

DOI:10.16136/j.joel.2023.01.0133

基于 FE-Unet 的机场道面裂缝检测

邓治林¹, 罗仁泽^{1*}, 费越², 李海丰³

(1. 西南石油大学 电气信息学院, 四川 成都 610500; 2. 成都圭目机器人有限公司, 四川 成都 610101; 3. 中国民航大学 计算机科学与技术学院, 天津 300300)

摘要: 机场道面裂缝具有形态复杂多变、走向不连续、数据噪音多等特征, 现有算法模型均未达到令人满意的结果。为了改善裂缝检测效果, 本文提出了一种新的深度学习模型, 命名为“FE-Unet”。该模型采用改进的残差连接方式, 在解决多层网络下梯度的回传问题的同时起到细化特征以及整合通道的信息作用, 提升了各阶段特征的区分度; 此外, 模型中的通道注意力模块(channel attention block, CAB)可以更好地提取判别特征, 增强预测的一致性; 最后, 利用焦点损失(focal loss, FL)使模型专注于难分类的细小裂缝。实验中, 以实际 7778 张机场道面裂缝图像来训练模型, 并在 1701 张图像上进行验证。在与经典的全卷积神经网络(fully convolutional network, FCN)、DeepLab v3 和 Unet 对比实验中, FE-Unet 对裂缝、灌缝和板缝的检测性能均优于其他模型。其中, FE-Unet 对裂缝检测的精度、召回率、F1 值分别达到了 80.31%、82.72% 和 81.49%。

关键词: 深度学习; 图像处理; 机场道面检测; FE-Unet; 裂缝识别

中图分类号: TP391 **文献标识码:** A **文章编号:** 1005-0086(2023)01-0034-09

Crack detection of airport pavement based on FE-Unet

DENG Zhilin¹, LUO Renze^{1*}, FEI Yue², LI Haifeng³

(1. College of Electrical and Information Engineering, Southwest Petroleum University, Chengdu, Sichuan 610500, China; 2. Chengdu Guimu Robot Co., Ltd., Chengdu, Sichuan 610101, China; 3. College of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Airport pavement cracks are characterized by complex morphology, discontinuous trend and lots of data noise, and the existing algorithm models have not achieved satisfactory results. In order to improve the crack detection effect, this paper proposes a new deep learning model named "FE-Unet". The model adopts the refine residual block, which not only solves the problem of gradient transmission in multi-layer network, but also refines the features and integrates the information of channels, and improves the distinguishing degree of features in each stage. In addition, the channel attention block (CAB) in the model can better extract discriminant features and enhance the consistency of prediction. Finally, focal loss (FL) is used to make the model focus on the fine cracks that are difficult to classify. In the experiment, the model is trained with 7778 airport pavement crack images and verified on 1701 images. In comparison with classical fully convolutional network (FCN), DeepLab v3 and Unet, FE-Unet has better detection performance for cracks, repair and joint than other models. Among them, the precision, recall rate and F1 value of FE-Unet for crack detection reached 80.31%, 82.72% and 81.49%.

Key words: deep learning; image processing; airport pavement detection; FE-Unet; crack recognition

0 引言

传统机场道面的裂缝评估主要是通过人工巡

视的方式, 该方式主观性强(易错)、效率低、成本高、危险性较大, 机场维护人员对裂缝评估自动化的需求非常强烈。在过去, 尽管国内外学者对裂

* E-mail: lrzsmith@126.com

收稿日期: 2022-03-06 修订日期: 2022-04-20

基金项目: 国家重点研发计划(2019YFB1310600)资助项目

缝自动化识别进行了大量的研究,但是依旧离落地应用非常遥远。如今深度学习被广泛应用于计算机视觉领域,取得了巨大的进展,也为裂缝自动化识别提供了强大的助力。

如今,已有大量学者利用目标检测模型对图像中的裂缝进行自动识别,例如经典的目标检测框架 R-CNN 系列和 YOLO 系列。GOU 等^[1]使用 Faster R-CNN 成功地对道面裂缝进行了检测,取得了一定的效果;DENG 等^[2]将 Faster R-CNN 方法使用在桥面裂缝检测领域,同样取得了成功。UKHWAH 等^[3]使用 YOLO 网络模型对道面裂缝进行检测,达到了一定的效果。总的来说,目标检测网络主要是利用边框回归的原理来对目标区域进行选取,并不太适合寻找粗细不一、形状多变的道面裂缝。

除了目标检测模型之外,很多语义分割模型也被应用于裂缝识别当中。FAN 等^[4]利用深度卷积网络加上自适应阈值的方法,实现了裂缝的精准分割。但是,深度卷积神经网络分割结果较宽,总体精度较低。文青等^[5]使用 Mask R-CNN 算法来实现对建筑物表面裂缝的检测。但由于候选区域提取准确度不高,导致分割结果较差。随后,编码-解码结构的网络不断成熟,大多数语义分割任务都是基于该架构进行,裂缝检测领域也是如此。ZHANG 等^[6]提出的 CrackNet 实现了 3D 图像中裂缝的像素级检测,但是 CrackNet 仅使用了通道的扩张,在图像的原始尺度下检测裂缝,导致检测出的裂缝的整体性较差。LIU 等^[7]提出了一种深度卷积神经网络(DeepCrack),通过在神经网络中加入条件随机场,实现了端到端的像素级的裂缝语义分割。但是,该网络对含有浅裂缝的图像识别效果较差,常常出现误检。曹锦纲等^[8]通过在编码-解码器结构网络中加入注意力机制,构建了基于注意力机制的编码-解码结构裂缝检测网络,提高了裂缝检测的性能。但是,该模型对细裂缝的检测效果不理想。SARMIENTO 等^[9]使用 DeepLab v3 网络对混凝土道面损坏进行分割,取得了较好的分割效果;DUNG 等^[10]使用全卷积神经网络(fully convolutional network, FCN)^[11]对混凝土裂缝进行检测,取得了一定的检测效果;ZHANG 等^[12]使用基于 Unet 的改进的模型来对建筑裂缝进行识别,同样也有较好的识别效果。虽然 FCN、DeepLab v3 和 Unet 在一定程度上提升了裂缝检测能力,但由于其复杂的卷积结构,导致卷积过程中损失了一部分重要的特征信息,使得检测边缘模糊,细节信息丢失。

