

基于改进 SegNet 网络的障碍物检测算法研究

胡均平 张洪伟* 黄强 向思平

(中南大学机电工程学院 湖南长沙 410006)

摘要 为了提高自动驾驶车辆的多类障碍物检测的精度,提出一种改进的 SegNet 神经网络算法。该算法在 SegNet 网络的基础上结合残差网络和多尺度融合算法,提高分类的准确性。对网络训练策略进行改进,采用自设置对比度归一化算法、学习率调整算法和类平衡算法提高网络的鲁棒性和收敛速度。通过在不同场景下进行实验,结果表明,相较于 SegNet 神经网络,改进后的 SegNet 神经网络的像素平均精度(PPA)从 85% 提高至 97%;平均交并比(MIOU)从 76% 提升至 90%。

关键词 自动驾驶 障碍物检测 SegNet 网络 残差网络 多尺度融合算法

中图分类号 TP394.1

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2024.05.033

OBSTACLE DETECTION ALGORITHM BASED ON IMPROVED SEGNET NETWORK

Hu Junping Zhang Hongwei* Huang Qiang Xiang Siping

(College of Mechanical and Electrical Engineering, Central South University, Changsha 410006, Hunan, China)

Abstract In order to improve the accuracy of multi-class obstacle detection for autonomous vehicles, an improved SegNet neural network algorithm is proposed. Based on SegNet, the algorithm combined residual network and multi-scale fusion algorithm to improve the accuracy of classification. The self-setting contrast normalization algorithm, learning rate adjustment algorithm and class balance algorithm were used to improve the robustness and convergence speed of the network. Through experiments in different scenes, the results show that compared with SegNet neural network, the per pixel accuracy of the improved SegNet neural network is improved from 85% to 97%, and the mean intersection over union is improved from 76% to 90%.

Keywords Autonomous driving Obstacle detection SegNet network Residual network Multiscale fusion algorithm

0 引言

障碍物检测^[1]作为智能驾驶领域的热门研究方向,广泛应用在场景理解、智能避障和自动驾驶等方面。目前障碍物检测技术仅对单类别障碍物有较优的检测,在多类障碍物检测存在分割精度低、细小物体无法识别等缺陷,而图像语义分割^[2]可以较好地实现多类障碍物的识别。图像语义分割是一种像素级图像识别的方式,通过提取特征来辨别出图像中每个像素所属类别的概率值大小并标注。传统的语义分割^[3]需要较多的人工操作,工作量大;而卷积神经网络,不仅可

以对图像像素所属类别进行分类,而且也可以实现对具有结构化输出的局部任务进行分类。相较于传统的语义分割方法,卷积神经网络在特征提取与特征选择方面具有高效和高准确的优势。Shelhamer 等^[4]提出采用 FCN 网络进行语义分割,实现单一场景的物体检测。FCN 在单一场景具有较好的分割效果,不适用于复杂的路面,且实时性不高。Hu 等^[5]提出了 U-Net 网络,将基于深度学习的语义分割带入医学检测领域。U-Net 实时性很高但是检测精度不够。Ni 等^[6]采用 GC-Net 网络进行物体检测,实现高精度的目标检测。GG-Net 检测精度高,但是检测速度相对较慢。Badri-narayanan 等^[7]提出 SegNet 网络带动力语义分割在智

能驾驶领域的发展。采用 SegNet 网络进行语义分割需要考虑两个问题:1) 特征图通道数尺寸。特征图通道数越多,特征图像所包含的特征量越多,语义分割的精度相对也越高。2) 上下文信息。图像中物体之间存在局部和全局的上下文关系,这些信息对网络的鲁棒性和分割结果的准确性有很大影响。只有合理地运用这些信息,才能提高语义分割结果。目前关于 SegNet 网络的改进网络主要是融合其他结构^[9],如融合稠密随机场和混合 U-Net 网络的 U-SegNet 改进网络。但这些网络并没有从本质上解决 SegNet 网络的特征提取的能力。本文综合考虑神经网络的检测实时性和准确性,改进了网络结构相对简单且分割精度中等的 SegNet 神经网络,以实现道路多类障碍物的快速、准确地检测。

本文的贡献主要包含:1) 利用残差网络和多尺度融合算法改进 SegNet 网络,提高网络特征提取和特征选择的能力。2) 采用功能更好的激活函数和损失函数,提高网络收敛的速度。3) 对网络训练策略进行改进,提出自设置对比度归一化算法、学习率优化算法和类平衡算法优化网络训练过程,提高网络的鲁棒性。

