



# 基于佳点集粒子群算法的 SVM 参数优化方法

doi:10.3969/j.issn.1674-7100.2019.02.011

黄 静 官易楠

浙江理工大学  
信息学院  
浙江 杭州 310018

**摘 要:** 针对传统的粒子群算法 (PSO) 初始种群随机生成而导致的算法稳定性差和易出现早熟等问题,提出了基于佳点集改进的粒子群算法(GSPSO),并将其优化支持向量机(SVM),构建一种高效的预测评估模型(GSPSO-SVM)。首先采用佳点集方法使 PSO 中初始粒子均匀分布,然后利用 GSPSO 优化 SVM 的惩罚因子  $C$  和径向基核函数参数  $g$  以获取最佳参数值,提高 SVM 分类性和稳定性,最后将模型应用于早情数据的评估预测。仿真实验结果表明:本模型在平均准确率和方差方面的准确都取得了很好的效果;对比分别用 PSO 和遗传算法(GA)优化的 SVM 模型,本模型的性能更好。

**关键词:** 佳点集; 粒子群算法; 支持向量机; 参数优化; 早情预测

**中图分类号:** TP301.6 **文献标志码:** A

**文章编号:** 1674-7100(2019)02-0074-07

**引文格式:** 黄 静, 官易楠. 基于佳点集粒子群算法的 SVM 参数优化方法 [J]. 包装学报, 2019, 11(2): 74-80.

## 0 引言

作为一种监督式的学习算法,支持向量机(support vector machine, SVM)属于机器学习的范畴,最早由 V. N. Vapnik 等<sup>[1-2]</sup>提出。随后学者们对 SVM 进行了大量地研究,其在很多领域得到广泛应用<sup>[3-4]</sup>。SVM 的基本思路是:利用非线性函数映射方法将数据样本映射到高维空间以分离训练样本,使样本集内的每个点与高维空间的距离值达到最大。其优势是处理小样本、非线性和高维数等问题,但是 SVM 的预测精度受多种因素的影响,如核函数及其参数的选取、模型训练算法的选取以及模型设计。从核函数的参数选取的角度来看,选择不合适的参数会大大降低分类性能。目前,大量的算法被相继运用于 SVM 的参数优化中<sup>[5-11]</sup>,包括交叉验证法(cross validation, CV)、遗传算法(genetic algorithm, GA)、萤火虫

算法(glowworm swarm algorithm, GSO)、人工鱼群算法(artificial fish swarm algorithm, AFSA)和蚁群算法(ant clony optimization, ACO)等。CV 易于实现且操作简单,然而算法缺乏理论基础,且算法性能较难提升。GA 有局部搜索能力强的优点,但其搜索速度较慢且全局精度较低。GSO 以其卓越的多模态优化性能而备受学者们的关注,但却容易陷入局部最优从而产生早熟现象。AFSA 的寻优速度快,对初始参数要求也不高,但算法后期很难收敛。ACO 的鲁棒性高且可扩展性优,但若参数设置不当则会使算法的求解速度缓慢,所得解的质量不高。虽然上述算法可以从多个层面改善 SVM 的分类性能,但是难以在全局与局部、速度与精度、实用性与简易性等方面寻求平衡点。

粒子群算法(particle swarm optimization, PSO)是新兴的启发式智能算法,具有运行效率高、算法

收稿日期: 2019-01-08

基金项目: 国家重点研发计划基金资助项目(2018YFD0700700), 国家自然科学基金资助项目(51375459)

作者简介: 黄 静(1965-), 女, 浙江杭州人, 浙江理工大学教授, 主要从事嵌入式系统、专用测试设备、电子功能材料计算设计及独立分析软件的设计方面的研究, E-mail: syhj\_sy@163.com

