

基于全局局部特征融合的FPC图像修复模型

孙海森¹, 李德健²

¹沈阳工业大学信息科学与工程学院, 中国辽宁省沈阳市

²沈阳工业大学信息科学与工程学院, 中国辽宁省沈阳市

发布日期: 2025年3月25日

摘要

针对柔性印制线路板 (Flexible Printed Circuits, FPCs) 因制作工艺问题而造成的线路缺损, 提出一种基于全局局部特征融合的FPC缺损图像修复模型。该模型以上下文编码器网络 (Context Encoder, CE) 为框架, 参照FPC缺损区域周围的上下文信息, 完成了对其缺损区域范围内的基础修复; 接着, 通过对缺损部分的局部信息修复细节差做了分析, 进而得出了扩大感受野的结论, 采用空洞卷积代替原有的普通卷积, 提高局部信息的提取能力; 后对整张FPC图像进行了全局特征的提取, 分析FPC图像更符合稀疏性的先验信息结构, 将该信息结构融入到全局特征的提取过程中, 增强全局信息的一致性和连贯性。如此将所提取的局部信息和全局信息融合, 共同指导修复结果更高效。最后, 我们分别用现有流行方法与本文方法进行了定性和定量的实验, 从多方面证明本文方法对大尺度缺损修复的有效性, 满足实际工业场景对FPC图像缺损进行修复的要求。

关键词

柔性印制线路板; 全局局部特征融合; 缺损修复; 图像补全

Image of FPC Defect Model Based on Global and Local Feature Fusion

Haisen Sun¹, Dejian Li²

¹School of Information Science and Engineering, Shenyang University of Technology, Shenyang, Liaoning Province, China

²School of Information Science and Engineering, Shenyang University of Technology, Shenyang, Liaoning Province, China

Abstract

Aiming at the circuit defects caused by the manufacturing process problems of Flexible Printed Circuits (FPCs), a FPC defect image repair model based on global and local feature fusion is proposed. The model uses the Context Encoder (CE) as the framework, and completes the basic repair within the defect area of the FPC by referring to the context information around the defect

area of the FPC; then, by analyzing the local information repair details of the defective part, the conclusion is drawn that the receptive field is expanded, and the dilated convolution is used instead of the original ordinary convolution to improve the ability to extract local information. Then, we extracted global features from the entire FPC image, analyzed the prior information structure of the FPC image that is more consistent with sparsity, and integrated this information structure into the global feature extraction process to enhance the consistency and coherence of global information. In this way, the extracted local information and global information are fused to jointly guide the repair results to be more efficient. Finally, we conducted qualitative and quantitative experiments using existing popular methods and the method in this paper, respectively, and proved the effectiveness of the method in this chapter for large-scale defect repair from many aspects, meeting the requirements of repairing FPC image defects in actual industrial scenarios.

Keywords

Flexible Printed Circuits; Global And Local Feature Fusion; Defect Repair; Image Completion

Copyright © 2025 by author(s) and Erytis Publishing Limited.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



1. 引言

柔性印制线路板, 简称 FPC, 因其柔软特性在电子产品的市场中占据了主导地位[1], 线路大多数通过银浆印制, 制作成本较高, 常因其制作工艺造成大范围的线路缺损, 直接废弃还会造成环境污染。目前国内针对 FPC 的修复还停留在人工补画阶段, 成本高, 效率低, 已无法满足市场需求, 自动化而精准的修复方法是亟需待开发的。目前, 解决该问题的修复方法按照修复原理主要分为传统方法和深度学习方法。在传统方法方面, Bert 等人[2]将图像的已知信息沿光线方向平滑传播于缺失区域, 以自动修复图像。Chan 等人[3]提出引入整体变分模型到图像修复任务中, 解决了修复只能沿直线方向修复的局限性。Efros 等人[4]提出将已知区域相似度最高的样本复制到破损区域, 增强了补全图像的纹理细节。Wei 等人[5]采用了多层金字塔结构做映射, 减少了计算的时间。传统算法的原理是根据图像样本的相似度, 通过数学和物理的手段修复小区域的破损图像, 但是由于样本构造具有不确定性, 在面对大面积缺失数据时, 普遍存在修复效果混乱不佳, 且算法迭代次数多较为复杂导致模型运行速度过慢; 随着深度学习技术的发展, 基于深度学习的图像修复算法也应运而生。在深度学习方法方面, Goodfellow 等人[6]提出的一种利用零和博弈思想预测生成模型的网络框架, 相较于传统算法摆脱了只能修复图像样本相似度高的限制。Yan 等人[7]提出在图像分割领域的深度网络结构中转移图像背景区域的特征信息, 将修复注意区域仅集中在图像的破损区域。深度学习方法方法虽然可以更好的分析图像数据从而修复破损区域, 但是针对 FPC 这种实际工业场景的应用中, 仍存在细节处理不准确, 补全图像边缘不连贯的缺点, 无法更好的适用于实际工业场景中的图像修复工作, 不满足工业场景中准确检测修复的需求。基于此, 在参考图像补全的方法基础上, 将其应用到工业实际场景中, 为了满足实际工业场景中 FPC 缺陷修复的需求, 提出了一种基于全局局部特征融合的 FPC 缺损图像修复模型。

