

改进的 PSO-LSSVM 火山岩气藏压裂水平井产能预测模型

王培玺¹, 张静²

1. 中国石油大学(华东)石油工程学院, 山东青岛 266555

2. 中国石化集团国际石油勘探开发有限公司, 北京 100083

摘要 在火山岩气藏压裂水平井产能预测模型中, 影响因素多、实际样本少、各项参数获取不完整, 因而利用常规方法预测的误差较大。为了充分地利用现有数据资料, 从而快速有效地确定火山岩气藏压裂水平井产能, 本文采用灰色关联方法确定了影响火山岩气藏压裂水平井产能的因素, 利用粒子群算法对最小二乘支持向量机参数进行了优化, 同时考虑到不同参数的敏感性, 引入因素权重, 形成了改进的 PSO-LSSVM 火山岩气藏压裂水平井产能预测模型。模型既充分利用了最小二乘支持向量机的小样本学习能力强和计算简单的特点, 又发挥了粒子群算法计算速度快和具有较强的全局搜索能力的优点, 还兼顾了各因素之间相互作用的影响。使用改进的 PSO-LSSVM 模型与传统的 PSO-LSSVM 模型和 BP-LM 模型进行计算对比的结果表明, 改进的 PSO-LSSVM 模型所需的计算迭代次数更少, 计算精度更高, 进行模型预测的结果也更精确。

关键词 灰色关联分析; 粒子群优化; 最小二乘支持向量机; 压裂水平井; 产能预测

中图分类号 TE319

文献标识码 A

doi 10.3981/j.issn.1000-7857.2011.33.008

Improved PSO-LSSVM Productivity Prediction Model for the Fractured Horizontal Well in Volcanic Gas Reservoir

WANG Peixi¹, ZHANG Jing²

1. School of Petroleum Engineering, China University of Petroleum, Qingdao 266555, Shandong Province, China

2. Sinopec International Petroleum Exploration and Production Corporation, Beijing 100083, China

Abstract The existing productivity prediction model of fractured horizontal well in volcanic gas reservoir has more influence factors, less real samples, and incomplete parameters, therefore, it is difficult to accurately predict the productivity by using conventional methods. In order to quickly and effectively make certain of the productivity of fractured horizontal well in volcanic gas reservoir with existing data, the influence factors are determined by using Grey Relational Analysis(GRA), and the sensitivity of factor weights is considered to amend the algorithm. The improved PSO-LSSVM productivity model is established based on the parameters of Least Squares Support Vector Machines (LSSVM) which are optimized by Particle Swarm Optimization (PSO) algorithm. This model not only makes full use of the characteristics of the LSSVM small samples, which possess the strong learning ability and simple calculation, but also takes the advantages of fast calculation and better global searching ability of PSO. Comparing the PSO-LSSVM model with the BP-LM model, the improved PSO-LSSVM model has less iteration times, higher calculation precision, and more accurate predict results.

Keywords GRA; PSO; LSSVM; fractured horizontal well; productivity prediction

0 引言

中国火山岩气藏资源丰富, 勘探开发前景广阔。加大火山岩气藏开发力度, 对于缓解中国日益严峻的能源压力具有

极其重要的意义。但是由于火山岩气藏储层结构复杂, 非均质性严重, 使用常规方法开采火山岩气藏的产能较低。因此油田现场利用压裂水平井技术开采火山岩气藏, 可以有效地

收稿日期: 2011-10-28; 修回日期: 2011-11-20

基金项目: 高等学校学科创新引智计划(“111”计划)项目(B08028)

作者简介: 王培玺, 博士研究生, 研究方向为油藏工程与数值模拟, 电子信箱: wangpeix@hotmail.com

改善火山岩气藏的渗流状况,降低单井成本,提高气井的产能。但是水平井经过压裂后,其流动特征更加复杂,相应的影响因素也更多。对火山岩气藏压裂水平井进行建模求解时,在现有的经济技术条件下,油田现场并不能获得模型所需要的相对完整的数据体,这就造成产能分析和预测结果的不精确。

