

任胜男, 孙 钰, 张海燕, 等. 基于 one-shot 学习的小样本植物病害识别[J]. 江苏农业学报, 2019, 35(5): 1061-1067.
doi: 10.3969/j.issn.1000-4440.2019.05.009

基于 one-shot 学习的小样本植物病害识别

任胜男¹, 孙 钰¹, 张海燕¹, 郭丽霞²

(1. 北京林业大学信息学院, 北京 100083; 2. 国家食品安全风险评估中心, 北京 100022)

摘要: 针对植物病害小样本问题提出一种基于 one-shot 学习的植物病害识别方法。以公开数据集 PlantVillage 中 8 类样本数量较少的植物病害图像作为识别对象, 使用焦点损失函数(focal loss, FL)训练基于关系网络的植物病害分类器。训练过程中, 调整 FL 超参数使模型聚焦于困难样本, 从而提高植物病害识别精确率。结果表明: 该方法在 5-way、1-shot 任务中识别精确率达到 89.90%, 相比原始关系网络模型精确率提高了 4.69 个百分点。同时, 与匹配网络和迁移学习相比, 改进后的方法在实验数据集上识别精确率分别提高了 25.02 个百分点和 41.90 个百分点。

关键词: 植物病害识别; 深度学习; one-shot 学习; 焦点损失函数; 关系网络

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-4440(2019)05-1061-07

Plant disease identification for small sample based on one-shot learning

REN Sheng-nan¹, SUN Yu¹, ZHANG Hai-yan¹, GUO Li-xia²

(1. School of Information Science and Technology, Beijing Forestry University, Beijing 100083, China; 2. China National Center for Food Safety Risk Assessment, Beijing 100022, China)

Abstract: A plant disease identification method based on one-shot learning was proposed to solve the problem of small plant disease dataset. Using eight kinds of plant disease images with few samples in the public dataset PlantVillage as recognition objects, the disease classifier based on relation network was trained by using focal loss (FL). To improve the accuracy of plant disease identification, the FL hyper-parameters were adjusted to focus the model on the hard samples during the training process. The results showed that the recognition accuracy of this method was 89.90% in 5-way and 1-shot task, which was 4.69% higher than that of the original relation network model. Besides, compared with matching network and transfer learning, the accuracy of improved method was improved by 25.02% and 41.90% on experimental set.

Key words: plant disease identification; deep learning; one-shot learning; focal loss; relation network

植物病害是影响植物生长发育的主要因素。在现代农业中, 病虫害问题是影响农作物产量和质量的关键问题之一^[1-2]。若能快速准确地发现并识别植物病害, 及时采取防御措施, 可有效地降低病害带来的损失。传统的植物病害识别是依赖经验丰富的

植物专家进行人工识别, 但这种方法存在主观性强、准确率低、成本高等问题。

随着计算机科学技术的不断发展, 基于深度学习的植物病害识别技术得到广泛的研究^[3-5]。深度学习模型是由多层卷积神经网络构成的深层网络架构, 包含成千上万个训练参数, 因此训练深度学习网络模型需要大量的数据样本。孙俊等^[6]以 PlantVillage 数据集中 21 917 张植物病害和健康图像作为研究对象, 提出一种归一化与全局池化相结合的卷积神经网络识别模型, 对多种植物叶片病害进行识别, 其精确率达到 99.56%。Liu 等^[7]以 13 689 张苹

收稿日期: 2018-12-03

基金项目: 北京林业大学中央高校基本科研业务费专项资金资助项目(TD2014-01); 国家重点研发计划项目(2017YFC1602002)

