doi:10.6041/j.issn.1000-1298.2020.07.022

基于深度学习的寒旱区遥感影像河流提取

沈　瑜　苑玉彬　彭　静　陈小朋　杨　倩
（兰州交通大学电子与信息工程学院，兰州 730070）

摘要：寒旱区河流提取对该地区生态环境监测、农业规划、灾害预警等具有重要意义。根据寒旱区特点制作了面向寒旱区遥感影像河流识别的专业数据集；为了提高网络的识别准确率，融合迁移学习与深度学习，将 ResNet50 网络迁移到 Linknet 网络，得到 R－Linknet 网络；为了提取到更多的细节信息和增加提取河流的连贯性，将密集空间金字塔池化与 R－Linknet 网络相结合，扩大网络的感受野；训练时，将 Dice 系数损失函数与二分类交叉熵函数相结合，作为新的损失函数。数据集验证结果表明，本文提出的方法与多种语义分割网络相比，像素准确率较 FCN_8s、ResNet50、DeeplabV3、Unet 和原始 Linknet 网络分别提高 0.216、0.099、0.031、0.056 和 0.023，交并比分别提高 0.19、0.142、0.056、0.105 和 0.028；加入 Dense ASPP 之后，像素准确率提高 0.023，交并比提高 0.050，采用新的损失函数进行训练后，像素准确率和交并比又分别提高 0.019 和 0.022。该方法提取到的河流更加清晰、连贯，能够满足后续的研究需求。

关键词：河流提取；寒旱区；深度学习；遥感影像
中图分类号：TP391.4　　**文献标识码**：A　　**文章编号**：1000-1298(2020)07-0192-10　　**OSID**：

River Extraction from Remote Sensing Images in Cold and Arid Regions Based on Deep Learning

SHEN Yu　YUAN Yubin　PENG Jing　CHEN Xiaopeng　YANG Qian
(*School of Electronic and Information Engineering*, *Lanzhou Jiaotong University*, *Lanzhou* 730070, *China*)

Abstract: The extraction of rivers in cold and arid regions is of great significance in the application of ecological environment monitoring, agricultural planning, and disaster early warning in cold and arid regions. In recent years, there have been more studies on river extraction, but river extraction for cold and arid regions is still in its infancy. The rapid development of deep learning provides new ideas for river extraction in cold and arid regions. A professional data set was produced based on the characteristics of cold and arid regions to provide support for river extraction in remote sensing images in cold and arid regions. Combining transfer learning and deep learning, the ResNet50 network was migrated to the Linknet network to obtain the R－Linknet network, which was used to improve the recognition accuracy of the network. At the same time, the dense atrous spatial pyramid pooling was combined with the R－Linknet network to expand the receptive field of the network, which can extract more detailed information and increase the coherence of the extracted river. A new loss function was combined with the Dice Loss function and the binary cross entropy loss function during training. The verification on the data set showed that compared with semantic segmentation networks, the proposed method had an accuracy rate of 0.216, 0.099, 0.031, 0.056 and 0.023 higher than that of FCN_8s, ResNet50, DeeplabV3, Unet and the original Linknet network, respectively, and the intersection over union was increased by 0.190, 0.142, 0.056, 0.105 and 0.028, respectively. After adding dense atrous spatial pyramid pooling, it increased the pixel accuracy by 0.023, and improved the intersection over union by 0.050. After training with the new loss function, the pixel accuracy and crossover ratios were increased by 0.019 and 0.022, respectively. The rivers extracted by this method were more clear and consistent, and can meet the needs of subsequent research.

Key words: river extraction; cold and arid area; deep learning; remote sensing image

收稿日期：2020－03－20　修回日期：2020－04－25
基金项目：国家自然科学基金项目(61861025、61663021、61761027、51669010)、长江学者和创新团队发展计划项目(IRT_16R36)和兰州市人才创新创业项目(2018－RC－117)
作者简介：沈瑜(1982—)，女，教授，博士，主要从事数字图像处理与人工智能研究，E-mail：18609311366@163.com

0　引言

遥感图像的语义分割应用非常广泛。河流是生态系统的重要组成部分，从遥感影像中准确提取河流信息在环境监测、灾害预警、农业规划等方面具有重要意义。寒旱区在中国分布较广，是众多河流的发源地，生态环境脆弱。因此，针对寒旱区特点寻找到快速、精确的河流提取方法显得尤为重要[1-3]。

传统的河流提取方法提取效率较低、精度较差[4-7]。近年来，深度学习成为人工智能科学研究的热点，其中，卷积神经网络作为深度学习的重要发展方向，在图像分类[8-10]和语义分割[11-12]等领域取得了一定成果，深度学习的方法在遥感图像的河流提取应用方面也取得了较大进展。由于在卷积神经网络后 3 层都是一维向量，计算方式不再采用卷积，所以丢失了二维信息。全卷积神经网络（Fully convolutional networks，FCN）[13]将后 3 层全部转换为 1 × 1 的卷积核所对应等同向量长度的多通道卷积层，即全部采用卷积计算。FCN 学习像素到像素的映射，输入一幅图像，输出也是一幅图像，实现了水体的快速分割，相对于传统方法以及卷积神经网络，在河流提取上具有明显的优势[14-15]。

OLAF 等[16]在 FCN 的基础上构建了 U-Net 网络，引入捷径连接，将反卷积作为上采样结构，并将网络编码器部分的特征连接到解码器部分，将低维信息和高维信息进行融合，使得网络在上采样过程恢复了更多的空间信息。WANG 等[17]将 Unet 网络与迁移学习相结合，采用弱监督训练的方法训练网络，在只有 100 幅图像的情况下，利用神经网络优越的分类性能获得了像素级的分割效果。ResNet 网络将残差学习引入深度学习[18]，大大提高了图像分类的提取精度，并在遥感影像提取上取得了较广泛的应用[19]。WANG 等[20]提出了一种多连接 ResNet，以融合与 FCN 不同层相对应的多层深度特征。CHAURASIA 等[21]提出 LinkNet 深度学习网络模型，LinkNet 采用 U-shape 结构，网络具有丰富的 shortcut，更加有利于将浅层信息传导至网络深层，实现了像素级的图像语义分割，在执行过程中，避免了参数增加过多，提高了运行效率。为了解决特征图分辨率和感受野之间的矛盾，Deeplab 系列引入了扩张卷积和金字塔池化结构（Atrous spatial pyramid pooling，ASPP）[22-24]。ASPP 利用了多尺度信息，进一步强化了分割效果，面对高分辨率的输入，ASPP 为了获取足够大的感受野，需足够大的扩张率，但随着扩张率增加（$d>24$），扩张卷积的衰退衰减变得无效[25-27]。YANG 等[28]将 Deeplab 系列中的 ASPP 和 DenseNet[29]中的密集连接相结合，构成了密集空间金字塔池化（Dense atrous spatial pyramid pooling，Dense ASPP）。新的模块具有更大的接收野和更密集的采样点。