简单易懂以及收敛速度快的优势, 适合于实值型处理<sup>[12]</sup>。在算法优化、神经网络训练、多目标优化、模糊控制等众多领域中, PSO 均取得了突出的成果。学者们也将 PSO 用于优化 SVM 参数。Xue Z. H. 等<sup>[13]</sup>在 SVM 的参数选择中嵌入了 PSO, 得到不错的分类结果。近年来, 许多学者对传统的 PSO 进行改进, 以期进一步提升 SVM 的性能。例如: Liu X. Y. 等<sup>[14]</sup>将 PSO 和布谷鸟算法结合以强化 SVM。R. R. Chhikara 等<sup>[15]</sup>则提出一种改进的 GLBPSO (global local binary PSO, GLBPSO) 算法, 通过在 PSO 迭代过程中动态地修正搜索邻居范围以提升算法性能, 进而优化 SVM。上述研究主要是针对 PSO 算法的参数进行优化, 但传统的 PSO 初始时随机地生成空间粒子, 无法确保初始解的稳定性, 这将可能导致算法的计算精度不高、对于离散型问题求解的效果不佳等。

针对 PSO 随机初始种群引起的一系列问题, 本课题组借鉴数论中佳点集思想, 提出了佳点集粒子群算法 (good-point set particle swarm optimization, GSPSO), 以保障初始种群均匀分布, 并利用 GSPSO 优化 SVM 参数, 以提高 SVM 分类器的性能, 最后利用 GSPSO-SVM 对某地的旱情数据进行预测实验, 以验证模型的有效性。

## 1 算法原理

### 1.1 PSO

PSO 是由 J. Kennedy 和 R. Eberhart 于 1995 年提出的<sup>[16]</sup>。该算法的灵感来源于自然界中鸟群觅食的行为。假设现有鸟群正在搜索某个区域空间内的食物, 这群鸟事先并不明确食物的具体位置, 而只清楚哪个个体距离食物更近, 则最快速的觅食方法是全体鸟群往该个体的附近集中搜寻。将鸟群的觅食行为进行抽象化, 具体描述如下: 将每只鸟看作一个粒子, 区域中各个粒子的初始位置和速度为随机分布, 速度决定了每个粒子的飞行方向和距离。每个粒子对应求解问题中的一个潜在解, 每个粒子的适应度值由目标函数确定, 每个粒子的最优解是个体极值, 全体种群是全局极值, 按公式 (1) 和 (2) 不断更新粒子速度与位置以追踪上述两个极值, 最终实现个体在自由空间中的寻优。

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{gd}^k - X_{id}^k), \quad (1)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1}, \quad (2)$$

式 (1) ~ (2) 中:  $d$  为维数;

$k$  为迭代次数;

$\omega$  为惯性系数;

$V_{id}^k$  为粒子  $i$  的速度;

$X_{id}^k$  为粒子  $i$  的位置;

$c_1$  和  $c_2$  为加速度因子;

$r_1$  和  $r_2$  为  $[0, 1]$  的随机数;

$P_{id}^k$  为个体极值;

$P_{gd}^k$  为全局极值。

PSO 是一种仿生算法, 存在一些缺陷, 如算法稳定性较差, 算法结果的优劣评判标准不唯一。针对上述问题, 本课题组应用数论中的佳点集 (good-point set, GS) 的理论和方法改进 PSO。

### 1.2 佳点集理论

佳点集理论首先由华罗庚等<sup>[17]</sup>提出。张铃等<sup>[18]</sup>利用佳点集理论和方法对遗传算法进行改进, 实验结果验证了以下结论:

1) 采用佳点集方法进行近似积分, 其误差的阶仅与样本数有关, 与样本的空间维数无关。

2) 运用佳点集方法的偏差为  $\varphi(n) = O(n^{-1+\varepsilon})$  (其中,  $n$  是样本数,  $\varepsilon$  是任意小的正数), 而使用随机方法的偏差为  $\varphi(n) = O(n^{-1/2} (\log \log n)^{1/2})$ 。