针对上述深度学习在裂缝识别中遇到的问

题,本文提出了一种快速、有效的机场道面裂缝检测网络(fast effective unet, FE-Unet)。该网络基于 Unet 框架^[13],在自编码中采用改进的残差模块(refine residual block, RRB)解决了多层网络下梯度的回传问题,加快了网络的收敛速度,整合了通道中的特征信息,细化了特征,提升了各阶段特征的区分度;同时,在编码器和解码器之间采用通道注意力模块(channel attention block, CAB),有助于模型获取具有判别性的特征,增强预测的一致性;在模型训练过程中,利用焦点损失(focal loss, FL)^[14]使模型赋予难分类的细小裂缝更多权重,使裂缝分割更加精确。

1 方法原理

本文提出的 FE-Unet 主要包含 RRB、CAB、反卷积模块(deconvolution block, DB)、多层感知模块(multilayer perception block, MLPB)4 个模块。其中主要的模块为 RRB 和 CAB。

1.1 整体框架

本文使用的 FE-Unet 网络结构如图 1 所示。其主要流程为:首先图像经过 RRB 模块中的 1×1 卷积,调整图像通道;而后经过 RRB 提取初级特征,主要提取裂缝的轮廓信息;再经最大池化(maxpool)进行降采样;经过几次重复操作,逐步提取图像的高级语义特征;通过 DB 进行上采样。在每个特征层上采样过后,利用 CAB 实现特征的选择,再利用 RRB 模块对特征进行处理。重复几次操作过后,最后得到裂缝、灌缝和板缝的精确的语义分割图像。

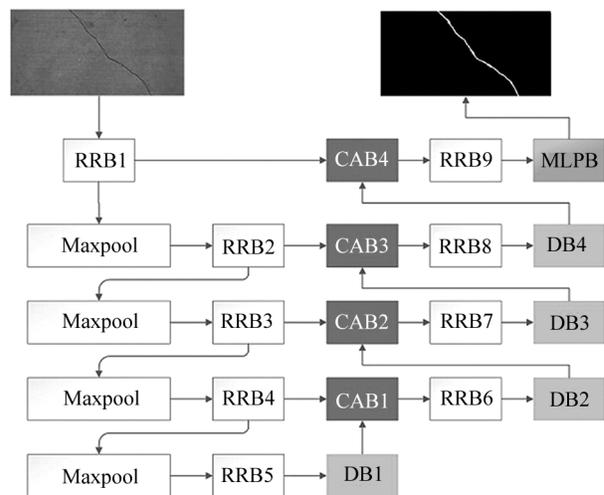


图 1 FE-Unet 结构

Fig. 1 FE-Unet structure

1.2 RRB

在深度神经网络中,当增加网络层数后,网络可

以进行更加复杂的特征模式的提取,但网络深度增加后,容易出现梯度消失和梯度爆炸的问题,模型变得难以训练。ResNet^[15]就很好地解决了模型训练时梯度回传的问题。

利用 ResNet 思想,本文设计了 RRB,其结构如图 2 所示。首先,使用 1×1 的卷积统一图像的通道数,在不改变特征图尺寸的大小的情况下,有效地减少网络的参数量,提升了浅层与深层特征图之间的信息交流与融合能力;其次,通过使用残差结构将原始特征信息与经过多次卷积后提取的特征信息进行融合,使得网络可以获取更多的关于裂缝的特征信息,起到一定的细化特征的作用,提升网络对各阶段特征的识别能力。在损失回传的过程中,该模块解决了多层网络下梯度回传的问题,加快了网络的收敛速度。同时,通过该模块后,网络的宽度与深度得到提升,每一层网络可以学习到更多的裂缝的纹理、亮度、频率等特征,对于特征信息也起到了一定程度上的增强作用。

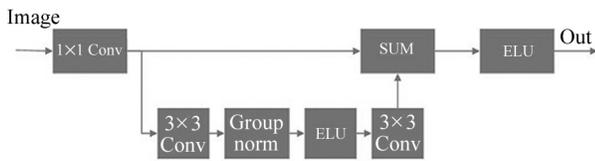


图 2 RRB

Fig. 2 Refine residual block

具体流程如下:

$$y_{RRB} = \text{ELU}(\text{Conv}_{1 \times 1}(\text{Conv}_{3 \times 3}(H(\text{Conv}_{1 \times 1}(x) + \text{Conv}_{3 \times 3}(H(\text{Conv}_{1 \times 1}(x))))))), \quad (1)$$

