

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2025)02-0533-13

论文引用格式: Ye X Y, Sui M C, Xue Z Q, Wang J X and Chen H H. 2025. Image inpainting with foreground-background semantic decoupling. Journal of Image and Graphics, 30(02):0533-0545(叶学义, 睢明聪, 薛智权, 王佳欣, 陈华华. 2025. 前景—背景语义解耦的图像修复. 中国图象图形学报, 30(02):0533-0545)[DOI:10.11834/jig.240165]

前景—背景语义解耦的图像修复

叶学义*, 睢明聪, 薛智权, 王佳欣, 陈华华

杭州电子科技大学通信工程学院, 杭州 310018

摘要: 目的 修复前后的图像在语义上保持一致是图像修复研究遵循的基本规则之一。然而, 现有的图像修复方法往往忽视了图像前景与背景间的语义区别, 从而在修复过程后二者相互影响导致边缘模糊和语义混杂等问题。针对此问题, 提出了一种基于语义解耦前景背景的图像修复方法。**方法** 此方法由3个步骤组成: 语义修复、前景修复以及整体修复。初始阶段, 对缺失的语义标签图进行修补; 随后, 采用经过修复的语义图将缺损图像的前景与背景分离, 然后将损坏的前景区域输入到前景修复模块进行修复; 最终, 将修复后的前景区域嵌入到损失的图像中, 输入到整体修复模块完成整体修复及前景背景融合。**结果** 在公开的 CelebA-HQ 人脸数据集和 Cityscapes 街景数据集上与现有同类方法进行比较, 本文方法在学习感知图像块相似度、峰值信噪比和结构相似性指标上表现更好; 相较于对比方法的最优平均值, 在 CelebA-HQ 数据集上, 学习感知图像块相似度降低 8.86%, 结构相似性提高 1.10%, 且此方法峰值信噪比均值达到 27.09 dB; 在 Cityscapes 数据集上, 学习感知图像块相似度降低 4.62%, 结构相似性提高 0.45%, 且此方法峰值信噪比均值达到 27.31 dB。消融实验的数据表明了算法各个环节的必要性和有效性。**结论** 该图像修复方法通过将前景背景的语义解耦, 采用三段式算法流程递进完成图像修复, 有效减少了语义混乱和边界模糊的影响, 修复后生成的图像前景背景边界清晰, 颜色风格和谐, 语义连贯。

关键词: 图像修复; 语义修复; 先验知识; 前景—背景解耦; 生成对抗网络(GAN)

Image inpainting with foreground-background semantic decoupling

Ye Xueyi*, Sui Mingcong, Xue Zhiqian, Wang Jiaxin, Chen Huahua

School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

Abstract: Objective Image inpainting is a technique that infers and repairs damaged or missing regions of an image on the basis of the known content of the image. It originated from artists restoring damaged paintings or photographs to restore their quality as close as possible to the original image. This technique has been widely applied in fields such as cultural heritage preservation, image editing, and medical image processing. The development of image inpainting technology has undergone a transition from traditional methods to modern methods. Traditional methods are typically good at handling small areas of simple structured image textures, but they often fail to achieve satisfactory results when faced with large missing areas and complex structural and textual information. With the rise of the big data era, deep learning methods such as generative adversarial networks have rapidly developed, substantially improving the effectiveness of image inpainting. Compared with traditional image inpainting algorithms, deep learning methods can better understand the semantic information of images, improving the accuracy and efficiency of repair. Deep learning models can fully understand the semantic infor-

收稿日期: 2024-03-22; 修回日期: 2024-05-21; 预印本日期: 2024-05-28

* 通信作者: 叶学义 xueyiye@hdu.edu.cn

基金项目: 国家自然科学基金项目(U19B2016)

Supported by: National Natural Science Foundation of China(U19B2016)

mation of images and generate highly accurate repair results when a large amount of data is learned. However, current methods usually treat images as a whole for repair. From a semantic perspective, the foreground and background have significant differences. Treating the foreground and background may lead to problems such as blurred edges and structural deformation, resulting in unsatisfactory results. This issue is addressed by adopting a new image inpainting framework that uses semantic label maps to separate the foreground and background for repair. **Method** The image inpainting method includes three modules: a semantic inpainting module, a foreground inpainting module, and an overall inpainting module. The purpose of the semantic repair module is to repair the defective semantic map to guide the subsequent semantic decoupling of the foreground and background areas. In the semantic repair phase, the missing semantic tag graph can be repaired, and the semantic information of the missing region can be enhanced. Then, the foreground mask is extracted via the repaired semantic map to obtain the accurate boundary and shape information of the foreground region. In the foreground restoration stage, the foreground region of the defect image is extracted on the basis of the foreground mask, and then the foreground restoration module is used to restore the texture and fill the missing region. The foreground area usually contains the key information in the image. Highly accurate and detailed foreground objects and their semantic information can be obtained when the foreground is repaired. The restored foreground region is subsequently embedded into the missing image. Finally, the missing image with foreground restoration completed is input to the overall repair module, which completes the two tasks of repairing the background region of the missing image and foreground-background fusion. The overall inpainting module repairs the entire image on the basis of the context information of the foreground, maintaining the consistency and smoothness of the image and further improving the inpainting effect of the foreground region. A joint loss function was employed for the three stages of image inpainting. The semantic inpainting module uses adversarial loss and semantic distribution loss to further improve the accuracy of semantic inpainting. The foreground inpainting and overall inpainting modules further incorporate perceptual loss, style loss, and global loss in addition to the losses. In particular, perceptual loss is used to ensure that the restoration results closely resemble the original image in terms of perception; style loss is used to reduce the occurrence of checkerboard artifacts caused by transposed convolution layers; and global loss is used to guarantee that the restored results exhibit a more coherent structure and content across the entire image. When these different types of loss functions are utilized, the proposed method can generate more realistic and natural images while maintaining high-quality inpainting results. **Result** Comparative experiments with other current image restoration methods demonstrated that the proposed approach outperforms other methods in terms of learned perceptual image patch similarity, the peak signal-to-noise ratio, and the structural similarity index on the CelebA-HQ and Cityscapes public datasets. Compared with the best average values of the baseline methods, on the CelebA-HQ dataset, the learned perceptual image patch similarity decreased by 8.86%, the structure similarity index measure (SSIM) improved by 1.1%, and the average peak signal-to-noise ratio (PSNR) was 27.09 dB. For the Cityscapes dataset, the LPIPS decreased by 4.62%, the SSIM improved by 0.45%, and the average PSNR was 27.31 dB. Furthermore, ablation experiments confirm the necessity and effectiveness of each component in the algorithm used in this study. **Conclusion** This image inpainting method decouples the semantics of the foreground and background and uses a three-stage algorithm process to complete the image inpainting step by step, which effectively reduces the impact of semantic confusion and fuzzy boundaries. The foreground and background boundaries of the repaired image are clear, and the color style is more reasonable.

