

深度可分离卷积神经网络在自动分拣中的应用

doi:10.3969/j.issn.1674-7100.2018.06.005

何 静¹ 程 涛^{1,2}
黄良辉³ 康组超¹

1. 湖南工业大学

电气与信息工程学院

湖南 株洲 412007

2. 东莞市汇林包装有限公司

广东 东莞 523000

3. 广东南海鹰视通达科技
有限公司

广东 佛山 528200

摘 要: 针对传统的花卉分类算法在工业自动化分拣应用中出现模型参数过大、分拣精度不高的问题,提出一种基于深度学习的花卉识别算法。介绍了花卉分类算法在工业花卉包装分拣系统中的应用;根据实际需求,采用一种深度可分离卷积神经网络提取花卉特征,并详细分析了网络的模型结构;为了提高模型训练速度,提出了一种微调的模型训练方法。实验结果表明,所采用的花卉分类算法在工业花卉自动分拣的应用中相比传统算法,准确率更高、稳定性更好、应用更加广泛。

关键词: 工业自动化分拣;花卉分类;深度可分离卷积神经网络;网络微调

中图分类号: TP183

文献标志码: A

文章编号: 1674-7100(2018)06-0033-08

1 研究背景

多数的植物花卉具有观赏和药用价值,不同种类的花卉包装储藏方法各不相同,而准确地对花卉进行分类是观赏性包装和药性储藏包装的首要工作。近年来,随着工业机器人技术的发展,在许多自动化包装流水线中,大量使用机器人来完成自动分拣、包装、转运等作业^[1]。将花卉识别算法与包装机器人结合,并运用于工业自动分拣包装的作业中,不仅可以扩大包装工业的规模,还可以推动包装装备、生产过程的智能化^[2-3]。

现有一些花卉分类算法应用于花卉包装机器人,并参与到自动化的生产中,主要包括传统手工提取花卉特征的方法、基于深度学习的方法。然而提取花卉样本特征是识别分类的关键环节。文献[4]在花卉分割的基础上提取颜色、形状、纹理特征,训练分类器实现花卉分类,但是受限于分割算法的计算复杂程度。文献[5]采用超图像分割方法与方向梯度直方图(histogram of oriented gradient, HOG)结合,该方

法有效降低了算法的计算复杂度。文献[6]提出一种特征融合算法,同时兼顾了局部颜色特征和形状特征,但是其特征提取难度较大,耗费成本太高,因此也无法大规模应用在花卉包装机器人的流水线上。尽管以上方法都取得了较好的分类效果,但这类方法都为传统手工提取花卉特征的方法,模型较为复杂,主要依赖于手工提取特征。而花卉特征的设计又依赖于专业人员的设计经验,同时同种花卉在不同的开放时节呈现不同的形态,不同花卉之间又具有很小的差异,这给手工提取特征带来了极大的难度。因此该类方法存在较大的缺陷。

针对传统手工提取花卉特征的方法存在人工操作繁琐、模型复杂的问题,研究人员提出了基于深度学习的方法。利用深度卷积神经网络的自学习能力提取花卉的高层语义,获得了比传统手工提取花卉特征的方法更高的分类准确率。文献[7-8]借鉴了A. Krizhevsky等提出的AlexNet卷积神经网络^[9],在此基础上进行自适应调参,重新训练得到新的花卉分类模型。文献[10]在卷积神经网络的基础上,

收稿日期: 2018-10-09

基金项目: 国家重点研发计划基金资助项目(2018YFD0400705)

作者简介: 何 静(1971-),女,广东开平人,湖南工业大学教授,硕士生导师,主要从事机电系统故障诊断和包装工业自动化方面的研究, E-mail: hejing @ 263. net

融合传统手工特征在 Oxford-17 Flower 数据库^[11] 和 Oxford-102 Flower 数据库^[4] 进行实验,取得了较高的准确率。文献[12]使用网络层更深、网络结构更为复杂的预训练 Inception-v3^[13] 卷积神经网络,在花卉数据集上再训练,该类方法极大提高了花卉图像分类的准确率,然而此类方法都是在理想环境下的图像分类结果,虽然取得了较高的准确率,却也无法满足特定环境下的花卉分类识别。文献[14]运用 PCA (principal component analysis) 网络和显著图结合,自建小样本花卉数据集,使其更符合实际工况,取得了较高的准确率。