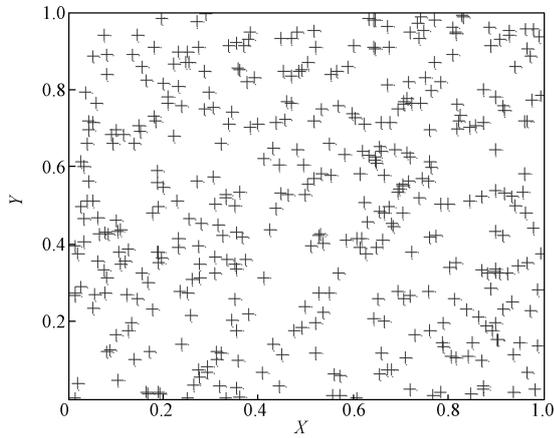
可见, 佳点集方法可以用于高维空间的近似计算; 用佳点集方法选择点比随机选择点的偏差小很多, 其偏差仅相当于随机方法的平方根级别<sup>[19]</sup>。

### 1.3 佳点集粒子群算法

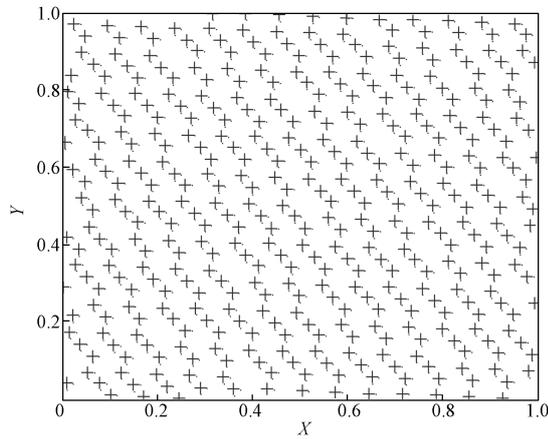
想要设计合理的 PSO 初始种群, 需要考虑如何利用尽可能少的粒子全面地表征整个空间所有潜在解的分布。如果生成的初始种群分布均远离实际解, 则很难或者无法找到问题的解。换言之, 倘若随机生成初始种群, 则很难遍历解空间中的各种情况。可见, 只有将整个解空间中最能表征潜在解分布的若干个体作为初始解集合, 实际的问题才能得到更好的解决。因此, 上述问题可以通过初始种群的均匀设计解决。受此启发, 遼少华等<sup>[20]</sup>提出了利用柯西分布方法产生初始种群, 实验结果表明该方法能克服早熟现象, 其收敛速度显著提高。然而当问题的规模突然增大时, 实验的规模也会迅速增大, 这对初始种群的均匀设计提出了更高的要求。为使计算精度不受空间维数的影响, 本课题组通过佳点集方法生成初始种群。

图 1 是分别采用随机方法和佳点集方法生成的规模为 100 的二维初始种群分布图。由图可知, 在相

同数目的取点下, 佳点集序列所产生的点比随机取点更加均匀, 设计出的群体具有更加丰富的多样性。其次, 佳点集稳定性能强, 取相同个数的点产生的种群分布, 在多次实验中所得到的效果是相同的。因此, 利用佳点集映射到目标求解空间的方式, 能够得到一个便于 PSO 处理的初始粒子种群, 理论上可以有效地提升 PSO 的性能。



a) 随机方法



b) 佳点集方法

图 1 二维初始种群分布图

Fig. 1 Two-dimensional initial population distribution

## 2 模型构建

选取径向基函数作为 SVM 核函数, 即

$$K(\mathbf{a}_i, \mathbf{a}_j) = \exp(-g \|\mathbf{a}_i - \mathbf{a}_j\|^2), \quad (3)$$

式中:  $\mathbf{a}_i, \mathbf{a}_j$  分别为第  $i$  和  $j$  个输入的列向量;

$g$  为径向基宽度, 是函数的一个重要参数,  $g > 0$ 。

本课题组利用 GSPSO 算法优化 SVM 误差惩罚因子  $C$  ( $C$  是为了解决遇到少数样本使得线性不

可分的问题而引入的调节因子) 以及参数  $g$ , 构建 GSPSO-SVM 模型。算法流程如图 2 所示, 具体步骤如下。

Step1 数据处理。导入样本数据, 将数据分成训练集和测试集, 并进行归一化处理。

Step2 参数初始化。将相关参数初始化, 包括种群规模  $sizeop$ , 加速度因子  $c_1$  和  $c_2$ , 惯性权重等; 设定算法的最大迭代数  $maxgen$ ; 利用佳点集方法生成均匀分布的粒子种群, 即确定 SVM 参数; 以 GSPSO 算法作为优化算法, 选用训练集建立 SVM 模型。

