

基于 DIL 的遥感影像修复方法

蒋雨佳¹ 李杭琪¹ 孙宝丹^{1,2} 张心一¹ 江俊慧^{1,2} 巩建光^{1,2}

1 哈尔滨工程大学计算机科学与技术学院 哈尔滨 150001

2 智慧农场技术与系统全国重点实验室 哈尔滨 150001

(jiangyujia@hrbeu.edu.cn)

摘要 目前,遥感影像已广泛应用于环境监测、灾害管理等领域。但在影像采集过程中,传感器故障或外部环境等因素会导致遥感影像质量下降,进而影响其应用效果。DIL(Distortion Invariant representation Learning)算法通过对不同的失真程度与失真类型进行建模并利用因果关系中的“后门”准则推导出因果网络进行图像修复,具有较强的泛化能力。因此,将 DIL 算法应用于遥感影像修复领域,旨在充分利用已采集到的遥感影像数据,提高遥感影像的修复质量,更好地在环境监测、灾害管理等领域应用。此外,还在 DIL 算法的基础上对训练数据进行了归一化处理操作,以保证训练数据的变量唯一,使其能更好地处理遥感影像的修复问题。在实验部分,使用 DIL 算法对遥感影像分别进行了去噪、去雨、去模糊,实验结果表明 DIL 算法在遥感影像修复方面的效果要优于 Noise2Noise、FFDNet、DnCNN、Restormer 算法,显著提升了图像修复质量。

关键词: DIL 算法; 归一化处理; 因果关系; 遥感图像修复

中图分类号 TP181

Remote Sensing Image Restoration Based on DIL

JIANG Yujia¹, LI Hangqi¹, SUN Baodan^{1,2}, ZHANG Xinyi¹, JIANG Junhui^{1,2} and GONG Jianguang^{1,2}

1 College of Computer Science and Technology, Harbin Engineering University, Harbin 150001, China

2 National Key Laboratory of Smart Farm Technologies and Systems, Harbin 150001, China

Abstract Currently, remote sensing images are widely used in environmental monitoring, disaster management and other fields. However, sensor failure or external environment results in the degradation of image quality in image acquisition influencing the application of remote sensing images. The DIL algorithm models different distortion degrees and distortion types, and uses the “backdoor” criterion in causal inference to derive the causal network for image restoration with fairly strong generalization ability. Therefore, this paper applies the DIL algorithm to remote sensing image restoration to use the collected remote sensing image data improving the restoration quality of remote sensing images. In this way, this paper uses DIL algorithm to improve the application of remote sensing images in environmental monitoring, disaster management and other fields. In this paper, the training data is normalized on the basis of the DIL algorithm to ensure that the variables of the training data are unique, so that they can better deal with the repair problems of remote sensing images. In the experiments, the DIL algorithm is used to denoise, rain and deblur the remote sensing images. The experimental results show that the DIL algorithm is better than the Noise2Noise, FFDNet, DnCNN and Restormer algorithms in remote sensing image restoration, and the image restoration quality is significantly improved.

Keywords Distortion invariant representation learning algorithm, Normalization, Causality, Remote sensing image restoration

1 引言

遥感影像作为地表监测与分析的重要资料来源,其质量直接影响到地理信息系统、气候变化监测、自然资源管理等多个领域的决策和研究质量^[1]。由于传感器故障和外部环境等因素,遥感影像在采集过程中常会受到噪声污染,或因云层、雨水等干扰影响其质量,显著降低了影像的可用性。因此,遥感图像修复就成为了遥感数据处理中的重要任务。当前,使用传统和深度学习方法进行图像修复已经取得了一定进展,这些方法大致可以分为基于插值^[2]、偏微分方程^[3]、稀疏

表示^[4]等传统方法和基于自编码器^[5]、生成对抗网络(GAN)^[6]、Transformer^[7]等深度学习方法。但是,它们在遥感影像修复方面仍然存在修复后图像细节丢失、修复模型的训练效率较低、泛化能力不足等问题。因此,深入研究遥感图像修复方法,改善遥感图像修复结果具有重要意义。

DIL^[8]算法将不同程度、不同类型的失真作为混杂因素模拟对修复网络的干预,并从元学习的角度消除失真带来的混杂因素,从而在图像修复上实例化了因果关系^[9-10]。其在 RGB 图像修复方面取得了较好的结果,但对于遥感图像修复仍然存在修复效果不佳等问题。因此,本文在数据预处理过

基金项目:黑龙江省重点研发计划(2022ZX01A23)

This work was supported by the Key R&D Program of Heilongjiang Province(2022ZX01A23).

