



计算机科学

COMPUTER SCIENCE

基于弱监督语义分割的道路裂缝检测研究

赵卫东, 路明, 张睿

引用本文

赵卫东, 路明, 张睿. 基于弱监督语义分割的道路裂缝检测研究[J]. 计算机科学, 2024, 51(11): 148-156.

ZHAO Weidong, LU Ming, ZHANG Rui. Study on Road Crack Detection Based on Weakly Supervised Semantic Segmentation [J]. Computer Science, 2024, 51(11): 148-156.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

一种引入核心实体关注度评估的KBQA算法

KBQA Algorithm Introducing Core Entity Attention Evaluation

计算机科学, 2024, 51(11): 239-247. <https://doi.org/10.11896/jsjcx.230900028>

面向自动驾驶的高精度实时语义分割算法架构

High-precision Real-time Semantic Segmentation Algorithm Architecture for Autonomous Driving

计算机科学, 2024, 51(11): 174-181. <https://doi.org/10.11896/jsjcx.231000009>

基于策略蒸馏主仆框架的优势加权双行动者-评论家算法

Advantage Weighted Double Actors-Critics Algorithm Based on Key-Minor Architecture for Policy Distillation

计算机科学, 2024, 51(11): 81-94. <https://doi.org/10.11896/jsjcx.231000170>

面向多目标状态感知的自适应云边协同调度研究

Study on Adaptive Cloud-Edge Collaborative Scheduling Methods for Multi-object State Perception

计算机科学, 2024, 51(9): 319-330. <https://doi.org/10.11896/jsjcx.240200036>

基于不确定性权重的保守Q学习离线强化学习算法

Offline Reinforcement Learning Algorithm for Conservative Q-learning Based on Uncertainty Weight

计算机科学, 2024, 51(9): 265-272. <https://doi.org/10.11896/jsjcx.230700151>

基于弱监督语义分割的道路裂缝检测研究

赵卫东 路明 张睿

复旦大学软件学院 上海 200433

上海市数据科学重点实验室 上海 200433

摘要 基于弱监督语义分割的道路裂缝检测方法大多基于先分块后检测的流程,分块增加了标注的工作量和误判的分块数量。针对上述问题,提出了基于深度强化学习的道路裂缝分块分类模型,根据道路裂缝图像特点,对智能体的状态、动作和获取的奖励进行了设计,训练智能体自主选择裂缝分块,并将选择结果作为分块标签用于多尺寸分块道路裂缝检测。在 *cqu-bpdd* 等数据集上进行的对比实验,证明了所提方法在道路裂缝分割性能、裂缝平均宽度的测量准确度方面优于现有方法。

关键词: 道路裂缝检测; 弱监督; 语义分割; 裂缝分块; 深度强化学习

中图分类号 TP391

Study on Road Crack Detection Based on Weakly Supervised Semantic Segmentation

ZHAO Weidong, LU Ming and ZHANG Rui

School of Software, Fudan University, Shanghai 200433, China

Shanghai Key Laboratory of Data Science, Shanghai 200433, China

Abstract Most of the existing weakly supervised semantic segmentation methods are based on the process of blocking before detection, which increases the annotation workload. However, the existing automatic block classification methods input all blocks into the model to predict the block category, increasing the number of blocks that are misjudged and affecting the performance of subsequent semantic segmentation. Aiming at the above problems, this paper proposes a road crack block classification model based on deep reinforcement learning. According to characteristics of road crack images, the states, actions, and rewards obtained by the agents are designed. The agent is trained to select crack blocks independently, and the selection results are used as block labels for multi-size block road crack detection. Through comparative experiments on several datasets, it is proved that the proposed model outperforms existing methods in terms of road crack segmentation performance and crack width measurement accuracy.

Keywords Road crack detection, Weakly supervision, Semantic segmentation, Crack blocks, Deep reinforcement learning

1 引言

传统的道路裂缝检测需要人工进行巡检、拍摄和测量。随着图像处理、机器视觉和深度学习等技术的发展,通过道路检测车和无人机拍摄路面图像并进行自动检测已成为主流的道路检测手段。主要的检测方法有图像分类、目标检测和语义分割等^[1-4]。其中,图像分类可以区分裂缝的类型;目标检测可以使用矩形框检测出裂缝的范围,估算出裂缝的面积。但这两种检测方法均无法得到较为精准的裂缝位置。而语义分割不仅能区分裂缝的类型,还能以像素级的精度检测裂缝的具体位置,后续也可以在此基础上计算出较为准确的裂缝面积,同时通过骨架提取方法得到裂缝长度,进而得到平均宽度等重要的公路技术评估指标,因而成为道路裂缝检测的重要方法。

使用完全监督的语义分割进行道路裂缝检测,需要对大量道路图像进行像素级的裂缝标注,制作训练数据需耗费较高的时间和人力成本^[5-7]。针对不同路面材质和路面环境,需要采集相应的路面图像并进行标注,这也加大了标注的工作量。同时,道路裂缝类型的判断和范围的界定需要一定的专业知识和经验,能胜任的标注人员较少,导致标注工作的难度和时间进一步增加。弱监督语义分割使用更粗糙的标注数据进行训练,可以使用图像级的类别标签训练模型完成语义分割任务,从而大幅减少标注工作量,该方法更适合实际的道路检测工作。现有基于弱监督语义分割的道路裂缝检测研究中,由于原图尺寸较大、裂缝占比较小等原因,通常会对原图进行分块后再进行检测。随着原图尺寸和分块数量的增加,分类标注的工作量不断增加,从而降低了弱监督语义分割相对于完全监督语义分割的优势。

到稿日期:2023-10-23 返修日期:2024-03-07

基金项目:国家自然科学基金(71971066)

This work was supported by the National Natural Science Foundation of China(71971066).

通信作者:赵卫东(wdzhao@fudan.edu.cn)

针对上述问题,本文对基于弱监督语义分割的道路裂缝检测进行了进一步的研究,对现有方法中图像分块标注这一重要环节进行了优化,使用深度强化学习的方法,结合道路裂缝的图像形态特点,设计了智能体的状态、动作和奖励函数,训练智能体进行多种尺寸图像分块的类别标注,并进行弱监督语义分割。最后,在 *cqu-bpdd* 等数据集上进行了实验,证明了该方法的有效性^[8]。

2 相关工作

道路裂缝图像通常有两个特点:(1)由道路检测车或无人机拍摄的路面图像通常尺寸较大且数量较多,例如 Yan 和 Zhang 拍摄了 22254 张尺寸为 1688×1874 的路面图像,Zhu 和 Song 制作了 93000 张 512×512 的道路裂缝数据集^[9-10];(2)常见的道路裂缝通常为细长形态,裂缝部分占整个图像的比例很小,直接对原图进行检测效果较差。因此,现有基于弱监督学习的道路检测方法通常基于“分块-标注-检测-拼接”的流程,即先对原图进行分块并标注类别,再使用弱监督方式对分块进行检测,最后将各分块的检测结果拼接成原图尺寸,得到最终的检测结果。根据检测结果粒度的不同,基于弱监督学习的道路检测方法可分为分块级检测、特征级检测和像素级检测 3 类。

