

基于卷积神经网络融合编码与解码特征的降水强度识别

林梦翔¹, 黄秀萍¹, 林志玮^{1,2,3,4*}, 洪思弟⁵, 刘金福^{1,2}¹福建农林大学计算机与信息学院, 福建 福州 350002;²福建农林大学海峡自然保护区研究中心福建省高校生态与资源统计重点实验室, 福建 福州 350002;³福建农林大学林学院, 福建 福州 350002;⁴福建农林大学林学博士后流动站, 福建 福州 350002;⁵莆田学院新工科产业学院, 福建 莆田 351100

摘要 为高效地利用红外降雨图进行雨量强度分类, 提出了一个融合编码与解码卷积特征的雨量强度识别模型。引入编码与解码卷积于深度卷积神经网络分类模型中, 在减少局部信息丢失的同时提取深层次的雨纹信息特征。于编码、解码卷积模块中考虑多尺度感受野卷积, 融合不同范围的局部特征, 同时在解码时融合相同尺度的编码与解码卷积特征图, 提高特征利用率, 从而构建一种融合编码与解码卷积特征的雨量强度识别模型。所提模型的分类精度优于主流卷积神经网络框架, 分类正确率最高达到了 91.7%, 且消融实验结果验证了编码与解码模块的有效性。

关键词 成像系统; 降雨强度识别; 卷积神经网络; 编码特征; 解码特征; 特征融合

中图分类号 TP183;P409

文献标志码 A

DOI: 10.3788/LOP212668

Precipitation Intensity Recognition Based on Convolution Neural Network with Fused Encoded and Decoded Features

Lin Mengxiang¹, Huang Xiuping¹, Lin Zhiwei^{1,2,3,4*}, Hong Sidi⁵, Liu Jinfu^{1,2}¹College of Computer and Information Science, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;²Key Laboratory for Ecology and Resource Statistics of Fujian Province, Cross-Strait Nature Reserve Research Center, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;³College of Forestry, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;⁴Forestry Post-Doctoral Station, Fujian Agriculture and Forestry University, Fuzhou 350002, Fujian, China;⁵New Engineering Industry College, Putian University, Putian 351100, Fujian, China

Abstract In order to efficiently use infrared precipitation images to determine the precipitation intensity, a precipitation intensity recognition model with fused encoded and decoded features has been proposed. The coding and decoding convolution is introduced into the deep convolution neural network classification model, which can extract the deep-seated features of rain information while reducing the loss of local information. In the coding and decoding convolution module, multi-scale receptive field convolution is considered, and local features in different ranges are fused. At the same time, coding and decoding convolution feature maps of the same scale are fused during decoding, so as to improve feature utilization. Thus, a precipitation intensity recognition model integrating coding and decoding convolution features is constructed. The proposed model has the highest classification accuracy of 91.7% compared to state-of-the-art methods. Moreover, an ablation experiment demonstrates the effectiveness of the proposed encoded and decoded model.

Key words imaging systems; precipitation intensity recognition; convolutional neural network; encoded feature; decoded feature; feature fusion

收稿日期: 2021-10-08; 修回日期: 2021-11-06; 录用日期: 2021-12-13; 网络首发日期: 2021-12-24

基金项目: 教育部人文社会科学研究项目(18YJCZH093)、海峡博士后交流资助计划、中国博士后科学基金面上项目(2018M632565)、福建省自然科学基金(2021J01128)

通信作者: *cwlin@fafu.edu.cn

1 引言

随着全球经济的快速发展,工业发展带来的大气问题日益突出,不精确的预报系统将会给地区带来较大的经济损失,而实时的雨量强度播报能够帮助活动开展,因此精确和实时的天气监测系统是社会有序、稳定发展的保障。雨量强度识别作为天气预报中重要的组成部分,深入了解降雨特性有助于居民出行、防洪救灾、农业灌溉等多种重要活动的开展^[1]。

降雨是全球水循环的重要组成部分^[2],为了更好地检测雨情,人们设计了雨量计^[3-4]、多普勒天气雷达^[5-6]、卫星遥感^[7]等降雨测量设备及结合雨量站网、天气雷达、卫星遥感的多源降雨估计,但这些设备的建设和维护成本过高,且在多源降雨数据进行融合的过程中,由于降雨本身在不同尺度上存在差异性,对数据的整合是一大难题^[8]。

随着人工智能的发展,许多机器学习分类算法被用于卫星图像分析,包括人工神经网络^[9]、支持向量机^[10]、随机森林^[11]、朴素贝叶斯^[12]等。在对卫星降水的估计中,使用以上算法作为分类器对卫星云图的像素进行识别和分类,然后将分类好的像素给定一个降水率。不同算法分类性能的主要差异在于对云图像素点的识别及分类,为了提高像素点的识别精度,研究人员通过组合分类器的方法来优化识别和分类^[13]。近年来,深度神经网络被广泛用于多个领域^[14-15],它能够进行复杂的特征提取,在很多应用中取得了重大突破。目前不少学者也将深度神经网络引入降雨量的估计中^[16-18],将雨量计测得的数据作为真实标签,对天气雷达、卫星获取的数据建立深度神经网络模型并进行特征提取,从而实现降雨量的估计与预测。但存在一定困难,一方面是数据获取的成本高,另一方面是多源降雨数据融合困难,且雷达和卫星影像数据是针对大范围的降雨强度识别,对于范围内更加细致的地区,降雨量估计精度低。本团队先前研究^[19]已经证明深度神经网络结合降雨光学图像进行降雨强度识别分析的可行性,但没有对模型进行改进使其具有更好的识别能力。因此,本文基于基础模型提出了多感受野编码解码模块并构造了一个融合编码与解码卷积特征的雨量强度识别模型。

视频监控已经广泛应用于生活中的各个领域,通过广泛设置监控设备不仅能够获得各地区的降雨图像信息,还能更容易地获得短时间段内的降雨数据。但是传统可见光的视频监控图像会受到雾天、粉尘等影响^[20],使得监控图像质量下降,从而不利于对图像中的雨滴、雨纹特征进行提取。此外,还存在夜间光照弱的环境下难以对目标物体进行识别的问题,而红外图像能够克服大雾、夜间光强弱、粉尘的影响,具有抗干扰能力强及夜间侦察的特性^[21],能够捕获降雨雨纹等细节信息。为了高效地利用红外降雨图进行雨

