

基于卷积神经网络的砂石骨料分类方法研究

鄢然^{*}, 廖记登, 吴小勇, 谢长江, 夏磊

重庆理工大学机械工程学院, 重庆 400054

摘要 针对目前在检测商用砂石骨料的过程中,人工检测的效率低下且受到主观因素的影响较大以及检测的准确率不理想,提出一种基于卷积神经网络(Convolutional Neural Network,CNN)的砂石骨料图像分类模型 CNN13.该分类模型参考经典卷积神经网络 VGG16(Visual Geometry Group 16)模型进行网络结构的改进和参数优化,利用 TensorFlow 深度学习框架搭建一个 13 层的卷积神经网络结构。实验数据集采集于某商用混凝土生产企业日常生产中的砂石骨料,共 5000 幅数字图像,模型在训练过程中采用 GPU 进行高速计算。相比于 VGG16 模型,CNN13 模型的卷积层和参数量较少,对 GPU 内存的要求更低,训练速度更快,分类的准确率更高,每个等级的砂石骨料的分类准确率都达到 99%以上。

关键词 图像处理;卷积神经网络;砂石骨料;图像分类;高速计算

中图分类号 TP317.4

文献标志码 A

doi: 10.3788/LOP202158.2010015

Research on Classification Method of Sand and Gravel Aggregate Based on Convolutional Neural Network

Yan Ran^{*}, Liao Jideng, Wu Xiaoyong, Xie Changjiang, Xia Lei

School of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China

Abstract In the current process of detecting commercial sand and gravel aggregates, the manual detection is inefficient, greatly affected by subjective factors, and the detection accuracy is not ideal. This paper proposes a convolutional neural network (CNN) based on the sand and gravel aggregate image classification model (CNN13). This classification model refers to the classic CNN visual geometry group 16 (VGG16) model to improve the network structure and optimize parameters. The CNN13 model uses the TensorFlow deep learning framework to build a 13-layer CNN structure. The experimental dataset includes 5000 digital images, which is collected from the sand and gravel aggregates in the daily production of a commercial concrete manufacturer. The model uses GPU for high-speed calculation during the training process. Compared with the VGG16 model, the CNN13 model has fewer convolutional layers and parameters, lower requirements for GPU memory, faster training speed, higher classification accuracy, and classification accuracy for each level of sand and gravel aggregates is more than 99%.

Key words image processing; convolution neural network; sand and gravel aggregate; image classification; high speed calculation

OCIS codes 100.4996; 100.3008; 100.2000

1 引言

混凝土是常用的建筑材料之一,主要由水泥和砂石骨料组成,其中砂石骨料是混凝土组成材料中

用量最多的材料。目前,在商用混凝土生产企业中对砂石骨料的检测^[1]大多采用的是人工检测的方式,然而人工检测不仅会受到人为因素的影响且检测标准不统一,使得检测效率低下。目前,国内的一

收稿日期: 2020-11-28; 修回日期: 2020-12-23; 录用日期: 2021-01-11

基金项目: 重庆市教育委员会科学技术研究项目(KJQN201801118)

通信作者: *yanran@cqut.edu.cn

些研究机构和企业利用数字图像处理技术^[2-3]和机器视觉技术对砂石骨料进行检测^[4-6]。李旭^[7]利用图像处理技术对混凝土粗骨料的长宽比系数进行提取,从而达到对混凝土粗骨料检测的目的。刘春等^[8]利用数字图像处理技术分割出了岩石颗粒与孔隙,从而提取岩石颗粒的轮廓信息,这对砂石骨料的检测具有借鉴意义。