作者简介: 任胜男(1993-), 女, 山东济南人, 硕士, 研究方向物联网技术。(E-mail) 18810977315@163.com

通讯作者: 张海燕, (E-mail) zhyzml@bjfu.edu.cn

果病害图像作为研究对象,提出基于 AlexNet 的深度卷积神经网络模型,对 4 种苹果病害图像识别精确率达到 97.62%。Amara 等^[8]以 3 700 张香蕉病害图像为研究对象,提出基于 LeNet 的卷积神经网络模型,对 2 种香蕉病害进行识别,其精确率达到 99.72%。Brahimi 等^[9]以 14 828 张西红柿病害图像作为研究对象,采用迁移学习的方法,利用 GoogleNet 和 AlexNet 模型识别 PlantVillage 数据集中 9 类西红柿病害图像,精确率分别可达到 99.18% 和 98.66%。Mohanty 等^[10]以 54 306 张植物病害图像作为研究对象,以 GoogleNet 和 AlexNet 作为预训练模型,识别 36 类植物病害图像,精确率分别达到 99.34% 和 85.53%。以上研究中采用的植物病害图像数据量较大,满足深度学习模型训练的基本要求。但是在实际应用中,有些植物病害发病率低且病害图像采集成本高^[11],导致采集的训练数据只有几张或几十张,限制了上述深度学习在植物病害识别领域的应用。迁移学习方法^[12]可以将通用大数据集上学到的知识迁移到数据量相对较少的专业领域,但对于只有几张或几十张图像的数据集,迁移学习方法同样会出现识别精确率低的问题^[8]。

针对训练集样本数量过少的问题, Li 等^[13]首次提出 one-shot 学习方法,并使用贝叶斯函数构建网络模型。随后,许多用于 one-shot 学习任务的模型被提出,并取得显著成果。Lake 等^[14]提出使用贝叶斯层次模型对字母进行识别,试验结果达到了人类级别的表现且优于其他算法。Finn 等^[15]使用基于梯度下降的元学习模型,应用在 miniImageNet 数据集上,识别率为 48.70%。Ravi 等^[16]提出使用长短期记忆网络(Long short-term memory, LSTM)更新分类器参数的元学习方法,在 miniImageNet 数据集上识别率为 43.44%。Koch 等^[17]提出孪生网络(Siamese network),通过近邻算法计算成对图像的距离,以此判断成对图像是否为同类。Vinyals 等^[18]提出匹配网络(Matching network),使用 LSTM 和余弦距离公式,应用在 miniImageNet 数据集上识别率为 46.60%。Snell 等^[19]使用欧氏距离替代余弦距离公式扩展了匹配网络,并为每类构建原型表征,在 miniImageNet 数据集上识别率为 49.42%。Sung 等^[20]提出关系网络(Relation network)模型,此模型提供一种可学习的非线性分类器,使 one-shot 学习任务更加简单,其在 miniImageNet 数据集上识别率为

50.44%。由此可见,one-shot 学习方法在解决小样本识别问题上具有明显的优势。

本研究使用 one-shot 学习方法解决植物病害识别中样本数量过少的问题,以 PlantVillage 数据集为研究对象,利用关系网络作为分类器,同时改进关系网络中的损失函数,使模型聚焦于困难样本,以进一步提高小样本识别精确率。

1 材料和方法

1.1 材料

试验数据使用公开数据集 PlantVillage,数据集包含单一背景和自然背景下的植物健康和病害图像 87 848 张,共 58 类,数据分布如图 1 所示,其中 8 类(苹果锈病、卷心菜黑腐病、丝瓜霉霜病、黄瓜健康、西瓜健康、马铃薯健康、木薯叶斑病和大葱健康)样本数量较少。为了进行 one-shot 学习识别任务,将这 8 类数据每类样本减少至 20 张。试验中,将 PlantVillage 数据集划分成训练数据、验证数据和测试数据,其训练数据 40 类和验证数据 10 类应用于训练阶段,剩余 8 类小样本数据为测试数据,应用于测试阶段。与传统深度学习数据划分不同,各数据集包含不同的类,且无交叉类。所有图像大小调整为适合关系网络模型的分辨率 84×84。

数据集的具体划分按照 one-shot 学习的训练策略。One-shot 学习任务将每次抽取的样本称为 1 个 episode^[18]。每个 episode 由支持集 $S = \{(x_1, y_1), \dots, (x_m, y_m)\} (m = K \times C)$ 和查询集 $Q = \{(x_1, y_1), \dots, (x_n, y_n)\}$ 构成,其中 C 为类, K 为每类含有的样本数量, m 为支持集的总样本数量, n 为查询集中的总样本数量。如果含有 C 类的支持集中每类包含 1 个样本,则称此方法为 C-way、1-shot 学习。在 5-way、1-shot 学习中,每个 episode 随机选取 5 类植物病害,支持集中每类只有 1 个样本,查询集每类包含 15 个样本,则每个 episode 样本共 80 张图像。

