

参数池化卷积神经网络图像分类方法

江泽涛¹, 秦嘉奇², 张少钦³

(1. 桂林电子科技大学广西图像图形与智能处理重点实验室, 广西桂林 541004;
2. 桂林电子科技大学信息科技学院, 广西桂林 541004; 3. 南昌航空大学, 江西南昌 330063)

摘 要: 传统的卷积神经网络使用池化层对信息进行降维操作, 通常会造信息损失, 从而影响网络的表达能力. 针对这一问题, 使用参数池化层(Parameterized Pooling Layer)替代传统卷积神经网络中的池化层, 提出参数池化卷积神经网络(Parameterized Pooling CNN, PPCNN). 参数池化层在仅仅增加了少量网络参数的情况下, 最大可能的保留了卷积神经网络中希望被保留下来的特征; 同时, 由于增加了池化层前向传播的信息, 从而影响了反向传播算法中权值的更新, 网络收敛速度更快; 实验结果表明, PPCNN 模型与传统卷积神经网络模型以及部分改进模型相比, 参数池化卷积神经网络模型是有效的.

关键词: 卷积神经网络; 图像分类; 池化方法; 参数优化

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2020)09-1729-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.09.009

Parameterized Pooling Convolution Neural Network for Image Classification

JIANG Ze-tao¹, QIN Jia-qi², ZHANG Shao-qin³

(1. Guangxi Key Laboratory of Image and Graphic Intelligent Processing, Guilin University of Electronic Technology, Guilin, Guangxi 541000, China;
2. Institute of Information Technology of Guet, Guilin, Guangxi 541000, China;
3. Nanchang Hangkong University, Nanchang, Jiangxi 330063, China)

Abstract: Traditional convolutional neural network uses pooling layer to reduce the dimension of feature, which usually results in information loss, thus affecting the expression ability of the network. To solve this problem, the parameterized pooling layer is used to replace the pooling layer in the conventional convolutional neural network, and the parameterized pooling CNN (PPCNN) is proposed. In the case that only a few network parameters are added in the parameter pooling layer, it is possible to retain the desired features. At the same time, the forward propagation information of the pooling layer is added, which affects the update of weight in the backpropagation algorithm, and the network convergence speed is faster. Compared with the conventional convolutional neural network model and some improved models, experimental results show that the PPCNN model is effective.

Key words: convolutional neural network; image classification; pooling; parameter optimization

1 引言

对于图像分类问题, 图像高维度特征的提取与表达存在着相当大的困难. 基于人工设计的特征描述子提取算法, 无法避免特征表达能力不足的缺陷. 深度学习的出现, 解决了人工设计特征表达能力不足的问题, 在图像分类问题上, 卷积神经网络自 2012 年 AlexNet^[1] 出现以来, 已经取得了巨大进展. 近年来图像分类任务

的冠军都被基于卷积神经网络的方法夺取.

卷积神经网络(CNN)其特征在于能够从输入样本中学习到的特征, 特征可以送入各类分类器形成整个分类模型. 其实质上是建立一个从数据到特征空间的映射关系, 是机器学习的一个重要分支, 也是目前人工智能领域的研究特点之一. 由于 CNN 中使用卷积运算提取图像特征, 使得提取到的特征对翻转、平移、比例缩放具有较强的鲁棒性, 仿生物神经网络结构使得

收稿日期: 2018-12-27; 修改日期: 2020-04-19; 责任编辑: 孙瑶

基金项目: 国家自然科学基金(No. 61876049, No. 61762066); 广西科技计划(No. AC16380108); 广西图像图形智能处理重点实验室项目(No. GIP201701, No. GIP201801, No. GIP201802, No. GIP201803); 广西研究生教育创新计划(No. YCBZ2018052, No. 2019YCXSO43)

