

DOI:10.19651/j.cnki.emt.2108738

多尺度卷积神经网络的图像边缘检测

石昌友 孙强 卢建平 夏榕泽 刘锦锋

(陆军工程大学通信士官学校 重庆 400035)

摘要: 在受图像拍摄条件、图像内容自身复杂性、图像内容与背景接近程度等多种因素的影响,图像的边缘线检测容易发生漏检、误检。因模型自身设计缺陷或训练样本中边缘像素点与非边缘像素点的不平衡原因,多数算法的图像边缘检测结果普遍存在线条粗、质量较低的问题。提出一种多尺度卷积神经网络模型,由三个分别接受一幅图像的不同尺度输入的子网络结构组成,分别在不同尺度视觉下学习图像的边缘知识。然后按尺度从粗到细对各尺度提取的知识特征进行融合,实现边缘轮廓检测。模型充分利用多尺度技术在图像处理领域的优势,同时引入了自注意力机制以提升卷积特征内部关联性的捕获能力。本文提出了一个新的损失函数,由交叉熵损失函数和L1范数组成,避免训练样本非均衡性对训练模型的影响。使用指标 ODS、OIS、AP 度量图像边缘检测的质量。在 BIPED 数据集上测试,三个指标的得分分别为 0.845,0.856,0.886。在 BSDS500 数据集上测试,算法在 F-measure 指标上得分为 0.826。实验结果表明,与其它学习型的算法相比,算法输出图像边缘结果漏检率更低、且质量更高。

关键词: 计算机视觉;卷积神经网络;自注意力集中;多尺度技术

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.604

Edge detecting based on multi-scale convolutional neural network

Shi Changyou Sun Qiang Lu Jianping Xia Rongze Liu Jinfeng

(University College of Communication NCOs, Army Engineering University of PLA, Chongqing 400035, China)

Abstract: Both false detection and missed detection are frequent for most edge detection algorithm, since the picture acquired in bad weather, the complexity of the image content itself, and the edge cues become vague especially when it is close to the background. Due to the design defects of the model or the imbalance between the edge pixels and non-edge pixels in the training samples, the edge detection results of most algorithms generally have the problem of thick lines and low quality. A multi-scale convolutional neural network is proposed, which is composed of three sub-structures and each one accepts one scale of an image. The algorithm learns the knowledge under different scale vision, extracts the edge of the image after the process of fusing gradually the edges from coarse to fine. Except for the advantages of multi-scale technology in image processing, a self-attention mechanism is introduced to improve the ability to capture the internal relevance of convolutional features. A new loss function, which is composed of the cross-entropy loss function and the L1 norm term, is proposed to train the network, and avoid the impact of the imbalance of training samples. Indices: ODS, OIS, AP are used to measure the quality of edge detection. The scores of three indicators are 0.845, 0.856, 0.886 respectively when tested on the BIPED dataset. The algorithm scored 0.826 on the F-measure indicator, tested on BSDS500 dataset. The experimental results show that the algorithm can generate more delicate image edge results.

Keywords: computer vision; convolutional neural network; self-attention mechanism; multi-scale technology

0 引言

图像边缘检测是计算机图像处理一个重要研究方向。图像边缘线至关重要,包含着图像内容物体的整体视觉形态和空间分布信息,直接描述了目标物体的拓扑结构,是图像高级

语义识别理解的基础,例如语义分割^[1-2]、目标检测识别^[3]、图像涂鸦^[4]等。图像的边缘线通常对应着像素值变化剧烈的像素位置,像素值变化剧烈程度可以近似看作边缘线的显著性,图像边缘检测的本质是从图像中识别出这些像素位置,然而面临两个困难。一是对于尺度较短、显著性微弱的图像噪声

位置,算法要么因没能采取技术措施而误检,要么因采取了处理手段但又影响到了真正边缘线的检出。图像边缘线与目标物体整体拓扑结构相关,表征着目标物体拓扑结构的线条毫无疑问应该被算法检出,但是算法应该过滤掉噪声点。二是边缘线的显著性与像素点被判定为边缘像素的关系难以使用有效模型度量。对于相对模糊的图像画面或者颜色比较接近的两个区域的边界,边缘像素的像素值变化就比较平缓,但是高清晰图像的边缘像素值变化就非常剧烈。

