

文章编号:2095-0411(2017)02-0065-06

## 基于 BP 神经网络视频火灾火焰检测方法

段锁林,顾川林

(常州大学 机器人研究所,江苏 常州 213164)

**摘要:**针对视频火焰图像识别问题,采取一种结合蚁群算法(Ant Colony Algorithm)优化的 BP 神经网络火灾火焰检测方法。该方法克服了传统神经网络容易陷入局部最优值和收敛速度慢的问题。使用混合高斯模型建立统计模型分割火焰图像。火焰的判别特征采用面积增加率、圆形度和火焰尖角数,并且各特征量作为神经网络的输入量来得到判别火焰的最终概率。通过对大量实验数据的分析,表明该算法在可接受的时间范围内能有效改善火焰识别的准确度。

**关键词:**蚁群算法;BP 神经网络;混合高斯模型;多特征融合

**中图分类号:**TP 391.4

**文献标志码:**A

**doi:**10.3969/j.issn.2095-0411.2017.02.012

## Rsearch on the Detection Method Based on the Optimized BP Neural Network for the Visual Fire Flame Recognition

DUAN Suolin, GU Chuanlin

(Robotics Institute, Changzhou University, Changzhou 213164, China)

**Abstract:** For the visible flame detection technology, a BP neural network method optimized by the ant colony algorithm is adopted to detect fire in this paper. This method overcomes the disadvantage of falling into local minimum and slow convergence caused by neural network. The gaussian mixture model was used to build statistical model and to divide the fire image. The growth rate of area, roundness and flame angle numbers were adopted as the feature value of flame recognition. In addition, these values will also be the input quantity for the BP neural network. The analysis of experimental data indicates that the algorithm can effectively improve the flame recognition accuracy within acceptable time.

**Key words:** ant colony algorithm; BP neural network; gaussian mixture model; multi feature fusion

早期,人们使用各种电子探测器,采集数据,判断火灾是否发生<sup>[1]</sup>。然而因其信息单一,且极易受到环境温度、湿度、腐蚀性等的影响,容易发生误检、漏检等。其可靠性、灵敏度、可持续性等皆有待提高。在某些特殊场合,火灾蔓延速度极快,传统的火灾探测系统完全不能满足火灾预警检测要求。随着计算机视觉技术的发展,火灾图像识别技术受到了人们的高度关注与研究。火灾图像技术针对性地克服了传统火灾检测系统的主要弱点,结合高度发展的图像采集卡与计算机处理能力,使得可视化火灾检测技术能结合火焰的大量动静态特征,极大的加强了火灾识别的可靠性、实时性。对火灾检测预防具有重要的突破。

马宗方等<sup>[2]</sup>提出了基于支持向量机的图像型火灾探测算法。向量机因其内部严格的数学模型,使其在

收稿日期:2016-08-20。

基金项目:江苏省科技支撑计划项目(社会发展)(BEK2013671)。

作者简介:段锁林(1956—),男,陕西岐山人,博士,教授,主要从事智能机器人视觉控制技术研究。

一定情况下具有计算量小、精度高的特点。然而目前相应的数学模型并不能精确地描述火焰燃烧时的运动特征。相比较而言,同样是作为建模工具的 BP 神经网络,其内部黑盒子的特性抽象而言,与火焰燃烧的无规则性不谋而合。

本文首先采用混合高斯模型建立疑似火焰模型,实现火焰图像与背景的分,在可疑火焰区域上以火焰的面积增长率、圆形度以及火焰尖角数目 3 个特征量作为 BP 神经网络的输入量,最终借由训练好的神经网络分类模型达到火焰识别的目的。

## 1 提取火焰图像区域

火焰图像识别的第一步,是分割出疑似火焰图像区域。在摄像机所拍摄的视频序列中,相较于背景中静态的物体,火焰燃烧具有明显的运动特性。对于运动目标的检测有许多方法,本文采用背景建模法,使用混合高斯模型,在各种光照情况的扰动下均有不错的区分度。

在摄像头获取的 RGB 颜色空间中,  $X$  表示单一像素(pixel)点值,则概率密度函数可以用  $K$  个高斯函数描述:

$$P(X = x_n) = \sum_{k=1}^K \omega_k p(x_n | \mathbf{u}_k, \sum_k) \tag{1}$$

$$P(x_n | \mathbf{u}_k, \sum_k) = \frac{1}{(2\pi)^{n/2} |\sum_k|^{1/2}} e^{-1/2(x_i - u_i)^T \sum_k^{-1} (x_i - x_u)} \tag{2}$$

