

一种基于密集连接网络的图像去雨方法

吴章云¹ 吴传宇^{1*} 叶智国¹ 熊盛佳¹ 王 硕¹ 林凯旋¹

WU Zhangyun WU Chuanyu YE Zhiguo XIONG Shengjia WANG Shuo LIN Kaixuan

摘 要

随着计算机视觉技术在自动驾驶、智能监控等领域的广泛应用，雨天环境因自身特性显著增加了图像去雨的难度，导致图像质量下降，这一问题亟待解决。为应对现有方法在提取关键雨条特征和避免信息冗余上的不足，文章提出了一种基于多尺度特征学习和注意力机制的密集连接网络（CMADNet），用于单幅图像的去雨处理。CMADNet 结合多尺度分割注意力（MSA）模块和多尺度特征学习（MFL）模块，在密集连接框架中可以有效提取雨条特征，同时抑制冗余信息。实验结果表明，CMADNet 在多个基准数据集上均实现了先进的性能，显著提高了 PSNR 和 SSIM 指标。与现有方法相比，该方法具备更高的计算效率和泛化能力。验证了其在恶劣天气下计算机视觉任务中的应用潜力。

关键词

图像去雨；密集连接网络；多尺度分割注意力；多尺度特征学习

doi: 10.3969/j.issn.1672-9528.2025.05.029

0 引言

在实际场景中，户外计算机系统如实时监控、自动驾驶和智能交通等常在恶劣天气条件下工作。在这些环境中捕获的图像或视频经常受到干扰，导致质量下降。不仅影响图像的可见性，还严重影响物体检测、语义分割和深度估计等高层次视觉任务的性能，这些任务是户外智能系统的关键组成部分。因此，去除图像中由于恶劣天气引起的不良影响，对于提高这些系统的可靠性至关重要。相比于其他天气现象，雨水是一种动态天气现象，处理起来更为复杂。此外，由于雨水对视觉传感器其功能的影响更加明显。因此，开发能适用于多种户外视觉任务的有效图像去雨算法是一个紧迫的实际需求。

单幅图像去雨技术主要分为基于模型优化的方法和基于数据驱动的方法。本节将综述这两类图像去雨方法的研究现状，并总结图像去雨任务面临的主要挑战。

基于模型优化的图像去雨方法，利用对雨条或背景的先验知识进行建模，将雨图像视为雨层与无雨背景层的叠加，通过图像分解来实现去雨。Luo 等人^[1]引入了一种基于字典学习和稀疏编码的去雨方法，有效保留了清晰的背景纹理，但有时无法完全去除所有雨条。Zhu 等人^[2]利用雨图的层状结构，提出了一个迭代层次模型来去除雨层，对于稀疏雨条效果较好，但在处理复杂雨形态时效果较差。Li 等人^[3]通过预定义约束和高斯混合模型去除小尺度雨条，但对大尺度雨

条效果较差。

近年来，随着深度学习技术的发展，基于数据驱动的去雨方法在性能上取得了显著提升，并逐渐成为主流。Fu 等人^[4]率先提出了一种端到端的去雨方法，通过残差卷积网络提取雨条特征。Jiang 等人^[5]开发了一种多尺度融合网络，用于去雨。Qian 等人^[6]利用生成对抗网络去除图像中的雨滴，Wei 等人^[7]设计了一种半监督网络来适应合成和真实雨条件。Yasarla 等人^[8]通过高斯过程模拟真实降雨，改进了去雨性能。Ye 等人^[9]利用 CycleGAN 学习雨特征，缩小了合成雨图像与真实雨图像之间的差距。Li 等人^[10]使用递归神经网络来更好地表示雨条特征。

