

# 基于 DenseNet 进化的卷积神经网络图像分类算法

马永杰\*, 刘培培

西北师范大学物理与电子工程学院, 甘肃 兰州 730070

**摘要** 卷积神经网络(CNN)的结构与参数决定了其在图像分类中的性能,针对深度网络结构复杂、参数量较大的问题,提出了一种基于稠密连接网络进化的 CNN(D-ECNN)图像分类算法。该算法可对网络结构空间进行有效搜索,并基于有限的计算资源对深度网络结构与参数进行自适应优化。在车辆数据集上的分类实验结果表明,本算法的准确率可达到 95%,相比视觉几何组(VGG16)算法,提升了约 1%,且本算法的模型文件较小、速度更快。

**关键词** 图像处理;卷积神经网络;进化算法;图像分类

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP57.241001

## Convolutional Neural Network Based on DenseNet Evolution for Image Classification Algorithm

Ma Yongjie\*, Liu Peipei

College of Physics and Electronic Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China

**Abstract** The structure and parameters of convolutional neural network (CNN) determines the performance of image classification. Aiming at the problems of complex structure and a parameters that require a lot of manual settings in deep network, a CNN image classification algorithm based on the evolution of densely connected networks(D-ECNN) is proposed in this work. The algorithm can effectively search the network structure space, and realizes the adaptive optimization of deep network structure and parameters based on limited computing resources. The classification experiment results on the vehicle data set show that the accuracy of this algorithm can reach more than 95%, which is about 1% higher than that of the visual geometry group (VGG16) algorithm. The model file of this algorithm is smaller and the test speed is faster.

**Key words** image processing; convolutional neural network; evolutionary algorithms; image classification

**OCIS codes** 100.2000; 100.4996; 150.1135

## 1 引言

大型数据集的出现与硬件计算能力的不断提升,使深度学习技术得到了快速发展。深度学习算法通过大量的数据训练用神经网络学习高度表达特征,通过隐藏层逐层深入地学习图像的抽象信息,从而更全面、直接地获取图像特征<sup>[1]</sup>。相比性能依靠特征提取与分类器的传统图像分类算法,深度学习算法在图像分类任务上的性能更优越<sup>[2]</sup>。深度学习算法包括卷积神经网络(CNN)、循环神经网络

(RNN)、长短时记忆(LSTM)网络等,其中,CNN用卷积计算提取特征,大幅度减少了模型参数,且对图像具有较好的特征表达能力,使其在图像分类任务上的表现更优异<sup>[3]</sup>。8层的 AlexNet 深度卷积网络在 2012 年的 ImageNet 分类任务中获得冠军<sup>[4]</sup>;包含 Inception 结构 22 层的 GoogleNet<sup>[5]</sup>与 16 层的视觉几何组(VGG)网络<sup>[6]</sup>分别取得了 2014 年 ImageNet 分类比赛的冠亚军,这表明已有网络框架都是趋向于更深层次的方向发展<sup>[7]</sup>。硬件计算能力的不断发展,使训练获得更深层的 CNN 模型成为

收稿日期: 2020-03-30; 修回日期: 2020-04-30; 录用日期: 2020-05-08

基金项目: 国家自然科学基金(62066041,41861047)

\* E-mail: myjmyj@163.com

可能,进一步增强了模型的分类性能<sup>[8]</sup>。深度卷积神经网络(DCNN)具有复杂的拓扑结构和数以万计的参数,因此,能自动调整参数与结构的卷积网络逐渐成为深度学习网络设计的重要研究方向<sup>[9]</sup>。将进化算法(EA)与神经网络结合的神经网络模型出现后取得了一系列研究成果<sup>[10-12]</sup>,Stanley<sup>[13]</sup>在2017年人工智能大会中表明进化神经网络在深度学习领域有巨大的发展潜力。

进化卷积神经网络是一种用EA学习卷积网络结构、连接权值或学习规则的方法,能使网络更好地适应动态环境<sup>[14]</sup>。Xie等<sup>[15]</sup>将CNN编码为二进制字符串,提出了一种编码长度固定且进化过程中滤波器尺寸固定的简单CNN。Real等<sup>[16]</sup>提出通过变异操作逐步进化出复杂CNN搜索空间的方法,采用1000台计算机进行异步操作,利用EA构建的网络结构可用于大规模的图像分类问题。Desell等<sup>[17]</sup>进化出任意结构与任意滤波器尺寸的CNN,但计算量较大,用4500台计算机训练了超过120000个CNN。