式中, y_{RRB} 表示输入图像 x 经过 1×1 卷积和 x 经过 1×1 卷积、 H 函数(H 表示 3×3 卷积、组标准化和 ELU 激活操作)、 3×3 卷积相加后经过 ELU 激活函数后的输出,该操作可以进一步整合特征图中存在的特征信息,进一步提升模型的非线性表达能力。

1.3 CAB

裂缝的形态存在较大尺度的变化。而单一的特征提取手段存在一定的局限性,使得网络提取特征信息不全以及不能充分利用高层和低层的特征信息。因此,需要利用特征融合模块结合裂缝的语义信息以及裂缝的细节信息。在特征融合中,使用注意力机制增强特征的一致性。根据 DFN (discriminative feature network)^[16]的结果可以看出,注意力机制可以在一定程度上提升模型预测的一致性。

整个特征融合注意力机制模块如图 3 所示。其

中,特征融合之后再通过卷积进行特征提取,得到更高层级的特征图,而后对特征进行有效的融合。其中,由于原始图像的分辨率较高,在低级特征层(low level feature)中,能够得到更多的图像空间编码的信息,这些特征大多表示裂缝的局部形态信息,具有较强的区分性,但是由于其感受野较小缺乏语义信息,导致低层特征的语义一致性较差;在高层特征层(high level feature)中,输入的特征图像的尺寸较小,模型相对于原图有了更大的感受野,能够较好地提取出裂缝的全局信息,有着更强的语义一致性,而高层特征却由于其较大的感受野而失去了较多的空间信息,因此预测出的裂缝结果模糊粗糙。针对此情况,本文设计 CAB 模块用于解决这种问题,该模块利用高级特征指导低级特征进行选择,使得模型可以获得更具区分性的特征。因此,该模块可以使模型在保留裂缝的低层局部空间特性的同时取得具有语义一致性的特征图。

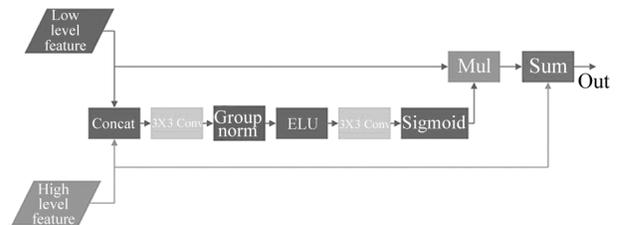


图 3 CAB

Fig. 3 Channel attention block

主要流程如下:

$$y_{i,j}^k = H_{i,j}^k + L_{i,j}^k W_{i,j}^k, \quad (2)$$

式中, $y_{i,j}^k$ 表示最后的特征输出, $i, j \in D$, D 表示特征像素位置集合, $k \in \{1, 2, 3, \dots, K\}$, K 表示总的通道数, $H_{i,j}^k$ 表示高层语义特征, $L_{i,j}^k$ 表示低层语义特征, $W_{i,j}^k$ 表示中间卷积输出,具体流程如下:

$$y_{\text{Concat}} = \text{Concat}(L, H), \quad (3)$$

式中, y_{Concat} 表示 Concat 高层及低层特征的后输出, L 表示低层特征, H 表示高层特征,通过级联不同层级的特征输出,使特征图的通道信息更加丰富。

$$W = \text{Sigmoid}(\text{Conv}_{3 \times 3}(H(y_{\text{Concat}}))), \quad (4)$$

式中, W 表示 y_{Concat} 经过 3×3 卷积、组标准化、ELU 激活函数、 3×3 卷积和 Sigmoid 激活函数后的输出,通过这一系列的操作,模型中的特征得到进一步提取,可以更好地利用特征。

2 实验数据

本次实验共选取了 9 479 张图像作为数据集,其

中 7778 张为训练集,1000 张为验证集,701 张为测试集。所使用的图像数据来自国内多个机场,图像数据是由道面机器人自动采集完成的灰度图,使用 labelme 工具进行标注,图像原始尺寸为 1800×900 。为了方便训练模型,每张图像被裁剪成 4 张 1024×512 大小的图像传入网络。相机采集图像如图 4 所示。

由于部分图像采集工作在夜晚进行,因此在图像采集时,机器人采用大功率 LED 射灯配合面阵相机采集机场道面图像,但是由于射灯的物理结构决定,相机拍摄图像呈中间亮、四周暗的特性。拍摄的原始图像以及图像行像素值分布如图 5 所示。因

此,需要对图像进行光照补偿处理。

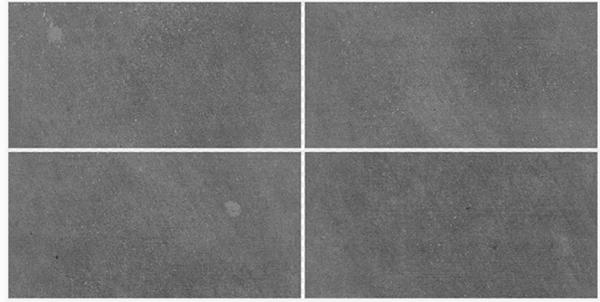
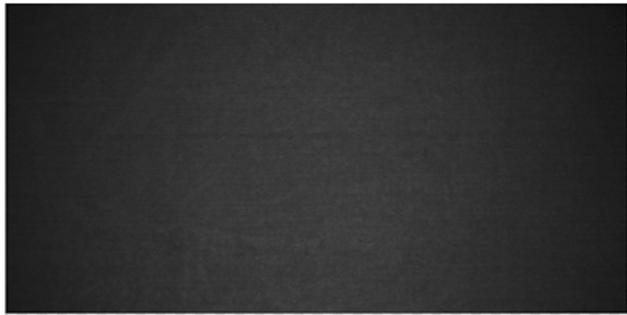
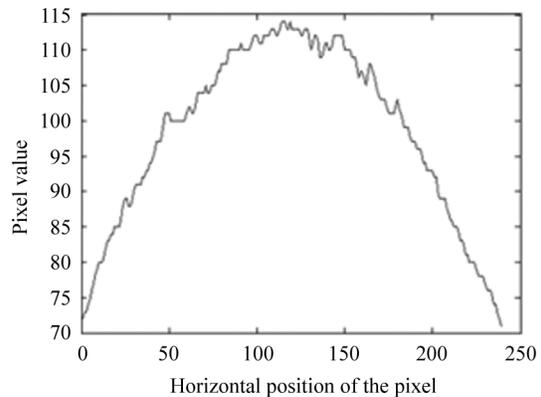