量强度分类,本文提出了一个融合编码与解码卷积特征的雨量强度识别模型。所提模型在深度卷积神经网络的基础上引入编码解码模块于深度卷积神经网络分类模型中,在减少局部信息丢失的同时提取深层次的雨纹信息特征。该模块以编码的方式提取特征信息并缩小特征图,为了增加后续局部信息的提取并减少局部信息丢失,再以解码的方式反卷积回原大小。编码解码模块中采用多尺度感受野卷积,提取不同范围的局部特征并融合,同时在解码时再融合相同尺度的编码与解码特征图,提高特征利用率。希望能够与监控系统结合,实现实时且小范围的降雨强度监测,为气象部门解决利用雨量计或小型自动气象站无法实现密集监测的技术问题。该方法只需常见且必要的摄像头,能够为无法安装雨量计及小型自动气象站的区域提供新的监测方式,为气象部门提供新的降雨监测方法。

2 所提方法

2.1 雨量强度识别模型

红外降雨图像数据表明,环境的差异(比如风向、光照、背景等)会影响雨纹的呈现状态,所以为了尽可能获取所有状态下的雨纹特征,本研究提出了一种融合编码与解码特征的雨量强度识别模型,如图 1 所示,对应的伪代码如图 2 所示。首先将输入的红外降雨图像经过 1 层 7×7 卷积层和 1 层 3×3 最大池化层得到的特征图作为编码解码模块的输入,在进行 7×7 卷积之后,对得到的特征进行一次正则化 Batch Normalization 和一次 ReLU 激活,红外降雨图像经过上述的操作后可得到一个拥有较大感受野的特征,在缩小特征尺寸的同时提取了大范围的图像信息,以便后续更加注重细节特征的提取。经过第 1 次卷积得到全局特征后,将其输入编码模块中,编码模块包含 2 层多感受野卷积,多感受野卷积拥有 4 个分支,在每层的编码模块中遍历该 4 个分支的操作,并将其结果在通道维度进行串联后再经过池化降低尺寸,得到该层结果后输入下一层。而在解码模块中,首先上采样其输入以扩大尺寸,然后与编码模块一致,进行多感受野卷积的遍历及通道串联,但不再进行池化而是将编码与解码模块中同尺寸的特征进行正反两次串联,得到的结果同样输入下一层。最后再经过卷积神经网络(CNN)、全连接(FC)和 Softmax 函数得到降雨强度结果,并将该结果通过交叉熵计算损失,并通过反向传播更新网络。

所采用的 CNN 是 ResNet^[22] 或 DenseNet^[23] 除去第 1 层卷积后剩余的网络,全连接层将网络输出的特征进行全局平均池化后利用输出通道为类别数的 1×1 卷积得到每类识别结果。编码解码模块中“MRF-Conv”表示多感受野卷积(MRF-Conv)。Softmax 函数能够求得每一类雨量对应的概率值,概率最大的为最终的分类结果。具体的模型网络层参数如表 1 所示,其中多感受野卷积操作一致,因此只在第 1 次出现

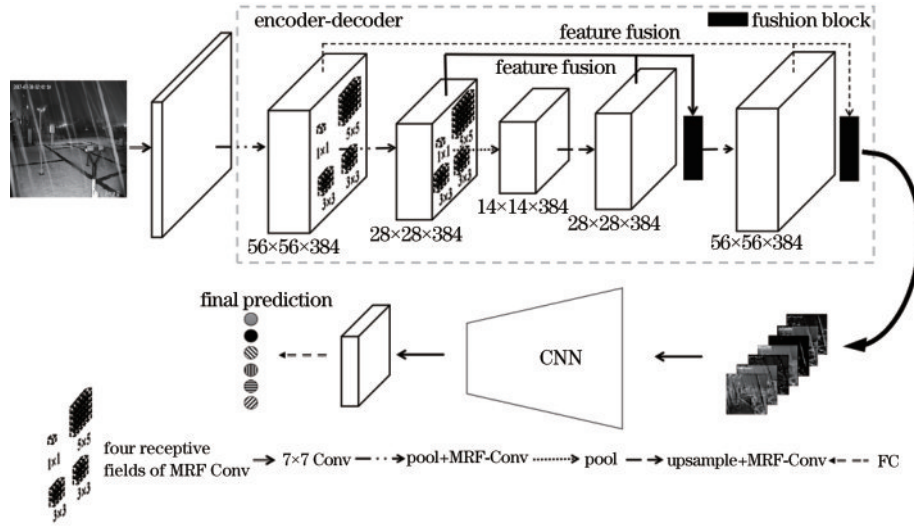


图 1 融合编码与解码卷积特征的雨量强度识别模型示意图

Fig. 1 Schematic diagram of precipitation intensity recognition model fusing encoded and decoded features

Input:

Infrared images of rainfall I ; #降雨图像输入
 Maximum number of iteration N #迭代次数

Output:

Rainfall intensity Y #降雨强度

1: **for** $n = 1$ to N **do** #开始迭代

2: Using 7×7 convolution and 3×3 max pooling to extract global features F_{gb} ; #利用卷积和池化提取全局特征

3: **for** $e_i = 1$ to layer number 2 of encoder module **do** #进行2次编码操作

4: **for** $b_i = 1$ to branch number 4 of MRF-Conv **do** #分别进行多感受野卷积中的4条分支操作

5: Performing the corresponding operation of convolution layer on current receptive field to obtain different receptive field features F_{b_i} ; #进行多感受野卷积

6: Concatenating different receptive field features F_{b_i} and pooling the result F_{e_i} to get output O_{e_i} of encoder module; #将得到的不同感受野特征进行串联并池化

7: **for** $d_i = 1$ to layer number 2 of decoder module **do** #进行2次解码操作

8: Upsampling the input double its size; #进行上采样操作

9: **for** $b_j = 1$ to branch number 4 of MRF-Conv **do** #分别进行多感受野卷积中的4条分支操作

10: Performing the corresponding operation of convolution layer on current receptive field to obtain different receptive field features F_{b_j} ; #进行多感受野卷积

11: Concatenating different receptive field features F_{b_j} to get result F_{d_i} ; #将得到的不同感受野特征进行串联