针对寒旱区河流较细、存在山体阴影遮挡等特点，本文结合迁移学习，将 ResNet50 迁移到 Linknet 网络，构建 R-Linknet 网络，并联合密集空间金字塔池用于寒旱区遥感影像的河流提取，通过设计实验证明方法的有效性。

1　实验区域与数据采集

本文数据来自中国寒旱区区域，如图 1 所示。该区域最冷月平均气温小于 -3.0℃、月平均气温大于 10℃不超 5 个月、多年平均降水量小于 500 mm，属于典型的寒旱区区域。寒旱区生态环境脆弱，存在生态退化、水资源分布不均、资源过度开发等问题。同时寒旱区包含众多河流发源地，寒旱区的生态问题亟待解决。

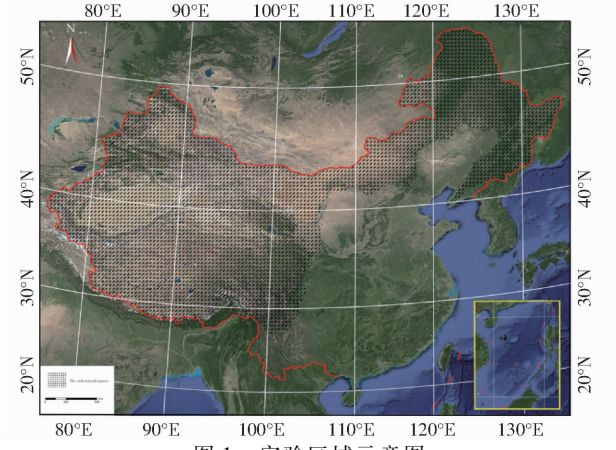

图 1　实验区域示意图

Fig. 1　Schematic of experimental area

采集含河流的图像 100 幅，尺寸为 1 024 像素 × 1 024 像素，并使用 Labelme 工具人工标注了语义图。将图像中的像素分为河流和非河流两种，河流标注为 1，非河流标注为 0。采集的图像包含了具有多种河流尺度的图像，以及有各种代表性干扰的图像，例如山的阴影、云的遮挡、道路干扰、河流含沙量不同、干涸河床干扰和图像拼接变化等具有寒旱区多个特征的高覆盖性，部分示例如图 2 所示。

2　网络构架

图 3 为本文河流提取的整体方案，遥感影像经过由 R-Linknet 网络与 Dense ASPP 相结合的语义分割网络，Dense ASPP 位于 R-Linknet 网络的 Encoder 与 Decoder 中间，用以扩增特征图谱尺寸和网络感受野。

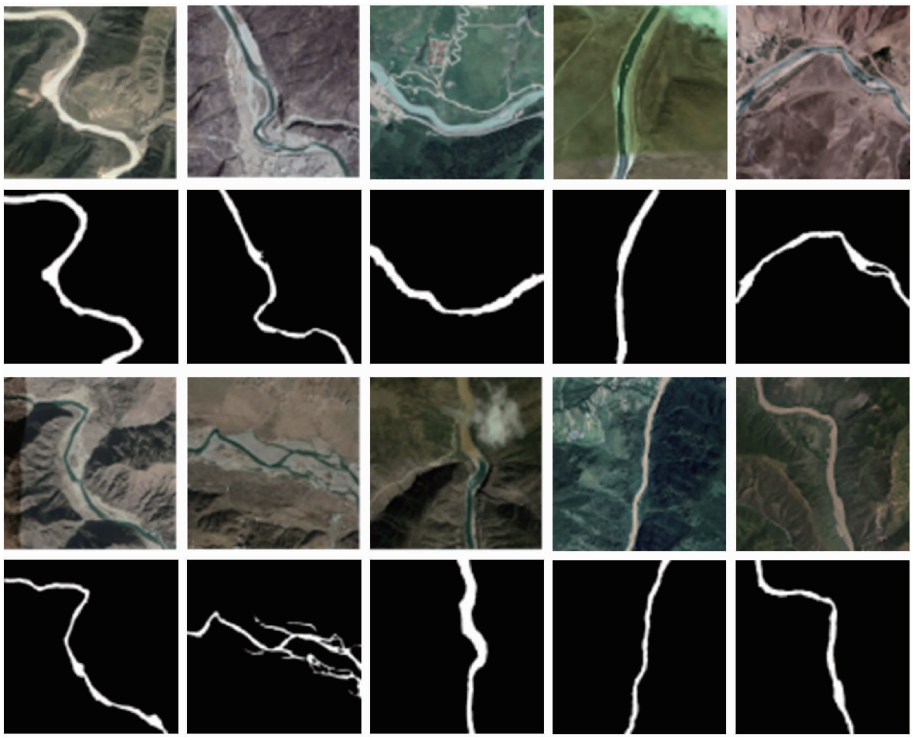

图 2 数据集样本图

Fig. 2 Samples of data set

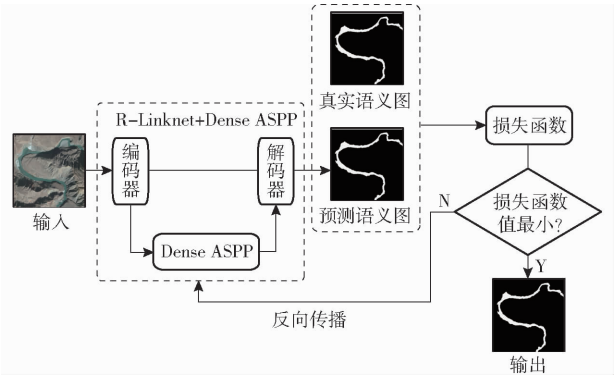

图 3 网络结构图

Fig. 3 Network structure diagram

将 Decoder 输出的预测图同 Ground Truth 经损失函数进行对比,直至得到最小值,若不是最小值则进行反向传播调参,得到最终的输出语义图。

2.1 R - Linknet

Linknet 网络是在 U 型全卷积神经网络的基础上引入了 ResNet,实现了像素级的图像语义分割,原始的 Linknet 使用 ResNet18 作为 Encoder,属于轻量级的 ResNet,但是精度不高且表征能力较弱。本文将 ResNet50 作为网络的 Encoder,提升网络性能和收敛速度,同时将 ELU 函数作为激活函数,构成 R - Linknet 网络,结构如图 4 所示。整个结构包含:2 个卷积层,用以融合邻域内像素的信息;1 个反卷积层,4 个编码层,每个编码层包含 6 个 Res - block;4 个解码层,每个解码层包含 2 层卷积和 1 层反卷积。

