

DOI:10.20033/j.1003-7241.(2026)10-0115-06

多尺度特征融合的雨天轨道车辆图像修复方法

刘安¹, 王志云¹, 张川江¹, 储节磊²

(1. 成都运达科技股份有限公司 广州运达智能科技有限公司, 广州 510030;

2. 西南交通大学 人工智能研究院, 成都 611756)

摘要:针对雨天城市轨道交通车辆图像中因雨条、雨雾等因素导致的视觉干扰问题,提出一种基于多尺度融合的深度学习模型。雨条在图像中呈现出多种模糊程度和分辨率特征,并在不同尺度的图像中具有显著的相似性和相关性。为此,设计多尺度特征金字塔结构,通过跨尺度特征交互模块动态建模,加强全局与局部特征的表达能力。模型结合多尺度卷积核重建策略,在去除雨条的同时有效保留图像细节,并通过递归策略联合建模相似雨条的空间特征,提升去雨效果。实验结果表明,提出的模型在多个数据集上表现优异,特别是在复杂雨天场景中,取得了较高的峰值信噪比(Test2800:32.022, R100H:28.950)和结构相似度(Test2800:0.930, R100H:0.891)。与传统方法相比,所提模型在复杂场景中的表现更加稳健,展现了强大的图像修复能力、适应性及良好的泛化能力。该方法为雨天轨道交通图像处理提供了新的解决方案,并为相关领域的进一步研究奠定了基础。

关键词:城市轨道交通车辆监控;图像去雨修复;跨尺度特征交互;多尺度卷积核重建;深度学习;特征金字塔;多尺度融合

中图分类号: TP391.41;U216.3;U495

文献标志码: A

文章编号: 1003-7241(2026)10-0115-06

Multi-scale feature fusion for image restoration method of rainy weather rail vehicles

Liu An¹, Wang Zhiyun¹, Zhang Chuanjiang¹, Chu Jielei²

(1. Guangzhou Yunda Intelligent Technology Co., Ltd., Chengdu Yunda Technology Co., Ltd, Guangzhou 510030, China;

2. Institute of Artificial Intelligence, Southwest Jiaotong University, Chengdu 611756, China)

Abstract: In this study, a deep learning model based on multi-scale fusion is proposed to address the problem of visual interference due to rain bars and rain fog in urban rail vehicle images in rainy weather. Rainbars present a variety of blurring levels and resolution features in images, and have significant similarity and correlation in images of different scales. For this reason, a multi-scale feature pyramid structure is designed in this paper, which is dynamically modelled by a cross-scale feature interaction module to enhance the representation of global and local features. The model incorporates a multi-scale convolutional kernel reconstruction strategy to effectively retain image details while removing rainbars, and jointly models the spatial features of similar rainbars through a recursive strategy to enhance the rain removal effect. Experimental results show that the proposed model performs well on multiple datasets, especially in complex rainy weather scenes, and achieves high PSNR (Test2800:32.022, R100H:28.950) and SSIM (Test2800:0.930, R100H:0.891). Compared with traditional methods, the model in this paper performs more robustly in complex scenes, demonstrating strong image restoration capability, adaptability and good generalisation. The method provides a new solution for rainy weather rail transit image processing and lays the foundation for further research in related fields.

Keywords: urban rail vehicle monitoring; image deraining restoration; cross-scale feature interaction; multi-scale convolutional kernel reconstruction; deep learning; feature pyramid; multi-scale integration

随着智能化技术在城市轨道交通中的应用,雨天图像质量下降已成为影响视觉任务性能的关键问题。近年来,基于深度学习的去雨方法,特别是卷积神经网络,已在图像去雨领域取得显著进展,尤其是通过递归结构^[1]、生成对抗网络^[2]和空间注意机制^[3]等创新方法。然而,现有方

法仍面临雨水与背景成分之间复杂非线性耦合的问题^[4]。为了解决这一问题,多尺度学习方法^[5]应运而生,该方法通过多尺度处理图像,增强了对复杂场景的理解,能够捕捉雨条多样性,有效去除雨水干扰并保留细节。

本文的主要贡献包括:设计了一种多尺度融合网络来

收稿日期:2025-07-02;录用日期:2025-08-02

基金项目:国家自然科学基金面上基金项目(62276218);中国中铁股份有限公司科技研究开发计划重大项目(2023-重大-23);四川省自然科学基金面上项目(2024NSFSC0490)