从1980年以来,随着仿生学、遗传学和人工智能以及计算机技术的发展,产生了一系列智能优化算法。这些算法通过大量信息传播和演变方法获得问题的最优解,具有全局性、自适应性和离散性的特点,在最优优化领域得到广泛应用。这些算法同时也被引入到油气藏产能预测中。1994年杨维宁等^[1]就利用神经网络方法预测气井产能,随之利用神经网络方法进行产能预测,得到了非常广泛的应用。但是神经网络算法具有如网络结构、过学习与欠学习、局部极小和样本容量等一系列问题,必须要加以改进才能使用,这在实际应用中造成了很多不便。2006年薛磊等^[2]使用支持向量机方法预测原油产能。随之支持向量机方法在预测水平井产能以及其他类型油气藏产能也得到应用^[3-4]。支持向量机方法建立在统计学基础上,并且遵循结构风险最小化准则,对样本数据的分布没有严格要求,适合于进行小样本的预测。但是对于支持向量机方法来说,不同参数的选取(调整参数、核函数参数和惩罚系数等)对整个系统的性能有较大的影响。因此如何选择合适的参数是一个重要的问题。参数优化的方法有遗传算法、模拟退火和蚁群算法等。而粒子群优化算法就是其中的一种基于种群的智能随机优化算法,它计算速度快,计算精度高,具有并行处理特征,鲁棒性好,而且简单容易实现。

本文利用粒子群算法对最小二乘支持向量机模型的参数进行全局寻优,以寻找最优化的计算参数。同时,考虑到各参数之间的相互影响,利用灰色关联分析方法将因素权重引入模型中,建立改进的 PSO-LSSVM 火山岩气藏压裂水平井产能预测模型。

1 火山岩气藏压裂水平井产能影响因素

由于火山岩气藏压裂水平井具有复杂的流动特征,其产能是多种因素共同制约下的综合反映。因此研究各因素对产能的影响,对研究火山岩气藏水平井压裂后的产能状况具有相当重要的应用价值。不同参数对产能影响的重要性不同,利用灰色关联分析方法就可以确定各种因素对产能的影响程度。

1.1 影响火山岩气藏水平井压裂产能的相关因素分类

影响火山岩气藏压裂水平井产能的因素大致可分为储层因素、水平井因素、压裂因素、生产因素和其他人为因素等^[5-9]。

储层因素是指储层的岩性、岩相、沉积特征、含油气性和流体性质等。包括储层渗透率、储层孔隙度、储层厚度、各向异性系数、储层微裂缝数目和含气饱和度等。

水平井因素是指水平井形状、性质和特征等。包括水平井段长度、水平井井深、水平井位置、水平井泄油半径和水平井

井筒尺寸等。

压裂因素是指水平井经过水力压裂后,形成的人工裂缝的形状和性质等因素。包括裂缝条数、裂缝位置、裂缝长度、裂缝宽度、裂缝高度、裂缝渗透率和裂缝导流能力等。

生产因素是指压裂水平井在实际生产过程中的影响因素。包括生产压差、井网状况、采气速度和气水比等。

其他人为因素是指受钻完井和井下作业过程中对地层的污染,以及各种增产措施实施后综合影响的相关因素。包括表皮系数和气井折算半径等。

综合来说,储层产能是由储层的自身条件与外部条件等共同决定的。然而,在实际生产中,受不同情况下的开发井网和作业方式的限制,外部条件一般相对不变。此时,储层的自身性质将对储层的产能高低产生决定性的影响。本文结合理论分析与油田现场实际获取的各种数据,选择其中相对独立的因素对产能进行分析。

1.2 灰色关联分析确定各因素权重

1.2.1 灰色关联分析方法原理

灰色关联分析方法(Grey Relational Analysis, GRA)是一种因素比较方法,以数据间差值的大小作为关联程度的衡量尺度。在实际问题中,某种方案实施的必要性很大,但其实施的可能性却不大,反映到评价方案中,就是要考虑方案与最优参考数据列和最差参考数据列之间的关联关系。

