

基于改进型人工鱼群算法的支持向量机参数优化

冯晓琳, 宁 芊, 雷印杰, 陈思羽

(四川大学 电子信息学院, 成都 610065)

摘要: 支持向量机在高维度、小样本情况下具有独特优势, 但同时支持向量机的参数优化极大制约了其分类效果, 目前参数优化缺乏系统的理论指导; 针对传统 DAG-SVM 训练分类器较多, 训练耗时长, 分类效果受到结构排序的影响, 提出了一种基于“1 vs R”策略的改进型算法; 针对 SVM 传统参数优化方式耗时大, 优化精度不高, 提出了改进型人工鱼群算法; 最后结合 1 vs R-DAG 支持向量机算法与改进型人工鱼群算法, 得到一种新的改进型支持向量机算法; 仿真对比实验证实, 对支持向量机的参数优化是有效可行的。

关键词: 支持向量机; 人工鱼群算法; 参数优化; 有向无环图

Support Vector Machine Parameter Optimization Based on Improved Artificial Fish Swarm Algorithm

Feng Xiaolin, Ning Qian, Lei Yinjie, Chen Siyu

(College of Electronics And Information Engineering, Sichuan University, Chengdu 610065, China)

Abstract: Support vector machine (SVM) algorithm has much more advantages than other classify algorithm under high-dimensional, small sample and multi-class situation. But at the same time, the parameters optimization has been one of the main factors restricting SVM effect and there is no clear theory to guide it. For original DAG-SVM algorithm's long time cost and randomness, an improved algorithm has been proposed; For traditional SVM parameter optimization's large time consuming and unsatisfactory results, an improved artificial fish swarm algorithm has been proposed; Finally, an improved support vector machine algorithm combined 1vsR-DAG-SVM and IAFSA has been proposed. Simulation experiments confirm that the SVM parameter optimization proposed in this paper is feasible and effective.

Keywords: support vector machine; artificial fish swarm algorithm; parameter optimization; directed acyclic graph

0 引言

支持向量机 (support vector machine, SVM)^[1] 是基于统计学习理论 (statistical learning theory, SLT) 的一种机器学习方法, 其在应用于分类问题时, 通过核函数将样本从输入空间映射到高维的特征空间, 并在高维的特征空间中构造问题的最优分类超平面, 实现了问题从低维空间向高维的推广, 同时也解决了维数灾难的问题。由于支持向量机有坚实的理论基础以及在小样本分类, 算法鲁棒性等多方面的许多优越性, 因此吸引了国内外许多科研人员的研究兴趣, 比较有影响与代表的研究有: 粒度支持向量机 (granular support vector machines, GSVM)^[2]、模糊支持向量机 (fuzzy support vector machines, FSVM)^[3-5]、孪生支持向量机 (twin support vector machines, TWSVMs)^[6-9]、排序支持向量机 (ranking support vector machines, RSVM)^[10-12] 等。但是支持向量机的执行效果很大程度上依赖于参数的设置, 目前尚没有统一有效的方法, 常用的参数优化方法主要有经验选择法、网格搜索法^[13-14] 和群体智能优化算法。

人工鱼群算法 (artificial fish swarm algorithm, AFSA) 是我国学者李晓磊^[15] 提出的一种模拟鱼类觅食活动的群智能算法。AFSA 模拟鱼群觅食, 据群, 追尾, 随机游动基本行为, 采用自下而上的思路进行寻优, 属于基于行为的人工智能算法。目前, 基于人工鱼群算法的研究已经渗透到多个应用领域, 并得到了很好的实际应用, 是群智能算法领域的研究热点之一^[16]。人工鱼群算法具有收敛速度较快, 鲁棒性强, 对初始参数依赖性小, 能快速收敛到可行解范围的优点, 很适合求解精度要求不高的优化问题^[17]。但同时, 人工鱼群算法也存在后期收敛性慢, 求解精度有限两个主要问题。

本文主要对支持向量机与人工鱼群算法进行优化与结合, 研究了一种基于“一对多”分类策略的 DAG-SVM 算法, 克服了传统 DAG-SVM 算法模型训练耗时长, 结构排序随机的不足。同时研究优化了一种人工鱼群算法, 克服了传统人工鱼群算法后期收敛性慢, 耗时长缺陷。最后, 结合优化的人工鱼群算法对基于“一对多”的 DAG-SVM 算法进行参数优化, 并用于实际的故障模式识别项目。实验证实, 优化后的算法在准确性与时效性上有很大提高。