1 所提图像去雨算法模型与改进

1.1 总体网络架构

CMADNet 的结构如图 1 所示。




图 1 结合多尺度特征学习和注意力机制的密集连接网络
单图像去雨网络架构

最初通过 3×3 卷积操作从输入图像中提取特征映射。这些映射通过多个由多尺度特征学习（MFL）模块组成的密集层逐渐提取雨条信息。每层的输出作为下一层的输入，

1. 福建农林大学机电工程学院 福建福州 350002

[基金项目] 福建农林大学科技创新项目“咖啡烘焙温度智能控制研究”（KFB23162A）

并通过跳跃连接将输出传递到未来的层。多尺度分割注意力（MSA）模块集成了来自不同密集层的特征，随后通过 3×3 卷积生成最终的雨条特征表示。然后从原始图像中减去雨条图像，以获得去雨后的结果。

1.2 密集连接网络的改进

DenseNet 是一种经典的密集连接网络，每层的输出作为后续层的输入，在通道维度上连接，以最大限度地重用特征。然而，随着网络深度的增加，特征信息累积，可能导致冗余和效率降低。为解决这一问题，本文提出了一种结合多尺度特征学习和分割注意力机制的密集连接去雨网络，以增强信息传递和鲁棒性。

图 2 展示了增强版 DenseNet 的结构，由多个密集层和转换层组成。密集层充当多尺度特征学习模块，而转换层将密集层的输出特征转换为固定的下一层特征。




图 2 多尺度分割注意力模块的架构

对转换层的主要改进包括：

（1）移除了传统的批量归一化（BN）层，BN 层在每次卷积操作后对特征信息进行归一化，由于训练集和测试集之间的差异，可能会影响泛化能力，同时占用大量 GPU 资源。

（2）引入了多尺度分割注意力模块，该模块标准化通道维度，使网络能够自适应地学习重要特征，同时抑制冗余特征。此模块将作为后续多尺度特征学习模块的预处理，增强了特征提取能力。

1.3 多尺度分割注意力模块

注意力机制帮助算法聚焦于特定区域，同时忽略无关信息。为增强网络学习雨条特征的能力并提高其执行效率，本文设计了多尺度分割注意力模块，如图 3 所示。




图 3 DenseNet 架构

该模块的处理步骤如下：

首先，分割连接模块通过通道对输入特征进行分组，并对这些分组的特征应用不同大小的卷积操作。此方法通过多个分支提取不同通道的多尺度特征映射。

其次，使用文献 [11] 提出的通道注意力模块捕获不同尺度特征的通道注意力特征。

最后，注意力特征与从分割连接模块获得的特征进行逐元素乘法，以生成加权的多尺度特征映射。所得特征具有丰富的多尺度信息，能够建立长期通道注意力依赖关系，并促进多尺度通道注意力之间的信息交互。

分割连接模块首先将通道维度为 c 的输入特征均匀分为 n 部分。然后，使用不同大小的卷积核对各部分特征进行处理，以提取多尺度特征信息，如式（1）所示。最后，使用式（2）将这些特征映射融合，得到多尺度特征。值得注意的是，使用不同大小的卷积核可以捕获不同的感受野，有效减少参数数量，提高操作效率，并增强不同特征通道之间的信息交换。

$$F_i = \text{Conv}(X_i), i = 0, 1, \dots, n-1 \quad (1)$$

$$F = \text{Cat}(F_0, F_1, \dots, F_{n-1}) \quad (2)$$

式中：Conv($\cdot$) 表示分组卷积； F_i 表示不同分组的输出特征映射。

通道注意力模块该模块对分割连接模块获得的特征组进行如下处理：

首先，对输入特征进行全局平均池化，生成 $1 \times 1 \times C$ 的特征映射。

其次，使用大小为 K 的卷积核执行 1×1 卷积操作，得到新的 $1 \times 1 \times C$ 特征映射。促进了局部跨通道交互。

最后，使用 Sigmoid 激活函数计算每个通道的权重 W 。在该模块中，全局平均池化确保通道与其各自的权重之间的直接对应关系，避免维度降低。1D 卷积捕获局部特征的跨通道交互，其中卷积核大小 K 决定了交互的范围，是一个关键参数。通常，较大的通道尺寸意味着更强的长期交互，而较小的通道尺寸则表明更强的短期交互。在设计该模块时， K 和 C 满足公式定义的自适应关系。

