

前 言

在空天信息产业高速发展的今天,遥感图像的质量直接关系到国家自然资源调查监测、防灾减灾、智慧城市等国家重大战略的实施效果。然而,受大气散射(雾霾)、光照条件(夜间低照度)及云层覆盖三大环境因素的制约,全球约 42%的遥感数据存在显著质量退化(据 2024 年 IGARSS 会议报告)。传统基于物理模型的图像增强方法在复杂场景下的泛化能力有限,而深度学习技术与遥感科学的深度交叉融合成为必然选择。在复杂场景下(如云雾遮挡、光照不均、地形扭曲),图像处理旨在解决真实环境中光照失衡、遮挡物干扰、背景杂乱等图像分析难题。

遥感图像(影像)处理技术在遥感科学领域内至关重要,提升其质量是遥感目标检测、识别等任务的核心基石。外部环境导致遥感图像质量下降的主要因素有雾霾造成的图像模糊、夜间光照不足引发的能见度降低,以及云层遮挡对地表信息完整性的影响等。

全书共 10 章,第 1 章对遥感图像增强处理、语义分割和目标检测进行归纳总结。第 2~4 章聚焦退化遥感图像增强处理,分别提出多尺度自适应的遥感图像去雾方法、视觉感知的遥感图像低照度增强方法,以及域自适应的遥感图像去云层遮挡方法,重点解决雾霾/低照度/云层导致的非线性退化过程建模困难以及地物边界分形特性与阴影干扰造成的耦合误差大的问题。第 5~7 章针对复杂地物边界易产生模糊粘连现象、区域阴影遮挡导致像素级分类可靠性降低等问题,开展基于深度学习的遥感图像语义分割技术研究。第 5 章提出以分形几何驱动的新型网络架构与阴影干扰抑制算法的协同解决方案,通过建立同类聚合与异类分离的优化机制提升分割精度。第 6 章针对遥感图像语义分割中区域边界粘连导致分割模糊的问题,提出分形几何驱动的 FCUNet 模型,针对遥感图像阴影遮挡引发的像素误分类问题,构建 U-Net 架构的多任务三支路 SPENet 模型。第 7 章针对遥感图像原始尺寸与模型输入尺寸失配问题,提出基于 SPENet 的端到端多尺度自适应裁切策略。第 8~10 章解决小目标特征捕捉不足、小目标因位置偏移敏感和目标检测模型参数量大等问题。第 8 章针对遥感图像目标检测因尺度多样性显著、小目标特征捕捉能力不足导致的检测精度低的问题,提出基于感受野特性的改进模型,通过动态调整锚框与多尺度上下文增强模块提升检测性能。第 9 章为解决遥感图像小目标因位置偏移敏感、正负样本梯度分配失衡引发的漏检问题,构建基于中心相似度的定位模型,结合 Wasserstein 距离与 WIoU 损失优化检

测效果。第 10 章针对高性能遥感目标检测模型参数量大、计算成本高、难以部署于星上边缘设备等资源受限场景的问题,采用全局通道剪枝技术实现模型轻量化,平衡检测精度与部署可行性。同时,开展星载边缘计算架构与不确定性量化方面的探索,并将上述研究成果应用于遥感图像变化检测和道路网络提取等领域,推动遥感监测向全天候、实时化、可解释化方向发展。为了方便阅读,本书提供部分彩图的电子文件,读者可自行扫描封底左上角防伪码上的二维码查阅。

本书是作者及团队多年科研和教学成果的梳理与总结。王新华、李壮教授负责本书的撰写工作,袁波涛、蒿乾坤、贾言鑫和曹金鹏等研究生参与本书的内容编排,宋向阳、郑慧等研究生参与本书的校稿工作,王鹤淇等教授为本书提供专业指导。在此,一并表示感谢!

由于作者的研究水平有限,书中难免存在不妥之处,恳请读者批评指正。

目 录

前言

第 1 章	复杂场景遥感图像处理分析方法	1
1.1	遥感图像增强处理方法	1
1.1.1	遥感图像去雾增强处理方法	4
1.1.2	遥感图像低照度增强处理方法	9
1.1.3	遥感图像去云层遮挡处理方法	16
1.2	遥感图像语义分割技术	18
1.2.1	语义分割技术	19
1.2.2	语义分割技术在遥感图像中的应用	23
1.2.3	遥感图像语义分割的典型应用场景与案例分析	26
1.2.4	遥感图像语义分割面临的挑战与解决方案分析	29
1.2.5	用于语义分割的深度学习架构分类	32
1.2.6	遥感图像语义分割的特殊性	35
1.2.7	遥感图像语义分割的应用场景拓展趋势	35
1.3	遥感图像目标检测方法	36
1.3.1	遥感图像目标检测的背景与意义	36
1.3.2	目标检测方法	37
1.3.3	基于 YOLO 模型的遥感图像目标检测方法	44
1.3.4	网络轻量化技术	46
	参考文献	49
第 2 章	多尺度自适应的遥感图像去雾方法	60
2.1	基于去雾 FFA-Net 模型分析	60
2.1.1	多尺度特征提取	61
2.1.2	ECA 机制	62
2.2	优化 FFA-Net 模型设计	63
2.2.1	多尺度自适应特征提取方法	63
2.2.2	损失函数	65
2.3	实验方案与结果分析	65
2.3.1	数据集设置	65

