

刘小刚, 李荣梅, 范诚, 等. 基于语义分割的芒果表皮缺陷识别 [J]. 华南农业大学学报, 2023, 44(1): 134-141.

LIU Xiaogang, LI Rongmei, FAN Cheng, et al. Recognition of mango skin defect based on semantic segmentation[J]. Journal of South China Agricultural University, 2023, 44(1): 134-141.

基于语义分割的芒果表皮缺陷识别

刘小刚¹, 李荣梅¹, 范 诚², 杨启良¹, 赵 璐³

(1 昆明理工大学 现代农业工程学院, 云南 昆明 650000; 2 中联重科智能技术有限公司, 湖南 长沙 410013; 3 四川大学 水利水电学院, 四川 成都 610065)

摘要:【目的】运用语义分割技术自动识别芒果及其表皮缺陷, 实现芒果的质量评估及分选, 为芒果质量快速无损检测提供参考。【方法】采集自然环境下的多场景芒果表皮缺陷图像用于模型的训练与测试, 将联合上采样金字塔 (Joint pyramid upsampling, JPU) 结构替换 DeepLabV3+ 中空洞空间卷积池化金字塔 (Atrous spatial pyramid pooling, ASPP), 将 Atrous-ResNet 模型替换 DeepLabV3+ 中 Xception 模型, 采用类别像素准确率 (Class pixel accuracy, CPA)、平均像素准确率 (Mean pixel accuracy, MPA)、平均交并比 (Mean intersection over union, MIoU) 作为模型的精度评价指标。【结果】采用 JPU 模块替换 ASPP 模块, 在 ResNet 网络中运用扩张卷积有利于增大模型的感受野, 总体上预测的边界更加平滑, 且对细小缺陷的识别更精确; 与 SegNet、LinkNet 算法的对比验证表明, Atrous-ResNet 模型具备更高的精度, CPA 小幅提升, MPA 提升 3.79 个百分点, MIoU 提升 4.57 个百分点, Atrous-ResNet 模型具有更好的识别效果。【结论】基于语义分割的方法应用于芒果表皮缺陷识别是可行的, Atrous-ResNet 模型较 SegNet 以及 LinkNet 算法比较具有更高的识别精度。

关键词: 语义分割; DeepLabV3+; 联合上采样金字塔; 缺陷检测; 芒果表皮

中图分类号: S436.67; TP391

文献标志码: A

文章编号: 1001-411X(2023)01-0134-08

Recognition of mango skin defect based on semantic segmentation

LIU Xiaogang¹, LI Rongmei¹, FAN Cheng², YANG Qiliang¹, ZHAO Lu³

(1 Faculty of Modern Agricultural Engineering, Kunming University of Science and Technology, Kunming 650000, China; 2 Zoomlion Intelligent Technology Limited Company, Changsha 410013, China; 3 College of Water Resources and Hydropower, Sichuan University, Chengdu 610065, China)

Abstract: 【Objective】The semantic segmentation technology was used to automatically identify mango and its skin defects, to realize the quality evaluation and sorting of mango and provide a reference for the rapid and nondestructive testing of mango quality. 【Method】Mango skin defect images in multi-scene of natural environment were collected for model training and testing. Atrous spatial pyramid pooling (ASPP) in DeepLabV3+ was replaced by joint pyramid upsampling (JPU) structure, and Xception model in DeepLabV3+ was replaced by Atrous-ResNet model. Class pixel accuracy (CPA), mean pixel accuracy (MPA) and mean intersection over union (MIoU) were used as the accuracy evaluation indexes of each model. 【Result】JPU module was used to replace ASPP module, and Atrous convolution was applied to ResNet network which was conducive to increase the receptive field of the model. In general, the predicted boundary was smoother, and the

收稿日期: 2022-04-22 网络首发时间: 2022-11-17 14:58:16

首发网址: <https://kns.cnki.net/kcms/detail/44.1110.S.20221116.1702.002.html>

作者简介: 刘小刚, 教授, 博士, 主要从事农业工程相关研究, E-mail: liuxiaogangjy@126.com; 通信作者: 范 诚, 工程师, 主要从事工程机械视觉技术研发, E-mail: 17771848474@189.cn

基金项目: 国家自然科学基金 (51979133); 四川省科技计划 (2022YFQ0082)

identification of small defects was more accurate. The comparison with SegNet and LinkNet algorithms showed that Atrous-ResNet model had higher accuracy, with CPA slightly improved, MPA was up 3.79 percent point and MIoU was up 4.57 percent. Atrous-ResNet model had better identification effects. 【Conclusion】 The method based on semantic segmentation is feasible for mango skin defect recognition. Compared with SegNet and LinkNet algorithms, Atrous-ResNet model has higher recognition accuracy.