$$K = \frac{\log_2(C)}{\gamma} + \frac{b}{a^2} \quad (3)$$

式中： C 表示通道数量； $\gamma=2$ ； $b=1$ 。

以上过程可以通过式（4）~（7）表示：

首先，用于获得不同尺度特征的注意力权重（ W_i ）公式为：

$$W_i = \text{Att}(F_i), i = 0, 1, \dots, n-1 \quad (4)$$

式中: Att 表示通道注意力模块。

其次, 整个多尺度通道特征组的注意力权重公式为:

$$W = W_0 \oplus W_1 \oplus \dots \oplus W_{n-1} \quad (5)$$

然后, 对分割连接模块获得的特征映射和通道注意力模块获得的注意力权重进行逐元素乘法, 其公式为:

$$T_i = F_i \odot W_i, i = 0, 1, \dots, n-1 \quad (6)$$

最后, 连接得到的注意力特征映射, 生成丰富信息的特征表示:

$$F_{\text{out}} = \text{Cat}(T_0, T_1, \dots, T_{n-1}) \quad (7)$$

如图 4 所示, 多尺度特征学习模块与文献 [12] 相比, MFL 模块的结构进行了几项改进, 同时保留了四个阶段的多尺度特征提取: 首先, 在特征提取过程中, 残差模块被替换为文献 [13] 中的 RepVGG 模块。此外, 在多尺度特征提取后, 引入 MB 卷积进行特征融合, 丰富了输出特征, 有效提升了网络性能。




图 4 多尺度特征学习模块的结构

MFL 模块利用多尺度特征学习同时捕捉深层和浅层特征。详细过程如下:

首先, 将输入特征映射下采样到原始尺寸的 1/2、1/4、1/8 和 1/16。然后使用 RepVGG 模块提取各个尺度的特征映射。再将每个尺度的特征映射上采样回原始尺寸, 并将这些上采样的特征映射与原始特征映射连接。最后, 将连接的特征映射输入 MB 卷积模块, 以获得多尺度融合特征。上述过程用公式分别表示为:

$$X_i = \text{LeakyReLU}(\text{Conv}_j^k(X_{i-1})) \quad (8)$$

$$X_i = \text{RepVGG}(X_i) \quad (9)$$

$$X_{\text{out}} = \text{MBCon}[\text{Concat}(X_0, X_1^{\text{Up}}, \dots, X_n^{\text{Up}})] \quad (10)$$

式中: $i(i=1, 2, \dots, n)$ 表示尺度数量; Conv_j^k 表示步长为 k 的 $j \times j$ 卷积操作; $\text{LeakyReLU}(\cdot)$ 表示参数为 0.2 的激活函数; 上采样操作 Up 使用插值策略; $\text{Concat}(\cdot)$ 表示连接操作。

2 损失函数

近年来, 图像去雨任务中常用的损失函数可分为两类: 复合损失函数和单一损失函数。典型的复合损失函数包括 MSE+SSIM、+SSIM 和对抗损失等组合。尽管这些复合损失函数在许多去雨网络中得到了应用并取得了良好的训练效果, 但也增加了训练过程中超参数调整的负担。因此, 本文使用单一的负 SSIM 损失函数, 以实现更好的训练性能。其公式为:

$$L = -\text{SSIM}(X, X_{\text{gt}}) \quad (11)$$

式中: X 表示去雨后的图像; X_{gt} 表示合成数据集中对应的无雨图像。



注: (a) 雨天图像; (b) DDN; (c) RESCAN; (d) PreNet; (e) MSPFN; (f) MPRNet; (g) 提出的 CMADNet; (h) 真值图像

图 5 不同方法在合成数据集上的去雨结果可视化

3 实验结果与分析

为验证本文所提出的 CMADNet 模型, 在多种合成和真实雨天数据集上进行了大量实验。结果与包括 DDN、RESCAN、SPANet、PreNet、MSPFN、MPRNet 和 RLNet 在内的最先进方法进行了比较。