(1)分块级检测。将道路裂缝图像进行分块后,利用原图的分类标注预测各分块的分类,从而得到损坏图像的块级别检测结果。例如 Huang 等提出的 WSPLIN-IP 以及 Tang 等提出的 IOPLIN,分别通过综合决策网络和期望最大化方法,从图像级分类标签预测了各分块的分类标签^[8,11]。此类方法可以检测出损坏分块所在的位置,但无法得到像素级的分割结果。同时此类方法还存在以下问题:一是所有分块都要在分块标签推理网络中进行一次前向传播,在正常分块占多数的情况下,这会严重影响分类准确率;二是其对分块的切分方法虽有优化工作,但缺少对各分块间相似关系的研究。

(2)特征级检测。将道路裂缝图像进行分块后,人工标注分块图像的类别,通过训练分类网络生成各分块的类激活图(Class Activation Maps, CAM)得到检测结果。例如, Xu 等使用 CAM 对路面裂缝检测模型的性能进行可视化对比,并通过 CAM 获取了裂缝的大致分布^[12]; Li 等在对水坝表面裂缝进行检测的过程中,使用 Grad-CAM 生成了分块的 CAM 图像,并将其拼接成原图尺寸^[13]。此类方法可以检测出裂缝的大致形态和走向,但边界处与真实裂缝区域差异较大,虽然为一些不需要精确检测的任务(如计算损坏的区域面积)提供了较可靠的语义信息,但是无法准确获取损坏宽度等重要指标。

(3)像素级检测。将道路裂缝图像进行分块后,人工标注分块图像的类别,通过弱监督方式得到每个分块的 CAM,将其作为分割伪标签,对 CAM 优化后进行语义分割,得到检测结果。Wang 等用此方法得到了裂缝的像素级检测结果^[14]。此类方法可以得到像素级的分割结果,但是需要对分块的类别进行手工标注。由于实际项目中损坏图像尺寸较大,分块

数量较多(例如 Dong 等拍摄了 521 张分辨率从 12614×2922 到 34473×2956 的裂缝图像,将其分成约 39 万个分块图像进行人工标注),因此此类方法仍需要耗费巨大的人力成本^[15]。

除了以上 3 个主要的研究方向之外,还有一类研究主要是针对不准确的路面裂缝标注,使用弱监督学习的方式获取分割结果。例如, Rill-Garcia 等针对不准确的像素级标注,使用模型预测的结果进行自训练,每个新模型将前一个模型的输出作为输入预测新的伪标签^[16]; Inoue 等设计了一个双分支模型在不准确的标注上进行训练, macro 分支基于不精准的标注进行语义分割, micro 分支对分割结果的边界进行修正^[17]。此类研究主要针对不准确的人工标注,未能对模型自动生成的伪标签进行研究。

在道路裂缝检测的分块标注环节,为了减少人工标注工作量,可以使用深度强化学习的方法训练智能体进行自动标注。目前基于深度强化学习的分块分类工作较少,但基于深度强化学习的目标定位与分块分类有一定的相似之处并获得了一定的成果。这类研究通常使用深度神经网络提取图像特征,将其作为强化学习中智能体的状态,将目标框的平移、缩放和比例改变等一系列变化作为动作,将预测目标框与真实目标框的 IOU(Intersection over Union)作为奖励,在没有真实目标框的情况下,根据预测目标框内外的分类概率计算奖励并指导智能体寻找最佳目标框^[18]。

上述研究取得了一定的成果,但在对原图像进行分块和分块类别标注环节仍有不足。道路裂缝检测前需要将原图像切分成大量分块图像,并进行分类标注,人工标注工作量极大,削减了弱监督学习的优势。而现有方法将原图像所有的分块都输入分类模型进行预测,未充分利用原图的分类标签对可能存在裂缝的分块进行预选,也没有对分块分类结果进行进一步的校正,导致分块分类标签准确度不高,从而降低了最终的裂缝检测效果。

3 问题定义

道路裂缝图像的分块分类任务是在只有原图分类标签的情况下,期望获取分块图像的分类标签。由于无法直接训练分块图像的分类模型,因此将其转换为一个序列动作的决策优化问题,使用深度强化学习的方法进行处理。通常的图像分类任务通过训练分类模型对图像的类别进行预测,任何一张图像的分类结果都不会影响下一张图片的分类结果。而在道路裂缝图像的分块分类任务中,智能体每次从原图像的分块中选择一个可能存在裂缝的分块,不断迭代,直到没有存在裂缝的分块,从而完成分块分类任务。在这个过程中,每次分块的选择会影响下一步可选的分块,所选分块存在裂缝的概率也将影响最终分类的准确率,任务的目标是使选择的分块存在裂缝的概率尽可能高,未选分块存在裂缝的概率尽可能低。

为了简化问题,本文选择较常见的条状裂缝和网状裂缝作为主要研究对象,将其与无裂缝的道路图像组成训练数据集,使用强化学习的方法,研究分块裂缝的分类模型。

基于强化学习的试错思想,训练智能体判断分块图像中是否存在裂缝。智能体在每一张图像的各个分块中进行

选择,刚开始时智能体接近于随机选择裂缝分块,选择错误或者选择正确将相应获得惩罚或奖励,并通过奖励函数进行量化。为了达到最大化奖励这一目标,智能体不断完善分块选择动作,使得获得的奖励越来越高,从而学会在给定图像中选择最佳的动作。

针对上述分块分类问题,将基于强化学习的分块裂缝分类问题定义如下:

已知原道路裂缝图像及其分类标签 $(\bar{X}; \bar{y})$, 将每张裂缝图像切分为 $r \times c$ 个分块, 得到分块图像为 $\{\bar{X}_{(i,j)}, i \in [1, r], j \in [1, c]\}$, 在没有真实分块裂缝分类标签的情况下, 训练模型预测 $\{\bar{X}_{(i,j)}\}$ 的分类标签 $\{\bar{y}_{(i,j)}\}$ 。

对于每一张道路裂缝图像 X , 智能体从其分块 $\{X_{(i,j)}\}$ 中选择可能裂缝的分块, 判断为存在裂缝的分块记为 $\{X_{(i,j)}^{\text{damage_pre}}\}$, 判断为无裂缝的分块记为 $\{X_{(i,j)}^{\text{normal_pre}}\}$, 智能体需要最大化预判为裂缝分块的概率:

$$X = \{X_{(i,j)}^{\text{damage_pre}}\} + \{X_{(i,j)}^{\text{normal_pre}}\}, \max_{X_{i,j}} P(\{X_{(i,j)}^{\text{damage_pre}}\})$$