通信作者:孙宝丹(sunbaodan@hrbeu.edu.cn)

程中,考虑到遥感影像分辨率大且本身存在不同程度的失真,对影像进行了归一化^[11]处理,以消除高质量遥感影像间的原始失真差异。同时,由于遥感影像对硬件的要求极高,因此本文将遥感影像分割成指定大小并将其作为训练数据集以降低模型训练过程对硬件的要求,大大减少了训练时间和成本。本文使用处理后的数据在DIL模型上进行训练,并在实验数据集上验证了DIL算法在遥感图像修复方面的有效性。

由于本文期望模型对于不同类型、不同程度的失真均具有良好的修复能力,但目前暂时无法公开获取大量相关的遥感影像数据,因此本文从公开数据集LANDSAT¹⁾中整理了大量的高质量遥感影像,对其添加混杂因素,从而获得了本文实验使用的失真影像。

本文的主要贡献在于:将较大的遥感图像分割成固定大小的小块并进行归一化处理,得到实验的训练数据集;在实验部分将DIL算法迁移到遥感图像数据集上进行训练和测试,对比实验显示修复效果良好,弥补了DIL算法对于遥感影像修复效果不佳的缺陷;将DIL算法对RGB图像修复泛化能力强的特点迁移到了遥感图像修复领域,使得遥感图像修复网络也具有较好的泛化能力,在去噪、去雨、去模糊上均有较好的修复效果。

2 图像修复研究进展

近年来,针对图像修复领域的研究已经取得了显著进展,本文将阐述近年来图像修复领域的主要研究。

Zhang等^[12]提出了DnCNN算法,该算法基于深度学习框架,利用卷积神经网络(CNN)^[13]来进行图像去噪。该模型通过学习噪声图像与干净图像之间的映射关系,使用残差学习来减少训练复杂性,在高斯噪声去噪上优于BM3D^[14]的性能,然而由于其依赖于在特定噪声条件下训练的清晰图像,在不同场景或不同类型的噪声下的性能有所下降,泛化能力不足且训练时间较长。而后,Zhang等^[15]提出了FFDNet算法,这一算法根据噪声水平进行自适应处理,允许输入噪声标准差来调整去噪强度,具备灵活性和快速性的同时也保持了较好的泛化能力。DnCNN算法和FFDNet算法都是用干净-失真图像对作为训练数据进行训练的,Jaakko等^[16]提出了Noise2Noise算法,这是一种无监督学习的方法,利用成对的噪声图像进行训练,无需干净图像,因此能适应多种噪声模式,泛化能力较好。然而,FFDNet算法和Noise2Noise算法虽然在RGB图像上修复和泛化能力都不错,但是在遥感图像修复上均未呈现出较好的修复效果。Jia等^[17]提出了DCCNet网络结构,它通过双通道结构来提取和融合噪声信息和图像特征,从而提升去噪性能。由于其双通道结构和多尺度特征提取模块,出现了参数量和计算复杂度较大、对硬件资源要求较高的问题。Han等^[18]提出了RSIDNet去噪网络,RSIDNet采用残差学习的方式和多尺度特征提取,可以处理复杂的噪声,训练速度较快。但其同样由于多尺度结构和注意力机制,导致计算开销增大,对硬件要求也较高。尽管其在复杂噪声处理上性能较高,但面对未知的噪声类型和未见的噪声分布时,修复效果仍显著下降,证明了其泛化能力有限。Liu等^[19]提出了DAA-SSID去噪网络,这是一种针对自监督图像去噪的算法,能够在无需干净图像的情况下高效去除

噪声。其采用了双重注意力机制和自适应特征提取模块,使得其能够有效保留边缘和纹理信息,减少了过度平滑现象,适应力也较强,但同时也存在计算复杂度较大、对硬件要求较高、泛化能力有限的问题。

综上所述,目前图像修复领域的研究已逐步完善,但应用在遥感图像修复时仍存在诸多问题。值得一提的是,本文将DIL算法迁移到遥感图像修复中,既保留了高泛化能力,在未见失真程度上也具有较好的修复效果,且训练过程中对于硬件的要求也有所降低。