2.3.2	实验环境及参数初始化	66
2.3.3	评价指标	66
2.3.4	实验结果	67
2.4	本章小结	72
	参考文献	72
第3章	视觉感知的遥感图像低照度增强方法	74
3.1	基于低照度增强 SCINet 模型分析	74
3.1.1	伽马校正	75
3.1.2	像素注意力机制	75
3.2	优化 SCINet 模型设计	76
3.2.1	自适应伽马校正模块	76
3.2.2	像素注意力照明估计模块	77
3.2.3	损失函数	77
3.3	实验方案与结果分析	78
3.3.1	数据集设置	78
3.3.2	实验环境及参数初始化	79
3.3.3	评价指标	79
3.3.4	实验结果	80
3.4	本章小结	87
	参考文献	87
第4章	域自适应的遥感图像去云层遮挡方法	89
4.1	基于去云层遮挡 CTGAN 模型分析	89
4.2	优化 CTGAN 模型设计	92
4.2.1	域自适应云层检测模块	92
4.2.2	局部对比度鉴别器	93
4.2.3	损失函数	93
4.3	实验方案与结果分析	94
4.3.1	数据集设置	94
4.3.2	实验环境及参数初始化	95
4.3.3	评价指标	95
4.3.4	实验结果	96
4.4	本章小结	103
	参考文献	103
第5章	基于分形曲线与 UNet 3+的边界分割 FCUNet 模型	105
5.1	基于 UNet 3+模型和分形曲线的图像编码	106

5.1.1 双线性插值模块	107
5.1.2 分形曲线编码方案	108
5.2 基于 UNet 3+模型的遥感图像解码框架	112
5.2.1 处理多源多维特征图的汇聚层	112
5.2.2 分形曲线模块的解码方案	113
5.3 实验方案与结果分析	114
5.3.1 数据集设置	114
5.3.2 评价指标	115
5.3.3 实验结果	118
5.4 本章小结	123
参考文献	124
第 6 章 基于相似点模块与 U-Net 型框架的区域遮挡 SPENet 模型	125
6.1 基于 ResNet 遥感图像的高维特征编码	125
6.2 三支路并行网络结构设计	128
6.2.1 基于 FCUNet 模型的边界确定模块	128
6.2.2 基于相似点模块的区域像素分类	129
6.2.3 基于 U-Net 框架的语义分割解码方案	131
6.3 实验方案与结果分析	132
6.3.1 数据集设置	132
6.3.2 评价指标	132
6.3.3 实验结果	133
6.4 本章小结	138
参考文献	138
第 7 章 基于 SPENet 的全尺寸遥感图像语义分割	140
7.1 基于图像尺寸与模型适配的策略	140
7.1.1 遥感图像的裁切策略	141
7.1.2 遥感图像切片的推理及掩码图的拼接合并策略	144
7.2 实验方案与结果分析	145
7.2.1 数据集设置	145
7.2.2 评价指标	147
7.2.3 实验结果	148
7.3 本章小结	153
参考文献	153
第 8 章 基于感受野特性的遥感图像目标检测模型	155
8.1 基于聚类算法动态调整锚框以适应不同数据集的尺寸	155