在 R - Linknet 训练时,将含有 3 通道的像素尺寸为 $H \times W$ 的遥感图像通过第 1 个卷积核尺寸 7 × 7、步长为 2、数量为 64 的卷积层处理,输出图像尺寸变为 $\frac{H}{2} \times \frac{W}{2}$,通道数变为 64。计算式为

$$X_j^l = f\left(\sum_{i=1}^{d} X_i^{l-1} * \boldsymbol{K}_{ij}^l + B_j^l \right) \tag{1}$$

式中 X_j^l——第 l 层输出的第 j 个特征图

f——激活函数 ELU

X_i^{l-1}——第 $l-1$ 层的第 i 个通道影像

$\boldsymbol{K}_{ij}^l$——第 l 层的卷积核矩阵

$*$——卷积运算符号

B_j^l——第 l 层卷积后第 j 个特征图的偏置

d——卷积核数量

为了防止网络的过拟合,在每次卷积操作之后增加了池化层,池化方式采用最大池化。窗口尺寸为 3 × 3,步长为 2。图像经池化处理之后尺寸变为 $\frac{H}{4} \times \frac{W}{4}$,通道数不变,仍为 64。

在编码层中,4 次编码输出图像特征通道数分别为 64、128、256、512,扩展到编码之前的 8 倍。解码层含有 2 个卷积层和 1 个反卷积层。4 次解码输出图像特征通道数分别为 512、256、128 和 64,图像尺寸和特征通道数变为与编码前相同。

解码层输出图像进入反卷积层,以降低计算复杂度,同时保留了影像的位置信息。输出特征通道

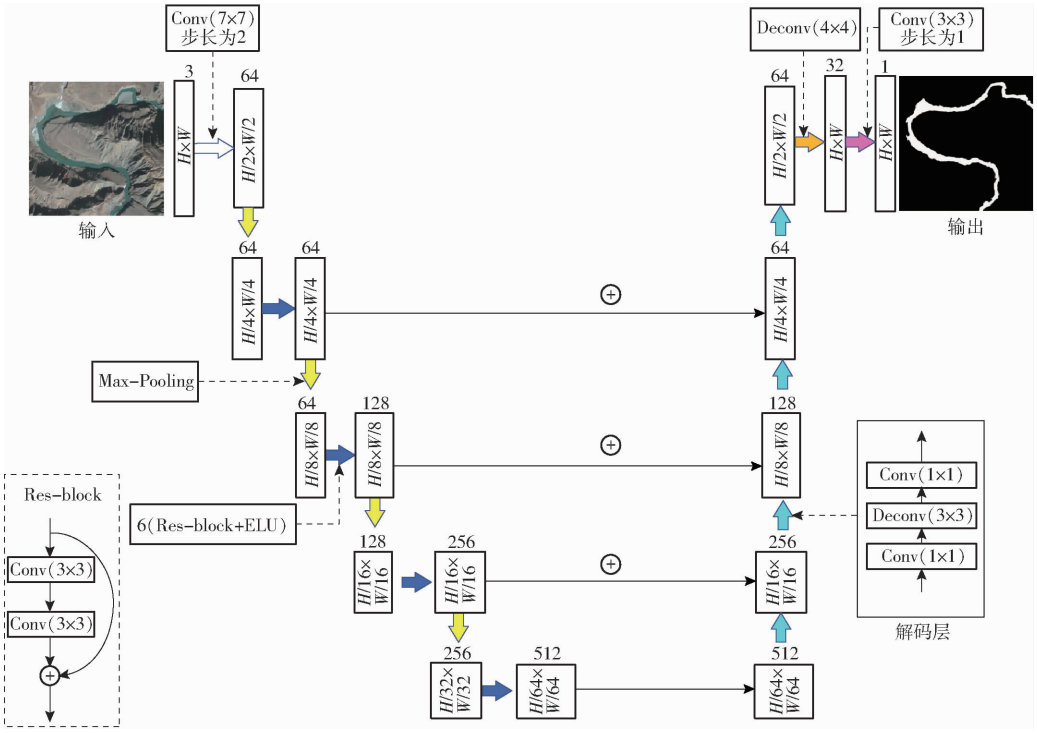

图 4　R－Linknet 网络结构图

Fig. 4　R－Linknet network structure diagram

数变为 32，图像尺寸为$\frac{H}{2}\times\frac{W}{2}$。图像接着输入 1 个卷积层，卷积核尺寸为 3×3，步长为 1。图像尺寸还原为 $H\times W$，通道数变为 1，此时输出河流提取的预测语义图。

2.2　Dense ASPP

与传统的卷积算子相比，空洞卷积能够在不增加核参数数量的情况下获得更大的接受域。由空洞卷积产生的特征图可以与输入尺寸相同，但每个输出神经元拥有更大的接受域，因此可以编码更高层次的语义。其原理如图 5 所示，最上层为一个普通的卷积核，可以理解为膨胀率为 1 的空洞卷积，是空洞卷积的特殊形式；中间层是膨胀率为 2 的空洞卷积，在普通的卷积核基础上，通过在 9 个点的周围增加权重为 0 的空洞点，增大感受野；最下层膨胀率为 4。空洞卷积的目的是在不使用池化与下采样操作的情况下，起到同样增大感受野的功能，让卷积的每一个输出都拥有较大范围的信息。

虽然空洞卷积解决了特征图分辨率与接受域之间的矛盾，空洞卷积输出的特征图中所有神经元都具有相同的接受域，意味着语义掩码的生成过程只利用了单一尺度上的特征。但是多尺度信息将有助于解决模糊情况，并产生更稳健的提取结果。