上述算法虽然不需要人工调整深度神经网络的参数与结构,但计算量较大,对硬件的要求较高。针对该问题,本文提出了一种基于稠密连接网络(DenseNet)模块进化的卷积神经网络(D-ECNN)算法。相比人工构建的DCNN,该算法可在不影响准

确率的情况下,极大减少计算资源的消耗。通过引入CNN中的DenseNet模块和EA思想,结合DenseNet模块和二维(2D)卷积的网络模型,对网络层与其激活函数、滤波器数目及尺寸等层属性进行编码(编码长度不固定),避免了固定编码长度寻优的限制。为了减少资源的大量消耗,设置模型的最大总层数为20,网络模型通过对层或模块的自动添加、删除或替换以及对层属性的随机选择达到自适应优化网络结构、提高网络空间搜索能力的目的,进而自动进化出效果更优的网络模型。该模型在车辆图像数据集的检测结果表明,其性能可达到甚至超过人工设计的网络。

## 2 相关工作

### 2.1 卷积神经网络

CNN由卷积层、池化层和全连接层组合而成,其结构如图1所示。卷积层可完成大部分计算,池化层通过降低数据维度减少参数数量,最后将图像特征输入到全连接层输出。计算样本与输出结果之间的误差,通过反向传播(BP)算法对网络进行优化并计算网络的参数<sup>[18]</sup>。DCNN在图像分类任务中的效果较好,但随着网络层数的加深,BP过程中的梯度容易消失,导致网络难以收敛,从而引起网络退化问题<sup>[2,19]</sup>。




图1 CNN的结构图

Fig. 1 Structure diagram of CNN

### 2.2 稠密连接网络

CNN是机器视觉领域中常用的图像分类方法,其网络表现力随网络深度的增加而增加,但同时也会出现梯度消失问题,导致分类精度下降。尽管残差网络(ResNet)可以有效解决这些问题<sup>[20]</sup>,但ResNet在每一层中都会生成大量的特征图,导致参数太多时训练困难<sup>[18]</sup>。而DenseNet中的每一层都接收来自所有先前层的输入,并将其输出到Dense块中的所有后续层<sup>[21]</sup>,这种连接结构可实现特征重用,减少梯度消失的问题,从而使更深层的网络能实现更好的分类效果。因此,实验在DenseNet模块、2D卷积层与全连接层的基础上进行添加、删除及替

换作为变异操作,寻找到最优或接近最优的网络结构,以实现自动构建高性能网络。DenseNet的结构如图2所示,其中, $X_i$ 为由多个网络层组成的DenseNet模块, $H_i$ 为非线性组合操作,包括批量归一化(BN)、线性整流单元(ReLU)激活函数与卷积操作(Conv)。

### 2.3 进化算法

EA是一种全局自适应智能优化算法,其思想来源于自然的生物进化,无需梯度信息就能自主寻优与并行计算,具有良好的全局搜索能力。首先对种群进行编码,经过交叉、变异操作等进化过程;然后依据设定的适应度函数计算适应度进行评价,确

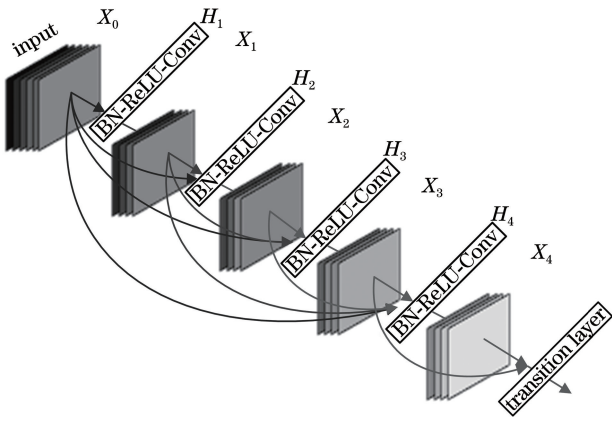


图 2 DenseNet 的结构图

Fig. 2 Structure diagram of DenseNet

定种群的环境适应度,淘汰适应度较差个体。进化算法可以有效利用已知信息,通过评价种群的适应度指导搜索、优化种群质量,不需要依赖优化对象的梯度信息,使 EA 在神经网络的结构与参数优化中具有更大的适应范围<sup>[22]</sup>,EA 的流程如图 3 所示。

