石油科学通报
Petroleum Science Bulletin

滨里海盆地东缘中区块碳酸盐岩储层渗透率预测研究

赵培强[1,2]，李长文[3]，沙峰[2,4]，张莉莉[3]，毛志强[1,2*]，蒋新宇[3]

1 中国石油大学(北京)油气资源与探测国家重点实验室，北京 102249
2 中国石油大学(北京)地球探测与信息技术北京市重点实验室，北京 102249
3 中国石油集团测井有限公司国际事业部，北京 102206
4 长城钻探工程有限公司国际测井公司，北京 100101
* 通信作者, maozq@cup.edu.cn

收稿日期: 2019–08–23
中国石油集团测井有限公司项目“乍得、尼日尔复杂油气层测井评价技术研究与应用”(2016D–4502) 资助

摘要 滨里海盆地东缘中区块石炭系KT–II碳酸盐岩储层孔隙类型复杂多变，导致利用毛管压力曲线准确预测渗透率困难。本文开展了基于毛管压力曲线的Purcell模型、Swanson参数、Capilliary–parachor参数、R_{25}、R_{35}、R_{50}等 6 种渗透率预测模型在研究区的适用性分析。在此基础之上，以孔隙度和毛管压力曲线特征参数等 7 个敏感性参数作为输入向量，利用基于粒子群参数优化的支持向量机方法预测渗透率。研究表明，传统的渗透率模型应用效果差，Purcell模型虽然优于其它几种模型，其预测值与测量值间的确定系数仅为 0.763；支持向量机方法预测的渗透率效果良好，训练样本、测试样本的预测结果与测量值的确定系数分别为 0.917 和 0.883，且相对误差多小于 30%，在一定程度上克服了传统渗透率模型对碳酸盐岩储层适用性差的缺陷，为储层评价提供有效信息。

关键词 碳酸盐岩储层；渗透率预测；毛管压力曲线；支持向量机

Study of permeability prediction of carbonate reservoirs in the middle block of the eastern margin of the Caspian Basin

ZHAO Peiqiang[1,2], LI Changwen[3], SHA Feng[2,4], ZHANG Lili[3], MAO Zhiqiang[1,2], JIANG Xinyu[3]

1 State Key Laboratory of Petroleum Resources and Prospecting, China University of Petroleum-Beijing, Beijing 102249, China
2 Beijing Key Laboratory of Earth Prospecting and Information Technology, China University of Petroleum-Beijing, Beijing 102249, China
3 CNPC Logging International Division, Beijing 102206, China
4 International Logging Company, CNPC Greatwall Drilling Company, Beijing 100101, China

Abstract The pore types of Carboniferous KT-II carbonate reservoirs in the middle block of the eastern margin of the Caspian Basin are complex and variable, which makes it difficult to predict the permeability accurately. In the studied area, application analysis was undertaken of six permeability prediction models based on capillary pressure curves. These were the Purcell model, Swanson parameter, capillary-parachor parameter, R_{25}, R_{35} and R_{50}. On this basis, seven sensitive parameters including porosity and other parameters obtained from capillary pressure curve are selected as input vectors, and the particle swarm optimization support vector machine (PSO-SVM) method is used to predict permeability. Results show that the traditional permeability models provide unreasonable results. Although the Purcell model is superior to other models, the coefficient of determination

引用格式：赵培强, 李长文, 沙峰, 张莉莉, 毛志强, 蒋新宇. 滨里海盆地东缘中区块碳酸盐岩储层渗透率预测研究. 石油科学通报, 2020, 01: 39−48
ZHAO Peiqiang, LI Changwen, SHA Feng, ZHANG Lili, MAO Zhiqiang, JIANG Xinyu. Study of permeability prediction of carbonate reservoirs in the middle block of the eastern margin of the Caspian Basin. Petroleum Science Bulletin, 2020, 01: 39-48. doi: 10.3969/j.issn.2096-1693.2020.01.004

©2016—2020 中国石油大学(北京) 清华大学出版社有限公司

between predicted and measured results is only 0.763. The permeability predicted by support vector machine is reliable. The coefficients of determination of predicted results of training samples and test samples with measured values are 0.913 and 0.854, respectively. The proposed method overcomes the shortcomings of the traditional permeability model to carbonate reservoirs to a certain extent, and provides valuable information for formation evaluation.

Keywords carbonate reservoir; permeability prediction; capillary pressure curve; support vector machine

doi: 10.3969/j.issn.2096-1693.2020.01.004

0 引言

碳酸盐岩储层在世界油气分布中占有重要地位，全球碳酸盐岩储层的油气产量约占油气总产量的60%[1]。滨里海盆地东缘中区块位于哈萨克斯坦阿克纠宾州让纳若尔油田东南地区。东缘中区块是油气运移的重要指向区带，区域构造位置十分有利。碳酸盐岩储层是其重要的勘探开发层组，主要发育在石炭系KT−I和KT−II层段，岩性包括泥质灰岩、石灰岩和灰质白云岩等[2]。KT−I层可划分为A、Б和B三个油层组，KT−II层纵向上分为Г、Д两个油层组。渗透率反映多孔介质岩石运输流体的能力，是储层评价和开发最重要的参数之一[3]。准确的渗透率评价可有效地提高油气的勘探开发效率。然而，中区块碳酸盐岩储层岩性比较复杂、孔隙类型多样，包括粒间(溶)孔、粒内溶孔、晶间孔和裂缝等，导致渗透率的准确计算存在一定困难。

毛管压力曲线可反映岩石的孔喉结构分布及喉道连通性等特征，因此，毛管压力曲线某些特征参数与渗透率具有相关性[4]。岩石的渗透率确定除了实验室直接测量外，国外学者提出许多基于毛管压力曲线的渗透率计算模型。Purcell[5]基于泊肃叶方程和达西定律提出一种基于孔隙度和毛管压力曲线的渗透率模型，简称“Purcell模型”。此外，有研究学者相继提出Swanson、Capilliary−parachor、R_{25}、R_{35}、R_{50}等参数[6−10]。由于这些参数与渗透率存在较好的相关关系，它们在碳酸盐岩和砂岩渗透率预测中具有广泛的应用。但是这些预测模型常常结合孔隙度及单一毛管压力曲线参数计算渗透率，未能充分利用毛管压力曲线的有效信息，导致它们在本研究区应用效果较差。

