

·综合研究·

一种改进的LS-SVM 算法及其应用

董 瑶 * 潘国锋 夏克文 张志伟

(河北工业大学信息工程学院)

董瑶,潘国峰,夏克文,张志伟.一种改进的 LS-SVM 算法及其应用.石油地球物理勘探,2007,42(6):673~677

摘要 为了避免 LS-SVM 算法中存在的矩阵求逆问题,提出一种改进的 LS-SVM 算法,即利用改进 PSO 算法对 LS-SVM 算法中线性方程组进行迭代优化求解,这样既能加快算法训练速度和节省内存,又总能得到最小二乘解,提高计算精度。将此改进算法应用到长庆气田 C 井目的层井段进行气层识别,并与 BP 神经网络算法、经典的 SVM 算法和传统的 LS-SVM 算法比较,结果表明此算法识别精度高,收敛速度快,与试气结果吻合,效果显著。

关键词 最小二乘支持向量机 粒子群优化算法 迭代优化 气层识别

的缺点,提高了识别准确率及计算速度。

1 引言

随着计算智能技术的迅猛发展,神经计算、进化计算和粒计算等计算智能技术在许多领域得到成功应用,并已成为气层识别的一项主要技术。比如在小样本情形下,基于结构风险最小化(SRM)准则^[1]的支持向量机(SVM)能够有效地避免经典学习方法中存在的过学习、维数灾难、局部极小等问题^[2],且具有良好的泛化能力,在各种分类问题中已得到成功应用^[3],但对于实际大规模问题则存在训练速度较慢的缺点。为此,Suyken 提出了最小二乘支持向量机(Least Squares Support Vector Machines,LS-SVM)^[4],把二次优化问题转化为一个线性方程组的求解问题,克服了 SVM 的缺陷。但 LS-SVM 算法在求解过程中总会出现矩阵的求逆,对于实际工程的大规模问题在微机上是难以实现的。为此,基于迭代计算思想,本文提出了一种新的求解方法,即采用再现群智能的粒子群优化算法(Particle Swarm Optimization,PSO)来求解 LS-SVM 中的任意线性方程组,不仅加快了计算速度,而且避免了矩阵的求逆,节省了内存。

将本文提出的改进 LS-SVM 算法应用到气层识别领域,克服了以往常规线性、经验性测井解释技术^[5]难以适应油井复杂的环境变化且识别准确率低

2 基本 LS-SVM 及其改进算法

2.1 基本 LS-SVM 原理

设训练集 $S=\{(x_k, y_k) | k=1, 2, \dots, N\}$, 其中 $x_k \in \mathbf{R}^n$, $y_k \in \mathbf{R}$, 分别为输入和输出数据。与经典 SVM 不同, LS-SVM 利用 SRM 准则构造如下最小化目标函数及其约束条件

$$\begin{cases} \min_{w, b, e} J(w, e) = \frac{1}{2} w^T w + \gamma \frac{1}{2} \sum_{k=1}^N e_k^2 \\ y_k = w^T \phi(x_k) + b + e_k \quad k = 1, 2, \dots, N \end{cases} \quad (1)$$

其中: w 为权值; γ 为正规化参数; e_k 为误差变量; $b \in \mathbf{R}$ 为偏置参数。将求解式(1)的优化问题转化为求解如下线性方程组

$$\begin{bmatrix} 0 & \mathbf{I}^T \\ -\mathbf{I} & K + \gamma^{-1} \mathbf{I} \end{bmatrix} \begin{bmatrix} b \\ \mathbf{a} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{Y} \end{bmatrix} \quad (2)$$

其中: $\mathbf{I}=[1, \dots, 1]^T$; $K=\phi(x)^T \phi(x_k)$ 是满足 Mercer 条件的核函数; $\mathbf{Y}=[y_1, \dots, y_N]^T$; $\mathbf{a}=[a_1, \dots, a_N]^T$; I 为单位矩阵。

用最小二乘法求出方程(2)中的 a 和 b ,由此得到预测输出为

$$y_k = \sum_{k=1}^l a_k K(x, x_k) + b \quad (3)$$

* 天津市北辰区河北工业大学信息工程学院 390 信箱,300401

本文于 2007 年 1 月 29 日收到,修改稿于同年 2 月 8 日收到。

本研究为国家自然科学基金项目(60377020,60673087)。

2.2 改进的 LS-SVM

我们将线性方程(2)改写为如下矩阵方程

$$\mathbf{A}\mathbf{x} = \mathbf{z} \quad (\mathbf{A} \in \mathbf{R}^{m \times n}, \mathbf{z} \in \mathbf{R}^m) \quad (4)$$