1 支持向量机

支持向量机算法 (support vector machine, SVM) 通过寻找使两类样本间隔最大的超平面^[18] 从而实现样本分类问题 (如图 1 所示)。

收稿日期: 2015-11-24; 修回日期: 2016-01-04。

基金项目: 国家自然科学基金项目 (61403265)。

作者简介: 通讯作者: 冯晓琳 (1990-), 女, 山西省吕梁市, 硕士研究生, 主要从事智能控制方向的研究。

任意一个超平面可以表示为 (H 为内积空间):

$$\{(\omega \cdot x) + b = 0 \mid x \in H, b \in \mathbf{R}\} \quad (1)$$

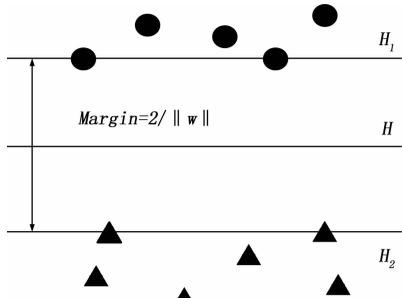


图 1 线性可分示意图

设 $\{x_1, x_2, x_3, \dots, x_l\}$ 为样本特征向量, $\{y_1, y_2, y_3, \dots, y_l\}$ 为对应的分类标签. 且 $x_i \in \mathbf{R}^n$, $y \in \{-1, 1\}$. 在线性可分的情况下, 其最优分类超平面对应的二次规划问题为:

$$\min \varphi(\omega) = \frac{1}{2}(\omega \cdot \omega) \quad (2)$$

$$s. t. y_i((\omega \cdot x_i) + b) \geq 1, i = 1, 2, 3 \dots l \quad (3)$$

在线性不可分的情况下, 通过非线性映射将样本集从低维空间映射到高维空间 (ξ_i 为非负松弛因子, C 为惩戒参数), 则问题转化为:

$$\min \varphi(\omega) = \frac{1}{2}(\omega \cdot \omega) + C \sum_{i=1}^l \xi_i \quad (4)$$

$$s. t. y_i(\omega \cdot x_i + b) \geq 1 - \xi_i, i = 1, 2, 3 \dots l \quad (5)$$

通过 Lagrange 乘数法求解最终所得的决策函数 (α_i ($i = 1, 2, 3 \dots l$) 为 Lagrange 系数):

$$f(x) = \text{sgn} \left[\sum_{i=1}^l y_i \alpha_i (x \cdot x_i) + b \right] \quad (6)$$

由于核函数在支持向量机分类效果中有决定性的作用, 因此在利用支持向量机解决分类判别时的首要任务是选择适当的核函数. 目前, 常用的核函数有: 线性核 (公式 (8)), 多项式核 (公式 (9)), 径向基核 (公式 (10)) 与 Sigmoid 核 (公式 (11)). 目前, 核函数的选择没有明确的指导原则, 一般利用“试探法”确定.

$$K(u, v) = u \cdot v + a \quad (8)$$

$$K(u, v) = [au \cdot v + b]^{\text{degree}} \quad (9)$$

$$K(u, v) = e^{-\text{gamma} \cdot |u-v|^2} \quad (10)$$

$$K(u, v) = \tanh(au \cdot v + b) \quad (11)$$

公式 (8)、(9)、(10) 以及 (11) 中: 参数 a 与 b 是常数项, \tanh 代表双曲正切函数.

考虑到标准 DAG-SVM 需要的时间长、分类器数目多、结果存在随机性等不足, 提出一种“1 vs R” DAG-SVM. 图 2 为其作拓扑结构.

2 基于改进型人工鱼群算法的 SVM 参数优化

2.1 人工鱼群算法概述

人工鱼群算法 (artificial fish swarm algorithm, AFSA) 通过自下而上的寻优模式进行寻优, 并通过种群间个体竞争与协作来实现对问题最优解的搜索.