作者简介:刘安(1981-),男,工程师,研究方向为智慧交通、故障诊断。

通信作者:储节磊(1977-),男,博士,副研究员,博士生导师,研究方向为人工智能、智慧交通。

引用本文:刘安,王志云,张川江,等.多尺度特征融合的雨天轨道车辆图像修复方法[J].自动化技术与应用,2026,45(10):115-120.(Liu An, Wang Zhiyun, Zhang Chuanjiang, et al. Multi-scale feature fusion for image restoration method of rainy weather rail vehicles[J]. Techniques of Automation and Applications, 2026, 45(10): 115-120.)

识别和去除不同尺度的雨条纹,特别针对城市轨道交通的复杂背景,提出了一种去雨算法。实验结果表明,该方法在复杂背景和多变的雨水条件下具有较强的鲁棒性和精度,为轨道交通图像处理提供了新的解决方案。

1 相关工作

1.1 单幅图像去雨

单幅图像去雨是计算机视觉中的重要任务,旨在从受雨水影响的图像中恢复清晰背景。早期,去雨方法依赖传统图像处理技术,如滤波、变换和稀疏表示,通过分析雨水物理特性来分离雨条和背景。Fattal^[3]提出了一种基于图像恢复的去雨方法,利用图像的自然结构和稀疏性去除雨条并恢复清晰背景。但这些方法过度依赖人工设计的先验知识,难以应对复杂背景和大范围降雨。随着深度学习的发展,卷积神经网络(convolutional neural network, CNN)成为主流去雨方法,自动学习局部特征,减少对人工特征设计的依赖,提升了去雨效果。Fu等^[4]提出的基于CNN的端到端去雨网络,利用多层卷积结构有效分离雨条和背景,取得了较好的去雨效果。但在处理复杂背景或大范围降雨时, CNN仍面临细节保留与去除雨水之间的平衡问题。生成对抗网络(generative adversarial networks, GAN)在图像去雨中也取得了显著进展。Zhang等^[5]提出的基于GAN的去雨方法,通过多任务学习框架,出色地去除了雨水并保留了细节,相较传统GAN方法,展现了更强的视觉逼真性。

在城市轨道交通系统中,图像去雨技术面临复杂挑战。轨道车辆图像包含多个元素,如车辆、轨道和建筑,雨水干扰不仅影响清晰度,还可能导致交通监控失败。传统去雨方法难以应对复杂背景和雨水形态,特别是在动态环境下。近年来,深度学习方法已被应用于轨道车辆图像去雨任务。例如,袁小军等^[6]提出的低能见度场景图像增强系统,有效解决低照度、雾天和雨天等问题,显著提升了多目标检测和语义分割的精度,尤其在雨天图像中准确率提升超过4%。

1.2 多尺度学习

多尺度学习在计算机视觉任务中得到广泛应用,尤其在目标检测、语义分割、图像超分辨率和小样本分类任务中取得显著成果。Lin等^[7]通过特征金字塔网络在不同分辨率的特征图上处理,有效提高了小目标的检测精度。Zhang等^[8]设计的多分辨率重建模块,增强了超分辨率图像的细节表现力。陈龙等^[9]在小样本分类中引入多尺度注意力模块,通过优化特征并减少领域间差异,提升了模型泛化能力。在医学影像领域,多尺度学习在提升病灶检测与分割精度方面表现突出,尤其在计算机断层扫描和磁共振成像图像处理上效果显著^[10]。周林鹏等^[11]则结合多尺度特征与注意力机制,提升了医学图像检索的精度和识别能力。

近年来,多尺度学习在单幅图像去雨任务中的应用也取得了显著进展。研究者们通过整合多尺度特征,有效增

强了模型对雨条和背景特征的分离能力。例如,2023年的一项研究设计了多尺度金字塔网络,通过对不同尺度的雨水特征进行逐层解耦和重构,显著提升了雨水分离的效果^[12]。此外,还有研究提出了一种基于循环对比的多尺度学习框架,结合自适应权重分配机制,不仅增强了图像去雨的质量,还减少了对数据规模的依赖^[13]。