12: Concatenating $[F_{e_i}, F_{d_i}, F_{d_i}, F_{e_i}]$ and convoluting to get output O_{d_i} of decoder module; #将同尺寸的编码特征和解码特征进行正反串联

13: Inputting the output O_{d_2} of the Encoder-Decoder module into a convolutional neural network to obtain the result O_{cnn} ; #将编码解码模块输出输入后续的卷积神经网络中

14: Using $Y = \text{argmax}\{\text{Softmax}[\text{FC}(O_{cnn})]\}$ to get the rainfall intensity Y ; #获得对应图片的降雨强度

15: Loss = Cross entropy loss(Y); #计算模型损失

16: Back-propagation (Loss); #反向传播更新模型

17: **end for** #结束迭代

18: **return** Y #输出识别的降雨强度结果

图 2 降雨强度识别模型伪代码

Fig. 2 Pseudocode of precipitation intensity recognition model

表 1 所提模型各层参数
Table 1 Parameters of each layer of proposed model

Layer	Parameters of layer	Output size
Input		224×224×3
Conv	7×7 Conv, 64, stride 2	112×112×64
Pool	3×3, maxpool, stride 2	56×56×64
MRF-Conv	Branch 1 1×1 Conv, 96, stride 1	Concatenate 56×56×384
	Branch 2 1×1 Conv, 64, stride 1 3×3 Conv, 96, stride 1	
	Branch 3 1×1 Conv, 64, stride 1 3×3 Conv, 96, stride 1 3×3 Conv, 96, stride 1	
	Branch 4 3×3, avgpool, stride 1 1×1 Conv, 96, stride 1	
Pool	2×2, maxpool, stride 2	28×28×384
MRF-Conv.	As above	28×28×384
Pool	2×2, maxpool, stride 2	14×14×384
Upsample	2×2 Deconv, 64, stride 2	28×28×64
MRF-Conv	As above	28×28×384
Fusion block	Concatenate 3×3 Conv, 96, stride 1	28×28×96
Upsample	2×2 Deconv, 64, stride 2	56×56×64
MRF-Conv	As above	56×56×384
Fusion block	Concatenate 3×3 Conv, 96, stride 1	56×56×96
CNN	Resnet or DenseNet	7×7×1024 or 7×7×2048
FC	Global average pool, FC	1×1×6

详细列出参数,后面的与其一致。网络层参数中“7×7 Conv, 64, stride 2”表示使用 64 个步长为 2、大小为 7×7 的卷积核进行卷积,“3×3, maxpool, stride 2”表示进行大小为 3×3、步长为 2 的最大池化,“Deconv”表示反卷积,用于放大特征图。

2.2 多感受野编码解码模块

由于红外降雨图像中雨滴、雨纹等信息位置分布的差异性及不同雨量下雨滴、雨纹大小的差异性,使用的卷积核大小将决定提取的特征分布,较小的卷积核偏向于提取更局部的特征信息,而较大的卷积核偏向于提取更全局性的图像特征。但是要保证输出特征映射到输入图像上的大小也就是感受野足够大,如果仅仅使用较小的卷积核,则往往需要更深层的网络,这就意味着容易导致网络过拟合。而仅使用较大的卷积核将会忽略局部信息,并且较大卷积核的堆叠将使得计算量增大,导致模型的效率下降。因此,所提方法采用多感受野卷积保证编码解码模块输出特征的感受野足够大并减小模型的深度。

多感受野编码解码模块如图 1 虚线框所示,其中多感受野卷积块的形式如 GoogleNet^[24]中的模块, fusion block 包含 feature fusion 与 1 层卷积, feature fusion 指将同分辨率特征融合,特征图尺寸如 56×56×384 分别指特征图的宽、高和通道数。首先,通过

多感受野卷积块和最大池化层编码,然后通过上采样和多感受野卷积块解码,并在解码时对编码解码中同尺寸的多感受野卷积特征进行融合。编码即对图像的特征进行浓缩,在缩小特征图尺寸的同时学习到更多的特征。解码则扩大特征,保证特征尺寸能够支撑后续信息的提取。多感受野卷积块不缩小特征尺寸,而是进行不同感受野的特征学习。多感受野卷积之后再通过最大池化层来进一步扩大感受野并浓缩特征,保留学习到的较为有效的特征,使得特征尺寸减小。图 1 中,多感受野卷积块拥有 4 种感受野,由 4 个子分支组成,通过增加网络宽度来提取到更多的特征:第 1 条子分支输出特征图上 1 个像素对应输入特征图上的 1 个像素大小,感受野为 1×1,偏向于雨纹等细节信息提取;第 2 条子分支与第 4 条分支对应感受野都为 3×3 区域,偏向于雨滴等部分信息提取;第 3 条子分支的感受野大小为 5×5 区域,偏向于降雨场景等较大范围信息提取。因此,该卷积块在同一层中通过 4 条子分支中得到了具有不同感受野的特征信息,并对这些特征进行合并作为该模块的输出。

3 实验结果与分析

3.1 数据集

实验数据来自福建省福州市的 8 个气象监测站

点,分别为晋安区、长乐区、福清市、连江县、罗源县、闽侯县、闽清县及永泰县气象站。气象站点的数据获取形式为固定角度及固定地点监控拍摄,数据通过气象站的红外监控摄像头(海康,DS-2DF82HJ)拍摄,该摄像头拥有红外夜视 200 m 变焦镜头,提供彩色与红外两种监控图像,以 JPG 格式呈现,图像大小为 1920×1080,并分别记录有拍摄时段的降雨量大小。于是,按照《降水等级标准-国标》中 1 h 降水量等级划分标准,并依靠人工标定的方式,将从这些气象站收集到的降雨图像数据进行降雨强度分度,其中降雨量小于 0.1 mm/h 的图像标定为零星小雨,降雨量在 0.1~1.5 mm/h 之间的标定为小雨,降雨量在 1.6~6.9 mm/h 的标定为中雨,降雨量在 7.0~14.9 mm/h

的标记为大雨,降雨量在 15.0~39.9 mm/h 的标记为暴雨,降雨量在 40.0~49.9 mm/h 的标记为大暴雨,降雨量大于 50.0 mm/h 的标记为特大暴雨。