1 SegNet 网络结构介绍

SegNet^[8]网络是非常经典的语义分割网络,通过修改 VGG-16 网络而得到,是目前使用最多的分割网络。结构如图 1 所示,前半部分是编码层(Encoder),后半部分是解码层(Decoder),由中间的池化层与上采样作为分割线的对称结构。编码层使用卷积(Convolution)提取高维特征,通过下采样使图片尺寸变小来增加视野距;解码层利用反卷积(Deconvolution)使得编码层部分丢失的特征得以重现,上采样用来还原图像尺寸。最后的 softmax 函数则用来计算出不同分类的最大概率。SegNet 网络里的卷积是等价卷积^[6](same convolution),即卷积后图像尺寸大小不发生改变,只会增加特征量。




图 1 SegNet 网络结构图

2 算法改进

2.1 改进后的 SegNet 的网络模型

为了结合像素间上下文的信息,本文在编码层融合了残差网络^[9],解码层则使用多尺度的特性进行改进。编码层利用残差网络将池化操作间的特征图进行迭代融合丰富特征信息;解码层则将编码层中池化获得特征图同该上采样获得的特征图进行迭代融合,最大程度还原图像的特征。图 2 为改进 SegNet 网络结构图,解码层部分将池化 1 和池化 3 获得的特征图进行上采样 5 和 6 后,与池化 2 和池化 4 获得特征图进行迭代融合。编码层将池化 2-4 获得特征图,与上采样 2-4 获得的特征图进行迭代融合得到新的特征图,称为跳跃连接。

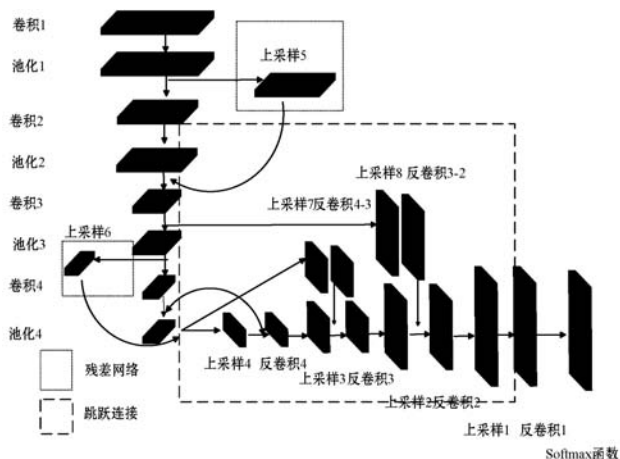


图 2 改进后的 SegNet 网络结构

解码过程中,池化 1 获得特征图进行上采用 5 后,同池化 3 获得的特征图进行迭代融合。池化 2 获得的特征图进行上采样 6 后,同池化 4 获得的特征图进行迭代融合。编码过程中通过池化操作获得原图像 1/4、1/8 和 1/16 尺寸的特征图,称编码过程的特征图。首先将编码过程的 1/8 特征图同该上采样 4 获得的特征图进行迭代融合,得到解码过程的 1/8 特征图。然后将编码过程的 1/16 特征图进行上采样 7 和反卷积 4-3 操作获得新的 1/4 特征图。将新的 1/4 特征图与上采样 3 获得的编码过程的 1/4 特征图进行迭代融合。最后将编码过程的 1/4 特征图进行上采样 8 和反卷积 3-2 操作获得新的 1/2 特征图,将其与上采样 2 获得的特征图进行迭代融合得到新的编码过程的 1/2 特征图。通过将不同尺寸的特征图进行上采样和卷积操作后,迭代融合得到新的特征图。之后与 SegNet 网络一致,由反卷积 2-softmax 函数获得结果。

2.2 改进 SegNet 网络的训练策略

1) 自设置对比度归一化算法。为减小泛化误差和拟合模型大小,本文提出自设置对比度归一化算法。首先将图像划分为四个区域;然后分别计算四个区域的对比度和对比度均值;最后将均值与计算的对比度进行比较,将与均值差距大于等于 50 的区域进行全局对比度归一化^[10]。若四个区域的对比度与均值相差都小于 50,不对图像进行对比度归一化。全局对比度归一化是将图像中像素减去像素的平均值,然后重新对图像进行缩放,使该图像像素的标准差等于常数的算法。其公式如下:

$$X'_{i,j,k} = s \frac{X_{i,j,k} - \bar{X}}{\max\left\{\varepsilon, \frac{1}{3rc} \sum_{i=1}^r \sum_{j=1}^c \sum_{k=1}^3 (X_{i,j,k} - \bar{X})^2\right\}} \quad (1)$$