在图 3 中, 一条人工鱼的当前位置记为 X ($X = (x_1, x_2,$

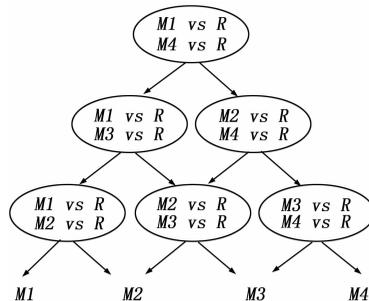


图 2 “1 vs R” - DAG-SVM 结构

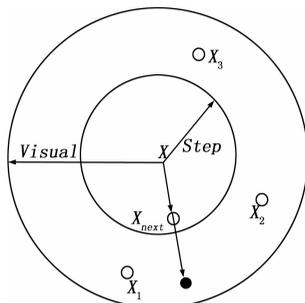


图 3 人工鱼基本模型

$x_3 \dots x_n$)), 它的视觉长度为 $Visual$, 每次能行动的最大距离为 $Step$, X_i ($i = 1, 2, 3 \dots$) 代表其它人工鱼. 人工鱼在期视野范围内随机索素, V_{next} ($V_{next} = (x_1^v, x_2^v, x_3^v \dots x_n^v)$) 表示某时刻人工鱼视点的位置, 如果 V_{next} 的事物浓度 (函数值) 大于 X 位置的食物浓度, 那么人工鱼下一步就向 V_{next} 的向量方向移动, 移动后的位置记为 X_{next} . 图中, V_{next} 与 X_{next} 的计算为公式 (12)、(13). 其中, r 是 $[-1, 1]$ 区间的随机数.

$$x_i^v = x_i + Visual \cdot r, i = 1, 2, 3 \dots n \quad (12)$$

$$X_{next} = \frac{X_v - X}{\|X_v - X\|} \cdot Step \cdot r + X \quad (13)$$

人工鱼群算法主要包括觅食, 聚群, 追尾与随机 4 种行为. 人工鱼群算法参数包括: 人工鱼群的规模 N 、人工鱼视野感知距离 $Visual$ 、人工鱼的步长 $Step$ 、拥挤度因子 δ 、试探次数 try_number . 人工鱼群算法寻优的流程图如图 4 所示.

2.2 改进型人工鱼群算法介绍

针对标准的人工鱼群算法研究后发现, 算法中固定的参数会造成迭代后期过大的计算量, 随机行为的存在不利于计算后期全局最优解的探索. 改进型人工鱼群算法实行参数动态化, 引入参数动态调节因子 λ ($0 < \lambda < 1$), 使 $Step$ 、 $Visual$ 参数能在迭代过程中动态变化, 并结合网格搜索. 其流程如图 5 所示.

3 改进型人工鱼群算法的实验对比

为探究改进型人工鱼群算法的有效性, 本节进行了两组对比仿真实验. 实验一主要对比了改进型人工鱼群算法与标准鱼群算法在算法的优化性能, 时间性能, 鲁棒性能上的优劣; 实验二主要对比了网格法, 交叉验证法, 标准人工鱼群算法与改进型人工鱼群算法对支持向量机参数寻优的优劣.