Dense ASPP 由一个基础网络和一系列层叠的卷积层组成。Dense ASPP 结合了并行和级联使用空洞卷积层的优点，在更大的范围内产生了更多的

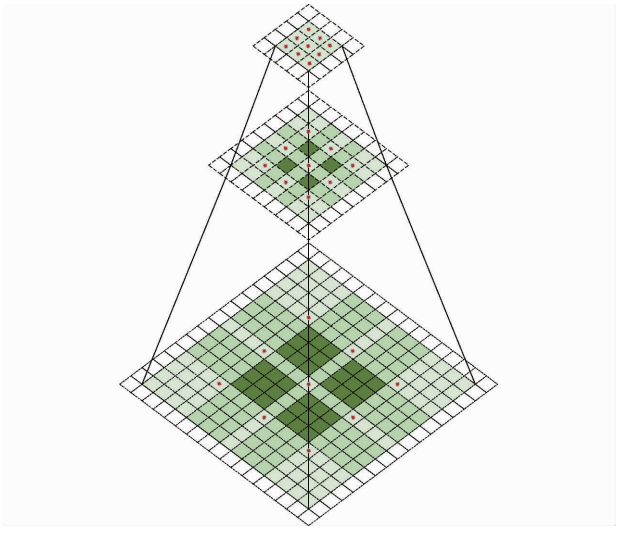

图 5　空洞卷积原理图

Fig. 5　Schematic of hole convolution

尺度特征。通过一系列的特征连接，每个中间特征图上的神经元从多个尺度对语义信息进行编码，不同的中间特征图从不同的尺度范围对多尺度信息进行编码。通过一系列的空洞卷积，较后层次的神经元获得越来越大的感受野，而不会出现 ASPP 的核退化问题。因此，Dense ASPP 最终的输出特征图不仅涵盖了大范围的语义信息，而且以非常密集的方式覆盖了该范围。Dense ASPP 原理图如图 6 所示，由编码器输出的特征图经 5 个卷积层，每个卷积层的卷积核尺寸均为 3，步长分别为 3、6、12、18、24，前一级的输出均与后面的每一级连接，然后作为后一

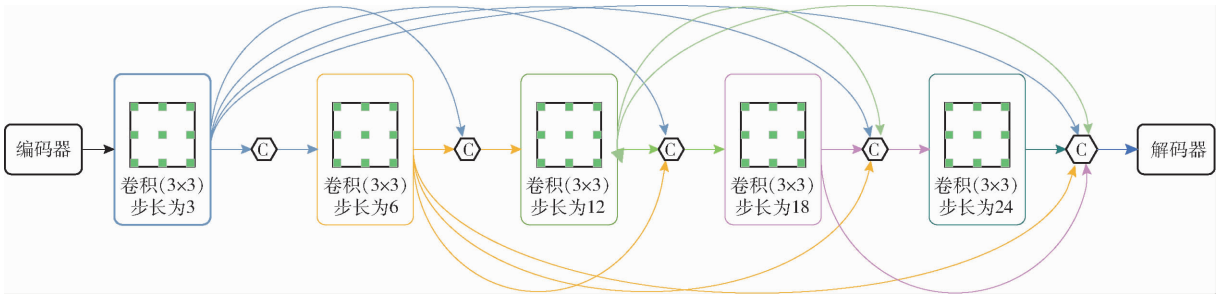

图 6 Dense ASPP 原理图

Fig. 6 Dense ASPP schematic

级的输入,最后输入解码器。

2.3 损失函数

损失函数可以估量模型预测值与真实值不一致的程度,是一个非负实值函数,损失函数越小,模型鲁棒性越好。

语义分割问题中使用最广泛的损失函数为 Dice 系数损失函数(Dice Loss)[30],其能够真实反映预测图像与真实语义图之间的重叠,但在预测图像与真实语义图都非常小的极端情况下,容易出现训练不稳定现象,因此在 Dice 系数损失函数的基础上引入了二分类交叉熵损失函数(Binary cross entropy loss, BCE Loss)[31],相加作为新的损失函数 L_{NEW},避免训练不稳定。

Dice 系数损失函数在 V-Net 网络中引入,用于计算预测类和地面实况类之间的重叠。Dice 系数(范围为[0, 1])计算式为

$$D_{ice} = \frac{2|T \cap P|}{|T| + |P|} \tag{2}$$

式中 $|T|$——真实语义图像素数量

$|P|$——预测语义图像素数量

其中,分子中存在系数 2 是分母存在重复计算 T 和 P 之间共同元素的原因。相当于预测结果区域和真实语义区域的交并比,所以它是把一个类别的所有像素作为一个整体计算损失值。Dice Loss 直接把分割效果评估指标作为损失值监督网络,计算交并比时还忽略了大量背景像素,解决了正负样本不均衡的问题,所以收敛速度较快。

本文目标是最大化预测真实类和基础真值类之间的重叠(即最大化骰子系数)。通常最小化目标,计算式为

$$DiceLoss = 1 - \frac{2|T \cap P|}{|T| + |P|} \tag{3}$$

交叉熵可以衡量系统的混乱程度,表示系统中信息量的总和;熵越大,表明系统不确定性越大。河流提取问题可以视为二分类问题,因此二分类交叉熵损失函数能够很好地表现系统的稳定性。

BCE Loss 的展开形式为

$$BCELoss(P,T) = -\sum_{i=1}^{W}\sum_{j=1}^{H}\left[T_{ij}\lg P_{ij} + (1 - T_{ij})\lg(1 - P_{ij})\right] \tag{4}$$

新的损失函数 L_{NEW} 将 Dice 系数损失函数与二分类交叉熵损失函数相加,提高了训练网络的精度,又解决了网络训练时的不稳定问题,计算式为

$$L_{NEW} = DiceLoss + BCELoss \tag{5}$$

3 实验结果与分析

3.1 评价指标

使用召回率(Recall)、F1 值、像素准确率(Accuracy, ACC)和交并比(Intersection over union, IOU)作为评价指标。河流提取被视为一个语义分割问题,将河流像素取 1,背景像素取 0。

召回率计算式为

$$R = \frac{T_P}{T_P + F_N} \tag{6}$$

式中 T_P——正确预测的河流像素数量

F_N——错误预测为背景的河流像素数量

像素准确率计算式为

$$A = \frac{T_P}{T_P + F_P} \tag{7}$$

式中 F_P——错误预测为河流的背景像素数量

F1 值计算式为

$$F1 = \frac{2AR}{A + R} \tag{8}$$

交并比(IOU)计算式为

$$IOU = \frac{T_P}{T_P + F_N + F_P} \tag{9}$$

3.2 预处理

遥感影像因季节变化、光照变化以及图像的拼接会产生一些色度变化,本文使用改变图像色度的方法扩增数据;同时遥感影像从各个方向观察均不会引起语义的变化,可以通过图像的旋转扩增数据;影像的放大缩小不会改变由鸟瞰拍摄的遥感影像的语义信息。通过色度变换、图像旋转、放大截取和缩小填零的方法将采集到的图像扩增了 9 倍达到了