为满足花卉包装生产线的要求,本文提出一种基于深度可分离卷积神经网络 (MobileNet)^[15] 的花卉

包装机器人自动分拣算法。首先,介绍在工业花卉包装领域,花卉包装机器人实现多类别花卉分拣系统的流程;然后,作为花卉分拣的首要目标,重点介绍 MobileNet 的结构层次、优化方法、训练方法;最后,采集实际工况的花卉样本数据,自建数据集进行仿真实验。仿真结果表明,该算法能有效提高花卉分拣的准确率并优于其他算法,适合工业花卉包装分拣场景作业。

2 花卉包装机器人自动分拣系统

花卉包装机器人实现多类别花卉分拣系统如图 1 所示。该系统主要有机器人控制系统、传感器系统、工业摄像头、夹持器等。




图 1 花卉包装机器人的系统架构

Fig. 1 System architecture of flower packaging robot

花卉包装机器人的分拣过程实际上属于机器视觉的多类别分类问题,在工业生产流水线上,待分类的花卉为日常生产中实际花卉品种,包括菊花、蒲公英、玫瑰、向日葵、郁金香。基于机器视觉的花卉包装机器人手臂,首先通过内置工业摄像头对待分拣的花卉进行实时拍照,再结合花卉识别算法建立识别规则进行推理分类,然后向机器人控制系统发送指令,驱动夹持器和传感器系统,将推理完成后的花卉品种按包装工艺要求,个性化分拣包装或传送到下一道生产包装程序。

3 算法的设计与实现

传统的花卉识别分类算法包含了大量的手工特征提取的过程,提取过程复杂而缓慢,而基于卷积

神经网络的特征提取可以直接对原图操作,自动提取特征,但网络参数巨大,训练过程复杂。因此本研究在提取花卉图像的特征网络的选择中,采用了 MobileNet 作为特征提取网络。该网络可自动学习花卉特征,模型参数较少;再通过网络微调训练模型,能有效地提高训练速度和模型准确率。

3.1 MobileNet 特征提取网络

MobileNet 是一种高效、模型结构小、低延迟的视觉模型。由于 MobileNet 网络的深度分离卷积方法,极大地降低了模型的大小,而且同时可以达到和标准卷积近乎相同的卷积效果,因而可以和大规模特征提取模型一样用于完成图像分类、检测、分割等任务。MobileNet 核心网络为 28 层深度可分离卷积神经网络 (如表 1 所示),主要包括分离卷

积层 (Conv)、Avg Pool 层 (平均池化层)、BN (batch normalization) 归一化^[16]、ReLU 层 (rectified linear unit, 修正线性单元)^[17]。输入图像大小为 224×224 , 经过一系列的分离卷积、再通过平均池化、全连接 (full connection, FC) 和 Softmax 分类器处理, 最终输出 1 000 维特征, 作为最终 1 000 分类的计算分析结果。

表 1 MobileNet 整体框架

Table 1 MobileNet overall framework

类型 / 步长	过滤器	输入大小
Conv/s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw/s1	$3 \times 3 \times 32 \text{ dw}$	$112 \times 112 \times 32$
Conv/s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw/s2	$3 \times 3 \times 64 \text{ dw}$	$112 \times 112 \times 64$
Conv/s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw/s1	$3 \times 3 \times 128 \text{ dw}$	$56 \times 56 \times 128$
Conv/s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw/s2	$3 \times 3 \times 128 \text{ dw}$	$56 \times 56 \times 128$
Conv/s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw/s1	$3 \times 3 \times 256 \text{ dw}$	$28 \times 28 \times 256$
Conv/s1	$1 \times 1 \times 256 \times 512$	$28 \times 28 \times 256$
Conv dw/s2	$3 \times 3 \times 256 \text{ dw}$	$28 \times 28 \times 256$
Conv/s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5 × Conv dw/s1	$3 \times 3 \times 512 \text{ dw}$	$14 \times 14 \times 512$
5 × Conv/s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw/s2	$3 \times 3 \times 512 \text{ dw}$	$14 \times 14 \times 512$
Conv/s1	$1 \times 1 \times 512 \times 1\,024$	$7 \times 7 \times 512$
Conv dw/s2	$3 \times 3 \times 1\,024 \text{ dw}$	$7 \times 7 \times 1\,024$
Conv/s1	$1 \times 1 \times 1\,024 \times 1\,024$	$7 \times 7 \times 1\,024$
Avg Pool/s1	Pool 7×7	$7 \times 7 \times 1\,024$
FC/s1	$1\,024 \times 1\,000$	$1 \times 1 \times 1\,024$
Softmax/s1	Classifier	$1 \times 1 \times 1\,000$