1.2.2 灰色关联分析步骤

(1) 选定评价分析指标。

根据气藏产能的实际情况,选定气井绝对无阻流量作为模型评价参数。同时考虑各因素的独立性、各因素对产能的影响程度和实际现场数据的获取情况,选定用于产能评价的因素包括储层渗透率、各向异性系数、气层厚度、泄油半径、水平井长度、微裂缝条数、裂缝条数、裂缝长度、裂缝宽度、裂缝渗透率和生产压差。

(2) 对原始数据的无量纲化处理。

由于各因素的物理意义不同,各个数据的量纲也不尽相同,因此需要对原始数据消除量纲。但是运用不同的无量纲化方法进行灰色关联分析的最终结果会有所不同,因此需要确定合理的无量纲化方法。经过实际计算和分析^[1],最终选定采用“中心化”处理方法,即为

$$y_i = \frac{x_i - \bar{x}_i}{\sigma_i} \quad (1)$$

其中, \bar{x}_i, σ_i 分别为测量样本 x 第 i 项的样本平均值和样本均方差。

(3) 计算各因素无量纲化处理后的各项因素 x_{ki} 与无阻流量无量纲化处理后所得相应数据 x_{0i} 之间的绝对离差 $\Delta_i(k)$

$$\Delta_i(k) = |x_{ki} - x_{0i}| \quad (i=1, 2, \dots, m; k=1, 2, \dots, n) \quad (2)$$

(4) 计算关联度

$$y_i(k) = \frac{A + \rho B}{\Delta_i(k) + \rho B} \quad (3)$$

其中, $A = \min_{1 \leq k \leq n} \{ \min_{1 \leq i \leq m} [\Delta_i(k)] \}$; $B = \max_{1 \leq k \leq n} \{ \max_{1 \leq i \leq m} [\Delta_i(k)] \}$; ρ 为分辨率, 一般取 0.5。

(5) 计算各因素与无阻流量之间的关联度

$$r_i = \frac{1}{n} \sum_{k=1}^n y_i(k) \quad (i=1, 2, \dots, m) \quad (4)$$

(6) 各个因素的权重

$$r'_j = r_j / (r_1 + r_2 + \dots + r_m) \quad (j=1, 2, \dots, m) \quad (5)$$

1.3 因素权重计算示例

利用灰色关联方法对某火山岩气田 14 口压裂水平井的各种影响因素数据进行分析, 计算结果如表 1 所示。

表 1 灰色关联分析单因素对无阻流量的权重

Table 1 Weights of GRA single factor to open flow capacity

因素	权重	因素	权重
裂缝渗透率	0.1114	微裂缝密度	0.0866
生产压差	0.0935	水平段长度	0.0863
裂缝条数	0.0931	泄油半径	0.0860
储层渗透率	0.0929	各向异性系数	0.0857
裂缝宽度	0.0922	气层厚度	0.0844
裂缝长度	0.0879		

从计算结果可以看出, 对该类型火山岩气田压裂水平井产能影响最大的是压裂相关因素, 其次是储层相关因素。进而验证了该类型火山岩气藏的原始储层条件是制约气井产能的最主要因素, 火山岩气藏的低渗透特征直接制约了气井的产能, 而对火山岩气藏水平井进行压裂改造是提高气井产能的必要手段。

2 改进的 PSO-LSSVM 方法的原理

2.1 最小二乘支持向量机算法原理

Suykens 等^[8]提出最小二乘支持向量机方法 LSSVM, 该方法是基于正则化理论对标准的支持向量机方法进行了改进。与传统支持向量机方法不同之处在于将不等式约束改为等式约束, 且将误差平方和损失函数作为训练集的经验损失。使用最小二乘支持向量机方法提高了求解问题的速度和收敛精度, 较好解决了小样本、非线性、高维数、局部极小点等实际问题。这种算法对于火山岩气藏压裂水平井产能预测数学模型中预测样本少、因素多和数据非线性等实际问题, 具有非常好的适应性。