式中: $X_{i,j,k}$ 是图像某点像素值, \bar{X} 是图像像素平均值, ε 是常数,约束分母大于等于该常数。

2) 学习率的调整。改进后的 SegNet 网络的解码层融合了编码层的特征图打破了原始的对称结构,为了提高鲁棒性和收敛速度,改进网络采用了不同层设置不同学习率的算法。如图 3 所示,解码层分为两个部分,前两层采用 0.001,后两层采用 0.01。编码层的特征图是一个线性的输出关系,前半部分保证特征提取不受异常数据的影响,选用 0.001 的学习率;后半部分加快网络收敛速度同时也保证避免异常数据的影响,采用 0.01 的学习率。编码层采用 0.1 的学习率,加快解码层部分的收敛速度。

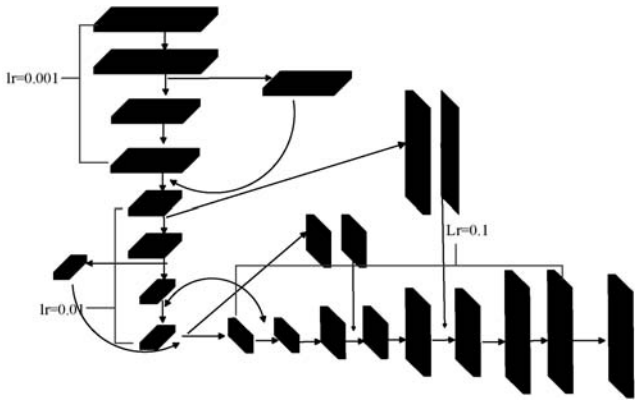


图3 设置不同学习率

为优化学习率,改进 SegNet 网络采用热重启的方式来改进 SGD,称为带重启的 SGD。带重启的 SGD 在每次重启时将学习率初始化,之后逐渐减少学习率。这种重启不是从头重启而是从网络上一步骤收敛的参数处开始重启优化。

3) 损失函数选择。焦点损失函数可解决前景类别不均衡的问题。因此改进网络采用解决极端数据不平衡的焦点损失函数^[11]计算损失率。焦点损失函数

在交叉熵的基础上,引入一个减重系数增加小类别的权重,增加分类错误的样本权重,公式如下:

$$L_{fl} = \begin{cases} -(1-y')^{\gamma} \log y' & y=1 \\ -y'^{\gamma} \log(1-y') & y=0 \end{cases} \quad (2)$$

式中: y 真实值, y' 预测值, $(1-y')^{\gamma}$ 减重系数。

为增加损失率的稳定性,本文采用负对数将输出的概率值从最大化概率转变为最小化能量,公式如下:

$$J = -\frac{1}{m} \left[\sum_{k=1}^m \sum_{j=1}^c \{y^{(k)} = j\} \ln \frac{\exp^{F_{kj}}}{\sum_{j=1}^c \exp^{F_{kj}}} \right] \quad (3)$$

$$J = -\frac{1}{m} \left[\sum_{k=1}^m \sum_{j=1}^c \{y^{(k)} = j\} \ln \frac{\exp^{F_{kj}}}{\sum_{j=1}^c \exp^{F_{kj}}} \right] + \frac{\lambda}{2} \|W\|_2^2 \quad (4)$$

式中: m 为输入的总样本数。 $\{\cdot\}$ 是示性函数:示性函数的表达式如果为真,则函数值等于 1;如果表达式不为真,则函数值等于 0。为了防止过拟合和损失率收敛过慢,在式(3)的基础上加入参数的正则项来优化损失函数, λ 权重衰减参数,主要用于过滤大参数同时保证具有唯一解。

4) 类别平衡化。多分类问题易造成损失曲线的动荡误差,焦点损失函数只能解决类极端的前景类别不平衡现象。本文选用类平衡算法来解决非极端的类别不平衡化,即在每个批次中将所有像素上的损失率相加来计算平均损失率。当训练集中某个类别的像素数量变化较大时(如建筑物、车辆等),就会利用真实类别对损失率进行一次加权平均计算,来均化损失率从而减少损失函数的误差。