有的算法^[2,5]是在图像局部邻域内捕获结构信息并比较区域块的差异,然后基于阈值策略实现对图像的边缘像素的判定,其结果严重依赖阈值。随着深度学习技术的蓬勃发展,研究者们提出了一系列基于卷积神经网络的图像边缘检测算法模型。算法 N4-Fields^[6]、DeepEdge^[7] 和 Deep-Contour^[8] 结合了传统图像处理技术和卷积神经网络技术实现图像边缘检测。有些算法^[9-10] 基于 VGG16 基础结构,利用加权交叉熵函数训练模型,实现图像边缘检测。Deng 等^[11] 开展了进一步研究,在损失函数中引入了 Dice 系数项,改善了图像边缘线的位置精确度。Poma 等^[12] 则采用残差网络模型为基础结构,并应用跨阶段特征连接技术实现图像边缘检测。Xia 等^[13] 以编码器-解码器为基础结构,运用多尺度处理策略实现端到端的图像边缘检测。卷积神经网络的高效特征提取能力可以从大量图像样本数据中学习得到有效边缘知识。但是边缘检测质量还有很大的提升空间,边缘线漏检、边缘线条粗的情况时有发生。

本文设计了一种多尺度卷积神经网络模型,通过三个子网络结构分别对一幅图像的三种尺寸输入进行计算处理,能在多个尺度下从训练数据中更好地理解图像的边缘线知识。由于表征着图像内容物体的结构的图像边缘线呈现出自依赖特点,引入自注意力机制可以有效捕获图像内容之间的关联性。自注意力机制^[14] 被引入生成对抗网络,展现出优秀的捕获图像的自关联关系的能力。多尺度技术是计算机视觉领域的一种技术策略,被广泛应用。例如医学图像分割^[15],图像去雾^[15-16],图像翻译^[17],碰撞检测^[18]。此外,本文设计了一种新的损失函数,在交叉熵损失函数的基础上增加一个正样本的 L1 范数项。可以解决因图像中绝大多数的区域都是平坦而边缘线像素位置非常少导致的训练样本数据非均衡问题。本文主要贡献:

1) 提出了一种多尺度卷积神经网络结构模型,逐步提炼并丰富图像的边缘提取结果,实现图像边缘提取。

2) 提出了一个新的损失函数解决训练图像中像素的正、负样本不均衡问题。

1 相关工作

1.1 图像边缘检测

学者们对图像边缘检测进行了大量的研究。Arbelaez 等^[2] 以像素为圆心,某方向为边缘线假设,在其图像局部邻域内计算区域间的信息差异,最后依据差异信息对像素点

进行边缘判断。他们构建的边缘轮廓图像数据库 (BSDS500) 被广泛应用模型训练。基于随机森林算法, Doll 等^[5] 利用结构化学习模型对图像特征进行分类,最后综合各决策树完成图像边缘检测。这些算法依赖于人工设计特征,泛化潜力不是很大。结合传统图像处理技术和卷积神经网络技术,也有相关的研究成果。Ganin 等^[6] 基于神经网络和邻近搜索的简单组合,对图像的局部区域块进行特征提取,然后在字典里面进行检索,查找与其相似的边缘,把这些相似的边缘信息集成起来,输出最终的结果。Bertasius 等^[7] 算法基于 Canny 边缘检测器提取候选轮廓点,以候选点建立多种尺度的图像区域块,通过卷积神经网络对区域块进行分类和回归,最后得到每个候选点属于边缘像素的概率。Shen 等^[8] 基于图像块处理的思路,将图像分割成图像块,然后使用卷积神经网络对各个图像块进行形状分类,最后整理所有图像块的边缘线类别得到边缘检测结果。这些方法都是基于局部策略,并没有很充分的利用高层语义的信息。Xie 等^[9] 提出了一个边缘检测算法,通过全卷积神经网络直接从图像生成边缘图像。Liu 等^[10] 在其基础上,对网络结构的中间卷积层进行独立边缘检测,最后融合所有阶段的边缘检测结果得到图像的最终边缘图像。Yang 等^[19] 提出了一种基于编码器-解码器框架的卷积神经网络完成对图像边缘检测。Yu 等^[20] 基于边缘像素可能出现在属于多个语义类的轮廓边界中的假设,提出了一种新的端到端深度语义边缘学习架构,实现对每个边缘像素的多类别关联建模,使用多类别的损失函数来监督特征的融合。Poma 等^[12] 提出了一个新的网络模型,构建了新的图像数据集 (BIPED)。基于数据集 BIPED 训练的多种图像边缘检测算法,均能够输出较高质量的边缘图像。在交叉熵损失函数的基础上引入戴斯系数项,算法^[11] 输出更为精细的边缘图像,提升了边缘线条的质量。

