

基于改进深度卷积神经网络的交通标志识别

马永杰*, 李雪燕, 宋晓凤

西北师范大学物理与工程学院, 甘肃 兰州 730070

摘要 在实际交通环境中, 所采集到的交通标志图像质量往往受到运动模糊、背景干扰、天气条件以及拍摄视角等因素的影响, 这对交通标志自动识别的准确性、实时性和稳健性提出了很大的挑战。为此提出了改进深度卷积神经网络 AlexNet 的分类识别算法模型, 该模型在传统 AlexNet 模型基础上, 以真实场景中拍摄的交通标志图像数据集 GTSRB 为研究对象, 将所有卷积层的卷积核修改为 3×3 大小, 为了预防和减少过拟合的出现在两个全连接层后加入 dropout 层, 并且为了提高交通标志识别精度, 在网络模型第 5 层后增加两层卷积层。实验结果表明, 改进后 AlexNet 模型在交通标志识别方面具有一定的先进性和稳健性。

关键词 图像处理; 卷积神经网络; 交通标志识别; 改进 AlexNet 模型; 可视化

中图分类号 TP391.7

文献标识码 A

doi: 10.3788/LOP55.121009

Traffic Sign Recognition Based on Improved Deep Convolution Neural Network

Ma Yongjie*, Li Xueyan, Song Xiaofeng

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

Abstract In the actual traffic environment, the quality of the collected traffic signs is often influenced by the factors such as motion blur, background interference, weather conditions and shooting angles and so on, which poses a great challenge to the accuracy, real-time and robustness of traffic sign automatic identification. Owing to this, a classification recognition algorithm model of improved deep convolution neural network AlexNet is proposed. On the basis of the traditional AlexNet model, this model takes the traffic sign image data set GTSRB taken in the real scene as the research object, modifies the convolution kernels of all coiling layers to 3×3 , in order to prevent and reduce the occurrence of over fitting, the dropout layer is added after two fully connected layers. In order to improve the accuracy of traffic sign recognition, two convolution layers are added after the fifth layer of the network model. The experimental results show that the improved AlexNet model is advanced and robust in traffic sign recognition.

Key words image processing; convolution neural network; traffic sign recognition; improved AlexNet model; visualization

OCIS codes 100.0100; 200.4260; 100.3008; 150.1135

1 引言

交通标志识别是智能交通系统的重要组成部分^[1], 它能够辅助驾驶从而减少驾驶员的驾驶疲劳, 保证出行安全, 在交通安全运行方面具有重大的现实意义。交通标志识别往往是在汽车运行过程中和复杂的室外交通环境下进行的, 比一般静止的事物识别更难, 主要体现在运动模糊、复杂多变的光照

(天气)条件^[2]、背景环境干扰、拍摄角度使交通标志位置倾斜等问题。

为了解决这些问题, 大量的复杂算法被提出, 深度学习是目前在目标识别方面应用最多的方法, 而深度学习中最著名的就是卷积神经网络 (CNN)^[3-6]。2012 ILSVRC 竞赛中, AlexNet 模型赢得了第一名, 刷新了图像分类的纪录, 一举奠定深度学习在计算机视觉中的地位, 成为 CNN 领域内

收稿日期: 2018-04-25; 修回日期: 2018-05-28; 录用日期: 2018-07-12

基金项目: 国家自然科学基金(41461078)

* E-mail: myjmyj@163.com

具有重要历史意义的一个网络模型。AlexNet 模型及其改进 AlexNet 模型被大量研究和应用。2017 年,党宇等^[7]利用 AlexNet 模型高效的训练、稳定的收敛速度等优势,验证了深度学习在遥感影像地表覆盖分类评价中的有效性。2017 年,吕鸿蒙等^[8]针对医学图像改进 AlexNet 模型,取得了较好的测试结果。2017 年,Zhang 等^[9]提出一个修改过的 AlexNet 网络来估计静止图像中的人数,证明了该方法的有效性。2018 年,陈清江等^[10]在多聚焦图像融合的过程中,在原有的 AlexNet 网络模型基础上对卷积核大小、步长等进行改进,利用改进后的深度学习网络特有的得分机制对聚焦图像块与散焦图像块进行分类。因此,本文利用 AlexNet 模型分类优势,考虑到交通标志识别应用中对实时性和准确性有较高的要求,对 AlexNet 进行改进并加以利用。