1.2 方法

1.2.1 关系网络模型 One-shot 学习网络模型分为 2 种:(1)非线性可学习的神经网络(例如关系网络);(2)线性依靠度量函数的神经网络(例如匹配网络)。本研究使用 one-shot 学习中的关系网络模型^[20-21],由嵌入单元(Embedding module)和关系单元(Relation module)构成(图 2)。嵌入单元由 4 个卷积模块构成,每个卷积模块包含 1 个卷积核尺寸




图1 PlantVillage 数据集植物病害图像数量分布柱状图

Fig.1 The histogram of image numbers of plant disease in PlantVillage

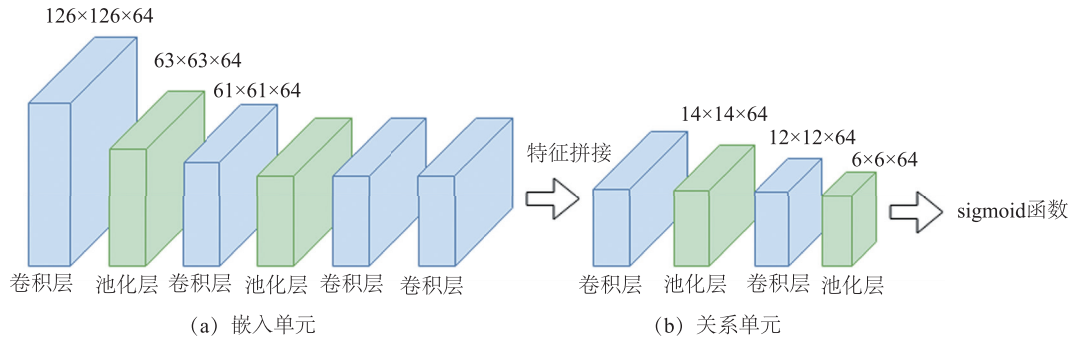


图2 关系网络结构

Fig.2 Structure of relation network

为 3×3 的卷积层, 1 个归一层和 1 个非线性 ReLU 层, 前 2 个卷积模块后有 2×2 的下采样层。嵌入单元的作用是提取查询集和支持集的图像特征。关系单元包含 2 个卷积模块和 2 个全连接层。卷积模块结构与嵌入单元卷积模块结构相同, 每个卷积模块后有 2×2 的下采样层。关系单元的作用是通过嵌入单元提取的图像特征计算关系分数 $r_{i,j}$, 判定是否属于同类。关系网络的输出层函数使用 sigmoid 函数, 函数公式如下:

$$\hat{y} = \sigma(w^T h + b) \quad (1)$$

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (2)$$

式中 σ 为逻辑回归函数, x 为输入特征, w 为权重, h 为模型输出层前一层的输出特征, b 为偏差。

1.2.2 损失函数 类不平衡问题是指在分类任务中不同类别的训练样本差别很大。在 5-way、1-shot 任务中, 每个 episode 输入到关系网络中得到 375 个关系分数, 其中 75 个为正样本, 剩余 300 个样本为

负样本, 正、负样本数量差异大, 存在严重的类不平衡问题。因此, 训练过程中模型更倾向于学习简单的负样本, 使正样本更难分类。为解决上述问题, 本研究使用变化后的二分类交叉熵损失函数代替原关系网络采用的均方误差损失函数 (Mean square error loss, MSE)。

二分类交叉熵损失函数变化过程如下:

$$l_n = -[y_n \lg x_n + (1 - y_n) \lg (1 - x_n)] \quad (3)$$

首先, 解决类不平衡问题。在二分类损失函数的基础上增加控制系数 $\alpha \in [0, 1]$, 当标签为 1 时, 代表正样本, $\alpha_n = \alpha$; 当标签为 0 时, 代表负样本, $\alpha_n = 1 - \alpha$ 。添加控制系数的损失函数称为 α -平衡二分类损失函数, 公式如下:

$$L_n = \alpha_n l_n \quad (4)$$

$$\alpha_n = \begin{cases} \alpha, & y = 1 \\ 1 - \alpha, & \text{其他} \end{cases} \quad (5)$$