Key words: image inpainting; semantic repair; priori knowledge; foreground-background decoupling; generative adversarial network (GAN)

0 引言

图像修复的目的是根据图像的已知信息修复损坏的图像内容,以产生视觉上可信的语义和纹理。(Xiang等,2023)。该项技术在许多领域得到了广泛

应用,如文化遗产保护、图像编辑和医学图像处理等。近年来图像修复取得了重大进展,但现有的方法仍然会导致结构不一致和颜色风格不和谐等语义性问题。

现有图像修复方法可以分为传统方法和基于深度学习方法两类。传统方法主要分为基于扩散的方

法(Shen等,2003)和基于补丁的方法(Barnes等,2009;Ding等,2018)。基于扩散的方法利用偏微分方程求解,将已知区域的重要信息传播到损坏的区域;基于补丁的方法核心通过寻找最匹配的局部区域来进行损坏区域的修复。然而在处理复杂修复任务时,传统方法缺乏对图像的语义理解容易导致修复图像出现伪影和模糊。

相较而言,基于深度学习的修复方法使用海量图像数据进行训练,能够学习到图像的各种特征和高级语义信息,进而生成与原始图像相符的修复结果。Pathak等人(2016)首次提出将生成对抗网络(generative adversarial network, GAN)(Goodfellow等,2014)和编码器—解码器网络结构相结合进行图像修复。然而,这种方法存在图像模糊和不连续边缘等问题。从网络结构方向优化,刘微容等人(2022)提出了一种多级解码网络,旨在充分整合不同尺度的图像特征信息。该网络包括主解码器和多个辅助解码器,用于精细化编码阶段各层特征,从而产生更精确、视觉上更合理的修复结果。此外,多阶段网络架构也被用于图像修复任务。Li等人(2020)提出了循环特征推理网络,通过循环推理反复处理特征图,逐步完善缺失图像。Quan等人(2022)提出了一种三阶段图像修复生成网络,结合了局部细化网络和全局细化网络。这一设计有助于在不同尺度上修复细节和结构。考虑到多阶段的依赖性问题,王倩娜和陈焱(2022)提出基于双解码器的图像修复方法来消除两阶段修复中的依赖性,并利用多种损失增强语义一致性。

由于修复缺损区域的不确定性,许多图像修复方法旨在从输入图像的已知区域学习有效的先验知识,然后根据这些先验知识推断损坏区域的内容。例如,Xiong等人(2019)提出前景感知修复模型,通过修复前景对象轮廓来指导整体修复。Wang等人(2021)提出外部—内部修复方案,外部重建结构细节,内部则通过渐进方式恢复颜色。Guo等人(2021)提出了一种新型双流网络,该网络通过耦合的方法,对受到结构约束的纹理合成和纹理引导下的结构修复进行了建模。此外,Zhang等人(2023)设计的算法通过纹理空间注意模块和结构通道激励模块实现图像修复纹理和结构的一致性。根据语义特征一致性,Liao等人(2020)提出了一种单个阶段的语义引导图像修复模型,该模型采用逐步生成更高分辨率

的语义图来指导图像修复,以获得更准确的修复结果。Liao等人(2021)提出了引入语义和纹理之间的连贯先验,从而可以专注于以语义方式完成单独的纹理修复。杨红菊等人(2022)提出通过整合语义信息和边缘信息来指导修复过程。该方法首先重建图像的语义结构,以此为基础引导边缘结构的重建。随后,利用语义信息和边缘信息共同指导最终的图像修复任务。考虑到多阶段实现的方法非常耗时,Yu等人(2022b)开发了一个端到端的多模态引导修复网络,包括一个修复分支和两个辅助分支,用于语义分割和边缘纹理。Chen等人(2023)提出利用高级语义特征指导结构感知特征修复,同时将低层特征图作为纹理修复先验,以获得具有合理语义的结果。Zhang等人(2024)提出了语义分割指导图像修复,并从图像修复中获得反馈,这两个过程相互作用并逐步提高修复质量。包括上述算法在内的许多深度学习修复方法通常将图像前景和背景作为一个整体来处理。但在图像修复任务中,前景和背景的特征差异很大。Luo等人(2023)指出整体处理前景实例对象和背景会导致不真实的对象以及纹理不一致的背景,因此需要对前景实例对象和背景分别处理。但该算法处理耗时较长,且结论表明对象大规模遮挡时很难产生令人满意的结果。针对该问题,本文提出了一种前景—背景语义解耦的方法。该方法根据重点关注区域人为设定前景,之后借助语义信息提取前景掩膜,再利用前景掩膜解耦缺损图像的前景和背景区域,从而减弱在修复过程中前景背景相互干扰。

基于该思想,将图像修复分为语义修复、前景修复和整体修复三个阶段。首先通过修复缺损图像对应的缺损语义标签图,从而提取前景掩膜;随后使用前景掩膜解耦缺损图像的前景与背景区域,接着将缺损前景输入到前景修复模块进行修复;最后将修复后的前景嵌入缺损图像,再经过整体修复模块进行前景背景融合和整体区域修复,以获得更高质量的修复结果。此外,在利用语义信息进行图像修复时,需要充分约束语义信息,并考虑缺损区域的局部一致性和特征独立性。因此,本文基于掩码将空间像素划分为不同区域的思路(Yu等,2020),提出了语义分部损失。在CelebA-HQ和Cityscapes数据集上进行实验,将本文方法与其他图像修复方法的修复结果进行定性和定量对比。实验结果显示,本文方法在这两个数据集上均展现出了更好的修复性能。