由于收集的数据集里不包含特大暴雨,于是该标定后的数据集共包括 6 类降雨强度图像,总共 9394 张。按照气象站点的话,其中晋安区有 1150 张图像,长乐区有 1194 张,福清市有 1226 张,连江县有 1137 张,罗源县有 1215 张,闽侯县有 1149 张,闽清县有 1149 张,永泰县有 1174 张,各个气象站点的降雨图像数据量分布较为均匀。而按照降雨强度的话,如图 3 所示,降雨强度为零星小雨的有 1412 张,小雨有 4574 张,中雨有 2870 张,大雨有 434 张,暴雨有 92 张,大暴雨仅收集到 12 张。

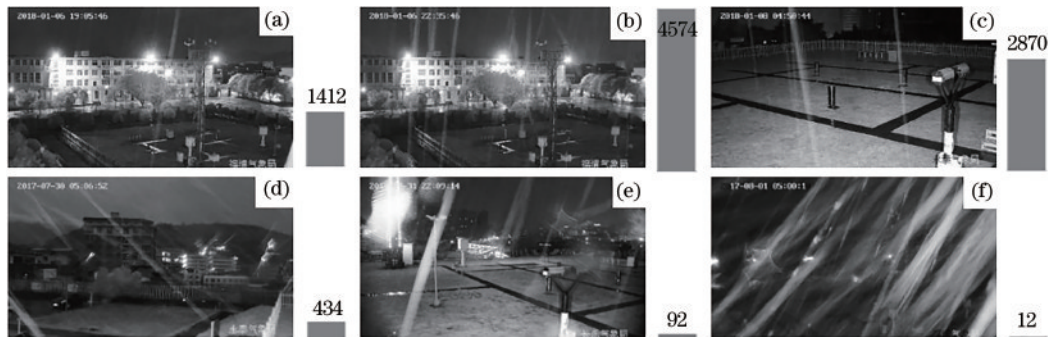


图 3 各降雨强度降雨图像示意图。(a)零星小雨;(b)小雨;(c)中雨;(d)大雨;(e)暴雨;(f)大暴雨

Fig. 3 Rainfall images of each rainfall intensity. (a) Scattered light rain; (b) light rain; (c) moderate rain; (d) heavy rain; (e) rainstorm; (f) heavy rainstorm

3.2 实验设置

操作系统为 Ubuntu16.04,网络开发框架为 Tensorflow,显卡为 GTX1080Ti (11 GB),CPU 为 Core i7。基于降雨图像数据集,依据气象站点及降雨强度采用随机抽样对数据集进行训练集与测试集的划分,划分比例为 7:3,得到的训练集有 6594 张图像,测试集有 2800 张图像。原始图像缩放至 224×224,模型训练优化器使用动量梯度下降法 (MSGD),学习率 (learning rate) 为 0.0001,动量为 0.9, batch size 为 32, epoch 为 400。

3.3 有效性分析

将所提模块分别添加到 ResNet 及 DenseNet 框架中对降雨强度进行识别,并与这两个基本框架的识别精度进行比较,来验证所提模块的有效性,测试识别结果如表 2 所示,训练识别结果皆为 100%。从不同降雨强度识别精度分析:在 ResNet 基本框架上,Proposed-ResNet-50 框架在零星小雨、小雨、中雨达到最高识别精度,分别为 97.1%、94.5% 和 89.0%;对大雨最好的识别精度为 67.2%,由 ResNet-101 框架得到;暴雨最好的识别精度为 84%,在 Proposed-ResNet-101、152 均出现;而大暴雨最好精度为 66.7%,出现在 Proposed-ResNet-101 框架。即在数据量较大的零星小雨、小雨及中雨上,所提方法识别正确率均较高,而在数据量较

小的大雨上,所提方法的正确率亦达到了 66.4%,而对于暴雨和大暴雨这两种降雨强度,因为数据量极少,在识别模型训练阶段,模型拟合较为困难,学习不充分,导致识别正确率波动较大。在 DenseNet 基本框架上:零星小雨、小雨、中雨及暴雨的最好识别精度均出现在 Proposed-DenseNet 框架上,分别为 94%、92.1%、90.9% 和 33%;而大雨和暴雨最好识别精度出现在 DenseNet 框架上,与 ResNet 为基本框架的结果相似。由于大雨、暴雨、大暴雨数据量较少,正确率波动较大,所提方法的识别精度大部分处于最高和次高的状态,而从零星小雨、小雨和中雨这 3 种数据量较大的降雨强度上看,所提方法均具有较好的识别精度,说明了所提方法的有效性。从识别总精度分析:在 ResNet 基本框架上,取 50、101 及 152 层这 3 种不同深度时,ResNet 在 101 层时取得了最好的识别精度,为 90.5%,其参数量达到 42.51×10^6 ;而所提方法,在 Proposed-ResNet 的 50 层时取得最好识别精度,有 91.7%,较 ResNet 最好结果提升了 1.2 个百分点,并且其参数量为 27.28×10^6 ,具有更高的识别效率;在 DenseNet 基本框架上取 63、121 及 169 层这 3 种不同深度时,DenseNet 在 121 层时取得最好的识别精度,为 87.8%,参数量为 6.96×10^6 ,而 Proposed-DenseNet 在 63 层时取得最好识别精度,为 89.8%,较 DenseNet 提升了 2 个百分点,其参数为

表 2 基于 ResNet 和 DenseNet 框架在不同降雨强度上的识别结果

Table 2 Recognition results of different rainfall intensities based on framework of ResNet and DenseNet

Model	Class							Parameter / 10 ⁶
	Scattered light rain / %	Light rain / %	Moderate rain / %	Heavy rain / %	Rainstorm / %	Heavy rainstorm / %	Overall accuracy / %	
ResNet-50	92.9	94.1	85.8	56.8	72.0	0.0	89.4	23.52
ResNet-101	96.2	93.4	87.3	67.2	72.0	33.3	90.5	42.51
ResNet-152	92.4	91.9	82.6	49.6	76.0	0.0	87.0	58.16
Proposed-ResNet-50	97.1	94.5	89.0	66.4	76.0	0.0	91.7	27.28
Proposed-ResNet-101	95.0	91.7	86.6	62.4	84.0	66.7	89.2	46.27
Proposed-ResNet-152	93.3	91.1	83.6	60.8	84.0	33.3	87.6	61.91
DenseNet-63	93.1	89.7	86.2	50.4	84.0	0.0	87.2	2.31
DenseNet-121	93.8	91.0	84.8	56.8	76.0	0.0	87.8	6.96
DenseNet-169	92.4	90.7	82.8	61.6	84.0	0.0	87.1	12.49
Proposed-DenseNet-63	93.8	91.7	90.9	50.4	80.0	0.0	89.8	6.07
Proposed-DenseNet-121	94.0	91.6	88.7	46.4	72.0	33.3	88.8	10.74
Proposed-DenseNet-169	89.8	92.1	87.2	50.4	60.0	0.0	88.0	16.27