本文将强化学习中的状态、动作和奖励定义如下:

- (1) t 时刻的状态为 X 去除已选分块后的部分图像特征, 记为 s_t 。
- (2) t 时刻的动作用于选择可能裂缝的分块, 记为 a_t , 动作的数量记为 N_{action} 。
- (3) $t+1$ 时刻的状态为选择 a_t 后下一时刻的状态, 记为 s_{t+1} 。
- (4) 奖励是环境在 (s_t, a_t) 下赋予智能体的奖励值, 记为 r_t 。

4 基于 DQN 的道路裂缝分块分类模型

现有的道路裂缝图像的分块分类方法主要有 Huang 等提出的 WSPLIN-IP^[11] 以及 Tang 等提出的 IOPLIN^[8]。WSPLIN-IP 方法使用原图不同尺寸的分块图像构建图像金字塔, 训练分块标签推理网络, 并通过综合决策网络以弱监督的方式引导分块标签推理网络进行学习, 完成道路裂缝图像的分块分类任务。IOPLIN 方法通过期望最大化进行分块标签蒸馏, 迭代地训练分块标签推理网络, 从而实现道路裂缝图像的分块分类。这两种方法在 cqu-bpdd 数据集上有较好的分块分类效果, 但均存在如下问题: 将所有分块都输入分类模型进行预测。由于路面裂缝所占面积相比于无裂缝部分通常较小, 因此进行分块后裂缝分块与无裂缝分块的数量相差较大, 分块图像作为后续弱监督语义分割的训练数据需要进行数据平衡, 很大一部分的无裂缝分块并不参与后续训练, 预测其分类会增加训练数据中的错误标签数量, 从而降低分块分类的准确率。本文基于强化学习的思想, 通过深度价值网络训练智能体选择裂缝的大致部位, 将预判为裂缝的分块输入分块裂缝分类模型, 预判为无裂缝的分块不再进行分类预测, 从而减少误判的分块数量, 提高分块分类的准确率。

深度强化学习是强化学习与深度学习相结合的产物, 使用神经网络作为网络结构。代表工作有 DeepMind 提出的 AlphaGo 以及腾讯 AI 实验室提出的深度强化学习框架等。

本文基于 DQN 的道路裂缝分块分类模型, 设计了价值网络和目标网络、智能体的状态和动作, 并利用原道路裂缝图像的分类标签同步训练分类模型用于奖励值的计算。图 1 展示了模型的总体结构。

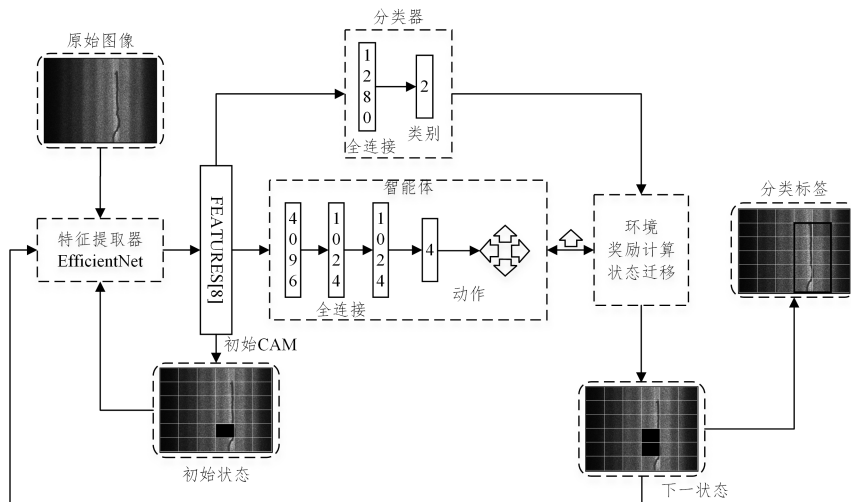



图 1 基于 DQN 的分块分类模型

Fig. 1 Model of road crack block classification based on DQN

4.1 状态设计

强化学习中的状态代表智能体当前的状况。首先将原图像划分为 $r \times c$ 个分块区域, 在基于深度强化学习的分块裂缝分类问题中, 智能体的状态与智能体选择的裂缝分块有关, 已选分块图像和未选分块图像都可以作为智能体的状态, 如图 2 所示。如果使用已选分块图像作为状态, 状态对应的图像为已选分块覆盖到原图大小的黑色

背景图上, 则初始的状态仅有一个分块, 其余均为黑色图像, 输入 DQN 计算 Q 值或输入分类器计算裂缝概率时的准确率较低, 导致后续的训练效果较差。因此使用未选分块图像作为状态, 状态对应的图像是在原图已选分块的位置上覆盖相应的黑色图像, 从而使得初始图像仅有一块黑色图像, 其余图像为原图像分块, 提高了后续计算 Q 值和裂缝概率的准确率, 改善了训练效果。



(a) 已选分块作为状态 (b) 未选分块作为状态

图2 将已选分块作为状态和未选分块作为状态

Fig. 2 Using selected blocks and unselected blocks as state

(1) 初始状态

初始状态可以使用原图像 X 的特征图,由智能体通过随机方式选择第一个可能存在裂缝的分块。但由于原图像中裂缝部分的占比较小,随机方式选择的分块大概率为无裂缝的分块,导致后续训练困难,最终选择的裂缝范围与真实裂缝部分相差较大,因此考虑充分利用原图分类信息,计算原图的 CAM,从而得到初始分块,如图 3 所示。




图3 由 CAM 确定初始状态

Fig. 3 Initial state determined by CAM

完全使用 CAM 覆盖的分块作为初始的裂缝分块也存在问题:一是进行二值化时难以确定最佳阈值,容易导致选择的初始分块数量过多,或选择不到初始分块,使得后续训练无法进行;另一个是 CAM 往往关注局部区域甚至是一些无裂缝的区域,容易选择到无裂缝的分块。本文通过对 CAM 进行二值化和坐标平均的方法来缓解上述问题。

(2) 状态转移

智能体在当前状态 s_t 选择了动作 a_t 后,其状态需要进行变换,下一时刻的状态 s_{t+1} 通过 s_t 和 a_t 即可计算得出。在 t 时刻,状态 s_t 对应的图像为原图像中已选分块用黑色背景遮盖后的图像,将其表示为分块的集合形式 $\{X_t\}$,将动作 a_t 对应选择的分块表示为 $\{X_{a_t}\}$,那么从当前状态对应的图像中将所选分块去除后即得下一状态的图像,即 $s_{t+1} = \{X_t\} - \{X_{a_t}\}$,如图 4 所示。