2 卷积神经网络

CNN 是深度学习中研究和应用较为广泛的一个分支,是一种专门用来处理具有类似网络数据结构的神经网络。CNN 包括卷积层、池化层(也称亚采样层)、全连接层等主要结构。

CNN 学习图像的特征是靠卷积层和池化层来实现的。卷积运算的主要作用为提取图像特征,卷积公式为

$$y(n) = x(n) * h(n), \quad (1)$$

式中 $*$ 表示卷积, $x(n)$ 为卷积对象, $h(n)$ 为卷积核, $y(n)$ 为卷积结果, n 为卷积核位移的量。将卷积层输出的结果作非线性的映射(保留特征,去除一些数据中的冗余),需要卷积层激活函数,本文的卷积层激活函数为 ReLU 函数^[11],计算公式为

$$f(x) = \max(0, x), \quad (2)$$

式中:当 $x > 0$ 时,该层的输出等于输入,无梯度耗散收敛快;当 $x \leq 0$ 时,该层的输出为 0,训练完成后为 0 的神经元越多,稀疏性越大,提取出来的特征就越具有代表性,泛化能力越强。

池化层则是降低特征维度,以此达到减小计算复杂度、避免过拟合的目的。池化方式一般有平均池化和最大池化这两种,两者都伴随着原始图像维度的降低。最大池化是选取图像目标局部区域的最大值作为该区域池化后的值,对提取纹理特征更好。计算公式为

$$y_{ij} = \max_{(i,j) \in \Omega} x_{ij}, \quad (3)$$

式中: x_{ij} 为邻域 Ω 内的 i 行、 j 列的函数值; Ω 表示

以 x_{ij} 为中心某一定值的邻域。图 1 为卷积核尺寸为 2×2 、步长为 2 的池化窗口对原始图像的最大池化过程,左侧输入为原始图像的像素表示,右侧输出为最大池化后的效果。




图 1 最大池化示意图

Fig. 1 Maximum pooling schematic

全连接层,即输出层的神经元和输入层的每个神经元都相连接,其本质是分类器,可以让整个网络使用基于梯度的学习方法来进行全局训练,比如 Softmax、径向基函数(RBF)网络、一层或两层的全连接神经网络等分类算法,即使是不可微的分类器[比如支持向量机(SVM)分类器]也可以使用。其中 Softmax 分类器由于其复杂度低且分类效果好,在神经网络中广泛应用。

考虑对模型速度和效果的影响^[12],本文从 CNN 的卷积核、层的效果及层数入手,将 CNN 的卷积核尺寸修改为 3×3 、在全连接层后加入 dropout 层和在网络模型第 5 层后增加两层卷积层。

3 改进 AlexNet 模型

3.1 AlexNet 模型

整个 AlexNet 模型有 8 个需要训练参数的层[不包括池化层和局部响应值归一化(LRN)层],前 5 层为卷积层,后 3 层为全连接层。用于交通标志识别的 AlexNet 最后一层是有 43 类输出的,这是由分类任务决定的,Softmax 输出层用作分类,而最大池化层出现在前两个卷积层及最后一个卷积层后。AlexNet 网络的基本结构如图 2 所示。

3.2 网络模型改进

在 CNN 训练过程中,有时由于数据集的大小和过度训练,会出现训练的模型在训练数据集中拟合程度很好,但在测试数据集中拟合效果较差的现象即过拟合。为了预防和减少过拟合,在全连接层后加入 dropout^[13]的优化方案,dropout 是在每层神经元单元训练开始时,随机的删除一定比例(一般设为 0.5)的隐藏层神经元,保持输入层与输出层的个