6.07×10^6 , 相比 DenseNet 在识别效率上亦有所提升。从训练测试损失分析。所提模型的训练测试损失曲线如图 4 所示, 训练时所有曲线都趋于平稳, 说明模型已

经收敛, 而测试时曲线同样趋于平稳, 部分曲线存在波动, 但该波动属于正常范围, 没出现损失不降反而不断上升的反弹情况, 因此模型没有过拟合, 是可行的。

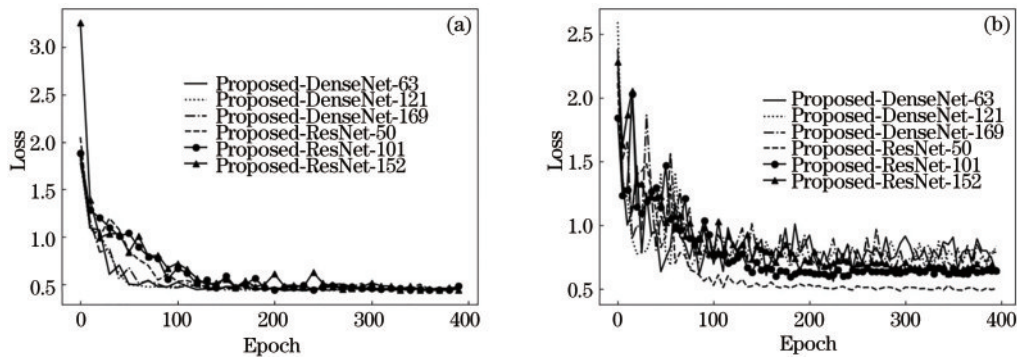


图 4 训练测试损失曲线图。(a)训练损失; (b)测试损失

Fig. 4 Training and testing loss curves. (a) Training loss; (b) testing loss

综上所述, 所提方法在零星小雨、小雨、中雨、大暴雨上均具有更好的识别精度, 且具有更高的识别总精度, 验证了所提方法的有效性。此外, 所提方法具有更少的参数量, 表明所提方法能够降低识别模型的复杂性。

3.4 消融实验

为了分析所提编码解码模块及其融合中串联操作的可行性, 将 CNN 基本框架、去掉特征融合的编码解码模块及不同特征融合方式进行了比较分析, 表 3 展示了消融实验的结果, 其中 Concat-once 表示串联一次, Concat-twice 表示串联两次, 特征串联两次的组合方式中, A 指编码时串联完的特征, B 指解码时串联完的特征, 组合名称顺序即串联顺序, 如 ABBA 指先将 A 特征串联在 B 特征上再串联在 B 特征上最后串联在 A 特征上。从表 3 可以看出: 去掉特征融合的 Proposed-ResNet-50 的正确率为 89.7%, 与只串联一次一致, 相较基本框架 ResNet-50 提升了 0.3 个百分点; 串联两次

的框架都优于串联一次的框架, 最好的为重叠式串联 AABB 和正反两次串联 ABBA, 正确率为 91.7%, 相较去掉特征融合和串联一次的结果提升了 2 个百分点; 相似的是, 去掉特征融合的 Proposed-DenseNet-63 的正确率为 88.3%, 比基本框架提升了 1.1 个百分点; 而采用正反两次串联 ABBA 的框架是最优的, 为 89.8%, 相较去掉特征融合的框架亦提升了 1.5 个百分点, 相较串联一次提升了 1 个百分点。综合两种基础框架, 正反两次串联是最稳定有效的。

综上所述, 去掉特征融合的编码解码网络在提升网络分类性能方面能够发挥积极作用, 而通过特征融合对编码网络与解码网络的特征进行融合, 使得编码解码模块在降雨强度分类性能上有了进一步的提升, 且融合中的两次串联能够利用两倍的特征信息提高特征利用率, 使得网络性能再次提升, 而两次串联中的正反两次串联拥有更加稳定有效的性能。这验证了

表 3 消融实验结果
Table 3 Results of ablation experiment

ResNet-50	Encoder-decoder	Fusion			Accuracy / %	Dense Net-63	Encoder-decoder	Fusion			Accuracy / %		
		Concat- once	Concat-twice					Concat- once	Concat-twice				
			AA BB	AB AB					AB BA	AA BB		AB AB	AB BA
✓					89.4	✓				87.2			
✓	✓				89.7	✓	✓			88.3			
✓	✓	✓			89.7	✓	✓	✓		88.8			
✓	✓		✓		91.7	✓	✓		✓	88.5			
✓	✓			✓	90.5	✓	✓		✓	89.0			
✓	✓			✓	91.7	✓	✓		✓	89.8			

所提特征融合及编码解码模块的可行性。

3.5 可视化分析

为了更好地展示所提框架对于雨纹特征的提取，将特征图可视化来展示所提模型的关注点，特征图可视化可以更加直接观察到模型学习特征的方式。图 5 展示的是多感受野卷积块中各分支的特征图：图 5(a) 为第 1 条分支的特征图，该分支感受野为 1×1 ，注重于提取小范围的雨纹信息，因此图 5(a) 中的特征较细，边缘轮廓信息较明显；图 5(b) 为 2 条分支的特征图，该分支感受野为 3×3 ，注重于提取中范围的雨纹信息，因此图 5(b) 中的特征范围相较于图 5(a) 更大一些，但轮廓信息不如其明显；图 5(c) 为第 3 条分支的特征图，该分支感受野为 5×5 ，注重于提取较大范围