Key words: Semantic segmentation; DeepLabV3+; Joint pyramid upsampling; Defect recognition; Mango skin

芒果具有良好的食用价值^[1], 市场需求不断增加。市场对芒果的外部品质进行分级的主要指标是形状、颜色、大小以及表皮缺陷, 其中, 芒果的表皮缺陷对其能否在市场上的销售起决定性的作用。目前市场水果的大小和质量分选主要依靠机械工程技^[2-3], 而形状、颜色、表皮缺陷的检测大多由人工完成, 劳动强度大、效率低、成本高。如果采用智能机器在自然环境下对果实进行采摘, 将表皮缺陷的芒果与表皮完好的芒果分开, 完成初步的分级, 可避免对完好果实的污染及浪费。因此, 对芒果果实进行表皮缺陷检测是目前需要解决的关键问题。

随着人工智能的发展, 越来越多的算法应用在农产品加工领域, 主要应用于果实的分类^[4-6]、成熟度检测^[7]、病虫害检测^[8-9]及缺陷检测^[10]。刘平等^[11]采用 Chan-Vese 模型对贴叠葡萄串进行识别, 识别准确率达 89.71%; 李江波等^[12]采用分水岭算法对桃子表皮缺陷进行识别, 取得了较高的准确率。然而面对复杂的自然环境, 如遮挡、密集、光照等因素影响, 传统的模型算法精度不能满足实际需求。更多的研究表明基于深度学习的模型较传统机器学习模型在速度和准确率方面表现更好^[13-14], 运用神经网络算法对农产品进行识别^[15-16]已成为热点。Jhuria 等^[17]运用神经网络对图像进行训练来识别苹果的表皮缺陷, 实现了在线实时检测, Basavaraj 等^[18]运用神经网络对香蕉病害进行识别, 实现了端到端的自动化识别。

目前已经提出了许多芒果表皮缺陷的识别算法。Sahu 等^[19]通过将 RGB 图转换为灰度图和二值图像, 再执行滤波操作以去除背景和噪声来识别图像中的缺陷, 能有效地识别出芒果表皮缺陷; 但该方法只能进行单幅图像的识别操作, 效率低。Huang 等^[20]采用支持向量机的方法进行芒果识别, 并结合比色传感器阵列对芒果进行质量分级, 在测试集的精度达到 97.5%, 具有无损、省时的特点。Sudarjat 等^[21]采用近红外光谱法能够准确检测芒果表皮的病害, 但没有进行自然环境下的检测。Kestur 等^[22]采用基于语义分割的算法 MangoNet

对自然环境下的芒果进行检测, 取得了比 FCN 网络^[23]更好的结果, 较机器学习模型有了更好的性能。然而, 实际自然环境复杂多变, 存在逆光、顺光、果实密集、遮挡与粘黏等现象, 降低了以上模型检测的准确率。为此, 本研究基于改进的 DeepLabV3+ 语义分割算法^[24], 识别自然环境下芒果的表皮缺陷, 以期获得更好的识别精度, 进而为芒果缺陷识别提供参考。

1 材料与方法

1.1 试验材料

芒果图像采集于中国西南地区云南省玉溪市元江县, 4 个品种分别为 ‘鹰嘴芒’、‘金煌芒’、‘苹果芒’和 ‘贵妃芒’。图像采集时间分为白天和夜晚, 在自然环境下共采集芒果图像 820 张, 经过图像翻转、平移、镜像、缩放等几何变换后扩增数据集为 1340 张图像, 图像的分辨率为 1440 像素×1080 像素。按照 6:2:2 的比例划分训练集、验证集和测试集, 训练集图像为 804 张, 验证集、测试集的图像均为 268 张。将数据集类别划分为芒果、缺陷、茎梗、背景 4 种, 图像的分辨率缩放为 512 像素×512 像素。

