

吕赵明,张颖江.基于改进 GOA-SVM 算法的异常流量识别[J].湖南科技大学学报(自然科学版),2019,34(4):90-96.doi:10.13582/j.cnki.1672-9102.2019.04.013

Lv Z M, Zhang Y J. Abnormal Traffic Identification Based on Improved GOA-SVM Algorithm [J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2019, 34(4):90-96.doi:10.13582/j.cnki.1672-9102.2019.04.013

基于改进 GOA-SVM 算法的异常流量识别

吕赵明*,张颖江

(湖北工业大学 计算机学院,湖北 武汉 430068)

摘要:异常流量的准确识别在网络安全中起着重要作用,支持向量机(Support Vector Machine, SVM)已经成功地应用于分类和函数逼近等方面,而核函数参数和惩罚参数(C)的选取对 SVM 的分类性能起着关键作用.为了提高 SVM 的分类性能,提出一种基于改进蚱蜢算法优化 SVM 的异常流量识别方法,命名为 SAGOA-SVM.在对蚱蜢算法进行实验研究后发现其局部搜索能力较弱,本文通过引入模拟退火算法和位置偏移机制增强蚱蜢趋向食物源的随机性来改进蚱蜢算法优化 SVM 参数的性能,从而提高 SAGOA-SVM 算法对异常流量的识别率.在选取的 7 个标准 UCI 数据集上的实验结果表明,所提出的 SAGOA-SVM 算法有很好的分类精度和性能.

关键词:蚱蜢优化算法;模拟退火算法;支持向量机;核函数;异常流量识别

中图分类号:TP393 文献标志码:A 文章编号:1672-9102(2019)04-0090-07

Abnormal Traffic Identification Based on Improved GOA-SVM Algorithm

Lv Zhaoming, Zhang Yingjiang

(School of Computer Science, Hubei University of Technology, Wuhan 430068, China)

Abstract: Accurate identification of abnormal traffic played an important role in network security. Support vector machine (SVM) was successfully applied to classification and function approximation. However, the selection of kernel function parameters and penalty parameters (C) played a key role in SVM classification performance. To improve the classification performance of SVM, an abnormal traffic identification method based on improved grasshopper optimization algorithm for optimizing SVM is proposed, named SAGOA-SVM. An experimental study of grasshopper algorithm show that its local search ability was weak. In order to enhance the local search ability of the algorithm, the simulated annealing algorithm (SA) and the position offset mechanism were introduced. Therefore, the performance of the algorithm for searching SVM parameters was improved. Experimental results on selected 7 standard UCI datasets show that the proposed SAGOA-SVM algorithm has good classification accuracy and performance.

Keywords: grasshopper optimization algorithm; simulated annealing algorithm; support vector machine; kernel function; abnormal traffic identification

支持向量机是基于统计学习理论的机器学习方法,它在解决小样本、高维数、非线性和局部极小点等

收稿日期:2018-04-12

基金项目:教育部下一代互联网创新项目基金资助(NGII20150404)

*通信作者,E-mail: 630245285@qq.com

问题方面有较好的效果.而核函数参数和惩罚参数(C)的选取对 SVM 的分类性能起着关键作用^[1-2].

在异常流量识别中,为了提高支持向量机的分类精度,采用合适的策略优化 SVM 参数至关重要.随着群体智能优化算法的广泛应用,出现了一些基于群体智能算法优化 SVM 参数的研究成果,如 Sudheer C 等^[3-6]提出了基于粒子群算法的 SVM 参数优化及应用,从而提高了 SVM 分类准确率;孟涛等^[7-9]提出了基于遗传算法的 SVM 参数优化及应用;Sayed G I^[10]提出了基于优化觅食算法的 SVM 参数优化方法,其他类似的方法还有 K P Wu 等^[11-14].然而基本的粒子群算法和蝙蝠算法易陷入局部极值,出现早熟现象,遗传算法存在局部搜索能力较差、搜索速度慢等问题.这些算法在一定程度上优化选取了 SVM 的核参数并取得了分类精度,但优化算法的缺陷并未得到改进,从而导致核参数选取存在局限性.