8.2 基于感受野特性改进网络架构	156
8.2.1 多尺度上下文增强模块	158
8.2.2 基于注意力机制的特征提取层	159
8.3 实验方案与结果分析	161
8.3.1 对开源遥感图像数据集 DOTA 进行图像增强	161
8.3.2 实验环境及评价指标	162
8.3.3 消融实验	163
8.3.4 对比实验	164
8.4 本章小结	168
参考文献	168
第 9 章 基于中心相似度的小目标定位模型	170
9.1 基于 Wasserstein 距离计算样本中心相似度	170
9.1.1 小目标漏检问题分析	170
9.1.2 基于高斯分布映射检测框	171
9.2 利用 WIoU 损失函数对样本进行梯度分配策略	173
9.3 基于数据自适应平衡系数构建 WTW 损失函数	175
9.4 实验方案与结果分析	177
9.4.1 实验环境	177
9.4.2 消融实验	178
9.4.3 对比实验	179
9.5 本章小结	182
参考文献	182
第 10 章 基于全局通道剪枝的轻量化遥感图像目标检测模型	184
10.1 基于全局通道剪枝算法	184
10.2 构建轻量化的遥感图像目标检测模型	185
10.2.1 基于联合显著性重排网络结构	185
10.2.2 基于逐层连续贪婪剪枝策略确定最佳剪枝率	188
10.3 实验方案与结果分析	191
10.3.1 实验环境	192
10.3.2 验证剪枝损失预实验	193
10.3.3 剪枝对比实验	195
10.4 本章小结	199
参考文献	200

第 1 章 复杂场景遥感图像处理分析方法

复杂场景下(如云雾遮挡、光照不均、地形扭曲)的图像处理旨在解决真实环境中光照不均、遮挡物多、背景杂乱等情况下的图像分析难题。遥感图像增强技术在遥感科学领域中至关重要,提升遥感图像质量是遥感目标检测和识别等任务的基石。受外部环境因素影响,遥感图像质量下降的原因主要表现为雾霾导致图像模糊、夜间光照不足造成能见度低,以及云层遮挡影响地表信息完整性等。此外,在遥感图像中,复杂地物的边界易出现模糊粘连,区域阴影遮挡会降低图像分割精度,进而限制其在变化检测、道路网络提取等领域的广泛应用。复杂场景遥感图像处理技术可以通过消除环境干扰,增强细节还原能力,进而提升数据精度与可用性。

1.1 遥感图像增强处理方法

随着航空航天事业的飞速发展,遥感技术在军事、社会和科研等领域的应用日益广泛。作为获取地表信息的关键数据源,遥感图像在环境监测、资源调查、灾害评估和国土规划等方面具有不可替代的研究价值和应用潜力。伴随着工业化的发展,环境污染愈发严重,雾霾天气出现越来越频繁。雾霾现象是由空气中悬浮颗粒物对光的散射作用引起的,会导致遥感图像模糊。气溶胶颗粒的粒径分布和化学组成会直接影响散射特性,使得雾霾在不同波段下的衰减模型呈现显著差异,这进一步增加了图像复原的难度。在夜间或阴天情况下,光照不足降低了遥感图像的能见度,特别是在月相变化、城市灯光干扰或恶劣天气条件下,遥感图像不仅整体亮度不足,还会出现局部过曝与欠曝并存的现象,形成动态范围极高的复杂场景。雾霾天气和夜间低照度情况使得遥感目标检测和识别^[1]算法性能下降。此外,云层遮挡也是光学遥感图像常见的问题之一,多变的云层覆盖使得部分地表信息无法被有效地获取,严重制约了遥感在环境动态监测、土地利用管理、灾害应急响应等领域应用的发展。不同高度的云层具有不同的光学特性和时空变化规律,卷云轻薄但分布广泛,积云厚实且形态多变,这对去云处理提出了多样化的技术要求。在城市建设和土地规划^[2]方面,图像去雾方法可以通过消除遥感图像的白色雾霾,恢复图像原有的信息,更准确地展示楼房建筑和道路的实际情况,更好地协助政府部门进行城市建设和土地规划。例如,在高密度城市区域,去雾处理可以提高对建筑高度、轮廓和密度的判读精度,为城市通风廊道规

划、热岛效应评估提供数据支撑。在夜间光线较弱的情况下,通过低照度图像增强技术适当改变遥感图像的亮度和对比度,即使在夜间光照不足的情况下也能准确观察到建筑物、车辆等地表信息。新一代深度学习方法如 RetinexNet、KinD 等通过分解光照与反射分量,能够更好地保持影像的自然度和细节真实性,显著改善了道路照明识别、夜间经济活动监测等应用的精度。此外,遥感图像去云层遮挡技术的发展致力于重建被云层遮挡的区域,通过融合多时相或互补传感器信息,恢复缺失的地表数据,为农业监测、地表变化分析等提供更完整的信息支持。基于时间序列的分析方法可以利用不同时期的影像实现云下信息重建,而合成孔径雷达(synthetic aperture radar, SAR)与光学影像的融合技术能够克服纯光学方法的局限,实现全天候的地表观测,为相关部门获取更加全面的地表信息。因此,遥感图像增强处理技术具有重要研究意义。