提取到的特征表达更为自然。

目前,卷积神经网络仍然朝着更精确、更快速的方向发展.为了更好的表达图像特征,卷积神经网络中的微架构不断的改进.VGGNets^[2]以及 InceptionNet^[3]展示了较深的网络往往能够获得到更好的性能;ResNet^[4]说明了通过输入之间的短接(shotcuts)能够使得学习过程更加高效,同时避免了梯度消失问题;MobileNet^[5]、SqueezeNet^[6]等网络模型则在不断追求网络精确度的同时,实现了保持网络精确度的前提下提高 CNN 的运行速度。

在上述的经典卷积神经网络中,在卷积层之后都会加入一个池化层(pooling layer),其目的是降低特征维度,将计算量降低到可以接受的范围.池化的主要方法有平均池化、最大池化和随机池化.为了降低池化层给网络性能带来的负面影响,前人也提出了改进的池化算法,He^[7]等提出的空间金字塔池化, Benjamin^[8]提出的分数最大池化(fractional max-pooling).上述池化方法的本质实际上是降采样,因此不论采用何种池化方法,必然都会造成特征损失从而影响 CNN 性能.对此 Chen-Yu Lee 等使用混合(mixed)、门限(gated)和树(tree)方法探讨了 CNN 中池化函数的泛化问题,并提出了有效的“mixed max-average pooling”、“gated max-average pooling”以及 tree pooling 方法^[9],罗畅^[10]等构建了一个用于提取卷积自编码器粗粒度池化特征的框架.受到在机器学习中,模型对于特征的自学习能力启发,本文对 CNN 模型的池化层进行改进,将参数引入池化层,使用参数池化(parameterized pooling)来替代传统的

池化过程.此过程依赖于向池化层中加入参数,依靠这些参数让 CNN 选择最优的池化方法.由于向池化层增加了参数,池化层能够选取最优特征,减少了池化过程中的信息损失,同时影响了网络的前向推断过程,使得反向传播过程有所改变.本文方法与传统的 CNN 模型,以及部分基于传统 CNN 改进的模型进行比较,在 Cifar-10 数据集上的实验验证了该模型的有效性。

2 传统 CNN

2.1 CNN 的基本结构

传统经典的 CNN 一般由输入层以及若干个卷积层、池化层和全连接层交替堆叠组成,其结构如图 1 所示。

从输入层将一图像送入卷积神经网络,图像会被进行若干次的卷积、激活和池化操作.在本文中,将由一个卷积层、激活层和池化层堆叠组成的单位称为一个卷积运算单元.卷积神经网络中最为关键的卷积网络部分就是由若干个卷积运算单元堆叠组成的.CNN 的最后部分是一层或者多层全连接人工神经网络,此网络的输出作为分类器的输入,由分类器输出最后的分类结果.常用的分类器有 softmax^[11], SVM^[12], Adaboost 及其改进方法^[13].由图像得到分类结果的过程称为 CNN 的前向推断过程,此过程实质是根据 CNN 中的权重参数计算得到分类预测结果的过程.CNN 中的权重参数一开始是随机的,在训练过程中,会计算预测结果和真实分类之间的差距,采用梯度下降等优化算法逐层反向调节网络中的权重参数。




图1 卷积神经网络的基本结构

2.2 卷积层的前向传播

CNN 核心原理是上述的卷积运算单元,主要涉及到卷积运算、激活操作和池化操作.假设网络的第 l 层是卷积层,则其计算公式可以用式(1)表示。

$$z_j^l = \sum_{i \in M_j} x_i^{l-1} * w_{ij}^l + b_j^l \quad (1)$$

其中, z 表示该层的带权输出, x 是该层的输入(即上一层的输出), $*$ 表示卷积运算, w 表示卷积核的权重参数, b 是该卷积层的偏置参数.该输出并不会直接作为池化层的输入,而是经过激活之后再行池化操作.其中,激活输出 a 的计算方式如式(2).经过激活的输出经过池化降维,作为该卷积运算单元的最终输出,该过程的计算方式如式(3)。

$$a_j^l(i, j) = f(z_j^l(i, j)) \quad (2)$$

$$o_c^l = D(a_j^l) \quad (3)$$

其中, $f(\cdot)$ 表示激活函数, $D(\cdot)$ 表示池化方法函数。

2.3 卷积层的反向传播

经过若干个卷积运算单元以及全连接层,图像最终的预测输出和真实分类之间的差距使用损失函数 C 来度量,那么最后一层的误差 δ 可以使用损失函数与最终预测输出的梯度表示。

$$\delta_j^l = \frac{\partial C}{\partial a_j^l} \sigma'(z_j^l) \quad (4)$$

其中, σ' 表示激活函数的导数, z 是该层的带权输出.随后,该误差会随着反向传播算法,沿着网络反向逐渐传播,这其中主要包含了卷积层误差和池化层误差的

传播.