在 LS-SVM 中,一般是采用最小二乘法求解。而对于实际工程的大规模问题,由于 $\mathbf{A}^\top \mathbf{A}$ 的维数较大,在微机上难以实现矩阵的求逆过程。为此,可以采用迭代计算的方法来求解矩阵方程。

用于解决优化问题的 PSO 算法是一种迭代寻优的计算方法。因此对于大型矩阵方程的求解,可以采用 PSO 算法来进行迭代求解,即将矩阵方程(4)转化为采用 PSO 算法来迭代求解最优粒子 $\mathbf{X}=(x_1, x_2, \dots, x_n)^\top$ 的问题,从而避免了矩阵求逆的过程。

基本 PSO 算法^[6]是由 Kennedy 和 Eberhart 最早提出的,粒子通过跟踪两个“极值”来更新自己的速度 v_i 和位置 x_i ,即局部极值 p_{best} 和全局极值 g_{best} 。迭代更新公式为

$$\begin{aligned} \mathbf{A} = & \begin{bmatrix} 0.901D+00 & -0.705D-03 & 0.122D-11 & 0.733D-16 & 0.000D+00 & 0.000D+00 \\ 0.716D+00 & -0.146D-02 & -0.454D-10 & 0.400D-10 & 0.000D+00 & 0.000D+00 \\ 0.542D+00 & -0.183D-02 & -0.119D-10 & -0.388D-14 & 0.000D+00 & 0.000D+00 \\ 0.392D+00 & 0.113D-03 & -0.179D-09 & -0.240D-12 & 0.715D-16 & -0.535D-16 \\ 0.263D+00 & 0.377D-02 & -0.861D-08 & -0.595D-09 & -0.464D-13 & -0.951D-15 \\ 0.129D+00 & 0.160D-02 & 0.159D-07 & -0.676D-08 & -0.235D-09 & -0.900D-12 \\ 0.196D-01 & 0.287D-03 & 0.706D-06 & 0.447D-06 & 0.149D-02 & -0.363D-02 \end{bmatrix} \\ \mathbf{z} = & (0.180130D+01 \quad -0.143054D+01 \quad -0.108217D+01 \quad -0.784113D+00 \quad -0.529770D+00 \\ & -0.259600D+00 \quad -0.473966D-01)^\top \end{aligned}$$

式(9)的真解为

$$\mathbf{x} = (-2.0 \quad -1.0 \quad 0.0 \quad 1.0 \quad 2.0 \quad 3.0)^\top$$

\mathbf{A} 的条件数高达 10^{13} ,可见式(9)是严重病态的。

采用基本 PSO 算法和改进 PSO 算法求解上述矩阵方程,参数设定如下:粒子数目 $N=10$,随机常数 $r_1=r_2=\text{rand}(0,1)$;加速常数 $\varphi_1=\varphi_2=2.05$, $\varphi=\varphi_1+\varphi_2=4.1$;则收敛因子 $\chi=\frac{2}{|2-\varphi-\sqrt{\varphi^2-4\varphi}|}=0.729$ 。

本文中将 ω 初始为 0.9 并使其随迭代次数的增加,依据下式

$$\omega = \omega_{\max} - \frac{(\omega_{\max} - \omega_{\min}) T_{\max}}{T} \quad (10)$$

线性递减至 0.1,从而调整算法的搜索能力,以达到优化目的;约束因子 $\alpha=0.8$ 。两种算法训练网络的迭代

$$\begin{aligned} v_{i+1} = & v_i + \varphi_1 \cdot r_1 \cdot (p_{\text{best}} - x_i) + \\ & + \varphi_2 \cdot r_2 \cdot (g_{\text{best}} - x_i) \end{aligned} \quad (5)$$

$$x_{i+1} = x_i + v_{i+1} \quad (6)$$

式中: φ_1, φ_2 为加速常数, r_1, r_2 为随机参量。

改进 PSO 算法^[7]即在基本 PSO 算法模型的基础上增加了收敛因子 χ 、惯性权重 ω 和约束因子 α ,保证了算法的收敛性,提高了收敛速度。粒子迭代公式为