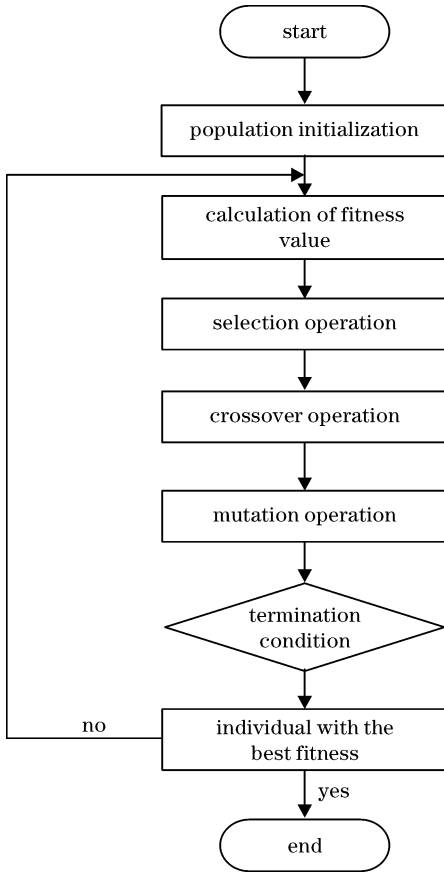


图 3 EA 的流程图

Fig. 3 Flow chart of EA

## 2.4 进化神经网络

进化神经网络利用 EA 搜索整个行为空间以优

化神经网络,从而寻找到给定任务的最优解决方案,可在减少人工调整网络结构时间的同时自动探索更多的网络结构,使网络具有更好的学习能力。

基于深度学习技术的进化神经网络是在增强拓扑进化神经网络(NEAT)<sup>[23]</sup>算法基础上的研究成果。NEAT 算法通过在基础网络中改变连接权值、增加连接权值或断开现有的连接插入节点三种方法执行变异操作,适用于规模较小的网络,但当网络深度与结构复杂度增加时,不适用于深度网络的优化。深度进化神经网络算法利用深度学习训练网络模型,结合 EA 进行深度神经网络的自动设计。目前,深度进化神经网络算法的研究还处于不断完善中,本算法在有限的计算资源下,针对图像分类的实际任务搭建网络,实现 DCNN 的进化设计。

## 3 基于 D-ECNN 的图像分类算法

进化神经网络通常从随机分布的初始种群开始,首先对种群中每个个体的参数进行编码,包括连接权值、网络体系结构、学习规则;然后,计算每个个体的适应度,通过交叉、变异、选择等操作反复进化该种群,直到满足确定的终止条件(获得一个足够好的个体或达到预定的最大代数)。本算法引入 DenseNet 模块,利用 EA 对 CNN 中的学习率与网络结构进行优化,获得一个最优的 D-ECNN 模型,通过输入测试集图像实现图像分类,D-ECNN 算法的流程如图 4 所示。

### 3.1 种群初始化

种群初始化是 EA 的初始阶段,可为后续的进化操作提供基本种群。学习率对网络训练的稳定性影响很大,当学习率较大时,网络参数的修正量较大,导致网络难以收敛;当学习率较小时,训练容易陷入局部极小值<sup>[24]</sup>。因此,实验先对学习率与网络结构进行编码,然后再进行进化操作。其中,网络结构编码信息包括 2D 卷积层、池化层、完全连接层、DenseNet 模块及其激活函数、滤波器数目、滤波器尺寸、步长与丢失率等层属性信息。由于本网络的层数及其层属性通过随机选择后用进化操作进行自适应优化,因此,编码长度不固定。针对实际问题,CNN 种群可自适应调整层数及层属性信息,在设定的 20 层网络内自适应寻优。采用只包含一个卷积层的最简 CNN 群体作为初始染色体种群,初始种群规模设置为 10。