(1) 卷积层误差的反向传播

假设第 l 层是卷积层,该卷积层向其上层传递的误差为 δ^{l-1} ,其计算公式如式(5).

$$\delta^{l-1} = \delta^l * \text{rot}(w^l) \cdot \sigma'(z^{l-1}) \quad (5)$$

其中,rot 实现将矩阵翻转 180 度的操作; z^{l-1} 表示前一层的带权输出,是一个已知量.

(2) 池化层误差的反向传播

假设第 l 层是池化层,则该层向上一层传播的误差 δ^{l-1} 可以由式(6)计算.

$$\delta^{l-1} = U(\delta^l) \odot \sigma'(z^{l-1}) \quad (6)$$

其中, U 表示上采样函数, \odot 表示哈马达(Hadamard)积.

(3) 误差与权重和偏置的导数

计算出每一层的误差之后,损失函数对于每一个权重 w 和偏置 b 的梯度可以通过式(7)、式(8)计算得出.

$$\frac{\partial C}{\partial w_{jk}^l} = a_k^{l-1} \cdot \delta_j^l \quad (7)$$

$$\frac{\partial C}{\partial b_j^l} = \delta_j^l \quad (8)$$

随后可以用相应的优化算法来更新权重和偏置参数.需要注意的是,传统卷积神经网络的池化层中没有参数,因此只需要反向传递误差而不需要计算梯度.

3 PPCNN 的提出

3.1 PPCNN 结构

由于传统 CNN 的池化层会造成信息损失,通过改进池化层可以提高特征的利用率,进而提高网络性能.对传统的 CNN 中的池化层进行改进,提出参数池化(parameterized pooling)方法和 PPCNN 网络模型.改进的 PPCNN 模型结构如图 2 所示.




图2 PPCNN网络结构示意图

PPCNN 对池化层做出了改进,将传统的池化层使用参数池化层替代.原始输入经过卷积层和激活层后送入参数池化层.由于参数池化层带有少量参数,因此能够让 PPCNN 模型自主的选择池化方式,从而最大化的保留了特征信息,减小了网络误差,提升了网络性能.此种方法从池化的本质意义上来使用权重参数,该层权重是具有可解释性的,同时也影响该层权重的更新方法.

3.2 参数池化层

3.2.1 参数池化层计算方法

设传入参数池化层的特征图 X 宽为 W ,高为 H ,通道数为 C ,即 $W * H * C$ 的矩阵,则其输出 G 可以根据式(9)计算得出.

$$G_c(i, j) = \sum_{m=0}^p \sum_{n=0}^q X_c(i + m, j + n) \cdot \beta(W_c(m, n)) \quad (9)$$

其中, X_c 表示输入特征图的第 C 个通道, G_c 表示对应第 C 个通道的输入; W 是权重参数矩阵,其形状为 $p * q * c$, W_c 表示参数池化层权重的第 C 个通道, p, q 是池化核的长和宽. β 是预激活函数,其作用是将相关运算转换为可以解释的池化运算.本文中使用的 sigmoid 函数作为预激活函数,将权重参数的任何一个值映射到实数区间(0,1).参数池化层给特征图的每一个通道 X_c 都分配了一个参数 W_c , W_c 经过预激活函数后,每一个参数

值都被规定到了 0 和 1 之间,这也就意味着,通过参数调整,PPCNN 网络的参数池化层可以最优选择不同的池化方法,图 3 给出了参数池化方法近似于平均池化的示意图.