3.1.1 分离卷积层

MobileNet 将标准的卷积过程转化为深度卷积和 1×1 的点卷积来构建整个网络, 其中深度卷积为一组二维卷积核, 每次仅处理一个通道, 在使用逐个通道卷积处理之后, 1×1 的点卷积来处理前一个输出的特征图, 将最终输出通道数变为一个指定的数量。通过以上操作, 标准卷积运算计算量为^[15]

$$D_K \times D_K \times M \times N \times D_F \times D_F; \quad (1)$$

深度可分离卷积运算计算量为

$$D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F. \quad (2)$$

式 (1) ~ (2) 中: D_K 为卷积核的大小;

M 为输入的通道个数;

N 为卷积核个数;

D_F 为输入的大小。

深度可分离卷积计算量与传统卷积计算量的比

值为:

$$\frac{D_K \times D_K \times M \times D_F \times D_F + M \times N \times D_F \times D_F}{D_K \times D_K \times M \times N \times D_F \times D_F} = \frac{1}{N} + \frac{1}{D_K^2} < 1. \quad (3)$$

由式 (1) ~ (3) 可知, 深度可分离卷积减少了大量的计算, 提高了系统的性能。

3.1.2 Avg Pool 层

Avg Pool 为常用池化操作的一种, 在 MobileNet 的特征提取中, 最终形成的特征图一般维度较高。在最终生成的特征图上固定大小的区域, 平均像素点的特征值, 将平均后的特征值代表原先的固定大小区域, 该方法能有效降低特征空间维度, 减少计算参数。

3.1.3 ReLU 层

MobileNet 用一种叫修正线性单元作为神经元的激活函数, ReLU 激活函数的形式为^[17]:

$$\text{ReLU}(x) = \begin{cases} x, & \text{if } x > 0; \\ 0, & \text{if } x \leq 0. \end{cases} \quad (4)$$

由式 (4) 可知 ReLU 函数为分段线性函数, 可实现单侧抑制。有了这单侧抑制才使得神经网络中的神经元具备了稀疏激活性。在深度神经网络模型中, 相比于其它激活函数来说, ReLU 函数有以下优势: 对于线性激活函数而言, ReLU 对神经元的抑制能力更强, 在深度网络中体现得尤为明显; 而对于非线性激活函数而言, ReLU 在非负区间的梯度为恒定值, 因此不会出现梯度消失问题, 使得模型的梯度值和收敛过程维持在一个稳定状态。

3.1.4 BN 归一化

BN 归一化是一种能够有效减少人为的超参数 (如学习率、初始参数、权重衰减系数、dropout 比例等) 调整的方法。BN 归一化还可以改变各层输入数据的分布, 使其浅层训练的微小变化不会被无限放大, 从而加快网络训练。其算法流程如下^[16]:

$$1) \text{ 数据预处理: } x' = \frac{x - E[x]}{\sqrt{\text{Var}[x]}}, \quad x \text{ 表示原始输入}$$

数据, $E[x]$ 表示一批输入训练数据的均值, $\text{Var}[x]$ 表示一批训练数据中各神经元输入值的标准差。训练过程所采用的方法为随机梯度下降算法。