然而数字图像处理技术对光照环境具有很强的敏感性,实际上混凝土的生产过程和环境比较复杂且光照不稳定,所以单纯的数字图像处理技术并不能很好地直接投入实际生产,仅仅适用于实验环境。卷积神经网络(CNN)^[9-12]因其具有权值共享和局部视野的特点,所以具有很强的鲁棒性,广泛应用于图像识别,特别是在图像分类^[13-14]、目标检测^[15]和预测结果^[16]。Zhang 等^[17]利用改进的卷积神经网络对汽车软管表面上的缺陷进行分类,分类的准确率达到 96% 以上。Ye 等^[18]通过优化 VGG16 (Visual Geometry Group 16) 和 VGG19 中完整连接层的数量,使得蔬菜害虫图像的识别准确率得到了有效提高。Hsu 等^[19]提出了一种集成卷积神经网络 (ECNN) 的框架,该框架对常见的晶圆仓图 (WBM) 中的缺陷模式可以获得很好的识别效果。Wang 等^[20]提出了一种深度多尺度卷积神经网络 (DMCNN),在检测网络入侵方面相比于传统网络具有较高的检测准确率。程国建等^[21]通过卷积神经网络模型实现了岩石薄片图像特征的自动提取,该模型基于岩石薄片图像可以获得高效且可靠的自动分类结果。

本文参考经典的 VGG16 模型^[22]并综合分析砂石骨料的特点,设计和搭建一个全新的由 10 层卷积层和三层全连接层组成的 13 层卷积神经网络模型 CNN13,通过优化卷积层的数量和参数并以某商用混凝土生产企业的砂石骨料图像为数据集,在 GPU 上分别对 CNN13 模型和 VGG16 模型进行高速训练实验。实验结果表明,相比于 VGG16 模型, CNN13 模型可以减少内存消耗以及加快训练时间,收敛更快也更稳定,同时能够大幅度提高砂石骨料识别的准确率和可靠性。

2 卷积神经网络

卷积神经网络是一种可以自动从数据库中学习并更新权重参数的模型,其是深度学习的代表模型之一。卷积神经网络由输入层、隐藏层和输出层组成,而权重参数“隐藏”在隐藏层中,隐藏层的数量越

多则表明深度学习的深度越深。卷积神经网络具有局部视野和权值共享的特点,在图像分类中具有很强的鲁棒性,能够对复杂的图像进行分类,而且因其结构简单且应用性强,广泛用于解决图像分类的问题。

卷积神经网络 VGGNet 由牛津大学的视觉几何组开发,其由多个卷积层和全连接层组成。根据层的深度,VGGNet 可以分为 VGG16 和 VGG19。VGGNet 具有结构简单、应用性强和识别率高的特点,是一种常用的深度学习经典模型,在比较模型性能的方面具有很好的对比意义。

VGG 的卷积层中使用的是 3×3 的小型滤波器,首先利用连续卷积操作来提取局部特征,然后利用池化操作进行降采样,最后由全连接层输出结果。

2.1 卷积神经网络的基本结构

2.1.1 卷积层

对于输入图像数据,卷积运算是指滤波器按一定的步幅滑动进行计算,即滤波器中的各个元素与相对应的输入图像数据中的各个元素(像素值)相乘,然后求和并将结果输出到对应位置。当输入图像数据在所有位置上都完成一次滑动计算时,即完成一次卷积运算。在相同的卷积神经网络中,滤波器越小,则参数量就越少。使用 5×5 的滤波器进行卷积运算的参数量有 $5 \times 5 = 25$ 个,使用 3×3 的滤波器进行两次卷积运算的参数量有 $2 \times 3 \times 3 = 18$ 个,因此在卷积神经网络中尽可能加深卷积层的深度(数量)以及使用小型滤波器。

2.1.2 池化层

池化是缩小长、高方向上的空间的运算,从而达到降采样的目的,而池化计算即是在滤波器中选择最大值或者平均值作为输出值。池化对输入图像数据的偏差具有很高的鲁棒性,当输入图像数据发生微小偏差时,池化仍会返回与没有发生偏差的结果相同。最大池化运算过程如图 1 所示。当在 2×2 的滤波器(虚线矩形框)中进行池化运算时,该滤波器中的最大值为 2,输出即为 2,以此类推。