1 模 型

在图像修复中,利用语义信息可以更准确地识别和理解图像中的对象、场景和结构,从而更精确地恢复受损部分(Yu等,2022a)。此外,语义信息还可以用于指导修复过程中的像素填补,以保持图像的语义一致性和连贯性。因此基于语义层面,本文提出一种三阶段递进的图像修复方法。通过语义解耦受损图像的前景和背景区域,实现对缺损图像的修复。该方法由3个模块组成,分别是语义修复模块、前景修复模块和整体修复模块。每个模块均采用生成器与鉴别器的架构。在模型中, G_s 、 G_f 和 G_a 分别表示语义分割修复模块、前景修复模块和整体修复模块的生成器; D_s 、 D_f 和 D_a 分别表示相应模块的鉴别器。初始语义修复模块通过修复缺损图像 I_{in} 对应的

语义图 S_{in} 以获取修复语义图 S_{re} ,从而指导后续的修复工作。接着,利用修复后的语义图提取前景区域掩膜 S_f 解耦缺损的前景区域,之后将受损的前景区域 F_{in} 输入到前景修复模块进行修复。最后,修复完成的前景图像 F_{re} 将被嵌入到缺损的图像中得到 I_{ina} ,随后经过整体修复模块进行背景区域的修复和整体融合得到最终修复结果 I_{re} 。本文整体方法流程如图1所示(以城市街景图像为例,将植被、建筑和天空作为背景,行人、车辆等其他区域作为前景)。

1.1 语义修复模块

语义修复模块利用修复缺损的语义图来指导后续的解耦图像修复过程。通过这种方法,可以更好地地区分不同语义区域的边界,从而提高局部特征修复的效果。

以人脸语义图为例来说明网络架构,图2为语义修复模块的生成器网络结构图,图3为语义修复




图1 三阶段模型整体架构

Fig. 1 The overall architecture of three-stage model

模块的鉴别器网络结构图,前景修复模块和整体修复模块的网络结构都与之类似。如图2所示,生成器构成包括编码器、解码器以及多尺度融合模块。该设计(叶学义等,2023)受到了U-Net架构核心特性的启发,通过跳跃连接将编码器捕获的特征信息传递到对应的解码器层,从而实现了特征图的融合。

这种设计策略使得解码器在执行上采样计算时,能够充分地利用来自编码器的原始信息。通过多尺度的逐层融合,该方法有效地传递并保留了编码器所捕获的高层次语义特征,进而改善了修复结果的语义连贯性,并有效解决了图像修复过程中高级特征信息缺失的问题。




图2 语义修复模块的生成器

Fig. 2 Generator of the semantic reconstruction module

为了更好地关注图像细节,本文的鉴别器基于马尔可夫判别器 PatchGAN (Isola等,2017)设计,采用一个含有5层卷积层的卷积网络作为基础架构,如图3所示。鉴别器将输入样本映射为矩阵,每个输出矩阵中的值表示对输入图像中尺寸为 93×93 像素的区域进行鉴别。




图3 语义修复模块鉴别器网络结构

Fig. 3 Discriminator network structure of the semantic reconstruction module

在语义修复阶段,生成器 G_s 的输入包括缺损图像 $I_{in} = I_o \odot (1 - M) + M$ 、缺损语义图 $S_{in} = S_o \odot (1 - M) + M$ 和不规则缺损掩膜 M , $\odot$ 表示像素矩阵对应元素相乘。生成器输出预测语义图 $S_g = G_s(I_{in}, S_{in}, M)$

得到最终修复结果 $S_{re} = S_g \odot M + S_o \odot (1 - M)$ 。

鉴别器 D_s 输入 S_{re} 和 S_o 来进行判别计算损失。为了使修复后的语义图 S_{re} 与真实语义图 S_o 尽可能相似,在语义修复模块采用联合损失,结合了生成对抗损失 L_{adv} 和语义损失 L_s ,以优化语义修复模块的训练过程。语义修复模块的训练指标函数定义为

$$\min_{G_s} \max_{D_s} L_{G_s} = \min_{G_s} \left(\lambda_{adv}^S \max_{D_s} (L_{adv}^S) + \lambda_s^S L_s^S \right) \quad (1)$$

式中, λ_{adv}^S 和 λ_s^S 是超参数,通过实验经验确定。

对抗损失是在对抗学习过程中使用的,旨在区分真实样本和生成样本。目标是使真实样本与生成样本的分布之间的距离尽可能大。因此,采用 hinge 函数来定义对抗损失,具体为

$$L_{adv}^S = -E_{S_{re} \sim P_{data}(S_{re})} [D_s(S_{re})] \quad (2)$$

$$L_D = E_{S_o \sim P_{data}(S_o)} [\text{ReLU}(1 - D_s(S_o))] + E_{S_{re} \sim P_{data}(S_{re})} [\text{ReLU}(1 + D_s(S_{re}))] \quad (3)$$

式中, D 为鉴别器, $P_{data}(S_o)$ 为真实图像样本分布, $P_{data}(S_{re})$ 为修复图像样本分布, $S_{re} \sim P_{data}(S_{re})$ 表示 S_{re} 从 $P_{data}(S_{re})$ 中得到, $S_o \sim P_{data}(S_o)$ 同理。ReLU (rectified linear unit) 代表激活函数。 L_{adv}^S 为语义修复模块鉴别器

的对抗损失, L_D 为鉴别器的总损失。

对鉴别器而言, 仅当 $D(S_o) < 1$ 和 $D(S_{re}) > -1$ 时, 样本才会对结果产生作用。因此, 使用 hinge 函数能提高训练过程的稳定性, 并有助于加速收敛。

语义分部损失考虑了不同语义区域之间的差异, 通过赋予不同语义区域不同的权重来约束修复过程, 从而保证修复后的图像在不同语义区域上具有更好的一致性。语义分部损失定义为

$$L_s^S = \sum_i \lambda_i \|\Delta_i(S_o) - \Delta_i(S_{re})\|_1 \quad (4)$$

式中, λ_i 表示不同语义区域的权重, 本文算法根据缺损比定义 λ_i , 缺损比越大权重越大。 $\Delta_i(S_o)$ 表示真实语义图 S_o 中标签值 i 对应的图像区域。