本文以滨里海盆地东缘中区块石炭系KT−II层段碳酸盐岩储层为例，分析几种常见的基于毛管压力曲线计算渗透率的模型应用效果。在此基础上，利用粒子群参数优化−支持向量机方法预测渗透率，并验证其准确性及有效性。

1 储层孔隙度、渗透率和毛管压力曲线特征

如图1所示，岩心物性测量结果统计分析表明，KT−II储层岩石孔隙度主要变化于7%~17%，平均孔

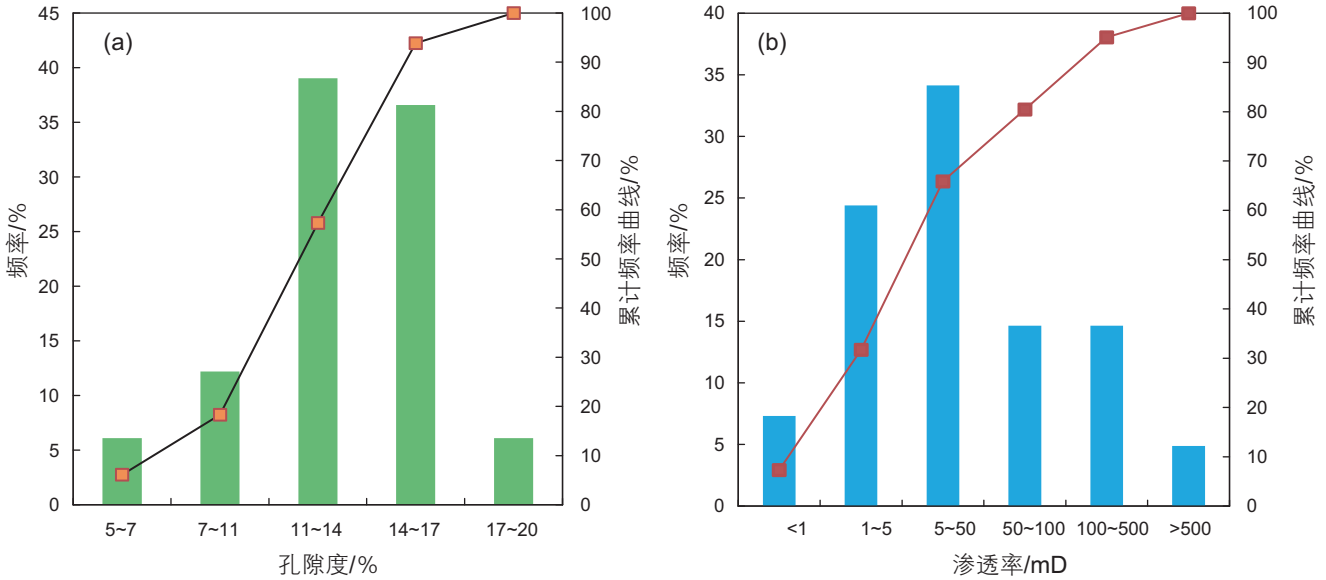

图1 KT-II储层孔隙度和渗透率分布直方图(a)孔隙度分布;(b)渗透率分布

Fig. 1 Porosity and permeability distribution histograms in KT-II reservoir (a) porosity distribution; (b) permeability distribution

隙度为 12.88%。渗透率主要介于 1~500 mD，渗透率的对数平均值为 17.62 mD。孙宝佃等[11]将渗透率为 1~50 mD的储层定义低渗透储层，因此，KT−II储层总体上属于低孔低渗储层。以样品孔隙度和渗透率从小至大的累计频率 5%左右为下限值，由于样品数量较少，KT−II储层的孔隙度下限值大致为 7%，渗透率下限值小于 1 mD。图 2 为岩石孔隙度和渗透率的交会图，由图可知孔隙度和渗透率相关性较差。

通过对毛管压力曲线形态分析，可以获得孔喉的定性特征和定量特征。80 块岩样的毛管压力曲线结果表明，KT−II碳酸盐岩储层驱替压力介于 0.0079~10.09 MPa，平均值为 0.295 MPa；中值压力介于 0.046~16.28 MPa，平均值为 1.12 MPa；中值毛管半径分布于 0.046~16.3 μm，平均值为 3.25 μm。最大进汞饱和度分布于 64.38~99.89%之间，平均值 92.21%。实验时最大进汞压力为 200 MPa，对应的最小孔喉半径大约为 3.7 nm。总体上，KT−II储层的孔隙结构特征中等至差。图 3 为岩石的压汞毛管压力曲线。根据毛管压力曲线形态将可其分为两类，图 3a中毛管压力曲线驱替压力大，中值半径小，其孔喉结构较差；而图 3b中位于下部的毛管压力曲线驱替压力小，中值半径大，孔喉结构较好。

2 基于毛管压力曲线的渗透率模型

Purcell基于泊肃叶方程和达西定律，推导出与孔隙度和毛管压力曲线有关的渗透率计算方程，该方程如下[5]：

$$K=(\sigma\cos\theta)^2\phi\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2} \tag{1}$$

其中，K为渗透率，mD；ϕ为孔隙度，小数；σ为界面张力，dyn(10^{-5}N)/cm；θ为汞和空气的接触角；S_i为汞饱和度增量，小数；P_{ci}为第i个毛管压力，MPa。