图4 状态转移

Fig. 4 State transition

4.2 动作设计

分块裂缝分类与目标检测中的目标定位有相似之处,两者都是选择图像中的一部分,使其尽可能与目标(如物体或裂缝部位等)的范围接近。不同之处是目标检测使用矩形窗口,用回归的方式寻找最佳位置和大小,是一个连续的过程;而分块裂缝分类则是选择由若干个分块组成的

裂缝区域,这个区域是一个不规则形状,并且选择过程是一个离散的过程。

分析道路图像中的裂缝部分可以发现,裂缝一般为横向、纵向或网状的连续区域,很少出现分散的裂缝形成多个独立区域。可以针对这一特点设计动作,将分块移动方向作为动作;设置一个活动分块 head,将其运动的方向作为动作,其运动的轨迹作为裂缝分块的选择结果。head 的初始位置为初始状态中已选分块的位置,智能体的动作设计为 head 的运动方向:向上、向下、向左、向右,在未选分块概率小于阈值或 head 周围没有分块可以选择时终止,如图 5 所示。




图5 智能体动作设计

Fig. 5 Agent action design

4.3 奖励函数设计

环境需要对智能体的动作进行奖励或惩罚,以指导智能体的试错过程。奖励和惩罚是衡量智能体行为好坏的标准,智能体的长期目标是使得其动作获得的奖励最大。智能体的动作选择越好,表明智能体选择分块确实为裂缝分块的数量越多,未选分块为无裂缝分块的数量越多。对于道路裂缝分块分类任务,如果使用原始 DQN 的方法,将智能体当前选择的分块存在裂缝的概率值作为奖励值,训练数据只有原图像的分类标签,没有分块的类别标签,只能使用原图训练的分类器预测分块的裂缝概率。由于分块和原图尺寸相差较大(特别是分块数量较多的情况下),因此预测的裂缝概率准确率较低,容易对智能体的决策产生误导,从而增加训练的难度。因此,在分块分类问题中,不直接使用当前动作对应分块的裂缝概率作为奖励值,而是基于当前状态和动作计算未选分块、已选分块的裂缝概率,进行综合评价。

在智能体选择了一个分块并将其从未选分块中去除后,如果未选分块存在裂缝的概率变小,说明所选分块为裂缝分块,模型给予智能体奖励;如果未选分块存在裂缝的概率变大,则所选分块既有可能为裂缝分块,也有可能为正常分块,无法判断智能体选择的好坏,既不给予惩罚,也不给予奖励。类似地,当智能体选择的分块加入已选分块中后,如果已选分块存在裂缝的概率变低,则认为选择的分块为无裂缝分块,给予智能体惩罚;如果已选分块存在裂缝的概率变高,则所选分块既有可能为裂缝分块,也有可能为正常分块,无法判断智能体选择的好坏,既不给予惩罚,也不给予奖励。同时,将奖励值设置为裂缝概率差值与原有概率值之比,以缓解奖励值过大导致训练震荡的问题。本文所提出的奖励函数是基于上述设计原则,经多次实验后得到的最佳奖励函数。

设当前时刻为 t ,未选分块组成图像为 $\{X_t\}$,已选分块组成图像为 $\{Y_t\}$,智能体选择的动作对应分块为 $\{X_{a_t}\}$,下一时刻 $t+1$ 状态对应的图像为 $\{X_t\} - \{X_{a_t}\}$ 。将 t 时刻未选分块的裂缝概率 $P(\{X_t\})$ 记为 $P_{u,t}$, t 时刻已选分块的裂缝概率

$P(\{Y_t\})$ 记为 $P_{s,t}$, $t+1$ 时刻未选分块的裂缝概率 $P(\{X_t\} - \{X_w\})$ 记为 $P_{u,t+1}$, $t+1$ 时刻已选分块的裂缝概率 $P(\{Y_t\} + \{X_w\})$ 记为 $P_{s,t+1}$ 。则奖励 r_t 的计算方法如下:

$$r_t = \begin{cases} \frac{P_{u,t} - P_{u,t+1}}{P_{u,t}}, & P_{u,t} > P_{u,t+1} \\ \frac{P_{s,t+1} - P_{s,t}}{P_{s,t}}, & P_{s,t} > P_{s,t+1} \end{cases}$$

4.4 训练网络

使用神经网络作为智能体的主体网络,将原图像去除已选分块后的图像特征输入网络,来获取当前状态下的状态-动作价值 $Q(s_t, a_t)$,选择 Q 值最大的动作更新状态,再进行下一步的选择,直到终止状态,并不断迭代以训练智能体。训练步骤如下。

(1)使用 Bellman 方程更新状态价值函数,其中 γ 是折扣系数:

$$Q(s_t, a_t) = E[r_t + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}) | s_t, a_t]$$

(2)在第 i 次迭代中定义以下损失函数来训练 Q 网络:

$$L_i(\theta_i) = E[(y_i - Q(s, a; \theta_i))^2]$$

其中训练目标 y_i 为:

$$y_i = E[r_t + \gamma \max_{a_{t+1}} Q(s_{t+1}, a_{t+1}; \theta_{i-1}) | s_t, a_t]$$

(3)使用梯度下降法等优化算法最小化损失函数,训练 DQN 网络。

5 多尺寸分块道路裂缝检测流程

弱监督道路裂缝检测方法主要基于 CAM 方法进行语义分割。由于 CAM 只能检测图像中较显著的裂缝特征,无法获取像素级精度的结果,因此现有研究对其进行了改进。

例如, Xu 等使用 CAM 获取了道路裂缝的大致分布^[12]; Li 等使用分块后再检测的流程,通过 Grad-CAM 生成了裂缝图像分块的 CAM 图像,并将其拼接回原图尺寸^[13]。然而现有研究的改进思路局限在提高弱监督语义分割网络的分割性能,忽略了对分块尺寸的研究。仅用一种尺寸对原图进行分块会导致分块边界处的裂缝检测结果错误,相邻两个分块之间存在重叠、矛盾或明显的边界痕迹,在分块边角处也容易产生误判。本文方法使用多种尺寸对道路裂缝图像进行分块和拼接,充分利用了多尺寸分块的图像信息来提升检测精度。在上文提出的分块分类模型中,由于智能体的动作只有活动分块的上、下、左、右 4 个方向,动作数量与分块数量无关,因此可以将不同尺寸的分块输入同一个 DQN 模型预测分块类别,获取分块训练数据集,这样可以极大地降低分块标注成本,使得多种尺寸分块成为可能。