1.3 城市轨道交通车辆图像修复

城市轨道交通车辆图像修复技术用于改善受雨水、污渍等因素影响的图像质量。雨天等外部环境因素会在车辆表面形成水渍和雨滴,影响图像清晰度并可能丢失重要信息。传统图像修复方法依赖像素级插值、纹理合成等技术,适用于简单损坏图像,但在处理复杂损坏时效果较差。在城市轨道交通车辆图像中,损坏区域的复杂性对修复提出了更高要求^[14-15]。随着深度学习的发展,尤其是卷积神经网络和生成对抗网络的应用,深度神经网络能自动从大规模数据中学习特征,恢复缺失区域的细节,生成对抗网络通过对抗机制生成更加自然的修复图像,具有重要应用价值^[16-19]。

在传统图像修复方法面临复杂图像损坏问题时,近年来,深度学习技术的进展显著提升了修复效果。例如,余晓晗等^[20]提出的改进掩码自编码器与YOLOv5相结合的两阶段装甲目标识别方法,首先通过掩码自编码器修复图像中遮挡的部分,然后利用YOLOv5进行目标检测,获取修复后的目标类别和位置。蒋婉等^[21]则提出了一种基于图像修复的异常检测算法,用于铁路线轨道道床的异物监测。该方法通过掩码修复图像,并利用非异常图像进行训练,从而提高了模型对上下文的语义理解能力,并增强了图像修复的效果。

2 方法

本文提出了一种基于多尺度融合网络的跨尺度特征交互与卷积重建雨天城市轨道交通车辆图像修复方法。如图1整体框架包括图像分块嵌入、基础分支与精细分支特征提取、混合表示模块、跨尺度特征交互模块以及多尺度重建模块。首先,雨天图像经分块嵌入后,分别通过基础分支提取全局特征与精细分支提取细节特征;然后,多尺度特征通过混合表示模块和跨尺度交互模块进行融合与增强;最后,利用多尺度重建模块生成高质量的无雨图像。该方法通过充分挖掘多尺度特征的全局信息与细节特性,实现对雨滴形态的鲁棒去除和图像细节的高精度复原。

2.1 预处理

首先,输入图像经过图像分块嵌入模块处理,通过标准卷积层投影至高维特征空间,并转换为特征块。随后,这些特征块分别经过两个深度可分离卷积层,用于提取不同层次的特征信息。在此过程中,特征被划分为基础分支和精细分支,其中基础分支主要负责提取低分辨率的全局特征,而精细分支则用于捕获高分辨率的细节特征,从而实现图像特征的全面表达与分层处理。




图 1 基于多尺度融合网络的跨尺度特征交互与卷积重建雨天城市轨道交通车辆图像修复方法

Fig. 1 A method for image restoration of urban rail vehicles in rainy conditions based on multi-scale fusion network for cross-scale feature interaction and convolutional reconstruction

然后各自通过高斯金字塔生成不同分支的多尺度雨图像。具体来说,原始图像通过高斯核进行模糊处理,并经过下采样(例如将图像尺寸缩小至原始的一半或四分之一),得到不同分辨率的图像。模糊处理是基于高斯函数的。高斯函数的数学表达式为

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (1)$$

式中, x 和 y 是图像中某个点的坐标, e 是自然常数。 σ^2 是标准差, 决定了模糊的程度。标准差越大, 模糊的效果越强。

这些金字塔图像在不同尺度下捕捉了雨条纹的不同细节: 高分辨率的图像保留了更多细节信息, 而低分辨率的图像则呈现了更大尺度的结构和全局信息。接着, 这些

下采样后的图像被输入到网络中, 通过多个并行卷积层分别提取每个尺度的浅层特征。最后, 这些从不同尺度获得的特征会被整合在一起, 以便后续处理和特征融合。

2.2 混合表示模块

为了实现更精确的推理, 混合表示模块通过双分支解耦网络探索了有雨和无雨组件之间的协同表示, 并结合了 Transformer 模型和卷积神经网络的优点。具体而言, 在混合特征提取块和耦合表示块中采用了非对称混合双路径网络, 其中 Transformer 模型用于建模雨条纹的长距离依赖和复杂模式卷积神经网络则专注于编码无雨背景的局部细节。此外混合表示模块采用了耦合方式的门控权重学习结构, 以便动态调整有雨和无雨特征之间的协同作用。具体如图 2 所示。