图3 参数池化近似于平均池化的情况

3.2.2 参数池化层的反向传播和参数更新

参数池化层赋予 PPCNN 根据需要进行池化方式的能力,权重参数的加入、池化计算方式的改变影响了参数池化层参数的更新方法和反向误差的计算,该层反向传递的误差不能按照式(6)来计算,同时还需要重新考虑该层权重的更新方法.

(1) 参数池化层的反向传播误差

设第 l 层为参数池化层, δ^l 为其误差,则该层向上一层传递的误差 δ^{l-1} 为

$$\delta_c^{l-1} = \frac{\partial C}{\partial G_c^l} \frac{\partial G_c^l}{\partial X_c^l}$$

其中, $\frac{\partial C}{\partial G_c^l} = \delta_c^l$,带入式(9),可得参数池化层的反向传播

误差公式.

$$\delta_c^{l-1} = \sum_{m=0}^p \sum_{n=0}^q \delta_c^l(i+m, j+n) \cdot \beta(w_c(p-m, q-n)) \quad (10)$$

其中,下标 c 表示计算对应特征图的第 c 个通道, β 表示预激活函数, w 是权重参数.

(2) 参数池化层的权重更新公式

使用优化算法对参数池化层的权重参数进行更新,其核心是要求出该层参数对于损失函数 C 的梯度. 设第 l 层为参数池化层,该层参数对于 C 的梯度为

$$\frac{\partial C}{\partial w_c^l} = \frac{\partial C}{\partial G_c^l} \frac{\partial G_c^l}{\partial w_c^l}$$

同样,将 G_c^l 用式(9)带入,最终可得式(11),即参数池化层权重对于损失 C 的梯度.

$$\frac{\partial C}{\partial w_c^l(p, q)} = \sum_i \sum_j (\delta_c^l(i, j) \cdot x_c^l(i+p, j+q)) \cdot \beta'(w_c^l(p, q)) \quad (11)$$

其中, x_c^l 是该层的输入.

假设使用梯度下降法优化权重,那么更新公式为

$$w_c^{l, \text{new}} = w_c^{l, \text{old}} - \eta \frac{\partial C}{\partial w_c^{l, \text{old}}}$$

本文改进的池化层直接影响了池化的计算方式,从而改变了池化层的反向传播过程,同时补充了参数池化层的参数更新方法,进而影响了整个 PPCNN 模型的性能.

4 实验结果与分析

本文实验基于当下流行的 tensorflow 深度学习库进行,使用 Windows 10 操作系统,实验服务器搭载了 3 块 NVIDIA GTX1080TI 显卡(单个实验在 1 块显卡上即可完成,多块显卡用于加速). 实验中,本文提出的 CNN 模型与传统的 CNN 模型以及基于传统 CNN 模型改进的一些模型对比,所有模型的卷积层以及卷积核数量都是相等的,且具有相同数量的全连接层. 对于不同的模型其池化层可能采用不同的处理,或者卷积核的深度有所变化,但模型总体层数和基本架构均不变.

4.1 基本实验网络结构

本文实验数据集使用的是 Cifar-10 公共数据集. Cifar-10 数据集共有 60000 张长宽均为 32 像素的图像,一共分为 10 类,其中 50000 张用于训练使用,10000 张用作网络性能测试. 对于该数据集,本文实验通过搭建不同网络模型的 3 层简单模型作为本文实验的基本实验网络,以此来验证 PPCNN 网络模型的有效性,与之对比的分别是传统的 Plain-CNN 模型, Supplement-CNN 模型^[14] 以及 All-CNN^[15] 模型,各模型主要层参数配置如表 1 所示.