1.2 前景修复模块

通过修复语义图可以提取前景掩膜, 从而实现前景与背景的语义解耦。前景区域通常包含图像中的关键语义信息。优先修复前景区域有助于获得更准确、详细的前景对象及其语义信息, 从而提供更丰富且有价值的视觉信息。因此, 本文根据重点关注区域人为定义了前景和背景所包含的语义区域。

为了提高前景掩膜的准确性, 将修复语义图从 RGB 空间转换到 HSV 空间, 并设定颜色范围进行颜色分类, 从而实现前景掩膜 M_f 的提取。在后续处理前景掩膜时, 采用常见图像后处理方法, 包括膨胀、腐蚀和连通域分析, 以去除掩膜中微小孔洞。

前景修复模块生成器网络架构基于语义修复模块, 并引入空间注意力机制, 以更好地聚焦于前景区域, 从而减少空白区域的干扰。鉴别器网络结构与语义修复模块相同。在前景修复阶段, 首先借助 M_f 获得修复语义图的前景区域 S_f 和缺损掩膜 M 的前景区域 M_{fm} , 并通过缺损图像 I_{in} 解耦得到缺损图像前景区域 $F_{in} = I_{in} \odot (1 - M_f) + M_{fo}$ 。生成器 G_f 在输入 F_{in} 、 S_f 和 M_{fm} 后输出预测前景区域图像 $F_g = G_f(F_{in}, S_f, M_{fm})$ 。真实图像的前景区域图像是 $F_o = I_o \odot (1 - M_f) + M_{fo}$, 保留 F_o 未缺损区域得到修复前景图像 $F_{re} = F_g \odot M_{fm} + F_o \odot (1 - M_{fm})$ 。

鉴别器 D_f 输入 F_{re} 和 F_o 判别预测前景图。为了使二者尽可能相似, 采用联合损失。联合损失结合了生成对抗损失 L_{adv}^F 、语义损失 L_s^F 、感知损失 L_{pe}^F 、风格损失 L_{sy}^F 和全局损失 L_{L1}^F , 具体为

$$L_{G_f} = \lambda_{adv}^F L_{adv}^F + \lambda_s^F L_s^F + \lambda_{pe}^F L_{pe}^F + \lambda_{sy}^F L_{sy}^F + \lambda_{L1}^F L_{L1}^F \quad (5)$$

式中, λ_s^F 、 λ_{adv}^F 、 λ_{pe}^F 、 λ_{sy}^F 和 λ_{L1}^F 是超参数。对抗损失与语义修复模块原理类似。全局损失定义为

$$L_{L1}^F = \|F_o - F_{re}\|_1 \quad (6)$$

式中, $\|\cdot\|_1$ 表示真实图像和修复图像整体 $L1$ 距离。

为了量化修复结果与真实结果之间的感知差异, 本文采用了感知损失 (Johnson 等, 2016)。该损失的目标是在特征空间上最小化修复图像和真实图像之间的距离, 从而惩罚在感知层面上与真实图像显著不同的修复图像。感知损失定义为

$$L_{pe}^F = E \left[\sum_i \frac{1}{N_i} \|\Phi_i(F_o) - \Phi_i(F_{re})\| \right] \quad (7)$$

式中, $\Phi_i(F_o)$ 是图像 F_o 经过 VGG-19 (Visual Geometry Group 19-layer net) 网络后第 i 层的输出特征图, $\Phi_i(F_{re})$ 同理。通过输出特征图可以计算感知损失和风格损失 (Johnson 等, 2016)。风格损失的设计目的是为了量化输入图像与目标图像在视觉风格方面的差异。当特征图大小为 $C_j \times H_j \times W_j$ 时, 风格损失通过衡量特征图之间协方差的差异来进行计算, 定义为

$$L_{sy}^F = E_j [\|G_j^{\Phi}(F_o) - G_j^{\Phi}(F_{re})\|] \quad (8)$$

式中, $G_j^{\Phi}(F_o)$ 是从特征图 $\Phi_i(F_o)$ 构建的 $C_j \times C_j$ 格拉姆矩阵, $G_j^{\Phi}(F_{re})$ 同理。通过应用风格损失, 能有效地减轻转置卷积引入的不良视觉伪影, 从而确保修复结果更加美观和真实。

1.3 整体修复模块

考虑到多阶段修复耗时的问题, 本文算法使用整体修复模块涵盖了整体修复和前景背景融合两大任务。整体修复模块采用与语义修复模块相同的网络架构设计, 有助于保持语义一致性, 使修复结果更加准确和合理。

在整体修复阶段中, 首先利用前景修复图像 F_{re} 和缺损图像背景区域 $I_{inB} = I_{in} \odot (1 - M_f) + M_{fo}$ 得到已修复前景区域的待修复图像 $I_{ina} = I_{inB} \odot F_{re}$ 。生成器 G_a 输入 I_{ina} 、 S_{re} 和 M , 进而输出整体生成图像 $I_g = G_a(I_{ina}, S_{re}, M)$, 保留图像未缺损区域, 得到整体修复图像 $I_{re} = I_g \odot M + I_o \odot (1 - M)$ 。

鉴别器 D_a 输入 I_{re} 和 I_o 判别整体修复图。同样采用联合损失, 联合损失结合了生成对抗损失 L_{adv}^A 、语义损失 L_s^A 、感知损失 L_{pe}^A 、风格损失 L_{sy}^A 和全局损失 L_{L1}^A , 具体为

$$L_{G_s} = \lambda_{adv}^A L_{adv}^A + \lambda_s^A L_s^A + \lambda_{pe}^A L_{pe}^A + \lambda_{sy}^A L_{sy}^A + \lambda_{Li}^A L_{Li}^A \quad (9)$$

式中, λ_{adv}^A 、 λ_s^A 、 λ_{pe}^A 、 λ_{sy}^A 和 λ_{Li}^A 是超参数, 通过实验经验设置。

2 实验

2.1 数据与实验细节

在本文实验中, 为了与当前其他图像修复方法进行公平比较, 使用尺寸为 256×256 像素的图像进行训练。本文实验采用包含语义分割标签的 CelebA-HQ 人脸数据集和 Cityscapes 城市景观数据集。