图 2 混合表示模块

Fig. 2 Hybrid representation module

混合特征提取块是一个混合双路径网络, 用于学习雨条纹和无雨背景的特征表示。Transformer 模型被用于建模雨条纹的长距离依赖和复杂模式, 而简单的卷积神经网络则专注于局部背景特征, 形成不对称结构, 能够捕捉雨条纹的非局部分布并学习无雨背景的局部细节。Transformer 模块通过跨通道生成注意力图, 降低计算复杂度, 采用多头自注意力机制在通道维度上并行化处理, 并在头部维度增加完全连接层以增强通信。此外, 使用步幅卷积进行下采样, 转置卷积进行上采样。为了增强局部特征学习, 混合特征提取块集成了修改版的耦合表示块, 通过两次连接通道注意力来调整不同通道间的权重。此外, 整个混合特征提取块通过采用深度可分离卷积来优化推理速度。

为了更好地优化基础分支和精细分支之间的相互关系, 耦合表示块并没有采取直接的细化方法, 而是通过建

立这两个分支之间的相互对应关系来进行细化。具体而言, 通过生成元素级别的乘法权重, 来捕捉这两个分支之间的残差信息。也就是说, 基础分支的残差信息来源于精细分支, 而精细分支的残差信息则从基础分支中提取。首先, 逐点卷积被用来实现跨特征通道的信息交互, 接着, 使用 sigmoid 函数生成一个 0 到 1 之间的权重系数, 用于调节信息的流动。为了进一步优化信息传递过程, 引入了可学习的系数 λ , 以实现自适应的调整。通过这种方式, 显著提高了基础分支和精细分支之间的协同作用和信息融合的鲁棒性。

2.3 跨尺度特征交互

首先, 输入的雨天图像通过一个基础卷积网络进行特征提取, 以捕获不同尺度的图像特征。通过初步的卷积操作, 生成了一组多层次的特征图, 表示为 $\{F\}_{i=1}^n$ 。这些特

征图具有不同的空间分辨率和语义信息,既能保留图像的细节特征,又能获得更广泛的上下文信息。特征提取后的特征图为后续的跨尺度融合和特征增强提供了高质量的输入。

为了充分利用多尺度特征信息,网络设计了跨尺度特征交互机制。该机制通过动态学习权重,将不同尺度的特征进行融合,从而实现信息的有效传递和增强。

$$\mathbf{F}'_i = \mathbf{F}_i + \sum_{j \in N(i)} w_{ij} \cdot \mathbf{F}_j \quad (2)$$

式中, $\mathbf{F}_i$ 和 $\mathbf{F}_j$ 分别表示不同尺度图像特征, $\mathbf{F}'_i$ 表示融合后的特征, $N(i)$ 表示与第 i 个尺度特征相邻的尺度集合,

表1 不同模型在图像修复任务中的性能对比

Tab. 1 Performance comparison of different models in image restoration tasks

Model	R100L		R100H		Test100		Test1200		Test2800		Average	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DIDMDN ^[22]	25.332	0.745	17.655	0.553	23.571	0.799	28.974	0.894	27.596	0.834	24.627	0.765
RESCAN ^[23]	30.572	0.896	25.787	0.805	25.785	0.847	30.198	0.856	30.866	0.879	28.642	0.857
LPNet ^[24]	35.537	0.947	22.653	0.795	24.231	0.783	24.781	0.763	27.311	0.804	26.903	0.819
UMRL ^[25]	28.932	0.937	25.982	0.824	23.984	0.816	29.431	0.872	28.632	0.861	27.392	0.862
PreNet ^[26]	33.631	0.947	26.537	0.864	24.531	0.844	30.752	0.889	29.958	0.906	29.082	0.890
MSPFN ^[27]	33.720	0.958	28.462	0.868	27.586	0.874	28.521	0.862	30.848	0.913	29.827	0.895
SWAL ^[28]	35.381	0.962	28.841	0.887	28.198	0.888	31.624	0.903	29.162	0.904	30.641	0.909
Our Model	36.174	0.967	28.950	0.891	28.943	0.895	30.218	0.884	32.022	0.930	31.261	0.913

解码模块则对增强后的特征进行逐步上采样,并通过跳跃连接融合不同层次的特征,逐步恢复出高分辨率的输出图像。在解码过程中,网络充分利用了前期提取的多层次特征信息,确保了最终图像修复结果的高质量,同时实现了细节纹理的精准还原。