基于Thomeer等[12]针对毛管压力曲线的研究，Swanson[6]进一步分析毛管压力曲线特征，认为进汞饱和度S_{hg}与毛管压力P_c的比值最高点$\left(\frac{S_{hg}}{P_c}\right)_{max}$与渗透率具有较好相关性，该值称为Swanson参数[13−14]。Swanson参数与岩石渗透率具有如下关系[6]：

$$K=a\times\left(\frac{S_{hg}}{P_c}\right)_{max}^{b} \tag{2}$$

式中，a和b为拟合系数。

Guo等[7]在分析进汞饱和度S_{hg}与S_{hg}和毛管压力P_c的平方比值$\frac{S_{hg}}{P_c^2}$的交会图时，发现最大值$\left(\frac{S_{hg}}{P_c^2}\right)_{max}$与渗透率有关。$\left(\frac{S_{hg}}{P_c^2}\right)_{max}$能够反映岩石的某些孔隙结构特征，称为Capillary−parachor参数，它与渗透率同样具有幂函数的关系[7]：

$$K=m\times\left(\frac{S_{hg}}{P_c^2}\right)_{max}^{n} \tag{3}$$

式中，m和n为拟合系数。

Kolodzie[8]指出在砂岩和碳酸盐岩储层参数R_{35}与渗透率的关系较好。R_{35}是指进汞饱和度为 35%时对应的孔喉半径。该文中渗透率和R_{35}的经验公式如下：

$$\log R_{35}=0.732+0.588\log K-0.864\log\phi \tag{4}$$

类似地，Pittman[9]和Rezaee等[10]认为R_{25}和R_{50}对渗透率的贡献也较大，R_{25}和R_{50}分别为进汞饱和度为 25%和 50%时所对应的孔喉半径。渗透率与R_{25}和R_{50}的经验关系分别为

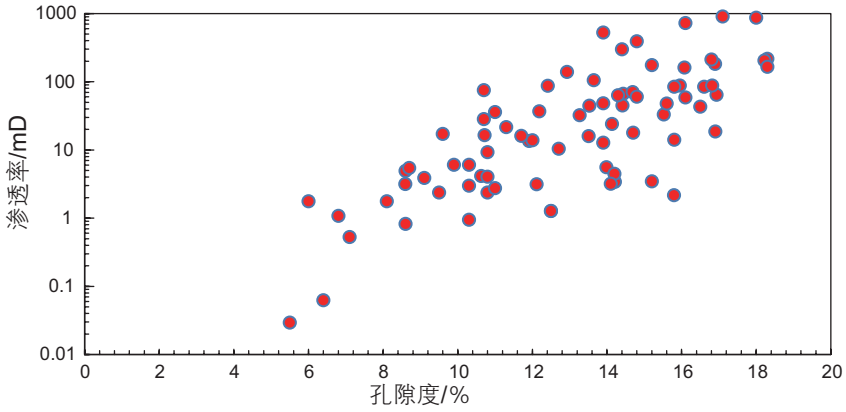

图 2 KT-II储层孔隙度和渗透率关系

Fig. 2 Relationship between porosity and permeability in KT-II reservoir

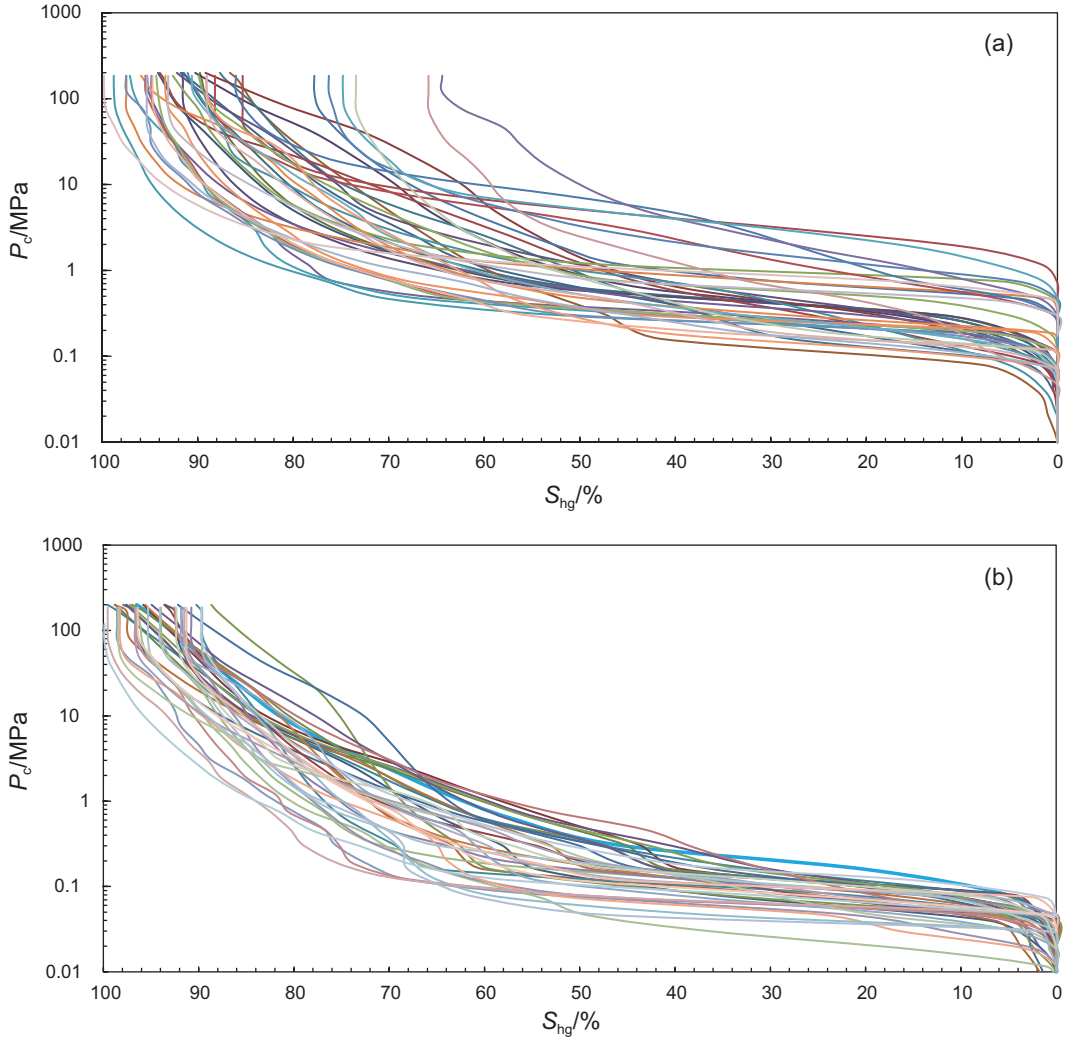

图 3 KT–II 储层毛管压力曲线形态 (a) 孔隙结构较差；(b) 孔隙结构较好

Fig. 3 Mercury intrusion capillary pressure curves in KT–II reservoir (a) pore structure is relatively poor; (b) pore structure is relatively good