本文所提方法基于 PyTorch 框架实现, 并在 NVIDIA GTX 4090 GPU 上完成训练和测试。考虑到内存限制, 在实验过程中训练图像统一随机裁剪为 $64 \text{ px} \times 64 \text{ px}$ 。使用 Adam 优化器优化训练过程。初始学习率设置为 5×10^{-4} , 每 500 个周期调整为原值的 1/10, 直到达到 5×10^{-6} 。网络共训练了 2000 个周期。网络中的密集层数量和通道数量均设置为 32。

在本节中，所提出的 CMADNet 方法通过与其他最先进方法的比较，进行了定量评估和定性分析。

定性分析：图 5 提供了 Rain100H 数据集上的去雨结果示例，并突出显示了关键区域。DDN、RESCAN 和 PreNet 等方法在降雨较大的图像中留下了残留的雨条。尽管 MSPFN 和 MPRNet 去除了大部分雨条，但在处理不均匀的雨模式时存在困难，导致细节丢失和模糊区域。相比之下，所提出的 CMADNet 在视觉效果和评估指标方面均提供了优越的去雨结果。

定量评估：本文提出的方法在合成数据集 Rain100H、Rain100L 和 Rain800 上进行了定量评估。如表 1 所示的实验结果所示，所提出的方法在所有数据集上均取得了最高的 SSIM 和 PSNR 值。在 Rain100L 合成数据集上，与 RLNet 方法相比，所提出的方法在 PSNR 指标上提高了约 1.38 dB，SSIM 指标提高了 1.2 dB。

表 1 不同去雨方法的 PSNR/SSIM 比较

去雨方法	Rain100L	Rain100L	Rain100H	Rain100H	Rain800	Rain800	参数数量
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	
DDN	32.16	0.936	21.92	0.764	22.77	0.810	57 369
RESCAN	29.80	0.881	26.36	0.786	25.00	0.835	149 823
SPANet	35.33	0.969	25.11	0.833	24.41	0.829	283 716
PreNet	32.44	0.950	26.77	0.858	24.81	0.851	168 963
MSPFN	32.40	0.933	28.66	0.860	27.50	0.876	13 225 376
MPRNET	36.40	0.965	31.41	0.889	30.27	0.897	3 637 225
RLNet	37.28	0.970	30.21	0.894	30.29	0.905	3 458 814
Proposed CMADNet	38.66	0.982	30.59	0.895	30.43	0.906	2 140 419

4 结论

本文提出了一种基于多尺度特征和注意力机制的图像去雨网络。所提出的网络通过结合多尺度分割注意力模块改进了密集连接架构，使网络能够自适应地学习重要特征，同时抑制冗余。此外，设计了多尺度特征学习模块，以捕捉各种尺度的特征，增强雨条特征的代表。实验结果验证了所提出方法的高效性和强大的泛化能力。

参考文献：

[1] LUO Y, XU Y, JI H. Removing rain from a single image via discrim- inative sparse coding[C]//2015 IEEE International Conference on Computer Vision (ICCV).Piscataway:IEEE, 2015:3397-3405.

[2] ZHU L, FU C W, LISCHINSKI D,et al. Joint bi-layer optimization for single-image rain streak removal[C]//2017 IEEE International Conference on Computer Vision (ICCV).

Piscataway: IEEE, 2017:2545-2553.

[3] LI Y, TAN R T, GUO X J,et al. Rain streak removal using layer priors[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 2736-2744.

[4] FU X Y, HUANG J B, DING X H, et al. Clearing the skies: a deep network architecture for single-image rain removal[J]. IEEE transactions on image processing, 2017,26(6):2944-2956.

[5] JIANG K, WANG Z Y, YI P, et al. Multi-scale progressive fusion network for single image deraining[C]//2020 IEEE/ CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 8343-8352.

[6] QIAN R, TAN R T, YANG W H, et al. Attentive generative adversarial network for raindrop removal from a single image[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).Piscataway: IEEE, 2018: 2482-2491.

[7] WEI W, MENG D Y, ZHAO Q, et al. Semi- supervised transfer learning for image rain removal[C]//2019 IEEE/ CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2019: 3872-3881.

[8] YASARLA R, SINDAGI V A, PATEL V M. Syn2real transfer learning for image deraining using gaussian processes[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 2723-2733.