图 1 最大池化运算的过程

Fig. 1 Process of maximum pooling calculation

2.1.3 激活函数

每次卷积运算都使用 Relu(Rectified Linear Units) 函数进行激活,当 Relu 函数的输入大于 0 时,直接输出该值,当输入不大于 0 时,输出为 0,可表示为

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases}, \quad (1)$$

式中: x 表示输入信号; $f(x)$ 表示输出信号。

2.1.4 输出层

卷积神经网络中使用 Softmax 函数作为输出函数来解决分类问题,当 Softmax 函数用于分类时,其输入的种类与对应的标签经过卷积神经网络多次迭代后输出映射到(0,1)区间,可以看作某一种类对应标签的概率,因此整个 Softmax 层的输出相

加结果为 1。Softmax 函数作为输出函数,则输出信号可表示为

$$y_k = \frac{\exp(a_k)}{\sum_{i=1}^n \exp(a_i)}, \quad (2)$$

式中: y_k 表示第 k 个神经元的输出信号; a_k 表示第 k 个神经元的输入信号; a_i 表示第 i 个神经元的输入信号; n 表示输入神经元的总数量。

2.2 卷积网络结构

本文参考 VGG16 并对其进行优化,设计一种基于 TensorFlow 深度学习框架的 13 层卷积神经网络(CNN13),其由 10 层卷积层和三层全连接(FC)层组成,该网络的结构设计如图 2 所示。




图 2 CNN13 的结构

Fig. 2 Structure of CNN13

卷积神经网络 CNN13 中各层网络层的设计如下。

1) 输入图像是经过预处理的单通道灰度图(分辨率为 $384 \text{ pixel} \times 275 \text{ pixel}$)。

2) 卷积层使用 3×3 的滤波器,步长为 1,边界填充的像素值为 0。每次卷积运算的输出特征尺寸不变,数量为该层滤波器的数量。

3) 池化层采用最大池化法进行处理,使用 2×2 的滤波器,步长为 2,边界填充的像素值为 0。每次池化运算的输出特征尺寸为输入特征的 $1/2$,数量不变。

4) 全连接层使用 1024 个参数。

CNN13 中各个网络层的参数设置如表 1 所示。

表 1 CNN13 中各个网络层的参数设置

Table 1 Parameter settings of each network layer in CNN13

Network layer	Input	Filter	Output
Input	$384 \times 275 \times 1$		$384 \times 275 \times 1$
conv 1-64	$384 \times 275 \times 1$	$3 \times 3 \times 64$	$384 \times 275 \times 64$
maxpooling 1	$384 \times 275 \times 64$	2×2	$192 \times 138 \times 64$

表 1(续)

Network layer	Input	Filter	Output
conv 2-128	192×138×64	3×3×128	192×138×128
maxpooling 2	192×138×128	2×2	96×69×128
conv 3-256	96×69×128	3×3×256	96×69×256
conv 4-256	96×69×256	3×3×256	96×69×256
maxpooling 3	96×69×256	2×2	48×35×256
conv 5-512	48×35×256	3×3×512	48×35×512
conv 6-512	48×35×512	3×3×512	48×35×512
maxpooling 4	48×35×512	2×2	24×18×512
conv 7-512	24×18×512	3×3×512	24×18×512
conv 8-512	24×18×512	3×3×512	24×18×512
maxpooling 5	24×18×512	2×2	12×9×512
conv 9-512	12×9×512	3×3×512	12×9×512
conv 10-512	12×9×512	3×3×512	12×9×512
maxpooling 6	12×9×512	2×2	6×5×512
FC 1-1024	6×5×512		1024
FC 2-1024	1024		1024
FC 3-1024	1024		1024

CNN13 采用反向传播的方式对权重参数进行更新,每个网络层使用非饱和线性激活函数 Relu 进行激活,使用神经元随机删除的方法随机删除全连接层的参数以防止网络过拟合,使用自适应矩估计优化器对整个网络进行优化,由 Softmax 函数输出分类结果。