CelebA-HQ 数据集是一个包含 30 000 幅高分辨率图像的大规模人脸数据集, 每幅图像都有对应的语义图, 包含 19 种语义类别。将这 30 000 幅图像随机划分 27 000 幅用于训练和 3 000 幅用于测试。在本文研究中, 使用不规则缺损数据集来进行训练和测试。本研究使用从 Liu 等人(2018)工作中获取的一个包含 6 个不同缺损率类别(0~10% 直至 50%~60%)的不规则缺损数据集, 每个类别包含 2 000 个掩膜。图 4 展示了部分掩膜示例。



图 4 不规则缺损掩膜图像示例

Fig. 4 Example of irregular damage mask images

Cityscapes 数据集包含 20 个类别的城市街道场景。实验使用来自原始训练集的 2 975 幅图像和来自原始测试集的 1 525 幅图像来构建训练数据集, 来自原始验证集的 500 幅图像作为测试数据集。对于 Cityscapes 数据集, 根据 Yu 等人(2019)方法绘制不规则缺损掩膜。

图 5 展示了两个数据集预处理后的各模块输入图像, 依次是真实图像、语义修复模块输入缺损语义图、前景修复模块输入缺损图像前景区域和整体修复模块输入修复前景嵌入后图像。

为了准确地评估本文提出的图像修复算法的性能, 使用定性和定量评价方法。为了保证实验结果具有可靠性和公正性, 使用了深度学习框架 PyTorch 进行模型的训练和测试, 并使用了 NVIDIA 3090Ti 显卡进行计算。实验将批处理大小设置为 32, 并使




图 5 预处理后的各模块输入图像

Fig. 5 Preprocessed input images for each module

用 Adam 优化器对目标函数进行优化。

本研究采用了多损失函数的训练策略, 并基于预设的基准权重对各损失函数的权重进行了调整。在训练过程中, 语义修复模块损失函数权重为 $\lambda_{adv}^S = 1$ 和 $\lambda_s^S = 20$; 前景修复模块损失函数权重为 $\lambda_{Li}^F = \lambda_s^F = 1$ 、 $\lambda_{adv}^F = \lambda_{pe}^F = 0.1$ 和 $\lambda_{sy}^F = 250$; 整体修复模块损失函数权重为 $\lambda_{Li}^A = \lambda_s^A = 1$ 、 $\lambda_{adv}^A = \lambda_{pe}^A = 0.1$ 和 $\lambda_{sy}^A = 250$ 。

2.2 定性评价

对于 CelebA-HQ 数据集, 本文根据重点关注区域人为定义前景。在人脸图像中人脸通常为重点区域, 因此将人脸及五官作为前景, 其余区域作为背景进行解耦。将本文方法与 RFR(recurrent feature reasoning)(Li 等, 2020)、CTSDG(conditional texture and structure dual generation)(Guo 等, 2021)、MMT(multi-modality technique)(Yu 等, 2022b)和 LG-Net(local and global network)(Quan 等, 2022)4 种图像修复方法进行定性比较。图 6 展示了各方法在 CelebA-HQ 数据集上的视觉比较结果。通过分析这些实验图像, 可以观察到 RFR 方法生成的图像存在扭曲和伪影问题, CTSDG 方法生成的图像整体不协调, 人脸眼睛模糊且不对称。MMT 方法生成的图像结构合理, 但部分图像存在前景背景干扰和语义混乱现象。LG-Net 方法修复图像视觉效果较自然, 但仍存在颜色风格不和谐和前景背景干扰等问题。相比之下, 本文提出的方法在图像结构和颜色风格上更加真实自然, 并且成功减少了前景背景之间干扰现象。

对于 Cityscapes 数据集, 街景图像中街景通常为重点区域, 例如行人、车辆等, 因此本文将植被、建筑以及天空作为背景, 行人、车辆等其他语义区域作为前景进行解耦。Cityscapes 数据集包含的街景图像




图6 CelebA-HQ数据集上定性对比

Fig. 6 Qualitative comparison on the CelebA-HQ dataset

在结构上复杂且具有显著的多样性,这使得图像修复工作面临较大挑战。将本文方法与RFR、CTSDG、MMT和LG-Net 4种方法进行定性比较。

图7展现了本文方法与其他图像修复方法在Cityscapes数据集上视觉比较的结果。相较于其他方法,本文方法在修复结果的一致性和视觉效果上表现更佳。特别是在第1行和第4行中,本文方法在汽车破损区域能够恢复更加清晰和完整的细节。在第2行中,本文方法成功精确修复了植被与道路,并且其分界线清晰可见,相比之下,其他方法在这些交界处的修复效果显得较为模糊。在第3行中,RFR和MMT生成的图像存在结构缺损且模糊,虽然CTSDG和LG-Net的修复效果有所改善,但仍然存在植被和道路、汽车之间的干扰现象。相比之下,本文方法生成图像在边界清晰度、结构合理性以及视觉真实感方面均表现出了显著的优势。

总体而言,在CelebA-HQ和Cityscapes数据集上,以往的图像修复算法通常采用整体修复的方式。

无论是否使用先验知识,都容易出现前景背景互干扰的现象,导致修复后的图像交界模糊、语义混乱等问题。相比之下,本文方法能够有效地解决这些问题,修复结果更加合理且伪影较少,纹理细节也更加真实。

2.3 定量评价

为了客观评价本文算法的图像修复效果,对于CelebA-HQ数据集,本文选取了不规则缺损掩膜图像,将其与原始图像合成缺损图像作为实验样本,通过定量评估比较修复效果。本文选用了图像修复研究中广泛认可的评价指标,包括学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)(Zhang等,2018)、峰值信噪比(peak signal-to-noise ratio, PSNR)以及结构相似性指数(structure similarity index measure, SSIM)(Wang等,2004)。这些指标共同为本研究修复效果的量化提供了全面的评估。表1列出了各方法对不同破损率的修复评估结果。其中,MMT对比方法的数据为本文作者复现




图7 Cityscapes数据集上定性对比

Fig. 7 Qualitative comparison on the Cityscapes dataset

结果, RFR、CTSDG、LG-Net 和 CSTF (contrastive structure and texture fusion) (Chen 等, 2023) 对比方法的数据来自 Chen 等人 (2023) 的实验结果。