图 2 AlexNet 网络的基本结构

Fig. 2 Basic structure of AlexNet network

数不变。然后按照反向传播(BP)算法对 CNN 中的参数进行学习更新(虚线连接的单元不更新),这样一次迭代更新便完成,下一次迭代中同样随机选择

删除一些神经元,直至训练结束。如图 3 所示,图 3(a)为未使用 dropout 的三层神经网络,图 3(b)为使用 dropout 的三层神经网络。




图 3 神经网络对比图。(a)未使用和(b)使用 dropout 的三层神经网络

Fig. 3 Neural network contrast diagrams. Three-level neural network with (a) unused and (b) used dropout

没有 dropout 时的神经网络训练过程为

$$\begin{cases} z_i^{(l+1)} = w_i^{(l+1)} y^l + b_i^{(l+1)} \\ y_i^{(l+1)} = f(z_i^{(l+1)}) \end{cases} \quad (4)$$

为了达到 ensemble 的特性,使用 dropout 后神经网络的训练过程对应的公式为

$$\begin{cases} r_j^{(l)} \sim \text{Bernoulli}(p) \\ \tilde{y}^{(l)} = r^{(l)} * y^l \\ z_i^{(l+1)} = w_i^{(l+1)} \tilde{y}^l + b_i^{(l+1)} \\ y_i^{(l+1)} = f(z_i^{(l+1)}) \end{cases} \quad (5)$$

式中: l 是隐藏层索引; z 表示 l 层的向量输入; y 是每一层的输出; y_0 是输入层; w 是权值参数; f 表示激活函数。预测时,每一个单元的参数要预乘以 p 。

改进 1:在计算资源有限的情况下,模型的训练过程中,不仅要关注模型结构的合理性、权值收敛情

况、分类的识别率等,还要考虑到训练过程所需的硬件计算能力和存储能力等。压缩减少卷积层的学习参数总量,将所有卷积层的卷积核修改为 3×3 大小,代替原来的 11×11 和 5×5 卷积核,且在两个全连接层后加入 dropout 层。

改进 2:卷积的作用是提取特征,在识别的过程中,输入特征提取得越精细,输入图像被识别的可能性越大,且识别精度越高。为了提高交通标志的识别准确率,本文在经典的 AlexNet 网络的基础上,在其第 5 层后面增加两层卷积层,提高网络的识别精度。

如上所述,得到改进的 AlexNet 网络模型结构如图 4 所示,此时 AlexNet 网络模型的参数设置如表 1 所示。




图 4 改进的 AlexNet 模型结构图

Fig. 4 Structure diagram of improved AlexNet model

表 1 改进的 AlexNet 网络模型设置
Table 1 Model setting of improved AlexNet network

Layer	Layer input	Convolution kernel				Convolution output	Pooling		Pooled output	Layer output
		Size	Number	Step	Pad		Size	Mode		
L1(conv1+pool1)	48×48×3	3×3	84	1	1	48×48×84	2×2	Max	24×24×84	24×24×84
L2(conv2+pool2)	24×24×84	3×3	125	1	1	24×24×125	2×2	Max	12×12×125	12×12×125
L3(conv3)	12×12×125	3×3	250	1	0	10×10×250	—	—	—	10×10×250
L4(conv4)	10×10×250	3×3	500	1	1	10×10×500	—	—	—	10×10×500
L5(conv5+pool5)	10×10×500	3×3	250	1	0	8×8×250	2×2	Max	4×4×250	4×4×250
L6(conv6)	4×4×250	3×3	250	1	0	2×2×250	—	—	—	2×2×250
L7(conv7)	2×2×250	2×2	500	1	0	1×1×500	—	—	—	1×1×500
L8(Full)	1×1×500	—	—	—	—	—	—	—	—	1000
L9(Full)	1000	—	—	—	—	—	—	—	—	1000
L10(Softmax)	1000	—	—	—	—	—	—	—	—	44

4 实验与结果分析

4.1 实验数据

实验使用德国交通标志数据集(GTSRB)^[14], 该数据集包含 43 类从德国真实交通环境中采集的交通标志, 其中训练集有 39029 幅, 测试集有 12630 幅, 总计为 51839 幅图像, 每幅图像只包含一个交通标志, 且数据集中包括大量低分辨率、不同光照强度、局部遮挡、视角倾斜、运动模糊等各种不利条件下的图像, 能够较真实且全面地反映现实情况、评价算法