1.2 卷积神经网络

卷积神经网络作为新的热门技术,受到研究者的大量关注,被广泛应用于计算机视觉任务。涌现出一系列经典结构模型,Simony 等^[21] 使用小尺寸卷积核大幅度减少了参数规模,Szegedy 等^[22] 采用多种大小的卷积核完成卷积操作实现了多视野下的特征提取,He 等^[23] 设计的残差卷积块改善了网络的训练质量,Huang 等^[24] 提出的密集型跨层连接达到充分利用多水平特征的目的。这些经典网络模型分别从深度和宽度上进行扩展,模型结构变得越加复杂,其完成任务的能力变得更加强大,已成众多其它网络的基础结构。学者们也提出了一些与应用相关的网络结构模型,例如编码器-解码器^[25]、全卷积网络^[26]、生成对抗网络^[27];还探索了一些有用的技巧策略、功能机制,例如自注意力机制^[14]、跨层连接^[23]、批样本归一化^[28]、卷积特征归一化^[29]。卷积神经网络已是机器视觉、自然语言处理领域一种强大的技术工具。本文提出一种多尺度卷积神经网络模型,利用深度学习的优势和先进性,实现图像边缘检测。

2 算 法

假设有数据集 $D = \{(X_i, Y_i) \mid i = 1, 2, \dots, T\}$, 每幅图像都有其对应的边缘标记图。设计算法, 目的是从该数据集中学习边缘线的知识, 生成边缘概率图。

2.1 图像边缘检测

网络模型详细如图1所示, 由3个结构相似、独立优化的子模型组成: 1号子模型、2号子模型、3号子模型分别负责对1/4尺寸、1/2尺寸、原始尺寸图像的计算处理, 子模型结构之间设计跨越连接, 实现多尺度边缘检测结果的深度融合, 达到从粗到精、逐步丰富图像边缘的目的。子网络模型由一系列卷积模块构成, 方便起见, 按照从网络输入端到输出端的顺序对卷积模块依次编号为第1、2、3、4、5号等

等。对于任意一个卷积模块, 其计算过程可以形式化表达如下

$$F^i = Pool \{ SA \{ LRU (Con(W_j * F_j + B_j)) \} \},$$

$$i = 1, 2, 3, \dots; j = 1, \dots, n. \quad (1)$$

式中: F^i, W_j, B_j, F_j, n 分别表示模块的输出、学习参数、偏置参数、卷积操作的输入、模块内重复卷积次数。卷积操作的具体次数已在图1中使用符号“x2/x3”标明, 卷积操作符号后面的数字分别代表卷积核大小、卷积步长、边缘补0的像素数、卷积核的数量。Pool, SA, LRU, Con 分别表示池化操作、自注意力操作、LRU激活函数计算和卷积操作。图1的网络结构中的符号: “Decon”、“Sigmoid/LRU”分别表示转置卷积、激活函数。

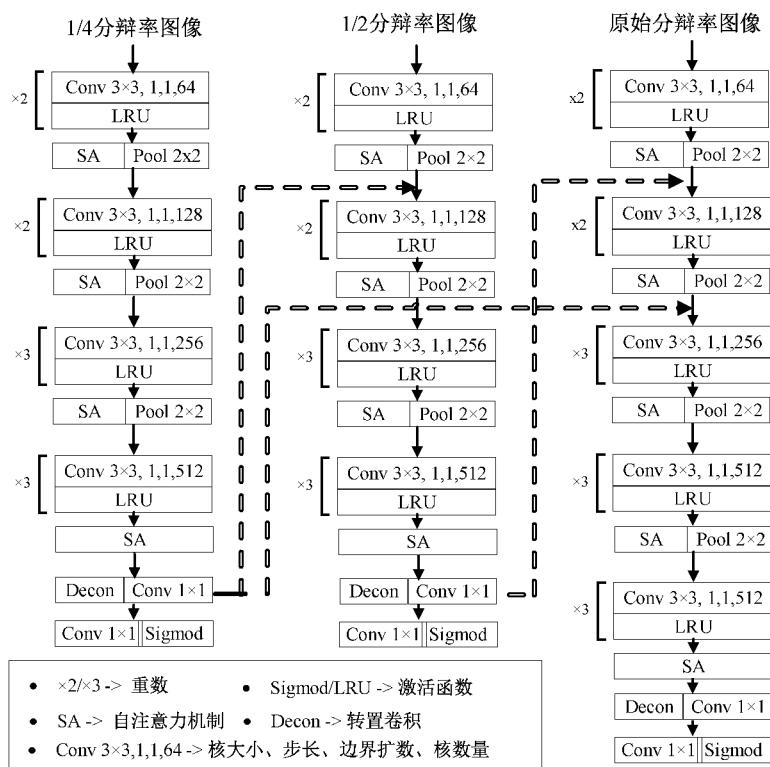


图1 多尺度卷积神经网络结构图

对于一幅图像, 网络模型的1号子模型负责在其1/4原始分辨率的视觉下进行边缘线提取, 卷积操作的观察视野大, 有利于从近似全局的角度理解图像的边缘线信息; 2号子模型负责在其1/2原始分辨率的视觉下进行边缘线提取, 3号子模型负责在其原始分辨率的视觉下进行边缘线提取, 子模型的观察视野逐渐变小, 从局部细节理解图像的边缘线信息变得越加便利。子模型之间设计跨越连接, 可以形式化表达如下

$$F_{m, skip}^{1+i} = Cat \{ F_m^{1+i}, F_{m-i}^{end-1} \}, m = 2, 3, i = 1, \dots, m-1. \quad (2)$$