检测流程主要包括多尺寸分块、邻接块标签校正、分块语义分割、多尺寸分块拼接、分割边界修正部分。多尺寸分块部分使用不同的尺寸对原图进行分块,并使用 DQN 的方法进行自动分类生成分块训练集。使用基于 DQN 的道路裂缝分块分类模型获取的分块分类标签中存在一部分错误标签,因此在对分块进行弱监督语义分割前,通过邻接块标签校正模块对分块标签进行优化校正,提高分块分类标签的准确率。分块语义分割部分通过弱监督语义分割模型获取分块 CAM 并优化生成分割结果。多尺寸分块拼接部分将不同尺寸分块的分割结果进行拼接,生成原图尺寸的裂缝分割结果。分割边界修正部分使用原图的亮度信息对分割结果的边界进行修正。总体检测流程如图 6 所示。

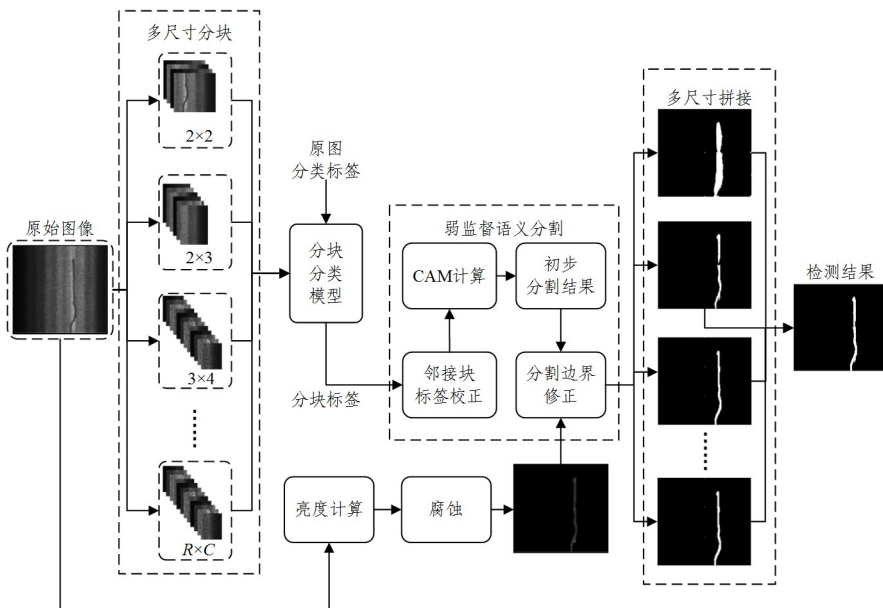


图 6 多尺寸分块道路裂缝检测流程

Fig. 6 Process of multi-size block road crack detection

5.1 邻接块标签校正

通过基于 DQN 的道路裂缝分块分类模型获取的分类标签存在部分错误,例如将无裂缝分块判断为裂缝分块,或将裂缝分块判断为无裂缝分块。分块标签的准确率直接影响了

后续语义分割的性能,因此需要对其进行一定的校正,提高分块的分类准确率。针对道路裂缝的图像形态,根据相邻分块裂缝类型趋于相似的原则,设计了不同的邻接区域的邻接块标签校正方法,如图 7 所示。

由于无裂缝分块的数量较裂缝分块的数量多,因此与某一分块相邻的分块中,无裂缝分块数量一般也多于裂缝分块。如果对判断为有裂缝的分块进行校正,容易将正确判断为裂缝的分块校正为无裂缝分块,反而降低了分块分类准确率。因此将校正范围限制在被判断为无裂缝的分块,即只对无裂缝分块进行校正。校正方法如下:

设 p_{ij} 为第 i 行第 j 列的分块 ij 被预测有裂缝的概率,按




图 7 3种邻接块标签校正区域

Fig. 7 Label recalibration regions of three adjacent blocks

5.2 多尺寸分块语义分割

由于基于 CAM 进行语义分割往往会关注目标物体的某一部位置,并且可能会关注与目标物体密切相关但在目标物体轮廓外的位置,因此只能得到目标物体的大致位置。鉴于此,可以对 CAM 生成的分割结果进行优化,如种子区域生长和迭代物体特征挖掘等方法;也可以对生成 CAM 的方法进行优化,如图像间语义相似性和差异性等方法^[21]。本文使用对 CAM 生成的分割结果进行优化的方式,对多种尺寸的分块图像进行弱监督语义分割,主要流程如下:

使用分块训练数据集训练 SEAM 模型^[22]得到 CAM,再使用密集条件随机场方法微调 CAM 结果,将微调结果作为语义亲和力网络 AffinityNet 的训练数据来训练 AffinityNet。

AffinityNet 训练完成后,由 AffinityNet 预测局部语义相似度,并将其转换为概率矩阵。之后使用随机游走传播提高 CAM 的质量,生成准确的分割标签并进行分割。

各尺寸分块的语义分割结果生成后,将分割结果拼接回原图尺寸(w, h)。拼接过程中使用投票法,统计每种尺寸分割结果中每个像素的类型,取数量最多的类型作为每个像素的类型。假设共使用了 N 种分块尺寸,并设原图尺寸的分割结果为 $S_n, n \in [1, N], S_n$ 中的像素为 $s_n^{ij}, i \in [1, h], j \in [1, w]$,由于是二分类的分割结果,因此 S_n 中的像素值为 0 或 1。设拼接后的结果为 T, T 中的像素为 $t^{ij}, i \in [1, h], j \in [1, w]$,使用以下方法计算 t^{ij} :

$$t^{ij} = \begin{cases} 1, & \sum_{n=1}^N s_n^{ij} \geq \lfloor N/2 \rfloor \\ 0, & \sum_{n=1}^N s_n^{ij} < \lfloor N/2 \rfloor \end{cases}, i \in [1, h], j \in [1, w]$$

基于弱监督语义分割获取的分割结果是通过 CAM 得到的, CAM 往往会关注裂缝特征明显的某一部区域,无法完全覆盖裂缝区域。上文中使用的 SEAM 方法对 CAM 进行了扩展,然而扩展后的 CAM 范围又超出了真实的裂缝区域,因此有必要对分割结果的边界进行进一步的修正:在双分支模型的基础上,增加了图像预处理和亮度计算后的腐蚀操作,通过计算原图像中每个像素的亮度值,得到裂缝的可能边界,并

如下方法计算其邻接块的相似度:

$$s_{ij} = \sum |p_{ij} - p_{adj}|$$

其中, p_{adj} 表示分块 ij 的邻接分块 adj 被预测有裂缝的概率。

校正后的分块分类结果为:

$$p_{ij}^{rec} = \begin{cases} 1 - p_{ij}, & \text{如果 } s_{ij} \geq s_{thresh} \\ p_{ij}, & \text{如果 } s_{ij} < s_{thresh} \end{cases}$$