3 基于DIL的遥感图像修复算法

3.1 图像归一化处理

由于遥感影像的特殊性,其不同影像的噪声程度、亮度、对比度等可能存在较大差异,直接使用原始图像进行训练的效果较差,泛化能力低。因此,本文在训练前先对遥感图像数据集进行了归一化处理,消除训练图像数据之间的差异,以便得到更好的训练效果。

首先对所有的原始图像进行噪声水平 $noise$ 估计,得到:

$$noise = I - GaussianBlur(I) \quad (1)$$

根据式(1)可以计算出噪声标准差 σ_{noise} :

$$\sigma_{noise} = \sqrt{\frac{1}{N} \sum_{i=1}^N (noise_i - \mu_{noise})^2} \quad (2)$$

然后对噪声标准差进行归一化处理。具体如下:

$$I_{normalized} = \frac{I - \mu_I}{\sigma_{noise}} \quad (3)$$

$$I_{clipped} = clip(I_{normalized}, 0, 1) \quad (4)$$

其中, I 为原始图像, $GaussianBlur(I)$ 是对图像 I 进行高斯模糊的结果, σ_{noise} 是噪声的标准差, μ_{noise} 是噪声的均值, N 是像素总数, μ_I 是图像 I 的均值。

归一化前后的图片对比如图1所示。




图1 归一化前后对比

Fig. 1 Comparison before and after normalization

3.2 DIL算法

DIL算法于2023年提出,算法从优化的角度出发,基于因果推断中的“后门”准则^[4],对不同失真的干预进行了建模,又根据失真的不同类型、不同程度更新模型从而实例化不同失真的干预,并从元学习的角度消除干预,从而达到图像修复的效果。DIL通过优化损失函数,使修复后的图像更接近原始图像,从而提升修复质量。算法用结构因果图对这一过程进行建模,如图2所示^[8]。

图2中, I_c, I_D, I_o, D 分别表示原始图像、失真图像、修复图像和失真集。失真集 D 中失真类型表示为 D_i ,失真程度表示为 D_i 。

从图中可以看出, $I_c \leftarrow D \rightarrow I_o$ 的存在使得修复网络 f 学习到的条件概率 $P(I_o | I_c)$ 是以失真 D 为条件的,其不独立于

¹⁾ <https://www.gscloud.cn>

不同的失真,因而不具有鲁棒性。DIL 算法为了得到具有鲁棒性的修复网络,使用因果推断中的“后门”准则遍历已知的失真来消除不同失真对于修复的干扰,提升修复网络的鲁棒性。具体地,DIL 算法采用“后门”准则,通过“do”操作^[4-5]去除混杂因素^[8]。




图2 因果结构图

Fig. 2 Causal structure diagram

$$P(I_o | d_o(I_d)) = \sum_{d_i \in D} P(I_o | I_d, d_i) P(d_i) \quad (5)$$

其中, $P(I_o | d_o(I_d))$ 是恢复网络 f 朝着失真不变学习的优化方向。

由此,DIL 算法就将图像修复问题转化为最大化因果条件概率 $P(I_o | d_o(I_d))$,即最小化其损失函数 $L(f_\theta(I_d), I_c)$,其中 f_θ 为参数为 θ 的修复网络, L 为损失函数。

DIL 算法提出通过训练失真-干净图像对 (I_d, I_c) 优化参数 θ 从而实例化不同类型、不同程度的干扰,进而对不同失真的干预进行建模。

然而,在现实世界中,找到大量相同图像的不同失真图像是困难的,甚至是无法实现的。因此本文通过收集高质量遥感影像并添加不同程度、不同类型的失真从而得到训练需要的数据集。

DIL 算法采用元学习^[20]策略 MAML^[21]实现上述干预的消除。但是在实际训练中,这需要多次梯度计算和更新,计算成本较高,代价昂贵。为了简化这个过程,DIL 算法利用 Talyor 展开式和逆展开式推导出如下方程^[8]:

$$\theta^* = \arg \min_{\theta} E_{(I_d, I_c) \sim D} [L(f_{\theta_{\tilde{d}_i}}(I_d), I_c)] \quad (6)$$