### 3.2 适应度评价和选择操作

适应度评价是根据设定的适应度函数评价群

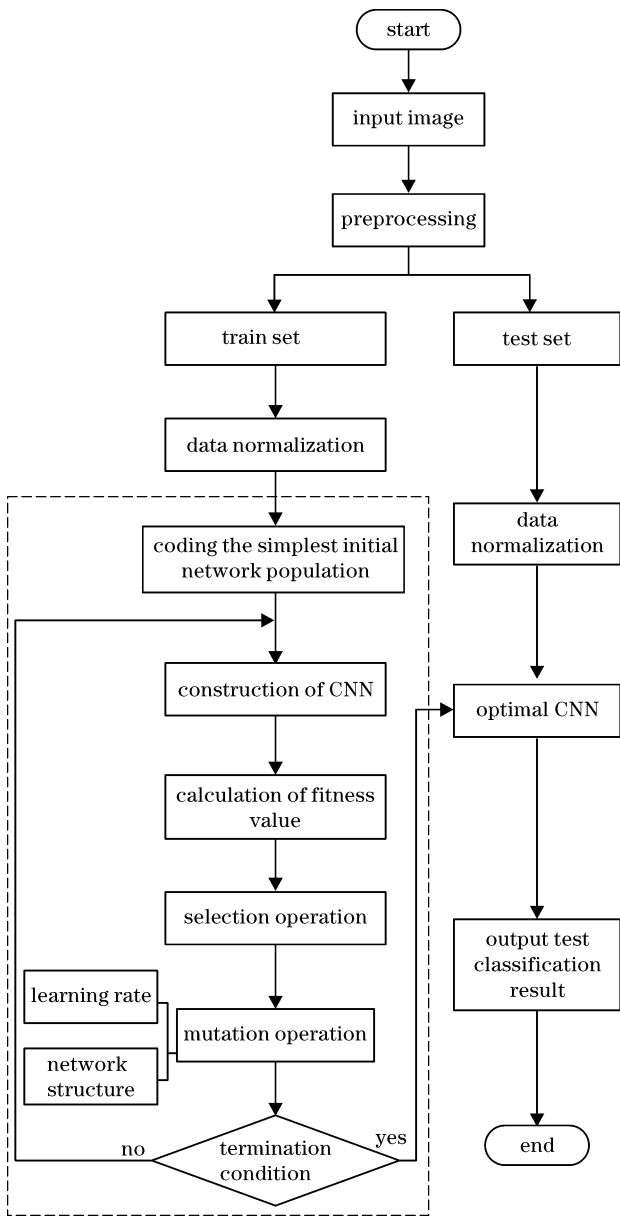


图 4 D-ECNN 算法的流程图

Fig. 4 Flow chart of D-ECNN algorithm

体中个体对于环境适应性的数值,选择操作通常基于概率选择种群中的个体,具有高适应度评价值的后代个体被选择的概率更高,以保证后代种群的总体质量<sup>[25]</sup>。适应度函数的设定直接影响了寻找最优个体的收敛速度,因此,用网络的准确率作为适应度函数以保证选择时的精确性,计算出适应度评价后,用轮盘赌方法选择父代。

### 3.3 变异操作

EA 通常通过交叉操作和变异操作重组父代信息,从而产生较好的后代<sup>[26]</sup>。部分进化神经网络中没有交叉操作,仅通过变异操作搜索空间<sup>[16,25-26]</sup>,本算法也采用该方法。对于初始化的最简 CNN 群体,通过随机改变其学习率或网络结构及其激活函数、步长、神经元数目、滤波器数目及尺寸等层属性实现变异操作。变异学习率是随机生成的,通过添加、删除、替换网络层或 DenseNet 模块实现网络结构的变异操作,网络层从 2D 卷积层、池化层或全连接层中选择,激活函数、步长、神经元数目、滤波器数目、丢失率等通过随机选择生成。变异操作的随机性可能导致生成无效的 CNN 结构,因此,在每次进行变异操作后,都会执行适应度评价以保证所得 CNN 结构的有效性。如果变异操作生成适应度低的无效结构,则淘汰适应度最低的个体再次进行变异操作,在三代中选择适应度最高的有效结构。

## 4 实验结果与分析

### 4.1 实验平台与参数设置

实验平台:操作系统为 Windows10、处理器为 Intel i5、内存为 16 GB。在 Conda 编程环境下用 Tensorflow、Keras 深度学习框架搭建网络,实验参数如表 1 所示。

