

引用格式: 黄友文, 方永平. 并行尺度裁切的深度卷积神经网络模型 [J]. 微电子学与计算机, 2019, 36(4): 6-11. [HUANG Y W, FANG Y P. Parallel scale cropping deep convolutional neural network model [J]. Microelectronics & Computer, 2019, 36(4): 6-11.]

并行尺度裁切的深度卷积神经网络模型

黄友文, 方永平

(江西理工大学 信息工程学院, 江西 赣州 341000)

摘 要: 针对并行卷积神经网络(PCNN)的参数过多, 模型训练时间成本高的问题, 本文提出了并行尺度裁切卷积神经网络(PSC-CNN). PSC-CNN 算法是将并行卷积神经网络其中一路(Path A)的输入及该通路的特征提取层的输出通过 Crop 层裁切得到新的尺寸的图像供给另一路(Path B)网络作为输入. 这样, Path A 的输入图像在数据层经过一次随机裁剪, Path B 则经过了两次裁剪操作, 增加了输入数据的多样性, 提升了模型的学习能力. 算法以 AlexNet 为基础网络, 分别设计了对应的 PCNN 及 PSC-CNN 模型, 在数据集 Caltech101、Caltech256 上进行实验. 实验结果表明, 相较原始的 PCNN, 本文提出的改进算法有效的提升了分类准确度同时缩短了训练时间.

关键词: 并行卷积神经网络; 识别; 尺度裁切; 特征提取; AlexNet

中图分类号: TP3

文献标识码: A

文章编号: 1000-7180(2019)04-0006-06

Parallel Scale Cropping Deep Convolutional Neural Network Model

HUANG You-wen, FANG Yong-ping

(School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou, 341000, China)

Abstract: As the excessive parameters of parallel convolutional neural network (PCNN) and the high cost of model training time, this paper proposes a parallel scale cropping convolutional neural network (PSC-CNN). The PSC-CNN algorithm is that obtains an input for one path (Path A) of the parallel convolutional neural network and an output of the feature extraction layer of the path, and then to get a new size image as input of the other path (Path B) network through the Crop layer. In this way, the input image of Path A undergoes a random cropping in the data layer, and Path B undergoes two cropping operations, which increases the data diversity and improves the learning ability. The algorithm is based on AlexNet, and the corresponding PCNN, PSC-CNN models are designed respectively. Experiments are carried out on the datasets Caltech101 and Caltech256. Experimental results show that compared with the original PCNN, the improved algorithm proposed in this paper effectively improves the classification accuracy and shortens the training time.

Key words: parallel convolutional neural network; recognition; scale cropping; feature extraction; alexnet

1 引言

深度卷积神经网络(DCNN)是由卷积、池化等特征提取层堆叠起来的端到端的网络, 由低到高逐层提取特征, 最后通过分类器完成分类任务. 与浅层网络相比, DCNN 的权值共享策略使得网络参数减

少了数个量级, 网络层数可以继续向下拓展. 文献[1]认为虽然随着网络层数的增加, 模型识别性能会更好, 但是由于梯度弥散、梯度爆炸问题^[2]的存在, 网络不能依靠简单地堆叠更深的层数以达到优化网络模型性能的目的. 随着科研人员对神经网络结构的探索, 不仅纵向加深网络深度可以提高网络的识

别性能,横向拓展网络的宽度^[3-5]也可以起到提高识别率的效果,并且一定程度上减轻了梯度弥散带来的影响。虽然网络的识别性能得到提升,但这是以成倍增加的网络参数为代价的。本文针对这个问题,结合文献[6]中对特征图进行 crop 处理达到修正特征图大小的目的,提出了并行尺度裁切的思想,在 AlexNet^[7]网络的基础上,设计了 PSC-AleNet 网络。在数据集 Caltech101、Caltech256 上进行分类实验,本文设计的网络,与对应的并行网络 PCNN-AlexNet 及文献[3]相比,不仅缩短了训练时间,还提升了识别准确度。

2 相关工作

2.1 卷积神经网络的工作原理

卷积神经网络是一种多层前馈神经网络:由输入层、隐藏层及输出层构成,其中隐藏层通常由卷积层及池化层(降采样)交替组成,每层由多个相互独立的神经元构成的二维平面组成,最后通过全连接层输出,最终输出的维度对应网络识别的类别数。