其中, $\theta_{\tilde{d}_i}$ 表示用损失函数虚拟更新的修复网络的参数。

本文采用 DIL 4 种变体中的串行采样^[8]和一阶梯度优化对上述公式进行训练。

4 实验

4.1 实验设置

本文的实验基于 Python3.8, PyTorch2.4.0, cuda12.4, 在显卡 NVIDIA GeForce RTX 4060 上进行训练和测试。使用 Adam 优化器,训练的批量大小 batch_size 为 32,总训练轮数 total_epoch 为 30,初始学习率为 1×10^{-4} ,每经过 20 个 epoch,学习率减半。

4.2 数据集

为了验证算法可行性,本文实验选用了地理空间数据云的 LANDSAT 系列数据。该数据集来自 landsat 卫星的长时间序列的遥感影像,包含可见光、近红外、短波红外等多个光谱波段,同时还具有 30 米的空间分辨率。由于遥感影像大小普遍为 30 MB 左右,训练过程中对于硬件要求太高,因此本文

将原始遥感影像统一切割成 256×256 大小的小块图像作为训练数据集。

4.3 实验结果

4.3.1 遥感影像去噪

本文使用标准差为 $[5, 10, 15, 20]$ 的高斯噪声图像和干净图像作为训练数据对归一化后的图像进行训练,训练完修复网络后,在 $[20, 30, 40, 50]$ 的含已知噪声和未知噪声的测试集上进行验证。

实验部分将本文使用的模型与 Noise2Noise, FFDnet, DnCNN, Restormer^[22] 进行比较。Noise2Noise, FFDnet 以及 DnCNN 算法都是图像修复领域较为经典的算法,Restormer 则是遥感图像修复领域较为经典的算法,均在图像修复领域有着较好的修复效果,因此本文选择这些算法作为对比实验。具体实验结果如表 1 所列。

表1 不同模型对于不同噪声程度的遥感图像的 PSNR 和 SSIM 对比

Table 1 Comparison of PSNR and SSIM of different models for remote sensing images with different noise levels

模型	指标	噪声程度			
		20	30	40	50
DIL	PSNR	47.62	37.84	31.54	27.82
	SSIM	0.97	0.93	0.86	0.76
Noise2Noise	PSNR	35.36	31.89	28.60	25.67
	SSIM	0.69	0.62	0.54	0.46
FFDnet	PSNR	41.13	37.29	33.25	29.98
	SSIM	0.92	0.81	0.62	0.46
DnCNN	PSNR	40.64	39.22	37.98	36.89
	SSIM	0.49	0.47	0.48	0.48
Restormer	PSNR	55.43	44.23	37.09	31.11
	SSIM	0.96	0.95	0.85	0.66

从表中可以看出,对于不同程度的噪声程度,DIL 修复网络对于遥感影像的修复均有较好的修复效果。其中,在已知噪声水平 20 上,DIL 算法的 SSIM 值达到了 0.97,质量较好并且优于其他 3 个算法,在未知噪声水平 $[40, 50]$ 上,DIL 算法的 SSIM 值分别达到了 0.86, 0.76, 也优于其他 3 个算法,证明了基于 DIL 的遥感影像修复方法在遥感影像上的修复能力和泛化能力。本文也将模型与 Noise2Noise, FFDnet, DnCNN, Restormer 修复后的图像进行了对比,结果如图 3 所示,可以看出,对于噪声程度为 50 的未知噪声,本文模型的修复效果也具有较好的效果。

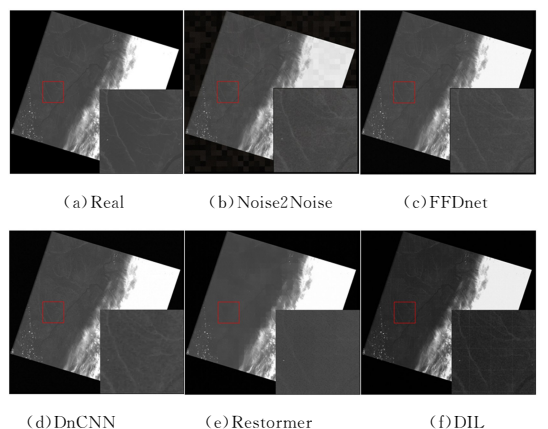


图3 噪声程度为 50 条件下的 DIL 和其他模型的修复图像对比

Fig. 3 Comparison of the restored images of DIL and other models at a noise level of 50