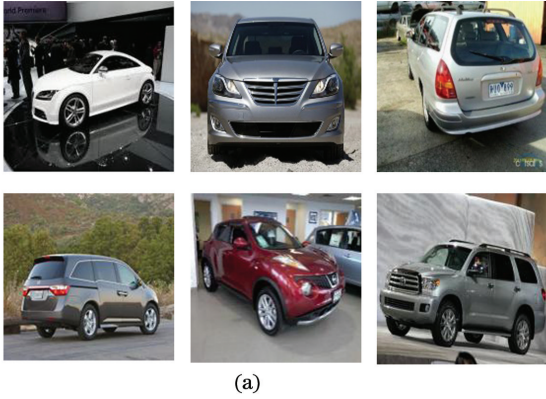
表 1 实验参数设置

Table 1 Parameter setting of experiment

Term	Parameter setting
Learning rate	[0.001,0.1]
Dropout rate	[0,0.1]
Number of filters in 2D convolution	[4,6,18]
Filter size for 2D convolution	[2,3]
Number of units	[64,128,256]
Layer or block	[2D convolution, fully connected layers, DenseNet]
Activation function of 2D convolutional layer	[Leaky ReLU, ReLU, PReLU, ReLU]
Activation function of the fully connected layer	[Sigmoid, Softmax, ReLU]
Activation function of the last fully connected layer	Sigmoid

## 4.2 数据集

实验数据集包含 24000 幅车辆图像,用于实验训练、验证及测试,其中,16000 幅正样本(包含车



(a)



(b)

图 5 数据集的部分图像。(a)正样本;(b)负样本

Fig. 5 Partial images of the data set. (a) Positive sample; (b) negative sample

## 4.3 评价标准

为了准确、全面地判定本算法中模型的泛化性能,用准确率(Accuracy)、召回率(Recall)、精确率(Precision)与 F1 分数(F1-score)四种性能度量指标评价 D-ECNN 模型的图像分类性能,可表示为

$$X_{\text{Accuracy}} = \frac{X_{\text{TP}} + X_{\text{TN}}}{X_{\text{TP}} + X_{\text{TN}} + X_{\text{FP}} + X_{\text{FN}}}, \quad (1)$$

$$X_{\text{Recall}} = \frac{X_{\text{TP}}}{X_{\text{TP}} + X_{\text{FN}}}, \quad (2)$$

$$X_{\text{Precision}} = \frac{X_{\text{TP}}}{X_{\text{TP}} + X_{\text{FP}}}, \quad (3)$$

$$X_{\text{F1-score}} = \frac{2X_{\text{Precision}}X_{\text{Recall}}}{X_{\text{Precision}} + X_{\text{Recall}}}, \quad (4)$$

式中, $X_{\text{TP}}$  为将正样本预测为正样本的数量, $X_{\text{TN}}$  为将负样本预测为负样本的数量, $X_{\text{FP}}$  为将负样本预测为正样本的数量, $X_{\text{FN}}$  为将正样本预测为负样本的数量。

## 4.4 实验分析

经过迭代和训练,最终得到一个与人工网络性能相当的 D-ECNN 模型,其结构如表 2 所示,包括 2 个 2D 卷积层、2 个全连接层、1 个 DenseNet 模块。

本算法通过训练得到最优分类模型,然后对不同分割比例下的测试集进行多次测试,计算出不同比例下算法的性能评价指标,结果如表 3 所示。可以发现,本算法在不同比例数据集下的准确率为 95.42%,召回率为 94.77%,精度和 F1 分数分别为 85.28%和 89.52%,这表明本算法在车辆数据集分类中具有较好的分类性能与稳定性。

辆)图像来自 Stanford cars 数据集,8000 幅负样本(无车辆)图像来自实景拍摄,部分实验样本如图 5 所示。

表 2 D-ECNN 模型的结构

Table 2 Structure of D-ECNN model

Layer	D-ECNN	Output channel
2D convolutional layer	Conv(3×3)	64
2D convolutional layer	Conv(2×2)	16
Dense block	Conv(1×1)	8
	Conv(3×3)	8
	Conv(1×1)	8
	Conv(3×3)	8
	Conv(1×1)	4
Transition layer	average pool(2×2)	4
Fully connected layer	Sigmoid	64
Fully connected layer	Sigmoid	2

表 3 D-ECNN 模型在不同分割率下的测试性能

Table 3 Test performances of D-ECNN model under different segmentation rates unit: %

Rate	Accuracy	Recall	Precision	F1-score
9 : 1	95.78	95.50	71.73	81.92
8 : 2	95.15	94.50	84.94	89.48
7 : 3	95.36	94.31	90.62	92.43
6 : 4	95.39	94.75	93.78	94.26
Average	95.42	94.77	85.28	89.52