2) 变换重构: $y = \gamma x' + \beta$, x' 为预处理结果, y 为变换重构结果, 引入两个可学习的参数 γ 、 β , 当且

仅当 $\gamma = \sqrt{\text{Var}[x]}$, $\beta = E[x]$ 时, 可以让网络恢复出原始数据所要学习的特征分布。

3.2 评价指标

对整个花卉包装分拣系统进行相应的评价, 构建交叉熵损失函数^[18]以及 Softmax 分类器。

3.2.1 Softmax 分类器

Softmax 分类是逻辑回归的延伸, 拥有多个类别标签, 可以应用于多类别分类的问题。假设有 n 个待训练花卉样本 $\{(x^{(1)}, y^{(1)}) (x^{(2)}, y^{(2)}) \dots (x^{(n)}, y^{(n)})\}$, $y^{(i)} \in \{1, 2, \dots, k\}$ 。利用 n 个样本对每一个样本估算出的概率值为 $p(y = j | x)$, 则 Softmax 的输出结果^[19]表示为

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)} = 1 | x^{(i)}; \theta) \\ p(y^{(i)} = 2 | x^{(i)}; \theta) \\ \dots \\ p(y^{(i)} = k | x^{(i)}; \theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \dots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix}, \quad (5)$$

式中: $\theta_1, \theta_2, \dots, \theta_k \in \mathbf{R}^{n+1}$ 为模型的训练参数;

$$\frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \text{ 为对概率进行归一化的操作。}$$

3.2.2 交叉熵损失

当对花卉分类优化时, 使用交叉熵损失函数作为代价函数。对于第 i 组样本, 假设函数表征正确的组合对数概率为

$$\begin{aligned} & I\{y^{(i)} = 1\} \log P(\hat{y}^{(i)} = 1 | x^{(i)}; \theta) + \\ & I\{y^{(i)} = 0\} \log P(\hat{y}^{(i)} = 0 | x^{(i)}; \theta) = \\ & y^{(i)} \log P(\hat{y}^{(i)} = 1 | x^{(i)}; \theta) + \\ & (1 - y^{(i)}) \log P(\hat{y}^{(i)} = 0 | x^{(i)}; \theta) = \\ & y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)})), \quad (6) \end{aligned}$$

式中 $I\{y^{(i)}=1\}$ 和 $I\{y^{(i)}=0\}$ 为示性函数, 可以理解为当 $\{\}$ 内条件成立时取 1, 否则取 0。

因此, 对于全部样本, 可以得到模型对于整体训练样本的表现能力, 如式 (7) 所示:

$$\sum_{i=1}^m y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)})). \quad (7)$$

式 (7) 为表达正确类别的概率, 其值越大, 模型对数据特征提取的能力越高。而在模型参数更新或评价模型优劣时, 需要一个能充分反映模型误差

的代价损失函数, 而且希望代价损失函数越小越好。根据这两个条件, 不妨令代价损失函数为式 (7) 的相反数^[20], 其结果如式 (8) 所示:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m y^{(i)} \log(h_{\theta}(x^{(i)})) + (1 - y^{(i)}) \log(1 - h_{\theta}(x^{(i)})). \quad (8)$$

采用梯度下降算法对权重参数层进行参数更新时, 采用链式法则求交叉熵损失函数对权重参数的偏导数, 采用反向传播的训练方法^[21]更新参数, 其参数更新的公式为

$$\omega_i^+ = \omega_i - \eta \frac{\partial E_{\text{all}}}{\partial \omega_i}, \quad (9)$$

式中: ω 为第 i 层的参数更新;

ω_i 为原始参数;

η 为学习率, 是一个超参数;

E_{all} 为该层的交叉熵损失函数之和。

3.3 网络微调

卷积神经网络对于训练数据要求非常高, 通常需要大规模的数据集才可较好地训练网络, 但在很多特定场景中, 无法获取足够多的数据去训练一个几十层的网络。本文采集的花卉数据集为实际场景下的工业包装花卉机器人需要分拣的几类花卉, 数据量较少, 这对于一个卷积神经网络的训练来说, 远达不到工业标准的要求。于是本研究采用微调的方法来解决花卉数据量不足的问题。

根据花卉分类的实际需求, 对 MobileNet 网络微调分为以下几个过程:

1) 在大型数据库 ImageNet^[22]上完成对 MobileNet 的 1 000 分类的预训练, 得到网络层参数。

2) 收集实际工况中常见的 5 种待分拣花卉的图像, 按比例划分数据集。

3) 冻结 Softmax 分类层之前的参数获得先验知识, 将得到的特征图作为输入, 重新训练 Softmax 分类层 (5 种类别的花卉种类) 获得分类模型。

4) 用重新训练的模型对测试数据进行分类, 完成花卉分拣的任务。

4 实验与分析











为了验证该系统的准确性和在真实场景下的花卉分拣效果, 收集了实际场景下包装机器人分拣的 5 种花卉数据, 并自建花卉识别数据库进行试验。采用

MobileNet 作为花卉特征提取网络, 采用 Softmax 多类别分类器分类, 以识别精度、交叉熵损失作为评判标准, 并传统的卷积神经网络作对比, 分析该系统的优缺点。以 Ubuntu 16.04 为操作系统、Python 2.7 为开发工具、TensorFlow 为深度学习框架, 配置 GPU (graphics processing unit)、CUDA (compute unified device architecture), 搭建由 GPU 加速图像处理的并行架构, 以提高网络训练速度。

4.1 自建花卉分拣数据集

本研究根据实际工况收集 5 种待识别花卉的图像共计 3 670 张, 其中菊花 633 张、蒲公英 898 张、玫瑰 641 张、向日葵 699 张、郁金香 799 张。采集过程中要求图像内尽量包含花卉图像本身, 同时又增加了大量有复杂背景和不同生长状态的图像, 增加了很多干扰因素, 使得模型更具有泛化能力。自建数据集如表 2 所示。

表 2 自建数据集
Table 2 Self-built data set

花卉种类	数量 / 张	标准图	样例图
菊花 (daisy)	633		
蒲公英 (dandelion)	898		
玫瑰 (roses)	641		
向日葵 (sunflowers)	699		
郁金香 (tulips)	799		

4.2 花卉分拣数据集划分

一般情况下将原始花卉数据集按照 8:1:1 划分为训练集、验证集、测试集。其中训练集在训练时估计模型参数; 验证集是从训练集中单独划分一部分作为每次迭代的性能度量; 测试集仅在模型训练完成后验证准确率, 检验最终选择的最优模型的性能。

4.3 实验分析

为了更好地拟合训练网络, 训练 MobileNet 时设置学习率为 0.01, 迭代次数为 1 000, 批量输入训练图像为 100 张, 预输入图像大小为 224×224 。实验结果如图 2 和图 3 所示, 图中虚线为训练集, 实线为验证集。

由图 2 可知, 在训练阶段, 本研究提出的花卉分拣包装算法在经过 1 000 次迭代之后, 模型的准确率不断上升并最终趋于平稳, 并且训练集和验证集的准确率相差不大。这表明该模型在少量数据下也能够很好地拟合网络, 能满足实际的要求。

交叉熵损失函数值是衡量模型优劣的重要指标之一。有效地降低损失值可使所设计的花卉分拣系统具备更强的泛化能力。从图 3 可看出, 本文采用的 28 层深度可分离卷积神经网络, 经过 1 000 次迭代后, 交叉熵损失函数值下降并最终保持在 0.12 左右, 这表明模型的预测结果和真实值不断接近。




图 2 模型准确率

Fig. 2 Model accuracy




图3 交叉熵损失

Fig. 3 Cross entropy loss

在自建数据集下,为比较本研究提出的花卉自动分拣算法与其他深度学习神经网络的花卉图像分拣算法的优劣,基于现有的数据集做了对比实验。为了保证实验的合理性,本文所采用的 MobileNet,传统的卷积神经网络 AlexNet、GoogLeNet 和文献 [14] 的方法都经过了 ImageNet 预训练。具体实验结果如表 3 所示。

表3 自建数据库下花卉分拣算法的结果比较


Table 3 Comparison of the results of flower sorting and packaging methods in self-built databases

方 法	分类准确率 / %	测试时间 / s
本文方法	91.20	0.237
AlexNet	73.50	4.221
GoogLeNet	89.80	1.244
文献 [14] 方法	84.12	2.556