最小二乘支持向量机算法的基本原理如下^[9]。

对于给定的训练样本 $(\mathbf{x}_i, y_i) (i=1, 2, \dots, l, \mathbf{x}_i \in \mathbb{R}^n, y_i \in \mathbb{R})$, 利用非线性映射 $\phi(\mathbf{x})$ 将样本从原空间 \mathbb{R}^n 映射到特征空间 $\phi(\mathbf{x}_i)$, 在高维特征空间中构造最优决策函数

$$y(\mathbf{x}) = \boldsymbol{\omega} \cdot \phi(\mathbf{x}) + b \quad (6)$$

将非线性估计函数转化为高维特征空间中线性估计函数, 利用结构风险最小化原则, 寻找权值矢量 $\boldsymbol{\omega}$ 和域值 b , 即最小化

$$R = \frac{\|\boldsymbol{\omega}\|^2}{2} + C \cdot R_{\text{emp}} \quad (7)$$

其中, $\|\boldsymbol{\omega}\|^2$ 为控制模型的复杂度; C 为正则化参数, 控制误差样本的惩罚程度; R_{emp} 为误差控制函数。

由于最小二乘支持向量机在优化目标中的损失函数为误差 ξ_i 的二次项。因此约束性优化问题可以表示为

$$\min J(\boldsymbol{\omega}, \boldsymbol{\xi}) = \frac{\boldsymbol{\omega}^T \boldsymbol{\omega}}{2} + C \sum_{i=1}^l \xi_i^2$$

$$y_i = \phi(\mathbf{x}_i) \cdot \boldsymbol{\omega} + b + \xi_i \quad (i=1, 2, \dots, l) \quad (8)$$

用拉格朗日法求解, 即

$$L(\boldsymbol{\omega}, b, \boldsymbol{\xi}, \boldsymbol{\alpha}) = \frac{\boldsymbol{\omega}^T \boldsymbol{\omega}}{2} + C \sum_{i=1}^l \xi_i^2 - \sum_{i=1}^l \alpha_i [\phi(\mathbf{x}_i) \cdot \boldsymbol{\omega} + b + \xi_i - y_i] \quad (9)$$

其中, $\alpha_i (i=1, 2, \dots, l)$ 为拉格朗日乘子。由优化条件

$$\begin{cases} \frac{\partial L}{\partial \boldsymbol{\omega}} = 0 \\ \frac{\partial L}{\partial b} = 0 \\ \frac{\partial L}{\partial \xi_i} = 0 \\ \frac{\partial L}{\partial \alpha_i} = 0 \end{cases} \quad (10)$$

可得

$$\begin{cases} \boldsymbol{\omega} = \sum_{i=1}^l \alpha_i \cdot \phi(\mathbf{x}_i) \\ \sum_{i=1}^l \alpha_i = 0 \end{cases} \quad (11)$$

其中, $\alpha_i = C \cdot \xi_i, \phi(\mathbf{x}_i) \cdot \boldsymbol{\omega} + b + \xi_i - y_i = 0$ 。

定义核函数 $K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i) \cdot \phi(\mathbf{x}_j)$, 问题就转化为求解如下线性方程组:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(\mathbf{x}_1, \mathbf{x}_1) + \frac{1}{C} & \dots & K(\mathbf{x}_1, \mathbf{x}_l) \\ \vdots & \vdots & \dots & \vdots \\ 1 & K(\mathbf{x}_l, \mathbf{x}_1) & \dots & K(\mathbf{x}_l, \mathbf{x}_l) + \frac{1}{C} \end{bmatrix} \cdot \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_l \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_l \end{bmatrix} \quad (12)$$

用最小二乘法求出回归系数 α_i 和阈值 b , 得到非线性预测模型:

$$f(\mathbf{x}) = \sum_{i=1}^l \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (13)$$