为了验证本算法在车辆图像分类任务下的有效性,在相同训练集、验证集、测试集下,用本算法与 VGG16 算法进行对比实验。将本算法与 VGG16 算法进行相同的分类训练得到最优模型,然后用最优模型对相同的测试集数据进行多次实验,得到的评价指标如表 4 所示。可以发现,本算法的性能指

标均略高于 VGG16 算法,这验证了本算法在图像分类任务中的有效性。

表 4 D-ECNN 与 VGG16 算法的性能指标

Table 4 Performance indicators of D-ECNN and VGG16 algorithms unit: %

Algorithm	Accuracy	Recall	Precision	F1-score
D-ECNN	95.34	94.88	95.77	95.32
VGG16	94.56	92.63	96.36	94.46

表 5 两种算法在相同训练集中的训练参数

Table 5 Train parameters of the two algorithms in the same train set

Algorithm	Number of network layers	Number of network parameters	Number of training parameters	Model file size /M	Time-consuming of the test data set /s
D-ECNN	11	70939	69703	1.04	0.0345
VGG16	16	27844930	27834434	212	0.3967

表 6 为 EA 对本算法进行种群规模优化后的 10 个算法模型,其中,学习率与网络结构均通过 EA 优化随机生成,无需人工设置网络结构与调整参数。10 个算法模型具有不同的网络结构和学习率,表明

表 6 10 种算法模型的参数

Table 6 Parameters of 10 algorithm models

Algorithm model	Number of layers	Learning rate	Accuracy /%
D-ECNN	11	0.0050	95.34
Model-1	18	0.0035	94.53
Model-2	19	0.0037	93.42
Model-3	13	0.0059	94.22
Model-4	19	0.0047	90.73
Model-5	11	0.0045	68.76
Model-6	19	0.0055	94.82
Model-7	5	0.0058	94.38
Model-8	18	0.0055	94.83
Model-9	6	0.0045	95.23

表 5 为本算法与 VGG16 算法训练后模型的网络层数、网络总参数量、训练参数量、模型文件大小和测试数据集耗时等信息数据,可以发现,本算法的网络总参数量与训练参数量远远小于 VGG16 算法,本模型的文件大小仅为 1.04 M,对测试数据集中每幅图像的分类耗时仅为 0.0345 s,为 VGG16 算法模型耗时的 1/11,这表明本算法在实际工程应用中具有一定的优势。

EA 可以充分搜索网络结构空间。D-ECNN 算法在网络层数为 3~20 范围内自适应搜索最优结构,可以发现,本算法的准确率优于其他网络模型,可达到 95%,这也验证了本算法的有效性。

epoch 为 10 时,本算法和 VGG16 算法的最优模型在训练过程中的验证准确率如图 6 所示,可以发现,本算法在 epoch 为 10 左右就已经达到收敛状态,而 VGG16 算法在训练 epoch 为 10 时仍未达到收敛状态,这表明本算法的最优模型比 VGG16 算法最优模型的训练收敛状态更平稳。

图 7 为 D-ECNN 算法进化完成 20 次实验后的最优染色体模型(网络模型)对测试集的分类准确率,横轴为实验次数对应的染色体序号,纵轴为每条染色体模型的测试准确率,图中的两条曲线分别为每条染色体模型的测试准确率与染色体模型测试准