Step3 粒子适应度值的计算。均方误差作为适应度评价函数, 进行粒子适应度值的计算及评估。均方误差公式为

$$MSE = E(\hat{\theta}_i - \theta_i)^2, \quad (4)$$

式中:  $\theta_i$  为第  $i$  个粒子的原始值;

$\hat{\theta}_i$  为  $\theta_i$  的估计值。

Step4 速度和位置更新。根据适应度值的变化, 更新个体极值和全局极值, 按式 (1) 和 (2) 更新粒子的速度和位置。

Step5 判断结束条件。若未达到最大迭代次数, 则转向 Step3; 否则终结寻优, 将得到的最佳参数赋予 SVM, 即得 GSPSO-SVM 模型。

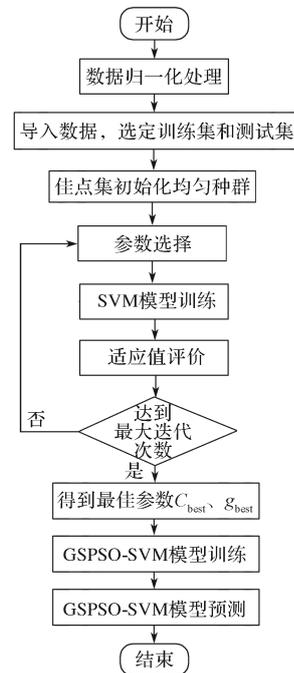


图 2 基于 GSPSO 的 SVM 模型流程图

Fig. 2 GSPSO-SVM model flow chart

### 3 实验部分

#### 3.1 数据采样和处理

为了验证 GSPSO-SVM 模型在实际运用中的可行性和有效性, 本课题组以安徽省某市近几年的 145 组旱情数据为样本。考虑旱情影响因素的多样性、复杂性, 同时依据可操作性、全面性以及定量与定性相结合的原则, 从若干相关指标中选取了 13 个最具代表性的指标进行实验, 包括参考作物蒸散量、降水量、需水量、平均气温、日照时数、20 cm 土壤相对湿度和作物系数等。样本数据用集合  $X=\{x_1, x_2, \dots, x_{13}\}$  表示。标签数据用集合  $Y$  表示, 包括 4 种情况:

干旱等级“1”表示轻涝, 干旱等级“2”表示正常, 干旱等级“3”表示轻旱, 干旱等级“4”表示重旱。因为每个样本数据包含 13 个指标, 且这些指标对应的属性存在较大的差异, 为了便于数据使用, 采用线性函数进行归一化处理, 即

$$p' = (p - p_{\min}) / (p_{\max} - p_{\min}), \quad (5)$$

式中:  $p$  为数据值;

$p_{\min}, p_{\max}$  分别为数据的最小值、最大值。

表 1 为归一化处理后的部分样本数据。从归一化处理后的样本数据中抽取 75 组作为训练样本集, 用于 SVM 分类器的数据训练; 抽取 70 组作为测试样本集, 用于 SVM 分类器的数据预测。