图 4 机场道面图像

Fig. 4 Image of airport road surface



(a)



(b)

图 5 相机原始图像及行像素值分布图:(a) 原始图像;(b) 原始图像行像素值分布

Fig. 5 The original camera image and the distribution of row pixel values:(a) Original image;

(b) Distribution of pixel values in original image rows

光照补偿算法流程如下:

$$\mathbf{I}(x, y) = \mathbf{B}(x, y) + \mathbf{G}(x, y), \quad (5)$$

式中, $\mathbf{I}(x, y)$ 表示机场道面总光强分布矩阵, $\mathbf{B}(x, y)$ 表示背景光强分布, $\mathbf{G}(x, y)$ 表示射灯光强分布, (x, y) 表示图像像素坐标。

求取像素平均值如下:

$$\bar{\mathbf{I}}(x, y) = \frac{1}{N} \sum_{i=0}^N \mathbf{I}_i(x, y), \quad (6)$$

式中, $\bar{\mathbf{I}}(x, y)$ 表示光照像素平均值矩阵, N 表示选取图像张数, $\mathbf{I}_i(x, y)$ 表示第张图像像素分布矩阵,通过多张图像求取均值,可以使图像中的噪声干扰减少。

$$\mathbf{M}(x, y) = \frac{\max(\bar{\mathbf{I}}(x, y))}{\mathbf{I}(x, y)}, \quad (7)$$

式中, $\mathbf{M}(x, y)$ 表示所得系数矩阵,通过平均值图像

矩阵 $\bar{\mathbf{I}}(x, y)$ 得到的系数矩阵,可以使光照补偿的图像的特征更加明显。

$$\mathbf{I}'_i(x, y) = \mathbf{M}(x, y) \otimes \mathbf{I}_i(x, y), \quad (8)$$

式中, $\mathbf{I}'_i(x, y)$ 表示第 i 张图像 $\mathbf{I}_i(x, y)$ 经过光照补偿后得到的光照均匀且特征明显的机场道面图像。

机场道面图像经光照补偿前后对比如图 6 所示。

此外,本文使用了一系列的数据增强手段。图 7 展示了机场道面图像经过相应图像增强手段后图像的变化。图 7 中第 1 列图像为网络输入图像。通过弹性变换、网格失真、光学畸变和旋转处理后,图像中裂缝、灌缝和板缝的形态和位置特征均出现了一定程度的变化,丰富了网络模型的输入,模型可以学习到更多的裂缝的特征,提升了模型的抗干扰能力。



图 6 机场道面原始图像以及光照补偿处理后的图像:(a) 原始图像;(b) 光照补偿处理后的图像
Fig. 6 The original image of airport pavement and the image after light compensation processing;

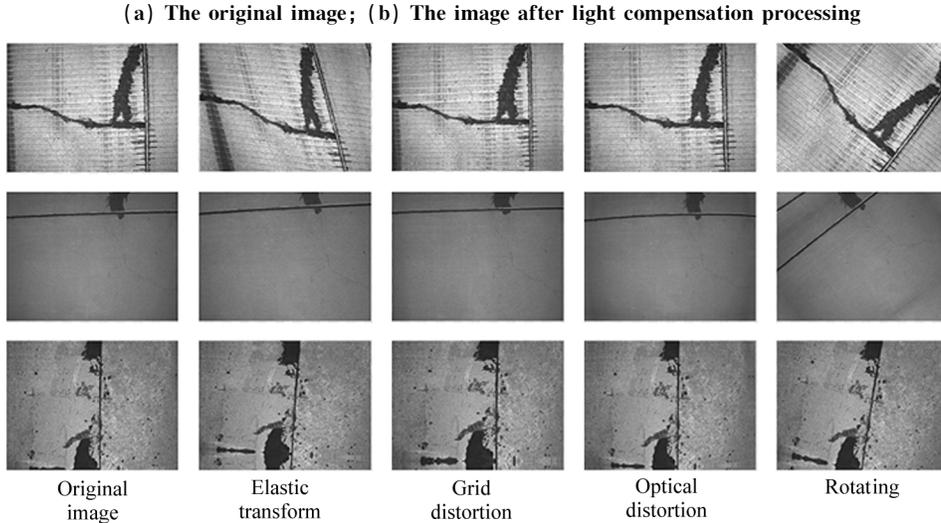


图 7 通过不同类型图像增强手段后图像的变化

Fig. 7 Changes in images after different types of image enhancement

3 模型训练

本文算法基于深度学习开源框架 Pytorch 实现,使用 Python 编程语言,程序运行的环境是主频为 3.20 GHz 的 i7-8700CPU,16 GB 运行内存,GPU 为 GeForce RTX 2080,8 GB 显存,操作系统为 Windows 10。实验中,每个 epoch 耗时 4 h 左右。