式中: $F_{m, skip}^{1+i}, F_m^{1+i}, F_{m-i}^{end-1}, Cat$ 分别表示第 m 号子模型中第 $1+i$ 卷积层跨越连接后的特征、跨越连接前特征、第 $m-i$

号子模型中倒数第2个卷积的特征、特征连接操作。子模型之间跨越设计可以带来两点好处: 1) 实现图像多尺度处理。算法除了各卷积组因池化层改变卷积神经网络的特征尺寸而提取多尺度特征外, 还可接受多尺寸图像输入, 能在3个尺度比例下对图像计算处理。2) 优化低级特征提取质量。针对子模型2和3, 在网络较前端就引入了其他子模型后端的高级特征, 其卷积特征提取操作是在高级别特征的参与下进行的, 优化了提取过程。

2.2 模型优化函数

图像边缘检测可以看作是对图像进行像素级分类问题, 本文采用交叉熵损失函数计算边缘检测图像与训练数据中标记图像的损失值, 通过最小化损失函数训练网络模

型。然而,训练样本中的图像的边缘像素与非边缘像素的分布高度不平衡(大多数像素是非边缘像素),势必影响训练模型的质量。引入了加权因子缓解样本非均衡的问题,加权交叉熵损失函数公式如下

$$L_{cross} = \beta \sum_{j \in Y_+} \log \{P(y_i = 1 | \mathbf{X}_i)\} - (1 - \beta) \sum_{j \in Y_-} \log \{P(y_i = 0 | \mathbf{X}_i)\}, \quad (3)$$

式中:符号 $P(\ast)$, Y_+ , Y_- , $\beta = Y_+ / (Y_+ + Y_-)$, 分别表示图像像素的边缘概率、正样本集合(边缘像素集)、负样本集合、样本平衡系数。

在加权交叉熵损失函数的基础上,增加了一个范数项,该项只对图像中边缘像素计算损失值,提高边缘像素样本在训练过程中的贡献率,以缓解样本非均衡问题。在研究^[11]中,学者论证了只使用交叉熵损失函数时,边缘检测结果为类似浮雕图像;运用加权平衡系数之后,网络能够输出边缘图像,但是其边缘线显得较为粗厚。范数项公式如下:

$$L_{norm1} = \|\mathbf{Y} - \tilde{\mathbf{Y}}\|_1, \quad (4)$$

式中:符号 \mathbf{Y} , $\tilde{\mathbf{Y}}$ 分别表示边缘像素集的像素值、网络模型输出的边缘像素位置对应的边缘概率值。最终网络模型的损失函数为

$$L_{final} = L_{norm1} - \alpha L_{cross}. \quad (5)$$

式中:符号 α 表示权重系数,在训练网络模型时,用于调和交叉熵损失与范数损失项。

3 实验与分析

使用 ADAM 优化算法训练网络模型,初始学习率为 0.0002,动量衰减系数设置为 0.9,权重系数 α 设置为 0.6,每次训练接收 24 幅图像,训练 40 轮之后,每经过 10 轮训练,学习率减少一半,总共进行 70 轮训练完成 1 号子模型的训练。涉及 VGG-16 基础结构部分的参数使用被训练稳定的 VGG-16 模型的值初始化,其它参数使用服从标准差为 0.01,均值为 0 的正态分布的随机变量初始化,网络的偏参数初始化为 0。采用渐进式策略开展模型训练:首先对 1 号子模型进行训练,其次训练 2 号子模型,2 号子模型中的参数使用已训练的 1 号子模型的对应参数值进行初始化。然后训练 3 号子模型,3 号子模型中的参数使用已训练的 2 号子模型的对应参数值进行初始化。算法模型基于 Pytorch1.8.0 开发实现,在英伟达 GPU 显卡 RTX2080Ti 上完成实验。

训练数据集包含:数据集 BIPED^[21]和 BSDS500^[22]。前者包含 250 张图像,其中训练集 200 张,测试集 50 张。后者包括 500 张图像,其中训练集 200 张,验证集 100 张,测试集 200 张。我们对数据集进行如下操作,以扩展训练数据。1)对每张图像旋转 15 个不同的角度,然后在确保不引入因旋转导致的空白区域的条件下从每张旋转图像裁剪