蚱蜢优化算法(Grasshopper Optimization Algorithm, GOA)^[15]是 Mirjalili 于 2016 年提出的一种新型启发式群体智能优化算法,它基于对自然界真实蚱蜢群体的觅食行为的研究,模拟真实蚱蜢的觅食行为特征.该算法通过一个位置更新公式更新群体位置,具有很强的全局搜索能力和局部搜索能力,其原理简单,易于实现,设置参数少.文献[11]已经验证了 GOA 算法优于粒子群算法(Particle Swarm Optimization, PSO)、萤火虫算法(Firefly Algorithm, FA)、蝙蝠算法(Bat Algorithm, BA)和遗传算法(Genetic Algorithm, GA)等算法.本文提出一种基于改进的蚱蜢算法优化 SVM 的异常流量识别算法(SAGOA-SVM),通过引入模拟退火算法和位置偏移机制提高蚱蜢趋向食物源的随机性来改进蚱蜢优化算法搜索的充分性,从而提高算法的局部搜索性能,最后运用该算法优化 SVM 参数,提高对异常流量的识别精度.实验结果表明:改进的 SAGOA-SVM 算法分类精度高于 GOA-SVM, PSO-SVM, BA-SVM 和 GA-SVM 算法.

1 支持向量机概述

支持向量机是由 Vapnik 等人根据统计学理论提出的一种新的机器学习方法^[1],它通过构造一个超平面使 2 类样本集分开,并且具有最大间隔.

对于线性可分情况,会存在一个超平面使得训练样本完全分开,这样的超平面方程可以描述为

$$\mathbf{w}^T \cdot \mathbf{x} + b = 0. \quad (1)$$

式中: \mathbf{w} 为 n 维向量; \mathbf{x} 为特征向量; b 为截距.

首先构造并求解约束最优化问题:

$$\min \varphi(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2; \quad (2)$$

$$\text{s.t. } y_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq 1, i = 1, 2, 3, \dots, n. \quad (3)$$

式中: y_i 为 \mathbf{x}_i 的类标记; \mathbf{x}_i 为第 i 个特征向量; $\varphi(\cdot)$ 为非线性函数.

求得最优解 \mathbf{w}^* , b^* , 然后得到分离超平面:

$$\mathbf{w}^* \cdot \mathbf{x} + b^* = 0. \quad (4)$$

分类决策函数为

$$f(x) = \text{sign}(\mathbf{w}^* \cdot \mathbf{x} + b^*). \quad (5)$$

对于线性不可分情况,通过非线性函数 $\varphi(\cdot)$ 将数据映射到特征空间,然后在特征空间使用线性学习器.首先选取适当的核函数 $K(\mathbf{x}_i, \mathbf{x}_j)$ 和适当的参数 C , 构造并求解最优化问题:

$$\max W(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i,j=1}^n y_i y_j a_i a_j K(\mathbf{x}_i, \mathbf{x}_j); \quad (6)$$

$$\text{s.t. } 0 \leq a_i \leq C, \sum_{i=1}^n a_i y_i = 0. \quad (7)$$

式中: a_i 为拉格朗日乘子; $K(\mathbf{x}_i, \mathbf{x}_j)$ 为核函数; C 为惩罚参数.

得到最优解 $\mathbf{a}^* = (a_1^*, a_2^*, \dots, a_l^*)^T$, 从 \mathbf{a}^* 中选择一个分量 $0 < a_i^* < C$ 计算:

$$b^* = y_j - \sum_{i=1}^l y_i a_i^* K(\mathbf{x}_i, \mathbf{x}_j). \quad (8)$$

最终的判别函数为

$$f(x) = \text{sign}\left(\sum_{i=1}^n a_i^* y_i K(\mathbf{x}_i, \mathbf{x}_j) + b^*\right). \quad (9)$$

SVM 算法中应用到的核函数主要有 4 种:线性核函数、多项式核函数、径向基核函数(RBF)和 Sigmoid 函数.由于 RBF 核可以将样本映射到一个更高维的空间,可以处理样本的标签和属性之间是非线性的样例,因此本文以径向基核函数作为 SVM 核函数参数优化对象:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left\{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right\}. \quad (10)$$

式中: σ 为核参数.

惩罚参数 C 和核参数 σ 是影响 RBF 核函数的 2 个重要参数.惩罚参数 C 表示对误差的宽容度, C 的值过大将会出现过拟合的现象,导致泛化能力降低, C 的值过小将会出现欠拟合的现象,并会导致错分样本数和支持向量数升高.核参数 σ 控制函数的径向宽度,一个非常小的 σ 值会导致 RBF 核值等于 0,因此会出现过拟合的现象,一个非常大的 σ 值会导致错分的样本数和支持向量数升高,就会出现欠拟合的现象.