900 幅，能够加速网络的收敛速度，并且提高准确率，示意图如图 7 所示。测试数据在寒旱区截取了 20 幅边长为 10 km 的含水图像，且包含了各种尺度的河流，含有山体阴影、道路干扰、图像拼接和河流颜色变化等。

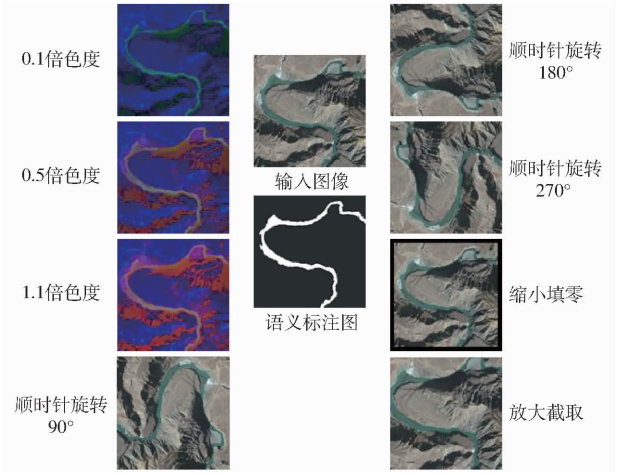

图 7　数据库扩展

Fig. 7　Database extension

3.3　实验设置

硬件平台为 I9 - 9900k CPU、64 GB 内存和 NVIDIA GeForce RTX 2080Ti(11G) GPU，本文涉及网络均在 TensorFlow 框架下搭建，迭代次数为 100 次，优化器均选择 Adam 优化器，初始学习率设为 2×10^{-4}，为防止神经网络后期训练的学习率过小，导致网络参数陷入某个局部最优解，并按多项式衰减，衰减率为 0.9，动量为 0.9，权重衰减率为 10^{-4}。

3.4　实验结果

为了验证 R - Linknet 网络的有效性，在不添加 Dense ASPP 的情况下，与多种语义分割网络做了实验，对比网络选用 FCN_8s、ResNet50、DeeplabV3、Unet 和 Linknet 网络。参数初始化方式均采用 MSRA 初始化方法[32]，只考虑输入的个数，权值初始化服从均值为 0、方差为 $2/n$（n 为输入数量）的高斯分布。实验中所有网络的损失函数均采用 Dice Loss。

网络测试中像素准确率变化曲线如图 8 所示，评价指标如表 1 所示。由图 8 和表 1 可知，本文所提出的 R - Linknet 与其他图像语义分割方法相比具有一定优势，训练过程中能够快速收敛，像素准确率较 FCN_8s、ResNet50、DeeplabV3、Unet、原始 Linknet 网络分别提高 0.216、0.099、0.031、0.056、0.023，交并比分别提高 0.190、0.142、0.056、0.105、0.028。图 9 ~ 12 为在数据集多种情形下的分割效果。由图可知，FCN_8s 误提了许多山体阴影、道路以及植被等，在一些含有细小河流处容易出现中断，提取结果较为杂乱；ResNet50 和 DeeplabV3 相对

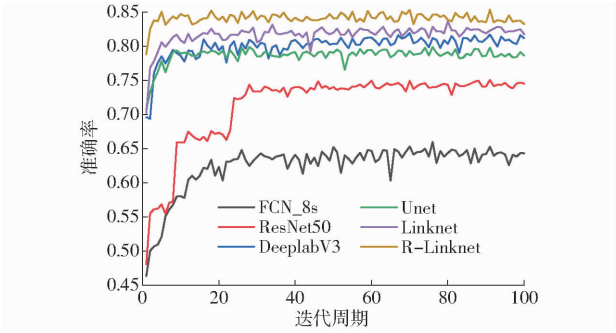

图 8　各个网络测试中的像素准确率变化曲线

Fig. 8　Curves of pixel accuracy during each network test

表 1　各个网络评价指标

Tab. 1　Evaluation indicators of each network

网络	召回率	F1 值	像素准确率	交并比
FCN_8s	0.642	0.636	0.631	0.439
ResNet50	0.714	0.731	0.748	0.487
DeeplabV3	0.825	0.821	0.816	0.573
Unet	0.803	0.797	0.791	0.524
Linknet	0.812	0.818	0.824	0.601
R - Linknet	0.835	0.842	0.847	0.629

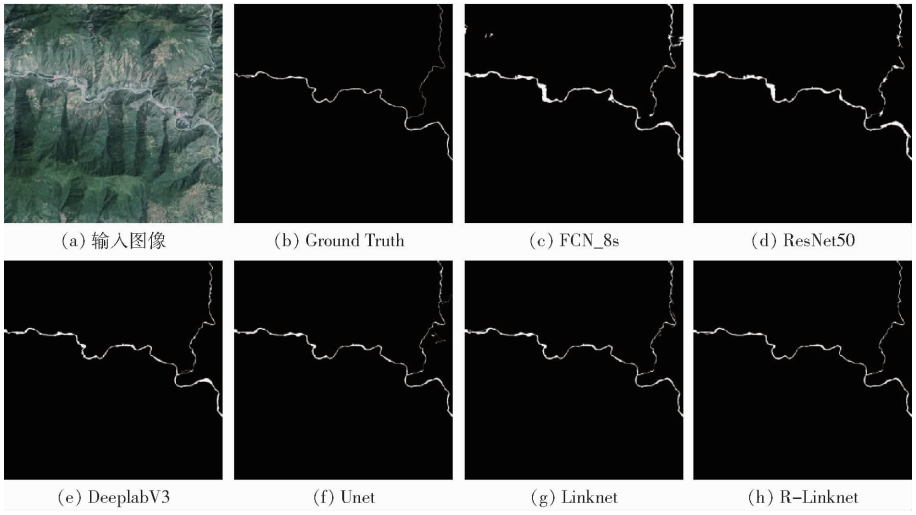

图 9　各个网络提取对比结果(1)

Fig. 9　Comparison results of each network extraction(1)