改进 SegNet 网络使用中值频率类平衡^[12]算法来优化网络的损失曲线。中值类平衡算法是在损失函数中给每个类别分配了一个权重,而这个权重是整个训练集上计算的类频率的中值除以该类频率的比率。这样像素类别较大的权重小于 1,较小类别的权重则大于 1。在多类别的分类问题里,可以解决大小类别相差较大所导致的误差动荡,使得损失曲线更光滑平稳。

5) PReLU 激活函数的采用。SegNet 网络使用 ReLU 函数作为激活函数,具有计算速度快、正向饱和等优势,曲线如图 4(a) 所示。但是当输入出现负数时,ReLU 函数在正向传播阶段无法激活;反向传播阶段梯度变为 0。为解决这一问题,本文选择 PReLU 函数作为改进网络的激活函数,其曲线图如图 4(b) 所示。PReLU 函数在输入小于 0 的时候具有很小的斜率,可以避免 ReLU 函数在反向传播阶段出现梯度为


0 的情况,保证正向传播阶段激活函数完全激活。
PReLU 函数的公式为:

$$P_{\text{PReLU}} = \begin{cases} x_i & x_i > 0 \\ a_i x_i & x_i \leq 0 \end{cases} \quad (5)$$

式中: a_i 为很小的固定值。



(a) ReLU 函数



(b) PReLU 函数

图 4 激活函数

3 实验验证

3.1 数据集及实验环境

实验使用的数据集以 CamVid 道路场景数据集为基础,对图像进行裁剪、亮度增强、对比度增强、水平翻转和随机方向旋转后获得了 6 040 幅图片的数据集。该数据集训练图像有 3 670 幅,测试图像 2 370 幅。网络使用 TensorFlow 框架搭建,训练过程迭代 20 000 次。网络的初始动量采用 0.9,训练过程采用带重启的随机梯度下降法。为确保在一个时期中每幅图像仅使用一次,每次训练前对所有的训练集进行混洗,之后依次取每个批量(5 幅图像)。

像素平均精度(Per Pixel Accuracy, PPA)和平均交并比(Mean Intersection Over Union, MIOU)作为网络性能测试指标,公式如下:

$$P_{\text{PPA}} = \frac{\sum_{i=0}^K p_{ii}}{\sum_{i=0}^K \sum_{j=0}^K p_{ij}} \quad (6)$$

$$U_{\text{MIOU}} = \frac{1}{K+1} \sum_{i=0}^K \frac{p_{ii}}{\sum_{j=0}^K p_{ij} + \sum_{j=0}^K p_{ji} - p_{ii}} \quad (7)$$

式中: K 为数据集中的总类别; p_{ij} 表示 i 类预测为 j 类

的像素数; $\sum_{j=0}^K p_{ij}$ 表示本属于 i 类却被误判为 j 类的像素点数; $\sum_{j=0}^K p_{ji}$ 表示 j 类被误判成 i 类的像素点数,而分母里 p_{ii} 计算了两次,所以最后需要再减去 p_{ii} 。

3.2 改进 SegNet 神经网络的尺寸参数选择

1) 最大通道数的选择。最大通道数指所有卷积操作里最大的通道数,本文选取最大通道数 64、128、256 和 512 四种尺寸参数的改进 SegNet 网络进行测试对比。实验结果如表 1 所示,最大通道数为 512 的网络的 PPA 与 MIOU 最高但是实时性最差;最大通道数 64 的实时性最好,但是 PPA 与 MIOU 较低。卷积操作的通道数越大,网络包含的特征量越多,分割结果越高。但是通道数增加,变量也增加,网络运行速度变慢。考虑自动驾驶的实时性,改进网络的最大通道数参数设置为 128。

表 1 不同通道数的分割结果

最大通道数	PPA	MIOU	example/s
64	0.929 3	0.766 2	13.3
128	0.963 1	0.869 3	7.9
256	0.976 5	0.881 1	6.0
512	0.972 1	0.907 5	4.6