表 1 旱情等级预测的部分样本数据

Table 1 Partial sample data for drought level prediction

样本	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$
$X_1$	0.842 105	0.191 699	0.572 192	0.257 732	0.619 565	0.627 586	0.573 840
$X_2$	0.571 052	0.205 534	0.417 112	0.030 928	0.326 087	0.575 862	0.510 549
$X_{51}$	0.878 947	0.239 130	0.609 625	0.319 587	0.467 391	0.989 655	0.664 556
$X_{52}$	0.581 578	0.365 612	0.807 486	0.536 082	0.521 739	0.627 586	0.495 780
$X_{101}$	0.797 368	0.278 656	0.668 449	0.360 824	0.554 347	0.558 620	0.457 805
$X_{102}$	0.884 210	0.223 320	0.582 887	0.206 185	0.282 608	0.524 137	0.459 915
$X_{144}$	0.352 631	0.039 525	0	0	0.195 652	0.344 827	0.048 523
$X_{145}$	0.744 736	0.120 553	0.486 631	0.278 350	0.304 347	0.689 655	0.592 827
样本	$x_8$	$x_9$	$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$Y$
$X_1$	0.283 019	0.593 060	0.372 014	0.455 285	0.970 696	0.561 341	1
$X_2$	0.245 283	0.274 448	0.264 505	0.463 415	0.780 220	0.550 642	1
$X_{51}$	0.207 547	0.558 359	0.556 313	0.308 943	0.798 534	0.857 346	2
$X_{52}$	0.490 566	0.444 794	0.259 385	0.455 284	0.608 058	0.325 962	2
$X_{101}$	0.339 622	0.264 984	0.321 672	0.471 544	0.846 153	0.725 392	3
$X_{102}$	0.320 754	0.495 268	0.338 737	0.439 024	0.846 153	0.721 825	3
$X_{144}$	0.283 018	0.003 154	0.057 167	0.463 414	0.201 465	0.172 610	4
$X_{145}$	0.169 811	0.454 258	0.506 825	0.430 894	0.835 164	0.547 075	4

#### 3.2 实验结果与分析

本课题组采用 Matlab R2013b 软件编写代码, 实验环境为: 64 位 Windows XP 操作系统, Intel 3.10 GHz CPU。从 Libsvm 软件包中选择径向基核函数工具箱, 设置参数搜索范围  $C \in [0.1, 1000.0]$ ,  $g \in [0.01, 1000.00]$ , 粒子规模设为 20, 最大迭代次数设为 200, 学习因子  $c_1$  设为 1.5,  $c_2$  设为 1.7。

通过 GSPSO 算法最小化 SVM 的均方误差以优化参数, 本实验的参数寻优结果如图 3 所示。由图可知: GSPSO 算法在不超过 50 次迭代就已经达到收敛, 并得到了较低的适应度值; 经过 GSPSO 的全局寻优后, 最优的 SVM 参数为  $C_{\text{best}}=13.945 8$ ,  $g_{\text{best}}=3.763 4$ 。

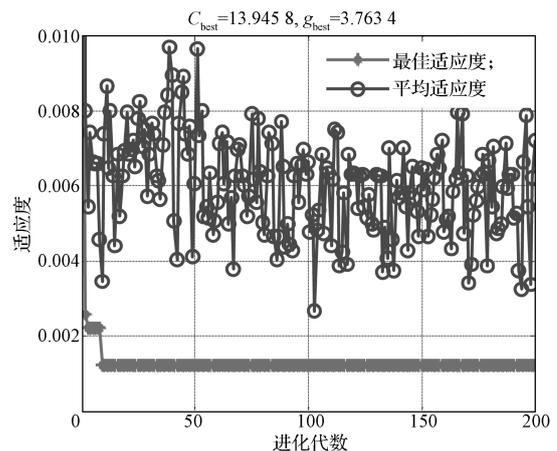


图 3 GSPSO 算法的参数优化结果图

Fig. 3 Parameter optimization results of the algorithm

将利用 GSPSO 算法优化所得的参数赋给早情预测评估模型，再用训练样本集训练早情预测评估模型，训练准确率为 100%。早情预测评估模型对测试样本集的预测结果如图 4 所示。由图可知：GSPSO-SVM 模型对 70 个测试样本集的测试中，仅有 1 个样本预测出错，即第 67 个测试样本为重旱，错误的预测为轻旱，模型预测准确率达到 98.57%，基本符合预期目标。