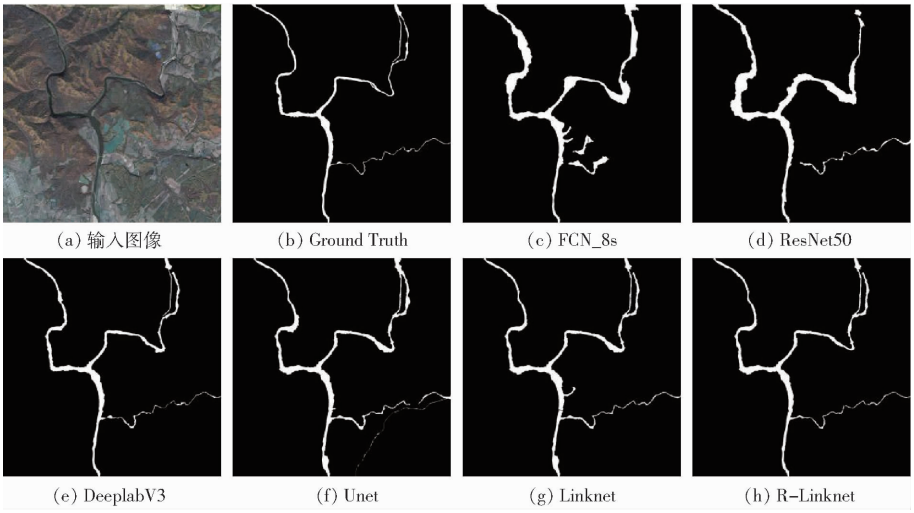

图 10 各个网络提取对比结果(2)

Fig. 10 Comparison results of each network extraction (2)

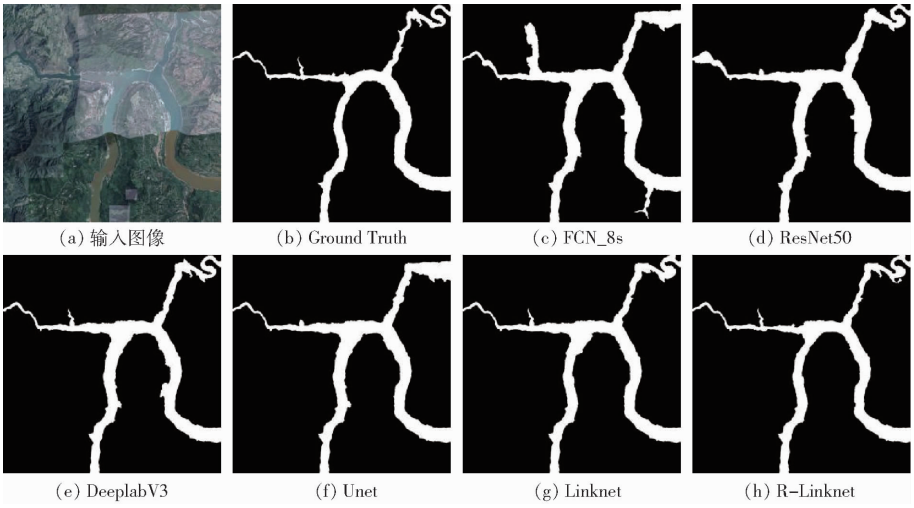

图 11 各个网络提取对比结果(3)

Fig. 11 Comparison results of each network extraction (3)

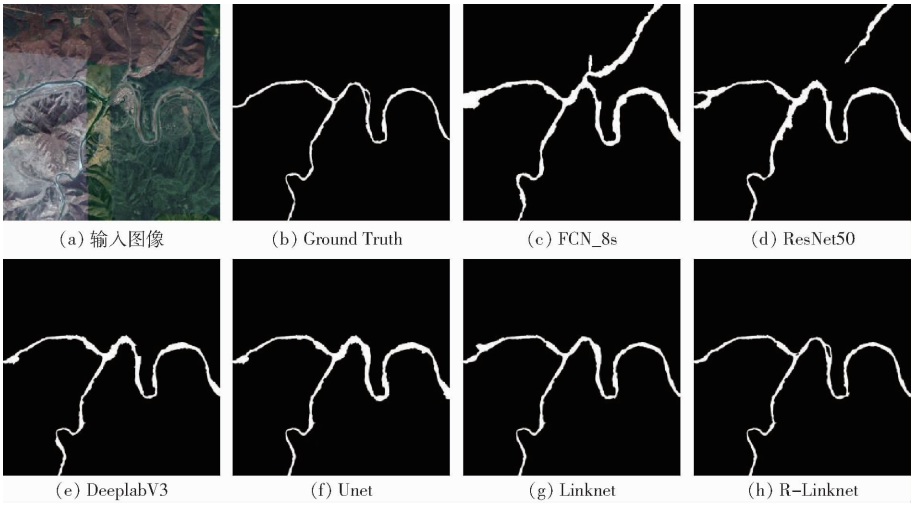

图 12 各个网络提取对比结果(4)

Fig. 12 Comparison results of each network extraction (4)

FCN_8s 有较大提升,但同样误提了阴影、道路和植被等。Linknet 的河流提取效果相对较好,降低了山体阴影、道路、植物等的干扰,但在河流边缘细节处理上较差,同时也没有避免阴影的影响。与对比网络相比,R - Linknet 提取的河流信息受到道路、植被影响较小,阴影影响也没能完全避免,河流边缘细节

上有了较大提升。

为了验证 Dense ASPP 和 L_{NEW} 损失函数在高分辨率遥感影像水体提取上的效果，将 R－Linknet、R－Linknet＋Dense ASPP 和 R－Linknet＋Dense ASPP＋L_{NEW} 进行对比。其准确率变化如图 13 所示，各项评价指标如表 2 所示。加入 Dense ASPP 之后像素准确率提高 0.023，交并比提高 0.050，采用新的损失函数后，像素准确率和交并比又分别提高 0.019 和 0.022。由图 13 可知，Dense ASPP 能够有效提升河流提取准确率，同时没有影响整个网络的收敛，证明了 Dense ASPP 及 L_{NEW} 的有效性。图 14 为各个网络在数据集上的河流提取效果，河流提取的连续性得到提升，细小河流更加连贯，边缘细节提取也更加准确。将 L_{NEW} 作为损失函数能够有效优化水体边缘细节，且河流网络提取完整。