$$\begin{aligned} v_{i+1} = & \chi \cdot [\omega \cdot v_i + \varphi_1 \cdot r_1 \cdot (p_{\text{best}} - x_i) + \\ & + \varphi_2 \cdot r_2 \cdot (g_{\text{best}} - x_i)] \end{aligned} \quad (7)$$

$$x_{i+1} = x_i + \alpha \cdot v_{i+1} \quad (8)$$

为了验证上述改进 PSO 算法求解矩阵方程的有效性,下面用改进 PSO 算法和基本 PSO 算法分别求解在面波频散反演中常见的一个典型病态方程组^[8]

$$\mathbf{A}\mathbf{x} = \mathbf{z} \quad (\mathbf{A} \in \mathbf{R}^{m \times n}, \mathbf{z} \in \mathbf{R}^m) \quad (9)$$

其中

误差曲线如图 1 所示。采用基本 PSO 算法求解迭代 247 次误差达到 7.0228×10^{-7} ,而改进 PSO 算法仅迭代 39 次就已达到这一误差精度,在迭代 108 次误差就已达到 8.9591×10^{-11} ,收敛速度及精度上均优于基本 PSO 算法。输出 \mathbf{x} 的结果如表 1 所示。

表 1 两种算法的输出结果

期望输出 \mathbf{x}	基本 PSO 算法的输出	改进 PSO 算法的输出
-2	-2.0003	-2.0000
-1	-1.0202	-1.0000
0	0.2720	0.1441
1	1.4414	1.0174
2	1.1465	1.9999
3	2.6464	3.0000
均方差	1.87×10^{-1}	3.5×10^{-3}

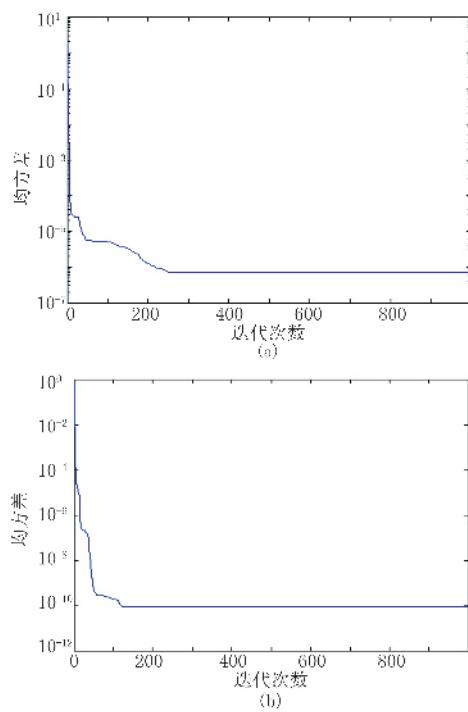


图 1 PSO 算法训练网络的误差演化曲线
(a) 基本 PSO 算法; (b) 改进 PSO 算法

由此可见,采用改进的 PSO 算法求解矩阵方程,与基本 PSO 算法相比收敛速度快,计算精度高,求解效果令人满意。为此提出基于 PSO 迭代优化的 LS-SVM 算法,其算法流程如下。

步骤 1 初始话粒子群。设定粒子群参数,在定义空间 \mathbf{R}^n 中随机产生 n 个粒子 x_1, x_2, \dots, x_n ,组成初始种群 $\mathbf{X}(t)$;随机产生各粒子的初始速度 v_1, v_2, \dots, v_n ,组成速度矩阵 $\mathbf{V}(t)$;每个粒子的个体最优解 $p_{best,i}$ 初始值为 x_i 的初始值。

步骤 2 评价各粒子适应度函数 $f(x)$ 。在具体矩阵方程求解中,可以按照残差 $(\mathbf{z} - \mathbf{Ax})$ 的均方差来计算适应度函数, $f(x)$ 越小,适应能力越强。适应度函数可定义为

$$f(x) = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (z_i - A_{ij}x_j)^2 \quad (11)$$

步骤 3 对每个粒子,比较当前适应度 $f(x_i)$ 和历史最好位置适应度 $f(p_{best,i})$,如果 $f(x_i) < f(p_{best,i})$,那么 $p_{best,i} = x_i$,即可比较群体所有粒子当前适应度 $f(x_i)$ 和群体最好位置适应度 $f(g_{best,i})$,如果 $f(x_i) < f(g_{best,i})$,那么全局最优解 $g_{best,i} = x_i$ 。