1.2 图像预处理

由于数据集是在自然环境下采集的, 存在果实相互遮挡的情况, 为了使模型具有更好的泛化性, 本文对图像进行随机遮挡处理。在试验数据集中发现芒果表皮存在细小的斑点, 这些斑点是正常的生理现象, 不影响芒果的质量, 然而过于密集的斑点会导致模型将其误判为表皮缺陷。

针对表皮具有密集斑点的芒果, 对图像进行闭运算 (图 1), 即依次进行膨胀、腐蚀处理, 可以有效地去除表皮细小的斑点。首先进行膨胀处理, 将图像与核进行卷积运算, 取每个局部的最大值; 图像的腐蚀处理是求取每个局部的最小值。本研究采用的核形态为矩形, 大小为 (1,1), 处理 1 次。采用闭运算去除芒果表皮颜色较浅的斑点, 保留颜色较深的区域, 具体计算如下:

$$E = I - S, \tag{1}$$




图 1 图像形态学处理

Fig. 1 Image morphological processing

$$D = I + S, \tag{2}$$

式中, I 为图像矩阵, S 为结构单元, E 为腐蚀后得到的图像, D 为膨胀后得到的图像。

1.3 模型结构

1.3.1 联合上采样金字塔模块 采用 DeepLabV3+ 算法对芒果表皮缺陷进行分割, 并作出如下改进: 使用联合金字塔上采样模块 (Joint pyramid upsampling, JPU)^[25] 替换空洞空间卷积池化金字塔 (Atrous spatial pyramid pooling, ASPP) 模块, 降低计算复杂度、提升运行速度。其次, 采用扩张卷积 (Atrous conv)^[26] 替换主干网络 ResNet 中部分常规卷积 (Regular conv), 扩张卷积的在增大特征图感受野的同时, 能够保持特征图尺寸, 避免空间位置信

息的损失, 使模型收敛得更快, 并提高其精度。

JPU 模块: 不同于 ASPP 只利用 1 个特征图 (f5) 中的信息, 该模块将主干网络最后 3 个特征图 (f3~f5) 作为输入, 使用多尺度上、下文模块产生最终的预测。首先, 对每个输入特征图进行卷积使其通道数一样, 然后进行上采样操作使其分辨率一致 (图 2a), 并行使用不同膨胀率 (1、2、4、8) 和 4 个可分离卷积提取特征 (图 2b), 膨胀率为 2、4、8 的卷积用于学习映射 h , 将 y_m 转化为 y_s , 较小的膨胀率有利于小目标的识别, 较大的膨胀率能够增大感受野, 对较大目标更敏感, 从而在特征图中提取到多尺度信息。最后对其进行卷积生成最终的预测 (图 2c), 计算见下式:




图 2 联合上采样金字塔结构

Fig. 2 The structure of joint pyramid upsampling

$$h = \arg \min \|y_s - h(y_m)\|, \tag{3}$$

式中, h 表示输入与输出的映射关系, y_s 表示输出的特征, y_m 表示输入的特征。

1.3.2 编码器与解码器 在编码器中对 ResNet50 网络进行修改, 替换 conv5 阶段的部分常规卷积为扩张卷积, 得到 Atrous-ResNet 作为主干网络。Atrous-ResNet 中不存在可分离卷积, 并且除扩张卷积层之外, 所有网络层均能加载 ImageNet 预训练

模型参数, 进行有效的初始化, 大幅提升模型的精度和收敛速度。但是, 主干网络中加入扩张卷积, 会增加模型后续阶段的计算成本, 因此只研究在 ResNet 网络的 conv5 阶段加入扩张卷积的情况。主干网络各个阶段输出的图像为原图尺寸的 1/2、1/4、1/8、1/16 和 1/32。在 DeepLabV3+基础上引入了更多来自 Encode 模块的特征图 (图 3), 将 f3~f5 层特征图连接到 Decoder 模块, 得到更多语义