2 基本蚱蜢优化算法

基本的蚱蜢优化算法模仿蚱蜢寻找食物源时的突然移动的行为实现算法的勘探过程,模仿其移动到局部食物源并消耗食物的行为实现算法的挖掘过程.蚱蜢的这些行为都是自然进行的,算法通过一个位置更新公式模拟蚱蜢的 2 个行为,蚱蜢的下一个位置是根据当前的位置、全局目标值和所有其他蚱蜢的位置来更新的^[15].蚱蜢在 d 维空间中位置的更新的仿真数学模型为

$$\mathbf{X}_i = c_w \left(\sum_{\substack{j=1 \\ j \neq i}}^N c_n \frac{\varepsilon - \eta}{2} s(d_{ij}) \frac{\mathbf{x}_j - \mathbf{x}_i}{d_{ij}} \right) + \bar{T}_d. \quad (11)$$

式中: \mathbf{X}_i 为第 i 个蚱蜢的位置向量; c_w 为类似于粒子群算法中的惯性权重 ω ,它平衡了围绕目标的整个群体的探索和挖掘; ε 和 η 为搜索范围的上界和下界; s 为吸引力函数; $d_{ij} = \|\mathbf{x}_i - \mathbf{x}_j\|$ 是第 i 只蚱蜢和第 j 只蚱蜢之间的距离; \mathbf{x}_i 为第 i 只蚱蜢的位置向量; \mathbf{x}_j 为第 j 只蚱蜢的位置向量; \bar{T}_d 为当前搜索到的最优目标值; c_n 为内部参数,它是收缩舒适区域、排斥区域和吸引区域的递减系数,计算公式为

$$c_w = c_n = c_{\max} - t \frac{c_{\max} - c_{\min}}{L}. \quad (12)$$

式中: c_{\max} 为最大值; t 为当前迭代; c_{\min} 为最小值; L 为最大迭代次数.

$s(r)$ 是社会作用部分,该函数随着参数 u 和 τ 的变化,可以将 2 只蚱蜢之间的空间分成排斥区域、舒适区域和吸引区域,其表达式为

$$s(r) = ue^{\frac{r}{\tau}} - e^{-r}. \quad (13)$$

式中: s 为吸引力函数; u 是吸引力强度; r 是距离变量; τ 为吸引力的范围.

文献[11]中详细解释了随着蚱蜢之间距离的变化,社会作用力(吸引或排斥)函数的变化,当一只蚱蜢距离另一只蚱蜢 2.0 单位时,此时既没有吸引力也没有排斥力称为舒适区域.当函数 $s(r)$ 的值大于 0 时,蚱蜢之间处于吸引状态,此时它们所在的范围称为吸引区域.当函数 $s(r)$ 的值小于 0 时,蚱蜢之间处于排斥状态,此时它们所在的区域范围称为排斥区域.式(14)是第 i 只蚱蜢和第 j 只蚱蜢之间的距离:

$$d_{ij} = \|\mathbf{x}_j - \mathbf{x}_i\|. \quad (14)$$

式(15)是从第 i 个蚱蜢到第 j 个蚱蜢的单位向量:

$$\hat{\mathbf{d}}_{ij} = \frac{\mathbf{x}_j - \mathbf{x}_i}{d_{ij}}. \quad (15)$$

算法通过蚱蜢的相互作用,随着参数 c_n 的线性递减算法逐渐向食物源逼近并最终消耗食物,从而搜

索到全局最优值.

3 SAGOA-SVM 算法

GOA 搜索效果如图 1 所示.在蚱蜢优化算法搜索过程中,通过调整参数 c_n 改变舒适区域、排斥区域和吸引区域,使群体逐渐向当前获得的最佳目标值移动,经过若干次迭代后逼近全局最优值.在算法的实现中,首先随机初始化种群,并计算每个粒子的适应度函数值,将最小适应度值作为目标值,所有群体追随该目标值.其次,算法在每次迭代过程中更新当前群体的位置并计算适应度值,如果该适应度值优于当前目标值,那么替换当前适应度值作为目前获得的最佳目标值,随着目标值越来越精确最终接近全局最优值.然而,算法在迭代过程中会出现连续多代最优值得不到更新的现象,只有最后局部搜索改变了最优值.由于成年的蚱蜢在寻找食物源时具有长距离和突跳的行为,寻找的食物源具有很强的随机性,导致整个搜索过程不充分,如图 1 所示稀疏部分,中间白点为最优目标值.