$$\log K = -1.221 + 1.415\log\phi + 1.512\log R_{25} \quad (5)$$

$$\log K = -1.16 + 1.78\log\phi + 0.93\log R_{50} \quad (6)$$

利用式(1)对研究区渗透率进行计算，计算结果与岩心测量的渗透率对比如图 4 所示，确定系数 R^2 为 0.763。由于式(2)~(6)均为经验公式，因此，对研究区域的岩心数据进行重新拟合，拟合结果及相应的确定系数如表 1 所示。从图 4 和表 1 看，上述几种模型预测的渗透率效果不是很理想，确定系数 R^2 均低于 0.8，而其中相关系数最高的模型是Purcell模型预测的结果，其值为 0.763 且误差较大。由此可见，现有模型无法满足实际需求，需对渗透率计算开展进一步的研究。

之所以出现较差的计算效果，可能是由于Purcell、Swanson和Capillary−parachor等参数模型主要针对以粒间孔为主的砂岩储层建立的。而研究区储层孔隙类型比较复杂，除了粒间孔、粒内孔外，还包括晶间孔、粒内孔、体腔孔、构造缝、溶蚀缝、粒裂纹和压溶缝等。图 5 为岩石铸体薄片显示的粒间溶孔和粒内溶孔，图 6 所示为岩石铸体薄片的裂缝发育特征。详细的孔隙类型研究可参照Sha等人的研究[15]。何伶等[2]的研究也证明了滨里海盆地台地相碳酸盐岩储层孔隙类型复杂是造成孔—渗关系复杂的主要原因，以不同孔隙类型为主的岩石孔渗相关性不同，如粒间—粒内孔为主的灰岩孔渗相关性好于以铸模孔为主的岩石孔渗相关性。因此，传统的毛管束模型对碳酸岩盐储层的适用性比较差。为了更加准确地预测渗透率，需要在模型中融合更多的渗透率相关信息。

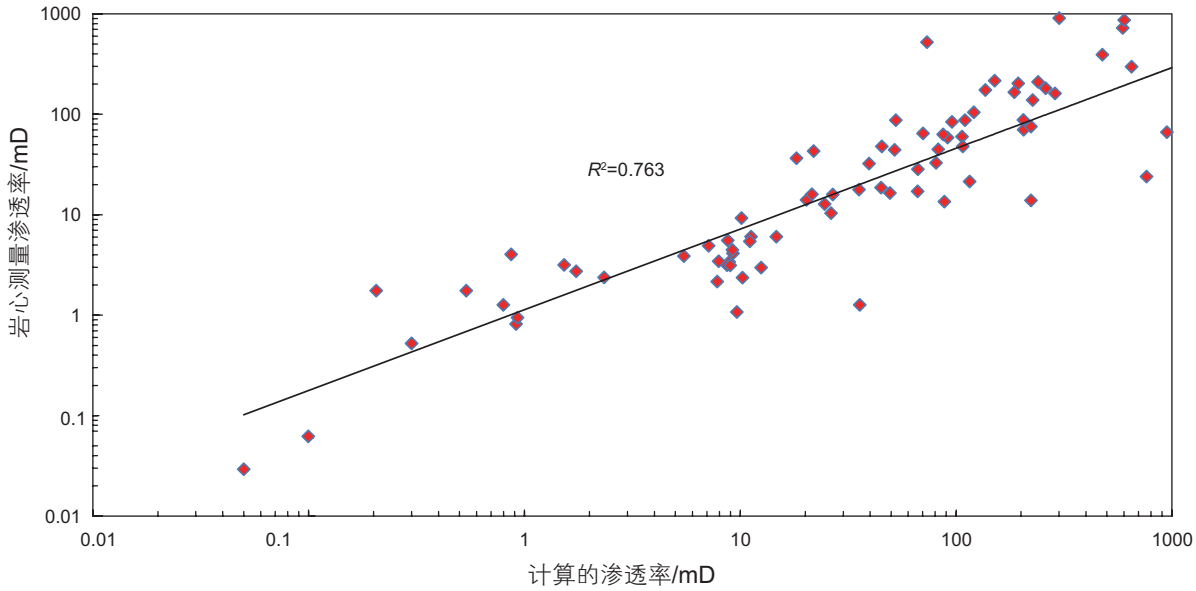

图 4　Purcell模型计算的渗透率与测量的渗透率对比

Fig. 4　Comparison of calculated permeability by Purcell model and measured permeability

表 1　各种渗透率模型的拟合结果

Table 1　Fitting results for various permeability models

模型	拟合公式	确定系数 R^2
Swanson	$K=8.597\times\left(\frac{S_{hg}}{P_c}\right)_{max}^{1.524}$	0.697
Capillary parachor	$K=3.445\times\left(\frac{S_{hg}}{P_c^2}\right)_{max}^{0.757}$	0.669
R_{25}	$\log K=-2.291+2.645\log\phi+1.078\log R_{25}$	0.755
R_{35}	$\log K=-2.168+2.661\log\phi+1.036\log R_{35}$	0.751
R_{50}	$\log K=-2.287+3.022\log\phi+0.884\log R_{50}$	0.725