由表 3 可知,利用传统卷积神经网络方法得到的分类准确率均低于本文的方法,且模型测试时间均长于本文的方法。这主要由于来自实际场景的自建数据集不足以拟合传统的卷积神经网络,从而出现了欠拟合的现象。

深度可分离卷积神经网络,由于其自身的网络结构特点而大大简化了模型参数,在模型识别阶段识别花卉图像的速度大幅提高。相比传统的卷积操作再次添加了 BN 层,训练数据在每一层的卷积操作之前都进行两次 BN 归一化操作,使得网络的非线性增强。


图 4 为网络微调模型输出参数直方图。从图 4 中可以看出,得益于 BN 归一化,在训练阶段和测试阶段通过微调的 MobileNet,末端输出、权重参数、偏置参数都体现出良好的状态分布,浅层网络参数训练时产生的误差不会在深层无限放大,模型稳定性更好。




a) 训练阶段微调网络输出




b) 测试阶段微调网络输出




c) 训练阶段微调网络偏置



d) 测试阶段微调网络偏置



e) 训练阶段网络权重



f) 测试阶段网络权重

图 4 网络微调模型输出参数直方图

Fig. 4 Network fine-tuning model output parameter histogram

5 结论

针对传统的花卉分类算法在工业包装机器人的应用中,呈现模型的复杂度高、分类精度低、需手动提取特征的问题,本文提出一种基于深度可分离的卷积神经网络的花卉自动分拣算法。综合上述讨论可得以下结论:1)深度可分离的卷积神经网络,由于自身的分离卷积和一系列的优化操作,可有效提取花卉数据特征,分类的准确度和识别速度均高于传统算法。2)通过网络微调的训练方法,极大地保存了 MobileNet 高效率的特征提取能力,模型参数更加稳定,重新训练得到的模型在新的样本数据集上呈现良好的效果。3)本文提出的算法应用于花卉分类识别时效果良好,可进一步开发成功能芯片卡。

参考文献:

- [1] 杜恩明, 张仁朝. 基于机器视觉的自动分拣码放系统研究[J]. 包装工程, 2018, 39(15): 194-198.
DU Enming, ZHANG Renchao. Automatic Sorting and

Stacking System Based on Machine Vision[J]. Packaging Engineering, 2018, 39(15): 194-198.

- [2] 王志伟. 智能包装技术及应用[J]. 包装学报, 2018, 10(1): 27-33.
WANG Zhiwei. Intelligent Packaging Technology and Its Application[J]. Packaging Journal, 2018, 10(1): 27-33.
- [3] 李光, 韩芮. “工业 4.0”视阈下智能包装装备发展趋势[J]. 包装学报, 2018, 10(1): 34-41.
LI Guang, HAN Rui. Development Trend of Intelligent Packaging Equipment from the Perspective of “Industry 4.0”[J]. Packaging Journal, 2018, 10(1): 34-41.
- [4] NILSBACK M E, ZISSERMAN A. Automated Flower Classification over a Large Number of Classes[C]//2008 Sixth Indian Conference on Computer Vision, Graphics & Image Processing. Bhubaneswar: IEEE, 2008: 722-729.
- [5] ANGELOVA A, ZHU S H. Efficient Object Detection and Segmentation for Fine-Grained Recognition[C]//2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland: IEEE, 2013: 811-818.
- [6] KHAN F S, VAN DE WEIJER J, VANRELL M. Modulating Shape Features by Color Attention for Object Recognition[J]. International Journal of Computer Vision, 2012, 98(1): 49-64.
- [7] 王爽. 基于机器学习的花卉识别算法的研究与实现[D]. 成都: 电子科技大学, 2018.
WANG Shuang. Research and Implementation of the Algorithm of Flower Recognition Based on Machine Learning[D]. Chengdu: University of Electronic Science and Technology of China, 2018.
- [8] 刘园园. 基于卷积神经网络的花卉图像分类算法的研究[D]. 北京: 华北电力大学, 2017.
LIU Yuanyuan. Research on Flower Classification via Convolutional Neural Network[D]. Beijing: North China Electric Power University, 2017.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet Classification with Deep Convolutional Neural Networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. Lake Tahoe: ACM, 2012, 60(6): 1097-1105.
- [10] 林思思, 叶东毅, 陈昭炯. 多特征融合的花卉图像深度学习分类算法[J]. 小型微型计算机系统, 2018(7): 1446-1450.
LIN Sisi, YE Dongyi, CHEN Zhaojong. Deep Learning-Based Flower Image Classification Algorithm with Multi-Features Fusion[J]. Journal of Chinese Computer Systems, 2018(7): 1446-1450.
- [11] GEHLER P, NOWOZIN S. On Feature Combination for Multiclass Object Classification[C]//2009 IEEE 12th