其中, s_{thresh} 表示校正的阈值。

与 CAM 得到的分割结果结合,进一步缩小分割边界范围,使其更贴近真实的裂缝区域。

5.3 裂缝测量评估

路面技术状况指数中路面裂缝的评估和分类主要基于裂缝部位的长度、宽度、面积和块度等,因此对路面裂缝进行测量是评定路面技术状况的重要依据。目前自动测量方法一般基于裂缝分割图像,对分割出的裂缝进行骨架提取后,计算细化后像素个数,再通过映射算法计算实际物理值。骨架提取是其中关键一步, Yang 等利用此类方法测量了路面裂缝长度^[23]。

本文使用 ZS 并行迭代方法在拼接后的道路裂缝分割结果上进行骨架提取。设骨架提取后的图像为 K , 其像素点为 $k^{ij}, i \in [1, r], j \in [1, c]$, 原图尺寸的分割结果为 $S_n, n \in [1, N], S_n$ 中的像素为 $s_n^{ij}, i \in [1, r], j \in [1, c]$, 则骨架像素点个数为 $L = \sum_{i=1, j=1}^n k^{ij} (i \in [1, r], j \in [1, c])$, 裂缝的面积为 $A = \sum_{i=1, j=1}^n s^{ij} (i \in [1, r], j \in [1, c])$, 裂缝的平均宽度为 $W = A/L$ 。

设真实的裂缝长度、面积和平均宽度分别为 L_{gt}, A_{gt}, W_{gt} , 本文通过计算误差来评估裂缝量化性能:

$$R_L = \frac{|L - L_{gt}|}{\gamma \cdot L_{gt}}, R_A = \frac{|A - A_{gt}|}{\gamma \cdot A_{gt}}, R_W = \frac{|W - W_{gt}|}{\gamma \cdot W_{gt}}$$

其中, γ 为误差修正系数,可设置为语义分割结果与真实裂缝区域的 mIoU 值。

6 实验

基于上述检测方法,使用 cqu-bpdd 数据集中的条状裂缝、网状裂缝图像和正常图像进行多种尺寸的分块,通过上述分块分类模型进行自动分类并进行邻接块标签校正和数据平衡,训练弱监督语义分割模型生成分割结果,对分割边界进行修正并对多尺寸分块进行拼接。使用语义分割常用评估指标 mIoU 以及裂缝测量评估指标,将所提方法与现有主流检测方法进行了比较。

使用 cqu-bpdd 数据集中的裂缝图像和正常图像构建实验数据。cqu-bpdd 数据集仅提供了道路图像以及其裂缝分类

标签。胶结裂缝、纵向裂缝和横向裂缝等多数呈条状分布,龟裂和块状裂缝呈网状分布,因此将其分别归并为条状裂缝和网状裂缝。训练集包括条状裂缝、网状裂缝和正常路面的图像,共计 3165 张,图像大小为 1200×900 ,使用 8 种尺寸的分块,分块数量分别为 1×1 (原图不分块)、 2×2 、 2×3 、 3×3 、 3×4 、 4×4 、 4×5 和 5×5 ,并对分块后的训练集进行数据平衡。验证集包括条状裂缝、网状裂缝和正常路面的图像,共计 789 张,人工进行像素级裂缝标注,用于与检测结果进行对比,评估道路裂缝的语义分割性能和裂缝量化性能。

将现有检测方法与本文提出的检测方法进行对比实验。现有方法使用单一尺寸的分块方式,利用原图训练 EfficientNet, WSPLIN-IP, IOPLIN 等进行分块分类,最后使用 Grad-CAM 或 SEAM 算法计算 CAM 并获取分割结果。本文方法使用多种尺寸进行分块,利用基于 DQN 的道路裂缝分块分类模型获取分块类别标签,并进行邻接块标签校正,再通过 SEAM 算法计算 CAM 并获取初步分割结果,进行分割边界修正后,利用不同组合将不同尺寸的分块分割结果拼接至原图尺寸。

弱监督语义分割的性能评价指标使用语义分割中常用的评价指标 mIoU(平均交并比)。由于裂缝的量化测量是道路裂缝检测的重要工作之一,因此还需要将检测结果与真实的裂缝测量结果进行对比。

$2 \times 3 + 3 \times 3 + 3 \times 4$ 组合、 $2 \times 2 + 2 \times 3 + 3 \times 4$ 组合、 $1 \times 1 + 2 \times 2 + 2 \times 3 + 3 \times 3 + 3 \times 4$ 组合的实验结果如表 1 所列。可以看出,使用 $2 \times 2 + 2 \times 3 + 3 \times 4$ 组合的语义分割性能最佳,本文方法所有分块组合得到的分割结果在 mIoU 性能指标上均超过了现有主流方法。

表 1 现有方法与本文方法性能的对比

Table 1 Comparison of performance between existing methods and the proposed approach

检测方法	IoU/%			
	背景	条状	网状	mIoU
EfficientNet+Grad-CAM(1×1 分块) ^[24]	81.71	10.78	17.21	36.56
EfficientNet+SEAM(1×1 分块)	85.50	26.43	29.21	47.05
EfficientNet+SEAM(2×2 分块)	87.55	44.82	37.81	56.73
EfficientNet+SEAM(2×3 分块)	88.43	47.59	30.67	55.56
EfficientNet+SEAM(3×3 分块)	93.21	51.17	28.85	57.74
EfficientNet+SEAM(3×4 分块)	92.94	44.26	13.67	50.29
EfficientNet+SEAM(4×4 分块)	93.83	48.44	14.10	52.12
EfficientNet+SEAM(4×5 分块)	92.25	38.75	16.36	49.12
EfficientNet+SEAM(5×5 分块)	92.33	37.50	7.37	45.73
WSPLIN-IP+SEAM(5×5 分块) ^[11]	93.22	39.65	26.56	53.14
IOPLIN+SEAM(5×5 分块) ^[8]	93.73	39.50	27.87	53.70
$2 \times 3 + 3 \times 3 + 3 \times 4$ 组合+DQN+多尺寸分块(本文方法)	94.81	51.58	36.73	61.04
$2 \times 2 + 2 \times 3 + 3 \times 4$ 组合+DQN+多尺寸分块(本文方法)	94.36	47.85	43.26	61.83
$1 \times 1 + 2 \times 2 + 2 \times 3 + 3 \times 3 + 3 \times 4$ 组合+DQN+多尺寸分块(本文方法)	94.18	47.19	43.27	61.54

使用上文的裂缝量化评估方法,分别计算使用 1×1 (原图不分块)、 2×2 、 2×3 、 3×3 、 3×4 、 4×4 、 4×5 和 5×5 尺寸分块,以及使用 $2 \times 3 + 3 \times 3 + 3 \times 4$ 组合、 $2 \times 2 + 2 \times 3 + 3 \times 4$ 组合、 $1 \times 1 + 2 \times 2 + 2 \times 3 + 3 \times 3 + 3 \times 4$ 组合拼接后的道路裂缝的语义分割结果与真实裂缝长度、面积和平均宽度的误差,结果如表 2 所列。可以看出, $2 \times 3 + 3 \times 3 + 3 \times 4$ 组合拼接的