出尽可能大的图像。2)对每幅图像进行上下、左右反转。训练数据集规模扩大了 64 倍。3 个评价指标 ODS、OIS、AP 定义如下:

$$ODS = \max_{\theta} \left\{ \frac{1}{T} \sum_{i=1}^T Fscore(\mathbf{X}_i, \theta) \right\}, 0 < \theta \leq 1. \quad (6)$$

$$OIS = \left\{ \frac{1}{T} \sum_{i=1}^T \max_{\theta_i} Fscore(\mathbf{X}_i, \theta_i) \right\}, 0 < \theta_i \leq 1. \quad (7)$$

其中, $Fscore, \theta_i, \theta$, 表示图像 F-score 值的计算,后者均为阈值。AP 指标就是平均准确率。

3.1 实验结果

算法的边缘检测结果如图 2 所示。第 1、2 行的图像选自 BSDS500 图像库,第 3、4 行的图像选自 BIPED 图像库。第 2 列为人工标记边缘图像,第 3 列是算法的边缘检测结果。算法成功实现了图像的边缘检测,例如 1 行图像的歌剧院建筑、第 2 行图像的企鹅、第 3 行图像的小汽车、第 4 行图像的英文字母。算法能够输出细腻的边缘线条,轮廓线完整、无间断,边缘检测结果质量高。

3.2 算法对比实验

为评估与其它算法的差异和优劣,在 BIPED 数据集上进行对比实验,对比数据如表 1 所示,其他图像边缘检测算法的性能数据直接引用文献^[11]。相较于算法^[30]和算法^[9],本文算法在 ODS、OIS、AP 3 个指标上得分均占优势。与算法^[10]相比,本文算法在 ODS、AP 两个指标上得分占优势,在 OIS 指标上得分略差。与 He 等^[31]提出的图像边缘检测算法相比,算法在 ODS、OIS 指标上得分更高,在 AP 指标上得分略差。

我们给出了不同边缘检测算法对四幅图像的边缘检测结果,如图 3 所示。在第 2 列图像的棕黑色墙体区域,其它算法在该区域的边缘线很模糊,而本文算法可以隐约看出横向的边缘线。第 3 列图像的植物树叶区域,本文算法能够输出更加干净背景,边缘线条较为细腻。

从对比数据可以看出本文算法表现最好。原因有两点:1)由于能在多个尺寸下观察图像,算法获得多视觉的分析机会,因此对图像边缘的理解更加合理。2)在损失函数中增加了针对边缘像素样本的 L1 范数项,增加了边缘像素样本在训练时的贡献,改善了边缘线的精确度。

基于 F-score 衡量指标,在 BSDS500 数据集上进一步开展方法对比实验,对比数据如图 4 所示,其它算法的性能数据直接引用在 Github 平台发布的算法^[10]的项目工程的数据。本文算法的 F-score 得分为 0.826。ROC 曲线下方所围成的区域面积最大,这面积也就是 AP 指标;相比较而言,本文算法略优。算法充分利用了多尺度策略优势和自注意力机制,学习到更多的有关图像结构边缘的知识,边缘检测结果能取得更好的质量。