式中:  $K$  是分布数,令  $K = 3$ ;第  $k$  个分布的均值矩阵、协方差矩阵和权重系数依次是  $\mathbf{u}_k$ 、 $\sum_k$  和  $\omega_k$ 。

随机选取一组在不同时刻不同光照干扰下的图像序列,组成一个实验图像向量  $F = \{f_1, f_2, \dots, f_n\}$ ,采用最大期望方法初始化样本序列的分布参数,然后重复迭代直到收敛得到每个像素的分布参数  $\theta = [\omega_1, \omega_2, \omega_3, u_1, u_2, u_3, \sum_1, \sum_2, \sum_3]$ 。

二值化当前图像及模板图像,建立像素矩阵  $\theta$  及  $\theta'$ ,依次相减每个像素值,取其偏差的绝对值。 $|E| = \theta - \theta'$ ,对角化后按照阈值公式  $E' \leq 5E^{1/2}$  筛选可疑区域。

## 2 火焰特征提取

图像火焰识别的第二步,是火焰的特征提取。图像火焰的特征分为颜色特征、物理几何特征。物理几何特征又可细分为边缘特征、纹理特征等。根据火焰的特征参数识别火焰,在当前计算机视觉领域中发展迅速。本文采用面积增长率、圆形度和火焰尖角作为火焰识别的特征以及后续神经网络的输入向量。

### 2.1 面积增长率

火焰开始燃烧的极短时间内,随着火焰的燃烧程度,其面积逐渐变大,相比于静态的物体,其变化率具有很高的区分度。由于是同一视频流上的图像(相邻两帧的火焰空间物理位置并不会相差太大),火焰区域的匹配,只需获得经过前述的预处理得到二值化图像即可,白色区域为火焰区域,通过计算其面积变化的比值可进行疑似火焰的判断。用火灾面积增长率  $G_i$  作为判据。可由下式计算  $G_i$ 。

$$G_i = \frac{S(R_i)_t - S(R_i)_{t_0}}{t - t_0} \tag{3}$$

式(3)为两时刻火焰图像区的面积差值。相邻两亮点之间的空间单位距离为单位长度 1。其余亮点的距离由勾股定理求得。周长可由边界算法求得。实验对煤油火焰、蜡烛火焰、路灯和行进中的车灯,提取 5 帧样本数据集见表 1。

### 2.2 圆形度计算

凭据火灾火焰形状的不规整,而部分干扰源(路

表 1 火灾火焰与干扰源面积增长率分析表

样本	1 帧	2 帧	3 帧	4 帧	5 帧	均值
火灾	1.173 9	1.207 8	1.257 9	2.364 8	2.465 9	1.592 2
蜡烛	1.021 7	1.006 3	1.068 3	1.053 9	1.015 7	0.833 2
车灯	1.553 9	1.663 2	1.694 3	1.727 4	1.775 8	1.442 5
路灯	0	0	0	0	0	0

灯、车灯等)的形状规整程度高,故将圆形度作为火焰判别依据。圆形度的定义如式(4)。

$$C_k = \frac{4\pi A_k}{P_k^2}, k = 1, 2, \dots, n \quad (4)$$

式中:  $C_k$ 、 $A_k$ 、 $P_k$  依次为第  $k$  个单位的圆形度、面积和周长,  $n$  为单位个数。若物体外形越接近圆,则  $C_k$  越大;反之,若其轮廓越复杂,则  $C_k$  越小,  $C_k$  的值介于 0 和 1 之间。拟定一个阈值  $C_0$ ,当  $C_k > C_0$  时,则认为该图圆外形轮廓较为规则,认定非火焰;当  $C_k < C_0$  时,则该图像外形轮廓非常不规则,满足火焰轮廓特征。提取 5 帧样本数据集见表 2。

由表 2 可以看出,车灯的圆形度相比于煤油火焰较难区分(煤油火焰的燃烧状态可近似为火灾火焰),由于是由远及近的拍摄,运动中车灯轮廓较难把握,圆形度可能因此有所降低。可见,行进中的车灯是一个较难辨别的干扰源。