2. 上下文编码器工作原理

2.1. 编码器及译码器工作原理

编码器（encoder）的主要功能是接收代表输入图片的高维序列，并将其转换压缩为固定的低维向量表示，这个向量捕获了输入图片中的关键信息，以便于后续的解码器进行处理。编码器的内部主要由 5 个负责下采样的卷积层构成，通过下采样卷积，逐层压缩数据，学习到一个潜在且紧凑的向量表示，在这个过程中只保留了最重要的图片特征。整体结构图如下图 1 所示。




Figure 1. Encoder structure diagram

图 1. 编码器结构图

解码器（decoder）的主要功能是接收潜在紧凑的向量表示，并开始尝试将这个低维的潜在向量重构为原始输入，如果在理想状态下，重构的质量高，那么就代表这个向量涵盖了原始输入图像中的关键信息。解码器的内部主要由 5 个负责上采样的转置卷积层来构成，通过上采样卷积，逐层扩展数据，重构成一个涵盖输入图像全部重要信息的全新图像，以达到修复图像的目的，整体结构如图 2 所示。




Figure 2. Decoder structure diagram

图 2. 解码器结构图

由这种编码器和解码器（encoder-decoder）构成的上下文编码器网络，可以有效的学习图像中的已知内容信息，生成出来的内容通常与原始图像更为相似，相较于其它深度学习方法，例如 U-Net 类，GAN 类，Transformer 类的修复方法来说，其整体结构更为简单，且由于其编码和解码结构可以更好的把握原始图像的信息，通常在修复任务中展现出了更为优秀的结果。

2.2. 全通道连接层工作原理

全通道连接层存在的意义是将编码器压缩的低维向量进行激活连接，以便于其后续输入进解码器中进行数据扩展，起到了一个桥梁连接的作用。由于编码器最后输出的是一个没有激活连接的一维向量，

这样的信息不能传递到解码器，这就需要有一个桥梁来将编码器输出的一维向量激活连接成解码器所能接收的信息。目前的一般架构中，向量之间的激活连接是靠全连接层来处理的，所有激活都需要直接互联，这种结构由于参数量巨大，会导致参数爆炸。所以为了减少网络的输入参数，全通道连接层被广泛应用，其核心在于稀疏输入和输出之间的连接，每个输入仅与输出的部分相连，在保证信息流完整度的同时，还减少了运行中的参数量。下图 3 所示全连接层和全通道连接层连接数据的结构对比图。




Figure 3. A comparison of the structure of the connected data
图 3. 连接数据的结构对比图

如图 3 所示，2 通道 2×2 的特征图展开成的神经元个数为 $2 \times 2 \times 2 = 8$ 个。如果使用全连接层，与每个神经元匹配的权重参数也为 8 个，这样计算则需要 $8 \times 8 = 64$ 个参数；如果使用全通道连接层，仅需要用 $2 \times 2 = 4$ 个参数的滑动向量分 2 个通道分别滑动连接每个神经元进行匹配，这样计算只需要 $8 \times 4 = 32$ 个参数，大大减少了参数的计算量。