性能。由于本文使用 CNN 方法, 所有的图像都必须大小一致, 文献[15]把所有的图像都转化成 48×48 大小, 获得感兴趣区域。CNN 方法具有很强的稳健性, 因此并没有使用具体的去噪方法进行去噪。

4.2 实验平台及流程

实验所用的计算机配置是 I5-7500 处理器, 主频 3.4 GHz, 内存 16 GB, Nvidia GeForce GT730 显卡, Ubuntu 16.04 版本的 Linux 操作系统, 深度学习框架为 caffe^[16], 软件编程环境为 Python 2.7。实验流程如图 5 所示。

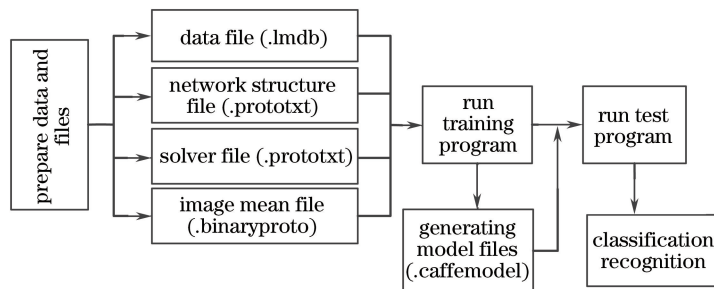


图 5 实验流程图

Fig. 5 Experimental flow chart

4.3 实验结果及分析

为了验证使用 dropout 改进后的模型在交通标志识别上是否具有有良好的防止过拟合的效果, 首先将原 AlexNet 模型、无 dropout 的改进后的模型和

有 dropout 的改进后的模型三种模型进行实验对比。测试样本随机从测试集中选取 5000 幅, 对比从测试样本错误量、测试误差率两方面进行分析。表 2 所示为 dropout 对模型的影响。

表 2 Dropout 对模型的影响

Table 2 Impact of dropout on the model

Model	AlexNet model	Improved model without dropout	Improved model with dropout
Test sample error number	196	173	58
Test error rate	0.040	0.035	0.012

由表 2 可知, 使用 dropout 改进的模型测试样本错误量最少同时测试误差率最小, 因此本文模型

具有良好的防止过拟合作用。

在全连接层后均加入 dropout 层, 采用

AlexNet 模型、本文改进的模型分别进行两组实验,求解文件参数为初始学习率设为 0.001,防止过拟合权重衰减项为 0.0005,动量为 0.9,学习速率变化因子为 0.1,每训练 1000 次进行一次测试,每训练 20 次在显示屏上显示一次。采用 AlexNet 模型时最大迭代次数设为 10000;采用改进的模型时最大迭代次数也设为 10000,训练结束均可得到稳定的结果。




图 6 部分卷积层操作可视化

Fig. 6 Visualization of the coiling layer operation

2) 学习曲线可视化

在训练过程中,通过绘制精度和损失曲线能够较为直观清楚地观察到训练的动态过程。图 7(a)和(b)分别表示采用 AlexNet 模型和改进的模型这两组网络模型在训练过程中对应的精度和损失曲线。采用 AlexNet 模型时最大迭代次数设为 10000;采用改进