最小二乘支持向量机算法最常用的核函数有: 多项式核函数 $K(\mathbf{x}, \mathbf{x}_i) = [(\mathbf{x}, \mathbf{x}_i) + 1]^q$ 、径向基核函数 (RBF) $K(\mathbf{x}, \mathbf{x}_i) = \exp(-\|\mathbf{x} - \mathbf{x}_i\|^2 / (2\sigma^2))$ 和 Sigmoid 核函数 $K(\mathbf{x}, \mathbf{x}_i) = \tanh[v(\mathbf{x}, \mathbf{x}_i) + c]$ (c 为常数) 等^[10]。对于具体的问题, 如何选择核函数是应用最小二乘支持向量机算法的一个难点。由于多项式核函数参数较多, 不利于参数的选择, 而且对于特定的参数, Sigmoid 核函数功能上与径向基核函数相同, 本文结合模型实际计算进行分析, 最终选择径向基核函数为本文算法的核函数。

2.2 粒子群优化算法

粒子群优化算法 (Particle Swarm Optimizer, PSO) 是一种进化计算技术, 由 Eberhart 和 Kennedy 于 1995 年首先提出,

是通过模拟鸟群觅食行为而发展起来的一种基于群体协作的随机搜索算法。基本思想是通过群体中个体之间的协作和信息共享来寻找最优解。Shi 等^[11]在此基础上提出了标准 PSO 算法,并引入了惯性权重因子 ω 的概念。

PSO 算法的一般形式为

$$v_{id}(t+1) = \omega \cdot v_{id}(t) + c_1 \cdot \text{Rand}() \cdot [p_{id} - x_{id}(t)] + c_2 \cdot \text{Rand}() \cdot [p_{gd} - x_{id}(t)] \quad (14)$$

$$x_{id}(t+1) = x_{id}(t) + v_{id}(t) \quad (15)$$

$$\omega = (\omega_{ini} - \omega_{end}) \cdot (G_k - g) / G_k + \omega_{end} \quad (16)$$

其中, $v_{id}(t)$ 为粒子的速度; $x_{id}(t)$ 为粒子的位置; p_{id} 为当前粒子搜索到的最优位置; p_{gd} 为整个粒子群搜索到的最优位置; G_k 为最大进化代数, g 为当前进化代数; ω_{ini} 为初始惯性权重; ω_{end} 为迭代至最大代数时惯性权重; $\text{Rand}()$ 为 0—1 之间的随机数; c_1 和 c_2 为学习因子。

由于粒子群算法具有算法实现简单、计算速度快且具有全局优化能力的特点,因此本文利用粒子群算法优化最小二乘支持向量机的各项参数。

2.3 改进的 PSO-LSSVM 产能预测模型

(1) 改进的 PSO-LSSVM 产能预测模型计算步骤。

Step 1: 运用灰色关联方法对影响火山岩气藏压裂水平井的参数进行筛选,计算各参数之间的关联度,根据灰色关联度的高低,选定相关因素,并据此整理相应数据作为输入数据。

Step 2: 对训练样本 $X_i(t)$ 进行灰色关联分析,根据灰色关联度将原训练样本赋予不同的权重,生成新的样本,其中的权重系数为 r'_i 。新的样本为 $X'_i(t) = X_i(t) \cdot r'_i$,并将预测样本也用权重进行处理,生成新训练样本 $R'_i(t) = R_i(t) \cdot r'_i$ 。