根据表1可以观察到在缺损率达到40%~60%时, 本文算法与CTSF算法相比, 其PSNR略低。这可能是因为当缺失区域较大时, 尽管人脸本身具有特异性的结构信息, 修复语义基本能保持一致。但修复人脸外的语义会产生差异, 导致修复图像引入了新的噪声或不协调的像素。综合考虑整体平均修复效果, 相对于其他先进的图像修复方法, 本文算法在定量上具有优势。

对于 Cityscapes 数据集, 同样使用评估指标 SSIM、PSNR 和 LPIPS 来衡量。表2列出了不同方法的修复评估结果。其中, RFR、CTSDG、LG-Net、W-Net (w-shaped network) (Zhang 等, 2023) 和 MDTG (mutual dual-task generator) (Zhang 等, 2024) 对比方法的数据来自 Zhang 等人 (2024) 实验结果, MMT 来自本文作者复现结果。

根据表2的结果可以看出, 本文算法在整体平均指标上均优于其他模型。在缺损率为40%~60%的区间内, 本文算法在PSNR和SSIM指标上表现不如部分算法。经分析可能是因为本文方法仅依赖于语义图来指导修复过程。尽管在车辆等形状相

对固定的语义缺失面积较大的情况下, 本文方法能够产生基本一致的语义, 但在处理行人等复杂、多样语义缺失面积较大的情况下, 语义难以准确恢复, 导致修复结果误差。尤其当语义完全缺失时, 无法准确地恢复原始的语义内容。通过对 Cityscapes 数据集的定量实验评估, 所提出模型的整体平均结果超过了参比模型, 进一步验证了本文所提出模型的优越性。

2.4 基于 CelebA-HQ 数据集的消融实验

2.4.1 前景—背景语义解耦的消融实验

前景—背景语义解耦是方法中的关键步骤, 指的是通过语义信息解耦缺损图像的前景和背景区域。消融实验用于验证该步骤的有效性。具体而言, 在包含该步骤实验完成后, 移除该步骤重新进行实验, 然后比较移除前后的修复结果质量。实验结果如表3所示。通过前景—背景解耦修复和直接整体修复指标对比, 发现在进行解耦后修复效果明显更好, 说明通过解耦修复前景区域能更好地处理图像前景背景特征差异, 提升修复结果质量。

2.4.2 语义分部损失的消融实验

语义分部损失是本文提出的一种语义约束, 旨在解决语义混乱问题。为了验证语义分部损失的有

表1 在 CelebA-HQ 数据集上不同图像修复方法定量对比

Table 1 Quantitative comparison of different image inpainting methods on CelebA-HQ dataset

方法	PSNR/dB ↑						SSIM ↑					
	(0.1, 0.2]	(0.2, 0.3]	(0.3, 0.4]	(0.4, 0.5]	(0.5, 0.6]	平均	(0.1, 0.2]	(0.2, 0.3]	(0.3, 0.4]	(0.4, 0.5]	(0.5, 0.6]	平均
RFR	28.90	26.30	23.96	22.12	21.61	24.58	0.945	0.905	0.860	0.808	0.730	0.850
CTSDG	30.57	28.33	26.36	24.77	21.98	26.40	0.957	0.936	0.907	0.871	0.799	0.894
MMT	31.17	28.85	26.61	24.46	22.36	26.69	0.961	0.935	0.914	0.867	0.823	0.900
LG-Net	31.12	28.21	26.65	24.69	22.57	26.65	0.960	0.925	0.909	0.868	0.826	0.898
CSTF	31.24	28.72	26.80	24.93	22.78	26.89	0.962	0.937	0.916	0.877	0.832	0.905
本文	32.33	28.96	26.83	24.92	22.42	27.09	0.969	0.945	0.920	0.889	0.850	0.915

方法	LPIPS ↓					
	(0.1, 0.2]	(0.2, 0.3]	(0.3, 0.4]	(0.4, 0.5]	(0.5, 0.6]	平均
RFR	0.056	0.086	0.105	0.139	0.189	0.115
CTSDG	0.057	0.079	0.091	0.122	0.179	0.106
MMT	0.051	0.072	0.082	0.099	0.124	0.086
LG-Net	0.052	0.069	0.080	0.097	0.121	0.084
CSTF	0.049	0.064	0.074	0.090	0.120	0.079
本文	0.033	0.047	0.068	0.086	0.131	0.072

注:加粗字体表示各列最优结果。“↑”代表越高越好,“↓”代表越低越好。

表2 在 Cityscapes 数据集上不同图像修复方法定量对比

Table 2 Quantitative comparison of different image inpainting methods on Cityscapes dataset

方法	PSNR/dB ↑				SSIM ↑				LPIPS ↓			
	(0, 0.2]	(0.2, 0.4]	(0.4, 0.6]	平均	(0, 0.2]	(0.2, 0.4]	(0.4, 0.6]	平均	(0, 0.2]	(0.2, 0.4]	(0.4, 0.6]	平均
RFR	31.11	25.79	23.33	26.74	0.942	0.860	0.780	0.861	0.038	0.090	0.140	0.089
CTSDG	30.34	26.07	24.28	26.90	0.941	0.882	0.822	0.882	0.069	0.104	0.140	0.104
MMT	31.12	25.89	23.15	26.83	0.947	0.873	0.798	0.873	0.039	0.092	0.159	0.097
LG-Net	31.38	26.17	23.69	27.08	0.946	0.867	0.791	0.868	0.037	0.087	0.131	0.085
W-Net	31.04	25.49	22.45	26.33	0.949	0.875	0.791	0.872	0.042	0.099	0.158	0.099
MDTG	31.68	26.61	23.44	27.24	0.950	0.884	0.817	0.884	0.027	0.066	0.103	0.065
本文	32.03	26.66	23.24	27.31	0.955	0.895	0.813	0.888	0.021	0.060	0.106	0.062

注:加粗字体表示各列最优结果。“↑”代表值越高越好,“↓”代表值越低越好。

效性,本文进行了消融实验。将语义分布损失移除后,比较移除前后的修复结果质量。实验结果如表4所示。

通过进行语义分部损失的消融实验,可以观察到在移除语义分部损失的情况下,修复结果的质量下降。这表明语义分部损失在修复过程中成功起到了约束作用,能够有效减少语义混乱的影响,提高修复结果的准确性和质量。