网络的训练是一种端到端的模式,通过卷积运算逐层抽象获取不同层次语义信息,并对数据集逐批次地训练从而调整各层卷积核的内部参数,从而能够无监督地对图像特征进行学习^[8]。网络的整个训练过程在前向传播及反向传播算法下完成的。在前向传播中,输入图像通过卷积、池化操作不断获取新的特征向量,前一层的输出被当作当前层的输入。

$$y_j^l = f\left(\sum_{i=1}^n (x_i^{l-1} \times w_{ij}^l) + b_j^l\right) \quad (1)$$

式中, l 表示的是网络层数; x_i^{l-1} 表示的是第 $l-1$ 层神经元 i 的输出; n 个输出信号同时输入进神经元 j , w_{ij}^l 表示的是第 l 层的第 i 个神经元连接到第 $l-1$ 个神经元的权重, b_j^l 表示第 l 层的第 j 个神经元的偏置; y_j 为神经元 j 的输出。每个神经元在参与完卷积运算之后都会经过激活函数 f (常用的非线性激活函数有 sigmoid、tanh、ReLU 函数等), 得到非线性输出, 实现特征信息的非线性转换, 能够有效地解决线性分类难以完成的分类任务。经过多个特征提取(卷积、池化等)层, 然后光栅化, 将进入全连接层前一层的像素点依次展开, 排成一行。最后进入分类层, 采用的是 Softmax 函数, 函数表达式为

$$S_j = \frac{e^{a_j}}{\sum_{k=1}^T e^{a_k}} \quad (2)$$

式中, $(\sum_{k=1}^T e^{a_k})^{-1}$ 对概率分布归一化, 分类结果之和为 1, T 是总类别数, j 是判定的类别。当一个样本经过 Softmax 层并输出一个 $T \times 1$ 的向量时, 取最大的值时的 j 作为这个样本的预测标签。

网络中各个神经元参数 w_{ij} 是随机的, 所以只进行一次前向运算不能很好地完成分类任务, 随机性强。Rumelhart 等人^[9] 提出由误差反向传播算法训练多层前馈网络即反向传播网络 (Back Propagation Network)。反向传播算法是一种无监督算法, 当网络输出与期望值之间存在差异, 误差通过梯度下降算法逐层向前传播, 逐层更新网络参数的值, 最终缩小实际输出与期望值之间的差异。公式如下:

$$L(w, b; x, y) = \frac{1}{2} \sum_{i=1}^m (h_{w,b}(x_i) - y_i)^2 \quad (3)$$

式(3)表示的是损失函数。式中, x_i 是第 i 类样本特征; $h_{w,b}(x_i)$ 是第 i 类样本经过网络的输出; y_i 是第 i 类样本的期望输出。目的是让损失函数尽可能的小, 采用梯度下降算法来求出每个参数的偏导值, 并更新每一层的权重 w 和偏置项 b 。

$$w_{ij}^l = w_{ij}^l - \eta \frac{\partial L(w, b)}{\partial w_{ij}^l} \quad (4)$$

$$b_i^l = b_i^l - \eta \frac{\partial L(w, b)}{\partial (b_i^l)} \quad (5)$$

式中, η 表示的是学习率, 其值越大参数更新的幅度越大。网络通过前向传播、误差反向传播及梯度下降算法, 不断调整网络权重、偏置等参数, 直至识别准确率曲线收敛。但根据实验对象的不同, 可能存在过拟合的风险, 解决办法是在 SGD 算法中加入一个正则项对这个损失函数进行约束:

$$w_{ij}^l = w_{ij}^l - \eta \frac{\partial E}{\partial w_{ij}^l} - \eta \lambda w_{ij}^l \quad (6)$$

式中, λ 是正则化系数 (weight decay); $\eta \lambda w_i$ 是损失函数的正则项, 起到约束的作用, 使得需要更新的权重值与其大小成比例衰减。

2.2 并行卷积神经网络

卷积神经网络的网络结构对识别性能起到决定性的影响, 一般情况下, 深层网络相较于浅层网络, 识别效果更好, 增加网络的层数可以起到提升模型识别性能的作用, 但是网络的层数过多, 由于梯度弥散的问题存在, 导致靠近输入层的隐藏层的梯度小, 参数更新慢。虽然文献[10]在一定程度上克服了这种问题带来的影响, 但是如果网络层数过深还是会导致准确度下降。部分实验数据

如下^[10].