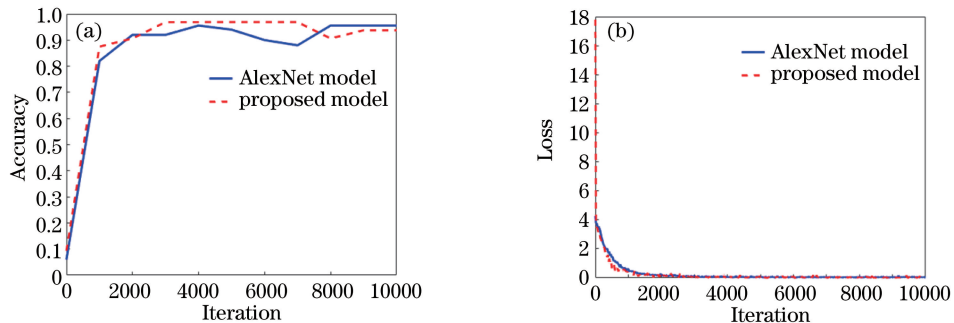


图 7 (a)精度和(b)损失曲线对比图

Fig. 7 Contrast diagrams of (a) Accuracy and (b) loss

3) 算法分类能力分析

采用 AlexNet 模型、本文模型在算法分类能力方面作比较分析,结果如表 3 所示。可以看出,改进

1) 特征图可视化

图 6 为一张交通标志图像在本文改进方法所提模型中经过各个卷积层特征处理后的部分结果,展示 CNN 在各个阶段进行图像处理的情况。从图 6 可以看出,C1、C2 低层响应特征图关注图像纹理及轮廓这样的不同细节特征,像 C7 高维响应特征图就变得局部且稀疏,甚至无法通过肉眼辨别,用来滤除不相关的内容并提取出重要特征。

的模型时最大迭代次数也设为 10000。由图 7 明显得出,两组模型损失值不断下降直至平稳,精度值不断上升直至平稳;当 AlexNet 模型的损失值接近 0 且精度值达到稳定状态时,网络迭代次数约为 8000;而改进模型在网络迭代次数为 3000~7000 时,损失值接近 0,精度值约为 97%,网络达到稳定状态。

的模型在参数消耗内存大幅减少的情况下,识别准确率还要高 1.3%。由此可见,本文对 AlexNet 模型进行的所有改进均合理有效。

表 3 算法分类能力分析

Table 3 Algorithm classification ability analysis

Algorithm	Training time /h	Parameter consumption memory /MB	Identifying each image time /ms	Recognition accuracy /%
AlexNet model	173	228.2	158	95.568
Improved model	16	21	40	96.875

设定只采用改进条件 1 为对比模型 1, 设定只采用改进条件 2 为对比模型 2。实验中求解文件参数设置一致; 最大迭代次数均为 10000, 初始学习率设为 0.001, 防止过拟合权重衰减项为 0.0005, 动量

为 0.9, 学习速率变化因子为 0.1, 每训练 1000 次进行一次测试, 每训练 20 次在显示屏上显示一次。对比模型 1 的实验结果与改进模型做比较, 对比模型 2 的实验结果与改进模型做比较, 如表 4 所示。

表 4 算法对比分析

Table 4 Algorithm comparison and analysis

Algorithm	Training time /h	Parameter consumption memory /MB	Recognition accuracy /%
Improved model	16	21	96.875
Contrast model 2	21	21.7	—
Contrast model 1	—	21.2	93.750

由表 4 可知, 改进模型压缩减少卷积层的学习参数总量, 将所有卷积层的卷积核修改为 3×3 大小, 代替原来的 11×11 和 5×5 卷积核, 训练时间由 21 h 减少到 16 h。改进模型在第 5 层后面增加两层卷积层, 网络识别精度由 93.750% 提高到 96.875%。

为了客观对本文算法进行分析, 基于相同的数据集将本文算法与其他交通标志的识别算法进行比较, 表 5 列举了不同方法在 GTSRB 数据集的识别准确率与耗时, 可见针对交通标志这个识别目标, 设计一种优秀的网络模型, 提取有效的特征层信息, 其识别准确率会大大提升。

表 5 不同方法在 GTSRB 数据集识别结果对比

Table 5 Comparison of different methods in GTSRB dataset recognition results

Algorithm	Classification time /ms	Accuracy rate /%
HOG+SVM algorithm of Ref. [17]	176	95.68
ANN	—	89.63
Random forests	—	96.14
Improved model algorithm	40	96.875
Algorithm of Ref. [1]	275	99.01
Algorithm of Ref. [6]	152	98.57

由表 5 可知, 本文改进模型算法比直方图与支持向量机 (HOG + SVM) 算法、人工神经网络 (ANN) 和随机森林算法的识别准确率都高, 虽然本文改进模型算法比文献[1]和文献[6]的识别准确率低些, 但是分类时间明显比文献[1]和文献[6]的分类时间少很多, 实时性和识别准确率均能满足交通标志识别的要求。