Step 3: 初始化设定最小二乘支持向量机模型参数初始值。

Step 4: 对粒子群的粒子进行初始化,初始化粒子数、权重、学习因子等。

Step 5: 计算各粒子的适应度。

Step 6: 根据粒子适应度更新各粒子的速度和位置。

Step 7: 判断是否得到最优化最小二乘支持向量机参数,如果得到则继续执行 Step8,否则返回 Step5 继续计算。

Step 8: 利用最优化最小二乘支持向量机参数和带权重的训练样本数据,建立产能预测模型。

Step 9: 利用改进的 PSO-LSSVM 产能预测模型预测其他样本的产能。

(2) 模型计算流程图如图 1 所示。

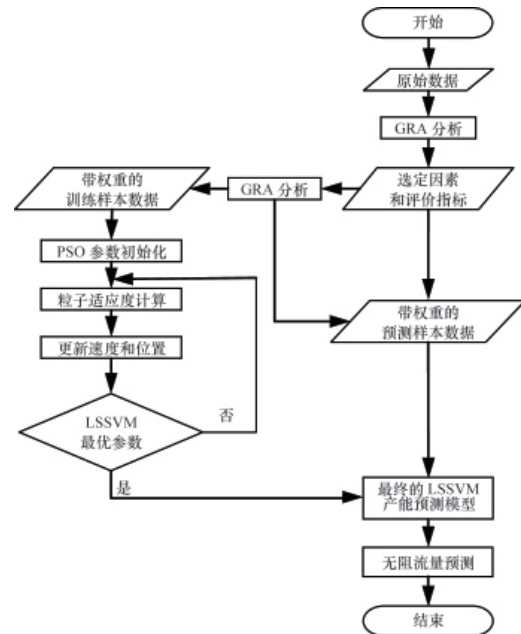


图 1 算法流程图

Fig. 1 Flowchart of model

3 应用实例

取某油田压裂水平井的实际生产数据,运用改进的 PSO-LSSVM 模型进行分析。样本总数为 10 个,设定最小计算平均相对误差为 10^{-6} ,最大计算迭代次数为 10^6 次,样本具体数据如表 2 所示。

表 2 压裂水平井样本数据

Table 2 Sample data of fractured horizontal well

序号	裂缝条数/条	储层渗透率/ ($10^{-3}\mu\text{m}^2$)	裂缝宽度/mm	生产压差/MPa	裂缝渗透率/ ($10^{-3}\mu\text{m}^2$)	水平段长度/m	泄油半径/m	裂缝长度/m	储层厚度/m	微裂缝密度/ (条· m^{-1})	各向异性系数	无阻流量/ ($10^4\text{m}^3\cdot\text{d}^{-1}$)
1	4	1.08	2.0	3.56	17907	692.1	197.6	59.6	111.1	6	1.18	7.21
2	4	1.63	11.7	6.75	13681	803.7	245.2	176.5	117.8	8	3.83	3.97
3	3	0.82	6.5	5.82	14309	826.4	204.5	146.5	149.9	9	3.07	3.41
4	3	1.00	8.2	6.30	20381	805.8	199.3	121.2	77.7	8	1.75	13.36
5	3	1.40	7.2	5.62	14723	996.9	361.0	177.1	104.9	8	2.64	5.16
6	3	2.01	13.3	4.75	15980	905.0	286.7	152.4	99.8	9	3.23	6.39
7	3	2.12	7.5	4.14	16237	828.5	238.0	91.7	118.4	11	2.60	5.56
8	3	0.95	3.5	3.56	11277	986.6	299.3	224.1	112.5	11	2.47	2.82
9	2	1.16	4.2	8.93	18057	679.1	207.4	211.7	99.7	9	1.60	8.17
10	3	1.80	6.3	3.56	14490	944.1	313.3	148.7	142.4	9	2.92	3.68

运用改进的 PSO-LSSVM 模型进行 10 次计算,平均经过 9 次迭代计算,用时 0.83s,即可达到设定计算精度,平均相对误差为 3.98×10^{-7} 。其中 PSO 模型中学习因子为 2.523,惯性权重为 0.725,粒子群个数为 25。计算过程如图 2 所示。




图 2 误差分析
Fig. 2 Error analysis

将该数据样本同时利用 PSO-LSSVM 方法^[4]和 BP-LM^[12]算法进行分析。计算结果如表 3 所示。

表 3 不同算法的计算结果对比
Table 3 Comparison of results based on different algorithms

算法	迭代次数/次	计算时间/s	平均计算相对误差/ 10^{-7}
改进的 PSO-LSSVM	9	0.830	3.980
PSO-LSSVM	16	1.237	4.065
BP-LM	75	0.985	9.654

从计算结果可以看出,使用改进的 PSO-LSSVM 算法比利用 PSO-LSSVM 算法或 BP-LM 算法构建的专家系统在相同状况下对样本进行数据拟合,所需的迭代次数更少,收敛速度更快,计算平均相对误差也要小。