图 1 GOA 搜索效果

基于以上分析,为了提高算法搜索的充分性,本文提出采用位置随机偏移机制和模拟退火算法增加目标值的随机性^[16-18],使算法摆脱上述现象.在每次迭代更新目标值时,如果新位置的适应度值优于当前目标值,那么替换当前适应度值作为目前获得的最佳目标值,否则,采用位置随机偏移机制,使当前搜索到的位置向任意方向偏移,偏移量如式(16)所示.

$$\begin{cases} p = L_i + (H_i - L_i)R; \\ X_{i+1} = X_i + X_i p. \end{cases} \quad (16)$$

式中: p 为偏移量; L_i 为搜索最小值; H_i 为搜索最大值; R 为随机数; X_i 为个体位置.

计算该位置的适应度值作为新目标值,并通过模拟退火算法接受这个新目标值,模拟退火算法具有概率突跳的能力,在退火过程中不但能接受好的解,而且还能以一定的概率接受差的解.高随机性的目标值使算法在解空间得以充分搜索,可以有效地增强局部搜索.

改进的算法 SAGOA 在搜索最优解时,当前目标位置随机发生偏移.最初算法朝着原始目标值 T 的方向进行搜索,而原始方向已偏离了最优目标值,虽然算法在搜索结束时可以逼近最优值,但算法在迭代过程中会出现多次最优值得不到更新的现象,导致整个搜索性能下降.偏移后的方向有可能打破这种现象并尽快指向最优目标值方向,如图 2 所示.当目标值偏移方向后,算法将均匀收敛到最优目标值,其搜索效果如图 3 所示,从图 3 可以看出群体均匀地向最优目标值逼近.




图 2 当前目标位置 T_c 发生偏移




图 3 SAGOA 搜索效果

SAGOA-SVM 算法的计算步骤如下:

步骤 1:初始化 SAGOA-SVM 算法的基本参数包括种群大小、空间维数、迭代次数、初始温度和退火常数等.

步骤 2:初始化参数 C 和 σ 的种群并加载数据集,交叉拆分数据集为训练集和测试集,采用 3 折交叉验证法训练 SVM 作为适应度值,并以错误率最小的训练值作为算法的目标值,计算公式如下:

```

cmd = [ '-v', num2str(v), '-c', num2str(P(i,1)), '-g', num2str(P(i,2)) ];
fitness(i) = svmtrain(train_label, train_set, cmd);
fitness(i) = 100 - fitness(i);

```

步骤 3:通过式(12)更新参数 c_n 值.

步骤 4:计算蚱蜢之间的距离并根据式(11)更新当前的位置.

步骤 5:如果新位置的适应度值优于当前的目标值,更新当前的目标值.

步骤 6:由式(16)计算随机偏移量更新位置,并训练新的适应度值,如果偏移后得到的新适应度值优于当前目标值,更新当前目标值为偏移后的适应度值,否则以一定的概率接受新适应度值.

步骤 7:进行退温操作.

步骤 8:判断是否满足最大迭代次数,不满足转到步骤 3.

步骤 9:输出全局最优参数 C 和 σ 并保存.

步骤 10:采用优化的 C 和 σ 训练 SVM,并通过测试集预测结果,算法结束.

4 仿真实验及分析

4.1 实验准备

本文从 UCI 机器学习库中选择 australian, iris, diabetes, wine, Breast-cancer, heart 和 liver 这 7 种数据集进行实验,数据集的详细描述如表 1 所示.开发 SAGOA-SVM 算法的使用工具包为 libsvm,开发环境为 Intel(R)Core(TM) i3-2120 CPU @ 3.30 GHz,8 G RAM, Window 7 操作系统和 MATLAB R2016a^[19].为了验证本文提出的 SAGOA-SVM 算法的有效性,本实验使用改进的 SAGOA-SVM 算法与基本的 GOA-SVM 算法,PSO-SVM,BA-SVM 和 GA-SVM 算法进行对比实验.

表 1 实验使用的数据集

数据集	样本数	特征数	训练集	测试集
australian	690	14	345	345
iris	150	4	75	75
wine	178	13	89	89
diabetes	768	8	384	384
liver	145	5	74	71
Breast-cancer	683	10	342	341
heart	270	13	220	50

4.2 参数初始化

群智能优化算法的参数初始化对算法的优化性能起着关键作用.为了验证算法的可比性,对于公有的算法参数进行一致性设置,种群大小都设为 60,最大迭代次数 200, C 和 σ 的搜索范围均为 $[2^{-5}, 2^5]$,由于搜索的参数对是 (C, σ) ,所以均初始化为 2 维的种群.所有算法的私有参数设置如表 2 所示.