的雨纹信息，图 5(c) 中的特征范围是最大的，由于其感受野较大，边缘部分包含相对较多的上下界信息，呈现较宽的轮廓；图 5(d) 为第 4 条分支的特征图，该感受野为 3×3 ，注重于提取中范围的雨纹信息，由于该分支经过平均池化层，所以该分支特征图相较于其他分支会比较模糊，其特征范围与分支 2 相似属于中范围。图 5 的特征图对于雨纹信息的提取范围与其感受野息息相关，感受野较大的分支其特征图的雨纹信息范围相对较大。所提模型还能够获取所有状态下的雨纹特征，如图 6 所示，每种降雨强度下的雨纹都有其特点，降雨强度增大，雨纹会渐渐变得更加密集、更加宽，所提模型对于每种降雨强度的雨纹信息都能够一一获取。当降雨强度较小时，所提模型专注提取场




图 5 多感受野卷积的各分支特征图。(a)分支 1；(b)分支 2；(c)分支 3；(d)分支 4

Fig. 5 Feature maps of each branch in multi-receptive field convolution. (a) Branch 1; (b) branch 2; (c) branch 3; (d) branch 4

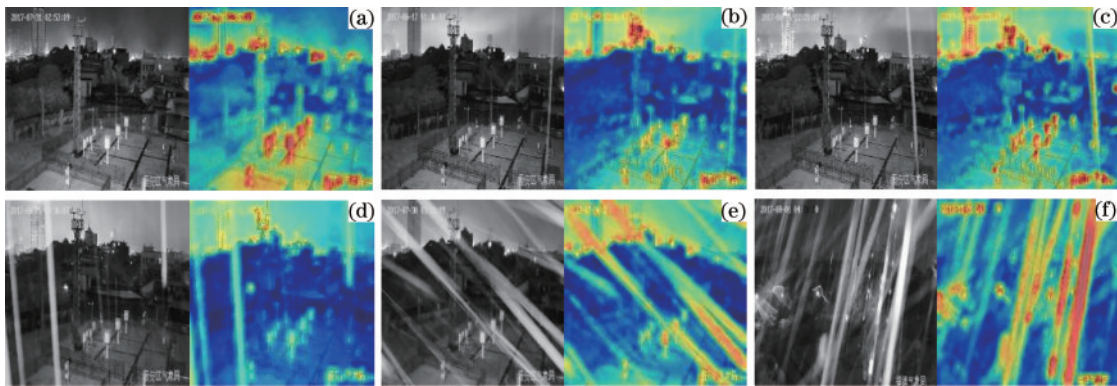


图 6 各降雨强度下所提模型热度图。(a)零星小雨；(b)小雨；(c)中雨；(d)大雨；(e)暴雨；(f)大暴雨

Fig. 6 Heat map of the proposed model under each rainfall intensity. (a) Scattered light rain; (b) light rain; (c) moderate rain; (d) heavy rain; (e) rainstorm; (f) heavy rainstorm

景信息,以此分辨出零星小雨或小雨等状态,随着降雨强度增大,雨纹渐渐明显,所提模型也更加专注于雨纹特征的提取。

4 讨 论

4.1 所提模型与其他 CNN 的对比分析

为了更进一步地说明所提模型的有效性,采用已有卷积神经网络建立降雨强度识别模型,与所提降雨强度识别模型进行比较,并通过比较各个模型的参数量,来说明所提模型的可行性及高效性。不同模型进行对比分析时存在两种参数设置:1)不同模型使用多种参数设置;2)不同模型在相同实验设置下比较^[25-26]。前者通过多种设置拥有多种结果比较,后者比较形式更加直接,能够体现模型适用性,本研究在比较时选择后者。在有效性方面。基于 Inception^[24,27-28]、ResNet^[22]、DenseNet^[23]、VGG^[29]、DCNet^[30]及细粒度识别中表现较好的 NTS^[31]和 DCL^[32]及融合多分辨率网络 HRNet^[33]进行降雨强度识别模型的搭建,NTS为利用注意力机制的多分支识别网络,DCL为提取多种判别性局部细节的识别网络。ResNet和 DenseNet 的实验结果在第 3.3 节已给出,表 4 展示了其余模型与所提模

表 4 与主流 CNN 的识别精度比较

Table 4 Comparison of recognition accuracy with popular CNN

Model	Year	Accuracy / %	Parameter / 10 ⁶
VGG-16	2015	82.6	134.29
VGG-19	2015	81.6	139.59
Inception-V2	2015	83.5	10.16
Inception-V3	2016	87.0	22.77
Inception-V4	2017	86.4	42.14
ResNet-50	2016	89.4	23.52
ResNet-101	2016	90.5	42.51
ResNet-152	2016	87.0	58.16
DenseNet-63	2017	87.2	2.31
DenseNet-121	2017	87.8	6.96
DenseNet-169	2017	87.1	12.49
DCNet-18	2017	87.0	41.93
DCNet-101	2017	85.9	42.58
NTS	2018	84.0	26.25
DCL	2019	86.6	23.52
HRNet	2020	87.6	39.20
Proposed-DenseNet-63	2021	89.8	6.07
Proposed-ResNet-50	2021	91.7	27.28

表 5 训练集与测试集为不同地点的识别精度比较

Table 5 Comparison of recognition accuracy with different locations between training set and test set

unit: %

Place of training	Place of testing	ResNet-101	Proposed-ResNet-50
Changle, Jinan, Minhou, Minqing, Fuqing, Yongtai	Lianjiang, Luoyuan	52.7	54.1
Changle, Jinan, Fuqing, Yongtai, Lianjiang, Luoyuan	Minhou, Minqing	51.6	60.6
Changle, Jinan, Minhou, Minqing, Lianjiang, Luoyuan	Fuqing, Yongtai	49.7	52.8
Minhou, Minqing, Fuqing, Yongtai, Lianjiang, Luoyuan	Changle, Jinan	46.4	46.7