取 4 组压裂水平井的数据进行产能预测分析,相关数据如表 4 所示。

表 4 压裂水平井产能预测数据
Table 4 Data for fractured horizontal wells prediction

序号	裂缝条数	储层渗透率/ $(10^{-3} \mu\text{m}^2)$	裂缝宽度/mm	生产压差/MPa	裂缝渗透率/ $(10^{-3} \mu\text{m}^2)$	水平段长度/m	泄油半径/m	裂缝长度/m	储层厚度/m	微裂缝密度/(条· m^{-1})	各向异性系数	无阻流量/ $(10^4 \text{m}^3 \cdot \text{d}^{-1})$
11	3	1.80	12.1	7.67	13380	998.7	283.9	255.2	92.2	6	3.53	5.17
12	2	1.20	12.1	3.56	14470	875.0	280.6	236.3	128.0	14	3.84	4.09
13	2	1.35	6.5	4.88	13037	630.0	324.0	200.7	117.2	12	2.99	5.68
14	2	0.95	6.3	4.62	11632	890.6	289.0	173.3	126.8	9	3.43	4.86

应用改进的 PSO-LSSVM 模型对表 4 中的数据进行产能预测分析,比较模型计算值与实际测量之间的误差,通过 4 组参数的预测结果可以看出(表 5),改进的 PSO-LSSVM 模型数据的预测值与实际值之间平均相对误差为 5.433%,最大相对误差为 10.955%,计算误差满足工程精度要求,由此可知该模型具有很好的数值稳定性,预测精度较高,可应用于火山岩藏压裂水平井产能预测中。

表 5 预测结果
Table 5 Predict results

方案	方案 1	方案 2	方案 3	方案 4
无阻流量实际值/ $(10^4 \text{m}^3 \cdot \text{d}^{-1})$	5.167	4.090	5.680	4.857
无阻流量预测值/ $(10^4 \text{m}^3 \cdot \text{d}^{-1})$	5.230	3.642	6.133	4.779
计算相对误差/%	1.205	10.955	7.967	1.607

4 结论

(1) 采用灰色关联分析方法对影响火山岩气藏压裂水平井产能的各种因素进行分析,选定其中最主要的影响因素,同时确定各因素的相应权重。

(2) 综合考虑了各参数的敏感性以及小样本的学习能力和算法全局搜索速度,并将因素权重引入计算模型中,建立了改进的 PSO-LSSVM 产能预测模型。

(3) 改进的 PSO-LSSVM 模型与传统的 PSO-LSSVM 和 BP-LM 算法相比,计算收敛速度快,计算精度更高,计算速度更快。

(4) 利用改进的 PSO-LSSVM 模型对火山岩气藏压裂水平井产能进行预测。预测结果表明,该模型预测精度高,计算误差满足工程精度要求。该模型为火山岩气藏压裂水平井产能预测,提供了一种更快速有效的方法。

参考文献 (References)

[1] 杨维宁,王宏,匡建超,等. 用神经网络滚动模型预测天然气的生产能力[J]. 大自然探索, 1994, 50(13): 40-47.
Yang Weining, Wang Hong, Kuang Jianchao, et al. Exploration of Nature, 1994, 50(13): 40-47.

[2] 薛磊,吴炜,杨晓敏,等. 一种基于支持向量回归的多层原油分层产能贡献预测模型[J]. 石油化工高等学校学报, 2006, 19(4): 88-92.
Xue Lei, Wu Wei, Yang Xiaomin, et al. Journal of Petrochemical Universities, 2006, 19(4): 88-92.