其次, 解决正样本难分类问题。根据预测概率 p_n , 添加调节系数 $(1 - p_n)^\gamma$ 解决正样本难分类问题

($\gamma > 0$)。如图 3 所示,当预测概率 p_n 越大时, $(1-p_n)$ 越小,则 $(1-p_n)^\gamma$ 值也越小,样本越容易分类;当预测值概率 p_n 越小时, $(1-p_n)$ 越大,则 $(1-p_n)^\gamma$ 值越大,样本越难分类。公式如下:

$$FL_n = (1 - p_n)^\gamma l_n \quad (6)$$




图 3 添加调节因子 $(1-p_n)^\gamma$ 的损失函数

Fig.3 The loss function adding a modulating factor $(1-p_n)^\gamma$

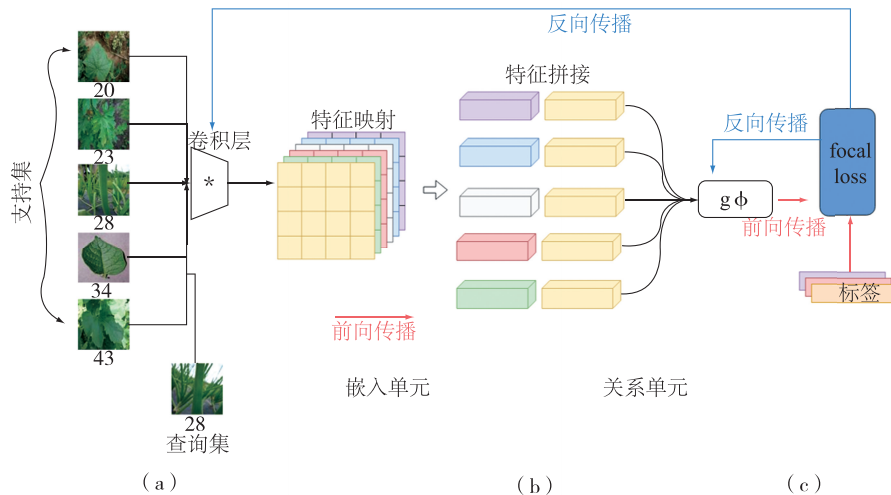
最后,使用 α -平衡二分类损失函数添加调节系数 $(1-p_n)^\gamma$ 定义 FL 损失函数:

$$FL_n = \alpha_n (1 - p_n)^\gamma l_n \quad (7)$$

1.3 5-way、1-shot 学习试验

5-way、1-shot 学习试验流程见图 4。前向传播阶段,支持集和查询集的图像输入到关系模型中(图 4a),由嵌入单元提取它们的图像特征,并将提取的图像特征按照图 4b 进行拼接。拼接后的特征输入到关系单元中,经过全连接层的计算输出关系分数 $r_{i,j}$ 。反向传播阶段,FL 函数通过关系分数 $r_{i,j}$ 和真实标签计算输出误差,使用误差反向传播给隐层对模型参数进行更新。

通过调整 FL 函数的 2 个超参数 α 和 γ ,使模型充分挖掘正样本的特征信息,以此提高精确率获得最优模型。并将最优模型与原始关系网络和匹配网络进行比较,one-shot 学习方法和迁移学习方法进行比较。



红色线为数据前向传播过程,蓝色线为数据反向传播过程。

图 4 5-way、1-shot 学习的流程

Fig.4 The learning process of 5-way and 1-shot

试验软、硬件环境配置见表 1。试验模型是基于开源深度学习框架 Pytorch 的模型。模型使用 Adam 优化策略,学习率为 1×10^{-3} 。训练策略是通过学习大量的 one-shot 任务,将学习到的知识迁移到新的同类任务中。

表 1 试验软硬件配置

Table 1 The software and hardware setup in the experiment

硬件	软件
CPU: 3.40 GHz i7-3770	Ubuntu16.04
RAM: 8 GB	CUDA9.0+CUDNN9.0
GPU: NVIDIA GTX 1070	Pytorch