目前,已有部分学者对图像增强进行研究,但随着科学技术的快速发展,现有的方法已经不足以满足新的需求。传统图像增强方法通常需要手动调整多个参数来适应不同的场景,这些方法往往基于简化的物理模型或经验假设,无法应对真实环境中多种退化因素交织的复杂情况。不同参数的选择会产生不同的图像增强效果,需要耗费大量的时间和先验知识进行参数调优。根据图像去雾大气散射模型原理,当大气光估计值和雾浓度等参数选择不合理时,去雾效果不佳。传统低照度图像增强方法在增强图像的同时可能会增强图像中的噪声,若采用固定的增强算法和参数,则无法根据图像的内容自适应地调整图像增强过程。传统去云层遮挡方法需要假设云层具有特定分布,无法适用不同类型的云层,当云层形状与假设不符时会产生伪影。传统去云层遮挡方法难以准确分离云层和背景,对背景中的细节或边缘进行过度处理,导致图像质量下降。当存在大面积云层遮挡时,传统去云层遮挡方法难以有效地去除云层,无法恢复出完整的地表信息。因此,遥感图像去雾、遥感图像低照度增强和遥感图像去云层遮挡仍存在研究价值。近年来,深度学习技术迅猛发展,极大地推动了图像处理领域的变革。作为一种模仿人脑神经网络结构的机器学习方法,深度学习通过构建多层非线性变换结构,能够从海量数据中自动学习具有判别性的特征表示,避免传统方法依赖人工设计特征和调整参数的局限性。特别是卷积神经网络(convolutional neural network, CNN)通过局部连接、权重共享和多层次特征提取等机制,能够有效地捕获遥感图像中的空间上下文信息,建立从退化图像到高质量图像的复杂非线性映射关系。在遥感图像增强任务中,基于 CNN、生成对抗网络(generative adversarial network, GAN)和自编码器(autoencoder, AE)等深度学习模型,能够有效地实现端到端的去雾、低光增强与云层去除,并在多项公开评测中表现出优越的性能。例如,去雾网络(DehazeNet)、特征融合注意力网络(feature fusion attention network, FFA-Net)等在去雾任务中实现了大气光与透射率的联合优化估

计；时空生成对抗网络(spatio-temporal generative adversarial network, STGAN)、云层生成对抗网络(cloud generative adversarial network, CloudGAN)等在云层去除中展现了强大的特征学习能力；而水下与低光照场景恢复(restoration of underwater and low-light scene)、低光照流(low-light flow, LLFlow)网络等最新方法在低光照增强方面取得了令人瞩目的效果。

目前深度学习方法广泛应用于图像增强任务，相比传统方法，深度学习方法能够实现自主学习特征表示，避免人工提取特征的复杂过程，有效地捕获遥感图像的高层次语义信息，提高图像清晰度、亮度和细节信息。然而，深度学习方法也面临一系列挑战。首先，深度学习方法对大规模高质量标注数据的依赖较强，而遥感图像的标注成本高、专业门槛高，限制了其在某些稀缺场景下的推广应用，特别是在罕见天气条件、特殊地物类型或突发灾害事件等场景下，获取足够数量和质量的训练样本极为困难。其次，模型训练依赖高性能计算资源，在边缘设备或算力有限的环境中难以实现实时处理。大型深度学习模型通常包含数百万甚至数十亿个参数，需要大量的图形处理单元(graphics processing unit, GPU)内存和计算时间，严重制约了在卫星端或地面站近实时处理的应用。此外，现有模型的可解释性仍有待提升，在处理极端退化或未知类型干扰时的泛化能力有限。黑箱特性使得模型决策过程难以理解，当遇到训练数据分布之外的样本时，可能出现不可预测的性能下降甚至完全失效。因此，尽管深度学习为遥感图像增强带来了新的突破，但如何进一步优化模型效率，降低数据依赖，提升跨场景泛化能力，仍是未来研究的重点。具体而言，需要从以下几个方向持续探索：①发展少样本/零样本学习范式，降低对标注数据的依赖；②设计轻量化的网络结构，适应边缘计算环境部署需求；③引入物理模型与先验知识，增强模型的可解释性和泛化能力；④构建多任务联合学习框架，实现多种退化因素的统一处理。技术发展路径表明，融合物理模型与数据驱动方法、发展轻量化网络结构及引入无监督或半监督学习策略，将是推动该领域向前发展的关键方向。Transformer、扩散模型等新兴架构在计算机视觉领域的成功应用，也必将为遥感图像增强注入新的活力，最终实现全天候、全地域获取高质量遥感信息的能力，如图 1-1 所示。