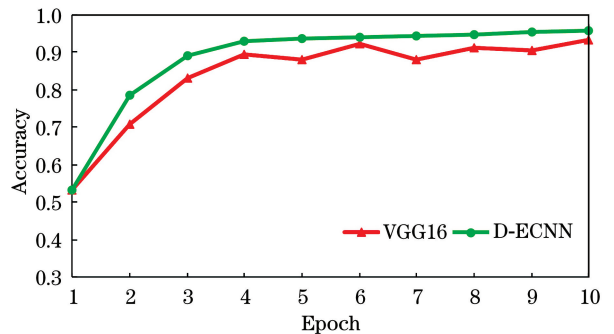


图 6 两种算法的验证准确率

Fig. 6 Verification accuracies of the two algorithms

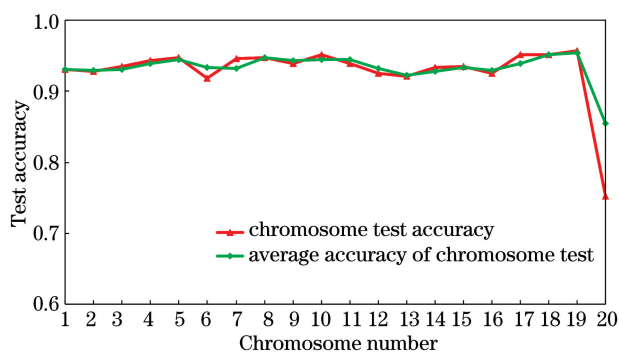


图7 D-ECNN算法20次实验的测试准确率

Fig. 7 Test accuracies of D-ECNN algorithm after 20 experiments

准确率的平均值。可以发现,除20号染色体的测试准确率为75.3%,其余染色体的测试准确率均在91%~95.8%之间,20条染色体的平均值为92.9%。这表明用EA对CNN的优化是有效的,也证明了本算法中网络设计的合理性。由于计算资源的限制,本算法将初始染色体群体设为10,最大网络层数设为20,在更多的计算资源情况下,可适当设置更多的初始染色体群体与网络层数,有利于寻找分类准确率更高的D-ECNN算法模型。

## 5 结 论

提出了一种用于图像分类任务的自动优化CNN算法,该算法基于DenseNet模块与2D卷积层,用EA优化CNN的结构与参数,避免了深度卷积网络中参数大与网络结构设计需要人工调试的问题,通过自主选择激活函数、卷积层滤波器数目及滤波器尺寸等参数与层属性组成最佳网络模型。实验结果表明,与传统机器学习中人工设计的算法相比,本算法的图像分类效果更好、更稳定。为了提高算法对复杂任务的分类准确率,还需引入网络的模块化思想,以减少重复模块的训练参数。

## 参 考 文 献

- [1] Yuan G P, Tang Y P, Han W M, et al. Vehicle category recognition based on deep convolutional neural network [J]. *Journal of Zhejiang University (Engineering Science)*, 2018, 52(4): 694-702.  
袁公萍, 汤一平, 韩旺明, 等. 基于深度卷积神经网络的车牌识别方法 [J]. *浙江大学学报(工学版)*, 2018, 52(4): 694-702.
- [2] Huang S, Li F F, Chen Q. Computed tomography image classification algorithm based on improved deep

residual network [J]. *Acta Optica Sinica*, 2020, 40 (3): 0310002.

黄盛, 李菲菲, 陈虬. 基于改进深度残差网络的计算断层扫描图像分类算法 [J]. *光学学报*, 2020, 40 (3): 0310002.

- [3] Liu F, Lu L X, Huang G W, et al. Landform image classification based on discrete cosine transformation and deep network [J]. *Acta Optica Sinica*, 2018, 38 (6): 0620001.  
刘芳, 路丽霞, 黄光伟, 等. 基于离散余弦变换和深度网络的地貌图像分类 [J]. *光学学报*, 2018, 38 (6): 0620001.
- [4] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks [C] // *Advances in Neural Information Processing Systems (NIPS)*, December 3-8, 2012, Nevada, USA. Cambridge: MIT, 2012: 1097-1105.
- [5] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions [C] // *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 7-12, 2015, Boston, MA, USA. New York: IEEE, 2015: 1-9.
- [6] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2020-03-15]. <https://arxiv.org/abs/1409.1556>.
- [7] Bai C, Huang L, Chen J N, et al. Optimization of deep convolutional neural network for large scale image classification [J]. *Journal of Software*, 2018, 29(4): 1029-1038.  
白琮, 黄玲, 陈佳楠, 等. 面向大规模图像分类的深度卷积神经网络优化 [J]. *软件学报*, 2018, 29(4): 1029-1038.
- [8] Tong G X, Tian F X. Classification method of twice train fusion based on CNNs [J]. *Journal of University of Electronic Science and Technology of China*, 2019, 48(5): 774-778.  
佟国香, 田飞翔. 基于CNNs的两次训练融合的分类方法 [J]. *电子科技大学学报*, 2019, 48(5): 774-778.
- [9] Assunção F, Lourenço N, Machado P, et al. Fast densenet: efficient deep neuroevolution [M] // *Sekanina L, Hu T, Lourenço N, et al. Genetic Programming. EuroGP 2019. Lecture Notes in Computer Science*. Cham: Springer, 2019, 11451: 197-212.
- [10] Lehman J, Chen J, Clune J, et al. Safe mutations for deep and recurrent neural networks through output gradients [C] // *Genetic and Evolutionary Computation Conference*, July 15-19, 2018, Kyoto, Japan. New