表 1 对比模型主要参数设置

网络模型	层名称	层参数	参数数量
Plain-CNN	输入层	32 * 32 * 3	0
	卷积层 1	5 * 5 * 32	2400
	最大池化层	3 * 3@ s2	0
	卷积层 2	5 * 5 * 32	25600
	最大池化层	3 * 3@ s2	0
	卷积层 3	5 * 5 * 64	51200
	最大池化层	3 * 3@ s2	0
Supplement-CNN	输入层	32 * 32 * 3	0
	卷积层 1	5 * 5 * 32	2400
	最大池化层	3 * 3@ s2	0
	卷积层 2	5 * 5 * 32	51200
	最大池化层	3 * 3@ s2	0
	卷积层 3	5 * 5 * 64	102400
	最大池化层	3 * 3@ 2	0
All-CNN	输入层	32 * 32 * 3	0
	卷积层 1	5 * 5 * 32	2400
	卷积层 2	3 * 3@ s2	9216
	卷积层 3	5 * 5 * 32	25600
	卷积层 4	3 * 3@ s2	9216
	卷积层 5	5 * 5 * 64	51200
	卷积层 6	3 * 3@ s2	36864
PPCNN	输入层	32 * 32 * 3	0
	卷积层 1	5 * 5 * 32	2400
	参数池化层	3 * 3@ s2	288
	卷积层 2	5 * 5 * 32	25600
	参数池化层	3 * 3@ s2	288
	卷积层 3	5 * 5 * 64	51200
	参数池化层	3 * 3@ s2	576

所有模型最后都是一个全连接层和 softmax 分类器,在此没有列出;“@ s2”表示卷积/池化的步幅为 2,未标明则表示步幅默认为 1. Plain-CNN 和 Supplement-CNN 中,所有卷积操作都维持输入的大小,池化操作则未保持输入大小;All-CNN 中,卷积层 2、4、6 实际上用于替代传统 CNN 中的池化层,因此也没有保持输入大小,且步幅为 2. 另外,所有卷积层、全连接层激活函数均为 leaky-relu.

4.2 实验结果分析

在目标实验平台上,使用表 1 中的 CNN 及其参数作为基准实验对比. 为了更加清楚的观察网络的收敛情况,每个网络模型都进行 400 次的迭代训练,每一批

次训练后使用测试集测试网络模型的分​​类精度,最终得到 Cifar-10 数据集上的实验结果如图 4 所示。

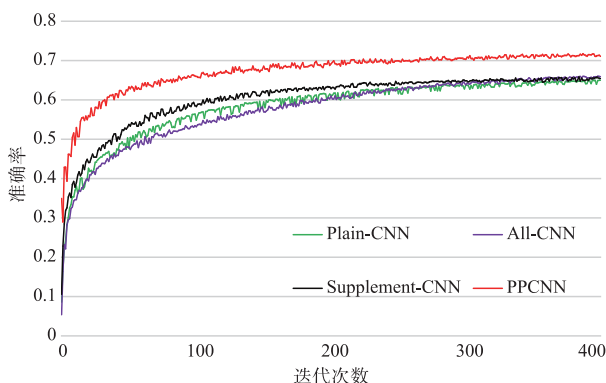


图4 Cifar10 基础网络架构下准确率变化

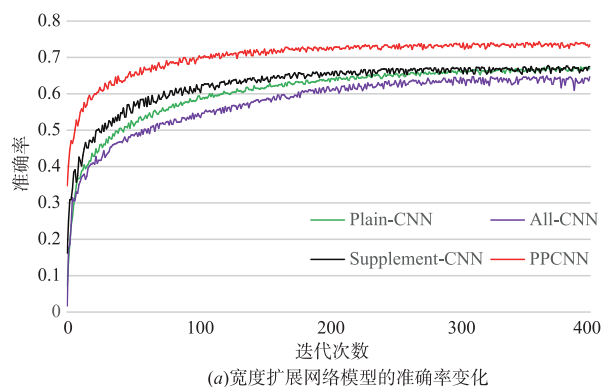
在 Cifar10 数据集上,本文提出 PPCNN 网络稳定后(第 350 至 400 次迭代)的平均准确率为 71.3%,其余网络模型平均准确率为 65.1% ~ 66.1%。从精度变化曲线上也可以看出,PPCNN 模型的收敛速度也要快于其他对比网络。

