

基于级联卷积神经网络的人脸关键点定位

陈锐^{1,2}, 林达^{1,2}

(1. 四川理工学院自动化与信息工程学院, 四川 自贡 643000; 2. 人工智能四川省重点实验室, 四川 自贡 643000)

摘要:由于人脸姿态、表情、遮挡物、光照问题的影响,人脸关键点检测时通常会出现较大的误差,为了准确且可靠地检测关键点,提出了一种基于级联卷积神经网络的方法。利用人脸检测器检测到的人脸图像作为输入,第一层卷积神经网络直接检测所有的5个人脸关键点。随后根据这些检测到的点裁剪出5个人脸局部图像,级联的第二层网络使用5个不同的卷积神经网络单独地定位每个点。在实验测试环节,级联卷积神经网络方法的使用将人脸关键点的平均定位误差降低到了1.264像素。在LFPW人脸数据库上的实验结果表明:该算法在定位准确性和可靠性上要优于单个CNN的方法以及其他方法,该算法在GPU(图形处理器)模式下处理一个人脸图像仅需15.9毫秒。

关键词:人脸关键点;卷积神经网络(CNN);深度学习

中图分类号:TP391.41

文献标志码:A

引言

人脸关键点定位是人脸识别等应用中必不可少的一个预处理环节,即使是简单地根据检测到的双眼坐标旋转图像将双眼置水平面,也可以有效提升人脸识别的准确率,复杂的预处理手段也更加离不开精确的人脸关键点定位算法。

人脸关键点定位算法可以分为两类:分类法和直接预测法。第一类算法,如文献[1-3]首先要对需要检测的每个关键点区域单独训练分类器,再通过对局部窗口下的图像进行分类来寻找候选区域,随后通过形态约束在这些候选区域中估计最优关键点。

分类法在寻找候选区域时,容易出现找到过多或数量不足的候选区域,这些对人脸定位算法的性能造成了一定的负面影响,而且运行效率较低。与前者相比,不需要使用滑动窗口对人脸图像进行扫描并分类的直接预测法要更为高效,文献[4-6]直接用回归器定位人脸图像的人脸关键点,人脸关键点的位置随着迭代而更新直到收敛。文献[7-8]首先从带有人工标注关键点坐

标的训练样本中学习到模型,利用学习到的模型直接对人脸图像的关键点坐标进行估计,这种方法明显要优于其他的大部分方法,尤其在运行效率上要远高于分类法。近来,文献[9-11]提出了一种由分类法和直接预测法结合改进而来的由粗到细的定位方法,该方法可以一定程度上提高定位算法的准确性。这类方法在第一次粗定位到的人脸关键点的基础上,再次估计更为精确的人脸关键点位置。大部分定位方法都面临着提取到的特征不足以准确定位人脸关键点,选择合适的特征提取方法就变得尤为重要。在整个人脸区域图像提取到的纹理信息特征包含丰富的信息,若是使用该特征进行人脸关键点定位,通过分类器或回归器进行精确定位显得异常困难。

为了解决上述问题,本文提出使用级联卷积神经网络(CNN)来对人脸关键点进行定位。卷积神经网络以整个人脸图像为输入,其深层的网络结构可以充分地提取到人脸图像的纹理信息特征,在该特征上进行人脸关键点定位可以达到较高的准确性和可靠性。同时在高性能GPU加速和深度学习框架^[12-13]下,可以快速地完成

成卷积神经网络的训练。仅使用单个卷积神经网络即可准确且高效地定位到人脸关键点,然而仍一定程度上存在着些许误差,通过级联的第二层卷积神经网络进行修正,可以有效降低定位误差。

1 卷积神经网络

卷积神经网络是传统人工神经网络与深度学习相结合而提出的新型人工神经网络,其在模式识别领域的表现要远超大部分的传统方法,尤其在人脸识别、字符识别等图像分类领域取得令人惊讶的成果,甚至在人脸识别领域上已经超越人类。