3 混凝土骨料的分类

通过查阅某商用混凝土生产企业的砂石骨料分类标准和具体分类细则,对不同等级的砂石骨料进行随机图像采集以获取数据集。

3.1 砂石骨料的分类标准

按照某商用混凝土生产企业的砂石骨料生产标准进行分类,砂石骨料的重要指标为粒径尺寸和粒形组成含量。合格砂石骨料的粒径分布在 10~25 mm;骨料的粒形以整形(正方体或者圆形)为主,针片状含量越少越好。砂石骨料一共分为 5 个等级,每个等级具体的分类标准如表 2 所示。

3.2 砂石骨料数据

随机对生产使用中的混凝土骨料进行图像采样,每个等级采集 1000 幅数字图像,总共采集 5000 幅数字图像。将每个等级的数字图像分为训练集和测试集,分配比例为 8:2,即使用 800 幅数字图像作为训练集,200 幅数字图像作为测试集。图像数据集

表 2 砂石骨料的分类标准

Table 2 Classification standard of sand and gravel aggregate

Grade	Particle size /mm	Mass fraction /%	
		Needle and flake(Q)	Round or square(P)
1	10-15	$0 \leq Q \leq 2$	$98 < P \leq 100$
2	10-20	$2 \leq Q \leq 5$	$95 < P \leq 98$
3	10-25	$5 \leq Q \leq 10$	$90 < P \leq 95$
4	10-25	$10 \leq Q \leq 20$	$80 < P \leq 90$
5	10-25	$20 \leq Q \leq 30$	$70 < P \leq 80$

包含了不同生产环境中的砂石骨料,包括表面干燥和表面潮湿的砂石骨料,如图 3 所示,各个等级的砂石骨料如图 4 所示。




图 3 砂石骨料示意图。(a)表面干燥的砂石骨料;
(b)表面湿润的砂石骨料

Fig. 3 Schematic of sand and gravel aggregate. (a) Sand and gravel aggregate with dry surface; (b) sand and gravel aggregate with wet surface




图 4 各个等级的砂石骨料示意图。(a)第一级;(b)第二级;(c)第三级;(d)第四级;(e)第五级

Fig. 4 Schematic of all grades of sand and gravel aggregate. (a) 1st level; (b) 2nd level; (c) 3rd level; (d) 4th level; (e) 5th level

3.3 砂石骨料数据的预处理

对采集到的数字图像采用双线性插值的方法进行预处理,将原始图像的宽和高压缩至原图像的 10%,处理前与处理后的图像数据如表 3 所示。

表 3 原始图像预处理前后的对比

Table 3 Comparison of original image before and after preprocessing

Image	Size /MB	Width /pixel	Height /pixel
Original image	10.00	3840	2748
Processed image	0.10	384	275

数字图像同时在宽和高的方向上进行双线性插值运算后,保留了原始数字图像上的特征,同时数字图像所占的内存也有效减少,因此预处理后的卷积计算和处理速度可以得到大幅度提升,并且对显存的需求也降低了。

4 实验过程及结果

实验过程中所采用的硬件平台参数:CPU 为 Inter Corei5-9400;GPU 为 NVIDIA GeForce GTX 1660 Ti,内存为 6 G。在计算过程中使用 GPU 硬件并调用深度学习库 (cuDNN) 进行深度学习计算,极大地提高了计算速度。

本文使用 CNN13 和 VGG16 两种卷积神经网络进行对比实验,训练过程中多次设置不同的超参数进行训练。

其他超参数设置:训练步幅设为 10000,全部图像参与 65 轮训练;每 25 步保存一次损失函数值、准确率和步幅。

4.1 损失函数对比

CNN13 模型和 VGG16 模型的损失函数变化曲线如图 5 所示。从图 5 可以看到,两种模型的损失函数曲线都在训练几百步之后快速收敛至一点几,但是 CNN13 模型的损失函数曲线的下降梯度比 VGG16 模型大很多。