3.1 评价标准

为了对本文提出的机场道面裂缝检测算法 FE-Unet 进行量化评估,本文采取了精度 (precision, $Prec$)、召回率 (recall, Rec)、和 $F1$ 对结果进行定量分析。精度表示裂缝区域像素被正确检出来的像素个数占检测出来的总的裂缝数量的比例;召回率表示被正确检出的裂缝像素个数占应被正确检出的裂缝像素个数的比例; $F1$ 是 $Prec$ 与 Rec 的综合评价指标。3 项指标分别定义如下:

$$Prec = \frac{TP}{TP + FP}, \quad (9)$$

$$Rec = \frac{TP}{TP + FN}, \quad (10)$$

$$F1 = 2 \cdot \frac{Prec \cdot Rec}{Prec + Rec}, \quad (11)$$

式中, TP 表示裂缝区域被正确检测出的裂缝像素个数, FP 表示非裂缝区域被预测为裂缝的像素个数, FN 表示裂缝区域未被检测为裂缝的像素个数。

3.2 损失函数

本文首先选用交叉熵 (cross entropy, CE) 损失函数对模型参数进行优化。

$$CE(p_k) = -\lg(p_k), \quad (12)$$

式中, p_k 表示预测样本属于第 k 类别的概率。

对于裂缝图像数据,由于裂缝呈线性分布且只占图像的小部分,图像大多为背景信息。造成了负样本过多,在训练的时候,背景的损失占据总损失的大部分,影响模型的优化方向。针对正负样本不平衡的情况,本文使用 FL 来平衡样本的权重。

$$FL(p_k) = -\alpha(1 - p_k)^\gamma \lg(p_k), \quad (13)$$

式中, α 为一常数,当 γ 增加的时候, α 需要减小一点,本次实验 $\alpha=2.5$, γ 为注意参数,本次实验 $\gamma=2.0$; $(1 - p_k)^\gamma$ 为调制系数,通过该系数减少易分类样本的权重,从而使模型更加专注于难分类样本。

3.3 模型设置

本文算法在训练中,批量大小为 4,优化器选用 Adam,初始学习率为 0.0001,第一次估计的指数衰减率为 0.9,第二次指数衰减率为 0.999。损失函数选用 CE 和 FL,激活函数选用 ELU。

3.4 训练结果

图 8(a)展示了 FE-Unet 模型在训练过程中裂缝

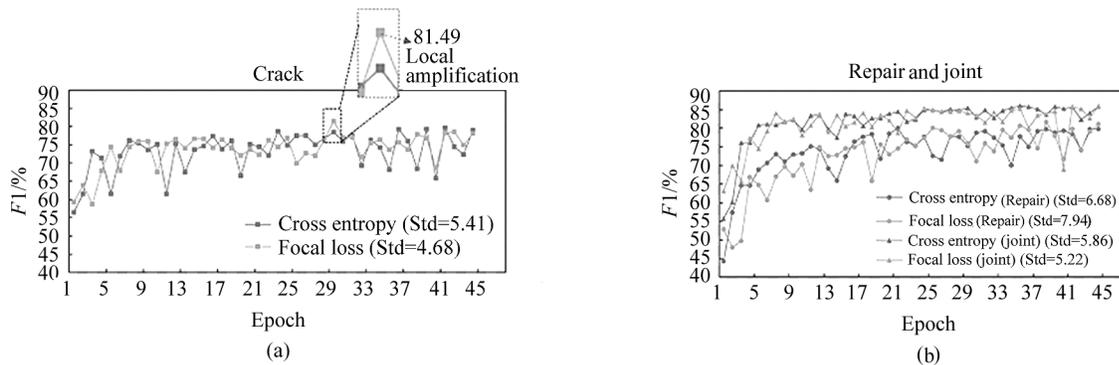


图 8 训练过程参数变化曲线图:(a) 裂缝 F1 值变化曲线;(b) 灌缝和板缝 F1 值变化曲线

Fig. 8 Curves of parameter change in training process:(a) Curves of F1 value of crack;
(b) Curves of F1 value of repair and joint

4 实验结果与分析

4.1 裂缝的识别

表 1 展示了利用 CE 和 FL 函数训练 DeepLab v3、FCN、Unet 以及 FE-Unet 模型的最终对裂缝的识别结果的 F1 值对比。从表 1 中可以看出,使用 FL 作为损失函数时,在部分网络的裂缝识别精度方面有所下滑。但是,使用 FL 函数对模型预测结果的召回率的提升效果十分明显。同时,对于不同的模型,使用 FL 函数对模型的 F1 值均有提升,其中对 FCN 以及 FE-Unet 模型作用效果明显,其 F1 值分别提升了 4.93% 和 2.8%,使 FE-Unet 模型的 F1 值达到了 81.49%。本次实验后续的对比如均为使用 FL 函数训练出的模型结果的对比。

从表 1 整体数据以及图 9 整体效果来看,FE-Unet 对裂缝的检测效果更好,在不同场景下,FE-Unet 网络对机场道面裂缝的检测效果明显优于 DeepLab v3、FCN 和 Unet。