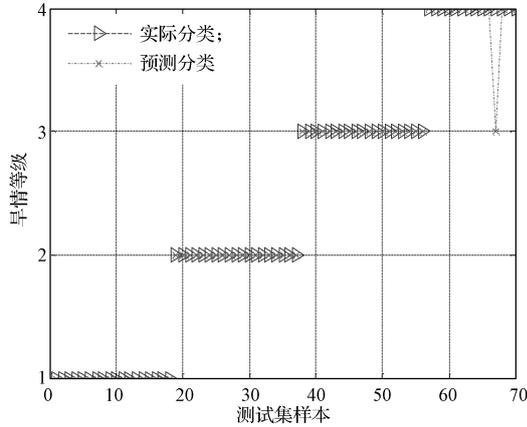
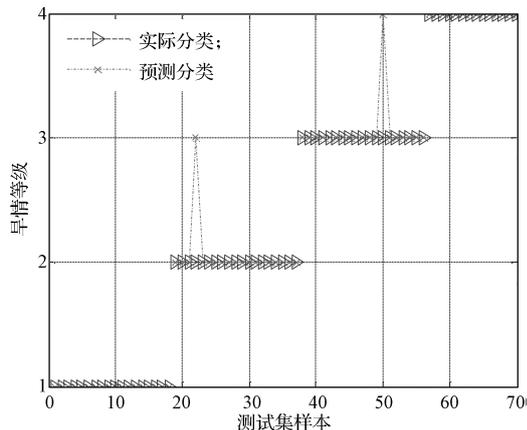


图 4 GSPSO-SVM 模型的预测结果图

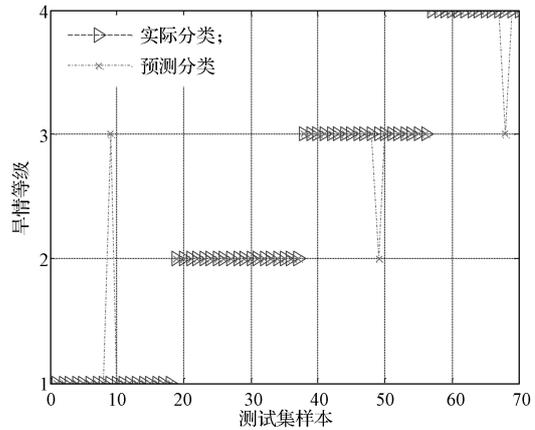
Fig. 4 GSPSO-SVM prediction results

分别以传统的 PSO 算法和 GA 算法优化 SVM 模型，并与本文模型进行比较，测试集样本的实验结果如图 5 所示。由图可知，GSPSO-SVM 的性能最佳，PSO-SVM 次之，GA-SVM 最差。

为了避免实验的偶然性因素的影响，本课题组从多个角度评判 GSPSO-SVM 模型的性能，即将 3 种模型在相同的数据集上分别独立运行 100 次，以平均准确率、方差和平均收敛时间作为评价模型性能的依据。GSPSO-SVM、PSO-SVM、GA-SVM 3 种模型的实验结果如表 2 所示。



a) PSO-SVM 模型



b) GA-SVM 模型

图 5 PSO-SVM 模型和 GA-SVM 模型的预测结果图

Fig. 5 PSO-SVM and GA-SVM prediction results

表 2 3 种模型 100 次实验的结果对比表

Table 2 comparing the results of 100 experiments of three models

模型	平均准确率 /%	方差	平均收敛时间 /s
GSPSO-SVM	98.65	0.007 6	39.31
PSO-SVM	96.14	0.010 0	46.17
GA-SVM	97.01	0.061 1	88.86

由表 2 可知：GSPSO-SVM 模型获得了最高的平均准确率，该值比 PSO-SVM 模型提高了 2.51 个百分点，比 GA-SVM 模型提高了 1.64 个百分点，这说明 GSPSO 算法能获得比传统的 PSO 算法和 GA 算法更理想的 SVM 参数  $C$  和  $g$ ，因而 SVM 分类预测的精度能得到有效的提高；GSPSO-SVM 模型预测结果的方差为 0.007 6，远低于另外两种模型的方差，这表明 GSPSO 算法的稳定性得到了很大的提高，即本文算法的稳定性较好。