卷积神经网络通过引入权值共享、局部感知以及池化层对传统的神经网络结构进行优化。卷积神经网络中卷积层神经元只与上一层的小范围内的神经元相连接,而不是与上一层所有的神经元进行相连,且处于同一特征映射面上的神经元权值是共享的。权值共享和局部感知策略的应用,大幅度减少了需要学习的参数,使得卷积神经网络的训练更为高效。池化层输出的特征具有平移、旋转空间等不变性,使得卷积神经网络对平移、旋转等影响具有良好的鲁棒性。通过卷积层和池化层的交替使用,卷积神经网络完成了对图像特征从局部到全局的学习过程。

常见的 CNN 模型中,通常以卷积层和池化层交替使用,即通过卷积层计算特征映射图,再利用池化层降低特征映射图的尺寸,且保持特征的旋转和平移特性,在特征映射图尺寸和层数达到要求时,将二维的特征映射图按顺序排列起来转换为一维的特征,再与全连接层进行连接。卷积层的运算过程可以表示为:

$$X^{(l,k)} = f\left(\sum_{p=1}^{n_{l-1}} (W^{(l,k,p)} \otimes X^{(l-1,p)}) + b^{(l,k)}\right) \quad (1)$$

式中: $X^{(l,k)}$ 表示第 l 层输出的第 k 组特征映射图, n_l 表示第 l 层特征映射图的层数, $W^{(l,k,p)}$ 表示第 $l-1$ 层中第 p 组特征映射图向第 l 层中第 k 组特征映射图映射时所用的滤波器。第 l 层的每一组特征映射图的生成都需要 n_{l-1} 个滤波器和一个偏置,假设滤波器的大小为 $h \times w$,那么第 l 层卷积层的参数数量为 $n_{l-1} \times n_l \times h \times w + n_l$ 。

常见的池化操作有最大值池化、均值池化等,本文的卷积神经网络仅使用了最大值池化。池化操作后,特征映射图的大小会根据步长 $step$, 缩小至原先的 $1/step$ 。最大值池化的一般形式可以表现为:

$$X^{(l+1,k)}(m,n) = \max_{0 < a, b < s} \{X^{(l,k)}(m \cdot step + a, n \cdot step + b)\} \quad (2)$$

式中: $X^{(l+1,k)}(m,n)$ 为第 $l+1$ 层输出的第 k 组特征映射

图坐标 (m,n) 处的值; s 为池化窗口的大小, $step$ 为池化窗口移动时的步长,本文中 s 和 $step$ 均设置为 2。

卷积神经网络在反向传播以最小化误差函数为目的,来更新神经元之间的所有连接权值和偏置。考虑到人脸关键点定位任务,采用平方和损失函数,它可以表示为:

$$E^N = \frac{1}{2N} \sum_{i=1}^N \|y_i - d_i\|_2^2 \quad (3)$$

式中: N 为神经网络输出层节点数, y 为神经网络的预测值, d 为人工标注值。

本文使用随机梯度下降^[14]算法对神经元之间的所有连接权值和偏置进行更新,则最终的损失函数的表现形式为:

$$E = \frac{1}{m} \sum_{j=1}^m \left(\frac{1}{2N} \sum_{i=1}^N \|y_i^j - d_i\|_2^2 \right) + \frac{1}{2} \eta \|W\|_2^2 \quad (4)$$

式中: m 为每次反向传播时所用训练样本的数量, W 为网络中每一层的权重矩阵。

卷积神经网络中的权重矩阵 W 在反向传播时进行更新,在网络训练开始前,以随机值矩阵 W_0 对网络进行初始化, $t+1$ 次迭代后更新的权重矩阵 W_{t+1} 可以表示为:

$$W_{t+1} = W_t - \lambda \cdot \frac{\partial E}{\partial W_t} \quad (5)$$

2 人脸关键点定位

由于姿态、光照、遮挡以及分辨率等影响,使用单个卷积神经网络定位的关键点仍存在一定程度的误差,而级联卷积网络的运用可以有效降低误差。人脸关键点定位算法共训练 6 个卷积神经网络,如图 1 所示。首先以人脸检测器检测到的人脸图像作为输入,第一个卷积神经网络作为第一层实现对所有关键点的粗定位实现。人脸关键点包括双眼、鼻尖和双侧嘴角,共计 5 个点。通过粗定位预测到的关键点,按照双眼到嘴巴中心的距离对图像进行缩放,随后再以关键点为中心,裁剪出 5 个局部区域图,第二层的 5 个卷积网络将完成人脸关键点的精确定位。