- York: ACM, 2018: 117-124.
- [11] Conti E, Madhavan V, Such F P, et al. Improving exploration in evolution strategies for deep reinforcement learning via a population of novelty-seeking agents[C]//Advances in Neural Information Processing Systems, December 3-8, 2018, Montreal, Canada. Cambridge: MIT, 2018: 5027-5038.
- [12] Lehman J, Chen J, Clune J, et al. ES is more than just a traditional finite-difference approximator[C]//Genetic and Evolutionary Computation Conference, July 15-19, 2018, Kyoto, Japan. New York: ACM, 2018: 450-457.
- [13] Stanley K O. Neuroevolution: a different kind of deep learning [EB/OL]. [2020-03-16]. [https://xueshu.baidu.com/usercenter/paper/show?paperid=d4d530940b846a6025057f59a4cafd7b&site=xueshu\\_se](https://xueshu.baidu.com/usercenter/paper/show?paperid=d4d530940b846a6025057f59a4cafd7b&site=xueshu_se).
- [14] Abraham A. Optimization of evolutionary neural networks using hybrid learning algorithms [C] // Proceedings of the 2002 International Joint Conference on Neural Networks. IJCNN'02, May 12-17, 2002, Honolulu, HI, USA. New York: IEEE, 2002: 2797-2802.
- [15] Xie L X, Yuille A. Genetic CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 1388-1397.
- [16] Real E, Moore S, Selle A, et al. Large-scale evolution of image classifiers [C] // International Conference on Machine Learning, August 6-11, 2017, Sydney, Australia. New York: ACM, 2017: 2902-2911.
- [17] Desell T. Large scale evolution of convolutional neural networks using volunteer computing [EB/OL]. [2020-03-12]. <https://arxiv.org/abs/1703.05422>.
- [18] Tao Y, Xu M, Lu Z, et al. DenseNet-based depth-width double reinforced deep learning neural network for high-resolution remote sensing image per-pixel classification[J]. Remote Sensing, 2018, 10(5): 779.
- [19] Betere J I, Kinjo H, Nakazono K, et al. Investigation of training performance of convolutional neural networks evolved by genetic algorithms using an activity function[J]. Artificial Life and Robotics, 2020, 25(1): 1-7.
- [20] Li H, Zhang L M, Jiang M R, et al. An infrared and visible image fusion algorithm based on ResNet152 [J]. Laser & Optoelectronics Progress, 2020, 57(8): 081013.  
李恒, 张黎明, 蒋美容, 等. 一种基于 ResNet152 的红外与可见光图像融合算法[J]. 激光与光电子学进展, 2020, 57(8): 081013.
- [21] Lodhi B, Kang J. Multipath-DenseNet: a supervised ensemble architecture of densely connected convolutional networks[J]. Information Sciences, 2019, 482: 63-72.
- [22] Ojha V K, Abraham A, Snášel V. Metaheuristic design of feedforward neural networks: a review of two decades of research[J]. Engineering Applications of Artificial Intelligence, 2017, 60: 97-116.
- [23] Stanley K O, Miikkulainen R. Evolving neural networks through augmenting topologies[J]. Evolutionary Computation, 2002, 10(2): 99-127.
- [24] Zhu W, Qu J Y, Wu R B. Straight convolutional neural networks algorithm based on batch normalization for image classification[J]. Journal of Computer-Aided Design & Computer Graphics, 2017, 29(9): 1650-1657.  
朱威, 屈景怡, 吴仁彪. 结合批归一化的直通卷积神经网络图像分类算法[J]. 计算机辅助设计与图形学学报, 2017, 29(9): 1650-1657.
- [25] Dufourq E, Bassett B A. EDEN: evolutionary deep networks for efficient machine learning [C] // 2017 Pattern Recognition Association of South Africa and Robotics and Mechatronics, November 30-December 1, 2017, Bloemfontein, South Africa. New York: IEEE, 2017: 110-115.
- [26] Such F P, Madhavan V, Conti E, et al. Deep neuroevolution: genetic algorithms are a competitive alternative for training deep neural networks for reinforcement learning [EB/OL]. [2020-03-12]. <https://arxiv.org/abs/1712.06567>.