表 1 cifar-10 上的分类错误率

方法	层数	错误率(%)
Highway	19	7.54
	32	8.80
	32	7.51
ResNet	56	6.97
	110	6.43
	1202	7.93

Highway Network 在 32 层时候的错误率比在 19 层更高,ResNet 虽然能加深到 110 层,并且保持错误率下降的趋势,但是当网络层数继续加深,仍然存在识别性能下降的可能. 相关科研人员提出并行卷积神经网络,为优化神经网络模型的性能提供一个研究方向.

并行卷积神经网络是分别通过两条通道对输入图像提取特征,在全连接层把两条通路的输出特征图融合在一起,将其作为最后的特征向量,通过 Softmax 函数完成分类任务.

3 本文网络

3.1 Crop 层简要介绍

在深度学习框架 Caffe(Convolutional architecture for fast feature embedding) 中^[11],数据是以




图 1 PSC-CNN 结构


网络存在两条网络通路,Path A 和 Path B. 输入图像像素是 256×256 的,首先在数据层进行随机 Crop 处理,截取成 224×224 大小. Path A 的输入像素为 224×224 保持不变,在隐藏层经过一系列的卷积、池化等操作,当特征图大小为 112×112 时,将其与数据层共同通过 Crop 层^[6],将 224×224 的数据层图像像素裁切成 112×112 ,并供给 Path B 作为 B 通路的输入. 即利用第一个通路的某一层的输出,在数据层裁切得到另一路通路的输入,这样 Path B 通路的输入图像经历了两次裁切操作,不仅整个模型输入的数据更具多样性,提升了模型的学习能力,且另一路网络的神经元个数也将减少,加速

Blobs 的形式在各层之间输入输出的. Blobs 是四维连续数组,即 (n, k, w, h) ,分别表示的是图像个数,通道个数,图像宽度及图像高度.

Crop 层的输入有两个,分别记作 $\text{Blob}_A, \text{Blob}_B$, 一个输出记作 Blob_C . 其中 Blob_A 是需要裁切的输入, Blob_B 是裁切的参考输入, Blob_C 是最后裁切的新的数据. 即以 Blob_B 为模板在 Blob_A 上裁切一个尺寸与 Blob_B 相同的输出 Blob_C . Crop 层有两个重要的参数 $\text{axis}, \text{offsets}$. 其中 axis 决定从 Blobs 的哪个轴开始裁剪, offsets 决定裁剪的位置. 设 $\text{Blob}_A = (n_a, k_a, w_a, h_a), \text{Blob}_B = (n_b, k_b, w_b, h_b), \text{Blob}_C = (n_c, k_c, w_c, h_c)$, 若 $\text{axis} = 1$, 保留轴 0, 则 $n_c = n_b = n_a$; $\text{offsets} = (s_1, s_2, s_3)$, 则 $k_c = k_b, w_c = w_b, h_c = h_b$, 裁切的位置及尺寸分别为 $[s_1, s_1 + k_b], [s_2, s_2 + w_b], [s_3, s_3 + h_b]$.

3.2 网络架构

较单路卷积神经网络,并行卷积神经网络的数量成倍增加,虽然模型识别性能得到提升,但增加了训练时间成本. 本文依此设计了并行尺度裁切网络模型,在减少参数的同时,还能提供不同的输入数据给网络,提升了模型的学习能力和泛化性. 网络结构如图 1.



模型的收敛.

3.3 模型设置

本文选取 AlexNet 网络作为 Path A 通路的网络,然后做出适当改动,构建 Path B 通路的网络. 改造后的网络(PSC-AlexNet)参数设置如表 2.