型的实验结果。从表 4 可以看到:在比较模型中,ResNet-101 的识别精度最高,有 90.5%,而 DCNet-18 为 87.0%,其识别有效性均不及 ResNet 及 DenseNet 模型,细粒度识别主流网络 NTS 和 DCL 对降雨数据的识别效果并不理想,只有 84% 和 86.6%;而 Proposed-ResNet-50 识别精度最高,为 91.7%,验证了所提模型的可行性、有效性。表 4 数据表明:识别精度最高的 Proposed-ResNet-50,其参数量并不高,与精度次高的 ResNet-101 对比,参数量更小,其中参数量最小的模型为 DenseNet-63;而 Proposed-DenseNet-63 的参数量只稍微多了一些,但识别效果却优秀了很多,精度达到 89.8%;剩余参数量较小的模型,识别精度较低。因此,当基本框架采用 DenseNet 时,所提模型在达到较好的识别精度时,亦能够提高降雨强度识别的效率。综上所述,所提模型不仅能够提高降雨强度识别的有效性,亦能够提高降雨强度识别的效率。

4.2 拓展分析

由于上述实验是将 8 个地点降雨数据一起训练的,为证明所训练的模型在完成“降水”检测,而不是在每个场景中拟合背景信息,将 8 个地点进行训练集与测试集的区别,从中选出 6 个地点作为训练集,2 个地点作为测试集。由于 8 个地点中部分地点只存在零星小雨、小雨、中雨、大雨等 4 类降雨强度,对数据进行了统一,删除了暴雨和大暴雨的数据,进行这 4 类降雨强度的识别。为保证测试集包含所有地区,进行了 4 组实验,并与比较对象中最高的 ResNet-101 进行比较,结果如表 5 所示。表 5 数据表明,模型对场景变化较为敏感,当训练与测试地点不同时,正确率出现了一定的下降。但在该种情况下,所提模型的效果也都优于 ResNet-101。为了验证所提框架对各个地方的适应性,按原数据区分出 8 个地点进行单独训练测试,也与 ResNet-101 进行比较,结果如表 6 所示。从表 6 可以看出,在所有地点中所提模型的识别精度都优于 ResNet-101,说明所提模型适用于各个地方。从降雨强度看,暴雨和大暴雨的图片张数较少,符合现实情况,对于样本不平衡,统一的数据增强将会同样导致数据不平衡,部分的数据增强将导致不同降雨强度的图片呈现不同(例如,只有大暴雨的图像存在旋转)。因此,利用欠采样的方式形成了 3 种测试方案,欠采样指将数据量多的类别数据进行抽样减少其数据量,从而使数据尽可能平衡。方案 1):在数据量较多的零星小

雨、小雨和中雨的原始数据中分别按照每个地点随机抽取 63 张的方式抽取 504 张数据,再按 7:3 的比例切分训练和测试数据,其他降雨强度的数据保持原数据。方案 2):在数据量较多的零星小雨、小雨和中雨的原始数据中分别按照每个地点随机抽取 50 张的方式抽取 400 张数据,其余数据也保持不变。方案 3):在数据量较多的零星小雨、小雨和中雨的原始数据中分别按照每个地点随机抽取 38 张的方式抽取 304 张数据,对于大雨的数据,每个地点的大雨数量若高于 38 张则抽取 38 张,小于 38 的则抽取原数据,其余两种降雨强度保持原数据。表 7 为所提框架在数据较平衡的情况下的识别精度。表 7 结果表明,数据集经过一定的平衡后,模型的正确率有一定的下降,但所提模型在 3 种方案中依然保持较好的正确率,优于 ResNet-101。

表 6 分地点的识别精度比较

Table 6 Comparison of recognition accuracy with different locations

Place	unit: %	
	ResNet-101	Proposed-ResNet-50
Changle	85.3	88.3
Fuqing	86.8	87.3
Jinan	82.4	83.0
Lianjiang	85.8	89.5
Luoyuan	83.1	84.7
Minhou	86.2	90.2
Minqing	89.9	91.4
Yongtai	85.9	89.0

表 7 数据平衡后的识别精度比较

Table 7 Comparison of recognition accuracy after data balance

Case	unit: %	
	ResNet-101	Proposed-ResNet-50
Case 1	76.4	76.8
Case 2	75.6	77.4
Case 3	73.7	74.5

5 结 论

所提雨量强度识别模型引入编码解码模块于深度卷积神经网络分类模型中,在减少局部信息丢失的同时提取深层次的雨纹信息特征,于编码解码模块中考虑多尺度感受野卷积,融合不同范围的局部特征,同时在解码时融合相同尺度的编码与解码特征图,提高特征利用率。基于所提雨量数据集利用融合编码与解码特征的雨量强度识别模型进行雨量强度识别,其识别精度优于目前主流的分类网络,基础框架为 ResNet 和 DenseNet 网络时,分类精度分别达到了 91.7% 和 89.7%,且消融实验证明了编码解码模块的有效性。该模型采用编码解码模块,并考虑多尺度感受野卷积,能够提取更多更深层次的雨纹信息特征,并融合不同范围的雨纹细节特征。该模型将编码器与解码器中同

尺度的特征图进行正反两次串联的组合,充分利用不同深度的特征提高分类精度。在红外降雨图像数据集上与现有卷积神经网络框架进行了对比,该模型均获得较好的性能,验证了该模型的可行性。目前,仅对夜晚的红外降雨图像进行了识别,未对白天的降雨图像进行识别,未来将朝着全天候降雨图像识别发展。