图 1-1 遥感雾霾图像、遥感低照度图像和遥感云层遮挡图像示例

1.1.1 遥感图像去雾增强处理方法

随着对地观测技术的飞速发展,高分辨率对地观测系统已成为重要的空间基础设施。遥感技术凭借其宏观性、综合性和周期性等特点,在资源调查、环境监测、城市规划、灾害评估与国防安全等领域发挥着不可替代的作用。根据欧洲航天局(European Space Agency, ESA)的统计结果,全球在轨运行的遥感卫星数量已超过 900 颗,每天产生超过 15TB 的对地观测数据,构成了名副其实的“数字地球”。

然而,在遥感传感器成像过程中,电磁波信号必须穿过厚厚的大气层,会受到大气条件的严重干扰,其中雾霾是最常见且影响最大的大气因素之一。世界气象组织(World Meteorological Organization, WMO)报告显示,全球超过 70%的主要城市区域每年经历超过 50 天的中度以上雾霾天气,在东亚和南亚地区,这一数字甚至超过 100 天。

雾霾是由大气中悬浮的多种微小颗粒物(如硫酸盐、硝酸盐、有机碳、粉尘等气溶胶颗粒)组成的气溶胶体系,其粒径通常为 $0.001\sim 10\mu\text{m}$ 。这些颗粒物对电磁波,特别是可见光波段($0.4\sim 0.76\mu\text{m}$)具有强烈的散射和吸收作用。米氏散射理论表明,当颗粒物的粒径与光波长相当时,散射效应最为显著,这正是雾霾影响成像质量的主要物理机制。这种相互作用导致遥感图像出现对比度显著下降、颜色失真、细节模糊、边缘特征弱化等退化现象,严重降低了图像的视觉质量和应用价值,具体影响表现在以下多个层面。

(1) 地物识别与分类困难。雾霾掩盖了地表物体的精细特征和轮廓,使人工判读和自动化目标检测(如车辆、船舶、建筑物)算法的准确率大幅下降。研究表明,在能见度低于 5km 的重度雾霾条件下,传统目标检测算法的精度可下降 40% 以上,误检率增加 35%,严重影响了城市规划、交通监控等应用的可靠性。

(2) 定量遥感失真。雾霾改变了地物反射率的真实值,导致基于遥感图像的定量反演出现系统性偏差。例如,在植被监测中,常用的归一化植被指数(normalized difference vegetation index, NDVI)在雾霾条件下会被严重低估,误差可达 30%~50%;在水环境监测中,叶绿素 a 浓度、悬浮物含量等关键水质参数的反演精度也会显著降低。

(3) 多时相分析失效。变化检测依赖于不同时期影像间的一致性,而雾霾的不均匀分布和变化使得在同一地区不同时间获取的影像缺乏可比性,严重影响了土地利用/覆盖变化监测、灾害评估等应用的准确性。

(4) 后续处理受阻。高质量的图像是进行图像分割、特征提取、三维重建等高级处理的前提。雾霾导致的图像质量退化会产生误差传递效应,直接降低这些后续处理任务的可靠性。

有效的去雾算法能够为各应用领域提供更可靠的数据基础。据估计，全球对地观测市场因数据质量问题导致的损失每年超过 5 亿美元，而先进的去雾技术可挽回其中约 30% 的损失。因此，遥感图像去雾增强不仅是为了提升图像的视觉直观效果，更是恢复地物真实物理属性，保障遥感信息提取准确性的关键预处理步骤，对充分发挥海量遥感数据的社会经济价值具有至关重要的意义。

近年来，大量学者正持续深入研究图像去雾技术，力求在这一领域取得新的突破与进展。去雾方法大致分为两种，一种是基于先验知识的去雾方法，主要通过利用大气散射模型和人工获取的先验知识实现去雾；另一种是基于深度学习的去雾方法，直接或间接地从大规模雾霾图像和清晰图像数据集中学习映射函数，达到去雾效果。图像去雾方法分类图如图 1-2 所示。




图 1-2 图像去雾方法分类图

1. 基于先验知识的去雾方法

在图像去雾任务中，基于先验知识的去雾方法是最早被提出和应用到实际的一类方法，为后续的图像去雾发展奠定了坚实的基础。基于先验知识的核心思路是基于图像统计规律和大气散射模型而提出的先验假设，结合优化技术来恢复出无雾图像。大气散射模型在计算机视觉领域和图像处理领域有着广泛的应用，如图 1-3 所示。在雾霾天气下拍摄照片时，相机被雾霾干扰，所接收到的光源就变成两个主要部分，第一部分是物体反射光，它在穿越雾霾层时受到颗粒物的衰减作用，再抵达相机；第二部分是大气光，由于光源的光线在经过雾霾层时发生散射现象，散射后的光线也会到达相机。因此，在雾霾天气下拍摄的照片，相机接收到的光线实际上是这两种光线的叠加效果。在数学上将大气散射模型进行推导，得到

$$I(x) = J(x)t(x) + A(1 - t(x)) \tag{1-1}$$

其中， $I(x)$ 是观测到的有雾图像在 x 位置的像素强度(观测亮度)； $J(x)$ 是希望恢复的无雾图像(场景真实辐射)； A 是全局大气光值(global atmospheric light)，通常假设为全局常量，代表无限远处大气的光强，通常取自图像中最亮区域的像素值； $t(x)$ 是透射率(transmission)，表示光线透过雾霾媒介到达相机的比例，它与