从图 9 中图像 1 的检测结果可以看出,对于背景简单且裂缝特征明显的图像,DeepLab v3、FCN、Unet 和 FE-Unet 均有较好的检测效果。具体对比来看,FE-Unet 网络的分割结果完整度最高,分割结果更加精细,最接近图 9 中第 2 行所展示的真实标注 (ground truth, GT) 结果。

识别的 F1 值的变化情况。从图中可以看出,使用 FL 函数训练模型时,裂缝的 F1 达到最大值 81.49%。图 8(b)展示了训练过程中灌缝和板缝 F1 值变化情况。结合(a)和(b)可以看出,对于裂缝和板缝,分割对象目标较小时,FL 训练模型时会更加稳定;对于灌缝,分割目标较大,使用 CE 损失函数训练模型时会更加稳定。

结合图 9 中图像 2 的检测结果可以看出,对于有板缝、存在轻微干扰、背景出现色差且裂缝较细的图像,DeepLab v3、FCN、Unet 和 FE-Unet 对裂缝的识别结果都受到不同程度的影响,对比其他网络模型结果来看,FE-Unet 模型对细裂缝分割结果更加精细,连续性更好。

当裂缝特征较为明显但是图像背景较暗且存在其他干扰因素时,如图 9 中图像 3 所示,FE-Unet 整体性能优于其他 3 个网络,DeepLab v3、FCN 和 Unet 均不能完整地检出裂缝,FE-Unet 模型的检测结果虽然存在一定程度上的不连续,但是整体对裂缝的检出结果明显优于其他 3 个模型的结果。

对于像图 9 中图像 4 这种背景复杂、存在灌缝等干扰因素且裂缝形态复杂的图像,DeepLab v3、FCN、Unet 和 FE-Unet 均能在不同程度检出裂缝,但是,DeepLab v3、FCN 和 Unet 模型对于干扰因素较多的图像,抗干扰能力较差;FE-Unet 相对于其他 3 个模型有着较强的抗干扰能力。对于背景极为复杂的机场道面图像,如图 9 中图像 5 所示,DeepLab v3 不能检出该场景下的裂缝,FCN 和 Unet 仅能检出极少部分裂缝,虽然 FE-Unet 也不能完全检出该场景下的裂缝,但是相对于 DeepLab v3、FCN 和 Unet,FE-Unet 检出的裂缝最完整,最接近真实情况。

总的来说,FE-Unet 对于不同场景下图像中的裂缝均能实现较好的提取效果,通过与 DeepLab v3、

FCN 和 Unet 进行对比,FE-Unet 识别出的裂缝更完整,更接近实际。

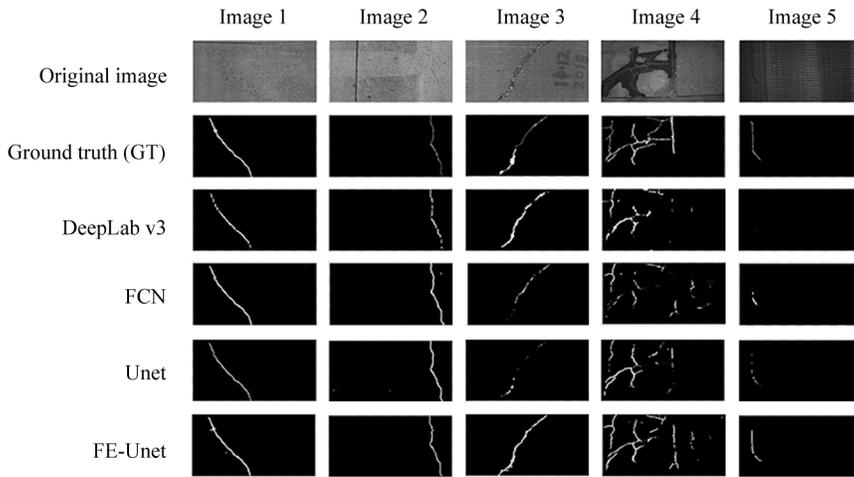


图 9 不同算法裂缝识别结果对比

Fig. 9 Comparison of crack recognition results of different algorithms

表 1 裂缝识别的性能对比

Tab. 1 Performance comparison of crack identification

Loss function	Model	Crack		
		Prec/%	Rec/%	F1/%
Cross entropy	DeepLab v3 ^[9]	67.82	58.46	62.79
	FCN ^[11]	74.40	62.68	68.04
	Unet ^[13]	78.64	64.54	70.89
	FE-Unet	81.91	75.71	78.69
Focal loss	DeepLab v3 ^[9]	67.15	60.73	63.78
	FCN ^[11]	77.64	68.83	72.97
	Unet ^[13]	78.71	67.54	72.69
	FE-Unet	80.31	82.72	81.49

4.2 灌缝和板缝的识别

机场道面板块的道面状况指数(pavement condition index, PCD)的计算不仅与表面的裂缝有关,还与灌缝和板缝等因素有关。因此,本次实验在识别

裂缝的同时还对机场道面中存在的板缝和灌缝进行识别。

4.2.1 灌缝的识别

图 10 和表 2 展示了不同的模型对机场道面中存在的灌缝的识别效果。原图中黑色区域为灌缝区域。从数据上来看,使用 FL 函数训练出的 FE-Unet 模型对灌缝识别的精度、召回率与 F1 值分别为 68.07%、85.67% 和 75.86%,总体要优于其他模型。具体来看,虽然 DeepLab v3、FCN 和 Unet 模型可以较为准确地识别裂缝,但是对灌缝的识别的整体性较差。从表 2 中可以看出,DeepLab v3、FCN、Unet 和 FE-Unet 通过 FL 函数训练后,模型对灌缝的识别效果有一定程度上的提升。本文的 FE-Unet 模型不仅对裂缝有着较好的识别效果,同时也能较为完整地识别出灌缝。