3 结 论

本文提出了一种新的图像修复方法,该方法通过解耦前景和背景来解决前景背景特征差异的问题,并利用语义分部损失来解决语义混乱的问题。实验结果表明,该方法在处理复杂和各类缺损的修复任务上取得了更高的修复质量。

表 3 前景—背景语义解耦的消融实验
Table 3 Ablation study of foreground-background semantic decoupling

缺损率	PSNR/dB ↑				SSIM ↑				LPIPS ↓			
	前景区域		整体区域		前景区域		整体区域		前景区域		整体区域	
	解耦	未解耦	解耦	未解耦	解耦	未解耦	解耦	未解耦	解耦	未解耦	解耦	未解耦
(0.1, 0.2]	38.03	37.53	32.33	31.10	0.996	0.992	0.969	0.951	0.009	0.012	0.030	0.051
(0.2, 0.3]	34.28	33.84	28.96	28.14	0.993	0.988	0.945	0.924	0.015	0.019	0.047	0.066
(0.3, 0.4]	32.24	31.86	26.83	26.21	0.989	0.973	0.920	0.901	0.020	0.023	0.068	0.078
(0.4, 0.5]	30.37	29.89	24.92	24.32	0.986	0.961	0.889	0.862	0.026	0.031	0.086	0.095
(0.5, 0.6]	27.94	27.62	22.42	21.96	0.979	0.952	0.850	0.828	0.038	0.043	0.131	0.142
平均	32.57	32.15	27.09	26.35	0.989	0.973	0.915	0.893	0.022	0.026	0.072	0.086

注:加粗字体表示各指标最优结果。“↑”代表值越高越好,“↓”代表值越低越好。

表 4 语义分部损失的消融实验
Table 4 Ablation study of semantic partition loss

缺损率	PSNR/dB ↑		SSIM ↑		LPIPS ↓	
	无	有	无	有	无	有
(0.1, 0.2]	31.97	32.33	0.965	0.969	0.032	0.03
(0.2, 0.3]	28.73	28.96	0.941	0.945	0.049	0.047
(0.3, 0.4]	26.54	26.83	0.916	0.92	0.069	0.068
(0.4, 0.5]	24.68	24.92	0.884	0.889	0.093	0.086
(0.5, 0.6]	22.16	22.42	0.842	0.85	0.135	0.131
平均	26.82	27.09	0.91	0.915	0.076	0.072

注:加粗字体表示各指标最优结果。“↑”代表值越高越好,“↓”代表值越低越好。

在实验中,首先使用缺损图像对应的缺损语义标签图来解耦前景区域进行前景修复,并将修复后的前景嵌入缺损图像。最后,使用整体修复模块完成前景背景融合和整体修复。同时,利用真实图像和修复图像之间各个语义区域的 L_1 损失来约束修复过程,以确保修复的图像与真实图像在语义上尽可能一致。

通过与其他先进方法在 CelebA-HQ 和 Cityscapes 数据集上进行对比实验,发现该方法在处理修复任务时具有更高的修复质量。这表明该方法能够更好地处理前景背景特征差异和语义混乱的问题,提升了修复结果的质量。然而,本文方法仍存在一些不足有待继续改进。例如:虽然本文方法对前景区域进行优先修复,但该修复顺序并不一定最优;在复杂场景下,仅依赖缺失的语义图来预测完整的语义图是具有挑战性的,因为不准确的先验信息可能会降

低后续图像修复的质量。

本文提出的图像修复框架在解决前景背景特征差异和语义混乱问题方面取得了良好的效果。此外,该框架可以很容易地扩展到其他图像任务如图像编辑等,为后续的图像修复研究提供了有价值的参考。

参考文献(References)

Barnes C, Shechtman E, Finkelstein A and Goldman D B. 2009. Patch-Match; a randomized correspondence algorithm for structural image editing. *ACM Transactions on Graphics (TOG)*, 28 (3): #24 [DOI: 10.1145/1531326.1531330]

Chen L, Yuan C G, Qin X, Sun W and Zhu X F. 2023. Contrastive structure and texture fusion for image inpainting. *Neurocomputing*, 536: 1-12 [DOI: 10.1016/j.neucom.2023.03.014]

Ding D, Ram S and Rodriguez J J. 2018. Perceptually aware image inpainting. *Pattern Recognition*, 83: 174-184 [DOI: 10.1016/j.pat-cog.2018.05.025]

Goodfellow I J, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, Courville A and Bengio Y. 2014. Generative adversarial nets//*Proceedings of the 27th International Conference on Neural Information Processing Systems*. Montreal, Canada: ACM: 2672-2680

Guo X F, Yang H Y and Huang D. 2021. Image inpainting via conditional texture and structure dual generation//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*. Montreal, Canada. IEEE: 14114-14123 [DOI: 10.1109/ICCV48922.2021.01387]

Isola P, Zhu J Y, Zhou T H and Efros A A. 2017. Image-to-image translation with conditional adversarial networks//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*.