3. 基于全局局部特征融合的 FPC 缺损图像修复模型

3.1. 整体架构

整个基于全局局部特征融合的大尺度缺损修复方法的网络结构如下图 4 所示。主体依旧采用 CE 为基本的网络架构，生成器采用上下文编码器构成，输入带有破损掩膜的图像，在进行全局修复的过程中，采用稀疏性的先验信息指导修复生成基本的预测图，提高图像全局的连贯性和网络的修复效率。接着，在判别网络阶段，分别采用两个判别器对整体生成图像质量进行判别，分别是全局判别器网络和局部判别器网络。具体而言，全局判别器网络将整幅图像作为输入，而局部判别器网络仅将已完成区域周围的一小块区域作为输入，且在局部判别器网络中采用空洞卷积扩大局部信息的感受野，更好的提取局部图像的特征信息。后将提取到的局部信息和全局信息进行向量的有效融合，指导修复破损的 FPC 图像。




Figure 4. Network structure diagram of large-scale defect repair method based on global local feature fusion
图 4. 基于全局局部特征融合的大尺度缺损修复方法的网络结构图

3.2. 基于先验的全局特征

为了使得大尺度破损 FPC 修复后的图像在视觉上保持一致性与自然性, 网络必须依赖于图像中已有的结构、纹理、颜色和语义等先验信息, 以合理地推测缺失区域的内容。图像先验能够帮助修复模型在不完整的信息基础上做出智能的推断, 从而获得更加真实和自然的修复效果。图像先验 (Image Prior) 在图像修复技术中扮演着至关重要的角色, 它是指基于图像统计特性或高层语义信息所建立的模型或假设, 用以指导缺失区域的填充过程。图像先验通常可以分为两类: 低级先验和高级先验。低级先验主要关注图像的基本统计特征, 如边缘、纹理、色彩分布等, 而高级先验则更多地关注图像的语义结构和全局一致性。在图像修复中, 低级先验有助于修复小范围的局部损坏区域, 通过推测缺失区域的纹理、边缘和颜色信息, 使得修复后的图像更加平滑、无缝; 而高级先验则能够帮助修复大范围缺失的区域, 确保图像的整体结构、物体语义和语境信息保持一致, 避免修复过程中的错位或不协调现象。

借助于不同的先验信息可以估计出不同的图像, 常用的图像先验信息有自然图像的局部平滑性、非局部自相似性、稀疏性等特征。在我们对 FPC 大尺度破损图像进行观察之后, 我们发现其图像属于稀疏性的变化特征。稀疏性本身是指矩阵或向量中非零元素个数很少。对于自然图像来说, 就是其可以用少量的几个独立成份来表示。即图像可以通过某些线性变化变成稀疏信号。图像的稀疏性是图像可以用压缩感知方法进行恢复的先决条件。压缩感知进行图像恢复的过程如下图 5 所示, 图像经过线性基变换可以变成稀疏向量。




Figure 5. The process of compressive sensing for image restoration**图 5.** 压缩感知进行图像恢复的过程

上文确定了采用图像的稀疏性信息进行图像的先验操作，后续我们针对最常用的先验模型 L_1 、 L_2 展开描述和来源推导。

在最大似然估计中，是假设权重 w 是未知的参数，从而求得对数似然函数（取了 $\log$ ）：

$$l(w) = \log[P(y|X; w)] = \log[\prod_i P(y^i|x^i; w)] \quad (1)$$

从上式子可以看出：假设 y^i 的不同概率分布，就可以得到不同的模型。若我们假设 $y^i \sim N(w^T x^i, \sigma^2)$ 的高斯分布，我们就可以带入下式高斯分布的概率密度函数：

$$l(w) = \log[\prod_i \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(y^i - w^T x^i)^2}{2\sigma^2}}] = -\frac{1}{2\sigma^2} \sum_i (y^i - w^T x^i)^2 + C \quad (2)$$

上面的 C 为常数项，常数项和系数不影响我们求解 $\max(l(w))$ 的解，于是便得到了代价函数。在最大化后验概率的估计中，我们将权重 w 看作随机变量，也具有某种分布，从而有：

$$P(w|X, y) = \frac{P(w, X, y)}{P(X, y)} = \frac{P(X, y|w)P(w)}{P(X, y)} \propto P(y|X, w)P(w) \quad (3)$$

总的来说，图像先验在图像修复中的实用性和意义不仅体现在其提升修复质量和效率的能力上，还在于其增强了修复模型的鲁棒性，使其在面对复杂情况和稀缺数据时仍然能够提供高质量的修复结果。通过融合低级和高级的图像先验，图像修复技术能够在保证精度的同时，更好地适应各种实际应用场景，推动图像修复技术在更广泛领域的应用与发展。