检测结果误差最小。3 种组合得到的检测结果在条状裂缝、网状裂缝上测量的平均宽度的误差均小于现有方法(表中的长度、宽度均为像素的相对大小)。

表 2 道路裂缝测量误差对比

Table 2 Comparison of measurement errors in road cracks

检测方法	长度	面积	平均宽度
EfficientNet+SEAM(1×1 分块) ^[22]	1.48	4.74	10.05
EfficientNet+SEAM(2×2 分块)	0.65	1.55	2.59
EfficientNet+SEAM(2×3 分块)	0.92	1.38	1.45
EfficientNet+SEAM(3×3 分块)	0.68	0.90	1.14
EfficientNet+SEAM(3×4 分块)	0.88	1.01	0.78
EfficientNet+SEAM(4×4 分块)	0.77	0.87	0.68
EfficientNet+SEAM(4×5 分块)	0.97	1.07	1.01
WSPLIN-IP+SEAM(5×5 分块) ^[11]	2.06	2.23	0.74
IOPLIN+SEAM(5×5 分块) ^[8]	2.55	2.54	0.72
$2 \times 3 + 3 \times 3 + 3 \times 4$ 组合+DQN+多尺寸分块(本文方法)	0.91	1.02	0.58
$2 \times 2 + 2 \times 3 + 3 \times 4$ 组合+DQN+多尺寸分块(本文方法)	0.95	1.16	0.64
$1 \times 1 + 2 \times 2 + 2 \times 3 + 3 \times 3 + 3 \times 4$ 组合+DQN+多尺寸分块(本文方法)	1.32	1.32	0.61

此外,对多尺寸分块进行了消融实验。在 1×1 (原图不分块)的基础上分别增加不同大小的分块进行拼接,分析不同大小分块对分割性能的影响。由表 3 可以看出,单独使用一种尺寸分块分割结果与原图分割结果进行拼接后,mIoU 指标均有一定提升,并且同时使用多种尺寸的组合性能提升更大。

表 3 多尺寸分块消融实验结果

Table 3 Results of multi-size block ablation experiments

分块组合	IoU/%			
	背景	条状	网状	mIoU
1×1 (原图不分块)	89.96	26.69	36.06	50.90
$1 \times 1 + 2 \times 2$ 组合	94.73	40.74	37.91	57.79
$1 \times 1 + 2 \times 3$ 组合	94.96	43.86	37.36	58.73
$1 \times 1 + 3 \times 3$ 组合	94.90	43.13	37.42	58.48
$1 \times 1 + 3 \times 4$ 组合	94.07	44.36	37.76	58.73
$1 \times 1 + 2 \times 2 + 2 \times 3 + 3 \times 3 + 3 \times 4$ 组合	94.18	47.19	43.27	61.54

实验结果表明,使用本文改进的基于弱监督语义分割的道路裂缝检测方法,道路裂缝分割和测量的精度均得到了提升,其在 DeepCrack 和 RoadDamageDataset 等数据集上也取得了较好的效果。在算法效率方面,实验中从道路裂缝分块分类和道路裂缝检测两个方面分别对现有方法与本文方法进行了算法效率的对比。

对于道路裂缝分块分类任务,使用 IOPLIN 和 WSPLIN-IP 以及本文方法标注一张 1200×900 道路裂缝图像的 2×2 、 3×3 、 4×4 和 5×5 个分块,本文方法耗时略长于现有方法,如表 4 所列。

表 4 道路裂缝分块分类耗时对比

Table 4 Time consumption for road crack block classification

分块数量	耗时/s		
	IOPLIN	WSPLIN-IP	DQN(本文方法)
2×2	21.55	20.21	23.17
3×3	23.48	22.33	23.95
4×4	26.70	26.46	26.47
5×5	28.60	27.79	30.59

对于道路裂缝检测任务,使用 Grad-CAM、SEAM 方法和

本文方法,使用3种分块组合检测一张 1200×900 的道路裂缝图像。本文方法较Grad-CAM方法耗时增加约10%,较SEAM方法耗时增加约5%,如表5所列。

表5 多尺寸分块道路裂缝检测耗时对比

Table 5 Time consumption for road crack detection of multi-size block

分块数量	耗时/s		
	Grad-CAM	SEAM	本文方法
2×3+3×3+3×4 组合	41.12	43.34	45.29
2×2+2×3+3×4 组合	41.87	42.31	45.82
1×1+2×2+2×3+3×3+3×4 组合	50.15	54.52	55.78

实际应用中,可使用单尺寸检测快速获取裂缝的大致分布区域范围,并使用多尺寸检测进一步优化检测结果,减小裂缝测量误差,提高道路损坏程度评估的准确度。

结束语 本文针对道路裂缝检测中图像分块产生的问题,对分块分类标注和多尺寸分块检测方法进行了研究,提出了基于强化学习的分块分类模型。基于深度学习的思想,定义了道路裂缝图像的分块分类任务,并根据道路裂缝图像分块分类任务的特点,设计了强化学习的状态、动作和奖励三大要素,训练智能体对裂缝分块进行选择。本文解决了分块后标注工作量大的问题,提高了分块分类性能,为后续基于弱监督语义分割的道路裂缝检测提供了必要的自动分块类别标注方法。在cqu-bpdd数据集中条状裂缝和网状裂缝类型上,对多种尺寸的分块进行了道路裂缝检测实验,测量了裂缝的长度、面积和平均宽度。所提方法在条状裂缝、网状裂缝类别的mIoU指标以及裂缝平均宽度指标上均超过了现有方法。

本文使用了多尺寸分块拼接的方法来提高分块弱监督语义分割的性能,分块拼接时需要遍历裂缝图像的像素点,在图像尺寸较大的情况下检测速度相对较慢。虽然实际项目中对像素级的道路裂缝检测的实时性要求不高,但是随着公路里程的快速增长,道路检测和养护工作量大量增加。检测方法的效率问题是后续研究需要关注的方向。

参考文献

[1] LI B, WANG K C P, ZHANG A, et al. Automatic classification of pavement crack using deep convolutional neural network[J]. International Journal of Pavement Engineering, 2020, 21(4): 457-463.

[2] PING P, YANG X, GAO Z. A Deep Learning Approach for Street Pothole Detection[C]// 2020 IEEE Sixth International Conference on Big Data Computing Service and Applications, Oxford, United Kingdom. IEEE, 2020: 199-205.

[3] HONG Y, LEE S, YOO S B. AugMoCrack: Augmented morphological attention network for weakly supervised crack detection[J]. Electronics Letters, 2022, 58(17): 651-653.