2.4 无雨图像重构

为了生成最终的残余雨图像,首先在通过多尺度重建模块中对多尺度初步融合的输出与多尺度深度融合的输出进行拼接。通过两组多尺度卷积分别处理基础分支和精细分支,进行特征提取和重建。通过从不同的尺度上提取图像的多层次特征,以增强模型对细节信息的捕捉能力,从而更好地进行图像恢复。

随后,利用卷积层建模通道间的关系,并对两部分特征进行权重调整,确保信息融合的平衡性和有效性。最后,通过跨越不同金字塔层的迭代采样与特征交互,进一步提取残余雨图像的关键细节,提升图像去雨效果的精度和稳定性。

在训练过程中,使用 Charbonnier 惩罚函数^[22]对真实雨条纹分布 J_R 进行逐步逼近。该函数在训练过程中能够更好地容忍小误差,具有较好的收敛性。具体的损失函数表达式为

$$L_{\text{con}} = \sqrt{(J_R^* - J_R)^2 + \epsilon^2} \quad (3)$$

式中, J_R^* 表示预测的残余雨图像, J_R 表示真实干净图像,惩罚系数 ϵ 设置为 10^{-3} 。

为了进一步提升去除雨条纹后的高频细节保真度和

w_{ij} 是融合权重。

特征增强模块进一步优化了融合后的特征,以提升特征的表达能力。该模块采用了通道注意力机制和空间注意力机制的联合设计,分别从特征通道和空间维度对特征进行加权处理。在通道注意力机制中,通过全局平均池化获取每个通道的重要性权重,从而对每个通道的特征进行调整。在空间注意力机制中,结合全局平均池化和最大池化的结果,计算空间维度上的权重,从而对空间特征进行加权。最终,通过将通道和空间注意力机制的结果进行相乘,生成了增强后的特征。

真实性,引入了额外的边缘损失。边缘损失通过限制真实干净图像与预测去雨图像之间的高频分量差异,帮助保留图像中的细节,其定义为

$$L_{\text{edge}} = \sqrt{[\text{Lap}(J_{\text{clean}}) - \text{Lap}(J_{\text{rain}} - J_R^*)]^2 + \epsilon^2} \quad (4)$$

式中, $\text{Lap}(\cdot)$ 表示通过拉普拉斯算子^[23]提取出边缘图, J_{rain} 为含雨图像, J_{clean} 为干净图像。最终,总损失函数通过以下公式给出:

$$L = L_{\text{con}} + \lambda \times L_{\text{edge}} \quad (5)$$

式中,权重参数 λ 设置为 0.05,用于平衡两项损失的权重。

3 实验结果

本节主要展示了所提出方法在多个基准数据集上的性能表现,以及与现有主流方法的对比情况。通过定量指标和可视化结果的分析,验证了模型在雨条纹去除任务中对背景信息保留和细节恢复的有效性。这些结果充分说明了所提出方法在复杂雨条纹场景中的适用性和优越性。

为了验证所提出方法的有效性,与多种主流去雨算法进行比较实验,包括 DIDMDN^[24]、RESCAN^[25]、LPNet^[26]、UMRL^[27]、PreNet^[28]、MSPFN^[29] 和 SWAL^[30]。为保证公平性,所有方法均使用 13,700 对晴天与雨天图像进行训练,并采用 Test100、Test1200、Test2800、R100H 和 R100L 数据集进行评估。对于有相应真实值的测试数据,采用峰值信噪比 (peak signal-to-noise ratio, PSNR) 和结构相似度 (structural similarity index measure, SSIM) 进行比较,具体而言,PSNR 和 SSIM 分数越大性能越好。

模型基于 PyTorch 实现,并在 NVIDIA A100-PCIE-40 GB GPU 上完成训练。训练过程中,利用随机裁剪操作从原始训练图像中生成 128×128 的样本块。优化器选用 Adam,批大小为 16,初始学习率设置为 4×10^{-4} ,每 60 个轮次衰减至原值的 0.8 倍,直至 500 个轮次完成,具体的训练结果如图 3~5 所示。




图 3 训练损失曲线
Fig. 3 Training LOSS curve




图 4 训练结构相似度曲线
Fig. 4 Training SSIM curve




图 5 训练峰值信噪比曲线
Fig. 5 Training PSNR curve

如表 1 所示,将上述训练过程中表现最好的模型与 DIDMDN 等 7 个其他模型进行了比较评估。评估在 Test100 等数据集上进行,以全面衡量模型的性能。

从表中结果可以看出,所提模型在多个数据集上均表现出了领先的性能,尤其在复杂场景(如 Test2800 和 R100H 数据集)中,取得了最高的 PSNR 和 SSIM 指标 (Test2800 : PSNR = 32.022, SSIM = 0.930 : R100H : PSNR = 28.950, SSIM = 0.891),充分展现了强大的图像修复能