场景深度 $d(x)$ 和大气散射系数 β 有关; x 表示像素位置信息, 透射率 $t(x)$ 为

$$t(x) = e^{-\beta d(x)} \quad (1-2)$$

其中, $d(x)$ 表示场景深度; β 表示大气散射系数, 场景深度越大或雾越浓 (β 越大), 透射率 $t(x)$ 越小。




图 1-3 大气散射模型示意图

基于暗通道先验(dark channel prior, DCP)知识方法的原理是阴影区域至少存在一些颜色值接近 0 的像素, 这些接近于 0 的像素点组成了图像的暗通道。对于雾霾图像, 由于雾霾的存在, 即使是阴影区域的像素也会被加上一定的雾光强度, 使得像素值偏离 0。基于这一区别, 可以估计出雾霾图像中的光照传输率, 实现图像去雾, 该理论为

$$J^{\text{dark}}(x) = \min_{c \in \{r, g, b\}} \left(\min_{y \in \Omega(x)} (J^c(y)) \right) \quad (1-3)$$

传统基于手工先验的方法存在以下局限性: ①该类方法依赖的暗通道先验在天空、水面等明亮区域易失效, 泛化能力较差, 在不同地理和气象条件下表现不稳定; ②该类方法通常需要人工调整大量参数(如大气光值、雾保留因子等), 鲁棒性低且依赖专业经验; ③该类方法计算复杂度高, 如暗通道先验中的软抠图操作时间复杂度达 $O(N^3)$, 难以实现高分辨率遥感图像的实时处理; ④该类方法在恢复图像时易出现光晕、色偏、块效应等伪影, 尤其在浓雾或复杂场景中, 图像的物理真实性难以保证; ⑤该类方法的固定先验与参数缺乏自适应能力, 无法灵活应对不同雾霾类型与浓度, 需依赖大量人工干预。

2. 基于深度学习的去雾方法

当前,深度学习在图像去雾领域的方法主要分为两种,一种是将深度学习与大气散射模型相结合的方法,另一种是直接进行端到端的去雾方法。深度学习与大气散射模型相结合的方法是利用 CNN 预测透射率和大气光值,将其输入到大气散射模型中学习相关参数,利用得到的参数进行去雾。

深度学习与大气散射模型相结合的方法研究现状如下。Cai 等^[3]最早在 2016 年将 CNN 用于图像去雾任务,提出了 DehazeNet,该模型输入雾霾图像,输出透射率预测值,再依据大气散射模型进行雾霾去除。Li 等^[4]在 2017 年提出大气光学厚度网络(atmospheric optical depth network, AOD-Net)模型,通过一体化轻量级 CNN 重建去雾图像,其缺点是去雾场景受限制。Zhang 等^[5]提出联合鉴别器结构,进一步融合估计的透射图和去雾结果之间的结构信息。Zhang 等^[6]开发了暗通道模型,通过传输系数重新优化传输图,实现雾霾去除。杨勇等^[7]改进大气散射模型,精细化求取透射率,结合全变分模型保边抑噪的方法实现去雾。针对雾霾图像中雾霾不均匀的问题,杜漫飞等^[8]对不同区域的雾霾进行分割,再使用暗通道先验方法对已经分割的区域进行去雾。陈黎黎等^[9]利用多向自相关增强和局部灰度分布特征设计滤波模板,提出了一种快速无人机航拍图像去雾算法。郑新杰等^[10]通过设置失效点、计算大气光值、精细化透射率图,应用大气传输模型去除雾霾。此类方法在使用大气散射模型预测大气光值和透射率值时,无法完全反映真实世界中的复杂大气条件,因此会产生误差。深度学习模型在学习本身就存在误差的预测值时会产生误差叠加,导致去雾效果不佳。