表 2 火灾火焰与干扰源圆形度分析表

样本	1 帧	2 帧	3 帧	4 帧	5 帧	均值
火灾	0.323 4	0.313 3	0.355 2	0.321 7	0.376 3	0.338 1
蜡烛	0.458 8	0.447 2	0.421 7	0.439 6	0.482 3	0.449 9
车灯	0.452 2	0.331 8	0.340 1	0.291 4	0.227 7	0.328 6
路灯	0.481 0	0.512 1	0.386 7	0.443 6	0.379 1	0.440 5

### 2.3 火焰尖角计算

火焰的运动特性很明显的有尖角,火焰的尖角数在时域上无规律可循<sup>[3]</sup>,因此,采取边缘抖动的特性,可鉴定可疑火源。分析早期火焰、噪声干扰下的尖角数目和疑似物体的边沿变化规律,能够区分其他干扰。为了提高火焰判断的准确性,依旧采用多组数据求均值的方法<sup>[4]</sup>。随机从各组图像序列中取出一帧,在单位时限内取得 5 帧火焰尖角数实验集,取其期望值  $\bar{J}_k = \sum_{1 \leq i \leq 5} J_{ik}$ 。与先验知识的阈值  $J_0$  比较,当  $\bar{J}_k > J_0$  时,认定  $k$  序号图集,满足火灾火焰的边沿抖动特征,反之,则不具备火灾火焰的边沿特征。对表 1 中图像数据进行火焰尖角计算,结果见表 3。

由表 3 可发现在圆形度上有较大干扰的车灯在尖角数上与火灾火焰已有很大差距。

表 3 火焰与干扰源火焰尖角数分析

样本	1 帧	2 帧	3 帧	4 帧	5 帧
火灾	8	7	7	9	11
蜡烛	1	1	1	1	1
车灯	1	0	0	0	1
路灯	0	0	1	1	1

## 3 蚁群神经网络(ACO-BPNN)

### 3.1 蚁群神经网络的基本思想

若单独从每个独立的特征来判断是否发生火灾,那该算法只能解决某些特定情况下的问题,不具备普遍性,甚至根本不具备有效性。为了融合前文的所有特征,得到一个较为合理的判断结果,采用 BP 神经网络作为训练模型检测算法的性能<sup>[5-6]</sup>。

拟使用一个类似 3-4-1(隐藏节点数拟为 4)结构的 BP 神经网络,输入层的 3 个参数分别表示为单一特征的可能火灾概率(各特征值与其某个阈值的比值),即面积增长率、圆形度概率和火焰尖角概率。神经网络的输出表示是否发生火灾的最终概率。选取双曲正切函数作为网络的响应函数。该模型的学习规则是依靠蚁群算法的正反馈特性,各路径初始权值的不同造成了蚂蚁构造的解存在优劣,算法采用蚁群算法的正反馈,在较优的解路径上留下更多的信息素,更多的信息素又吸引更多的蚂蚁,这个正反馈过程使得权值初始化的差别得到不断扩大,理论上使整个系统向全局最优解靠近。因此,该模型可得出可靠的最优解。

神经网络具有容易陷入局部极小值及收敛慢的问题,这是采用神经网络模型必须解决的问题,本文采用蚁群算法<sup>[7-12]</sup>(ACA)来优化这 2 个问题。该方式的原理大致如下:利用蚁群算法的全局性,在解空间找到最优的权值、阈值组合,然后利用神经网络对这组解进行更细致的优化,从而得到最优解。这一思想可以解决神经网络收敛慢的问题。然而,整个模型依旧容易陷入局部最优解,根本原因是模型依旧使用的是梯度下降细致优化。有学者认为多基因算法能够有效引导模型向全局最优解前进。已知,蚁群算法本质上是遗传算法的变形,初始化基因时,设置多组随机值,增加实验样本,然后并行对实验集,优化计算,以此来减低模型陷入局部最优解的风险。