参 考 文 献

- [1] Kalpana P, Parthiban S, Gopinathan P, et al. Spatio-temporal estimation of rainfall patterns in north and northwestern states of India between 1901 and 2015: change point detections and trend assessments[J]. *Arabian Journal of Geosciences*, 2020, 13(21): 1-15.
- [2] Graf M, Chwala C, Polz J, et al. Rainfall estimation from a German-wide commercial microwave link network: optimized processing and validation for 1 year of data[J]. *Hydrology and Earth System Sciences*, 2020, 24(6): 2931-2950.
- [3] Yan J R, Bárdossy A, Hörning S, et al. Conditional simulation of surface rainfall fields using modified phase annealing[J]. *Hydrology and Earth System Sciences*, 2020, 24(5): 2287-2301.
- [4] Suseno D P Y, Yamada T J. Simulating flash floods using geostationary satellite-based rainfall estimation coupled with a land surface model[J]. *Hydrology*, 2020, 7(1): 9.
- [5] Han J, Olivera F, Kim D. An algorithm of spatial composition of hourly rainfall fields for improved high rainfall value estimation[J]. *KSCE Journal of Civil Engineering*, 2021, 25(1): 356-368.
- [6] Krajewski W F, Smith J A. Radar hydrology: rainfall estimation[J]. *Advances in Water Resources*, 2002, 25(8/9/10/11/12): 1387-1394.
- [7] Grimes D I F, Pardo-Igúzquiza E, Bonifacio R. Optimal areal rainfall estimation using raingauges and satellite data [J]. *Journal of Hydrology*, 1999, 222(1/2/3/4): 93-108.
- [8] Villarini G, Mandapaka P V, Krajewski W F, et al. Rainfall and sampling uncertainties: a rain gauge perspective [J]. *Journal of Geophysical Research: Atmospheres*, 2008, 113(D11): D11102.
- [9] Lazri M, Ameer S, Mohia Y. Instantaneous rainfall estimation using neural network from multispectral observations of SEVIRI radiometer and its application in estimation of daily and monthly rainfall[J]. *Advances in Space Research*, 2014, 53(1): 138-155.
- [10] Sehad M, Lazri M, Ameer S. Novel SVM-based technique to improve rainfall estimation over the Mediterranean region (north of Algeria) using the multispectral MSG SEVIRI imagery[J]. *Advances in Space Research*, 2017, 59(5): 1381-1394.
- [11] Kühnlein M, Appelhans T, Thies B, et al. Improving the accuracy of rainfall rates from optical satellite sensors with machine learning: a random forests-based approach applied to MSG SEVIRI[J]. *Remote Sensing of Environment*, 2014, 141: 129-143.
- [12] Hameg S, Lazri M, Ameer S. Using naive Bayes

- classifier for classification of convective rainfall intensities based on spectral characteristics retrieved from SEVIRI [J]. *Journal of Earth System Science*, 2016, 125(5): 945-955.
- [13] Lazri M, Ameer S. Combination of support vector machine, artificial neural network and random forest for improving the classification of convective and stratiform rain using spectral features of SEVIRI data[J]. *Atmospheric Research*, 2018, 203: 118-129.
- [14] 肖康, 田立君, 王中阳. 基于深度学习的低信噪比下的快速超分辨荧光显微成像[J]. *中国激光*, 2020, 47(10): 1007002.
Xiao K, Tian L J, Wang Z Y. Fast super-resolution fluorescence microscopy imaging with low signal-to-noise ratio based on deep learning[J]. *Chinese Journal of Lasers*, 2020, 47(10): 1007002.
- [15] 王梦瑶, 孟祥超, 邵枫, 等. 基于深度学习的 SAR 辅助下光学遥感图像去云方法[J]. *光学学报*, 2021, 41(12): 1228002.
Wang M Y, Meng X C, Shao F, et al. SAR-assisted optical remote sensing image cloud removal method based on deep learning[J]. *Acta Optica Sinica*, 2021, 41(12): 1228002.
- [16] Chen H N, Chandrasekar V, Tan H M, et al. Rainfall estimation from ground radar and TRMM precipitation radar using hybrid deep neural networks[J]. *Geophysical Research Letters*, 2019, 46(17/18): 10669-10678.
- [17] Le X H, Lee G, Jung K, et al. Application of convolutional neural network for spatiotemporal bias correction of daily satellite-based precipitation[J]. *Remote Sensing*, 2020, 12(17): 2731.
- [18] 杨素慧, 林志玮, 赖绍钧, 等. 结合双流 3D 卷积和监控图像的降水临近预报[J]. *激光与光电子学进展*, 2020, 57(20): 201011.
Yang S H, Lin Z W, Lai S J, et al. Precipitation nowcasting based on dual-flow 3D convolution and monitoring images[J]. *Laser & Optoelectronics Progress*, 2020, 57(20): 201011.
- [19] 洪思弟, 赖绍钧, 林志玮, 等. 结合深度卷积网络及光学图像的降雨强度识别[J]. *福建农林大学学报(自然科学版)*, 2020, 49(4): 567-576.
Hong S D, Lai S J, Lin Z W, et al. Identification of rainfall intensity by associating deep convolutional neural network and optical images[J]. *Journal of Fujian Agriculture and Forestry University (Natural Science Edition)*, 2020, 49(4): 567-576.
- [20] Ma J Y, Ma Y, Li C. Infrared and visible image fusion methods and applications: a survey[J]. *Information Fusion*, 2019, 45: 153-178.
- [21] Fan Z L, Bi D Y, Ding W S. Infrared image enhancement with learned features[J]. *Infrared Physics & Technology*, 2017, 86: 44-51.
- [22] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [23] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [24] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C]//Proceedings of the 31th AAAI Conference on Artificial Intelligence, February 4-5, 2017, San Francisco, USA. Virginia: AIAA Press, 2017: 4278-4284.
- [25] 郑雯, 沈琪浩, 任佳. 基于 Improved DR-Net 算法的糖尿病视网膜病变识别与分级[J]. *光学学报*, 2021, 41(22): 2210002.
Zheng W, Shen Q H, Ren J. Recognition and classification of diabetic retinopathy based on improved DR-Net algorithm[J]. *Acta Optica Sinica*, 2021, 41(22): 2210002.
- [26] 党吉圣, 杨军. 深度图注意力 CNN 的三维模型识别[J]. *计算机科学与探索*, 2021, 15(1): 141-149.
Dang J S, Yang J. 3D model recognition based on deep graph attention CNN[J]. *Journal of Frontiers of Computer Science and Technology*, 2021, 15(1): 141-149.
- [27] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning, July 6-11, 2015, Lille, France. [S.l.: s.n.], 2015: 448-456.
- [28] 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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [29] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]//Proceedings of Third International Conference on Learning Representations (ICLR2015), May 7-9, 2015, San Diego, USA. [S.l.: s. n.], 2015.
- [30] Liu W Y, Liu Z, Yu Z D, et al. Decoupled networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2771-2779.
- [31] Yang Z, Luo T G, Wang D, et al. Learning to navigate for fine-grained classification[C]//Proceedings of the 15th European Conference on Computer Vision, September 8-14, 2018, Munich, Germany. [S.l.: s.n.], 2018: 438-454.
- [32] Chen Y, Bai Y L, Zhang W, et al. Destruction and construction learning for fine-grained image recognition [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5152-5161.
- [33] Wang J D, Sun K, Cheng T H, et al. Deep high-resolution representation learning for visual recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(10): 3349-3364.