

基于粒子群算法的 Universum SVM 参数选择

张新峰, 焦月, 李欢欢, 卓力

(北京工业大学 信号与信息处理研究室, 北京 100124)

摘要: 分类器的模型参数对分类结果有直接影响. 针对引入无关样本的 Universum SVM 算法中模型参数选择问题, 采用粒子群优化 (particle swarm optimization, PSO) 算法对其进行优化. 该方法概念简单、计算效率高且受问题维数变化的影响较小, 可实现对多个参数同时优选. 此外, 在 PSO 中粒子适应度函数的选择是一个关键问题. 考虑 k 遍交叉验证法的估计无偏性, 利用交叉验证误差作为评价粒子优劣的适应值. 通过舌象样本数据实验, 对参数优选前后测试样本识别正确率进行比较, 实验结果验证了该算法的有效性.

关键词: Universum SVM; 参数选择; 粒子群算法

中图分类号: TP 391

文献标志码: A

文章编号: 0254-0037(2013)06-0840-06

Model Parameter Selection of the Universum SVM Based on Particle Swarm Optimization

ZHANG Xin-feng, JIAO Yue, LI Huan-huan, ZHUO Li

(Signal & Information Processing Laboratory, Beijing University of Technology, Beijing 100124, China)

Abstract: The model parameters of a classifier directly affect the classification results. According to the traits of additional irrelevant samples in the learning process of Universum SVM, this paper optimizes parameters with particle swarm optimization (PSO) due to its simple concept, high computational efficiency, and less impact by the changes of the problem dimension; therefore, several parameters can be simultaneously optimized. Besides, selection for fitness function is a key factor in PSO algorithm. According to its unbiased estimation, k -fold cross validation error is considered as the fitness value, by which an evaluation on the particle can be obtained. Finally, through experiment on tongue samples, the recognition accuracy rates on test samples before and after optimizing the parameters are compared. Result verifies the effectiveness of the proposed algorithm.

Key words: Universum SVM; parameter selection; particle swarm optimization (PSO)

支持向量机 (support vector machine, SVM) 是建立在结构风险最小化原则的基础上, 将经验风险和置信范围综合考虑, 保证了分类器具备较好的推广能力^[1-2].

然而, SVM 是一种传统的监督学习方法. 该方法在应用之前必须对输入样本进行类别标定, 在实际应用中往往不易进行或代价较高. 标准 SVM 仅

利用有标记样本进行学习, 样本数量小时, 分类信息不充足, 最终影响分类器的性能.

Universum SVM 方法是标准 SVM 方法的扩展, 最早由 Vapnik 提出, 目的是将附加的无关样本引入算法的训练过程中, 这些无关样本中一般隐含着一定的分类信息, 从而使得到的分类器具有更好的推广性能^[3-4].

收稿日期: 2011-07-12.

基金项目: 国家自然科学基金资助项目 (61201360); 北京市自然科学基金资助项目 (4092009).

作者简介: 张新峰 (1974—), 男, 副教授, 主要从事智能化信息处理、机器学习方面的研究, E-mail: bjupezxf@126.com.

对 SVM 而言,参数选择是研究中的一个核心问题,它对分类结果产生直接影响.目前,对 SVM 算法中参数优化已经提出了许多方法,如交叉验证法、粒子群优化法等,这些都只是对核函数参数和有标记样本的惩罚因子做了优化,而 Universum SVM 算法模型中的参数除了核函数及其参数、有标记样本的惩罚因子外,还包括无关样本的惩罚因子,对该参数则没有给出一个合适的值.在利用 Universum SVM 的分类方法中,其中的参数都是根据经验值来确定的,不一定是最优值.

若考虑将 k 遍交叉验证法应用到 Universum SVM 的模型参数优化问题中,由于参数较多,计算量相当大,尤其当参数变化的步长取较小值时,训练次数将显著增加,优化过程费时;而采用粒子群优化 (particle swarm optimization, PSO) 算法可克服上述缺点,由于其不受粒子维数的影响,可实现同时对几个参数进行寻优,因此本文将基于 PSO 实现对 Universum SVM 算法中参数的选择.