4.3.2 遥感图像去雨、去模糊

为了进一步证明本文模型的实际应用能力,本文也验证了模型对于遥感影像去雨、去模糊的强大修复能力。

对于去雨验证,本文用竖线条模拟雨效果,在实验部分,使用雨强度为 $[5, 10, 15, 20]$ 的遥感影像进行训练,并用雨强度为 $[20, 30, 40, 50]$ 的遥感影像进行测试,结果如表2所列。从表中可以看出,对于已见雨强度20和未见雨强度30, 40, 50, DIL模型的修复指标PSNR值可以分别达到44.60, 42.06, 39.93, 37.76, SSIM值也可以达到0.99, 0.98, 0.96, 0.94, 效果较好。为了进一步证明本文模型去雨的效果,本文对雨强度为30的失真图像及其修复图像进行了对比,如图4所示,可以看出本文模型的修复程度较高。

表2 DIL模型对于不同雨强度遥感影像的修复指标

Table 2 Restoration indexes of DIL model for different rain levels on remote sensing images

指标	雨强度			
	20	30	40	50
PSNR	44.60	42.06	39.93	37.76
SSIM	0.99	0.98	0.96	0.94




图4 雨强度为30条件下的失真图像和修复图像对比

Fig. 4 Comparison of distorted and restored images at 30 rain levels

对于去模糊验证,本文使用模糊程度为 $[1.0, 2.0, 3.0, 4.0]$ 的遥感影像进行训练,并使用模糊强度为 $[4.0, 5.0, 6.0]$ 的遥感影像进行测试,结果如表3所列。从表中可以看出,对于已见模糊程度4.0和未见模糊程度5.0, 6.0, DIL模型的修复指标PSNR值可以分别达到31.08, 30.02, 29.13, 同时SSIM值也可以分别达到0.91, 0.89, 0.88, 修复效果较好。对于模糊失真,本文也对模糊程度为5.0的失真图像和修复图像进行了对比,结果如图5所示,可以看出本文模型的修复程度较高。

表3 DIL模型对于不同模糊程度遥感影像的修复指标

Table 3 Restoration indexes of DIL model for different blur levels on remote sensing images

指标	模糊程度		
	4.0	5.0	6.0
PSNR	31.08	30.02	29.13
SSIM	0.91	0.89	0.88




图5 模糊程度为5.0条件下的失真图像和修复图像对比

Fig. 5 Comparison of distorted and restored images at 5.0 blur levels

4.4 消融实验

为了进一步验证归一化处理对于DIL在遥感影像修复性能上的提高,本文对模型进行了消融实验。本文分别使用未归一化处理和已归一化处理的数据集对DIL模型进行了训练,并使用噪声强度为 $[20, 30, 40, 50]$ 遥感图像进行测试。消融实验结果如表5所列。

表5 归一化前后指标对比

Table 5 Comparison of indicators before and after normalization

模型	指标	噪声强度			
		20	30	40	50
DIL-未归一化处理	PSNR	46.93	37.44	33.14	30.49
	SSIM	0.97	0.88	0.68	0.61
DIL-已归一化处理	PSNR	47.62	37.84	31.54	27.82
	SSIM	0.97	0.93	0.86	0.76

从表中可以看出,对于噪声程度为20和30的遥感影像,使用已归一化处理的数据集进行训练的模型的修复指标PSNR可以分别达到47.62, 37.84;对于噪声程度为30, 40, 50的遥感影像,使用已归一化处理的数据集进行训练的模型的修复指标SSIM可以分别达到0.93, 0.86, 0.76, 优于使用未归一化处理的数据集进行训练的模型。本文也对噪声程度为50的遥感影像对于使用已归一化处理和未归一化处理的数据集训练的模型修复后的图像进行了对比,结果如图6所示,可以看出使用已归一化处理的数据集进行训练的模型的修复效果更好。




图6 噪声程度为50条件下的归一化处理后修复图像对比

Fig. 6 Comparison of the restored images before and after normalization under the condition of noise level of 50