表 2 算法的私有参数设置

算法	参数	参数值
	c_{max}, c_{min}	$c_{max} = 1, c_{min} = 0.000\ 04$
GOA	attractive length scale(τ)	$\tau = 1.5$
	attraction force(u)	$u = 0.5$
SA	annealing constant	$\alpha = 0.5$
	initial temperature	$T = \text{Fitness}/\log(5);$
PSO	Cognitive and social constants	$c_1 = 1.5, c_2 = 1.7$
	Inertial weight(ω)	$\omega = 0.9$
	Frequency(f_{min} and f_{max})	$f_{min} = 0$ and $f_{max} = 2$
BA	Pulse rate(r)	$r = 0.5$
	Loudness(A)	$A = 0.7$
GA	Coding type	Binary Coded
	Select type	Stochastic Universal Sampling
	Crossover probability	0.7
	Mutation probability	0.9

4.3 实验结果及分析

为了评估 SAGOA-SVM 算法的性能,实验选取 7 种标准数据集进行仿真实验,并同 GOA-SVM, PSO-SVM, BA-SVM 和 GA-SVM 算法进行比较.每种算法分别使用 7 种标准数据集独立运行 10 次,并计算预测精度的平均值和标准差,计算结果如表 3 所示.从表 3 中的平均精确度和标准偏差中可以看出:SAGOA-SVM 算法的整体效果比 GOA-SVM, PSO-SVM, BA-SVM 和 GA-SVM 算法好,分类准确率高于 GOA-SVM, PSO-SVM, BA-SVM 和 GA-SVM 算法.

表 3 算法 SAGOA-SVM 和 SI-SVM 性能对比

数据集	平均精度±标准差				
	SAGOA-SVM	GOA-SVM	PSO-SVM	BA-SVM	GA-SVM
australian	86.41%±0.14	86.36%±0.12	85.80%±0.37	85.51%±0.57	86.38%±0.19
iris	96.03%±1.14	94.93%±1.51	95.07%±0.91	95.62%±0.82	95.62%±1.03
wine	98.88%±0.87	98.54%±0.72	40.11%±1.33	93.60%±1.24	98.09%±0.72
diabetes	77.98%±0.08	77.64%±0.21	77.02%±0.16	77.46%±0.18	77.23%±1.50
liver	66.76%±0.69	61.27%±5.98	66.48%±0.85	65.77%±4.76	64.79%±3.83
Breast-cancer	97.64%±0.00	97.67%±0.09	97.67%±0.16	97.35%±0.72	97.52%±0.35
heart	82.86%±0.74	81.50%±2.48	83.46%±0.00	83.23%±0.48	78.87%±4.64

图 4 是 SAGOA-SVM 算法与其他算法在数据集 liver 中独立运行 10 次预测结果的曲线图,横坐标是运行次数,纵坐标是测试正确率.图 4 中 GA-SVM 算法只有在运行第 9 次时预测正确率高于 SAGOA-SVM 算法.数据集 liver 上的误差棒图如 5 所示,从图 5 中可以看出:SAGOA-SVM 不仅在平均正确率上高于其他算法而且误差最小,证明 SAGOA-SVM 算法的鲁棒性高于 GOA-SVM, PSO-SVM, BA-SVM 和 GA-SVM 算法,取得了更好的分类效果.

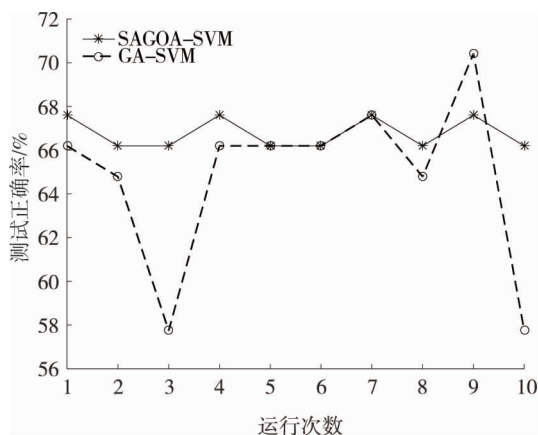


图 4 算法 SAGOA-SVM 和 GA-SVM 的预测结果




图 5 数据集 liver 上的误差棒图

仿真结果表明:基于 SAGOA-SVM 算法的异常流量识别是行之有效的,但在异常流量识别中,异常流量数据集的预处理和特征提取也会影响算法的分类性能,因此实验选取了小样本低维数据集验证 SAGOA-SVM 算法的有效性.