2) 卷积核的选择。本文分别训练 3×3 、 5×5 、 7×7 、 9×9 、2 个 3×3 和 3 个 3×3 卷积核的改进网络,结果如表 2 所示。卷积核尺寸越大 PPA 与 MIOU 越高,但是速度相对较低,综合表现能力最好是 3 个 3×3 卷积核的卷积操作。这是因为卷积核越大,网络能包含更多的特征值,分割结果越好,但是参数也增加,速度相对减慢。而 3 个 3×3 卷积核和一个 7×7 的卷积核可以达到同等效果,参数却减小一半。因此改进网络的卷积操作均采用最大通道数 128,卷积核为 3 个 3×3 ,结构尺寸如表 3 所示。

表 2 不同卷积核尺寸结果

卷积核	PPA	MIOU	example
3×3	0.954 1	0.809 8	11.4
5×5	0.956 5	0.844 3	9.5
7×7	0.971 0	0.865 2	7.3
9×9	0.974 2	0.864 4	5.8
2 个 3×3	0.961 3	0.856 9	10.0
3 个 3×3	0.972 5	0.857 8	8.2

表3 改进网络结构尺寸

名称	输入	核	输出	通道数
卷积1	360×480	3×3	360×480	64
池化1	360×480	2×2	180×240	64
卷积2	180×240	3×3	180×240	128
池化2	180×240	2×2	90×120	128
池化5	180×240	2×2	90×120	128
卷积3	90×120	3×3	90×120	128
池化3	90×120	2×2	45×60	128
卷积4	45×60	3×3	45×60	128
池化4	45×60	2×2	23×30	128
池化6	45×60	2×2	23×30	128
上采样4	23×30	2×2	45×60	128
反卷积4	45×60	3×3	45×60	128
上采样3	45×60	2×2	90×120	128
上采样5	23×30	4×4	90×120	128
反卷积4-3	90×120	3×3	90×120	128
反卷积3	90×120	3×3	90×120	128
上采样2	90×120	2×2	180×240	128
上采样6	90×120	2×2	180×240	128
反卷积3-2	180×240	3×3	180×240	128
反卷积2	180×240	3×3	180×240	64
上采样1	180×240	2×2	360×480	64
反卷积1	360×480	3×3	360×480	64

3.3 改进网络的消融实验

为了验证改进策略的有效性,本文以带重启的SGD算法、焦点损失函数和类平衡算法为变量进行消融实验,分别以A、B和C代替。实验结果如表4所示,带重启的SGD算法优化学习率,主要影响了网络的PPA和MIOU;焦点损失函数和类平衡算法优化损失率,主要影响网络的损失率。因此本文提出的3种主要算法对网络的改进是可行的。

表4 消融实验

算法	PPA	MIOU	example/s	Loss
AB	0.967 5	0.851 5	9.5	0.76
AC	0.954 5	0.841 2	9.2	0.75
BC	0.941 5	0.830 1	9.0	0.65
ABC	0.972 1	0.907 5	7.1	0.60

3.4 多类障碍物检测对比实验


为了验证本文提出的改进的SegNet网络的优越

性,本文分别训练了改进SegNet网络、原始SegNet网络、融合稠密场的SegNet网络、U-SegNet网络和FCN网络。图6为5种网络的损失曲线图。FCN网络的损失曲线不仅波动大,而且损失率最大,在0.21左右;SegNet网络的损失率在0.11左右;融合稠密场的SegNet网络的损失率在0.8左右;U-SegNet网络的损失率在0.7左右;改进SegNet网络的损失率在0.6左右。改进网络相对于其他网络采用类平衡算法减少了类不平衡问题,同时学习率优化算法进一步加快了网络的收敛速度,减少损失率。因此SegNet改进网络与前4种网络相比精度高、鲁棒性强。


如表5所示,FCN网络的平均精度与平均交并比以及实时性均比较差;SegNet网络的平均精度与平均交并比比本文所提出的改进SegNet网络差,但是实时性最优;融合稠密场的SegNet网络和U-SegNet网络的平均精度与平均交并比比SegNet网络好,但低于本文提出的改进网络。与前4种网络相比,SegNet改进网络在实时性上不及SegNet网络,但是平均精度与平均交并比最高。这是因为SegNet改进网络是在SegNet基础上融合残差网络和多尺度学习算法,充分利用了上下文信息和多尺度的特性,将不同尺寸的细节信息最大程度的还原,充分提高网络的特征提取,因此语义分割精度更高。由于网络结构复杂化,速度较原始网络慢。为保证精度,选用了3个3×3的卷积核的卷积操作,大幅度地减少了参数量,因而速度保留在合理的要求内。