图 3 改进的算法架构图

Fig. 3 Structure chart of improved algorithm

信息的同时具有更多的空间信息,使高层特征图对分割结果起到更大的作用。

1.3.3 评价指标 模型评价指标是衡量模型训练结果优劣的重要因素,能够直接反映出模型在训练集的学习效果及验证集的测试效果。采用的评价指标为类别像素准确率 (Class pixel accuracy, CPA)、平均像素准确率 (Mean pixel accuracy, MPA、平均交并比 (Mean intersection over union, MIoU)。其中,MPA 反映总体的多类别预测准确率,MIoU 是语义分割模型的标准度量指标。评价指标的值越大,模型的效果越好。每种类别像素的准确率计算如下式。

$$CPA = \frac{P_{ii}}{\sum_{i=0}^{k-1} P_{ij}}, \quad (4)$$




图 4 不同模型评价指标的比较

Fig. 4 Comparison of evaluation indexes for different models

$$MPA = \frac{1}{k} \sum_{i=0}^{k-1} CPA, \quad (5)$$

式中, P_{ii} 表示第 i 个类别预测准确的数量, P_{ij} 表示将第 i 类别物体预测为第 j 类别的数量, P_{ji} 表示第 j 类别物体预测为第 i 类别的数量, i 表示真实类别, j 表示预测类别。 k 为类别的数量,不考虑背景类别,因此 k 为 3。

$$MIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}}. \quad (6)$$

通过计算每一类真实值及预测值像素集合的交集和并集的比值,得到每一类别的交并比后,计算所有类别的平均值即为平均交并比,该指标在试验中能够较好地反映模型在不同类别区域分割的准确性和完整性。

2 结果与分析

2.1 主干模型的训练与测试

试验环境: 本研究采用 Pytorch1.5 深度学习框架, Python3.6 语言, CPU: Intel i9-9900KF, GPU: NVIDIA RTX 2070。所有模型训练及测试都在同一硬件环境下进行,模型初始学习率为 1×10^{-4} ,采用 Adam 优化器,对数据集训练了 120 次迭代,并且在线对数据进行随机裁剪、缩放、翻转、镜像等几何变换操作,采用基于 ImageNet 数据集的预训练模型。

为了比较模型在训练集的效果,将本文改进的模型 Atrous-ResNet 与 DeepLabV3+算法 Xception 模型的损失值与平均像素准确率进行比较,结果如图 4 所示。Atrous-ResNet 模型训练集的准确率达到 97.30%,模型的损失值较 Xception 模型下降 0.263,说明改进后模型的预测值与真实值的差异更小,预测结果与真实结果更接近;且平均交并比较原模型均有提升,本研究所作改进具有可行性。

2.2 多场景的识别效果比较

本研究采集了多种场景下的芒果图像,时间有

白天和夜晚，数量分布情况分为果实密集、稀疏，位置上为果实遮挡与粘黏。在测试集中挑选白天及夜晚的芒果图像均为 20 幅，随机挑选果实密集及稀疏的图像均为 15 幅，随机挑选果实遮挡与粘黏的图像 10 幅，使用改进的模型 Atrous-ResNet 与 DeepLabV3+模型分别进行检测，结果见图 5。由图 5 可知，侧光照射下，芒果图像表皮纹理、缺陷清晰，是理想的光线环境；顺光照射下芒果表皮会有一些的反光现象，光线强的部分纹理不清晰，易造成漏识别；逆光照射下，芒果背景较暗，表皮纹理不清

晰、缺陷边界模糊，增加了缺陷定位的难度。白天不同光照且果实稀疏时，DeepLabV3+模型与改进模型识别效果相近，但是改进模型在类别边界定位上更加平滑。在夜晚使用 LED 灯照明时，芒果的表皮纹理较清晰，但背景颜色暗，只能识别光线照射良好的芒果。芒果分布密集时，靠近镜头的芒果表皮较清晰，体型较大，模型易识别；远离镜头的芒果表皮不清晰且体型较小，导致模型难以识别缺陷。在芒果、茎梗密集且相互遮挡时，模型对于细小的缺陷部位难以定位。




图 5 不同场景下的模型预测效果

Fig. 5 Prediction performance in multi-scenarios

2 种模型在不同场景的测试集中进行测试(表 1), Atrous-ResNet 模型对芒果识别的准确率较 DeepLabV3+模型高, CPA 上升 3.79 个百分点, MIoU 上升 4.57 个百分点。总体来看, Atrous-ResNet 模型在测试集的表现均优于 DeepLabV3+模型, 但在自然复杂场景下, 芒果表皮较小的缺陷难以

检测, 模型的性能仍需要提升, 特别是针对小目标的检测。

2.3 多种算法在芒果表皮缺陷数据集的检测效果

为了进一步评价不同模型的优劣, 探究多种算法对芒果表皮缺陷数据集的检测效果, 选择有代表性的实时网络 LinkNet^[27]、标准网络 SegNet^[28] 与

