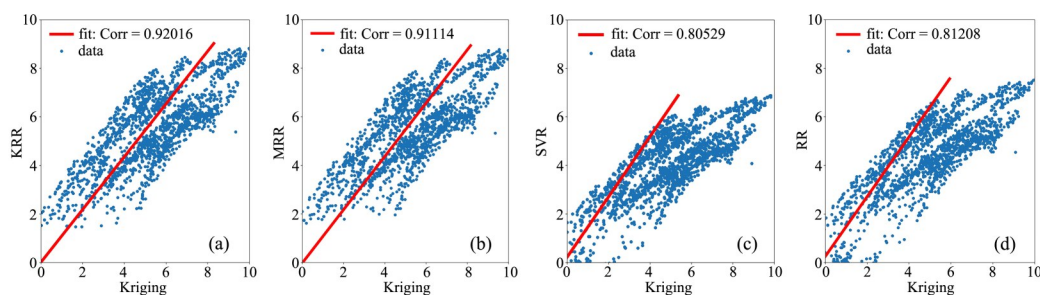


图6 孔隙度预测结果

Fig. 6 Porosity estimation results

表1 四种方法的性能比较

方法	<i>MAE</i>	<i>MSE</i>	<i>MADE</i>	R^2
<i>k</i> -means+RR	0.92128	1.34466	0.76712	0.90566
MeanShift+RR	0.93917	1.34847	0.77563	0.90539
SVR	1.29394	2.22002	1.32370	0.83577
RR	1.33315	2.32215	1.37887	0.83708



(a) crossplot between k -means+RR and geostatistics, (b) crossplot between MeanShift+RR and geostatistics, (c) crossplot between SVR and geostatistics, (d) crossplot between RR and geostatistics

图 7 地质统计学与四种方法预测的孔隙度交汇图

Fig. 7 Porosity crossplots of geostatistics and four methods

4 结 论

孔隙度是地层解释和地质建模的基础和关键,但是传统的地质统计学方法耗时且无法解释大数据量的地质信息,而机器学习技术可以对庞大的地震数据进行优化处理.本文针对不同沉积环境对孔隙度的影响,提出了基于相带划分的机器学习孔隙度预测方法,先利用 k -means聚类进行相带划分,再对单一相带中的数据与孔隙度值利用岭回归方法进行拟合,建立预测模型.实验结果及分析表明,该方法不仅可以有效识别沉积相,且在此基础上的孔隙度预测精度比仅使用回归方法的精度更高.随着机器学习的发展,必将会受到越来越多的关注, k -means与岭回归结合在孔隙度预测中的成功应用为储层预测提供新的思路,需要进一步研究机器学习其他方法在储层预测中的应用.

参考文献

- [1] Gholami A, Ansari H R. Estimation of porosity from seismic attributes using a committee model with bat-inspired optimization algorithm. *Journal of Petroleum Science and Engineering*, 2017, 152: 238—249.
- [2] Miller K, Vanorio T, Yang S, et al. A scale-consistent method for imaging porosity and micrite in dual-porosity carbonate rocks. *Geophysics*, 2019, 84(3), doi:10.1190/geo2017-0812.1.
- [3] Arévalo - López H S, Dvorkin J P. Porosity, mineralogy, and pore fluid from simultaneous impedance inversion. *The Leading Edge*, 2016, 35 (5):423—429.
- [4] 刘云,贺振华,汪瑞良等.基于地震相分析的孔隙度预测. *物探化探计算技术*, 2010, 32(4): 359—364. (Liu Y, He Z H, Wang R L, et al. Porosity prediction based on seismic facies analysis. *Computing Techniques for Geophysical and Geochemical Exploration*, 2010, 32(4): 359—364.)
- [5] De Figueiredo L P, Grana D, Santos M, et al. Bayesian seismic inversion based on rock-physics prior modeling for the joint estimation of acoustic impedance, porosity and lithofacies. *Journal of Computational Physics*, 2017, 336: 128—142.
- [6] 于正军,董冬冬,宋维琪等.相带控制下协克里金方法孔隙度预测. *地球物理学进展*, 2012, 27(4): 1581—1587. (Yu Z J, Dong D D, Song W Q, et al. Porosity prediction with co-Kriging method controlled by sedimentary facies. *Progress in Geophysics*, 2012, 27(4): 1581—1587.)
- [7] Mahgoub M I, Padmanabhan E, Abdullatif O M. Facies and porosity 3D models constrained by stochastic seismic inversion to delineate Paleocene fluvial/lacustrine reservoirs in Melut Rift Basin, Sudan. *Marine and Petroleum Geology*, 2018, 98: 79—96.
- [8] 师政,邱隆伟,张阳等.基于地震属性聚类的岩相分析方法及应用——以南堡凹陷奥陶系潜山储层为例. *中国矿业大学学报*, 2015, 44(4): 688—695. (Shi Z, Qiu L W, Zhang Y, et al. Petrographic analysis method and application based on seismic