[3] 张锋,张星,张乐,等. 利用支持向量机方法预测储层产能 [J]. 西南石

- 油大学学报, 2007, 29(3): 24-27.
Zhang Feng, Zhang Xing, Zhang Le, et al. *Journal of Southwest Petroleum University*, 2007, 29(3): 24-27.
- [4] 肖京男, 汪志明, 魏建光, 等. 改进 LSSVM 在水平井产能预测中的应用[J]. 石油钻探技术, 2010, 38(6): 95-98.
Xiao Jingnan, Wang Zhiming, Wei Jianguan, et al. *Petroleum Drilling Techniques*, 2010, 38(6): 95-98.
- [5] 庞彦明, 毕晓明, 邵锐, 等. 火山岩气藏早期开发特征及其控制因素[J]. 石油学报, 2009, 30(6): 882-886.
Pang Yanming, Bi Xiaoming, Shao Rui, et al. *Acta Petrolei Sinica*, 2009, 30(6): 882-886.
- [6] 周学民, 唐亚会. 徐深气田火山岩气藏产能特点及影响因素分析[J]. 天然气工业, 2007, 159(1): 90-92.
Zhou Xuemin, Tang Yahui. *Natural Gas Industry*, 2007, 159(1): 90-92.
- [7] 李炳军, 朱春阳, 周杰. 原始数据无量纲化处理对灰色关联序的影响[J]. 河南农业大学学报, 2002, 36(2): 199-202.
Li Bingjun, Zhu Chunyang, Zhou Jie. *Journal of Henan Agricultural University*, 2002, 36(2): 199-202.
- [8] Suykens J A K, Vandewalle J. Recurrent least squares support vector machines [J]. *Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on*, 2000, 47(7): 1109-1114.
- [9] 冯学军. 最小二乘支持向量机的研究与应用 [J]. 安庆师范学院学报: 自然科学版, 2009, 15(1): 112-113.
Feng Xuejun. *Journal of Anqing Teachers College: Natural Science Edition*, 2009, 15(1): 112-113.
- [10] 游张平, 胡小平, 张凯, 等. 基于自适应 LS-SVM 的柴油机进排气系统故障诊断[J]. 科技导报, 2010, 28(8): 77-80.
You Zhangping, Hu Xiaoping, Zhang Kai, et al. *Science & Technology Review*, 2010, 28(8): 77-80.
- [11] Shi Y, Eberhart R C. A modified particle swarm optimizer [C]// *Proceedings of the IEEE International Conference on Evolutionary Computations*, 1998. Piscataway, NJ: IEEE Press, 1998.
- [12] Saini L M, Soni M K. Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods [J]. *IEE Proc-Gener Transm Distrib*, 2002, 149(5): 578-584.

(责任编辑 郑伟, 刘志远)

· 学术动态 ·



“第七届国际电力电子与运动控制会议”征文

由中国电工技术学会(CES)、国际电气与电子工程师协会(IEEE)电力电子学会(PELS)、国家自然科学基金委员会(NSFC)主办的第七届国际电力电子与运动控制会议将于 2012 年 6 月 2-5 日在哈尔滨召开。

征文范围: 器件、封装和系统集成, 功率集成电路, 功率半导体器件, 无源元件, 热分析、封装和系统集成; 率变换器及其控制, DC/DC、DC/AC、AC/AC、AC/DC 及多电平变换器, 功率因数校正及谐波抑制, 调制和控制策略, 电力电子系统 EMI 抑制; 驱动及运动控制, 感应电机驱动, 永磁电机驱动, 同步磁阻电机驱动, 直线电机驱动, 无传感器控制, 特种电机、驱动器和传感器, 电机驱动系统应用; 源和智能电网技术, 新能源及替代系统(如太阳能、风能、海洋能、燃料电池等)与应用接口专题, 能系统, 网及分布式发电, 能电网控制、通信及监测; 推进系统, 电动和混合动力车、舰船, 电源和电动汽车充电器, 电池建模及管理系统, 汽车电子; 能质量管理, 电能质量分析及改善, 静态并联补偿静态串联补偿, 串并联补偿; 其他电力电子应用, 不间断电源, 感应加热, 电力电子及驱动在家用电器中的应用, 电力电子及驱动在 LEDs&HIDs 中的应用等。

论文截稿日期: 2012 年 2 月 10 日。

电 话: 0451-86413420

电子信箱: ipemc2012@163.com

会议网站: <http://www.ipemc2012.org>