在判定阶段,将所有满足单一特征概率条件的数据样本所对应的的三维向量作为神经网络的输入,输出

一个表示火灾可能发生的概率,拟定一个特定的阈值,若此概率大于该阈值,则可认为当前视频中检测到了火灾发生。

### 3.2 蚁群神经网络的实现

假设BP神经网络所有权值和阈值共有  $m$  个,设定权值区间  $[W_{\min}, W_{\max}]$ ,均匀划分成  $s$  等份,设立集合  $I_{p_i}$  包含等分后的神经网络参数  $p_i (1 \leq i \leq m)$ 。每只蚂蚁  $(1 \leq k \leq m)$  从集合  $I_{p_i}$  的第  $j (1 \leq j \leq m)$  个元素  $p_j(I_{p_i})$  出发,根据每个元素的信息素  $\rho$  和路径选择概率公式(式(5))在每个集合  $I_{p_i}$  中选择一个元素作为下一目标。

$$P_{\text{rob}}(\tau_j^k(I_{p_i})) = \frac{(\tau_j(I_{p_i}))}{\sum_{g=1}^m \tau_g(I_{p_i})} \quad (5)$$

当所有蚂蚁完成选择后,认为一次算法完成,根据信息素更新公式(式(6)),调整所有的元素的信息素,反复迭代此过程。

$$\begin{cases} \tau_j(I_{p_i})(t+m) = (1-\rho)\tau_j(I_{p_i})(t) + \Delta\tau_j(I_{p_i}) \\ \tau_j(I_{p_i})(t+m) = \tau_j(I_{p_i})(t) + \Delta\tau_j(I_{p_i}) \end{cases} \quad j = 1, 2, \dots, m \quad (6)$$

当所有蚂蚁收敛至同一路径即认为最优解的产生,或达到最大循环次数  $N_{\max}$  时,算法结束。算法流程如图1所示。

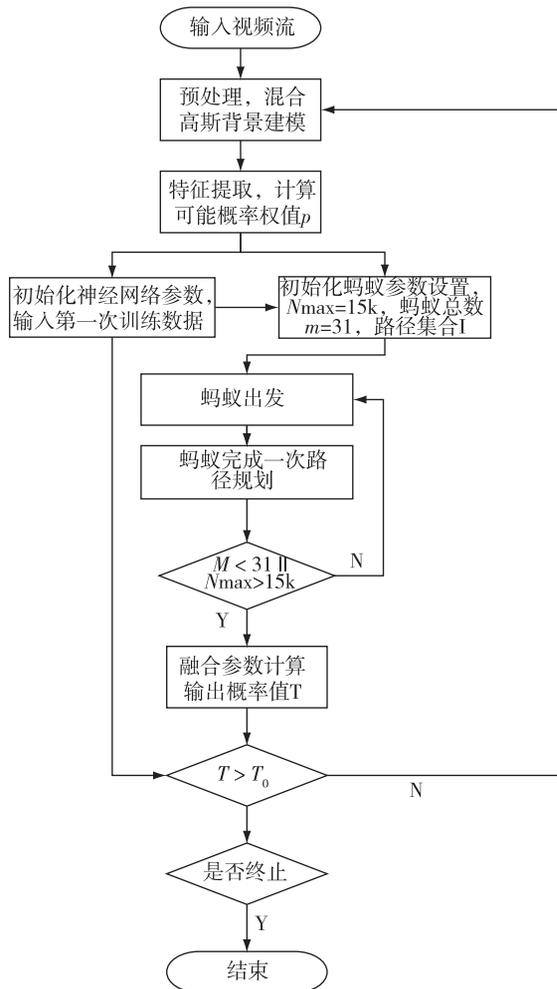


图1 火焰检测方法流程示意图

## 4 系统仿真实验研究及分析

### 4.1 蚁群神经网络参数的确定

神经网络隐层采用标准S激活函数,输出层采用线性激活函数,初始权值是  $[0, 1]$  内的随机值,网络的隐藏节点数为  $[1, 10]$  内的某个值,为防止欠匹配(under-fitting)或者过匹配(over-fitting)的情况发生,需要对节点值进行测试,选取网络计算所得误差最小的节点。结果如图2所示,  $n$  为节点。显然,当节点数为6时,网络所得误差最小。

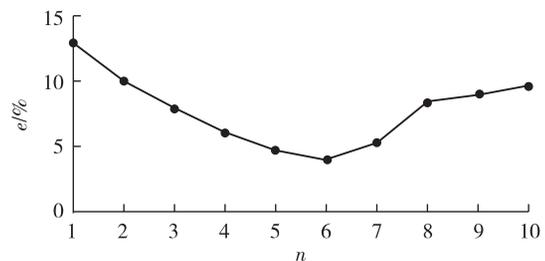


图2 不同隐含节点数对计算误差的影响

神经网络为  $3-6-1$  的结构,共有31个参数,信息素挥发系数  $\rho$  为0.3,信息素调整速度  $V_q$  为8,  $s$  数为60,最大迭代次数为1500,权值区间为  $(0, 1)$ 。见表4。