2.1 级联卷积神经网络结构

本文设计的级联卷积神经网络,第一层的卷积神经网络 F1 的输入为整张人脸,输入由人脸检测器检出,缩放至 112×112 大小, F1 可以对双眼、鼻尖和双侧嘴角进行粗定位。第二层的卷积神经网络分别为 LE、RE、N、LM、RM,这些网络要分别定位左眼、右眼、鼻尖、左侧嘴角、右侧嘴角。第二层的网络模型结构相同,输入均为 32×32 的图像,根据 F1 定位到的关键点计算双眼中心




图1 人脸关键点定位算法流程图

到双侧嘴角中心的距离,并按照比例对图像进行缩放,使该距离为 48,随后在缩放后的图像上,分别裁剪出 5 块以 F1 定位到的关键点为中心,大小为 32×32 的图像。第二层的 5 个卷积神经网络分别对 5 个局部图像进行单点定位,相比与 F1 定位到的关键点而言,第二层的卷积网络定位的坐标要精确许多。

2.2 各级卷积神经网络结构

人脸定位算法使用了 2 种不同结构的卷积神经网络,第一层和第二层的网络结构不同,LE、RE、N、

LM、RM 结构相同。第一层采用了 CNN 模型 A 结构,以 $112 \times 112 \times 3$ 的图像作为输入,输出分别为所有关键点的坐标。第二层采用了 CNN 模型 B 结构,以 $32 \times 32 \times 3$ 的图像为输入,输出单个关键点坐标。CNN 模型 A 和 B 均由 7 层卷积层、3 层池化层和 2 层全连接层组成,模型 A、B 的具体结构参数见表 1。为了保持卷积处理后,图像尺寸的变化,在卷积操作前,大部分卷积层都对输入特征图进行了边缘零填充。

表1 CNN模型A、B的结构

A				B			
层	滤波器尺寸/步长	输出	参数数量	层	滤波器尺寸/步长	输出	参数数量
Data	-	$112 \times 112 \times 3$	-	Data	$32 \times 32 \times 3$	-	-
Conv1	$5 \times 5/2$	$56 \times 56 \times 64$	4864	Conv1	$5 \times 5/1$	$32 \times 32 \times 64$	4864
Pool1	$2 \times 2/2$	$28 \times 28 \times 64$	-	Pool1	$2 \times 2/2$	$16 \times 16 \times 64$	-
Conv21	$3 \times 3/1$	$28 \times 28 \times 32$	18464	Conv21	$3 \times 3/1$	$16 \times 16 \times 32$	18464
Conv22	$3 \times 3/1$	$28 \times 28 \times 64$	18496	Conv22	$3 \times 3/1$	$16 \times 16 \times 64$	18496
Pool2	$2 \times 2/2$	$14 \times 14 \times 64$	-	Pool2	$2 \times 2/2$	$8 \times 8 \times 64$	-
Conv31	$3 \times 3/1$	$14 \times 14 \times 64$	36928	Conv31	$3 \times 3/1$	$8 \times 8 \times 64$	36928
Conv32	$3 \times 3/1$	$14 \times 14 \times 96$	55392	Conv32	$3 \times 3/1$	$8 \times 8 \times 96$	55392
Pool3	$2 \times 2/2$	$7 \times 7 \times 96$	-	Pool3	$2 \times 2/2$	$4 \times 4 \times 96$	-
Conv41	$3 \times 3/1$	$5 \times 5 \times 96$	83040	Conv41	$3 \times 3/1$	$4 \times 4 \times 96$	83040
Conv42	$3 \times 3/1$	$3 \times 3 \times 128$	110720	Conv42	$3 \times 3/1$	$2 \times 2 \times 128$	110720
Fc1	-	320	368960	Fc1	-	160	82080
Drop	-	-	-	Drop	-	-	-
Fc2	-	10	3210	Fc2	-	2	322
Total	-	-	700074	Total	-	-	410306