3.3. 基于感知的局部特征

FPC 大尺度破损修复的核心目标是填补图像中的缺失区域，这不仅需要精确的局部信息，还要求网络能够理解和恢复缺失部分与周围区域的整体结构和语义一致性，而感受野（Receptive Field）在图像修复技术中起着至关重要的作用，它决定了网络在处理每个像素时能够“看到”多大范围的上下文信息。因此，合适的感受野设计对修复效果至关重要。

在传统的卷积神经网络（CNN）中，感受野是指网络中某一层的每个神经元所能接收到的输入图像区域的大小。随着网络层数的增加，感受野逐渐扩大，使得网络能够捕捉到更大范围的图像特征。然而，在图像修复任务中，感受野的设计需要特别关注，因为修复任务不仅依赖于局部像素的上下文，还需要理解图像的全局结构。一个过小的感受野可能无法有效地恢复大范围缺失区域的结构信息，导致修复效果不自然，甚至出现拼接痕迹；而感受野过大的网络可能会忽视局部细节，导致图像失真或细节缺失。因此，合理的感受野设计能够帮助网络在图像修复过程中更好地整合局部与全局信息，实现精细化修复。近年来，很多研究采用了多尺度网络架构，通过逐步扩大感受野的方式，结合局部细节和全局语义，从而提升修复质量。此外，感受野的优化不仅体现在网络结构的设计上，还包括对特征提取和注意力机制的进一步强化，使得网络能够更智能地选择和利用图像中最相关的区域信息。总之，感受野在图像修复技术中扮演着至关重要的角色，直接影响修复结果的质量和自然度。通过合理的感受野设计，网络能够更好地恢复缺失区域与周围内容的连贯性与一致性，从而提升图像修复的效果。下图 6 为感受野感受特征的示意图。




Figure 6. Schematic diagram of sensory characteristics of the sensory field

图 6. 感受野感受特征示意图

为了合理的扩大感受野，我们采用空洞卷积（Dilated Convolution）进行实现，其作为一种有效的手段，开始在网络设计中发挥着越来越重要的作用。空洞卷积通过在卷积核元素之间插入间隔（即空洞），在不增加计算量的情况下扩展了感受野，从而使得网络能够在处理图像时获取更广泛的上下文信息。这一特性使得空洞卷积成为提升图像修复性能的有力工具。在图像修复中，尤其是当缺失区域较大或呈现复杂形态时，空洞卷积能够有效扩展感受野，帮助网络更好地恢复缺失部分与图像整体的结构一致性。例如，在修复大面积的缺失区域时，空洞卷积能够使网络“看到”更多的周围区域信息，从而生成更加连贯、自然的修复结果。同时，空洞卷积能够减少因扩大感受野所带来的计算开销，避免了传统卷积中增加更多层或扩展卷积核尺寸所带来的计算负担。

此外，空洞卷积还能够通过引入多个不同膨胀率（dilation rate）来构建多尺度的感受野，使得网络在不同尺度上都能够捕捉到关键的上下文信息。这对于处理包含细节和大范围结构的图像修复任务尤为重要，因为它能帮助网络在不同层次上同时理解图像的细节和全局关系，进而提升修复效果的精细度和自然度。下图 7 所示为空洞卷积原理图。




Figure 7. Schematic diagram of a dilated convolution

图 7. 空洞卷积原理图

总的来说，空洞卷积的重要意义在于它能够与其他高级特性（如注意力机制、残差连接等）结合，进一步提高修复模型的效果。通过精细控制感受野的扩展方式，空洞卷积不仅能够帮助网络更加高效地捕捉图像中的关键信息，还能在多层次、多尺度的特征融合中发挥作用，增强模型的表达能力和修复精度。空洞卷积在图像修复中的实用性和意义主要体现在其通过扩展感受野而不增加计算量，能够帮助

网络捕捉到更广泛的上下文信息, 提高修复质量和效率。特别是在处理大范围缺失或复杂纹理修复时, 空洞卷积的引入为模型提供了更强的上下文感知能力, 进而提升了图像修复技术的效果。