3.3 自注意力机制讨论

通过实验评估自注意力机制对图像边缘检测结果的

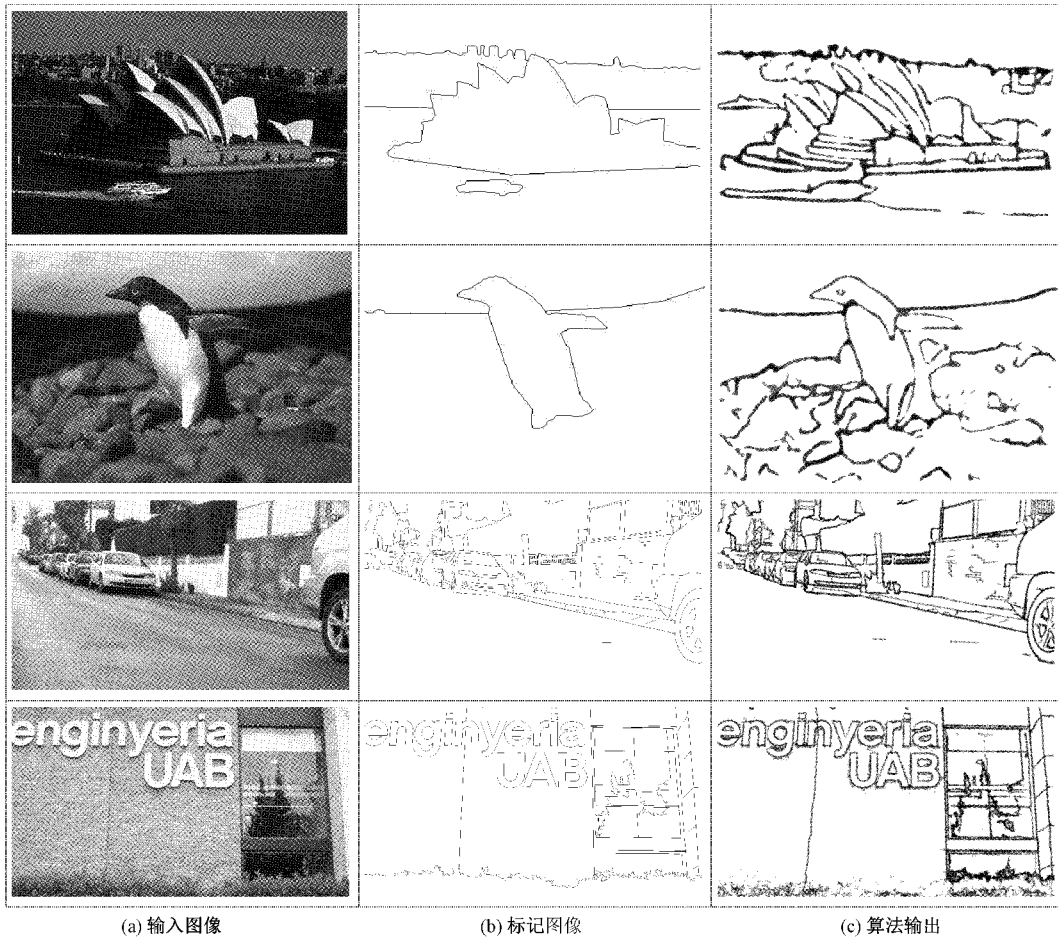
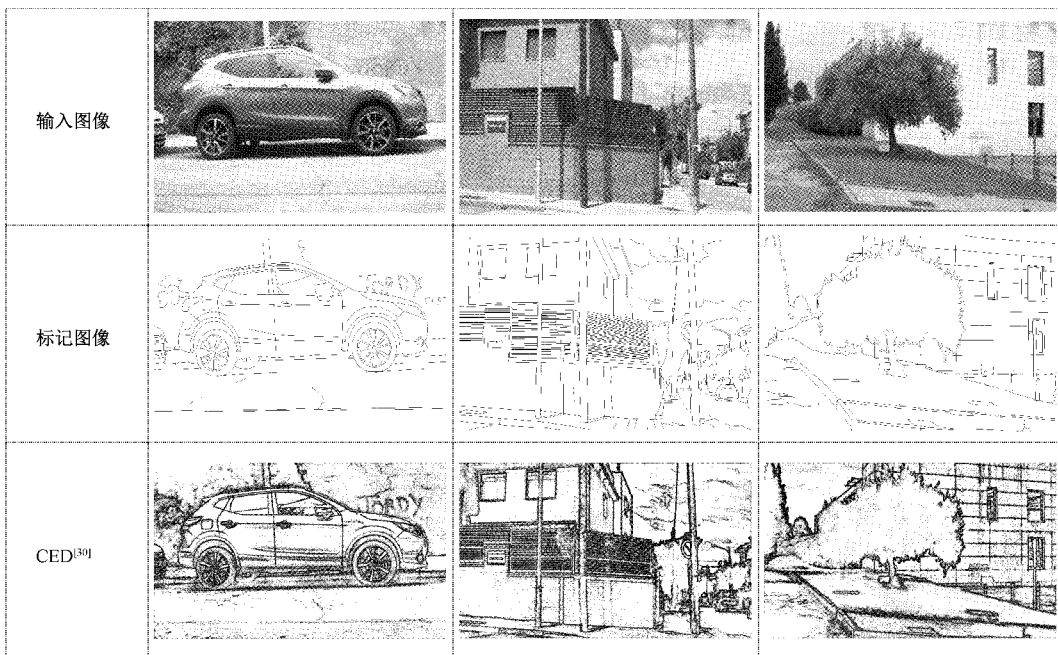


图2 部分边缘检测结果案例






图 3 部分边缘检测结果案例

表 1 指标对比实验

算法	ODS 指标	OIS 指标	AP 指标
CEDE ^[30]	0.795	0.815	0.830
HED ^[9]	0.829	0.847	0.869
RCF ^[10]	0.843	0.859	0.882
BDCN ^[31]	0.839	0.854	0.887
Ours	0.845	0.856	0.886