在算法收敛速度方面，3 种模型运行的最大和最小收敛时间如图 6 所示。图中折线段的端点为算法运行的平均收敛时间。

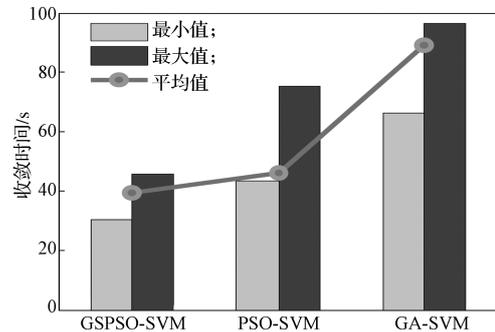


图 6 各模型的收敛时间对比图

Fig. 6 Convergence time comparison of each model

由图 6 可知, GSPSO-SVM 模型能大大节省时间, 其收敛时间明显低于另外两种模型, 根本原因在于佳点集理论的均匀思想使得初始解的分布更加均匀, 容易遍布空间的各个角落, 更快搜索到目标解。

## 4 结语

本文提出了一种基于佳点集方法的粒子群算法。通过在基本粒子群算法中引入佳点集理论, 对初始种群进行均匀化设计, 可以较好地增强 PSO 的稳定性; 应用 GSPSO 算法对 SVM 的参数进行优化, 不仅避免了 SVM 出现早熟和易陷入局部最优的问题, 更能提高 SVM 分类预测的稳定性和精度。将构建的 GSPSO-SVM 模型应用在安徽省某市的旱情数据分析中, 实验结果表明了所提方法的高效性。但本算法还存在一些不足之处以待进一步改进, 如在迭代过程中动态地缩小参数的取值区间以提高 PSO 的寻优精度, 这将是本课题组未来的研究重点。

### 参考文献:

- [1] CORTES C, VAPNIK V N. Support Vector Networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [2] VAPNIK V N. An Overview of Statistical Learning Theory[J]. *IEEE Transactions on Neural Networks*, 1999, 10(5): 988-999.
- [3] CHEN D D, TIAN Y J, LIU X H. Structural Nonparallel Support Vector Machine for Pattern Recognition[J]. *Pattern Recognition*, 2016, 60: 296-305.
- [4] SUN J, FUJITA H, CHEN P, et al. Dynamic Financial Distress Prediction with Concept Drift Based on Time Weighting Combined with Adaboost Support Vector Machine Ensemble[J]. *Knowledge-Based Systems*, 2017, 120: 4-14.
- [5] LI Q, SALMAN R, TEST E, et al. Parallel Multitask Cross Validation for Support Vector Machine Using GPU[J]. *Journal of Parallel and Distributed Computing*, 2013, 73(3): 293-302.
- [6] GARCÍA NIETO P J, GARCÍA-GONZALO E, SÁNCHEZ LASHERAS F, et al. Hybrid PSO-SVM-Based Method for Forecasting of the Remaining Useful Life for Aircraft Engines and Evaluation of Its Reliability[J]. *Reliability Engineering & System Safety*, 2015, 138: 219-231.
- [7] GURAV A, NAIR V, GUPTA U, et al. Glowworm Swarm Based Informative Attribute Selection Using Support Vector Machines for Simultaneous Feature Selection and Classification[C]//International Conference on Swarm, Evolutionary, and Memetic Computing. [S. l.]: Springer, 2014: 27-37.
- [8] LIU J J, LI Z, HU F R, et al. A THz Spectroscopy Nondestructive Identification Method for Transgenic Cotton Seed Based on GA-SVM[J]. *Optical and Quantum Electronics*, 2015, 47(2): 313-322.
- [9] SHAN C, SUN J, WU T, et al. Dynamic Sensor Fault Detection in WSNs by Adaptive GASVM[J]. *Journal of Computational Information Systems*, 2014, 10(20): 8669-8676.
- [10] GAO Y Y, SHEN Y J, ZHANG G D, et al. Information Security Risk Assessment Model Based on Optimized Support Vector Machine with Artificial Fish Swarm Algorithm[C]//2015 6th IEEE International Conference on Software Engineering and Service Science (ICSESS). Beijing: IEEE, 2015: 599-602.
- [11] 邱志刚. 基于蚁群优化支持向量机的公路隧道围岩变形预测模型及应用[J]. *隧道建设*, 2014, 34(1): 13-18.  
QIU Zhigang. Highway Tunnel Surrounding Rock Deformation Prediction Model Based on Support Vector Machine Optimized by Ant Colony Optimization and Its Application[J]. *Tunnel Construction*, 2014, 34(1): 13-18.
- [12] 梁 枫, 秦 斌, 王 欣, 等. 基于粒子群算法的地铁列车节能运行优化[J]. *湖南工业大学学报*, 2016, 30(6): 29-33.  
LIANG Feng, QIN Bin, WANG Xin, et al. Optimization of Energy Saving Operation for Metro Trains Based on Particle Swarm Optimization[J]. *Journal of Hunan University of Technology*, 2016, 30(6): 29-33.
- [13] XUE Z H, DU P J, SU H J. Harmonic Analysis for Hyperspectral Image Classification Integrated with PSO Optimized SVM[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2014, 7(6): 2131-2146.
- [14] LIU X Y, FU H. PSO-Based Support Vector Machine with Cuckoo Search Technique for Clinical Disease Diagnoses[J]. *The Scientific World Journal*, 2014, 2014: 1-7.
- [15] CHHIKARA R R, SHARMA P, SINGH L. A Hybrid Feature Selection Approach Based on Improved PSO and Filter Approaches for Image Steganalysis[J]. *International Journal of Machine Learning and Cybernetics*, 2016, 7(6): 1195-1206.
- [16] KENNEDY J, EBERHART R. Particle Swarm Optimi-