步骤 4 根据改进 PSO 算法式(7)和式(8)更新粒子的速度和位置,产生新种群 $\mathbf{X}(t+1)$,速度调整规则如下

$$\begin{cases} v_i = V_{\max} & v_i > V_{\max} \\ v_i = -V_{\max} & v_i \leq -V_{\max} \end{cases} \quad (12)$$

步骤 5 检查结束条件。若满足条件,则结束寻优,返回当前最优个体为结果,否则 $T = T + 1$,转至步骤 2。设定结束条件为寻优达到最大迭代次数 T_{\max} 或评价值小于给定精度。

步骤 6 输出结果。输出所求得的矩阵方程的最小二乘解,即对应式(2)中最优参数 b 和 $\{a_i\}_{i=1}^N$ 。

步骤 7 将 $\{a_i\}_{i=1}^N$ 和 b 代入式(3),得到识别函数式,再输入待识别样本进行识别。

本文选取径向基函数 $K(x, x_k) = \exp(-\|x - x_k\|^2 / 2\sigma^2)$ 为核函数, σ 为核函数的宽度。

3 应用举例

长庆气田为低产、低含气丰度、大面积分布的隐蔽岩性气藏,应用传统识别方法对气层测井资料进行定量评价存在很大困难。为此采用改进 LS-SVM 算法对 C 井目的井段(3300~3400m)进行定量评价。设计基于改进 LS-SVM 的气层训练识别模型如图 2。

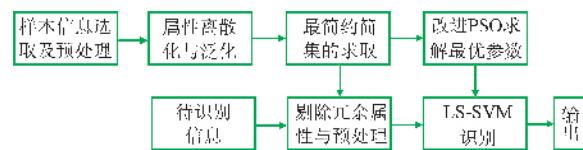


图 2 基于改进 PSO 的 LS-SVM 气层识别模型

3.1 样本信息选取与预处理

样本集资料的选取要完备、全面,应与气层评价密切相关,尽量保证选取的资料不重叠。在长庆气田 C 井目的井段(3300~3400m)处提取 190 个样本点测井数据作为训练样本,其中气层样本 85 个,非气层样本 105 个。为避免出现计算饱和现象,要对样本数据进行归一化处理,使输入的样本数据在区间 [0,1],归一化公式为

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (13)$$

式中: $x \in [x_{\min}, x_{\max}]$; x_{\min}, x_{\max} 分别为样本数据的最小值和最大值。

3.2 属性离散化和泛化

样本信息的决策属性为{非气层,气层},将决策属性 D 泛化为{-1,1},分别代表非气层和气层,样

本信息的条件属性有 13 个,即:GR、DT、SP、WQ、LLD、LLS、DEN、NPHI、PE、U、TH、K、CALI,采用黄金分割优选法实现连续属性离散化,各属性离散化区间如表 2 所示。

表 2 13 个条件属性离散化区间

条件属性	离 散 化 区 间
GR	[26.2090,80.1413], (80.1413,167.3930]
DT	[204.2380,239.9491], (239.9491,262.0230]
SP	[-132.3970,-108.8555], (-108.8555,-94.3040]
WQ	[5.9760,123.5468], (123.5468,196.2200]
LLD	[16.9160,89.4111], (89.4111,134.2220]
LLS	[16.5520,84.5147], (84.5147,126.5240]
DEN	[2.3180,2.5806], (2.5806,2.7430]
NPHI	[4.6180,18.5690], (18.5690,41.1390]
PE	[1.7510,2.9833], (2.9833,3.7450]
U	[0.2950,3.7774], (3.7774,5.9300]
TH	[0.7480,9.2307], (9.2307,22.9540]
K	[0.4060,2.3249], (2.3249,3.5110]
CALI	[22.6490,23.8918], (23.8918,24.6600]

3.3 样本信息属性约简

将 13 个条件属性通过预处理和离散化处理后,采用基于相似度的属性约简算法^[9]剔除样本集中的冗余属性,从而得到反映气层特性的最简条件属性集{GR,DT,SP,LLD,LLS,DEN,K},如表 3 所示,为约简后的 7 个样本属性的数值范围。