4. 实验结果与分析

通过由我们自己拍摄的 1000 张 4975×4975 的 FPC 键盘裸板图像按不同尺寸切割成共 20000 张有缺陷的图片来验证模型的泛化性能。为了增加数据的丰富性和模拟实际工业场景的真实性, 取正弦函数作随机曲率, 将数据集中的 20000 张图片像素进行了随机弯折。且该数据集图片收集了大量不规则的断口缺陷, 它们大小不一, 位置遍布直线区域、线路转折或交叉处等“复杂”结构处, 且来自原图像的 1000 张图片灰度光照条件不同, 部分图像的线路背景区域包含杂质噪声点, 所切割的图像不仅仅包含一处断口缺陷, 存在实际工业场景中由于丝网破损而造成的大幅面多线路断口缺陷, 满足实际工业场景中的工作环境, 对验证模型的修复能力有较高的置信度, 将数据集命名为 FPC-DET。同样地, 将处理过后的数据集, 按照 9:1 的比例随机划分为训练集验证集, 即训练集包含 18000 张图像, 验证集包含 2000 张图像。

实验环境基于 Windows10 操作系统, 实验设备为 NVIDIA GeForce RTX 3060 GPU, 缺陷检测模块由 opencv-python 完成, 深度学习框架为 Pytorch 2.1.0, CUDA 版本为 12.1, 使用 python3.10 语言进行编程。具体的训练策略如下表 1 所示。

Table 1. Training parameters
表 1. 训练参数

Parameter	FPC-DET
Epochs	5000
Batch_size	64
workers	8
input_size	256*256
lr	0.0002
optimizer	Adam

由于图像修复任务没有固定的指标来评判修复效果的好坏, 只能通过人眼来判别修复效果的好坏, 所以我们需要对 FPC 大尺度缺损修复任务的结果进行主观的评估, 对修复效果进行一个定性的分析。设计从主观视觉角度对本文提出的基于全局局部特征融合的大尺度缺损修复方法在我们自行制作的 FPC 数据集 FPC-DET 数据集上进行实验, 并选用不同尺寸的大型矩形掩膜, 所占图像的比例分别在 0.2-0.3、0.3-0.4 之间, 将掩膜与 FPC 数据集 FPC-DET 结合, 生成各不相同的大尺度 FPC 破损图像, 最后将本文方法与流行的 CE 网络、Edge Connect 网络进行效果的对比, 通过三种方法的对比查看本文方法对大尺度 FPC 破损的修复效果。

具体修复效果如下图 8 所示, 当破损矩形掩膜区域占 FPC 图像的比例在 0.2-0.3 之间时, 三种方法没有明显的差别, 总之满足正常人眼的评判标准。而当破损矩形掩膜区域占 FPC 图像的比例在 0.3-0.4 之间时, 如图 9 所示, 伴随着破损区域面积的扩大, 三种方法则有较大的差别, 本文方法的优势也愈发显现出来。CE 网络模型在 FPC-DET 上明显出现了线路结构失真, 背景与线路混杂的问题, Edge Connect 网络模型在 CE 网络的基础上, 分两阶段进行修复, 先模拟修复破损图像的边缘, 再根据边缘指导修复具体的纹理和图像色块, 虽然较 CE 网络模型有了一定的提高, 但是线路的修复效果仍不稳定, 仍有线路像素缺失, 模糊混杂和线路与背景分割不自然的问题。而本文基于全局局部特征融合的大尺度缺损修复

方法可以达到一个很好的修复效果, 在线路细节修复质量和线路与背景分割效果上有很好的表现。





Figure 8. The proportion of the damaged rectangular mask area to the FPC image is between 0.2-0.3

图 8. 破损矩形掩膜区域占 FPC 图像的比例在 0.2-0.3 之间






Figure 9. The proportion of the damaged rectangular mask area to the FPC image is between 0.3-0.4

图 9. 破损矩形掩膜区域占 FPC 图像的比例在 0.3-0.4 之间

为了进一步验证本文方法的有效性,使用常用来评判图像质量的峰值信噪比 (PSNR) 和结构相似度 (SSIM) 以及错误补全概率 (ECP) 和平均绝对值误差 (MAE) 四种图像修复效果评价指标来对本文所提出的方法进行定量的分析。分别将 CE 网络、Edge Connect 网络和本文所提出的基于全局局部特征融合的大尺度缺损修复网络在 FPC-DET 数据集上进行修复结果的对比,同样选用不同尺寸的大型矩形掩膜,所占图像的比例分别在 0.2-0.3、0.3-0.4 之间,将掩膜与 FPC 数据集 FPC-DET 结合,生成各不相同的大尺度 FPC 破损图像,分别计算上文提出的四种图像修复效果评价指标,对比修复性能的差异,如下表 2 所示。