端到端直接去雾的方法学习雾霾图像和清晰图像之间的映射关系,通过构建深度神经网络模型实现直接生成去雾图像的过程。这种方法不需要依赖大气散射模型,而是通过学习数据的内在特征和复杂的映射关系进行去雾,从而得到更理想的去雾效果。Li 等^[11]对条件生成对抗网络(conditional generative adversarial network, CGAN)进行优化,通过引入视觉几何组(visual geometry group, VGG)网络特征和正则化梯度先验实现去雾。针对训练数据集需要配对的约束限制,Engin 等^[12]提出循环去雾网络 Cycle-Dehaze,该网络通过将清晰图像和模糊图像以非配对的方式输入训练网络,摆脱了训练需要配对的数据集约束。Dong 等^[13]提出融合鉴别器,将频率信息用于附加的先验信息中以生成更高质量的去雾图像。Huang 等^[14]提出的 CGAN 结合了红绿蓝(red green blue, RGB)图像和 SAR 图像的信息来消除图像模糊。Yin 等^[15]提出了具有金字塔池化操作的编码器-解码器框架,还提出了一种新颖的并行空间通道注意力块,并将其应用于编码器的末端,引导解码器实现去雾。这些方法普遍存在的缺点是计算复杂度高。

使用 CNN 实现去雾的方法研究较为广泛。Chen 等^[16]在 2019 年提出全局上下文聚合网络(global context aggregation network, GCANet), 动态地聚合上下文信息实现去雾, 缺点是在处理雾霾不均匀的图像时效果较差。同年, Liu 等^[17]提出网格去雾网络(GridDehazeNet)用于减少去雾过程中产生的伪影, 后续提出增强型网格去雾网络(GridDehazeNet+)^[18], 引入网格结构和空间通道注意力块, 增强多尺度估计和特征融合能力, 从而实现去雾, 其缺点是模型复杂度高。Ren 等^[19]提出门控融合网络, 聚合上下文信息实现去雾, 其缺点是难以去除不均匀的雾霾。Xu 等^[20]提供了前景和背景的线索, 通过迭代使用去雾算子, 逐步去除雾霾。Mei 等^[21]通过直接学习雾霾图像到无雾图像的高度非线性转换函数实现去雾, 其缺点是会引入噪声。Dong 等^[22]提出多尺度增强去雾网络, 逐步输出去雾后的图像, 其缺点是会有雾霾残留。

针对现实去雾效果较差的问题, Shao 等^[23]将真实雾霾图像添加到模型训练中, 提高雾霾区域的自适应性, 达到去雾效果。为了解决模型复杂度高的问题, Hong 等^[24]采用知识蒸馏方法设计去雾网络, 通过教师网络对学生网络的指导, 实现轻量化去雾, 但是不能适用于其他场景。Wu 等^[25]挖掘雾霾图像和清晰图像的正负样本信息, 以达到更好的去雾效果。在遥感领域, Li 等^[26]提出了一种两阶段的去雾神经网络, 即特征协同传输与融合网络(feature collaborative transmission and fusion network, FCTF-Net), 该网络通过多尺度特征提取和结果细化来改善遥感图像的去雾效果, 其缺点是模型复杂度高。Huang 等^[27]提出去雾上下文恢复与细节增强网络(dehazing context recovery and detail enhancement network, DCRD-Net), 该网络能够去除遥感图像中的雾霾并恢复细节。Wang 等^[28]提出金字塔特征融合模块(pyramid feature fusion module, PFE), 利用来自不同 CNN 层的互补特征帮助进行去雾图像预测。Huang 等^[29]引入自过滤块来消除冗余特征, 改善学习特征的表征能力, 恢复出雾霾图像。Jin 等^[30]从预训练的自监督视觉 Transformer (self-supervised visual transformer, SiT)模块中提取特征表示以恢复背景信息, 引入了不确定性反馈学习, 关注非均匀的雾区域。基于不确定性地图, 反馈网络迭代地改进去雾输出, 其缺点是计算复杂度高。2020 年, Qin 等^[31]提出 FFA-Net 模型, 其缺点是在处理背景复杂的图像时难以恢复局部细节。Qiu 等^[32]提出一种新的变压器变体, 采用泰勒展开式来近似最大注意值, 设计多尺度注意细化模块作为纠正泰勒展开误差的补充, 并引入具有多尺度补丁嵌入的多分支架构, 通过不同尺度的重叠可变形卷积来嵌入特征, 达到去雾效果。Xie 等^[33]提出热红外引导彩色图像去雾算法, 利用热红外的区域对比度信息来指导彩色图像的对比度增强, 并在模型中引入颜色保真度约束, 其缺点是会产生噪声。表 1-1 为经典图像去雾方法的优势和劣势。