- attributes cluster:taking Ordovician buried hill reservoir in Nanpu sag for example. *Journal of China University of Mining & Technology*, 2015, 44(4): 688—695.)
- [9] 郝茜茜,周亚同,任婷婷. 基于半监督核均值漂移聚类的地震相识别研究. *河北工业大学学报*, 2017, 46(6): 6—12. (Hao X X, Zhou Y T, Ren T T. Research on seismic facies identification based on semi-supervised kernel mean shift clustering. *Journal of Hebei University of Technology*, 2017, 46(6): 6—12.)
- [10] Hampson D P, Schuelke J S, Quirein J A. Use of multiattribute transforms to predict log properties from seismic data. *Geophysics*, 2001, 66(1): 220—236.
- [11] Helmy T, Fatai A, Faisal K. Hybrid computational models for the characterization of oil and gas reservoirs. *Expert Systems with Applications*, 2010, 37(7): 5353—5363.
- [12] 王昕旭. 偏最小二乘回归在孔隙度预测中的应用. *地球物理学进展*, 2015, 30(6): 2807—2813. (Wang X X. Partial least-squares regression for the application in porosity prediction. *Progress in Geophysics*, 2015, 30(6): 2807—2813.)
- [13] Saffarzadeh S, Shadizadeh S R. Reservoir rock permeability prediction using support vector regression in an Iranian oil field. *Journal of Geophysics and Engineering*, 2012, 9(3): 336—344.
- [14] Oyewole E, Saneifar M, Heidari Z. Multiscale characterization of pore structure in carbonate formations: application to the scurry area canyon reef operators committee unit. *Interpretation*, 2016, 4(2): 157—169, doi: 10.1190/INT - 2015 - 0123.1 .
- [15] Baziari S, Shahripour H B, Tadayoni M, et al. Prediction of water saturation in a tight gas sandstone reservoir by using four intelligent methods: a comparative study. *Neural Computing and Application*, 2018, 30(4): 1171—1185.
- [16] 赖玉霞,刘建平. K-means算法的初始聚类中心的优化. *计算机工程与应用*, 2008, 44(10): 147—149. (Lai Y X, Liu J P. Optimization study on initial center of K-means algorithm. *Computer Engineering and Applications*, 2008, 44(10): 147—149.)
- [17] 张莹,陈普春,曹俊等. 基于K-means岩石铸体图像分割及孔隙度的计算. *现代电子技术*, 2012, 35(6): 141—143. (Zhang Y, Chen P C, Cao J, et al. K-means-based rock casting image segmentation and calculation of porosity. *Modern Electronics Technique*, 2012, 35(6): 141—143.)
- [18] Luo H, Liu Y H. A prediction method based on improved ridge regression//*Proceedings of 2017 8th IEEE International Conference on Software Engineering and Service Science*. Beijing, China: IEEE, 2017: 596—599.
- [19] Lima L Z, Görnitz N, Varela L E, et al. Porosity estimation by semi-supervised learning with sparsely available labeled samples. *Computers & Geosciences*, 2017, 106: 33—48.

(责任编辑 杨可盛)