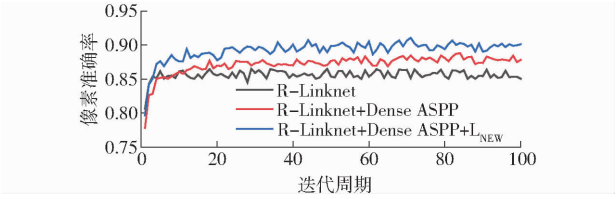

图 13　网络测试像素准确率变化曲线

Fig. 13　Changing curves of network pixel accuracy

表 2　网络各项评价指标

Tab. 2　Network evaluation indicators

网络	召回率	F1 值	像素准确率	交并比
R－Linknet	0.835	0.842	0.849	0.629
R－Linknet＋Dense ASPP	0.868	0.870	0.872	0.679
R－Linknet＋Dense ASPP＋L_{NEW}	0.902	0.896	0.891	0.701

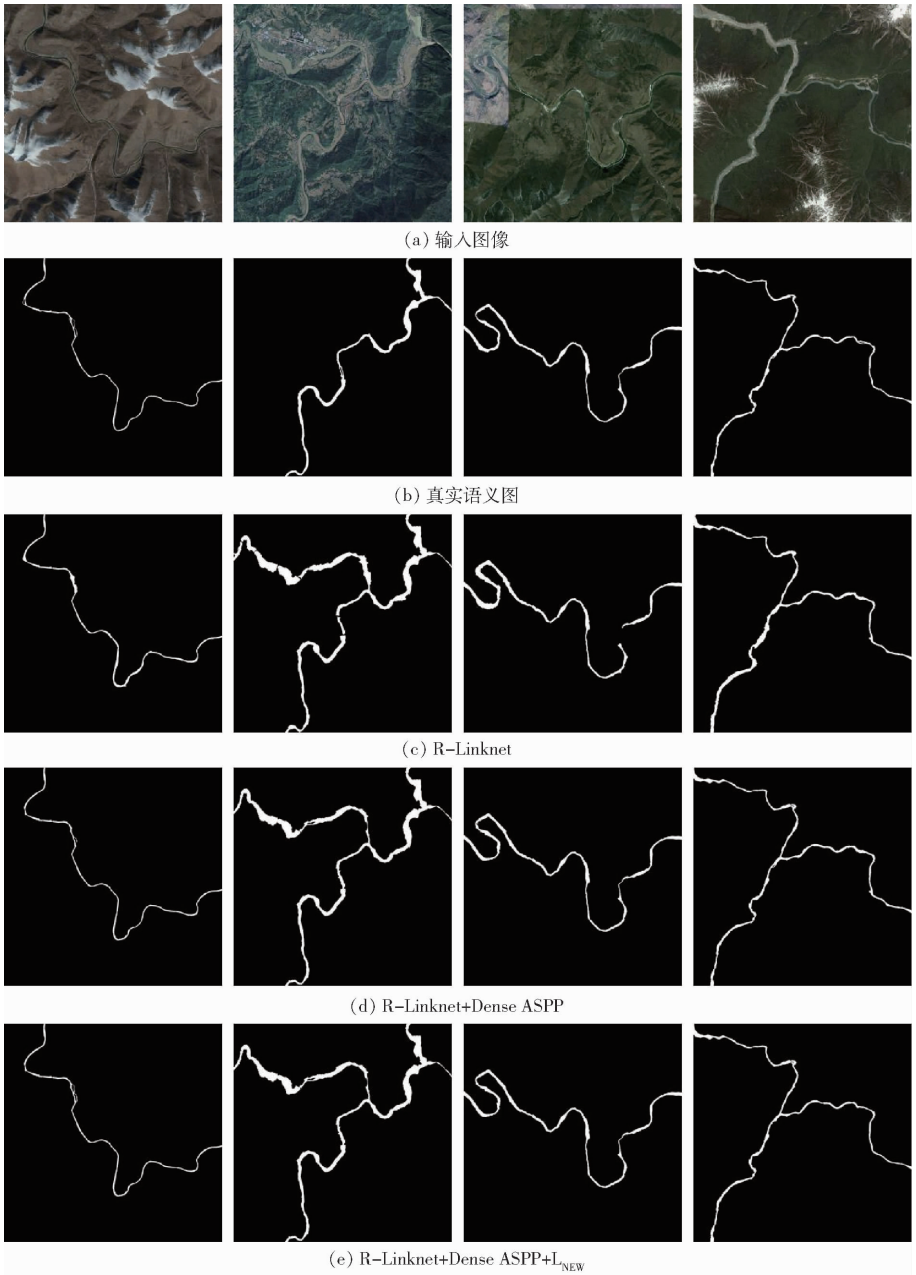

图 14　各种网络提取对比结果

Fig. 14　Comparison results of each network extraction

4 结束语

针对寒旱区河流提取存在的问题提出高效的提取方法。首先,根据寒旱区遥感影像的特点制作了面向寒旱区遥感影像河流识别的数据集;其次,结合迁移学习和 Linknet 神经网络,将 ResNet50 迁移到 Linknet 中,并使用 ELU 函数作为激活函数构成 R - Linknet 网络;该网络能够完全恢复图像的分辨率,同时保证河流提取的连贯性,结合 Dense ASPP,有效提升了河流提取的准确性;在训练过程中,将二次交叉熵损失函数和骰子损失函数相加,作为损失函数,有效提升了图像质量。实验结果表明,本文提出的 R - Linknet 与主流的图像语义分割网络相比,在河流提取上有较大的性能提升,将 R - Linknet 与 Dense ASPP 相结合,提取到的河流网络更加连贯。使用 L_{NEW} 作为损失函数,训练后网络提取到的河流信息细节更加丰富。

参 考 文 献

[1] LU C, REN C, WANG Z, et al. Monitoring and assessment of wetland loss and fragmentation in the Cross - Boundary protected area: a case study of Wusuli river basin[J]. Remote Sensing, 2019, 11(21): 2581.

[2] AUNG E, TINT T. Ayeyarwady river regions detection and extraction system from Google Earth imagery[C]// IEEE International Conference on Information Communication & Signal Processing, 2018.

[3] KAPLAN G, AVDAN U. Object-based water body extraction model using Sentinel - 2 satellite imagery[J]. European Journal of Remote Sensing, 2017, 50(1): 137 - 143.

[4] MONTGOEMERY J S, HOPKINSON C, BRISCO B, et al. Determining hydroperiod for boreal and prairie pothole wetlands using SAR, optical and LiDAR remote sensing data fusion[C]// Agu. Fall Meeting. AGU Fall Meeting Abstracts, 2017.