优化性能指标^[19]主要反映算法结果的精确度, 一般用“相对误差 E_m (公式 (14)、(14))”或“最优值标准差 D_m (公

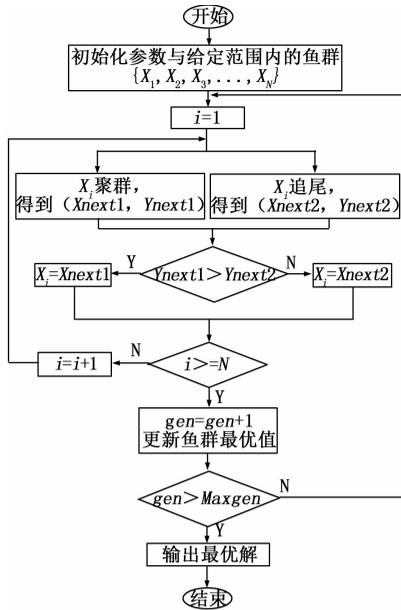


图 4 人工鱼群算法整体流程图

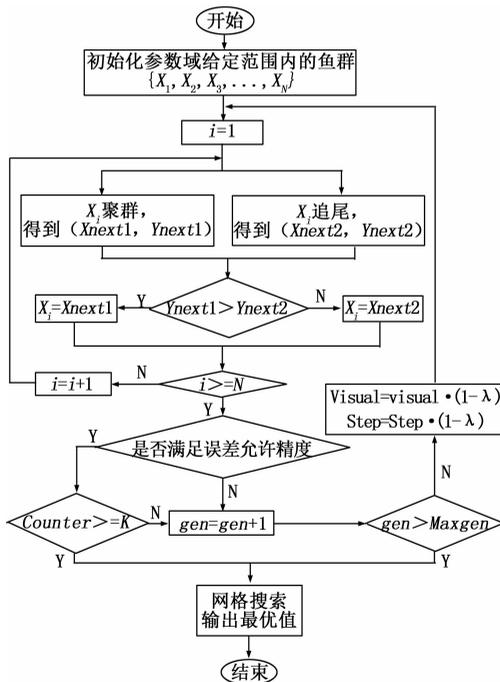


图 5 改进型人工鱼群算法流程图

式 (15))”表示。

$$E_m = \frac{C_b - C^*}{C^*} \times 100\% \quad (14)$$

$$E_m(k) = \frac{C_b(k) - C^*}{C^*} \times 100\% \quad (15)$$

$$D_m = \sqrt{\frac{\sum_{i=1}^n (C_{b,i} - C^*)^2}{n}} \quad (16)$$

公式 (14)、(15) 与 (16) 中: C^* 表示问题的理论最优解, 理论最优解未知或无法求出时可由已知最优解代替。公式 (14) 定义的是离线相对误差, C_b 代表算法运算后得到的实际

最优值; 公式 (15) 定义的是在线相对误差, 主要衡量算法的动态最佳优化度, 其中 $C_b(k)$ 代表算法运行第 k 代时的最佳优化值。公式 (16) 中, $C_{b,i}$ 代表算法重复运算第 i 次后得到的实际最优值。 $E_m, E_m(k), D_m$ 越小说明算法的优化性能, 即精确度越好。为降低随机性对实验结果产生的偏差影响, 本节对比实验采用最优值标准差 D_m 作为评价算法精度的指标, 每组对比实验统一进行 5 次测试, 即公式 (16) 中 $n = 5$ 。

时间性能指标^[19]主要反映算法的运算速度, 即算法对问题解的搜索快慢程度。时间性能指标可以直接使用算法求解运行的平均耗时表示 (公式 (17)), 也可以利用运算迭代次数 (公式 (18)) 作为衡量依据。

$$E_t = \frac{\sum_{i=1}^n T_i}{n} \quad (17)$$

$$E_s = \frac{I_a \cdot T_o}{I_{\max}} \times 100\% \quad (18)$$

公式 (17) 中, T_i 代表算法第 i 次求解最优值的耗时。公式 (18) 中, I_a 代表算法多次运行所得的满足终止条件时的迭代步数平均值, I_{\max} 代表算法允许的最大迭代次数, T_o 代表算法中一步迭代的平均耗时。 I_{\max} 一定时, E_s 越小意味着算法收敛速度越快, 即时效性越好。但是, 在实际的算法迭代过程中, 每一步的迭代耗时差异很大且精确统计也比较困难, 因此使用公式 (18) 作为时间性能评价指标可能出现很大偏差。考虑到公式 (18) 在定义上的缺陷与实际操作上引入的误差干扰, 本节对比实验采用算法求解运行的平均耗时作为算法的时间性能指标, 其中每组对比实验统一进行 5 次测试, 即公式 (16) 中 $n = 5$ 。

鲁棒性能指标^[19]主要反映算法的可靠性, 一般用均方差 (公式 (19)) 表示。其中, C_i 代表算法第 i 次运行的值, \bar{C} 表示算法 n 次运行的评价。 E_f 越小说明算法的鲁棒性 (或可靠性) 越高。

$$E_f = \sqrt{\frac{\sum_{i=1}^n (C_i - \bar{C})^2}{n}} \quad (19)$$

在仿真对比实验一中主要对比了标准人工鱼群算法与改进型人工鱼群算法之间的算法优化性能, 鲁棒性能与时间性能。仿真实验选择了十组有确定最大值的函数作为目标函数, 并使用数学手段求解了相应的最大值最为评估参考 (即表 5 中: 理论最值)。为保证仿真对比实验的有效性, 仿真对比实验一中的参数统一设置如表 1。由于人工鱼群算法中随机行为的存在, 为尽可能的减小其影响, 每组仿真对比采用 5 次重复实验取平均值的方式进行, 最终结果记录在表 2 中。

表 1 仿真实验一参数设置表

算法参数	N	$Visual$	$Step$	try_n $umber$	Max gen	δ	K	λ	ϵ
AFSA	50	1	1	30	50	0.618	/	/	/
IAFSA	50	$1 * (1 - \lambda)$	$1 * (1 - \lambda)$	30	50	0.618	10	0.05	0.01