表4 蚁群神经网络参数设置

$m$	$V_q$	$s$	$\rho$	$N_{\max}$	$W_{\min}$	$W_{\max}$
31	8	60	0.3	1500	0	1

保持模型各参数不变,仅改变模型的输出阈值  $T$  得到对应的正确检测率和误检率,结果如图 3 所示。

显然,当输出阈值  $T$  选为 0.7 的时候,模型能够确保尽可能高的检测正确率,同时尽可能使误检率降低。

### 4.2 实验样本分析展示

训练集样本共采用 250 组图像样本。在实验室中拍摄的 100 组不同时刻、不同光照程度的火焰图像作为正确检测的训练样本集,其余拍摄包括蜡烛火焰、路灯、车灯在内的各 50 组干扰图像作为错误检测的训练样本集。图 4 为所用到的经图像分割步骤后的实验样本集。

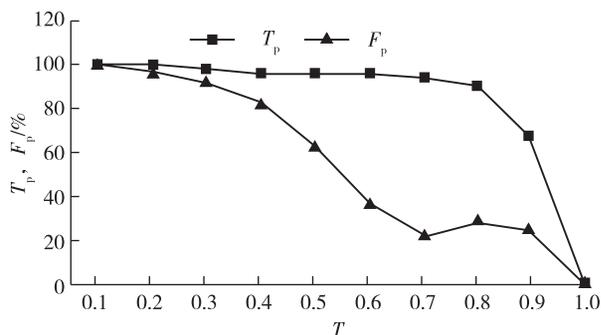


图 3 不同输出阈值对计算误差的影响

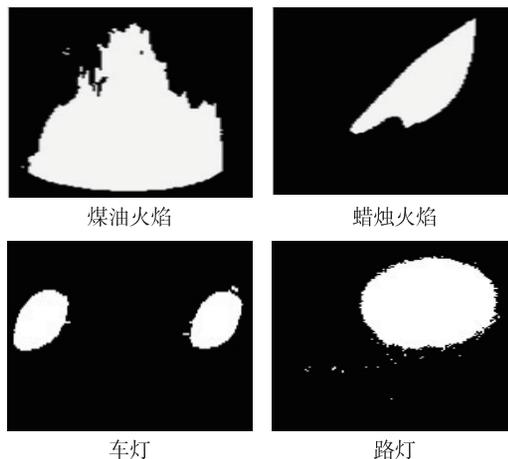


图 4 训练样本集

取出仿真实验集中具有针对性的两帧不同光照的蜡烛火焰图像如图 5 所示。

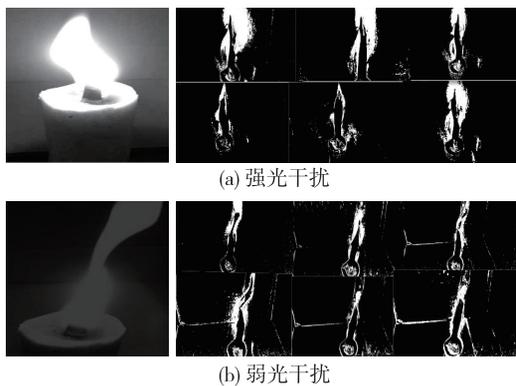


图 5 不同光照下的图像提取结果

图 5(a)、图 5(b)明显处于不同的光照影响状态。模板图像为混合高斯建模的背景图像,列举的 6 幅小图是视频流中的前景图像。火焰区别于背景具有明显的运动特性,利用混合高斯背景建模法能够准确地提取出运动的火焰图像,实验表明本方法能够有效地减少背景光照的干扰。

图像分割之后对火焰可疑区域进行特征提取,表 5 给出了待识别的 4 段视频集的部分特征结果。

表 5 待识别数据集特征

样本集名称	面积增长率	圆形度	火焰尖角数
火灾火焰	0.211 3	0.236 6	9
	1.747 1	0.384 1	13
	0.880 5	0.447 7	14
蜡烛火焰	0	0.459 4	1
	0.034 1	0.443 2	1
	0.017 2	0.480 5	1
路灯	0	0.480 3	1
	0	0.445 1	0
	0	0.373 2	1
车灯	0	0.227 7	0
	0.613 8	0.352 8	0
	0.327 3	0.331 9	1