- International Conference on Computer Vision. Kyoto: IEEE, 2009: 221–228.
- [12] XIA X L, XU C, NAN B. Inception-v3 for Flower Classification[C]//2017 2nd International Conference on Image, Vision and Computing. Chengdu: IEEE, 2017: 783–787.
- [13] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the Inception Architecture for Computer Vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV: IEEE, 2016: 2818–2826.
- [14] 尹红. 基于深度学习的花卉图像分类算法研究[D]. 南昌: 南昌航空大学, 2018.
- YIN Hong. Research on Flower Image Classification Algorithm Based on Deep Learning[D]. Nanchang: Nanchang Hangkong University, 2018.
- [15] HOWARD A G, ZHU M L, CHEN B, et al. MobileNet: Efficient Convolutional Neural Networks for Mobile Vision Applications[EB/OL]. [2018–09–12]. https://www.researchgate.net/publication/316184205_MobileNets_Efficient_Convolutional_Neural_Networks_for_Mobile_Vision_Applications.
- [16] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[EB/OL]. [2018–09–11]. <http://www.oalib.com/paper/4071527#.XAjQbnZT-ug>.
- [17] NAIR V, HINTON G E. Rectified Linear Units Improve Restricted Boltzmann Machines Vinod Nair[EB/OL]. [2018–09–11]. https://www.researchgate.net/publication/221345737_Rectified_Linear_Units_Improve_Restricted_Boltzmann_Machines_Vinod_Nair.
- [18] GOH G B, HODAS N O, VISHNU A. Deep Learning for Computational Chemistry[J]. Journal of Computational Chemistry, 2017, 38(16): 1291–1307.
- [19] RANJAN R, CASTILLO C D, CHELLAPPA R. L2-Constrained Softmax Loss for Discriminative Face Verification[EB/OL]. [2018–09–11]. https://www.researchgate.net/publication/315683968_L2-constrained_Softmax_Loss_for_Discriminative_Face_Verification.
- [20] WU J, CHUNG A C S. Cross Entropy: A New Solver for Markov Random Field Modeling and Applications to Medical Image Segmentation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Berlin: Springer, 2005: 229–237.
- [21] SCHMIDHUBER J. Deep Learning in Neural Networks: An Overview[J]. Neural Networks, 2015, 61: 85–117.
- [22] RUSSAKOVSKY O, DENG J, SU H, et al. ImageNet Large Scale Visual Recognition Challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211–252.

Depth Separable Convolutional Neural Network and Its Application in Automatic Sorting

HE Jing¹, CHENG Tao^{1,2}, HUANG Lianghui³, KANG Zuchao¹

(1. College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou Hunan 412007, China;

2. Huilin Packing Dongguan Co., Ltd., Dongguan Guangdong 523000, China;

3. Guangdong Nanhai Eagle View Technology Co., Ltd., Foshan Guangdong 528200, China)

Abstract: Aimed at the problem of too large model parameters and low sorting precision of the traditional flower classification algorithm in industrial automation sorting application, a flower recognition algorithm based on deep learning was proposed. The application of flower classification algorithm in industrial flower packaging sorting system was introduced. According to the actual demand, a deep separable convolutional neural network was used as the flower feature extraction, and the model structure of the network was analyzed in detail. In order to improve the speed of model training, a fine-tuned model training method was proposed. The experimental results showed that the flower classification algorithm used in the industrial flower automatic sorting application had higher accuracy, better stability and wider application than traditional algorithms.

Keywords: industrial automation sorting; flower classification; deep separable convolutional neural network; network fine tuning