从算法性能仿真对比实验结果 (表 2) 中数据分析可知: 由于改进型人工鱼群算法实行了参数动态设置并加入了局部网格搜索, 相对于标准人工鱼群算法其优化的结果更接近理论最值, 优化性能参数与鲁棒性参数都更小; 在时间性能方面, 由

表 2 算法性能仿真对比实验表

函数	函数最值探索区域	理论最值	寻优结果		优化性能 D_m		鲁棒性能 E_i		时间性能 E_t/s	
			AFSA	IAFSA	AFSA	IAFSA	AFSA	IAFSA	AFSA	IAFSA
$f(x) = \frac{1}{2}e^{-\frac{x^2}{2}}$	$x \in [-10, 10]$	0.5	0.500	0.500	5.50×10^{-6}	5.50×10^{-6}	4.61×10^{-6}	4.61×10^{-6}	1.21	0.568
$f(x) = x^3 - x^2 - x$	$x \in [-1, 1]$	0.185	0.185	0.185	8.86×10^{-3}	7.84×10^{-3}	8.86×10^{-3}	7.84×10^{-3}	1.44	0.562
$f(x) = -(x^2 - 1)^3 - 1$	$x \in [-10, 10]$	0	-1.54×10^{-4}	-1.20×10^{-5}	1.43×10^{-4}	1.19×10^{-5}	1.32×10^{-6}	1.11×10^{-7}	1.07	0.518
$f(x) = x^2 - 3x + 2 $	$x \in [-3, 3]$	20	20.039	20.000	0.202	5.17×10^{-4}	0.185	7.46×10^{-4}	1.359	0.615
$f(x) = 1 + \frac{36x}{(x+3)^2}$	$x \in [-5, 5]$	4	4.000	4.000	4.40×10^{-2}	4.40×10^{-2}	3.68×10^{-2}	3.68×10^{-2}	1.255	0.530
$f(x) = \cos^4 x - 2\sin x \cos x - \sin^4 x$	$x \in [0, 1.58]$	1	1.010	1.004	1.01×10^{-2}	9.47×10^{-3}	9.30×10^{-3}	9.25×10^{-3}	1.457	0.546
$f(x, y) = -(x-1)^2 - (y-1)^2$	$x \in [-10, 10]$ $y \in [-10, 10]$	0	-3.95×10^{-4}	-3.05×10^{-6}	3.93×10^{-4}	3.03×10^{-6}	3.65×10^{-6}	2.81×10^{-8}	1.067	0.604
$f(x, y) = \frac{xy}{2x^2y^2 + 4x + 4y}$	$x \in (0, 10]$ $y \in (0, 10]$	0.105	0.104	0.105	1.89×10^{-3}	1.15×10^{-3}	5.58×10^{-3}	9.67×10^{-4}	1.126	0.643
$f(x, y) = \frac{\sin x}{\cos y + 2}$	$x \in [0, 1.58]$ $y \in [0, 1.58]$	0.5	0.502	0.499	4.73×10^{-3}	4.01×10^{-3}	4.62×10^{-3}	4.59×10^{-3}	1.274	0.528
$f(x, y) = 24x\sin y - 2x^2\sin y + x^2\sin y\cos y$	$x \in [0, 10]$ $y \in [0, 1.58]$	83.138	82.126	82.715	1.685	1.194	0.856	0.762	1.396	0.589

于改进型人工鱼群算法加入了“迭代自适应机制”，其优化耗时明显小于标准算法，算法时效性得到很大提升。

为进一步探究改进型人工鱼群算法在支持向量机参数优化中的效果，进行了支持向量机参数优化对比仿真实验二。仿真实验二中对比了支持向量机参数优化常见的网格法，五折交叉验证法，标准人工鱼群优化法以及本文研究的改进型人工鱼群优化法。为保证实验对比的有效性，在对比仿真实验中 SVM 函数统一用 Libsvm 官网提供的 libsvm-3.20 程序包中提供的函数，核函数统一选择为 RBF，其它相应的参数设置如表 3 所示。