与文献[15]中采用 3 层级联的网络不同,本文仅使用了 2 层,第一层卷积神经网络完成关键点的粗定位,第二层的卷积神经网络进行 5 次精确的单点定位。在 F1 中,输入大小为 $112 \times 112 \times 3$ 的整张人脸,卷积层 Conv1 使用了 64 个不同的卷积核对面脸图像的不同纹理和边缘特征进行学习。随着卷积层和池化层的交替使用,特征映射图的长宽不断变小,层数不断增加,Conv42 输出的特征映射图同全连接层 Fc1 进行连接,Fc1 输出的 160 维的特征将作为最后的关键点坐标定位。全连接层 Fc2 根据 Fc1 输出的特征,进行最终的关键点坐标预测。模型 A 中的 Fc2 输出为 10 维,用于 5 点定位,而模型 B 的 Fc2 层输出为 2 维,用于单点定位。Drop 层引入 Dropout^[16],通过随机将神经元的部分输出

置零,来提升网络的泛化能力,Dropout 只在训练环节时使用。

3 实验

3.1 训练数据的扩充及预处理

本文实验数据均来自文献[15],其中包含 13 466 个人脸图像,所有人脸图像都有相关坐标标注信息,训练卷积神经网络的过程中,10 000 张图像作为训练集,3 466 张图像作为测试集。仅 10 000 张图像作为训练集是远远不够的,数据增强可以有效提高卷积神经网络的表现,通过顺时针和逆时针分别旋转 16° 与 8° 对训练数据进行扩充,随后通过镜面翻转再次进行扩充,最终获得 80 000 个训练数据。由于图像中存在大量无关的背

景,需要通过人脸检测器检出人脸区域。第一层的 F1 将在这 80 000 个数据集上进行训练。

在 F1 训练完成后,使用 F1 对训练数据集进行关键点定位,根据比例将双眼中心到嘴角中心的距离调整至 48 像素。随后以 F1 定位的关键点为中心,并对该坐标进行 5 次小幅度随机偏移后,裁剪出 32×32 的人脸局部图像。最终可以收集到 250 万个人脸局部图像,第二层的 LE、RE、N、LM、RM 分别使用其中的 50 万个数据进行训练。

实验使用开源深度学习框架 Caffe^[12]来完成卷积神经网络的训练,并使用 Python 语言完成代码编写,硬件平台为 i5 - 4590, 3.3 GHz 的处理器,内存为 8 GB,显卡为 GTX960,内含 GPU,系统为 Windows 7。图 2 为本文算法的人脸关键点定位测试效果图,其中第一行图像在人脸关键点定位时仅使用了一个卷积神经网络,即 F1,可以发现定位算法仍存在瑕疵,定位不够精确,第二行图像使用的定位算法为本文提出的级联卷积神经网络算法,在表情、遮挡物、扭曲等影响下,该算法仍可以精确定位人脸图像关键,精确度得到了明显提升。



图 2 人脸关键点定位效果对比图

人脸关键点定位算法的定位误差可以表示为 $err = \sqrt{(x - x')^2 + (y - y')^2}$, 其中的 (x, y) 为人工标注的关键点坐标, (x', y') 为算法定位的关键点坐标。在实验的测试环节,本文将同时测试算法的每个人脸关键点平均误差以及所有关键点的平均误差。

3.2 实验测试

表 2 为卷积神经网络训练时所用的验证集的测试结果,该验证集仅用于测试网络泛化能力。从表 2 中可以看出,单个卷积神经网络在测试样本上的总平均误差以及单个点的平均误差均远高于级联卷积神经网络,本文提出的算法提高了关键点定位的精确度。图 3 是 LFPW^[1]人脸库中部分图像的人脸关键点定位效果,可以看出在姿态偏转严重、以及各种表情下仍能准确地定位到人脸关键点。表 2 与表 3 中的误差均为定位误差 err 的平均值。

表 2 不同模型误差对比

方法	左眼误差	右眼误差	鼻尖误差	左侧嘴角误差	右侧嘴角误差	总平均误差
单 CNN(F1)	1.564	1.795	2.279	2.078	2.199	1.983
级联 CNN	0.869	0.864	1.105	1.289	1.289	1.083



图 3 基于级联卷积神经网络的人脸关键点定位效果图

表 3 不同算法误差对比

方法	左眼误差	右眼误差	鼻尖误差	左侧嘴角误差	右侧嘴角误差	总平均误差
本文算法	0.989	1.009	1.801	1.256	1.265	1.264
Sun ^[15]	2.040	1.940	2.130	2.510	2.340	2.190
ASEP ^[17]	2.390	3.195	3.114	2.92	1.902	2.704
杨海燕 ^[18]	1.312	1.220	1.901	1.401	1.602	1.487