表 1 DeepLabV3+与 Atrous-ResNet 模型的评价指标比较

Table 1 Comparison of evaluation indexes between DeepLabV3+ and Atrous-ResNet model

%

模型 Model	类别像素准确率 Class pixel accuracy			平均像素准确率 Mean pixel accuracy	平均交并比 Mean intersection over union
	芒果	缺陷	茎梗		
	Mango	Defect	Stalk		
DeepLabV3+	92.03	91.29	88.74	90.69	89.56
Atrous-ResNet	94.16	95.32	93.95	94.48	94.13

Atrous-ResNet 进行比较。

由图 6 可知, 不同光照下, 侧光照射下识别效果相对较好; 不同密集程度下, 果实稀疏的识别效果优于果实密集; 不同时间段下, 白天的情况复杂, 识别效果多样, 夜晚只有在光线良好的条件下才能有效识别; 果实遮挡与粘黏条件下的识别效果较差。总体来说, Atrous-ResNet 模型在不同场景下的识别效果均优于其他模型。




图 6 LinkNet、SegNet 及 Atrous-ResNet 模型在不同场景下的识别效果对比

Fig. 6 Comparison of recognition performance among LinkNe, SegNet and Atrous-ResNet model in multi-scenarios

表 2 为 3 种不同的算法对测试集评价指标的结果, Atrous-ResNet 模型较 LinkNet 与 SegNet 算法有显著的提升, CPA 上均高于 LinkNet 与 SegNet, MPA 较 LinkNet 算法提升 13.02 个百分点, 较 SegNet 算法提升 16.19 个百分点; MIoU 较 LinkNet 算法提升 15.28 个百分点, 较 SegNet 算法提升 19.96 个百分点。同时发现, 实时语义分割算法 LinkNet 在识别效果上优于 SegNet 算法。

表 2 不同算法的评价指标的比较
Table 2 Comparison of evaluation indexes of different algorithms

模型 Model	类别像素准确率 Class pixel accuracy			平均像素准确率 Mean pixel accuracy	平均交并比 Mean intersection over union
	芒果 Mango	缺陷 Defect	茎梗 Stalk		
LinkNet	82.72	81.17	78.94	80.94	77.37
SegNet	80.49	77.14	75.68	77.77	72.69
Atrous-ResNet	94.27	94.58	93.03	93.96	92.65

3 结论

本研究以芒果为研究对象,采用图像处理及语义分割相结合的方法对多场景下芒果表皮缺陷进行检测,主要结论如下。

1) 改进 DeepLabV3+模型,主要在 ResNet 网络中添加 Atrous 卷积,有利于增大模型的感受野,其次采用 JPU 模块替换 ASPP 模块,能提取到更多的尺度特征,使模型预测的边界更加平滑,对细小缺陷的识别更准确。

2) Atrous-ResNet 模型较原始 DeepLabV3+模型,类别像素准确率有所提升,MPA 为 94.48%,MIoU 为 94.13%,满足自然复杂场景下芒果表皮缺陷识别的要求。

3) Atrous-ResNet 模型的 CPA、MPA 及 MIoU 均优于 LinkNet 和 SegNet 模型。

参考文献:

[1] DEEPA M, PUSHPA B, UDAYKUMAR K. Physico-chemical properties, nutritional and antinutritional composition of pulp and peel of three mango varieties[J]. International Journal of Educational Science and Research, 2017, 7(3): 81-94.

[2] KANGD, WANGY, FANY, et al. Research and development of *Camellia oleifera* fruit sheller and sorting machine[J]. Earth and Environmental Science, 2018, 108: 042051. doi: 10.1088/1755-1315/108/4/042051.

[3] SIHOMBING P, TOMMY F, SEMBIRING S, et al. The *Citrus* fruit sorting device automatically based on color method by using tcs320 color sensor and arduino uno microcontroller[J]. Journal of Physics: Conference Series, 2019, 1235: 012064. doi: 10.1088/1742-6596/1235/1/012064.

[4] 邓继忠, 任高生, 兰玉彬, 等. 基于可见光波段的无人机超低空遥感图像处理[J]. 华南农业大学学报, 2016, 37(6): 16-22.

[5] 戴泽翰, 郑正, 黄莉舒, 等. 基于深度卷积神经网络的柑橘黄龙病症状识别[J]. 华南农业大学学报, 2020, 41(4): 111-119.