2 结 果

2.1 焦点损失函数对识别精确率的影响

选取 FL 函数 2 个超参数的值 $\alpha=[0.10, 0.25, 0.50, 0.75, 0.90]$, $\gamma=[0, 0.1, 1.0, 2.0]$ 。当 $\gamma=0$, FL 函数降为 α -平衡二分类损失函数。随着 γ 的增加,易分类的负样本损失值也在降低(图 3)。调整 FL 函数 2 个超参数 α 和 γ ,结果见表 2。当 $\alpha=0.9$, $\gamma=1.0$ 时,模型精确率最高。在 5-way、1-shot 学习任务中,关系模型分别使用 MSE 损失函数和 FL 函数的精确率见图 5。从图 5 可知,使用 FL 函数比使用 MSE 损失函数的精确率提高 4.69 个百分点。

表 2 在 5-way、1-shot 下调整焦点损失函数 (FL) 超参数 α 和 γ 的精确率

Table 2 The accuracy of adjusting the hyper-parameter α and γ of focal loss (FL) in 5-way, 1-shot

γ	α	5-way 1-shot 精确率 (%)
0	0.10	85.97
0	0.25	85.61
0	0.50	87.75
0	0.75	86.79
0	0.90	87.56
0.1	0.10	84.09
0.1	0.25	85.64
0.1	0.50	85.77
0.1	0.75	87.62
0.1	0.90	87.19
1.0	0.10	87.44
1.0	0.25	86.03
1.0	0.50	87.38
1.0	0.75	87.28
1.0	0.90	89.90
2.0	0.10	80.80
2.0	0.25	84.35
2.0	0.50	87.24
2.0	0.75	88.92
2.0	0.90	85.74

2.2 关系网络与匹配网络对小样本植物病害识别精确率的比较

关系网络与匹配网络具有相同的构建模块,即




图 5 分别使用 MSE 损失函数和 FL 损失函数的精确率

Fig.5 Test accuracy of the relation network with MES loss function and focal loss function

卷积层和下采样层。两者区别在于匹配网络使用余弦距离函数判定图像是否为同类,而关系网络使用关系单元计算关系分数判定图像是否为同类。对比关系网络与匹配网络的训练精确率(表 3)发现,匹配网络在 PlantVillage 数据集的 one-shot 学习精确率只有 64.88%,而使用 FL 训练关系网络可获得 89.90%的精确率。由此可见,使用关系单元判定图像相似度的关系网络优于使用度量函数判定图像相似度的匹配网络。

表 3 不同方法对 PlantVillage 中小样本类别的训练精确率

Table 3 The accuracy of different methods for small categories in PlantVillage

学习方法	模型	精确率 (%)
迁移学习	ResNet50	48.00
One-shot 学习	匹配网络	64.88
	原始关系网络	85.21
	改进的关系网络	89.90

2.3 迁移学习方法对小样本植物病害的识别

对于小样本集的植物病害识别,一般使用迁移学习方法^[12]。首先使用大数据集训练预训练模型,再将预训练模型应用于新数据集上实现知识迁移。为了与 one-shot 学习任务匹配,迁移学习中的大数据集包含 50 类,小数据集包含 5 类,每类有 16 个样本。首先使用 ResNet50 在 50 类大数据集上训练预训练模型,然后在小数据集上对预训练模型进行微调。在微调过程中,每类为训练集只分配 1 张图像,剩余的图像用于验证集。one-shot 学习方法与迁移学习方法的比较试验结果(表 3)显示,以 ResNet50 作为预训练模型的精确率只有 48.00%。通过使用

混淆矩阵,对 one-shot 学习方法和迁移学习方法的试验结果进行可视化展示(图 6)。迁移学习方法将类 28(健康大葱)错分给了类 43(健康西瓜),关系网络则对类 28 分类正确,并提高了类 20(健康黄

瓜)和类 23(丝瓜霉霜病)的分类结果。说明在小样本数据集上,one-shot 学习方法优于迁移学习方法,使用 one-shot 学习方法可提高样本识别的精确率。




图 6 微调 ResNet50 (a) 和使用 FL 训练关系网络 (b) 的混淆矩阵

Fig.6 The confusion matrix of fine-tuning ResNet50 (a) and relation network with focal loss (b)