1 Universum SVM 方法介绍

1.1 无关样本的概念

在 Universum SVM 的训练样本集中,不仅包括有类别标记的训练样本,还包括与正、负两类无关的样本.

Universum 表示不属于分类问题中任何一类的数据的集合,它包含的数据属于分类问题的领域,只是与有标记样本来自不同的分布,因此,也称 Universum 中的数据为无关数据^[3].

Universum 集合中的数据并不是真正的训练样本,但是它们能提供该应用领域中样本分布的先验知识.例如,在数字手写体识别中,若学习问题是要将数字 5 和 8 区分出来,就可把其他手写体数字 0、1、2、3、4、6、7、9 作为该学习问题的无关样本,这些样本包含了手写体数字中一定的特征信息,但是它们不能被划分为 5 或 8 两类中的任何一个类别^[5].

1.2 Universum SVM 基本原理

Universum SVM 的基本思想^[3-8]是在标准 SVM 方法的基础上,在训练过程中加入无关数据以获得更多的样本分布的信息.因此,考虑 2 类分类问题,训练样本集由 2 部分组成: l 个有标记的训练数据 $\{(x_i, y_i)\}_{i=1}^l$ 和 m 个无关数据 $\{x_j^*\}_{j=1}^m$.

假设有类别标记的训练样本能被最大间隔超平面 $f(x) = (w \cdot x) + b$ 线性的分开,则图 1 从直观上

表示出了无关样本对分类超平面的影响^[5].




图 1 加入无关样本后分类超平面的变化

Fig. 1 Universum data change of the separating hyperplanes

图 1 中 2 条实线为标准 SVM 算法利用最大化分类间隔得到的分类边界超平面,虚线为加入无关样本后采用 Universum SVM 方法得到的边界超平面.尽管 2 种方法都能将正、负两类样本正确地分开,且具有相同的分类间隔,但是仍然认为 Universum SVM 方法得到的分类器更好,原因在于这些无关样本并不属于两类中的任何一类,要使分类器具有更好的推广性能,必须尽量多地使这些样本落在分类器的分类间隔内.

SVM 采用铰链损失 (hinge loss) 函数^[6],如图 2 (a) 所示,因此,其优化问题的目标函数可表达为

$$\min_{w, b} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l H_1 [y_i f_{w, b}(x_i)]$$

式中: $H_\theta [t] = \max\{0, \theta - t\}$ 为铰链损失函数,对于 SVM,此时 $\theta = 1$; w 为权值向量; θ, t 为实数.

同样,在 Universum SVM 算法中,不仅要对错分的有标记训练样本给予惩罚,还要惩罚那些远离分类超平面的无关样本.因此,采用 ϵ -敏感损失 (ϵ -insensitive loss) 函数^[6],如图 2 (b) 所示.进而,无关样本上总的损失为

$$L_{total} = \sum_{i=1}^m U[f(x_i^*)] \tag{1}$$




图 2 铰链损失与 ϵ -敏感损失

Fig. 2 Hinge loss and ϵ -insensitive loss

现在将无关样本加入到标准 SVM 的算法中,只需要在目标函数的基础上,加入对无关样本损失的惩罚项,因此,Universum SVM 算法最终要最小化的目标函数为^[3, 5-6]

$$\frac{1}{2} \| \mathbf{w} \|^2 + C \sum_{i=1}^l H[y_i f_{\mathbf{w}, b}(x_i)] + C^* \sum_{i=1}^m U[f_{\mathbf{w}, b}(x_i^*)]$$

式中 C 和 C^* 分别表示有标记样本和无关样本的惩罚因子。

由上述 Universum SVM 可知, 无关样本中包含着样本分布的先验知识, 对分类超平面的确定能起到一定的指导作用. 因此, Universum SVM 方法利用这种附加的信息进行学习, 理论上可得到推广性能更好的分类器。