图 4 ROC 曲线对比结果(算法基于 BSDS500 训练)

作用。表 2 是实验数据,符号“Without SA”表示没有应用自注意力,符号“SA-stage1”、“SA-stage1,2”、“SA-stage1,2,3”分别表示自注意力应用在第 1 号卷积模块、自注意力应用在第 1、2 号卷积模块、自注意力应用在第 1、2、3 号卷积模块,符号“SA-all stages”表示自注意力应用在所有卷积模块。

表 2 自注意力机制验证实验(数据集 BIPED)

配置策略	ODS 指标	OIS 指标	AP 指标
Without SA	0.811	0.831	0.839
SA-stage1	0.815	0.837	0.842
SA-stage1,2	0.826	0.845	0.857
SA-stage1,2,3	0.843	0.852	0.879
SA-all stages	0.845	0.856	0.886

与没有使用自注意力相比,自注意的应用能使得指标得分从 0.801,0.824,0.829 提升到 0.845,0.856,0.886,随着自注意机制的运用范围扩大,图像边缘检测性能逐步提升。实验数据显示自注意力能够大幅度提升图像边缘检测质量,因为自注意力机制可以扩展卷积操作的观察视野,捕获图像区域间的元素关联关系。

3.4 网络模型结构讨论

网络能够同时接受图像的多尺度输入,通过实验研究多尺度技术策略对图像边缘检测结果的影响。符号“Model 1 only”表示网络只由1号子模型组成,接受原始尺寸的图像输入;符号“Model 1+2”表示网络只由1、2号子模型组成,接受原始尺寸、二分之一尺度的图像输入;“Model 1+2+3”表示网络只由1、2、3号子模型组成,接受原始尺寸、二分之一尺度、四分之一尺度的图像输入。从表3的数据可知,与仅仅使用原始尺寸图像输入相比,多尺度策略的运用提升了图像检测效果。多尺度技术策略为算法模型提供了类似不同镜头下的观察。算法学到更多的关于边缘线的知识。

表3 不同网络结构对比实验(数据集 BIPED)

模型组合策略	ODS 指标	OIS 指标	AP 指标
Model 1 only	0.793	0.819	0.827
Model 1+2	0.829	0.841	0.862
Model 1+2+3	0.845	0.856	0.886

4 结 论

本文算法模型同时接收多种尺度图像输入,在不同尺度视觉下对图像边缘检测,然后由粗到精逐步融合不同输入尺寸的边缘结果。实验表明,多尺度卷积神经网络模型能够发挥多尺度计算策略优势,挖掘到更多的图像边缘线。在加权交叉熵基础上,添加一个正样本的范数项,成功解决了样本类间非均衡化的问题,算法获得更精细的边缘输出效果。本文仅研究了一种跨子模型连接,后期将对多种其它的跨子模型连接形式开展进一步研究。

参考文献

- [1] FU J, LIU J, WANG Y, et al. Stacked deconvolutional network for semantic segmentation [J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2019, DOI:10.1109/TIP.2019.2895460.
- [2] ARBELAEZ P, MAIRE M, FOWLKES C, et al. Contour detection and hierarchical image segmentation[J]. IEEE transactions on pattern analysis and machine intelligence, 2011, 33(5): 898-916.
- [3] YANG Z, SOLTANIAN-ZADEH S, FARSIU S. BiconNet: An edge-preserved connectivity-based approach for salient object detection [J]. ArXiv Preprint, 2021, DOI:arXiv:2103.00334.
- [4] LI M, LIN Z, MECH R, et al. Photo-sketching: Inferring contour drawings from images [C]. Proceedings of the IEEE Winter Conference on Applications of Computer Vision, IEEE, 2019, DOI: 10.1109/WACV.2019.00154.
- [5] DOLL'AR P, ZITNICK C L. Fast edge detection using structured forests [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(8): 1558-1570, DOI:10.1109/TPAMI.2014.2377715.
- [6] GANIN Y, LEMPITSKY V. N4-Fields: Neural network nearest neighbor fields for image transforms [C]. Proceedings of the Asian Conference on Computer Vision, Springer, 2014, DOI: https://doi.org/10.1007/978-3-319-16808-1_36.
- [7] BERTASIUS G, SHI J, TORRESANI L. Deepedge: A multi-scale bifurcated deep network for top-down contour detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2015: 4380-4389, DOI:10.1109/CVPR.2015.7299067.
- [8] SHEN W, WANG X, WANG Y, et al. Deepcontour: A deep convolutional feature learned by positive-sharing loss for contour detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2015, DOI: 10.1109/CVPR.2015.7299024.
- [9] XIE S, TU Z. Holistically-nested edge detection[C]. Proceedings of the IEEE international conference on computer vision, IEEE, 2015: 1395-1403, DOI: 10.1109/ICCV.2015.164.
- [10] LIU Y, CHENG M M, HU X, et al. Richer convolutional features for edge detection [J]. IEEE transactions on pattern analysis and machine intelligence, 2019, 41(8): 1939-1946, DOI:10.1109/TPAMI.2018.2878849.
- [11] DENG R, SHEN C, LIU S, et al. Learning to predict crisp boundaries [C]. Proceedings of the 2018 European Conference on Computer Vision. Springer, 2018: 570-586, DOI:http://doi.org/10.1007/978-3-030-01231-1_35.
- [12] POMA X S, RIBA E, SAPPA A D. Dense extreme inception network: Towards a robust CNN model for edge detection[C]. Proceedings of 2020 IEEE Winter Conference on Applications of Computer Vision, IEEE 2020: 1912-1921, DOI:10.1109/WACV45572.2020.9093290.
- [13] XIA C, PENG J, MA Z, et al. A multi-scale network with the encoder-decoder structure for CMR segmentation[J]. Journal of Information Hiding and Privacy Protection, 2019, 1: 109-117, DOI: 10.32604/jihpp.2019.07198.
- [14] ZHANG H, GOODFELLOW I, METAXAS D, et al. Self-attention generative adversarial networks [J].