表 3 约简后的样本属性数值范围

属性	GR	DT	SP	LLD	LLS	DEN	K
最小值	20	190	-135	10	10	2	0
最大值	180	280	-90	170	150	3	4

将这 7 个属性按式(13)在井段 3300~3400m 之间进行归一化处理,如图 3 所示。

3.4 迭代寻优

设粒子群规模为 30,解空间为 191 维,即寻优参数的个数,加速常数 φ_1 和 φ_2 为 2.05,则收敛因子 $\chi=0.729$,初始惯性权重 $\omega=0.9$,粒子的最大速度 $V_{\max}=10$ 。通过交叉验证的方式选取改进 LS-SVM 中正规化参数 $\gamma=1000$,径向基核函数的宽度参数 $\sigma^2=0.125$,利用基本 PSO 和改进 PSO 求解 LS-SVM 算法中的式(2),所得到的误差曲线如图 4 所示。基本 PSO 迭代 298 次误差精度达到 1.4667×10^{-8} ,而改进 PSO 达到同一精度仅需迭代 43 次,在迭代 96 次误差精度就已达到 2.0115×10^{-12} ,可见

改进 PSO 在收敛速度和精度上均远远优于基本 PSO。

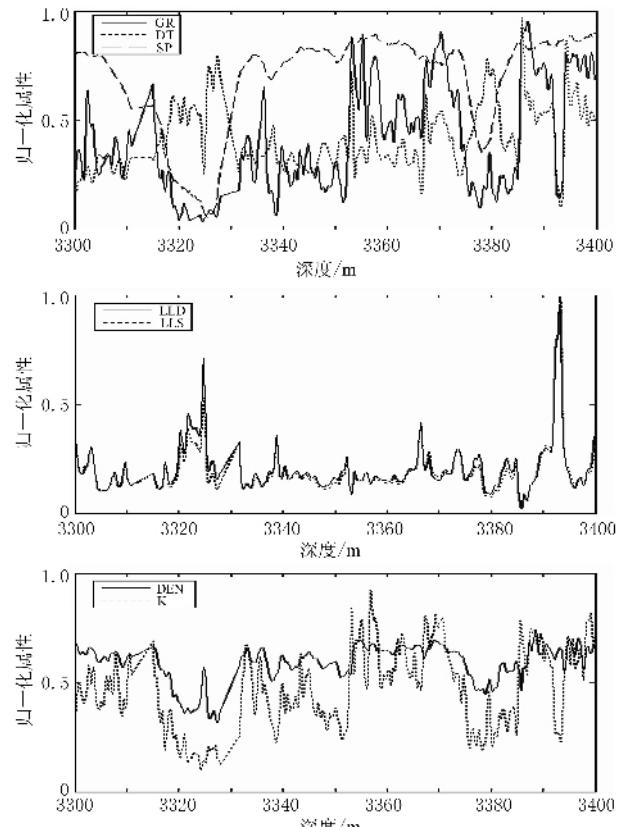


图 3 经过归一化的 7 个属性的曲线图

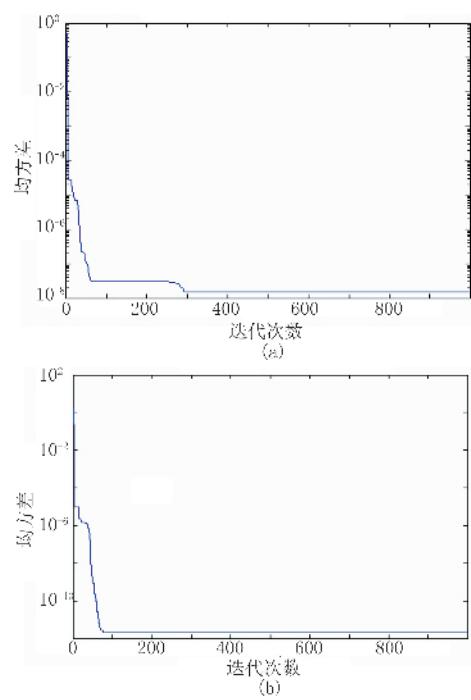


图 4 PSO 算法训练网络的误差演化曲线
(a) 基本 PSO 算法; (b) 改进 PSO 算法

4 结果分析比较

将迭代寻优后得到的预测模型对全部井段样本进行气层识别,并与采用 BP 算法、经典 SVM 算法和传统 LS-SVM 算法的识别结果相比较。为了衡量识别结果的性能,定义以下几个性能指标

$$\text{均方根误差: } \text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N e_i^2} \quad (14)$$