[5] 尼加提·卡斯木,师庆东,刘素红,等. 基于卷积网络的沙漠腹地绿洲植物群落自动分类方法[J/OL]. 农业机械学报, 2019,50(1):217 - 225.
NIJAT Kasim, SHI Qingdong, LIU Suhong, et al. Automatic classification method of oasis plant community in desert hinterland based on VGGNet and ResNet models[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(1): 217 - 225. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20190124&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2019.01.024. (in Chinese)

[6] LUO X, XIE H, TONG X, et al. A water extraction method based on airborne hyperspectral images in highly complex urban area[C]//2017 International Workshop on Remote Sensing with Intelligent Processing, 2017.

[7] WANG J, DING J, ZHANG C, et al. Method of water information extraction by improved SWI based on GF - 1 satellite image[J]. Remote Sensing for Land & Resources, 2017,29(1):29 - 35.

[8] 姚建华,吴加敏,杨勇,等. 全卷积神经网络下的多光谱遥感影像分割[J]. 中国图象图形学报,2020,25(1):180 - 192.
YAO Jianhua, WU Jiamin, YANG Yong, et al. Segmentation in multi-spectral remote sensing images using the fully convolutional neural network[J]. Journal of Image and Graphics,2020,25(1):180 - 192. (in Chinese)

[9] CHIAO J Y, CHEN K Y, LIAO Y K, et al. Detection and classification the breast tumors using mask R - CNN on sonograms[J]. Medicine, 2019, 98(19): e15200.

[10] YU L, WANG Z, TIAN S, et al. Convolutional neural networks for water body extraction from landsat imagery[J]. International Journal of Computational Intelligence and Applications, 2017, 16(1): 1750001.

[11] DONG R, XU D, JIAO L, et al. A fast deep perception network for remote sensing scene classification[J]. Remote Sensing, 2020, 12(4): 729.

[12] MIAO Z, FU K, SUN H, et al. Automatic water-body segmentation from high-resolution satellite images via deep networks[J]. IEEE Geoscience and Remote Sensing Letters, 2018,15(4):602 - 606.

[13] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 39(4):640 - 651.

[14] HAN X, NGUYEN C, YOU S, et al. Single image water hazard detection using FCN with reflection attention units[C]// European Conference on Computer Vision, 2018.

[15] 方海泉,蒋云钟,冶运涛,等. 基于深度学习和多次棋盘分割法的高分辨率影像河流提取[J]. 北京大学学报(自然科学版),2019,55(4):692 - 698.
FANG Haiquan, JIANG Yunzhong, YE Yuntao, et al. River extraction from high-resolution satellite images combining deep learning and multiple chessboard segmentation[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2019,55(4):692 - 698. (in Chinese)

[16] OLAF R, PHILIPP F, THOMAS B. U - Net: convolutional networks for biomedical image segmentation[C]// International Conference on Medical Image Computing and Computer-Assisted Intervention,2015: 234 - 241.

[17] WANG S, CHEN W, XIE S, et al. Weakly supervised deep learning for segmentation of remote sensing imagery[J]. Remote Sensing, 2020, 12(2):207.

[18] HE K, ZHANG X, REN S,et al. Identity mappings in deep residual networks[J]. arXiv preprint arXiv, 2016: 1603.05027.
[19] WANG G, WU M, WEI X, et al. Water identification from high-resolution remote sensing images based on multidimensional densely connected convolutional neural networks[J]. Remote Sensing, 2020, 12(5):795.
[20] WANG J, SHEN L, QIAO W, et al. Deep feature fusion with integration of residual connection and attention model for classification of VHR remote sensing images[J]. Remote Sensing, 2019, 11(13):1617.
[21] CHAURASIA A, CULURCIELLO E. LinkNet: exploiting encoder representations for efficient semantic segmentation[C]// IEEE Visual Communications and Image Processing, 2017.
[22] CHEN L, PAPANDEREOU G, KOKKINOS I. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 40(4): 834 – 848.
[23] PAPANDREOU G, CHEN L, KEVIN P, et al. Weakly-and semi-supervised learning of a deep convolutional network for semantic image segmentation[C]// IEEE International Conference on Computer Vision, 2015: 1742 – 1750.
[24] CHEN L, PAPANDREOU G, SCHROFF F. Rethinking atrous convolution for semantic image segmentation[J]. arXiv preprint arXiv, 2017: 1706. 5587.
[25] 杨红艳,杜健民,王圆,等.基于无人机遥感与卷积神经网络的草原物种分类方法[J/OL].农业机械学报,2019,50(4): 188 – 195.
YANG Hongyan, DU Jianmin, WANG Yuan, et al. Classification method of grassland species based on unmanned aerial vehicle remote sensing and convolutional neural network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(4): 188 – 195. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20190421&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2019.04.021. (in Chinese)
[26] HE H, YANG D, WANG S, et al. Road extraction by using atrous spatial pyramid pooling integrated Encoder-Decoder network and structural similarity loss[J]. Remote Sensing, 2019, 11(9):1015.
[27] 刘文萍,赵磊,周焱,等.基于深度学习的无人机土地覆盖图像分割方法[J/OL].农业机械学报,2020,51(2):221 – 229.
LIU Wenping, ZHAO Lei, ZHOU Yan, et al. Deep learning based unmanned aerial vehicle landcover image segmentation method[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(2):221 – 229. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2002024&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2020.02.024. (in Chinese)
[28] YANG M, YU K, ZHANG C, et al. DenseASPP for semantic segmentation in street scenes[C]// IEEE Conference on Computer Vision and Pattern Recognition, 2018:3684 – 3692.
[29] JOSE D, KARTHIK G, YUAN J, et al. Hyper Dense – Net: a hyper-densely connected CNN for multi-modal image segmentation[J]. IEEE Transactions on Medical Imaging, 2019, 38(5): 1116 – 1126.
[30] FAUSTO M, NASSIR N, SEYED A. V – Net: fully convolutional neural networks for volumetric medical image segmentation [J]. arXiv preprint arXiv, 2016:1606.04797
[31] CRESWELL A, KAI A, ANIL A. On denoising autoencoders trained to minimise binary cross-entropy[J]. arXiv preprint arXiv, 2017:1708.08487.
[32] KAIMING H, XIANGYU Z, SHAOQING R, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]// IEEE International Conference on Computer Vision, 2015: 1026 – 1034.