- Honolulu, USA: IEEE: 5967-5976 [DOI: 10.1109/CVPR.2017.632]
- Johnson J, Alahi A and Li F F. 2016. Perceptual losses for real-time style transfer and super-resolution//Proceedings of the 14th European Conference on Computer Vision. Amsterdam, the Netherlands: Springer: 694-711 [DOI: 10.1007/978-3-319-46475-6_43]
- Li J Y, Wang N, Zhang L F, Du B and Tao D C. 2020. Recurrent feature reasoning for image inpainting//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 7757-7765 [DOI: 10.1109/CVPR42600.2020.00778]
- Liao L, Xiao J, Wang Z, Lin C W and Satoh S I. 2020. Guidance and evaluation: semantic-aware image inpainting for mixed scenes//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 683-700 [DOI: 10.1007/978-3-030-58583-9_41]
- Liao L, Xiao J, Wang Z, Lin C W and Satoh S I. 2021. Image inpainting guided by coherence priors of semantics and textures//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 6535-6544 [DOI: 10.1109/CVPR46437.2021.00647]
- Liu G L, Reda F A, Shih K J, Wang T C, Tao A and Catanzaro B. 2018. Image inpainting for irregular holes using partial convolutions//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer: 89-105 [DOI: 10.1007/978-3-030-01252-6_6]
- Liu W R, Mi Y C, Yang F, Zhang Y, Guo H L and Liu Z M. 2022. Generative image inpainting with multi-stage decoding network. *Acta Electronica Sinica*, 50(3): 625-636 (刘微容, 米彦春, 杨帆, 张彦, 郭宏林, 刘仲民. 2022. 基于多级解码网络的图像修复. *电子学报*, 50(3): 625-636) [DOI: 10.12263/DZXB.20201451]
- Luo W Y, Yang S, Zhang X J and Zhang W S. 2023. SIEDOB: semantic image editing by disentangling object and background//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 1868-1878 [DOI: 10.1109/CVPR52729.2023.00186]
- Pathak D, Krahenbühl P, Donahue J, Darrell T and Efros A A. 2016. Context encoders: feature learning by inpainting//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 2536-2544. [DOI: 10.1109/CVPR.2016.278]
- Quan W Z, Zhang R S, Zhang Y, Li Z F, Wang J and Yan D M. 2022. Image inpainting with local and global refinement. *IEEE Transactions on Image Processing*, 31: 2405-2420 [DOI: 10.1109/TIP.2022.3152624]
- Shen J H, Kang S H and Chan T F. 2003. Euler's Elastica and curvature-based inpainting. *SIAM Journal on Applied Mathematics*, 63(2): 564-592 [DOI: 10.1137/s0036139901390088]
- Wang Q N and Chen Y. 2022. Enhanced semantic dual decoder generation model for image inpainting. *Journal of Image and Graphics*, 27(10): 2994-3009 (王倩娜, 陈隼. 2022. 面向图像修复的增强语义双解码器生成模型. *中国图象图形学报*, 27(10): 2994-3009) [DOI: 10.11834/jig.210301]
- Wang T F, Ouyang H and Chen Q F. 2021. Image inpainting with external-internal learning and monochromic bottleneck//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 5116-5125 [DOI: 10.1109/CVPR46437.2021.00508]
- Wang Z, Bovik A C, Sheikh H R and Simoncelli E P. 2004. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4): 600-612 [DOI: 10.1109/TIP.2003.819861]
- Xiang H Y, Zou Q, Nawaz M A, Huang X F, Zhang F and Yu H K. 2023. Deep learning for image inpainting: a survey. *Pattern Recognition*, 134: #109046 [DOI: 10.1016/j.patcog.2022.109046]
- Xiong W, Yu J H, Lin Z, Yang J M, Lu X, Barnes C and Luo J B. 2019. Foreground-aware image inpainting//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 5833-5841 [DOI: 10.1109/CVPR.2019.00599]
- Yang H J, Li L Q and Wang D. 2022. Deep learning image inpainting combining semantic segmentation reconstruction and edge reconstruction. *Journal of Image and Graphics*, 27(12): 3553-3565 (杨红菊, 李丽琴, 王鼎. 2022. 联合语义分割与边缘重建的深度学习图像修复. *中国图象图形学报*, 27(12): 3553-3565) [DOI: 10.11834/jig.210702]
- Ye X Y, Zeng M S, Sun W J, Wang L Y and Zhao Z J. 2023. Image inpainting based on multi-scale stable-field GAN. *SCIENTIA SINICA Informationis*, 53(4): 682-698 (叶学义, 曾懋胜, 孙伟杰, 王凌宇, 赵知劲. 2023. 多尺度稳定场GAN的图像修复模型. *中国科学: 信息科学*, 53(4): 682-698) [DOI: 10.1360/SSI-2022-0065]
- Yu J H, Lin Z, Yang J M, Shen X H, Lu X and Huang T. 2019. Free-form image inpainting with gated convolution//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 4470-4479 [DOI: 10.1109/ICCV.2019.00457]
- Yu T, Guo Z Y, Jin X, Wu S L, Chen Z B, Li W P, Zhang Z Z and Liu S. 2020. Region normalization for image inpainting//Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York, USA: AAAI: 12733-12740 [DOI: 10.1609/aaai.v34i07.6967]
- Yu W B, Du J H, Liu R X, Li Y X and Zhu Y S. 2022a. Interactive image inpainting using semantic guidance//Proceedings of 26th International Conference on Pattern Recognition. Montreal, Canada: IEEE: 168-174 [DOI: 10.1109/ICPR56361.2022.9956171]
- Yu Y S, Du D W, Zhang L B and Luo T J. 2022b. Unbiased multi-modality guidance for image inpainting//Proceedings of 17th Euro-

pean Conference on Computer Vision. Tel Aviv, Israel: Springer: 668-684 [DOI: 10.1007/978-3-031-19787-1_38]

Zhang R, Isola P, Efros A A, Shechtman E and Wang O. 2018. The unreasonable effectiveness of deep features as a perceptual metric// Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 586-595 [DOI: 10.1109/cvpr.2018.00068]

Zhang R S, Quan W Z, Zhang Y, Wang J and Yan D M. 2023. W-net: Structure and texture interaction for image inpainting. IEEE Transactions on Multimedia, 25: 7299-7310 [DOI: 10.1109/TMM.2022.3219728]

Zhang Y L, Liu Y M, Hu R T, Wu Q and Zhang J. 2024. Mutual dual-task generator with adaptive attention fusion for image inpainting. IEEE Transactions on Multimedia, 26: 1539-1550 [DOI: 10.1109/

TMM.2023.3282892]

作者简介

叶学义,男,副教授,硕士生导师,主要研究方向为模式识别和信息安全。E-mail: xueyiye@hdu.edu.cn

睢明聪,男,硕士研究生,主要研究方向为数字图像修复。E-mail: smc13777849137@163.com

薛智权,男,硕士研究生,主要研究方向为图像处理。E-mail: 879764330@qq.com

王佳欣,女,硕士研究生,主要研究方向为目标检测。E-mail: wjx15168134014@163.com

陈华华,男,副教授,硕士生导师,主要研究方向为图像处理。E-mail: iseealv@hdu.edu.cn