图 5 CNN13 模型和 VGG16 模型的损失函数对比曲线

Fig. 5 Comparison curves of loss function between CNN13 model and VGG16 model

CNN13 模型的损失函数曲线的收敛速度较快且波动范围较小,在训练初期极速下降,然后在小范围内波动,最后逐渐收敛至 0。在训练 4000 步即数据集迭代 26 轮后,损失函数值收敛至 0。模型继续训练,即使损失函数曲线出现较小范围的波动,但损失函数值最终收敛于 0。

VGG16 模型的损失函数曲线的收敛速度较慢且波动范围较大,在训练 6000 步即数据集迭代 39 轮后,损失函数值才逐渐收敛至 0。模型继续训练,损失函数曲线出现小范围的波动,损失函数值最终收敛于 0。

4.2 准确率对比

CNN13 模型与 VGG16 模型的准确率如图 6 所示。CNN13 模型的准确率曲线在训练过程中呈小范围的波动,逐渐收敛于 1,在训练 4000 步即数据集迭代 26 轮后收敛至 1。模型继续训练,CNN13 模型的准确率曲线虽然出现小范围的波动,但仍始




图 6 CNN13 模型和 VGG16 模型的准确率对比曲线

Fig. 6 Comparison curves of accuracy between CNN13 model and VGG16 model

表 4 CNN13 模型与 VGG16 模型的内存消耗对比

Tabel 4 Comparison of memory consumption between CNN13 model and VGG16 model

Model	Number of convolution layers	Total parameters	Model memory /MB	Output memory /MB	Maximum batchsize
CNN13	13	31692160	120.9	73.2	37
VGG16	16	138357544	527.8	58.1	33

卷积神经网络 CNN13 模型的训练耗时为 66 min,卷积神经网络 VGG16 模型的训练耗时为 71 min,后者比前者多耗时 5 min。

4.4 实验结果

使用测试集中的数据对已完成训练的模型进行测试。测试集一共有 5 个种类,每个种类有 200 幅图像,总共 1000 幅图像。统计模型的预测结果,每个种类的准确率如表 5 所示。

表 5 CNN13 模型和 VGG16 模型的准确率

Tabel 5 Accuracy of CNN13 model and VGG16 model

Model	Accuracy /%				
	Grade 1	Grade 2	Grade 3	Grade 4	Grade 5
CNN13	100.0	100.0	99.5	99.5	100.0
VGG16	97.5	100.0	99.5	81.0	93.0

从表 5 可以看到,CNN13 模型的预测结果中仅有第 3 类和第 4 类的预测结果错误,但是两个种类中都只有一幅图像预测错误,准确率均为 99.5%,其他种类的预测结果全部正确,准确率均为 100%;VGG16 模型的第 4 类预测结果最不理想,准确率仅

终保持在 0.9 以上。训练结束,准确率收敛于 1。

VGG16 模型的准确率曲线在训练后出现较大范围的波动,在训练 6000 步即数据集迭代 39 轮后才逐渐收敛于 1。模型继续训练,准确率曲线出现小范围的波动,甚至出现反常的波动,准确率波动下降至 0.7,训练结束后收敛于 1。

4.3 内存消耗对比

相比于 VGG16 模型,CNN13 模型使用的网络层数更少,参数总量仅有三千万左右,比 VGG16 模型少了一亿,只有 VGG16 模型的 23%,参数占用的内存消耗也逐渐减少。虽然 CNN13 模型中每个网络层的输出内存消耗比 VGG16 模型多出 15.1 MB,但在 6 G 内存的 GPU 上训练能够同时接受的数据批次提升了,CNN13 模型每次能够投入 37 个批次,VGG16 模型每次只能投入 33 个批次,说明 VGG16 模型对 GPU 内存的要求降低。两个模型的内存消耗如表 4 所示。