5 结论

1) SAGOA-SVM 算法在异常流量的识别中的性能高于 GOA-SVM, PSO-SVM, BA-SVM 和 GA-SVM 算法.

2) 对智能优化算法的缺点进行改进,并应用于异常流量的识别中比未改进前的应用更加有效.

3) 蚱蜢优化算法是一种新型的群体智能优化算法,其在实际工程应用中还处于起步阶段,在以后的研究中将继续从蚱蜢优化算法的应用及性能的改进等方面进行研究.

参考文献:

- [1] Harrington P. 机器学习实战[M]. 李锐, 李鹏, 曲亚东, 译. 北京: 人民邮电出版社, 2013: 89-106.
- [2] 于剑. 机器学习: 从公理到算法[M]. 北京: 清华大学出版社, 2017: 163-179.
- [3] Sudheer C, Maheswaran R, Panigrahi B K, et al. A hybrid SVM-PSO model for forecasting monthly streamflow[J]. *Neural Computing and Applications*, 2014, 24(6): 1381-1389.
- [4] Gong Q, Lu W, Gong W, et al. Short-term load forecasting of LSSVM based on improved PSO algorithm[C]//Chinese Conference on Pattern Recognition, 2014.
- [5] García-Nieto P J, García-Gonzalo E, Vilán J A, et al. A new predictive model based on the PSO-optimized support vector machine approach for predicting the milling tool wear from milling runs experimental data[J]. *Advanced Manufacturing Technology*, 2016, 86(1): 769-780.
- [6] Prasad Y, Biswas K K. PSO-SVM Based Classifiers: A comparative approach[C]//Contemporary Computing, 2010: 241-252.
- [7] 孟涛, 周新志, 雷印杰. 基于自适应遗传算法 SVM 参数优化[J]. *计算机测量与控制*, 2016, 24(9): 215-217.
- [8] 朱庆生, 程珂. 一种基于累积适应度遗传算法的 SVM 多分类决策树[J]. *计算机应用研究*, 2016, 33(1): 64-67.
- [9] 谢川, 解武杰. 自适应遗传算法优化支持向量机的过电压识别[J]. *现代电子技术*, 2016, 39(19): 137-138.
- [10] Sayed G I, Soliman M, Hassanien A E. Modified optimal foraging algorithm for parameters optimization of support vector machine[C]//Advanced Machine Learning Technologies and Applications, 2018.
- [11] Wu K P, Wang S D. Choosing the kernel parameters for support vector machines by the inter-cluster distance in the feature space[J]. *Pattern Recognition*, 2009, 42(5): 710-717.
- [12] Qin H S, Wei Y, Zeng S H. Parameter optimization for SVM classification based on NGA[C]//Proceedings of the International Conference on Information Engineering and Applications (IEA), 2013.
- [13] Lameski P, Zdravevski E, Mingov R, et al. SVM parameter tuning with grid search and its impact on reduction of model over-fitting[C]//Rough Sets, Fuzzy Sets, Data Mining, and Granular Computing, 2015.
- [14] Do T N, Poulet F. Parallel learning of local SVM algorithms for classifying large datasets[C]//Lecture Notes in Computer Science, 2017.
- [15] Saremi S, Mirjalili S, Lewis A. Grasshopper optimisation algorithm: Theory and application[J]. *Advances in Engineering Software*, 2017, 105: 30-47.
- [16] 刘颖, 张丽娟, 韩亚男, 等. 基于粒子群协同优化算法的供应链金融信用风险评价模型[J]. *吉林大学学报(理学版)*, 2018, 56(1): 120-124.
- [17] 韩守飞, 李席广, 拱长青. 基于模拟退火与高斯扰动的烟花优化算法[J]. *计算机科学*, 2017(5): 257-262.
- [18] 贺兴时, 丁文静, 杨新社. 基于模拟退火高斯扰动的蝙蝠优化算法[J]. *计算机应用研究*, 2014, 31(2): 392-397.
- [19] 龚纯, 王正林. 精通 MATLAB 最优化计算[M]. 北京: 电子工业出版社, 2012: 163-179.