单 CNN(F1)方法在 GPU 模式下,进行一次人脸关键点定位,仅需要 3.3 毫秒。在相同的测试环境下,本文提出的级联 CNN 方法中级联的第二层 CNN 需要耗时 12.6 毫秒,总耗时 15.9 毫秒,而 CPU 模式下总耗时 23.1 毫秒。

卷积神经网络的训练过程需求很高的内在并行度,并存在着大量的浮点数据运算以及大规模的矩阵运算,有着高度并行结构的图形处理器可以很好的解决这些问题。在相同情况下,GPU 模式下的卷积神经网络训练速度远超前于 CPU 模式下的训练速度。在 CNN(F1)的训练过程中,GPU 模式下迭代 1000 次用时仅为 34.7 秒,而 CPU 模式下用时 611.3 秒,GPU 模式下 Caffe 训练卷积神经网络的速度是 CPU 的 17.6 倍。使用支持 GPU 加速的开源深度学习框架 Caffe 可以大幅度缩短卷积神经网络的训练耗时。

3.3 与其他算法的对比

为了与其他算法相比较,本文将在 LFPW 人脸数据库进行测试,该数据库由 1432 张人脸图像组成,其中训练集有 1132 张图像,测试集有 300 张脸图像。LFPW 主要用于在非限制环境下,如姿态、表情、光长存在很大差

异,以及遮挡物存在的情况下测试人脸关键点定位算法。本文仅获得训练集中的781个图像和测试集中249个图像的关键点人工标注信息,由于部分人脸图像难以被人脸检测器检测,以至于最终仅在983张人脸图像上进行了测试,结果见表3。从表3可以看出,本文提出的算法在相同测试样本下,与其他算法相比仍具有较好的表现,准确性更高。

4 结束语

本文提出的人脸关键点算法通过卷积神经网络对人脸关键点进行定位,可以快速且准确地定位到人脸关键点。在LFPW人脸库上的测试表明,通过级联卷积神经网络可以有效降低误差,算法的平均像素误差降低至1.264,且检测速度快,在GPU模式下定位一张人脸图像的关键点仅需15.9毫秒。如果可以获取到更多具有人脸关键点标注信息的数据,则最终训练出的级联卷积神经网络将具有更好的鲁棒性和准确性。文中提出的算法对光照、遮挡、姿态、表情等干扰,表现出较好的抗干扰能力,将该算法应用于人脸识别程序中,必然可以提高人脸识别的准确率。

参考文献:

- [1] BELHUMEUR P N, JACOBS D W, KRIEGMAN D J, et al. Localizing parts of faces using a consensus of exemplars[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(12): 545-552.
- [2] LIANG L, WEN F, SUN J. Face alignment via component-based discriminative search//Proceedings of the 10th European Conference on Computer Vision, Marseille, France, October 12-18, 2008: 72-85.
- [3] RAMANAN D, ZHU X. Face detection, pose estimation, and landmark localization in the wild[J]. Computer Vision and Pattern Recognition, 2012, 157(10): 2879-2886.
- [4] GAO X D, WEI Y, WEN F, et al. Face alignment by explicit shape regression[J]. International Journal of Computer Vision, 2014, 107(2): 177-190.
- [5] COOTES T F, EDWARDS G J, TAYLOR C J. Active appearance models [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2001, 23(6): 681-685.
- [6] FANELLI G, GALL J, DANTONE M, et al. Real-time facial feature detection using conditional regression forests[J]. Computer Vision & Pattern Recognition, 2012, 157(10): 2578-2585.
- [7] KIMURA M, YAMASHITA T, YAMAUCHI Y, et al. Facial point detection based on a convolutional neural network with optimal mini-batch procedure[C]//Proceeding of 2015 IEEE International Conference on Image Processing, Quebec, Canada, September 27-30, 2015: 2860-2864.
- [8] YAMASHITA T, WATASUE T, YAMAUCHI Y, et al. Facial point detection using convolutional neural network transferred from a heterogeneous task[C]//Proceeding of 2015 IEEE International Conference on Image Processing, Quebec, Canada, September 27-30, 2015: 2725-2729.
- [9] SAUER P, COOTES T, TAYLOR C, et al. Accurate regression procedures for active appearance models [J]. Bmvc, 2011, 1(6): 681-685.
- [10] REN S, CAO X, WEI Y, et al. Face alignment at 3000 FPS via regressing local binary features[J]. IEEE Transactions on Image Processing, 2014, 25(3): 1685-1692.
- [11] YU X, HUANG J, ZHANG S, et al. Pose-Free facial landmark fitting via optimized part mixtures and cascaded deformable shape model [C]//Proceeding of 2013 IEEE International Conference on Computer Vision, Sydney, December 1-8, 2013: 1944-1951.
- [12] JIA YQ, SHELHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding [C]//Proceedings of the 22nd ACM international conference on Multimedia, Orlando, Florida, USA, November 3-7, 2014: 675-678.
- [13] ABADI M, AGARWAL A, BARHAM P, et al. TensorFlow: large-scale machine learning on heterogeneous distributed systems [EB]. Google Research whitepaper, 2016.
- [14] BOTTOU L. Stochastic gradient descent tricks [M]. Berlin Heidelberg: Springer, 2012: 421-436.
- [15] SUN Y, WANG X, TANG X. Deep convolutional network cascade for facial point detection[J]. Computer Vision and Pattern Recognition, 2013, 9(4): 3476-3483.
- [16] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning

Research,2014,15(1):1929-1958.

fornia,June 20-26,2009:2105-2112.

[17] BOLME D S,DRAPER BA,BEVERIDGE J R.Average of synthetic exact filters [C]//Proceeding of 2012 IEEE Computer Society Conference on Computer Vision & Pattern Recognition, San Diego, Cali-

[18] 杨海燕,蒋新华,聂作先.基于并行卷积神经网络的人脸关键点定位方法研究[J].计算机应用研究,2015,32(8):2517-2519.

Facial Points Detection Based on Cascade Convolutional Neural Network

CHEN Rui^{1,2}, LIN Da^{1,2}

(1. School of Automation & Information Engineering, Sichuan University of Science & Engineering, Zigong 643000, China; 2. Artificial Intelligence Key Laboratory of Sichuan Province, Zigong 643000, China)

Abstract: Suffered from facial pose, expressions, occlusions and illumination, there is usually larger errors in the facial points detection. In order to detect facial points accurately and reliably, a method based on cascade convolutional network is proposed. Using the face image detected from face detector as input, all of 5 facial points are detected by the first level CNN directly. After then 5 images from the facial points are cropped, and each of the points is predicted singly by the second level CNN with 5 different CNN. The mean error of all points is reduced to 1.264 pixel in test phase by the cascade convolutional network method. The experiments on LFPW database show that this method outperforms single CNN method and many other methods in both detection accuracy and reliability. This method process one face image takes approximately 15.9 ms on a standard GPU (graphics processing unit).

Key words: facial points; convolutional neural network (CNN); deep learning



(上接第31页)

Solving Model Based on Particle Swarm Optimization and Artificial Fish Swarm Algorithm

PENG Kai, HUANG Yiqing, SHAO Shouchen

(College of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, China)

Abstract: The traditional group intelligent algorithms are optimized and improved. However, the inherent shortcomings and limitations of the traditional simple algorithm is difficult to fundamentally removed, resulting in many groups of intelligent hybrid algorithm. A new hybrid algorithm of particle swarm and artificial fish swarm is proposed to overcome the shortcomings of artificial fish swarm algorithm (AFSA) convergence and the poor global convergence of particle swarm optimization algorithm (PSO). Based on the artificial fish swarm algorithm, the linear decreasing inertia weight strategy of particle swarm optimization algorithm is introduced into the artificial fish swarm algorithm. Artificial fish processing is encoded and the field of view of the individual artificial fish is changed dynamically, so that the new particle swarm and artificial fish swarm hybrid algorithm (PSO-AFSA) is formed. And the hybrid algorithm is applied to Traveling Salesman Problem (TSP). The simulation results show that the hybrid algorithm has better global convergence performance and faster convergence speed than the traditional artificial fish swarm algorithm and particle swarm optimization algorithm.

Key words: traveling salesman problem; artificial fish swarm algorithm; particle swarm optimization; hybrid algorithm