为 81%,说明 1000 幅图像中有 54 幅图像预测分类错误。

5 结 论

在混凝土砂石骨料的预测分类问题中,相比于 VGG16 模型,CNN13 模型的预测准确率更高、稳定性更强并且效果更好,还具有如下几个优点:1)相比于 VGG16 模型,CNN13 模型的网络层数更少,参数量更少,GPU 内存消耗更少,训练时间更短;2)在训练过程中,CNN13 模型的损失函数曲线的收敛速度比 VGG16 模型更快,波动范围更小,收敛之后更加稳定,不会出现较大范围的波动,准确率曲线同样也收敛更快,波动范围更小,收敛之后没有出现较大范围的波动;3)模型测试结果表明,CNN13 模型的分效果更好,准确率更高,1000 幅图像中仅有 2 幅图像预测分类错误,但是 VGG16 模型的准确率下降很多,1000 幅图像中有 54 幅图像预测分类错误。

本文所提出的基于 CNN13 模型的混凝土砂石骨料分类方法已成功地应用于某商用混凝土生产重

点企业并得到了全面推广,该方法在实际生产中大幅度提高了检测的准确性和稳定性,提高了生产效率,在该企业推动混凝土制造过程的全面智能化中起到了关键作用。

参 考 文 献

- [1] Zhou X G, Qin X X, Lü Y L. Quality analysis of concrete aggregates and study on grading optimization [J]. Construction Quality, 2016, 34(11): 15-20.
周新刚, 秦绪祥, 吕英林. 混凝土骨料质量统计分析及骨料级配优化研究[J]. 工程质量, 2016, 34(11): 15-20.
- [2] Rafael C G, Richard E W. Digital image processing [M]. 3rd ed. Ruan Q Q, Ruan Y Z, Transl. Beijing: Publishing House of Electronics Industry, 2010.
Rafael C G, Richard E W. 数字图像处理[M]. 第 3 版. 阮秋琦, 阮宇智, 译. 北京: 电子工业出版社, 2010.
- [3] Liu G H. HALCON digital image processing [M]. Xi'an: Xidian University Press, 2018.
刘国华. HALCON 数字图像处理[M]. 西安: 西安电子科技大学出版社, 2018.
- [4] Fang H Y, Yang J H, Huang W J, et al. A detection device and method for aggregate form quality: CN106969708A[P]. 2017-07-21.
房怀英, 杨建红, 黄文景, 等. 一种骨料形态质量的检测装置和方法: CN106969708A[P]. 2017-07-21.
- [5] Zeng B F, Yan Y P, Hu Z G. A method for measuring the mixing proportion of coarse and fine aggregate: CN106546980A[P]. 2017-03-29.
曾宝锋, 闫艺萍, 胡再国. 一种粗细骨料混合比例测量方法: CN106546980A[P]. 2017-03-29.
- [6] Yang J H, Li L N, Zhang R C, et al. Fine aggregate on-line detection device and method: CN105699258A [P]. 2016-06-22.
杨建红, 李丽娜, 张认成, 等. 一种细骨料在线检测装置及方法: CN105699258A[P]. 2016-06-22.
- [7] Li X. Study on inspection method for aspect ratio of concrete coarse aggregate based on image processing [J]. Shanxi Architecture, 2018, 44(5): 103-105.
李旭. 基于图像处理的混凝土粗骨料长宽比检测方法研究[J]. 山西建筑, 2018, 44(5): 103-105.
- [8] Liu C, Xu Q, Shi B, et al. Digital image recognition method of rock particle and pore system and its application [J]. Chinese Journal of Geotechnical Engineering, 2018, 40(5): 925-931.
刘春, 许强, 施斌, 等. 岩石颗粒与孔隙系统数字图像识别方法及应用[J]. 岩土工程学报, 2018, 40(5): 925-931.
- [9] Zhang L, Yuan F N, Zhang W R, et al. Review of fully convolutional neural network [J]. Computer Engineering and Applications, 2020, 56(1): 25-37.
章琳, 袁非牛, 张文睿, 等. 全卷积神经网络研究综述[J]. 计算机工程与应用, 2020, 56(1): 25-37.
- [10] Yu S H. Development and application of convolution neural network [J]. Information & Communications, 2019, 32(2): 39-43.
俞颂华. 卷积神经网络的发展与应用综述[J]. 信息通信, 2019, 32(2): 39-43.