- ArXiv Preprint, 2018, ArXiv:1805.08318.
- [15] REN W, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks [C]. Proceedings of the IEEE European Conference on Computer Vision, Springer, 2016: 154-169, DOI: https://doi.org/10.1007/978-3-319-46475-6_10.
- [16] DONG H, PAN J, XIANG L, et al. Multi-scale boosted dehazing network with dense feature fusion [C]. Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020: 2154-2164, DOI:10.1109/CVPR42600.2020.00223.
- [17] LAXMAN K, DUBEY S, KALYAN B, et al. Efficient high-resolution image-to-image translation using multi-scale gradient U-Net[J]. ArXiv Preprint, 2021, ArXiv:2105.13067.
- [18] QU Z, CAO C, LIU L, et al. A deeply supervised convolutional neural network for pavement crack detection with multiscale feature fusion [J]. IEEE Transactions on Neural Networks and Learning Systems, 2021: 1-10, DOI: 10.1109/TNNLS.2021.3062070.
- [19] YANG J, PRICE B, COHEN S, et al. Object contour detection with a fully convolutional encoder-decoder network[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2016: 193-202, DOI:10.1109/CVPR.2016.28.
- [20] YU Z, FENG C, LIU M. Y., et al. Casenet: Deep category-aware semantic edge detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017, DOI: 10.1109/CVPR.2017.191.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, ArXiv Preprint, 2014, ArXiv:1409.1556.
- [22] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2015: 1-9, DOI: 10.1109/CVPR.2015.7298594.
- [23] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778, DOI: 10.1109/CVPR.2016.90.
- [24] HUANG G, LIU Z, MAATEN L V D, et al. Densely connected convolutional networks[C]. Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), IEEE 2017: 2261-2269, DOI:10.1109/CVPR.2017.243.
- [25] CHO K, BART V M, GULCEHRE C, et al. Learning phrase representations using rnn encoder-decoder for statistical machine translation [J]. Computer Science, 2014, DOI: 10.3115/v1/D14-1179.
- [26] LONG J, SHELDHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. Proceedings of In IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2015: 3431-3440, DOI:10.1109/CVPR.2015.7298965.
- [27] GOODFELLOW I, POUGET-ABADIE J, MIRZA J, et al. Generative adversarial networks[J]. Advances in Neural Information Processing Systems, 2014, 3: 2672-2680.
- [28] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [J]. Computing Research Repository, 2015, DOI:arXiv:1502.03167.
- [29] BA J, KIROS J, HINTON G E. Layer normalization[J]. ArXiv Preprint, 2016, ArXiv:1607.06450.
- [30] WANG Y, ZHAO X, HUANG K. Deep crisp boundaries[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 3892-3900, DOI:10.1109/WACV.2019.00154.
- [31] HE J, ZHANG S, YANG M, et al. Bi-directional cascade network for perceptual edge detection [C]. Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2020: 3823-3832, DOI:10.1109/CVPR.2019.00395.

作者简介

石昌友, 硕士, 主要研究方向为计算机视觉、图像处理与识别。

E-mail: youchangshi@163.com

孙强, 讲师, 硕士, 主要研究方向为计算机应用技术。

卢建平, 副教授, 主要研究方向为网络安全。

夏榕泽, 博士, 主要研究方向为自然语言处理。

刘锦锋, 副教授, 硕士, 主要研究方向为计算机网络技术。