[6] 赵德安, 吴任迪, 刘晓洋, 等. 基于 YOLO 深度卷积神

经网络的复杂背景下机器人采摘苹果定位[J]. 农业工程学报, 2019, 35(3): 164-173.

[7] 刘小刚, 范诚, 李加念, 等. 基于卷积神经网络的草莓识别方法[J]. 农业机械学报, 2020, 51(2): 237-244.

[8] XING S L, LEE M. Classification accuracy improvement for small-size *Citrus* pests and diseases using bridge connections in deep neural networks[J]. Sensors, 2020, 20(17): 4992. doi: 10.3390/s20174992.

[9] SELVARAJ M G, VERGARA A, RUIZ H, et al. AI-powered banana diseases and pest detection[J]. Plant Methods, 2019, 15(1): 92.

[10] PATEL K K, KAR A, KHAN M A. Common external defect detection of mangoes using color computer vision[J]. Journal of the Institution of Engineers: Series A, 2019, 100(4): 559-568.

[11] 刘平, 朱衍俊, 张同勋, 等. 自然环境下贴叠葡萄串的识别与图像分割算法[J]. 农业工程学报, 2020, 36(6): 161-169.

[12] 李江波, 彭彦昆, 黄文倩, 等. 桃子表面缺陷分水岭分割方法研究[J]. 农业机械学报, 2014, 45(8): 288-293.

[13] 张德军, 周学成, 杨旭东. 基于图像处理和深度迁移学习的芒果果实病状识别[J]. 华南农业大学学报, 2021, 42(4): 113-124.

[14] 袁培森, 黎薇, 任守纲, 等. 基于卷积神经网络的菊花花型和品种识别[J]. 农业工程学报, 2018, 34(5): 152-158.

[15] 尚增强, 杨东福, 马质璞. 基于深度卷积神经网络的大豆叶片多种病害分类识别[J]. 大豆科学, 2021, 40(5): 662-668.

[16] 程曦, 吴云志, 张友华, 等. 基于深度卷积神经网络的储粮害虫图像识别[J]. 中国农学通报, 2018, 34(1): 154-158.

[17] JHURIA M, KUMAR A, BORSE R. Image processing for smart farming: Detection of disease and fruit grading[C]//IEEE 20th International Conference on Image Information Processing. Shimla, India: IEEE, 2013: 521-526.

[18] BASAVARAJ T, BHAVANA S. Banana plant disease detection and grading using image processing[J]. International Journal of Engineering Science and Computing, 2016: 6512-6516.

[19] SAHU D, POTDAR M. Defect identification and maturity detection of mango fruits using image analysis[J]. American Journal of Artificial Intelligence, 2017, 1(1): 5-14.

[20] HUANG X Y, LÜ R Q, WANG S, et al. Integration of computer vision and colorimetric sensor array for nondestructive detection of mango quality[J]. Journal of Food Process Engineering, 2018, 41(8): 1-9.

[21] SUDARJAT, KUSUMIYATI, HASANUDDIN, et al. Rapid and non-destructive detection of insect infestations on intact mango by means of near infrared spectroscopy[J]. *IPO Conference Series: Earth and Environmental Science*, 2019, 365(1): 012037. doi: 10.1088/1755-1315/365/1/012037.

[22] KESTUR R, MEDURI A, NARASIPURA O. MangoNet: A deep semantic segmentation architecture for a method to detect and count mangoes in an open orchard[J]. Engineering Applications of Artificial Intelligence, 2018, 77: 59-69.

[23] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. *Proceedings of the IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 640-651.

[24] CHOLLET F. Xception: Deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE, 2017: 1800-1807.

[25] WU H K, ZHANG J G, HUANG K Q, et al. FastFCN: Rethinking dilated convolution in the backbone for semantic segmentation[EB/OL]. ArXiv preprint arXiv, 2019: 1903.11816. (2019-03-28)[2022-03-20]. <https://arxiv.org/abs/1903.11816>.

[26] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[M]//Computer Vision ECCV. Cham: Springer, 2018: 833-851.

[27] CHAURASIA A, CULURCIELLO E. LinkNet: Exploiting encoder representations for efficient semantic segmentation[J]. IEEE Visual Communications and Image Processing (VCIP), 2017: 1-4. doi:10.1109/VCIP.2017.8305148.

[28] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *Proceedings of the IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(12): 2481-2495.

【责任编辑 霍 欢】