力和适应性。与其他模型相比,所提模型在各数据集之间的表现更加均衡,没有出现明显的性能波动,反映出其出色的泛化能力和鲁棒性。

具体而言,传统方法如 DIDMDN 和 RESCAN 在 PSNR 和 SSIM 上的表现较低,特别是在 R100H 数据集上,PSNR 分别仅为 17.655 和 25.787,难以应对复杂的雨天场景;LPNet 在 R100L 数据集上虽然达到较高的 PSNR (35.537),但在其他数据集上大幅下滑,泛化能力明显不足;UMRL 和 PreNet 在部分数据集上具有一定优势,但在关键指标上均未超越所提模型;MSPFN 和 SWAL 则在 R100H 和 Test2800 数据集上表现接近,但整体依然略逊一筹。



图 6 图像去雨效果对比

Fig. 6 Effects comparison of rain removal in images

如图 6,为了验证模型在雨天图像修复任务中的卓越性能,展示去雨前后的图像对比效果。从结果可以清晰地看到,本文提出的多尺度融合网络能够有效去除雨线和雨雾干扰,使图像的结构和纹理得到精准还原。无论是在雨滴密集的复杂场景中,还是在细雨覆盖的微妙场景下,该模型均展现出了卓越的去雨能力。同时,修复后的图像不仅清晰度显著提升,局部细节更加丰富,整体对比度也得到了优化。这些效果充分证明了该模型在雨天图像修复中的强大能力,为雨天场景的视觉任务提供了高质量的图像支持。

最后,将雨天城市轨道交通车辆图像进行测试,结果如图 7 所示。通过模型的处理,图像中的雨水痕迹几乎完全消失,车辆的细节和背景结构得到了清晰恢复。与原始的雨天图像相比,修复后的图像不仅在色彩上更加自然,细节更加鲜明,而且整体视觉效果更具真实感。特别是在城市轨道交通车辆的车身、车窗和周围环境的表现上,模型能够有效去除雨滴的影响,保留了图像的清晰度和结构信息。这一结果验证了模型在处理复杂雨天环境下轨道交通车辆图像时的优越性,并显示了其在城市轨道交通领域应用的潜力。



图 7 雨天城市轨道交通车辆图像去雨效果对比

Fig. 7 Effects comparison of rain removal on urban rail vehicle images in rainy days

4 结论

本研究提出了一种基于多尺度融合网络的跨尺度特征交互与卷积重建方法,旨在解决雨天城市轨道交通车辆图像修复中的挑战。本研究的创新点在于:1)提出了多尺度融合网络,能够在多个尺度上处理雨条纹并恢复图像细节。2)设计了跨尺度特征交互模块,有效提升了图像去雨过程中的信息融合能力。3)在卷积重建模块中结合多尺度信息,进一步增强了模型的去雨效果和图像质量。研究表明,该方法能够提升雨天图像修复精度,并为智能交通系统提供了可靠的技术支持。未来的研究可以进一步提升算法的实时性,尤其是在复杂场景下的应用。结合边缘计算与深度学习的最新进展,未来可在多模态传感器融合、动态场景重建等领域取得突破,推动智能交通系统的进一步发展。