然而实验表明, 并不是所有的无关样本都能正确指导分类面的确定, 不同的无关数据集对分类超平面的影响也不同^[7]. 为实现 Universum SVM 方法更好的应用, 需要首先利用文献[9]的 IBU 选择算法(in-between Universum) 选取无关样本, 该算法利用核函数在高维空间中计算样本之间的距离, 并根据该距离之间的关系, 找出分布在正、负两类样本之间的无关样本作为选择出来的 IBU 样本。

2 粒子群算法基本原理

粒子群优化(particle swarm optimization, PSO) 算法是群体智能的一个新分支, 属于进化算法的一种, 它利用简单的速度和位置概念, 避免了交叉、遗传和变异等复杂的操作. 因此, PSO 算法的概念更加简单, 计算过程更容易实现。

在 PSO 系统中, 优化问题每个备选的解对应搜索空间中 1 只鸟的位置, 将 1 只鸟称为 1 个“粒子”(particle). 每个粒子都有自己的位置和速度, 分别决定着粒子的飞行方向和飞行距离, 还有一个由被优化函数决定的适应值, 作为评价粒子优劣的标准. 每个粒子通过记忆和追随当前的最优粒子, 来实现在解空间中的搜索^[10].

PSO 首先初始化一群随机的粒子, 然后通过反复迭代找到最优解. 在每次的迭代过程中, 粒子通过跟踪 2 个“极值”来不断更新自己. 第 1 个是粒子本身搜索到的最优解, 这个解称为个体极值 p_{best} ; 另一个极值是整个种群目前搜索到的最优解, 这个极值称为全局极值 g_{best} . 在找到这 2 个最优值后, 粒子根据式(2)(3)来更新自己的速度和位置^[11]:

$$v(t+1) = w \cdot v(t) + c_1 r_1 [p_{\text{best}}(t) - p(t)] + c_2 r_2 [g_{\text{best}}(t) - p(t)] \quad (2)$$

$$p(t+1) = p(t) + v(t+1) \quad (3)$$

式中: $p(t)$ 是粒子当前的位置, 如在标准 SVM 模型

参数选择中, $p(t)$ 表示参数 $\{C, g\}$ 的当前取值; $v \in [-v_{\text{max}}, v_{\text{max}}]$ 是粒子的速度, 决定着下一代粒子的更新方向和大小(对速度调整的规则为: 在当前粒子速度 $v_i > v_{\text{max}}$ 时, 令 $v_i = v_{\text{max}}$; 当 $v_i \leq -v_{\text{max}}$ 时, 令 $v_i = -v_{\text{max}}$); c_1, c_2 是学习因子, 或称为加速常数, 分别代表将每个粒子推向个体极值和全局极值的加速项权重^[12], 通常取值为 $c_1 = c_2 = 2$; r_1, r_2 是介于(0, 1)的随机数; w 是非负数, 称为惯性因子, 它的引入可使粒子群算法在较少的迭代次数内获得全局最优解. Shi 等^[13] 研究指出: 当 w 取较大的值时, 算法具有更强的全局搜索能力, 而当 w 取较小的值时, 算法对应着较强的局部搜索能力; 因此, 通常采取的方法是: 在迭代过程中, 将 w 的值从大到小进行线性递减, 即首先着重对全局的搜索能力, 然后再逐渐增强局部的搜索能力, 可采用式(4)实现对 w 的线性递减:

$$w = w_{\text{max}} - \frac{w_{\text{max}} - w_{\text{min}}}{T} \times T_{\text{max}} \quad (4)$$

式中: T_{max} 为最大迭代次数; T 为当前的迭代次数; $w \in [w_{\text{min}}, w_{\text{max}}]$, 可令 $w_{\text{max}} = 0.95$, $w_{\text{min}} = 0.4$, 即随迭代次数的增加, 使 w 从 0.95 递减到 0.4, 从而可逐步调整算法的搜索能力, 达到参数优化的目的。