### 4.3 结果分析

本仿真实验与文献[2]中的方法进行对比,测试中使用了  $K$  次交叉验证(K-fold cross-validation)的实验方法,以达到减少随机性、增加准确性的目的。所有数据被分割成  $K$  ( $K=10$ )份数据,除 1 份数据作为最后验证,其余  $K-1$  份数据用来训练。该过程重复进行  $K$  次,每次采用不同的子数据组合求平均值。结果如表 4 所示,  $T_p$  为正确检测率,  $F_p$  为误检率。由表 6 可看出本方法在确保正确检测率的同时误检率也大大降低,然

而其误检率依旧有 20%，误检的实验集多为行进中闪烁的车灯，显然光从颜色及几何特征来判定火焰还缺乏全面性，文献[5]中加入了火焰频率的特征，这是本文有待提高的部分。

### 5 结 论

针对传统火焰检测方法的缺点，采用结合蚁群算法和多基因算法优化的 BP 神经网络的视频火焰检测方法，克服了神经网络模型容易陷入局部最小值和收敛速度较慢的缺点。通过混合高斯模型的背景建模分割火焰图像，分析火焰的颜色和面积增长率、圆形度、火焰尖角等几何特征，在背景光线变化等干扰环境中能有效识别火焰。与传统火焰检测方法相比确保检测正确率的同时，降低了误检率。然而对行进中的车灯识别率低，会误识别为火焰。

表 6 本文方法与文献[2]方法交互验证结果

次数	文献[2]方法		本文方法	
	$T_P/\%$	$F_P/\%$	$T_P/\%$	$F_P/\%$
1	93.75	40.28	93.75	23.64
2	90.59	39.27	90.36	21.84
3	96.43	30.68	96.24	23.54
4	89.97	39.14	92.14	20.58
5	94.63	38.92	95.13	23.68
6	96.28	40.59	95.99	24.22
7	97.17	45.13	97.00	26.52
8	93.57	41.35	95.31	22.37
9	96.82	36.62	97.61	19.85
10	90.27	40.51	90.19	23.62
Aveval	93.95	39.25	94.37	22.99

### 参考文献:

[1]段悦. 火灾探测中动态火焰的数字图像处理[J]. 中国计量学院学报, 2009, 20(1): 55-58.

[2]马宗方, 程咏梅. 基于快速支持向量机的图像型火灾探测算法[J]. 计算机应用研究, 2010, 27(10): 3985-3987.

[3]吴龙标, 宋卫国. 图像火灾监控中一个新颖的火灾判据[J]. 火灾科学, 1997, 16(2): 60-66.

[4]李明, 吴爱国. 大空间早期火灾的双波段图像型探测方法[J]. 低压电器, 2007(2): 37-40.

[5]谢迪, 童若锋, 唐敏, 等. 具有高区分度的视频火焰检测方法[J]. 浙江大学学报(工学版), 2012, 46(4): 698-704.

[6]朱红红, 朱正礼. 基于 SVM 的 LEACH 分簇算法优化[J]. 常州大学学报(自然科学版), 2014, 26(3): 18-23.

[7]薛国新, 王岳. 一种改进的蚁群算法求解车辆的最短路径问题[J]. 常州大学学报(自然科学版), 2012, 24(1): 78-81.

[8]DORIGO M, MAN IEZZNO V, COLONIA. The ant system optimization by a colony of cooperating Agents[J]. IEEE Transactions on Systems Man and Cybernetics Part B, 1996, 26(1): 29-41.

[9]DORIGO M, BONABEAU E, THERAULAZ G. Ant algorithms and stigmergy[J]. Future Generation Computer Systems, 2000, 16(8): 851-871.

[10]WU Q H, ZHANG J H, XU X H. An ant colony algorithm with mutation features[J]. Journal of Computer Research and Development, 1999, 36(10): 1240-1245.

[11]DORIGO M, GAMBARDELIAL M. Ant colony system: A cooperative learning approach to the traveling salesman problem[J]. IEEE Transactions on Evolutionary Computation, 1997, 1(1): 53-66.

[12]李祚泳, 汪嘉扬, 郭淳, 等. 基于蚁群算法的 BP 网络优化算法[J]. 计算机应用, 2010(6): 1513-1515.

(责任编辑: 李艳)