- [11] Yang Z Z, Kuang N, Fan L, et al. Review of image classification algorithms based on convolutional neural networks [J]. Journal of Signal Processing, 2018, 34(12): 1474-1489.
杨真真, 匡楠, 范露, 等. 基于卷积神经网络的图像分类算法综述[J]. 信号处理, 2018, 34(12): 1474-1489.
- [12] Xu B B, Cen K T, Huang J J, et al. A survey on graph convolutional neural network [J]. Chinese Journal of Computers, 2020, 43(5): 755-780.
徐冰冰, 岑科廷, 黄俊杰, 等. 图卷积神经网络综述[J]. 计算机学报, 2020, 43(5): 755-780.
- [13] Zhang T F, Zhong S C, Lian C M, et al. Deep learning feature fusion-based retina image classification [J]. Laser & Optoelectronics Progress, 2020, 57(24): 241025.
张添福, 钟舜聪, 连超铭, 等. 基于深度学习特征融合的视网膜图像分类[J]. 激光与光电子学进展, 2020, 57(24): 241025.
- [14] Su Z B, Gao M, Li P F, et al. Digital printing defect classification algorithm based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2020, 57(24): 241011.
苏泽斌, 高敏, 李鹏飞, 等. 基于卷积神经网络的数码印花缺陷分类算法[J]. 激光与光电子学进展, 2020, 57(24): 241011.
- [15] Jiang C, Hu A M, He W. Convolutional-neural-network based license plate location algorithm [J]. Laser & Optoelectronics Progress, 2020, 57(2): 021010.
姜策, 胡岸明, 何为. 基于卷积神经网络的车牌定位算法[J]. 激光与光电子学进展, 2020, 57(2): 021010.
- [16] Liang L Y, Zhang T T, He W. Head pose estimation based on multi-scale convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(13): 131003.
梁令羽, 张天天, 何为. 多尺度卷积神经网络的头部姿态估计[J]. 激光与光电子学进展, 2019, 56(13): 131003.
- [17] Zhang Y J, Wang Z L. Surface flaw detection of industrial products based on convolutional neural

- network [J]. IOP Conference Series: Earth and Environmental Science, 2019, 252(2): 022114.
- [18] Ye H J, Han H, Zhu L N, et al. Vegetable pest image recognition method based on improved VGG convolution neural network [J]. Journal of Physics: Conference Series, 2019, 1237(3): 032018.
- [19] Hsu C Y, Chien J C. Ensemble convolutional neural networks with weighted majority for wafer bin map pattern classification [J]. Journal of Intelligent Manufacturing, 2020, 32(4): 2.
- [20] Wang X W, Yin S L, Li H, et al. A network intrusion detection method based on deep multi-scale convolutional neural network [J]. International Journal of Wireless Information Networks, 2020, 27(4): 503-517.
- [21] Cheng G J, Guo W H, Fan P Z. Study on rock image classification based on convolution neural network [J]. Journal of Xi'an Shiyou University (Natural Science Edition), 2017, 32(4): 116-122.
程国建, 郭文惠, 范鹏召. 基于卷积神经网络的岩石图像分类 [J]. 西安石油大学学报(自然科学版), 2017, 32(4): 116-122.
- [22] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [EB/OL]. (2015-04-10)[2020-07-25]. <https://arxiv.org/abs/1409.1556>.