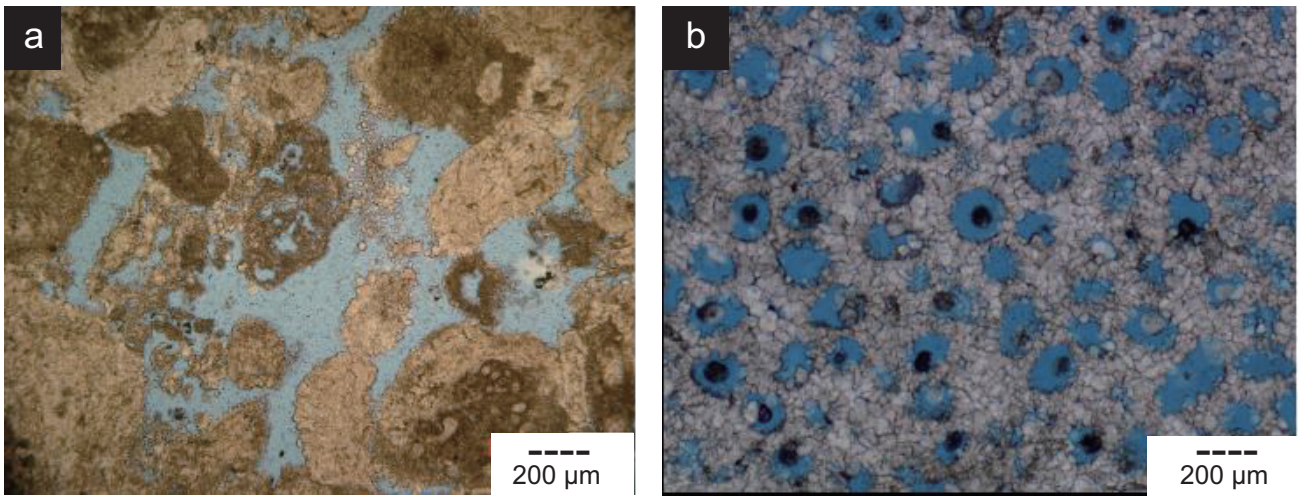

图 5　粒间溶孔和粒内溶孔[15] (a) 亮晶红藻有孔虫颗粒灰岩，粒间溶孔发育；(b) 亮晶铸模鲕粒灰岩，鲕模孔占绝大多数

Fig. 5　Intergranular and intragranular dissolution pores. (a) sparry red algae foraminifera granules limestone, intergranular dissolution pores; (b) sparry cast oolitic limestone, ooids modic pores

图 6 裂缝发育特征[15] (a) 亮晶铸模鲕粒灰岩，溶蚀缝；(b) 垂向扩展缝；(c) 构造缝；(d) 缝合线

Fig. 6 Fracture characteristics in the study area (a) spray oolitic limestone, dissolution fracture; (b) vertical extension fracture; (c) oblique tectonic fracture; (d) stylolite

3 基于支持向量机的渗透率预测

3.1 支持向量机基本原理

支持向量机(support vector machine，SVR)是一种机器学习方法，常用于解决小样本、高维模式识别的非线性预测问题，具有许多独特的优点，这些特性可以保证更好的泛化[16–18]。支持向量机既可用于分类问题，也可用于回归问题。回归问题模型训练的目的是给出的回归函数能够使得在一定的限制条件下(限制条件由惩罚因子提供)，相应的目标值与实际值之间的偏差总和尽量小。由于支持向量机具有坚实的理论基础，其预测效果较好。

对于回归问题，假设训练数据集(x_i, y_i), i=1, 2⋯, n。$x_i \in \mathbf{R}^n, y_i \in \mathbf{R}$，线性的支持向量机问题为：

$$f(\boldsymbol{x}) = <\boldsymbol{\omega}, \boldsymbol{x}> + b, \boldsymbol{\omega} \in \mathbf{R}^n, b \in \mathbf{R} \tag{7}$$

其中，Epsilon支持向量机的目标是寻找函数$f(\boldsymbol{x})$评价输出结果，与训练样本的偏差小于误差ε。支持向量机回归方程转化为优化问题[17]：

$$\min \frac{1}{2}\|\omega\|^2 + C\sum_{i=1}^{n}\xi_i$$
$$\begin{cases} y_i - <\omega, x_i> - b \leqslant \varepsilon + \xi_i \\ <\omega, x_i> + b - y_i \leqslant \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* > 0 \end{cases} \tag{8}$$

式中C为惩罚因子，ξ_i, ξ_i^*为惩罚拟合函数的松弛变量。

通过优化算法求解出方程(8)，因此，回归模型可通过拉格朗日函数构建[16]：

$$\omega = \sum_{i=1}^{n}(\alpha_i - \alpha_i^*)\boldsymbol{x_i}$$
$$f(\boldsymbol{x}) = \sum_{i=1}^{n}(\alpha_i - \alpha_i^*) < \boldsymbol{x_i}, \boldsymbol{x} > + b \tag{9}$$
$$b = \begin{cases} y_i - <\omega, x_i> - \varepsilon & \alpha_i \in (0, C) \\ y_i - <\omega, x_i> + \varepsilon & \alpha_i^* \in (0, C) \end{cases}$$

对于非线性问题，支持向量机将原空间样本数据通过非线性变换$\phi(\boldsymbol{x})$映射到高维特征空间，寻求回归方程[19]。这个过程中需引入核函数，常用的核函数有多项式、高斯函数和sigmoid函数[20]。通常，高斯函数具有较好的应用效果，本文选择高斯函数作为核函数，高斯函数也称为径向基函数，其表达式为[20]：

$$K\left(x_i,x_j\right)=\exp\left(-\gamma\left\|x_i-x_j\right\|^2\right),\gamma>0 \tag{10}$$

3.2 粒子群算法优选参数

惩罚因子C和径向基函数的参数γ决定了支持向量机的回归效果，因此，在进行支持向量机回归时，需要优选这两个参数。研究人员通常使用遗传算法(genetic algorithm, GA)、粒子群算法(particle swarm optimization, PSO)等进行参数优选[21-22]。由于PSO算法具有简便、参数少、快速达到全局最优等特点，本文利用PSO算法对参数(C, γ)进行寻优。