$$\text{最大正误差: } \text{MAXPE} = \max\{e_i, 0\} \quad (15)$$

$$\text{最大负误差: } \text{MAXNE} = \min\{e_i, 0\} \quad (16)$$

式中: $e_i = y_i - \hat{y}_i$, \hat{y} 和 y_i 分别为识别输出值和期望输出值。

其中,BP 算法采用“7-8-1”的网络结构,学习因子取为 0.05,隐含层和输出层的传输函数均选取 Tansig 函数($f(x) = 2/(1+e^{-2x}) - 1$),经典 SVM 模型亦采用径向基核函数,通过交叉验证的方式选取传统 LS-SVM 中正规化参数 $\gamma=256$,径向基核函数的宽度参数 $\sigma^2=0.125$,性能指标如表 4 所示。

表 4 性能指标比较

算 法	RMSE	MAXPE	MAXNE	识别率 %	运行时间 s
BP	0.3020	1.2710	-1.0919	81.4	4.4913
经典 SVM	0.2613	1	-1	90.6	8.0938
LS-SVM	0.2321	1	-1	98.4	2.6875
改进 LS-SVM	0.1228	1	-1	99.1	1.0190

所得结果表明采用 LS-SVM 算法在识别率等性能指标上明显优于 BP 算法和经典 SVM 算法,LS-SVM 与 SVM 算法在识别精度、泛化能力上要优于 BP 算法,本文提出的改进 LS-SVM 不但有效地避免了 BP 算法中存在的过学习、维数灾难、局部极小等问题,而且解决了 SVM 算法对于大规模样本所出现的计算复杂度高、计算速度慢等问题,并且较传统 LS-SVM 算法在微机运行速度和识别率上均有所提高。

利用改进 LS-SVM 算法训练好的网络对 3300~3400m 井段进行识别,结果如图 5 所示,即在井段 3315~3326.5m、3336~3338m、3358~3360.5m、3374~3383m 这 4 个区间段均为气层,其

他区间段均为非气层,识别结果与试气结论吻合,表明本文提出的改进 LS-SVM 算法适用于解决气层识别等大规模样本问题,且识别效果显著。

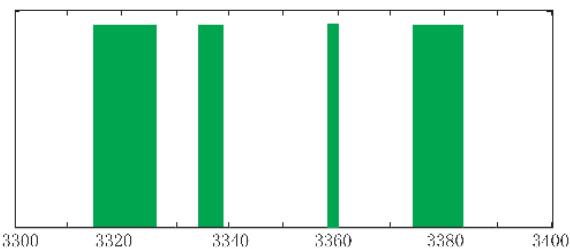


图 5 改进 LS-SVM 气层识别结果图

横坐标表示井深,单位为 m;纵坐标无量纲。
阴影区间表示气层,其它区间表示非气层

5 结论

基于结构风险最小化(SRM)准则的 LS-SVM 是一种很好的分类方法,本文提出的改进 LS-SVM 算法不仅避免了矩阵求逆计算,而且总能求得最优解,且其训练速度和求解精度均得到提高。实际应用结果表明,本文提出的改进的 LS-SVM 算法在气层识别中效果显著,且可以应用到其他大规模工程识别中,具有很好的应用前景。

参 考 文 献

- [1] Vladimir N Vapnik 著,张学工译.统计学习理论的本质.北京:清华大学出版社,2000
- [2] Cortes C, Vapnik V. Support vector machine. *Machine Learning*, 1995, 20: 273~297
- [3] Nello Cristianini, John Shawe-Taylor 著,李国正等译.支持向量机导论.北京:电子工业出版社,2005
- [4] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers. *Neural Processing Letters*, 1999, 9 (3) : 293~300
- [5] 《测井学》编写组.测井学.北京:石油工业出版社,1998
- [6] Kennedy J, Eberhart R C. Particle swarm optimization. *Proc IEEE Int Conf Neural Networks*. Piscataway, NJ: IEEE Press, 1995, 1942~1948
- [7] Shi Y, Eberhart R. A modified particle swarm optimizer. In: *IEEE World Congress on Computational Intelligence*, 1998: 69~73
- [8] 李平,王椿镛.地球物理反演中奇异值分解应用的若干问题研讨.自然科学进展,2001,11(8):891~896
- [9] 夏克文,刘明霄,张志伟,董瑤.基于属性相似度的属性约简算法.河北工业大学学报,2005,34(4):20~23

(本文编辑:冯小球)