4) 实际环境条件因素下的识别

随机选取在实际行车环境下的 30 幅运动过程中模糊的图像、51 幅受背景干扰的图像、30 幅受光照(天气)条件影响图像和 30 幅存在拍摄角度的图像, 作为实际环境条件因素下的识别。此时, 直接调用训练 8000 次保存的 AlexNet 模型、训练 3000~7000 次保存的改进的模型文件, 统计测试样本数量和正确识别出来的数量, 并计算准确率。测试结果如表 6 和 7 所示。

表 6 实际环境条件下 AlexNet 模型的识别情况

Table 6 Identification of AlexNet model under real environmental conditions

Type	Test sample number	Correct recognition number of AlexNet model	Recognition accuracy rate of AlexNet model /%
Motion blur	30	22	73.3
Background interference	51	43	84.3
Light (weather)	30	25	83.3
Shooting angle	30	26	86.6

从表 6 和 7 测试结果可以看出, 4 种实际环境条件因素下的改进的模型识别准确率都达到了较高的水平, 说明本文采用的改进模型具有良好的分类

识别能力。但是在各种环境条件下识别过程中仍存在分类错误的个例, 这主要是由于图像受实际环境因素中多种因素综合影响, 图像受损比较严重。

表 7 实际环境条件下改进模型的识别情况

Table 7 Identification of improved model under real environmental conditions

Type	Test sample number	Correct recognition number of improved model	Recognition accuracy rate of improved model / %
Motion blur	30	23	76.6
Background interference	51	45	88.2
Light (weather)	30	27	90.0
Shooting angle	30	28	93.3

5 结 论

设计并实现了改进深度 CNN AlexNet 的网络模型及结构,得到了算法模型参数,通过多次实验验证了本文算法的参数设计的合理性,应用于交通标志识别取得了良好的效果,在 GTSRB 数据集上得到了 96.875% 的识别准确率、分类识别每幅图像 40 ms 的识别速度。通过与 AlexNet 模型对比,在参数总量大幅减少的情况下,识别准确率还要高 1.3%,验证了本文算法的先进性;在 4 种实际环境条件因素下进行识别,验证了本文算法的稳健性,但本文算法在识别受损严重的图像方面仍需深入研究。

参 考 文 献

- [1] Xu Y, Wei Z Y. An improved traffic sign image recognition algorithm [J]. *Laser & Optoelectronics Progress*, 2017, 54(2): 021001.
徐岩, 韦镇余. 一种改进的交通标志图像识别算法 [J]. *激光与光电子学进展*, 2017, 54(2): 021001.
- [2] Zhang S F, Zhu T. A method of traffic sign detection and recognition based on HDR technology [J]. *Laser & Optoelectronics Progress*, 2018, 55(9): 091006.
张淑芳, 朱彤. 一种基于 HDR 技术的交通标志牌检测和识别方法 [J]. *激光与光电子学展*, 2018, 55(9): 091006.
- [3] Luo H L, Yang Y, Tong B, *et al.* Traffic sign recognition using a multi-task convolutional neural network [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(4): 1100-1111.
- [4] Zhong X M, Yu G Z, Ma Y L, *et al.* Research on traffic sign recognition algorithms based on fast regional convolution neural network [C] // *Annual Conference Papers of China Society of Automotive Engineers*, 2016: 4.
钟晓明, 余贵珍, 马亚龙, 等. 基于快速区域卷积神经网络的交通标志识别算法研究 [C] // *中国汽车工程学会年会论文集*, 2016: 4.
- [5] Tan T Z, Lu J B, Wen J W, *et al.* Traffic sign

recognition applying with convolution neural network and RPN [J]. *Computer Engineering and Applications*, 2018, 54(21): 251-256.

谭台哲, 卢剑彪, 温捷文, 等. 应用卷积神经网络与 RPN 的交通标志识别 [J]. *计算机工程与应用*, 2018, 54(21): 251-256.