表 1-1 经典图像去雾方法的优势和劣势

方法	优势	劣势
AOD-Net ^[4]	训练速度快	特定场景去雾受限
DehazeNet ^[3]	推理速度快	颜色失真
GCANet ^[16]	细节恢复较好	难以去除不均匀雾霾
GridDehazeNet ^[17]	减少伪影	雾霾残留
FFA-Net ^[31]	色彩保真度高	去雾结果局部模糊

尽管深度学习在遥感图像去雾中取得了显著进展，但仍面临诸多挑战。首先，训练数据严重匮乏，真实成对数据难以获取，而基于物理模型的合成数据与真实图像之间存在域差异，导致模型泛化性能下降。其次，遥感图像尺度多样，涵盖从细粒度纹理到大型地物结构，要求模型具备多尺度感知与处理能力；同时，模型在不同地理环境或传感器类型(如从城市到山区)上泛化困难，气溶胶分布的复杂差异进一步加剧了这一挑战。此外，高计算复杂度模型(如Transformer)难以部署于卫星、无人机等边缘设备，且高分辨率图像(万级像素)对内存和算力要求极高。最后，深度学习方法的黑盒特性缺乏物理可解释性，限制了其在军事、灾害评估等高可靠性领域的应用，而真实场景中地面真实值(ground truth)的缺失也使得客观评估体系尚未完善。

未来研究将致力于通过多种前沿技术路线应对当前挑战。主要方向包括以下内容：①发展无监督与弱监督学习(如对比学习)，以降低计算机领域成对数据的依赖；②通过域自适应和迁移学习弥合成与真实数据间的域差异；③采用知识蒸馏与轻量化网络设计(如神经架构搜索)提升计算效率，满足边缘设备部署需求；④将物理模型嵌入网络结构或损失函数中以增强数据可解释性；⑤利用多模态数据(如 SAR、红外与高光谱影像)实现更鲁棒的图像恢复；⑥构建去雾-检测-分割的一体化联合学习框架，并建立面向遥感应用的标准化评估体系。

这些努力旨在推动去雾技术向数据高效、模型轻量、物理可解释且多模态融合的方向发展。未来，遥感图像去雾不仅能够提升图像的视觉质量，更将显著增强遥感数据的可用性和应用深度，为对地观测、环境监测、防灾减灾及可持续发展提供关键技术支持，成为解析“地球观测之眼”不可或缺的核心工具。

1.1.2 遥感图像低照度增强处理方法

随着对地观测技术的飞速发展与广泛应用，遥感成像技术已逐步从早期的单一可见光光学成像，演进为覆盖多时段、多谱段的综合对地观测体系。

然而，在夜间、黄昏、黎明或多云、雨雾等恶劣气象条件下，由于环境照度

极低, 成像传感器所接收的光子通量较日光条件下降 5~6 个数量级, 图像出现整体亮度不足、对比度大幅下降、噪声明显增强和色彩严重失真等一系列退化现象, 这些问题严重制约了影像的判读质量与信息自动提取能力, 限制了遥感数据在实际业务系统中的可用性。

为应对上述挑战, 低照度图像增强技术应运而生。该技术通过信号处理与机器学习等方法, 提升图像整体亮度、扩展动态范围、抑制传感器噪声并恢复真实色彩, 从而显著改善图像的视觉质量与可利用性。在多个应用领域, 该类技术正发挥着关键作用。例如, 在夜间城市监测中, 该技术可使灯光分布提取与建筑物识别的准确率提升 40% 以上; 在灾害应急响应中, 该技术能使灾情评估与救援调度的效率提升约 35%; 在极地科学考察、军事侦察、海上监视及公共安全等领域, 低照度图像增强也提供了不可或缺的信息支持。

据国际遥感市场分析报告, 预测有效的低照度图像增强技术有望将全球遥感数据的总体利用率提升 25% 以上, 年创造经济价值超过 3 亿美元。随着全球商业航天产业的蓬勃发展, 低照度遥感应用市场正以年均 15% 的速度快速增长, 对该类高性能图像处理技术的需求变得日益迫切。未来, 进一步融合人工智能、多源信息融合并实现传感器的技术突破, 使得低照度遥感图像增强能力持续提升, 为构建全球对地观测体系提供更加完整和高效的全天候信息获取能力。

目前, 由于部分工作需要夜间展开, 研究人员对于低照度图像增强的研究工作也愈发深入。在夜间和阴天光照不足的情景下, 卫星采集到的遥感图像亮度和对比度都偏低。低照度图像增强方法大致分为基于直方图均衡化 (histogram equalization, HE)、Retinex 理论、去噪和深度学习的低照度图像增强方法, 如图 1-4 所示。




图 1-4 低照度图像增强方法分类图