[4] ZHANG Y, LI Q, ZHAO X, et al. TB-Net: A Three-Stream Boundary-Aware Network for Fine-Grained Pavement Disease Segmentation[C]// 2021 IEEE Winter Conference on Applications of Computer Vision, Waikoloa, IEEE, 2021: 3654-3663.

[5] YANG F, ZHANG L, YU S, et al. Feature Pyramid and Hierarchical Boosting Network for Pavement Crack Detection[J].

IEEE Transactions on Intelligent Transportation Systems, 2020, 21(4): 1525-1535.

[6] ZOU Q, ZHANG Z, LI Q, et al. DeepCrack: Learning Hierarchical Convolutional Features for Crack Detection[J]. IEEE Transactions on Image Processing, 2019, 28: 1498-1512.

[7] LAU S L H, CHONG E K P, YANG X, et al. Automated Pavement Crack Segmentation Using U-Net-Based Convolutional Neural Network[J]. IEEE Access, 2020, 8: 114892-114899.

[8] TANG W, HUANG S, ZHAO Q, et al. An Iteratively Optimized Patch Label Inference Network for Automatic Pavement Distress Detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(7): 8652-8661.

[9] YAN K, ZHANG Z. Automated Asphalt Highway Pavement Crack Detection Based on Deformable Single Shot Multi-Box Detector Under a Complex Environment[J]. IEEE Access, 2021, 9: 150925-150938.

[10] ZHU J S, SONG J B. Weakly supervised network based intelligent identification of cracks in asphalt concrete bridge deck-ScienceDirect[J]. Alexandria Engineering Journal, 2020, 59(3): 1307-1317.

[11] HUANG G, HUANG S, HUANGFU L, et al. Weakly Supervised Patch Label Inference Network with Image Pyramid for Pavement Diseases Recognition in the Wild[C]// ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing. Toronto, 2021: 7978-7982.

[12] XU B, LIU C. Pavement crack detection algorithm based on generative adversarial network and convolutional neural network under small samples[J]. Measurement, 2022, 196(9): 111219.

[13] LI Y, BAO T, XU B, et al. A deep residual neural network framework with transfer learning for concretedams patch-level crack classification and weakly-supervised localization[J]. Measurement, 2022, 188(1): 110641.

[14] WANG H, LI Y, DANG L M, et al. Pixel-level tunnel crack segmentation using a weakly supervised annotation approach[J]. Computers in Industry, 2021, 133(12): 103545.

[15] DONG Z, WANG J, CUI B, et al. Patch-based weakly supervised semantic segmentation network for crack detection[J]. Construction and Building Materials, 2020, 258(10): 1-14.

[16] RILL-GARCÍA R, DOKLADALOVA E, DOKLÁDAL P. Pixel-accurate road crack detection in presence of inaccurate annotations[J]. Neurocomputing, 2022, 480(4): 1-13.

[17] INOUE Y, NAGAYOSHI H. Crack Detection as a Weakly-Supervised Problem: Towards Achieving Less Annotation-Intensive Crack Detectors[C]// 2020 25th International Conference on Pattern Recognition, Milan, Italy. 2021: 65-72.

[18] CAICEDO J C, LAZEBNIK S. Active Object Localization with Deep Reinforcement Learning[C]// 2015 IEEE International Conference on Computer Vision. Santiago, Chile, 2015: 2488-2496.

[19] SILVER D, HUBERT T, SCHRITTWIESER J, et al. Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm [EB/OL]. <https://arxiv.org/abs/1712.01815>.

- [20] YE D, LIU Z, SUN M, et al. Mastering Complex Control in MO-BA Games with Deep Reinforcement Learning[C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2020; 6672-6679.
- [21] AHN J, KWAK S. Learning Pixel-level Semantic Affinity with Image-level Supervision for Weakly Supervised Semantic Segmentation[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018; 4981-4990.
- [22] HUANG Z, WANG X, WANG J, et al. Weakly-Supervised Semantic Segmentation Network with Deep Seeded Region Growing[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018; 7014-7023.
- [23] WANG X, YOU S, LI X, et al. Weakly-Supervised Semantic Segmentation by Iteratively Mining Common Object Features [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018; 1354-1362.
- [21] SUN G, WANG W, DAI J, et al. Mining Cross-Image Semantics for Weakly Supervised Semantic Segmentation[C]// Computer Vision—ECCV 2020. 2020; 347-365.
- [22] WANG Y, ZHANG J, KAN M, et al. Self-Supervised Equiva-
- riant Attention Mechanism for Weakly Supervised Semantic Segmentation[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, 2020; 12272-12281.
- [23] YANG X, LI H, YU Y, et al. Automatic Pixel-Level Crack Detection and Measurement Using Fully Convolutional Network [J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(12): 1090-1109.
- [24] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization[C]//2017 IEEE International Conference on Computer Vision. Venice, 2017; 618-626.



ZHAO Weidong, born in 1971, Ph.D, associate professor. His main research interests include machine learning, deep learning and recommender systems.

(责任编辑:柯颖)

CCF 东莞换届, 新一届执监委会产生

2024年10月13日, CCF 东莞会员活动中心(以下简称: CCF 东莞)举行换届选举会议。30余名来自高等院校、科研院所、企事业单位的 CCF 东莞委员和会员代表参会, 本次会议由 CCF 东莞主席魏文红主持。

会议伊始, CCF 东莞换届筹备组组长袁华强教授首先就本次换届选举的筹备情况及选举规则进行了简要介绍。

随后, CCF 东莞现任主席魏文红向与会代表详细介绍了 CCF 东莞近年来的发展情况。分享了分部在学术交流、会员服务、校企合作等方面取得的成果, 并展望了未来的发展方向和目标。

换届选举环节, 按照 CCF 会员活动中心选举规则, 依次进行主席、副主席、秘书长、执行委员, 监督委员会主席和委员的选举, 各位候选人分别进行限时竞选演说, 阐述任职后的工作规划并回答委员提问。现场委员们认真聆听, 并积极参与提问和讨论。由现场委员通过不记名差额选举的方式, 选举产生了新一届 CCF 东莞执行委员会和监督委员会成员(名单附后)。

新当选的 CCF 东莞主席陶铭在会上发表了当选感言。他表示将带领新一届执委会成员, 继续秉承 CCF 的宗旨和使命, 为会员提供更多有价值的服务和支撑, 推动 CCF 东莞不断向前发展。

CCF 会员与分部工委副主任秦征给与会代表做了 CCF 文化介绍。他详细阐述了 CCF 的宗旨、发展历程以及核心价值观, 并分享了 CCF 在推动计算机科学与技术领域发展方面所做的努力和取得的成就, 赢得了在场委员的认可。

与会代表们纷纷表示, 将一如既往地支持 CCF 东莞的工作, 共同推动东莞地区计算机科学和技术的发展。



参会人员合影