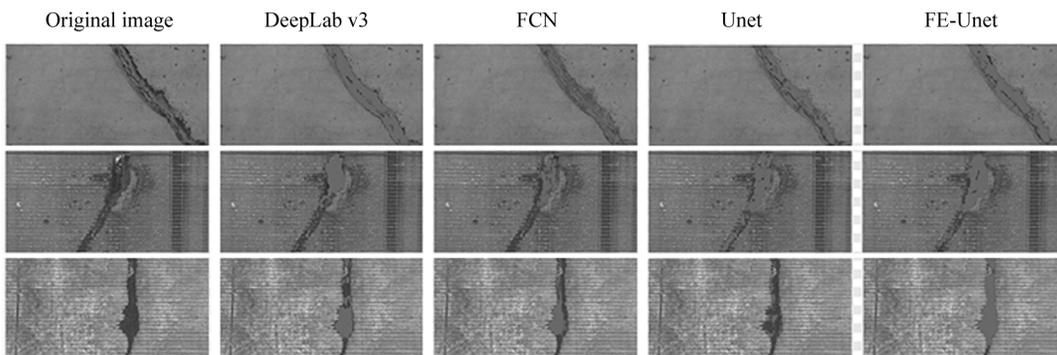


图 10 不同算法灌缝识别结果对比

Fig. 10 Comparison of repair recognition results of different algorithms

表 2 灌缝识别的性能对比

Tab. 2 Performance comparison of repair recognition

Loss function	Model	Repair		
		Prec/%	Rec/%	F1/%
Cross entropy	DeepLab v3 ^[9]	52.38	74.46	61.50
	FCN ^[11]	60.05	67.81	63.69
	Unet ^[13]	63.66	69.71	66.55
	FE-Unet	91.48	63.91	75.25
Focal loss	DeepLab v3 ^[9]	55.29	74.83	63.59
	FCN ^[11]	66.45	72.30	69.25
	Unet ^[13]	59.88	84.75	70.18
	FE-Unet	68.07	85.67	75.86

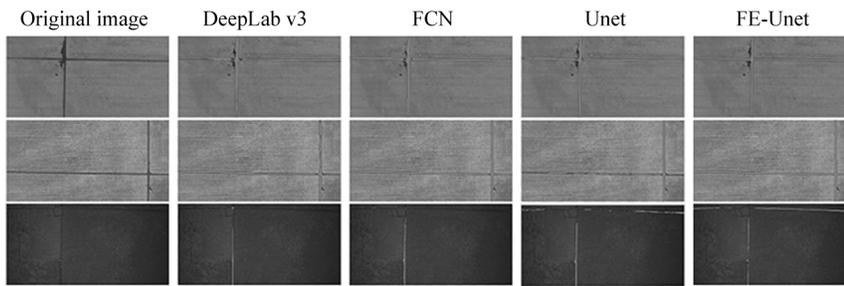


图 11 板缝识别性能对比

Fig. 11 Performance comparison of joint recognition performance

表 3 板缝识别的性能对比

Tab. 3 Performance comparison of joint recognition

Loss function	Model	Joint		
		Prec/%	Rec/%	F1/%
Cross entropy	DeepLab v3 ^[9]	63.60	84.68	72.64
	FCN ^[11]	87.96	66.56	75.78
	Unet ^[13]	72.87	82.89	77.56
	FE-Unet	90.32	75.71	82.37
Focal loss	DeepLab v3 ^[9]	72.50	78.04	75.16
	FCN ^[11]	80.35	75.52	77.86
	Unet ^[13]	85.09	76.03	80.31
	FE-Unet	88.03	80.47	84.08

4.3 消融实验

FE-Unet 整体架构设计采用模块化的概念,每个模块都是相对独立设计的,允许根据实际需求来设计与升级网络。为了验证 FE-Unet 模型中 RRB

4.2.2 板缝的识别

图 11 和表 3 展示了不同模型对机场道面的板缝的识别效果。从数据上来看,使用 FL 函数训练出的 FE-Unet 模型对板缝识别的精度、召回率与 F1 值分别为 88.03%、80.47% 和 84.08%,总体优于其他模型。具体来看,相对于 DeepLab v3、FCN 和 Unet 模型,FE-Unet 能够识别出更加完整的板缝。同时,从表 3 可以看出,对于板缝的分割,使用 FL 函数训练出的模型有着更好的性能。

和 CAB 的有效性,本文开展如下消融实验,实验结果如表 4 所示。从表 4 的数据中可以看出,在 Unet 模型中,分别引入 RRB 和 CAB 后,模型的性能均得到了一定程度的提升。同时,在 FE-Unet 模型中,去掉 RRB 时,模型对裂缝、灌缝和板缝的整体识别性能下降幅度明显,其 F1 值分别降低至 73.19%、72.10% 和 81.08%。实验结果表明,RRB 能够获取更多有效的特征信息。单独从 FE-Unet 模型中去掉 CAB 时,模型对裂缝、灌缝和板缝的整体识别性能也出现了一定程度上的下降,其 F1 值分别降低至 77.34%、71.92% 和 81.74%。实验结果表明,CAB 能够提取并保留更具区分性的特征。由表 4 消融实验可知,当两个模块同时使用时,FE-Unet 模型对裂缝、灌缝和板缝的识别精度、召回和 F1 值均达到最高,验证了 CAB 和 RRB 的有效性。