表5 FCN网络、SegNet网络与SegNet改进网络的实验结果对比


网络名称	PPA	MIOU	example/s
FCN	0.703 2	0.402 5	5.1
SegNet	0.855 2	0.767 3	9.7
融合稠密场	0.933 4	0.834 6	7.9
U-SegNet	0.949 3	0.852 5	6.5
SegNet改进	0.972 1	0.907 5	7.1




(a) FCN网络




(b) SegNet 网络的损失曲线



(c) 融合稠密场的 SegNet 改进



(d) U-SegNet 网络



(e) 改进 SegNet 网络

图 5 FCN 网络、原始网络与改进网络的损失曲线对比

图 6 为 5 种网络的语义分割图像,其中:(a)为输入图像;(b)为 FCN 网络;(c)为 SegNet 网络的损失曲线;(d)为融合稠密场的 SegNet 改进;(e)为 U-SegNet 网络;(f)为改进 SegNet 网络。FCN 网络对大类别物体的区分明显,复杂环境下的物体出现糅杂,细小物体无法识别。SegNet 网络能识别各类物体,但是分割结果不够精细,轮廓出现不完整,细小物体也无法识别。如方框里车辆的轮廓不完整,圆框里路灯和椭圆框里围栏无法识别。融合稠密场的 SegNet 网络和 U-SegNet 网络对于路灯可以识别但是轮廓均不完整;融合稠密场的 SegNet 网络像素间出现糅杂;U-SegNet 网络

房屋的墙面被识别为背景。改进 SegNet 网络能完整识别出车辆轮廓,区分细小的路灯和复杂场景的围栏,不会出现像素杂糅现象。

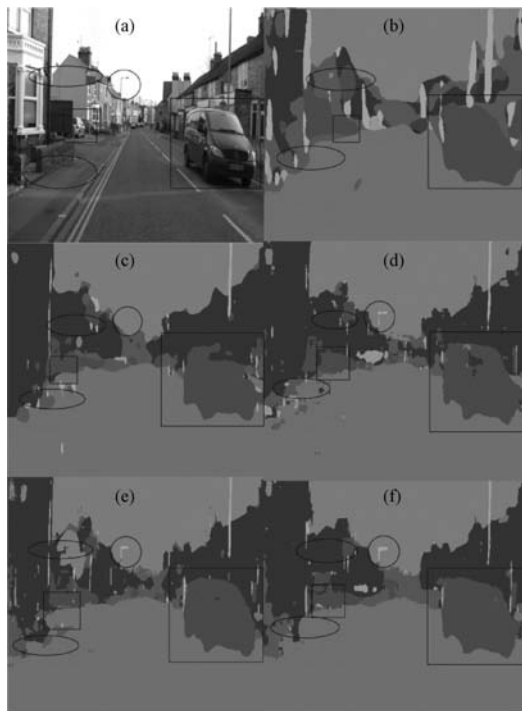


图 6 FCN、原始网络与改进网络的实验结果对比图
主要原因:

1) 原始 SegNet 网络只注重解码和编码的对称结构,并没有注重物体上下文细节信息对分割结构的影响。上下采样会忽略多细小的像素点,导致分割精度不高。

2) 融合残差网络和多尺度融合算法,将解码与编码过程得到的特征图迭代形成新的特征图,充分利用多尺度的特性,提高网络对细节信息的特征提取和特征选择。

综合分析,改进 SegNet 网络考虑输入像素间的上下文关系,实现了对多类障碍物的精准识别以及细小障碍物的识别。通过实验,改进 SegNet 网络能够获得高准确率的实时道路多类障碍物检测。

4 结 语

本文提出一种改进 SegNet 网络的道路多类障碍物检测算法。该算法在 SegNet 网络基础上融合了跳级结构,充分利用多尺寸的特性,将不同尺寸的特征图进行融合获取高精度的语义分割图像。在网络的训练策略上,首先使用自设置全局对比度归一化算法消除图像对比度差异,然后利用学习率优化算法提高网络的收敛速度,最后采用焦点损失函数和类平衡算法优

2880.