[9] YE Y T, CHANG Y, ZHOU H Y, et al. Closing the Loop: joint rain generation and removal via disentangled image translation[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR).Piscataway: IEEE, 2021: 2053-2062.

[10] LI X, WU J L, LIN Z C, et al. Recurrent squeeze-and-excitation context aggregation net for single image deraining[C]//Computer vision–ECCV 2018. Berlin: Springer, 2018: 262-277.

[11] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer

基于改进支持向量机的计算机网络信息入侵检测研究

冷 静¹

LENG Jing

摘 要

计算机网络信息数据具有高维度、复杂多变的特点,其中包含大量的噪声和无关信息,使得难以准确、高效地获取关键特征,进而导致入侵检测精度下降。为此,研究了一种基于改进支持向量机的计算机网络信息入侵检测方法。首先通过引入高效的映射函数将原始的高维、复杂的网络信息数据映射到一个更合适的特征空间。以自动提取和捕捉计算机网络信息入侵特征样本,有效过滤掉噪声和无关信息;然后利用粒子群优化算法对支持向量机的参数进行优化,以降低计算复杂度并提高模型的泛化能力。并采用优化后的支持量机对捕捉的计算机网络信息入侵特征样本分类;最后根据分类结果判定特征样本所属类别实现入侵检测。实验结果表明,该方法网络信息入侵检测精度最高时达到97%,当时间达到100 min时,本文方法的监测数据量达到了375 Mbit/s。

关键词

改进支持向量机; 计算机网络信息; 入侵检测; 样本分类; 粒子群优化

doi: 10.3969/j.issn.1672-9528.2025.05.030

0 引言

网络入侵检测作为保障网络安全的重要手段,其研究具有重要的现实意义和应用价值。计算机网络信息入侵检测旨在通过对网络流量的实时监测和分析,及时发现并响应潜在的入侵行为,从而保护网络系统的安全稳定运行。然而,面对日益复杂多变的网络攻击手段,传统的入侵检测方法已难以满足当前网络安全防护的需求。

近年来,研究者们提出了一系列基于不同技术的网络入侵检测方法。例如,刘联海等人^[1]研究的基于图像凸包特

征的CBAM-CNN网络入侵检测方法,首先将数据集转化为RGB图像,通过提取图像中的凸包特征进行分类实现网络入侵检测。然而,将数据集转化为RGB图像的过程中,可能会丢失原始数据集中一些重要的特征信息,导致检测性能下降。王雪妍等人^[2]研究的卷积神经网络结合特征融合的网络入侵检测方法将流量数据转化为灰度图像,提取纹理特征并与流量特征进行融合,利用优化后的卷积神经网络模型进行多分类实验提高入侵检测精度。然而,特征融合会导致数据维度和复杂度增加,在处理大规模网络数据时,会面临计算资源不足和训练时间过长的问题。张震等人^[3]研究基于空间特征和生成对抗网络的网络入侵检测方法通过转换流量数据

1. 深圳市第二职业技术学校 广东深圳 518107

- Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 11534-11542.
- [12] CHEN X, HUANG Y F, XU L. Multi-scale attentive residual dense network for single image rain removal[C]//Computer Vision-ACCV 2020. Berlin: Springer, 2021: 286-300.
- [13] DING X H, ZHANG X Y, MA N N, et al. RepVGG: making VGG-style convnets great again[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 13728-13737.

【作者简介】

吴章云(1999—),男,湖南郴州人,硕士研究生,研

究方向:人工智能, email:741124643@qq.com。

吴传宇(1976—),通信作者(email:360626964@qq.com),男,福建建瓯人,博士,高级工程师,研究方向:农业机械化。

叶智国(1999—),男,江西上饶人,硕士研究生,研究方向:人工智能。

熊盛佳(2000—),女,湖南益阳人,硕士研究生,研究方向:人工智能。

王硕(2001—),男,黑龙江绥化人,硕士研究生,研究方向:农业工程与信息技术。

林凯旋(2002—),男,福建福州人,硕士研究生,研究方向:集成电路工程。

(收稿日期:2024-12-23 修回日期:2025-05-08)