- [6] Xu Z, Feng C H. Modified scale dependent pooling model for traffic image recognition [J]. *Journal of Computer Applications*, 2018, 38(3): 671-676.
徐喆, 冯长华. 用于交通图像识别的改进尺度依赖池化模型 [J]. *计算机应用*, 2018, 38(3): 671-676.
- [7] Dang Y, Zhang J X, Deng K Z, *et al.* Study on the evaluation of land cover classification using remote sensing images based on AlexNet [J]. *Journal of Geo-Information Science*, 2017, 19(11): 1530-1537.
党宇, 张继贤, 邓略中, 等. 基于深度学习 AlexNet 的遥感影像地表覆盖分类评价研究 [J]. *地球信息科学学报*, 2017, 19(11): 1530-1537.
- [8] Lü H M, Zhao D, Chi X B. Deep learning for early diagnosis of Alzheimer's disease based on intensive AlexNet [J]. *Computer Science*, 2017, 44(6A): 50-60.
吕鸿蒙, 赵地, 迟学斌. 基于增强 AlexNet 的深度学习阿尔茨海默病的早期诊断 [J]. *计算机科学*, 2017, 44(6A): 50-60.
- [9] Zhang Y M, Chang F L, Li N J, *et al.* Modified AlexNet for dense crowd counting [C] // *2017 2nd International Conference on Computer Science and Engineering, Information Science and Internet Technology (CII 2017)*: 351-357.
- [10] Chen Q J, Li Y, Chai Y Z. A multi focus image fusion algorithm based on deep learning [J]. *Laser & Optoelectronics Progress*, 2018, 55(7): 071015.
陈清江, 李毅, 柴昱洲. 一种基于深度学习的多聚焦图像融合算法 [J]. *激光与光电子学进展*, 2018, 55(7): 071015.
- [11] Li J N, Zhang B H. Face recognition by feature matching fusion combined with improved convolutional neural network [J]. *Laser & Optoelectronics Progress*, 2018, 55(10): 101504.

- 李佳妮, 张宝华. 特征匹配融合结合改进卷积神经网络的人脸识别[J]. 激光与光电子学进展, 2018, 55(10): 101504.
- [12] Xiao J S, Liu E Y, Zhu L, *et al.* Improved image super-resolution algorithm based on convolutional neural network [J]. *Acta Optica Sinica*, 2017, 37(3): 0318011.
- 肖进胜, 刘恩雨, 朱力, 等. 改进的基于卷积神经网络的图像超分辨率算法[J]. 光学学报, 2017, 37(3): 0318011.
- [13] Hinton G E, Srivastava N, Krizhevsky A, *et al.* Improving neural networks by preventing co-adaptation of feature detectors [J]. *Computer Science*, 2012, 3(4): 212-223.
- [14] Stallkamp J, Schlipsing M, Salmen J, *et al.* Man vs. computer: Benchmarking machine learning algorithms for traffic sign recognition [J]. *Neural Networks*, 2012, 32: 323-332.
- [15] Liu Z W, Zhao X M, Li Q, *et al.* Traffic sign recognition method based on graphical model and convolutional neural network [J]. *Journal of Traffic and Transportation Engineering*, 2016, 16(5): 122-131.
- 刘占文, 赵祥模, 李强, 等. 基于图模型与卷积神经网络的交通标志识别方法[J]. 交通运输工程学报, 2016, 16(5): 122-131.
- [16] Ou X F, Xiang C Q, Guo L Y, *et al.* Research of recognition of digital characters on vehicle license based on caffe deep learning framework [J]. *Journal of Sichuan University (Natural Science Edition)*, 2017, 54(5): 971-977.
- 欧先锋, 向灿群, 郭龙源, 等. 基于 Caffe 深度学习框架的车牌数字字符识别算法研究[J]. 四川大学学报(自然科学版), 2017, 54(5): 971-977.
- [17] Ruta A, Li Y M, Liu X H. Real-time traffic sign recognition from video by class-specific discriminative features [J]. *Pattern Recognition*, 2010, 43(1): 416-430.