粒子群算法是一种基于群体智能的方法，利用个体之间以及个体与群体之间的信息交互进行群体演化，进而得到最优解。它的基本思想是：首先初始化一群粒子作为优化问题的潜在解，每个粒子在群体中的位置和移动速度信息用O_i和V_i表示，并计算得到相应的适应度fit_i，然后粒子通过目前的个体最佳位置$p_{i\text{best}}$和群体最佳位置$g_{i\text{best}}$控制自己下一步迭代的位置和移动速度进行寻优，直到寻找到最优解。迭代过程中速度和位置更新公式为[22]：

$$V_i^{l+1}=wV_i^l+c_1r_1\left(p_{i\text{best}}^l-O_i^l\right)+c_2r_2\left(g_{i\text{best}}^l-O_i^l\right) \tag{11}$$

$$O_i^{l+1}=O_i^l+V_i^{l+1} \tag{12}$$

其中，V_i^{l+1}为第i个粒子在第l次迭代的速度，O_i^{l+1}为第i个粒子在第l次迭代的位置；w为惯性权数；$p_{i\text{best}}^l$表示第i个粒子到第l次迭代为止找到的最优位置，$g_{i\text{best}}^l$表示粒子群到第l次迭代为止所找到的最优位置；c_1,c_2为学习因子，一般取非负常数；r_1,r_2为(0,1)范围内的随机数。

本文中，用粒子代表支持向量机的参数，即$O_i=\{C,\gamma\}$，在设定的C和γ的参数范围内进行寻优，并通过支持向量机回归精度确定的适应度评价函数来确定个体最佳位置和群体最佳位置，进行速度和位置更新，直到得到最优的参数组合$\{C,\gamma\}$。

3.3 预测模型的建立及分析

结合上述渗透率计算模型、支持向量机和粒子群算法，本文构造了基于粒子群优化参数选择的支持向量机预测渗透率方法，该方法的工作流程如图7所示，其具体步骤为：

(1)收集岩心及测井资料，选择输入特征参数和输出参数，生成样本集；

(2)将归一化处理后的样本集分成训练集和测试集两部分后，设置初始参数、迭代步数、粒子群个体数、参数搜寻范围等参数，将样本集输入支持向量机、将支持向量机参数作为粒子群个体，启动支持向量机预测渗透率模型；

(3)根据测试集的预测准确率确定粒子群算法中相应粒子的适应度函数值，得到个体最优位置和全局最优位置，然后根据式(11)和式(12)更新速度和位置得到新的粒子种群；

(4)计算新种群中每个粒子的适应度，并与粒子自身迭代以来最优适应度进行比较，选择适应度更高值更新个体最优位置和全局最优位置，进入下一次迭代；

(5)当迭代次数或预测精度满足设定终止条件时，输出当前最佳参数组合$\{C,\gamma\}$；

(6)最后，将优选出的参数C和γ代入支持向量机模型即可得到研究区的渗透率预测模型，并对样本集进行测试检验预测效果。

通过上述研究可知，孔隙度和渗透率具有一定的相关性，而基于毛管压力曲线的6个模型参数在常规砂岩中也与渗透率紧密相关的。因此，结合孔隙度和6个模型的参数为输入特征参数，基于粒子群－支持向量机预测渗透率。随机选取60块样品作为训练集，20块样品作为测试集，对特征参数及渗透率进行归一化处理，将每组特征归一到[−1,1]范围，开展支持向量机的训练及测试。需要说明的是对数据进行归一化之前首先对渗透率取对数，最后将预测结果进行乘幂计算。粒子群算法的种群数量30，进化代数设为200，参数c_1=1.5，c_2=1.7, C和γ的范围均为[0, 100]。通过计算求得的最佳参数C为7.454，γ为0.230。根据前文的相关性分析，依次减少一个参数，训练样本及测试样本的预测值与实际测量值确定系数如表2所示。从该表可以看出，每增加一个输入参数，预测精度均有不同程度的提高，当输入参数从2个增加至3个以及从4个增加至5个时，精度提高程度较大。这说明Swanson和Capillary−parachor相关性较好，而R_{25}、R_{35}、R_{50}这3个参数之间的相关性较好。虽然这两组参数之间有一定的相关性，但是7个输入参数预测的精度还是最高的，因此，本文最终采取7参数进行支持向量机建模与预测。

以7个输入参数开展支持向量机预测的渗透率与测量的岩心渗透率对比图如图8所示。该图中训练样本自预测结果与测量值确定系数R^2为0.917，测试样本预测结果与测量值确定系数为0.883. 图中两条黑