表 4 FE-Unet 不同模块有效性验证

Tab. 4 Verification of the effectiveness of different FE-Unet modules

Model	Crack			Repair			Joint		
	Prec/%	Rec/%	F1/%	Prec/%	Rec/%	F1/%	Prec/%	Rec/%	F1/%
Unet	78.71	67.54	72.69	59.88	84.75	70.18	85.09	76.03	80.31
Unet+CAB	76.83	69.88	73.19	67.78	77.00	72.10	85.17	77.35	81.08
Unet+RRB	73.29	81.86	77.34	68.07	76.23	71.92	86.00	77.88	81.74
FE-Unet	80.31	82.72	81.49	68.07	85.67	75.86	88.03	80.47	84.08

4.4 实验总结

本次实验以现有的机场道面数据集为基础,分别使用 DeepLab v3、FCN、Unet 和 FE-Unet 模型来识别机场道面特征(裂缝、灌缝、板缝),并总结如下:

本次实验对机场道面图像中存在的裂缝进行识别,实验结果表明,使用 FL 函数训练出的 FE-Unet 模型具有较好的鲁棒性,能在有不同干扰程度的图像中较为准确地识别出机场道面存在的裂缝。

除此之外,本文也对灌缝和板缝的识别性能进行了评估。最终识别结果表明,FE-Unet 对灌缝和板缝的识别效果也有相当的水准。

FE-Unet 模型对机场道面中的裂缝、灌缝和板缝识别结果明显优于 DeepLab v3、FCN 和 Unet。

5 结 论

本文提出了新型的图像分割模型 FE-Unet,利用 RRB 以及 CAB 来提升道面表观特征的识别能力。在训练过程中,相较于传统的 CE 损失,FL 更加关注道面特征处的误差,进而提升裂缝、灌缝和板缝的识别能力。实验结果表明,深度学习模型很有希望落地应用,为机场道面检测人员减少工作量以及对机场道面养护与管理提供了理论依据。

参考文献:

- [1] GOU C, PENG B, LI T, et al. Pavement crack detection based on the improved Faster-RCNN[C]//2019 IEEE 14th International Conference on Intelligent Systems and Knowledge Engineering (ISKE), November 14-16, 2019, Dalian, China. New York: IEEE, 2020: 962-967.
- [2] DENG J H, LU Y, LEE V C. Concrete crack detection with handwriting script interferences using faster region-based convolutional neural network [J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35(4): 373-388.
- [3] UKHWAH E N, YUNIARNO E M, SUPRAPTO Y K. Asphalt pavement pothole detection using deep learning method based on YOLO neural network[C]//2019 International Seminar on Intelligent Technology and Its Applications (ISITIA), August 28-29, 2019, Surabaya, Indonesia. New York: IEEE, 2020: 35-40.
- [4] FAN R, BOCUS M J, ZHU Y, et al. Road crack detection using deep convolutional neural network and adaptive thresholding[C]//2019 IEEE Intelligent Vehicles Symposium (IV), June 9-12, 2019, Paris, France. New York: IEEE, 2019: 474-479.
- [5] WEN Q. Research and implementation of building surface crack detection technology based on deep learning[D]. Beijing: Beijing University of Posts and Telecommunica-

tions, 2019: 13-14.

文青. 基于深度学习的建筑物表面裂缝检测技术研究与应用 [D]. 北京: 北京邮电大学, 2019: 13-14.

- [6] ZHANG A, WANG K C P, LI B X, et al. Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep-learning network [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(10): 805-819.
- [7] LIU Y H, YAO J, LU X H, et al. DeepCrack: a deep hierarchical feature learning architecture for crack segmentation [J]. Neurocomputing, 2019, 338(21): 139-153.
- [8] CAO J G, YANG G T, YANG X Y. Pavement crack detection with deep learning based on attention mechanism [J]. Journal of Computer-Aided Design and Computer Graphics, 2020, 32(8): 1324-1333.
曹锦钢, 杨国田, 杨锡运. 基于注意力机制的深度学习路面裂缝检测 [J]. 计算机辅助设计与图形学学报, 2020, 32(8): 1324-1333.
- [9] SARMIENTO J A. Pavement distress detection and segmentation using YOLOv4 and DeepLabv3 on pavements in the Philippines [EB/OL]. (2021-03-11)[2022-02-28]. <https://arxiv.org/abs/2103.06467>.
- [10] DUNG C, LE D A. Autonomous concrete crack detection using deep fully convolutional neural network [J]. Automation in Construction, 2018, 99(1): 52-58.
- [11] 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.
- [12] ZHANG L X, SHEN J K, ZHU B J. A research on an improved Unet-based concrete crack detection algorithm [J]. Structural Health Monitoring, 2021, 20(4): 1864-1879.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation [EB/OL]. (2015-05-18) [2022-02-28]. <https://arxiv.org/abs/1505.04597>.
- [14] 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.
- [15] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [EB/OL]. (2015-12-10) [2022-02-28]. <https://arxiv.org/abs/1512.03385>.
- [16] YU C, WANG J, PENG C, et al. Learning a discriminative feature network for semantic segmentation [EB/OL]. (2018-04-25) [2022-02-27]. <https://arxiv.org/abs/1804.09337>.

作者简介:

罗仁泽 (1973—), 男, 博士研究生, 教授, 主要研究方向为人工智能信号处理。