由式(2)可知, 粒子群算法将每个个体看做是一个在搜索空间中飞行的没有质量和体积的粒子, 通过在种群中个体之间相互协作和信息共享实现对最优解的搜索. 这样, 算法的收敛速度将更快, 而且不需要对很多参数进行调节. 此外, 该算法受问题维数的变化影响较小, 使得求解过程更容易计算。

3 基于 PSO 的 Universum SVM 参数选择

在 Universum SVM 方法的分类模型中, 各模型参数之间相互影响, 因此, 不能对每个参数单独进行寻优, 而必须将所有参数综合在一起同时考虑, 来寻找一种最优的参数组合. 粒子群算法不受粒子维数的影响, 可实现同时对几个参数进行寻优。

3.1 Universum SVM 算法需要优化的参数

研究表明: 径向基核函数(radial basis function, RBF) 是一种通用的核函数^[14], 在各种不同的模式识别问题中都能取得比较好的效果; 因此, 将采用该核函数进行实验, 其具体形式为

$$K(x, y) = \exp(-g \|x - y\|^2) \quad (5)$$

式中 g 为一个可调的参数。

在 Universum SVM 中, 需要对参数 g 进行合理选择, 以保证分类器具有更好的分类识别能力。

惩罚因子 C 也是能对分类器产生影响的一个

重要参数. 选取较大的 C 值,意味着强调更小的训练误差,选取较小的 C 值,强调分类间隔较大,即期望寻求分类器具有更好的推广能力. 惩罚因子 C 是对有标记样本错分程度的惩罚,而在 Universum SVM 方法中,还要对无关样本的错分做出惩罚,这样需要增加一个无关样本的惩罚因子 C^* ,该参数与有标记样本的惩罚因子 C 具有相同的意义,较大的 C^* 值表示无关样本对分类器的影响作用越大,强调分类器在无关样本上的错分更小.

此外,无关样本的损失函数为 ε -敏感损失函数 ε 表示对无关样本错分惩罚的敏感级别. 由于它对分类器结果的影响不大,一般选取一个较小的正数即可,不需要将其加入模型参数选择算法的过程中再对 ε 的值进行寻优.

综上所述,Universum SVM 在模型参数选择中需进行优选的有 3 个参数:核函数参数 g 、有标记样本的惩罚因子 C 、无关样本的惩罚因子 C^* .

3.2 适应度函数的选择

在利用进化算法解决模型参数的优化问题时,解的编码和适应度函数是其中的 2 个重要方面^[15-16]. 由于 PSO 算法采用的是实值编码方式,要对哪些参数进行寻优,就将粒子编码为由这些参数组成的向量,各参数的不同取值就代表了不同的粒子个体,因此,只要在解的范围内对其任意初始化即可;而适应度函数就成为 PSO 算法中的一个至关重要的问题.

适应值是评价粒子优劣的标准,而适应值由适应度函数来决定. 在模型参数选择的问题中,一组好的模型参数不仅要在训练过程中使分类器具有很强的学习能力,还需要对未知样本有很好的预测能力. 因此,适应度函数一般取对分类器推广能力的估计值. 在对分类器推广能力估计的方法中,考虑 k 遍交叉验证法实现估计的无偏性^[10],本文选用 k 遍交叉验证误差作为模型参数选择中评价粒子优劣的适应值.

需要说明的是,为实现对无关样本惩罚因子 C^* 的优选,采用引入无关样本的交叉验证误差作为评价粒子优劣的适应值,即在交叉验证的训练阶段将无关数据加入训练过程中,只是加入的这些数据并不参加平均分配的过程,并采用 Universum SVM 方法进行训练,这样就可将无关样本的惩罚因子加入到对粒子的评价过程中,从而实现对所有模型参数的优化.

3.3 粒子群算法实现步骤

在确定了需要进行优化的参数以及评价粒子优

劣的适应度函数后,采用 PSO 算法实现 Universum SVM 模型参数寻优的流程如图 3 所示.