Path A 的 Conv1 层输入是 Data 层输出,大小为 224×224 ; Path B 的 Conv1 层输入是 Crop 输出,以 Conv1_A 层的输出尺寸为模板,将 Data 层的输出裁切成大小为 112×112 的图像供给 Path B 网络训练. 目的是让 Path B 的输入特征图矩阵大小为 Path A 通路的一半. 由于 AlexNet 原网络中的第一个卷积层卷积步长设置为 4,网络在第一次卷积之

后,特征图矩阵直接缩小到 55×55 ,需要对网络进行改动,本文将原来 Conv1 拆成两个卷积模块 Conv1 和 Conv1’进行级联,参数都设置为 $7\times 7/2$. 然后根据 Conv1_A 层的形状信息对 Data 层的输出进行裁切,在 Data 层裁切一个 112×112 的图像供

给 Path B 通路. 这样 Path B 的输入图像经历了两次随机裁切,相较原网络,输入数据更具多样性,并且由于输入图像尺寸变小,整个双路网络的计算量将降低.

表 2 PSC-AlexNet 的网络结构和参数设置

Layer name	Path A		Layer name	Path B	
	K/S	F/ N_{out}		K/S	F/ N_{out}
Data	—	$224\times 224/3$	Data	—	$224\times 224/3$
—	—	—	Crop	—	$112\times 112/96$
Conv1_A	$7\times 7/2$	$112\times 112/64$	Conv1_B	$7\times 7/2$	$56\times 56/64$
Conv1_A’	$7\times 7/2$	$55\times 55/96$	Conv1_B’	$7\times 7/2$	$27\times 27/96$
Max pool1/LRN	$3\times 3/2$	$27\times 27/96$	Max pool1/LRN	$3\times 3/2$	$13\times 13/96$
Conv2_A	$5\times 5/1$	$27\times 27/256$	Conv2_B	$5\times 5/1$	$13\times 13/256$
Max pool2/LRN	$3\times 3/2$	$13\times 13/256$	Max pool2/LRN	$3\times 3/2$	$6\times 6/256$
Conv3_A	$3\times 3/1$	$13\times 13/384$	Conv3_B	$3\times 3/1$	$6\times 6/384$
Conv4_A	$3\times 3/1$	$13\times 13/384$	Conv4_B	$3\times 3/1$	$6\times 6/384$
Conv5_A	$3\times 3/1$	$13\times 13/256$	Conv5_B	$3\times 3/1$	$6\times 6/256$
Max pool3/LRN	$3\times 3/2$	$6\times 6/256$	Max pool3/LRN	$3\times 3/2$	$3\times 3/256$
FC1_A	—	$256\times 6\times 6/2\ 048$	FC1_B	—	$256\times 3\times 3/2\ 048$
FC2_A	—	$4\ 096\times 2\ 048$	FC2_B	—	$4\ 096\times 2\ 048$
FC3_A	—	$4\ 096\times 1\ 024$	FC3_B	—	$4\ 096\times 1\ 024$

4 实验

4.1 实验设置

实验在深度学习框架 caffe^[11] 环境下进行. 实验环境如下:

- ①Intel(R) Core(TM) 3.91 GHz;
- ②内存 8 GB;
- ③显卡 NVIDIA GeForce GTX1070;
- ④Ubuntu 16.04 $\times$ 64.

本文实验是在计算机视觉领域较为经典的数据库 Caltech101 和 Caltech256 中进行的. Caltech101 包含 101 个实物类和一个背景干扰类共 9144 幅图像,其中最少的包含 31 幅,最多包含 800 多幅图像,将其中 7 254 幅图像作为训练集,1 890 幅图像构作为测试集. Caltech256 是 Caltech101 数据库的扩展,共 30 607 幅图像,包含 256 个实物类和一个背景干扰类,将其中 24 323 幅图像作为训练集,剩下的 6284 幅图像作为测试集,相较 Caltech101 数据库,该数据库不仅类别和图像更多,它在物体的位置、大小和形态上差异更明显,识别难度更大.

在训练之前,首先将数据库中所有图像的尺寸

统一为 256×256 像素. 在训练和测试时,在数据层对每幅图像随机裁切成 224×224 像素(测试时只裁切图像中间部分),并对其进行水平翻转. 本文实验中所有网络的学习率变化方式选择 ‘fixed’ 模式,设置为 0.001,迭代次数为 20 万次, gamma 为 0.1, weight decay 为 0.001, Batch size 设置为 20.