3 结 论

本研究使用 one-shot 学习方法,用关系网络模型识别 PlantVillage 数据集中 8 类样本较少的植物病害。通过使用 FL 损失函数并调整 FL 的超参数,使关系模型充分挖掘正样本的特征,从而提高识别精确率。本研究的模型识别精确率高达 89.90%,比原始关系网络的识别精确率提高了 4.69 个百分点。在 5-way、1-shot 学习任务中,与匹配网络相比,本模型的识别精确率提高了 25.02 个百分点。One-shot 学习方法与迁移学习方法相比,识别精确率提高了 41.9 个百分点。通过使用混淆矩阵,对 one-shot 学习方法和迁移学习方法的试验结果进行可视化展示,结果表明 one-shot 学习方法可提高健康黄瓜、霜霉病丝瓜和健康大葱的识别精确率。

参考文献:

- [1] 王华弟,沈颖,黄茜斌,等.浙江省杨梅病虫害种类与发生规律及其绿色防控技术[J].南方农业学报,2017,48(4):640-646.
- [2] 王震,李金秀,张彬,等.赤霉病对江苏省北部小麦主栽品种品质的影响[J].江苏农业科学,2018,46(13):105-108.
- [3] 周云成,许童羽,郑伟,等.基于深度卷积神经网络的番茄主要器官分类识别方法[J].农业工程学报,2017,33(15):219-

226.

- [4] 王臻,武新慧,李志伟,等.基于卷积神经网络提取多尺度分层特征识别玉米杂草[J].农业工程学报,2018,34(5):144-151.
- [5] 刘圆宇,冯全.基于卷积神经网络的葡萄叶片检测[J].西北大学学报(自然科学版),2017,47(4):505-512.
- [6] 孙俊,谭文军,毛罕平,等.基于改进卷积神经网络的多种植物叶片病害识别[J].农业工程学报,2017,33(19):209-215.
- [7] LIU B, ZHANG Y, HE D, et al. Identification of apple leaf diseases based on deep convolutional neural networks[J].Symmetry, 2018,10(1):1-16.
- [8] AMARA J, BOUAZIZ B, ALGERGAWY A, et al. A deep learning-based approach for banana leaf diseases classification[C].Gesellschaft Für Informatik, Bonn; Lecture Notes in Informatics, 2017:79-88.
- [9] BRAHIMI M, BOUKHALFA K, MOUSSAOUI A. Deep learning for tomato disease: Classification and symptoms visualization[J].Applied Artificial Intelligence,2017,31(4):299-315.
- [10] MOHANTY S P, HUGHES D P, SALATHE M. Using deep learning for image-based plant disease detection[J].Frontiers in Plant Science,2016,7:1-10.
- [11] CRUZ A, LUVISI A, BELLIS L D, et al. X-FIDO: An effective application for detecting olive quick decline syndrome with deep learning and data fusion[J].Frontiers in Plant Science,2017,8:1741.
- [12] FERENTINOS K P. Deep learning models for plant disease detection and diagnosis[J].Computers and Electronics in Agriculture,

- 2018, 145:311-318.
- [13] LI F F, FERGUS R, PERONA P. One-shot learning of object categories[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(4):594-611.
- [14] LAKE B M, SALAKHUTDINOV R, TENENBAUM J B. Human-level concept learning through probabilistic program induction[J]. Science, 2015, 350(6266):1332-1338.
- [15] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-Learning for fast adaptation of deep networks[C]. Sydney Australia; International Conference on Machine Learning, 2017:1126-1135.
- [16] RAVI S, LAROCHELLE H. Optimization as a model for few-shot learning[C]. San Juan, Puerto Rico; International Conference on Learning Representation, 2016:1-11.
- [17] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for One-shot image recognition[C]. Lille France; International Conference on Machine Learning, 2015:1-8.
- [18] VINYALS O, BLUNDELL C, LILICRAB T, et al. Matching network for one shot learning[J]. In Advances in Neural Information Processing Systems, 2016, 7:3630-3638.
- [19] SNELL J, SWERSKY K, ZEMEL R S. Prototypical networks for few-shot learning[C]. Long Beach; Thirty-first Conference on Neural Information Processing Systems, 2017:4077-4087.
- [20] SUNG F, YANG Y, ZHANG L. Learning to Compare: Relation network for few-shot learning[C]. Hawaii USA; IEEE Conference on Computer Vision and Pattern Recognition, 2017:1199-1208.
- [21] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]. Venice Italy; International Conference on Computer Vision, 2017:2999-3007.

(责任编辑:张震林)