结束语 本文针对目前遥感影像受到各种退化的影响使用效果欠佳的问题,提出了基于DIL的遥感影像修复方法。首先对训练数据进行了归一化处理,以实现训练过程中的变量唯一。而后使用训练后的修复网络对遥感影像进行修复,实验结果表明本文提出的基于DIL的遥感影像修复方法在结构相似度上要优于Noise2Noise, FFDnet, DnCNN, Restormer算法,实现了由RGB图像修复网络到针对遥感影像领域的修复网络的迁移。未来也将尝试进一步扩大数据集,搜集各种领域的遥感影像加以修复,使得模型可以得到更广泛的应用。


参考文献

- [1] SONG T T, HANG Y, SHI M L. Hybrid Noise Removal Technology for Remote Sensing Images Based on Deep Learning[J]. Computer Literacy and Technology, 2024, 20(13): 37-38, 48.
- [2] WANG X Y, CEHN L, LI M. Interpolation-based image inpainting algorithms[J]. Journal of Shantou University: Natural Science Edition, 2015, 30(2): 9.
- [3] LIU F F. Image Restoration Based on Partial Differential Equa-

- tions and Its Fast Algorithm[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2024.
- [4] SHEN J. Research on image restoration method based on sparse representation[D]. Beijing: North China Electric Power University, 2016.
- [5] MAO X J, SHEN C H, YANG Y B. Image Restoration Using Convolutional Auto-encoders with Symmetric Skip Connections [J]. arXiv:1606.08921, 2016.
- [6] HU Y, WANG Y, ZHANG J. DEAR-GAN: Degradation-Aware Face Restoration With GAN Prior[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2023, 33: 4603-4615.
- [7] PAN J W, YIN Y, LI Y B, et al. Restoration of Material Pore Structure Image Using Transformer Architecture [C] // 2024 IEEE Conference on Artificial Intelligence (CAI). Singapore, 2024: 1214-1219.
- [8] LI X, LI B, JIN X, et al. Learning Distortion Invariant Representation for Image Restoration from a Causality Perspective [C] // 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 1714-1724.
- [9] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C] // International Conference on Machine Learning. PMLR, 2017: 1126-1135.
- [10] PEARL J. Causal inference in statistics: An overview[J] Statistics surveys, 2009, 3: 96-146.
- [11] WEI X, PHUNG S L, BOUZERDOUM A, et al. Invariant image recognition under projective deformations: An image normalization approach[C] // 2015 Visual Communications and Image Processing (VCIP). IEEE, 2015: 1-4.
- [12] ZHANG K, ZUO W, CHEN Y, D, et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising[J]. IEEE Transactions on Image Processing, 2017, 26 (7): 3142-3155.
- [13] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.
- [14] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering [J]. IEEE Trans. Image Process, 2007, 16(8): 2080-2095.
- [15] ZHANG K, ZUO W, ZHANG L. FFDNet: Toward a Fast and Flexible Solution for CNN-Based Image Denoising [J]. IEEE Transactions on Image Processing, 2018, 27(9): 4608-4622.
- [16] JAAKKO L, MUNKBERG J, HASSELGREN J, et al. Noise2Noise: Learning Image Restoration without Clean Data [J]. arXiv:1803.04189, 2018.
- [17] JIA X, PENG Y, LI J, et al. Dual-Complementary Convolution Network for Remote-Sensing Image Denoising[J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19: 1-5.
- [18] HAN L, ZHAO Y, LV H, et al. Remote Sensing Image Denoising Based on Deep and Shallow Feature Fusion and Attention Mechanism[J]. Remote Sens., 2022, 14: 1243.
- [19] LIU M, JIANG W, LIU W, et al. Dynamic Adaptive Attention-Guided Self-Supervised Single Remote-Sensing Image Denoising [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 1-11.
- [20] GLYMOUR M, PEARL J, JEWELL N P. Preliminaries: Statistics and Causal Models[M] // Causal inference in statistics: A primer[J]. John Wiley & Sons, 2016: 2-4.
- [21] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks[C] // International Conference on Machine Learning. PMLR, 2017: 1126-1135.
- [22] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: Efficient transformer for high-resolution image restoration[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2022: 5728-5739.



JIANG Yujia, born in 2004, undergraduate. Her main research interest is software engineering.



SUN Baodan, born in 1993, Ph.D, lecturer, master supervisor. Her main research interest is machine learning.