- zation[C]//Proceedings of International Conference on Neural Networks(ICNN' 95). Perth: IEEE, 1995, 4: 1942-1948.
- [17] 华罗庚, 王元. 数论在近似分析中的应用[M]. 北京: 科学出版社, 1978: 83-86.  
HUA Luogeng, WANG Yuan. Applications of Number-Theoretic Methods in Approximate Analysis[M]. 1978: 83-86.
- [18] 张铃, 张钹. 佳点集遗传算法[J]. 计算机学报, 2001, 24(9): 917-922.  
ZHANG Ling, ZHANG Bo. Good Point Set Based Genetic Algorithm[J]. Chinese Journal of Computers, 2001, 24(9): 917-922.
- [19] 方贤, 铁治欣, 李敬明, 等. 多模态函数聚类后再创种群的并行搜索佳点集萤火虫算法[J]. 浙江理工大学学报(自然科学版), 2017, 37(6): 843-850.  
FANG Xian, TIE Zhixin, LI Jingming, et al. A Parallel Search Good-Point Set Glowworm Swarm Optimization of Re-Created Population after Clustering of Multi-Modal Functions[J]. Journal of Zhejiang Sci-Tech (Nature Sciences Edition), 2017, 37(6): 843-850.
- [20] 逮少华, 张晓伟, 鲍承强, 等. 柯西种群分布的自适应范围粒子群优化算法[J]. 计算机应用, 2014, 34(4): 1070-1073, 1079.  
LU Shaohua, ZHANG Xiaowei, BAO Chengqiang, et al. Adaptive Range Particle Swarm Optimization with the Cauchy Distributed Population[J]. Journal of Computer Applications, 2014, 34(4): 1070-1073, 1079.
- (责任编辑: 邓彬)

## Parameter Optimization Method of SVM Based on Good-Point Set Particle Swarm Optimization

HUANG Jing, GUAN Yinan

(School of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

**Abstract:** In order to solve the problems of poor stability and premature phenomenon caused by the initially randomly generated population in traditional particle swarm optimization (PSO) algorithm, a good-point set particle swarm optimization (GSPSO) was proposed. Based on that, an efficient prediction model (GSPSO-SVM) was constructed by combining support vector machine (SVM). The good-point set was utilized to make the initial particles uniformly distributed in PSO algorithm, and then GSPSO was used to optimize the penalty factor  $C$  and radial basis function parameter  $g$  of SVM to obtain the best parameter for improving the accuracy and stability of classification of SVM. Finally, the model was successfully applied to the drought forecasting. The simulation results showed that the model have achieved good results in average accuracy and variance. Compared with PSO and genetic algorithm (GA) to optimize SVM model, the performance has been improved.

**Keywords:** good-point set; particle swarm optimization; support vector machine; parameter optimization; drought forecasting