4.2 实验结果及分析

文献[6]设计了一个并行卷积神经网络,并在该数据库 Caltech101 和 Caltech256 上做了图像分类的研究工作. 本文将并行尺度裁切卷积神经网络算法应用在 AlexNet 的并行网络上,通过与文献[6]、单路 AlexNet 及并行 AlexNet 网络作对比,验证本文算法的可行性.

表 5 各模型在 Caltech101 上的性能

网络模型	准确率(Top1)/%	训练时间/s
文献 6	63	—
AlexNet	70.26	7 697
PCNN-AlexNet	72.15	33 616
PSC-AlexNet	73.42	23 059

表 6 各模型在 Caltech256 上的性能

网络模型	准确率(Top1)/%	训练时间/s
文献 6	46.4	—
AlexNet	45.91	8 229
PCNN-AlexNet	48.91	34 873
PSC-AlexNet	50.37	24 013

表 5,表 6 给出了不同卷积神经网络模型在 Caltech101 和 Caltech256 上的识别准确率,以及模型的训练时间.从中可以看出,基于 AlexNet 的并行卷积神经网络(PCNN-AlexNet)和并行尺度裁切卷积神经网络(PSC-AlexNet)的识别准确度要高于传统网络 AlexNet,且 PSC-AlexNet 的训练时间比 PCNN-AlexNet 更少.可以看出,在 Caltech101 上,PSC-AlexNet 算法的 Top1 分类准确度达到了 73.42%,其值相对 AlexNet,PCNN-AlexNet 分别提升了 4.58%,1.76%,且训练时间相对 PCNN-AlexNet 缩短了 45.78%.在 Caltech256 上,PSC-AlexNet 的 Top1 达到了 50.37%,比 AlexNet,PCNN-AlexNet 分别提高了近 9.71%,2.98%,且训练时间较 PCNN-AlexNet 缩短了 45.22%.

另外,文献[6]的分类准确度均比本文设计的 PSC-AlexNet 算法低,甚至在数据集 Caltech101 上,其 Top1 识别率不及本文的单路 AlexNet 网络.原因可能有:

(1)文献[6]为防止过拟合发生将 Dropout ratio 设为 0.9(本文设为 0.5).通过实验发现过拟合的预防,可以通过调节 Weight decay 来缓解,不需要舍弃更多的神经元输出;

(3)训练集和测试集的分配方式不同 ;

(3)Weight decay 等一些超参设置不同.




图 2 不同模型在 Caltech101 上准确率曲线

图 2,图 3 中横坐标是网络迭代次数,每迭代 10000 次进行一次测试,共 20 个点,纵坐标是测试分类准确度.利用 Caffe 自带的绘图工具,绘制准确




图 3 不同模型在 Caltech256 上准确率曲线

度曲线.从中可以看出,本文网络算法在刚开始训练时,识别准确度并不高,甚至在 Caltech256 上出现过分类准确度低于单路网络的情况,模型迭代到 3 万次左右开始超过 AlexNet,迭代到 9 万次开始超过并行网络 PCNN-AlexNet.综合表 4、表 5、图 2 和图 3 可以得出,本文设计的网络算法比并行网络的性能更优,不仅识别准确度更高,且模型训练的时间更短.

5 结束语

本文针对并行卷积神经网络参数过多,实验复杂度高的问题提出了并行尺度裁切思想,设计了并行尺度裁切卷积神经网络(PSC-CNN).在数据集 Caltech101 和 Caltech256 上进行实验,选择 AlexNet 作为基础网络,设计了并行网络 PCNN-AlexNet 和并行尺度裁切网络 PSC-AlexNet.实验发现,本文在并行网络上加入本文提出的算法之后,在数据集 Caltech101 和 Caltech256 上性能均得到提升.分类准确度分别提升了 1.76%、2.98%,训练时间分别缩短了 45.78%、45.22%.

参考文献:

[1] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification[C]//Proceedings of the IEEE international conference on computer vision. 2015: 1026-1034.

[2] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[C]//Proceedings of the thirteenth international conference on artificial intelligence and statistics. 2010: 249-256.