参考文献

- [1] Yang Wenhan, Tan Robby T, Wang Shiqi, et al. Learning to remove rain in video with self-supervision [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(3): 1378-1396.
- [2] Yang S, Jiaying Liu, Lian Z, et al. Awesome typography: statistics-based text effects transfer [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA; IEEE, 2017: 7464-7473.
- [3] Fattal R. Single image dehazing [J]. ACM Transactions on Graphics (TOG), 2008, 27(3): 1-9.
- [4] Fu X, Huang J, Zeng D, et al. Removing rain from single images via a deep detail network [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA; IEEE, 2017: 3855-3863.
- [5] Zhang H, Patel V M. Density-aware single image de-raining using a multi-stream dense network [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA; IEEE, 2018: 695-704.
- [6] 袁小军, 李晨, 刘昕武, 等. 轨道交通低能见度场景图像增强系统研究 [J]. 图像与信号处理, 2023, 12(3): 302-316.
- [7] Lin T Y, Dollár P, Girshick R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA; IEEE, 2017: 2117-2125.
- [8] Zhang Y, Tian Y, Kong Y, et al. Residual dense network for image super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA; IEEE, 2018: 2472-2481.
- [9] 陈龙, 张建新, 彭昊, 等. 多尺度注意力与领域自适应的小样本图像识别 [J]. 光电工程, 2023, 50(4): 60-73.
- [10] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-assisted Intervention, Munich, Germany; Springer, 2015: 234-241.
- [11] 周林鹏, 姚剑敏, 严群, 等. 融合多尺度特征及注意力机制的医学图像检索 [J]. 液晶与显示学报, 2021, 36(8): 1174-1185.
- [12] Wang Q, Jiang K, Wang Z, et al. Multi-scale fusion and decomposition network for single image deraining [J]. IEEE Transactions on Image Processing, 2023, 33: 191-204.
- [13] Zhao C, Cai W, Hu C W, et al. Cycle contrastive adversarial learning for unsupervised image deraining [PP/OL]. arXiv (2024-07-16) [2026-07-14]. <https://arxiv.org/abs/2407.11750>.
- [14] Yang J, Ruhaiyem N I R. Review of deep learning-based image inpainting techniques [J]. IEEE Access, 2024, 12: 138441-138482.
- [15] Cho R K, Sood K, Channapragada C S C. Image repair and restoration using deep learning [C]//2022 4th International Conference on Artificial Intelligence and Speech Technology (AIST). Delhi, India; IEEE, 2022: 1-8.
- [16] Xu Z, Zhang X, Chen W, et al. A review of image inpainting methods based on deep learning [J]. Applied Sciences, 2023, 13(20): 11189.
- [17] 范春奇, 任坤, 孟丽莎, 等. 基于深度学习的数字图像修复算法最新进展 [J]. 信号处理, 2020, 36(1): 102-109.
- [18] 宋晓晓, 谢明璐. 基于图像识别的跌倒检测研究进展 [J]. 自动化技术与应用, 2026, 45(3): 1-8.
- [19] 姚钢, 张玉宝, 蒋继成, 等. 智能材料核环境图像处理技术研究 [J]. 自动化技术与应用, 2026, 45(3): 104-107.
- [20] 余晓晗, 毛绍臣, 王家宝, 等. 基于改进 MAE 和 YOLOv5 的遮挡目标两阶段检测方法 [J]. 信息技术与信息, 2023(8): 31-38.
- [21] 蒋婉, 杨凯, 邱春蓉, 等. 基于图像修复的无砟轨道道床异常检测算法 [J]. 激光与光电子学进展, 2024, 61(12): 1237006.
- [22] Lai W S, Huang J B, Ahuja N, et al. Deep laplacian pyramid networks for fast and accurate super-resolution [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA; IEEE, 2017: 624-632.
- [23] Kamgar-Parsi B, Rosenfeld A. Optimally isotropic Laplacian operator [J]. IEEE Transactions on Image Processing, 1999, 8(10): 1467-1472.
- [24] Zhang H, Patel V M. Density-aware single image de-raining using a multi-stream dense network [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA; IEEE, 2018: 695-704.
- [25] Li X, Wu J, Lin Z, et al. Recurrent squeeze-and-excitation context aggregation net for single image deraining [C]//Proceedings of the European Conference on Computer Vision (ECCV). Munich, Germany; Springer Science, 2018: 254-269.
- [26] Fu X, Liang B, Huang Y, et al. Lightweight pyramid networks for image deraining [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 31(6): 1794-1807.
- [27] Yasarla R, Patel V M. Uncertainty guided multi-scale residual learning using a cycle spinning CNN for single image de-raining [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA; IEEE, 2019: 8405-8414.
- [28] Ren D, Zuo W, Hu Q, et al. Progressive image deraining networks: A better and simpler baseline [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA; IEEE, 2019: 3937-3946.
- [29] Jiang K, Wang Z, Yi P, et al. Multi-scale progressive fusion network for single image deraining [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA; IEEE, 2020: 8346-8355.
- [30] Huang H, Yu A, Chai Z, et al. Selective wavelet attention learning for single image deraining [J]. International Journal of Computer Vision, 2021, 129(4): 1282-1300.