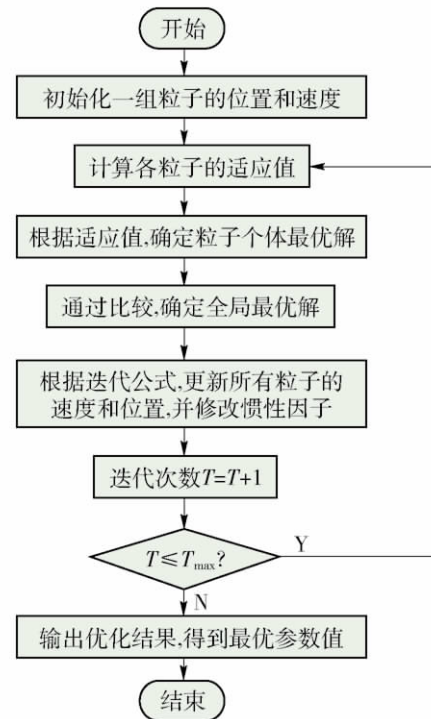


图 3 粒子群算法流程

Fig. 3 Flow of PSO algorithm

在图 3 所示的粒子群算法实现步骤中,粒子适应值的计算是关键,根据关于适应度函数选择的讨论,可得到引入无关样本的交叉验证误差的具体计算步骤如下:

步骤 1 把有标记的训练样本集平均分成 k 个互不包含的子集 S_1, S_2, \dots, S_k ;

步骤 2 初始化 $i = 1$;

步骤 3 将 S_i 作为测试样本集,合并其余的子集作为训练样本集,同时在训练样本集中加入无关样本集,将训练样本与附加的样本合并在一起,根据当前粒子中各参数的值进行训练,得到分类器;

步骤 4 计算分类器在第 i 个子集上的测试误差 $e_i = \text{mean}(S_i - \hat{S}_i)^2$,并令 $i = i + 1$,重复步骤 3 直至 $i = k + 1$;

步骤 5 计算 k 次测试误差的平均值作为 k 遍交叉验证的误差.

在进行模型参数优选之前,还需要阐明一个特殊的问题,即核函数参数的确定问题:在应用 Universum SVM 算法之前需要利用文献 [9] 的算法对无关样本进行选择,在该算法中,利用了核函数将输入的样本映射到高维空间中,从而是在某个确定的参数 g 下所做的映射.但是,若经过粒子群算法

对模型参数进行优选,核函数参数 g 的值必然发生改变.这样就出现了矛盾,即 PSO 算法之前需要确定参数 g 的值以选出 IBU 样本,而 PSO 算法之后,对参数优选又将 g 的值改变了.如果继续后面的实验,在新的模型参数下训练 Universum SVM 分类器,使用的还是原参数下选取的 IBU 样本,这在理论上存在问题.

为解决这一矛盾,采取工程中经常使用的一种思想策略,对上述的问题而言,具体的方法:

步骤 1 根据经验确定一个核函数参数 g 的初始值;

步骤 2 在当前 g 值 g_{old} 下,利用选择 IBU 算法选出 IBU 样本;

步骤 3 根据这些无关样本,采用 PSO 算法对模型参数优化,得到新的 g 值 g_{new} ;

步骤 4 若 $|g_{new} - g_{old}| \leq \delta$,其中 δ 为很小的正数,则算法结束,将 g_{new} 作为最优的模型参数;否则,令 $g_{old} = g_{new}$,返回步骤 2.

可以看出,上述算法是期望通过反复应用选择 IBU 算法与 PSO 模型参数优化算法,实现核函数参数 g 值的最终收敛,从而得到最优的模型参数.

4 舌象数据实验与分析

为了说明模型参数进行选择前后对分类器性能的影响,利用舌象样本进行实验.实验中所用样本为已经由中医专家进行过类别标定的典型样本块,由于不同舌色苔色样本的主要区别体现于颜色特征,因此选择样本的 RGB 值作为输入特征向量.