Table 2. Quantitative comparison of different models with different mask ratios on FPC-DET

表 2. 不同模型在 FPC-DET 上不同掩码率的定量对比

评价指标	模型	掩码率	
		0.2-0.3	0.3-0.4
PSNR (db)	CE	26.55	23.33
	Edge Connect	27.83	24.12
	Ours	27.94	27.15
SSIM	CE	0.78	0.42
	Edge Connect	0.81	0.69
	Ours	0.83	0.81
ECP	CE	0.09	0.25
	Edge Connect	0.09	0.23
	Ours	0.08	0.09
MAE	CE	0.09	0.24
	Edge Connect	0.08	0.21
	Ours	0.07	0.09

综上所述,从定量分析的角度来看,本文提出的基于全局局部特征融合的大尺度破损修复方法,相较于 CE 网络和 Edge Connect 网络,在修复质量、计算效率和鲁棒性等方面展现出明显的优势,尤其是在 FPC 大尺度破损的修复中,我们提供 2 个通道的鉴别器,分别是基于先验的全局特征判别和基于感知的局部特征判别,全局特征采用稀疏性的特征先验,对整体生成图像质量有一个提前的把握和指导,对局部特征采用扩大感受野的手段增加局部特征信息,最后将全局和局部特征融合,共同指导生成器生成破损区域的图像,克服了当 FPC 图像发生大尺度缺损时,图像结构失真、细节丢失和模糊混杂的问题,

能够提供更加自然、精准和高效的解决方案。这些优势使得本方法在实际应用中具备了更高的实用价值和可行性。

5. 结束语

针对柔性印制线路板缺损修复领域的难题,设计了一种基于上下文编码器的 FPC 缺损图像修复模型,在 20000 张 FPC 缺损图像中进行了有效性的验证,有着较好的修复效果,满足工业场景的需求。在实际的工业场景中,现有方法一般会导致 FPC 图像修复后出现结构失真、细节丢失和模糊混杂的问题,造成整体低效的修复水平。对此,本文提出的基于全局局部特征融合的大尺度缺损修复方法有效的解决了以上问题,分别设计提取了基于稀疏先验性指导的全局特征和基于空洞卷积的局部特征,组成两个判别器网络,并在最后融合两者的特征,共同指导修复结果。最后经实验证明,本文方法在面对破损程度接近于图像一半时,依然能够有良好的表现,相对于现有流行方法,展现出独有的优势。

参考文献

- [1] 张宜生, 彭毅, 梁书云. 基于图像比对技术的柔性印刷电路板检测系统[J]. 计算机工程与应用, 2005(2): 220-222.
- [2] BERTALMÍO M, SAPIRO G, CASELLES V. Image inpainting[C]//Proceedings of the ACM SIGGRAPH Conference on Computer Graphics. 2000: 417-424.
- [3] SHEN J, CHAN T. Mathematical Models for Local Nontexture Inpaintings[J]. SIAM Journal on Applied Mathematics, 2002, 62: 1019-1043.
- [4] EFROS A A, LEUNG T K. Texture synthesis by non-parametric sampling[C/OL]//Proceedings of the Seventh IEEE International Conference on Computer Vision. Kerkira, Greece: IEEE, 1999: 1033-1038.
- [5] WEI L Y, LEVOY M. Fast texture synthesis using tree-structured vector quantization[C/OL]//Proceedings of the 27th annual conference on Computer graphics and interactive techniques. USA: ACM Press/Addison-Wesley Publishing Co., 2000: 479-488[2024-07-30].
- [6] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M. Generative Adversarial Networks[EB/OL]. arXiv, 2014[2024-07-14].
- [7] YAN Z, LI X, LI M. Shift-net: Image inpainting via deep feature rearrangement[C/OL]//Proceedings of the European conference on computer vision (ECCV). 2018: 1-17[2024-07-31].