对表 1 所示的基准实验网络模型在宽度和深度上进行扩展.将基准实验网络模型各卷积层的卷积核数量增加一倍,得到宽度扩展网络模型;在基准实验网络模型的最后一层增加一个 $3 \times 3 \times 128$ 的卷积层以及对应的池化层,得到深度扩展网络模型.在扩展网络模型上的实验结果如图 5 所示。

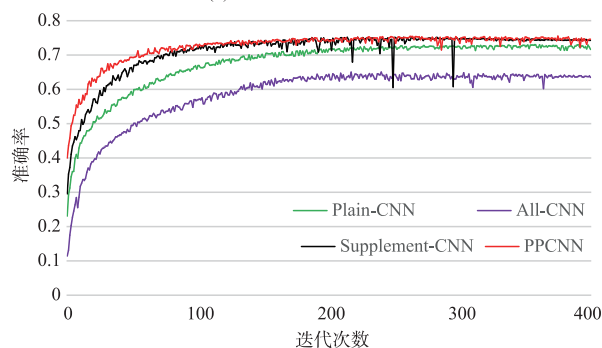
经过宽度扩展的网络模型,Plain-CNN 平均准确率达到了 66.7%,Supplement-CNN 平均准确率达到 67% 左右,PPCNN 平均准确率达到了 73.5%,而 All-CNN 出现了过拟合现象,导致没有达到理想的分类效果.对网络的深度进行扩展之后,Plain-CNN 平均准确率到达 72.5%,Supplement-CNN 为 74.4%,PPCNN 为 74.6%。该实验结果表明,网络模型加宽带来网络模型参数量的上升,对分类性能的提升有一定的作用,但加深网络对网络模型性能的提升更加明显。

虽然在网络模型深度增加后,Supplement-CNN 与 PPCNN 的平均准确率到达了相近的水平,但由图 5(b) 可见,PPCNN 较 Supplement-CNN 收敛更快,稳定性更高.且考虑到前者几乎比后者多 1 倍的参数量,故 PPCNN 仍然具有一定优势. All-CNN 使用卷积层来替换池化层,并不能很好的解释池化本身的含义,网络加宽、加深的同时也导致网络模型的参数量剧增,网络复杂度上升.最终导致训练难度加大,极易陷入局部最优解.各个网络模型的平均准确率、最高准确率对比如表 2。

实验结果表明,使用参数池化方法的卷积神经网络在增加极少量参数的情况下能够较大提升网络模型



(a)宽度扩展网络模型的准确率变化



(b)深度扩展网络模型的准确率变化

图5 扩展网络模型上的准确率变化

性能.相较于对网络的宽度进行扩展,对网络深度进行扩展带来的影响较小.这是因为在网络中较深层的神经元具有较大的感受野,而在较大感受野的尺度上,池化操作带来的信息损失不是那么明显.但是,增加网络深度就意味着更多的参数和更长的传播链,这不利于提升网络效率,过深的网络也容易造成过拟合,这也增大了网络调试、应用的难度.因此尽管参数池化对深层网络的影响较小,但对于浅层快速网络仍然具有现实意义,是提高网络效率的有效方法。

表 2 对比模型主要参数设置

模型类型	模型结构	平均准确率	最高准确率
基本实验网络	Plain-CNN	64.5%	65.2%
	All-CNN	65.6%	66.1%
	Supplement-CNN	65.2%	65.8%
	PPCNN	71.3%	71.8%
宽度扩展网络	Plain-CNN	66.7%	67.4%
	All-CNN	63.9%	64.9%
	Supplement-CNN	66.8%	67.8%
	PPCNN	73.5%	74.3%
深度扩展网络	Plain-CNN	72.5%	73.0%
	All-CNN	63.7%	64.3%
	Supplement-CNN	74.4%	74.7%
	PPCNN	74.6%	75.5%