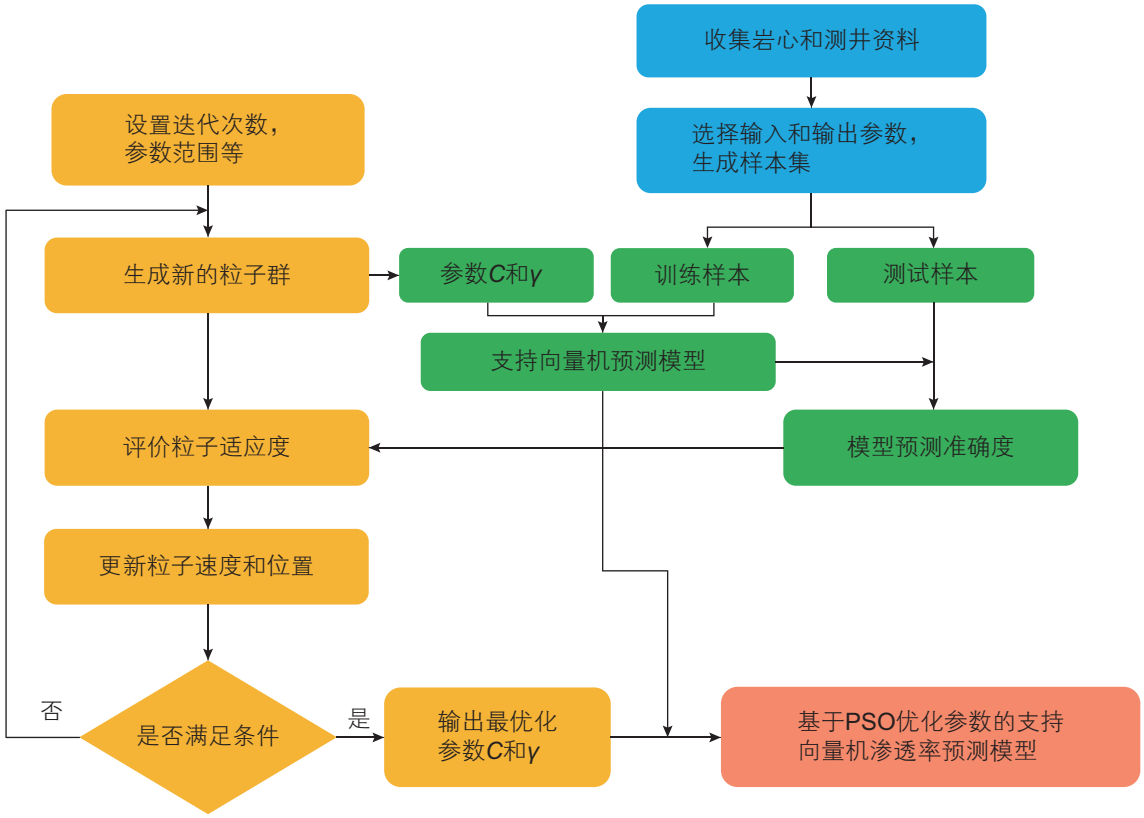

图 7 基于 PSO–SVM 渗透率预测方法的工作流程图

Fig. 7 Work flow of permeability prediction method by PSO–SVM

表 2 不同输入参数的支持向量机预测

Table 2 Support vector machine prediction with different input parameters

输入个数	输入参数	训练样本确定系数	测试样本确定系数
7	ϕ/ $\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2}$ / Swanson/ Capillary–parachor/ R_{25} / R_{35}/ R_{50}	0.917	0.883
6	ϕ/ $\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2}$ / Swanson/ Capillary–parachor/ R_{25} / R_{35}	0.908	0.859
5	ϕ/ $\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2}$ / Swanson/ Capillary–parachor/ R_{25}	0.913	0.854
4	ϕ/ $\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2}$ / Swanson/ Capillary–parachor	0.824	0.840
3	ϕ/ $\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2}$ / Swanson	0.825	0.838
2	ϕ/ $\sum_{i=1}^{N}\frac{S_i}{(P_{ci})^2}$	0.793	0.802

色加粗实线为 ±30% 的相对误差线，可以看出数据点大多集中于 45° 对角线附近，并且仅有少数点落在 ±30% 的相对误差线外。对比图 5 及表 1，该图相关系数高，相对误差小，效果明显好于传统的渗透率模型(即使测试样本的预测效果也好于传统模型)。因此，基于支持向量机模型预测渗透率在一定程度上克服了传统模型对碳酸盐岩储层适用性差的缺陷。

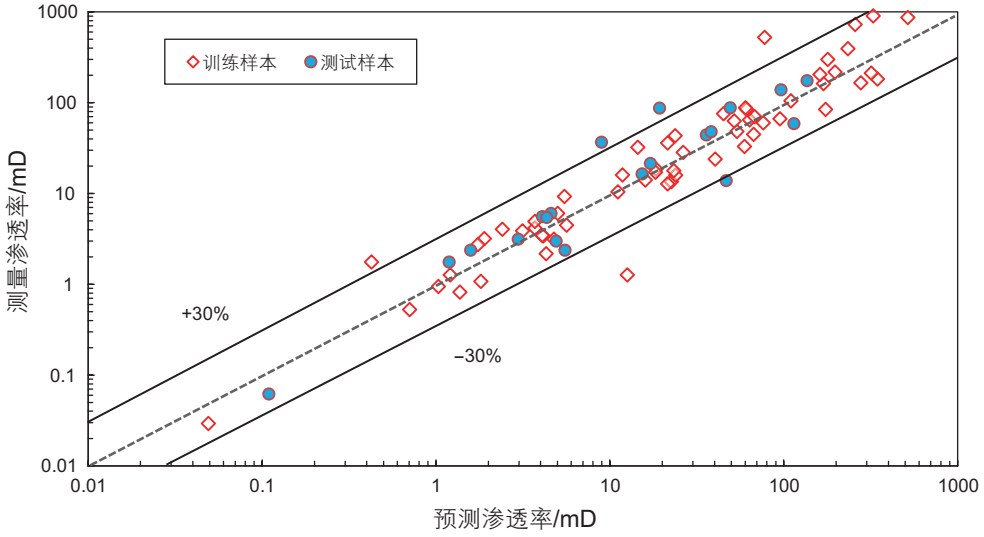

图 8　基于 PSO–SVM 预测的渗透率与测量值对比图

Fig. 8　Comparison of calculated permeability by PSO–SVM and measured permeability

4　结论

(1) 岩心分析结果表明，滨里海盆地东缘中区块石炭系KT−II碳酸盐岩储层隙度主要介于 7%~17%，平均孔隙度为 12.88%。渗透率主要变化于 1~500 mD，渗透率的对数平均值为 17.62 mD。毛管压力曲线分析表明，KT−II储层孔隙结构特征中等至差。

(2) 对基于毛管压力曲线的Purcell模型、Swanson参数、Capilliary−parachor参数、R_{25}、R_{35}、R_{50} 等 6 种渗透率预测模型进行了应用效果分析，发现这些传统的模型应用效果较差。可能的原因是传统的渗透率预测模型多基于孔隙类型单一的砂岩提出的，而KT−II酸盐岩储层孔隙类型复杂多变。

(3) 以孔隙度和六个模型的参数作为输入，利用基于粒子群算法的支持向量机方法，可以准确地预测研究区的渗透率。训练样本、测试样本的预测结果与实际测量值的确定系数分别为 0.913 和 0.854，且误差较小，效果明显好于基于毛管压力曲线的传统渗透率模型。

参考文献

[1] 王权锋. 礁滩相储层地震预测及油气检测技术研究——以四川盆地川东北SYB地区为例[D]. 成都: 成都理工大学, 2008. [WANG Q F. Reef flat facies reservoir seismic prediction and hydrocarbon detection technology study: Take Sichuan northeast SYB area in Sichuan Basin as an example[D]. Chengdu: Chengdu University of Technology, 2008.]