表 3 仿真实验二参数设置表

算法参数	N	Visual	Step	try-number	Maxgen	δ	K	λ	ϵ
AFSA	30	1	1	30	50	0.618	/	/	/
IAFSA	30	1* (1-)	1* (1-)	30	50	0.618	10	0.05	0.01
网格法	/	/	0.01	/	/	/	/	/	/
五折交叉验证法	/	/	0.01	/	/	/	/	/	/

对比实验针对支持向量机的 γ 、 C 参数进行优化：为保证优化范围的统一，网格法、五折交叉验证法、AFSA 与 IAFSA 的优化搜索范围统一设置为 $\gamma \in [0.01, 10]$ ， $C \in [0.01, 10]$ 。对比实验一共设置了五组不同的数据，其数据详细情况如表 4 所示。

在对比实验中，每组数据进行五次重复实验。其中算法优化时间(表 5)中数据为五次实验的平均值，优化值、判别正确率与评估正确率取五次实验中评估正确率最大的一组，实验结果记录在表 6、表 7 中。

表 4 仿真实验二数据表

数据特征	数据维度	数据类别	训练规模	评估规模	测试规模
Iris	4	3	96	24	30
Statlog	18	4	752	150	94
Yeast	8	10	959	241	284
Segment	19	7	1 600	400	310
Optical	64	10	3 060	763	1 797

表 5 仿真实验二优化时间

数据对比	SVM 参数优化耗时/s			
	网格法	交叉验证	AFSA	IAFSA
Iris	6.442	22.274	45.312	10.012
Statlog	115.208	876.466	1163.336	174.042
Yeast	224.376	1118.140	1630.144	198.150
Segment	376.791	1 360.237	2 108.530	244.510
Optical	8 043.050	3 5267.739	40 741.306	6 398.772

表 6 仿真实验二优化值

数据对比	SVM 最优参数组合/(γ, C)			
	网格法	交叉验证法	AFSA	IAFSA
Iris	(0.040, 0.040)	(2.000, 0.030)	(0.331, 0.591)	(0.010, 0.200)
Statlog	(0.500, 6.000)	(1.000, 6.000)	(1.463, 8.804)	(1.363, 2.563)
Yeast	(4.000, 8.000)	(8.000, 2.000)	(3.962, 8.354)	(4.047, 2.642)
Segment	(8.000, 6.000)	(2.000, 8.000)	(7.330, 7.012)	(3.160, 2.690)
Optical	(0.250, 4.000)	(0.250, 2.000)	(0.250, 1.503)	(0.250, 3.702)

表 7 仿真实验二优化对比

数据对比	SVM 参数评估正确率				SVM 参数判别正确率			
	网格法	交叉验证	AFSA	IAFSA	网格法	交叉验证	AFSA	IAFSA
Iris	100%	95.83%	100%	100%	86.67%	86.67%	93.33%	96.67%
Statlog	86.00%	84.04%	84.00%	82.67%	97.87%	94.68%	97.87%	99.36%
Yeast	64.32%	60.50%	64.73%	63.07%	58.45%	59.15%	58.80%	60.21%
Segment	95.50%	96.90%	95.75%	94.25%	97.42%	96.45%	96.45%	97.48%
Optical	99.21%	99.29%	99.58%	99.58%	98.50%	98.33%	98.33%	98.50%

通过分析实验数据可知: 网格法在小样本数据的优化方面耗时最短, 但优化产生的评估正确率和判别正确率间相差较大, 优化得到的参数的判别正确率较低, 且在数据较大的情况下耗时大于改进型人工鱼群算法; 五折交叉验证算法相对于网格法, 其评估正确率更接近判别正确率, 但算法的耗时相对网格法成倍增加, 在四类方法中耗时较大, 不适用于大数据情况, 且最终的判别正确率普遍小于 AFSA 与 IAFSA; AFSA 相对于网格法与五折交叉验证算法得到的评估正确率与判别正确率普遍更高, 即优化精度更高, 但 AFSA 耗时在 4 种方法中普遍最高, 同样不适用于大数据; IAFSA 耗时接近网格法, 且在大数据环境中耗时最低, 是 4 种方法中适合大数据环境的一种。在优化精度方面, IAFSA 普遍的评估正确率和判别正确率高于其它 3 类。整体上来说, IAFSA 是一种具备良好时效性能与优化性能的算法, 适合对支持向量机的参数优化。

4 结论

本文主要对支持向量机算法以及人工鱼群算法进行了研究与改进, 提出了一种混合算法——I-DAG-SVM 算法, 并运用仿真实验来验证算法优化性能。本文取得的主要成果有:

1) 针对标准 DAG-SVM 算法需要训练的分类器数量多, 耗时长, 结构排序随机的不足, 提出了“1 vs R” DAG-SVM 算法。

2) 针对 AFSA 后期收敛速度慢, 优化精度不高的弊端, 对标准算法进行了优化, 通过引入参数自适应, 迭代自终止机制, 有效提高了 AFSA 的收敛速度; 加入局部遍历算法, 提高了 AFSA 的精度。

3) 将 1 vs R-DAG-SVM 算法与 IAFSA 算法结合, 提出 I-DAG-SVM 算法, 利用其优化 SVM 参数对 UCI 官方网站的分类测试数据集进行仿真实验, 实验结果证实了算法在 SVM 参数优化中的有效性和可行性。

参考文献:

- [1] Vapnik V. The nature of statistical learning theory [M]. New York: Wiley, 1998.
- [2] Tang Yuchun, Jin Bo, Zhang Yanqing et al. Granular support vector machines for medical binary classification problems [A]. Proceedings of the IEEE CIBIB [C]. Piscataway, NJ: IEEE Computational Intelligence Society, 2004: 73-78.
- [3] Lin C F, Wang S D. Fuzzy support vector machines [J]. IEEE Transactions on Neural Networks, 2002, 3 (2): 464-471.
- [4] 张贵香, 费 岚, 杜 徐, 等. 基于类内超平面的模糊支持向量机

[J]. 计算机工程与设计, 2008, 12 (29): 3177-3178.

- [5] 李苗苗, 向凤红, 刘新旺. 一种新颖隶属度函数的模糊支持向量机 [J]. 计算机工程与科学, 2009, 31 (9): 92-94.
- [6] Jayadeva R, Khemchandani S C. Twin support vector machines for pattern classification [J]. IEEE Trans On Pattern Analysis and Machine Intelligence, 2007, 29 (5): 905-910.
- [7] Arun K M, Gopal M. Least squares twin support vector machines for pattern classification [J]. Expert Systems with Applications, 2009, 36: 7535-7543.
- [8] Zhang X S. Boosting twin support vector machine approach for MCs detection [A]. Proceedings of Asia-Pacific Conference on Information Processing [C]. Shenzhen: [s. n.], 2009, 46: 149-152.
- [9] Peng X J. A ν -twin support vector machine (ν -TSVM) classifier and its geometric algorithms [J]. Information Sciences, 2010, 180 (20): 3863-3875.
- [10] Joachims T. Optimizing Search engines using click through data [A]. Proceedings of the eighth ACM SIGKDD International Conference on Knowledge Discovery And Data Mining [C]. New York, USA: ACM, 2002, 133-142.
- [11] Cao Yunbo, Xu Jun, Liu Teyan, et al. Adapting ranking SVM to document retrieval [A]. Proceedings of the 29th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval [C]. New York, USA: ACM, 2006, 186-193.
- [12] Nguyen T, Ngo A V, Nguyen H V, et al. Probabilistic ranking support vector machine [A]. Advances in Neural Networks - ISNN 2009. Berlin: Springer, 2009 [C]. 345-353.
- [13] 郭 超, 宋卫华, 魏 威. 基于网格搜索-支持向量机的采场顶板稳定性预测 [J]. 中国安全科学学报, 2014, 24 (8): 31-36.
- [14] 李清毅, 周 昊, 林阿平, 等. 基于网格搜索和支持向量机的灰熔点预测 [J]. 浙江大学学报 (工学版), 2011, 45 (12): 2181-2187.
- [15] 李晓磊. 一种新型的智能优化方法——人工鱼群算法 [D]. 杭州: 浙江大学, 2003.
- [16] 邹 康, 刘 婷, 鲍韦韦, 等. 人工鱼群算法研究综述 [J]. 山西电子技术, 2012, 2 (2): 1674-4578.
- [17] 陈广洲, 汪家权, 李传军, 等. 一种改进的人工鱼群算法及其应用 [J]. 系统工程, 2009, 27 (12): 105-110.
- [18] 肖 晓, 张 敏. 支持向量机多分类问题研究 [J]. 淮海工学院学报 (自然科学版), 2014, 23 (3): 28-31.
- [19] 谭明交, 张宏梅, 吕艳秋. 群体智能算法及其性能评价指标研究 [J]. 计算机与数字工程, 2008, 8 (36): 10-12.