5 结论

本文提出一种新的池化方式——参数池化,并将其运用到 CNN 中. 使用参数池化层的 CNN 与以往 CNN 模型相比,该模型尽可能的保留了特征图信息,减少了信息损失,提升了模型性能. 由于在池化层引入了参数,因此影响了该模型的前向传播和反向传播过程. 在 Cifar10 数据集上的实验表明,PPCNN 相比于传统 CNN 具有一定优越性. 为验证 PPCNN 的稳定性和普适性,采用“加宽”(增加卷积核数量)和“加深”(增加网络深度)的对比实验进行验证,证明了该模型具有运用到各种卷积神经网络模型中的前景. 本文中的参数池化方法是通过解释降采样的本意得来,预激活函数是为了建立从一般权重参数到降采样参数之间的转换,目前可用 sigmoid 和 softmax. 在下一步的研究中,还需要从池化的本质出发,寻找更加合适、更具有解释性的预激活函数;同时研究该池化方法运用到大型网络结构中.


参考文献

- [1] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[A]. International Conference on Neural Information Processing Systems[C]. USA: Curran Associates Inc, 2012. 1097 – 1105.
- [2] Simonyan, Karen, Zisserman, Andrew. Very deep convolutional networks for large-scale image recognition[J]. Computer Vision and Pattern Recognition, 2014, arXiv: 1409.1556.
- [3] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[A]. Proc of the IEEE Conf on Computer Vision and Pattern Recognition[C]. Piscataway, NJ: IEEE, 2015. 1 – 9.
- [4] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. USA: IEEE, 2016. 770 – 778.
- [5] Howard A G, Zhu M, Chen B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications [A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. Honolulu, Hawaii: IEEE, 2017. 1 – 14.
- [6] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5 MB model size [A]. International Conference on Learning Representations [C]. Toulon, France: ICLR, 2017. 1 – 9.
- [7] He K, Zhang X, Ren S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9): 1904 – 1916.
- [8] Yue K, Xu F, Yu J. Shallow and wide fractional max-pooling network for image classification[J]. Neural Computing & Applications, 2017(5): 1 – 11.
- [9] Lee C Y, Gallagher P, Tu Z. Generalizing pooling functions in CNNs: Mixed, gated, and tree[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2018, 40(4): 863 – 875.
- [10] 罗畅, 王洁, 王鹏飞, 等. 卷积自编码器中粗粒度池化特征提取研究[J]. 电子学报, 2017, 45(10): 2390 – 2401. LUO Chang, WANG Jie, WANG Peng-fei, et al. Coarse-grained pooled features learning in convolutional autoencoders[J]. Acta Electronica Sinica, 2017, 45(10): 2390 – 2401. (in Chinese)
- [11] Memisevic R, Zach C, Hinton G E, et al. Gated softmax classification[A]. Advances in Neural Information Processing Systems[C]. Columbia, Canada: ACM, 2010. 1603 – 1611.
- [12] Routray S, Ray A K, Mishra C, et al. Efficient hybrid image denoising scheme based on SVM classification [J]. Optik, 2018, 157: 503 – 511.
- [13] Lee S J, Chen T, Yu L, et al. Image classification based on the boost convolutional neural network[J]. IEEE Access, 2018, 99(6): 12755 – 12768.
- [14] 王强, 李孝杰, 陈俊. Supplement 卷积神经网络的图像分类方法[J]. 计算机辅助设计与图形学学报, 2018, (3): 385 – 391. WANG Qiang, LI Xiao-jie, CHEN Jun. Image classification method based on supplement convolutional neural network[J]. Journal of Computer-Aided Design & Computer Graphics, 2018, (3): 385 – 391. (in Chinese)
- [15] Springenberg J T, Dosovitskiy A, Brox T, et al. Striving for Simplicity: The All Convolutional Net[J/OL]. <https://ui.adsabs.harvard.edu/abs/2014arXiv1412.6806S/abstract>, 2014/2019-04-06.

作者简介



江泽涛 男, 1961 年 3 月出生, 江西九江人. 桂林电子科技大学教授, 博士生导师, 主要从事图像处理、计算机视觉、信息安全方面的研究.



秦嘉奇 (通讯作者) 男, 1993 年 11 月出生, 广西桂林人. 桂林电子科技大学硕士研究生. 现为桂林电子科技大学信息科技学院教师, 主要从事计算机视觉、图像理解方面的研究. E-mail: 1445155606@qq.com