[2] 何伶, 赵伦, 李建新, 等. 碳酸盐岩储集层复杂孔渗关系及影响因素——以滨里海盆地台地相为例[J]. 石油勘探与开发, 2014, 41(2): 206−214. [HE L, ZHAO L, LI J X, et al. Complex relationship between porosity and permeability of carbonate reservoirs and its controlling factors: A case of platform facies in Pre-Caspian Basin[J]. Petroleum Exploration and Development, 2014, 41(2): 206−214.]

[3] SHOKIR E M E, ALSUGHAYER A A, Al-Ateeq A. Permeability estimation from well log responses[J]. Journal of Canadian Petroleum and Technology, 2006, 45: 41−46.

[4] 杨胜来, 魏俊之. 油层物理学[M]. 北京: 石油工业出版社, 2004. [YANG S L, WEI J Z. Petrophysics[M]. Beijing: Petroleum Industry Press, 2004.]

[5] PURCELL W R. Capillary pressures – their measurement using mercury and the calculation of permeability therefrom[J]. Journal of Petroleum Technology, 1949, 1: 39−48.

[6] SWANSON B F. A simple correlation between permeabilities and mercury injection capillary pressures[J]. Journal of Petroleum Technology, 1981, 33: 2498–2504.

[7] GUO B, GHALAMBOR A, DUAN S. Correlation between sandstone permeability and capillary pressure curves[J]. Journal of Petroleum Science and Engineering, 2004 43 (3): 239–246.

[8] KOLODZIE S J. Analysis of pore throat size and use of the Waxman–Smits equation to determine OOIP in spindle field[C].// SPE Annual Technical Conference and Exhibition, Dallas, TX, USA, 21–24 September 1980.

[9] PITTMAN E D. Relationship of porosity and permeability to various parameters derived from mercury injection-capillary pressure curves for sandstone[J]. AAPG Bulletin, 1992, 76 (2): 191−198.

[10] REZAEE M R, JAFARI A, KAZEMZADEH E. Relationships between permeability, porosity and pore throat size in carbonate rocks using regression analysis and neural networks[J]. Journal of Geophysics and Engineering, 2006, 3 (4): 370−376.

[11] 孙宝佃, 周灿灿, 赵建武, 等. 油气层测井识别与评价[M]. 北京: 石油工业出版社, 2014. [SUN B D, ZHOU C C, ZHAO J W. Well log identification and evaluation of oil and gas reservoir [M]. Beijing: Petroleum Industry Press, 2014.]

[12] THOMEER J H M. Introduction of a pore geometrical factor defined by the capillary pressure curve[J]. Journal of Petroleum Technology, 1960, 12 (03): 73–77.

[13] 廖明光, 李士伦, 付晓文, 等. 储层岩石渗透率估算模型的建立[J]. 天然气工业, 2001(4): 45−48. [LIAO M G, LI S L, FU X W, et al. Establishment of reservoir rock permeability estimating model[J]. Natural Gas Industry, 2001(4): 45−48.]

[14] 肖忠祥, 肖亮, 张伟. 利用毛管压力曲线计算砂岩渗透率的新方法[J]. 石油物探, 2008, 47(2): 204−207. [XIAO Z X, XIAO L, ZHANG W. A new method for calculating sandstone permeability by using capillary pressure curves[J]. Geophysical Prospecting for Petroleum, 2008, 47(2): 204−207.]

[15] SHA F, XIAO L Z, MAO Z Q, et al. Petrophysical characterization and fractal analysis of carbonate reservoirs of the eastern margin of the Pre-Caspian Basin[J]. Energies, 2019, 12(1): 78.

[16] TAN M J, SONG X D, YANG X, et al. Support-vector-regression machine technology for total organic carbon content prediction from wireline logs in organic shale: A comparative study[J]. Journal of Natural Gas Science and Engineering, 2015, 26: 792−802.

[17] 邓呈祥, 高文利, 潘和平, 等. 庐枞矿集区科学钻探的岩性识别方法[J]. 物探与化探, 2015(6): 1144−1149. [DENG C X, GAO W L, PAN H P, et al. Lithologic identification method in scientific drilling of the Luzhong ore district[J]. Geophysical and Geochemical Exploration, 2015(6): 1144−1149.]

[18] 王凯军, 曹剑峰, 李升, 等. 多层次分类支持向量机在水质评价中的应用[J]. 水资源保护, 2009, 25(2): 30−32. [WANG K J, CAO J F, LI S, et al. Application of multiple classified support vector machine in water quality assessment[J]. Water Resource Protection, 2009, 25(2): 30−32.]

[19] 李晓龙. 基于支持向量机的岩体力学参数反演及工程应用[D]. 郑州: 郑州大学, 2009. [LI X L. Mechanical parameters inversion of rock mass with support vector machine and its engineering application[D]. Zhengzhou: Zhengzhou University, 2009.]

[20] 张弦, 李世平, 孙浚清, 等. 基于支持向量机的动态测量误差非线性组合预测方法[J]. 工业仪表与自动化装置, 2007, 5: 50−53. [ZHANG X, LI S P, SUN J Q, et al. A nonlinear combination forecasting method for dynamic measurement errors based on support vector machines[J]. Industrial instrument & automation, 2007, 5: 50−53.]

[21] 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 Y D, TONG G J, ZHENG J, 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.]

[22] 田建忠, 王威, 谢梅芳. 基于粒子群算法的支持向量机训练和实现方法[J]. 武汉理工大学学报(信息与管理工程版), 2007, 29(10): 85−88. [TIAN J Z, WANG W, XIE M F. Support vector machine training and testing method based on particle swarm algorithm[J]. Journal of WUT(Information & Management Engineering) , 2007, 29(10): 85−88.]

(编辑 付娟娟)