- [5] Meng J Y, Shi W B, Tan H S, et al. Cloudlet placement and minimum-delay routing in cloudlet computing[C]//3rd International Conference on Big Data Computing and Communications,2017:297-304.
- [6] Yang S, Li F, Shen M, et al. Cloudlet placement and task allocation in mobile edge computing[J]. IEEE Internet of Things Journal,2019,6(3):5853-5863.
- [7] Li Y Z, Wang S G. An energy-aware edge server placement algorithm in mobile edge computing[C]//IEEE International Conference on Edge Computing,2018:66-73.
- [8] Chen L, Wu J G, Zhou G Q, et al. QUICK: QoS-guaranteed efficient cloudlet placement in wireless metropolitan area networks[J]. The Journal of Supercomputing,2018,74(8):4037-4059.
- [9] Ma L J, Wu J G, Chen L. DOTA: Delay bounded optimal cloudlet deployment and user association in WMANs[C]//17th IEEE International Symposium on Cluster,2017:196-203.
- [10] Ma L J, Wu J G, Chen L, et al. Fast algorithms for capacitated cloudlet placements[C]//21st International Conference on Computer Supported Cooperative Work in Design,2017:439-444.
- [11] Ren Y Z, Zeng F, Li W J, et al. A low-cost edge server placement strategy in wireless metropolitan area networks [C]//27th International Conference on Computer Communication and Networks,2018:1-6.
- [12] Wang S G, Zhao Y L, Xu J L, et al. Edge server placement in mobile edge computing[J]. Journal of Parallel Distributed Computing,2019,127:160-168.
- [13] Li B, Hou P, Wang K Y, et al. Deployment of edge servers in 5G cellular networks[J]. Transactions on Emerging Telecommunications Technologies,2020,33(8):e3937.
- [14] Gao W F, Liu S Y, Huang L. A global best artificial bee colony algorithm for global optimization[J]. Journal of Computational and Applied Mathematics,2012,236(11):2741-2753.
- [15] Gao W F, Liu S Y. Improved artificial bee colony algorithm for global optimization[J]. Information Processing Letters, 2011,111(17):871-882.
- [16] Zhu G P, Kwong S. Gbest-guided artificial bee colony algorithm for numerical function optimization[J]. Applied Mathematics and Computation,2010,217(7):3166-3173.
- [17] 赵临东,庄文芹,陈建新,等. 异构蜂窝网络中分层任务卸载:建模与优化[J]. 通信学报,2020,41(4):34-44.

屋、行人等多类障碍物的检测。通过实验验证,本文提出的改进后的 SegNet 神经网络算法实现了复杂道路的多类障碍物检测,障碍物识别的准确率达 97%,具有优异的准确率和鲁棒性。

参 考 文 献

- [1] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018,40(4):834-848.
- [2] Liu L, Ouyang W L, Wang X G, et al. Deep learning for generic object detection: A survey[J]. International Journal of Computer Vision,2020,128(2):261-318.
- [3] Cheng X, Liu H S. A novel post-processing method based on a weighted composite filter for enhancing semantic segmentation results[J]. Sensors(Basel),2020,20(19):5500.
- [4] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(4):640-651.
- [5] Hu X G, Yang H G. DRU-Net: A novel U-net for biomedical image segmentation[J]. IET Image Processing,2020,14(1):192-200.
- [6] Ni J, Wu J H, Tong J, et al. GC-Net: Global context network for medical image segmentation[J]. Computer Methods and Programs in Biomedicine,2020,190:105121.
- [7] Badrinarayanan V, Kendall A, Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(12):2481-2495.
- [8] Li G, Liu Q W, Ren W, et al. Automatic recognition and analysis system of asphalt pavement cracks using interleaved low-rank group convolution hybrid deep network and SegNet fusing dense condition random field[J]. Measurement,2021,170:108693.
- [9] 史文玲,杜慧谦,梅文波. 用于单图像超分辨率的新型通道注意力残差网络[J]. 北京理工大学学报,2020,29(3):345-353.
- [10] Kusuma G P, Wigati E K, Chandra E. A review of recent advancements in appearance-based object recognition [J]. Procedia Computer Science,2019,157(3):613-620.
- [11] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2020,42(2):318-327.
- [12] Eigen D, Fergus R. Predicting depth, surface normals and semantic labels with a common multi-scale convolutional architecture[C]//IEEE International Conference on Computer Vision,2015:2650-2658.

(上接第 217 页)

化损失率,提高网络鲁棒性,最终实现车辆、路灯、房