[3] 汤鹏杰,王瀚漓,左凌轩.并行交叉的深度卷积神经网络模型[J].中国图象图形学报,2016,21(3):339-347.

[4] GUO L, LI F, LIEW A W C. Image esthetic evaluation using parallel deep convolution neural network[C]//Digital image computing: techniques and applications

- (DICTA), 2016 international conference on. IEEE, 2016:1-5.
- [5] 杨远飞,曾上游,冯燕燕,等. 基于并行和切片的深度卷积网络设计研究[J]. 微电子学与计算机, 2018, 35(3): 120-124.
- [6] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431-3440.
- [7] KRIZEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Advances in neural information processing systems. 2012: 1097-1105.
- [8] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. science, 2006, 313(5786): 504-507.
- [9] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors [J]. nature, 1986, 323(6088): 533.
- [10] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [11] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: Convolutional architecture for fast feature embedding[C]//Proceedings of the 22nd ACM international conference on Multimedia. ACM, 2014: 675-678.

作者简介:

黄友文 男, (1982-), 博士, 副教授. 研究方向为计算机视觉, 图像处理与模式识别. 嵌入式系统及应用.

方永平(通讯作者) 男, (1994-), 硕士研究生. 研究方向为深度学习. E-mail: 2754172445@qq. com.

(上接第 5 页)

5 结束语

针对 QPSO 算法中势阱中心更新方式展开研究, 提出了 LSL-QPSO 算法, 社会学习有助于加强非最优粒子间信息共享, 莱维飞行有助于增强最优粒子的引导作用, 两种更新机制的融合, 形成优势互补. 实验结果证明了 LSL-QPSO 算法收敛精度和速度上的优势, 且与同类算法相比, 算法普适性强, 维度增加并不会造成算法性能快速衰退, 在大规模和复杂优化问题上具有较大应用前景. 下一步将考虑将算法与实践相结合, 用于解决工程实际问题.

参考文献:

- [1] SUN J, FENG B, XU W. Particle swarm optimization with particles having quantum behavior[C]// Proc. Congress on Evolutionary Computation. San Diego: IEEE, 2004:325-331.
- [2] LI Y, JIAO L, SHANG R, et al. Dynamic-context cooperative quantum-behaved particle swarm optimization based on multilevel thresholding applied to medical image segmentation [J]. Information Sciences, 2015, 294:408-422.
- [3] 孙俊. 量子行为粒子群优化算法研究[D]. 无锡: 江南大学, 2009.
- [4] 王安龙, 何建华, 陈松, 等. 双心扰动量子粒子群优化算法研究[J]. 计算机工程, 2014, 40(7):193-196.
- [5] 吴涛, 严余松, 陈曦. 基于随机评价机制的交互式双子群 QPSO 算法[J]. 控制与决策, 2015, 30(3): 526-530.
- [6] LI S J, XUAN P H, WANG X D. Improved quantum behaved particle swarm optimization algorithm[C]// Chinese Control and Decision Conference. Yinchuan: IEEE, 2016:774-776.
- [7] 靳雁霞, 张鑫, 薛丹. 具有自适应逃逸的环状全互连结构粒子群算法[J]. 微电子学与计算机, 2018, 35(2):1-5.
- [8] 张新明, 康强, 王霞, 等. 交叉反向学习和同粒社会学习的粒子群优化算法[J]. 计算机应用, 2017, 37(11):3194-3200.
- [9] CHENG R, JIN Y. A social learning particle swarm optimization algorithm for scalable optimization[J]. Information Sciences, 2015, 291(6):43-60.
- [10] 秦岭, 戴睿闻. 具有记忆性的自适应布谷鸟搜索算法[J]. 微电子学与计算机, 2017, 34(3):15-19.

作者简介:

袁小平 男, (1966-), 博士, 教授. 研究方向为智能算法、机器学习、图像处理;

金 鹏(通讯作者) 男, (1991-), 硕士研究生. 研究方向为量子行为粒子群算法、先进控制、智能算法等.

E-mail: jinpeng_kd@163. com

周国鹏 男, (1972-), 博士, 教授. 研究方向为智能算法、非线性控制.