实验中,首先从 6 种舌色和 9 种苔色中分别选出 3 组两两组合,共构成 6 组两类分类问题.其中,各组有标记的训练样本数都为 60 个;测试样本数为 1 200 个;对于一个确定的两类分类问题,其他不属于这 2 类的另外 13 类数据可构成无关数据集,从这 13 类样本中每类随机选出 30 个数据,因此,每个分类问题都共有 390 个无关数据.实验所用各类样本的具体数量为测试样本 1 200 个,有标记样本 60 个,无关样本 390 个.

无关样本数是未经过选择的初始数量,需要首先针对各组训练数据选出 IBU 样本,实验中选择 RBF 核函数,其中的参数 $g = 0.001$.6 组分类问题选出的 IBU 样本个数分别为 21、16、17、30、16、33.

下面利用粒子群算法对 Universum SVM 中模型参数进行优选,算法初始化方式为:以最小化 5-fold 交叉验证误差为目标,利用 PSO 算法对径向基核函

数参数 g 和惩罚系数 C 、 C^* 进行优选. PSO 中的 v_{max} 取 100; w 采用线性下降法,从 0.95 下降到 0.4; g 在 $[0, 1]$ 内初始化, C 和 C^* 在 $[1, 1000]$ 内初始化;种群大小取 10;最大迭代 100 次.得到的最优参数值如表 1 所示.

表 1 PSO 对 Universum SVM 方法模型参数优选结果
Table 1 Parameters optimization result of Universum SVM with PSO algorithm

组别	g	C	C^*
1	0.000 92	523.301	1
2	0.000 13	556.413	243.308
3	0.000 41	352.068	136.753
4	0.000 83	367.823	63.262
5	0.000 77	471.446	104.352
6	0.000 64	513.528	1

为说明本文模型参数选择算法的有效性,分别采用上述最优模型参数与经验参数值对测试样本进行识别.对于舌象样本的分类,各参数的经验值分别取为: $g = 0.001$, $C = 100$, $C^* = 1$,对比结果如图 4 所示.




图 4 参数优选前后对测试样本识别准确率的比较

Fig. 4 Recognition accuracy rates on test samples before and after parameter optimization

从实验结果来看,与未对模型参数进行优选相比,利用优选后的参数对测试样本进行识别,识别准确率得到了明显提高.这说明利用粒子群算法能有效地实现对 Universum SVM 方法中模型参数的优选,对测试样本具有很好的预测能力,从而保证了引入无关样本的 Universum SVM 方法在舌象样本分类中的可行性和准确性.

5 结论

1) 为了将舌象样本中大量的无关样本利用起

来采用 Universum SVM 方法训练舌象分类器。

2) 由于无关样本的引入,需要对模型中的参数进一步优选,以保证得到的分类器具有更好的性能,而粒子群算法计算效率高,受问题维数的影响小,能同时实现对多个参数的寻优,因此采用粒子群算法实现了对 Universum SVM 算法中模型参数的寻优。

3) 对模型参数优选前后的实验结果对比表明,粒子群算法能有效地实现对 Universum SVM 模型参数的优选。

参考文献:

- [1] 邓乃扬,田英杰. 数据挖掘中的新方法——支持向量机[M]. 北京: 科学出版社,2004.
- [2] 张春华. 支持向量机中最优化问题的研究[D]. 北京: 中国农业大学经济管理学院,2004.
ZHANG Chun-hua. Optimization problems in support vector machines [D]. Beijing: College of Economics & Management, China Agricultural University, 2004. (in Chinese)
- [3] WESTON J, COLLOBERT R, SINZ F, et al. Inference with the Universum [C] // Proceedings of the 23rd International Conference on Machine Learning, Pittsburg, Pennsylvania, June 25-29, 2006: 1009-1016.
- [4] KING I. Maximum margin semi-supervised learning with irrelevant data [C/OL] // The 7th Chinese Workshop on Machine Learning and Applications. [2010-12-12]. <http://lamda.nju.edu.cn/conf/MLA09/program.htm>, Nanjing, November 6-8, 2009.
- [5] CHERKASSKY V, DAI W Y. Empirical study of the universum SVM learning for high-dimensional data [C] // Proceedings of the 19th International Conference on Artificial Neural Networks: Part I, Limassol Cyprus, September 14-17, 2009: 932-941.
- [6] HUANG Kai-zhu, XU Zeng-lin, KING I, et al. Semi-supervised learning from general unlabeled data [C] // The 8th IEEE International Conference on Data Mining, Pisa, Italy, December 15-19, 2008: 273-282.
- [7] CHEN Shuo, ZHANG Chang-shui. Selecting informative universum sample for semi-supervised learning [C] // Proceedings of the 21st International Joint Conference, Pasadena, July 11-17, 2009: 1016-1021.
- [8] ZHANG Dan, WANG Jing-dong, WANG Fei, et al. Semi-supervised classification with universum [C] // In SIAM International Conference on Data Mining (SDM), Atlanta, April 24-26, 2008: 323-333.
- [9] JIAO Yue, ZHANG Xin-feng, ZHUO Li, et al. Tongue image classification based on universum SVM [C] // The 3rd International Conference on BioMedical Engineering and Informatics, Yantai, October 16-18, 2010, 2: 657-660.
- [10] 邵信光,杨慧中,陈刚. 基于粒子群优化算法的支持向量机参数选择及其应[J]. 控制理论与应用, 2006, 23(5): 740-743, 748.
SHAO Xin-guang, YANG Hui-zhong, CHEN Gang. Parameters selection and application of support vector machines based on particle swarm optimization algorithm [J]. Control Theory & Applications, 2006, 23(5): 740-743, 748. (in Chinese)
- [11] 袁小艳,刘爱伦. 基于 PSO 算法的支持向量机核参数选择问题研究[J]. 自动化技术与应用, 2007, 26(5): 5-8.
YUAN Xiao-yan, LIU Ai-lun. Kernel parameter selection of the support vector machine based on particle swarm optimization [J]. Techniques of Automation and Application, 2007, 26(5): 5-8. (in Chinese)
- [12] 姚全珠,蔡婕. 基于 PSO 的 LS-SVM 特征选择与参数优化算法[J]. 计算机工程与应用, 2010, 46(1): 134-136, 229.
YAO Quan-zhu, CAI Jie. Feature selection and LS-SVM parameters optimization algorithm based on PSO [J]. Computer Engineering and Applications, 2010, 46(1): 134-136, 229.
- [13] SHI Y H, EBERHART R. A modified particle swarm optimizer [C] // Proceedings of IEEE World Congress on Computational Intelligence, New York, May 4-9, 1998: 69-73.
- [14] 吴涛. 核函数的性质、方法及其在障碍检测中的应用[D]. 长沙: 国防科学技术大学机电工程与自动化学院, 2003: 18-23.
WU Tao. Kernels' properties, tricks and its applications on obstacle detection [D]. Changsha: College of Mechatronic Engineering and Automation, National University of Defense Technology, 2003: 18-23. (in Chinese)
- [15] 王东,吴湘滨. 利用粒子群算法优化 SVM 分类器的超参数[J]. 计算机应用, 2008, 28(1): 134-135, 139.
WANG Dong, WU Xiang-bin. Utilizing particle swarm optimization to optimize hyper-parameters of SVM classifier [J]. Computer Applications, 2008, 28(1): 134-135, 139. (in Chinese)
- [16] 陈帅,朱建宁,潘俊,等. 最小二乘支持向量机的参数优化及其应用[J]. 华东理工大学学报: 自然科学版, 2008, 34(2): 278-282.
CHEN Shuai, ZHU Jian-ning, PAN Jun, et al. Parameters optimization of LS-SVM and its application [J]. Journal of East China University of Science and Technology: Natural Science Edition, 2008, 34(2): 278-282.

(责任编辑 杨开英)