

基于深度学习的图像去噪技术研究与应用分析

马芸娟 马海英

西京学院机械工程学院 陕西西安 710100

摘要: 本文聚焦于基于深度学习的图像去噪技术, 深入探讨其核心原理、关键技术、应用场景及面临的挑战与应对策略。通过分析卷积神经网络、生成对抗网络等在图像去噪中的应用, 阐述其在提升图像质量方面的显著效果。同时, 结合医学影像、卫星遥感等领域的实际应用案例, 揭示深度学习图像去噪技术的广阔前景。最后, 针对数据标注、模型泛化等问题提出相应策略, 为该技术的进一步发展提供参考。

关键词: 深度学习; 图像去噪; 卷积神经网络; 生成对抗网络

在计算机视觉领域里, 图像质量直接影响后续图像分析、识别任务的准确性和可靠性。在图像采集过程中受传感器热噪声、光子散射噪声这些因素影响, 难免会带入噪声, 导致图像质量下降。传统图像去噪方法如均值滤波、中值滤波等处理复杂噪声时效果有限, 难以满足实际应用需求。而深度学习技术凭借其强大的特征提取和模式识别能力, 能自动学习噪声和信号之间的复杂映射关系, 有效去除噪声并保留图像细节, 给图像去噪领域带来了全新的解决思路和技术支持。

一、深度学习图像去噪的核心原理与关键技术

(一) 卷积神经网络的降噪机制

卷积神经网络(CNN)是深度学习里处理图像数据的经典模型。其通过局部感受野和权值共享这两个核心概念来捕捉图像的空间关联特性, 它实现降噪主要分为三个核心步骤: 特征提取、非线性映射和信号重建。在特征提取这一阶段, 卷积层利用可学习的滤波器组提取图像的多尺度特征, 初步把噪声和信号分离; 非线性映射阶段, 引入ReLU、LeakyReLU这类激活函数, 能让模型对复杂噪声模式的表达能力增强。信号重建阶段, 反卷积或者转置卷积层逐步完成上采样, 再结合跳跃连接技术把浅层细节和深层语义信息融合起来, 最终恢复出

高清图像。

(二) 生成对抗网络的对抗训练

生成对抗网络(GAN)由两个关键部分: 生成器和判别器组成, 其核心逻辑是零和博弈, 从而实现图像去噪。生成器以含噪图像为输入, 输出降噪结果, 核心目的是尽量让判别器分不清真假; 而判别器的主要作用是区分真实图像和生成器的输出, 为生成器提供梯度反馈。GAN模型靠对抗损失和L1损失这类像素级损失结合起来, 能保障图像的结构一致。在训练过程中, 生成器和判别器形成相互竞争、相互促进的关系, 越优化越完善, 最终生成器能够输出逼真度高的降噪图像。这种对抗训练的机制, 也让GAN在图像增强、超分辨率重建等领域具备应用潜力, 生成细节丰富的高质量图像。

(三) 自编码器与变分自编码器的特性

自编码器(AE)通过编码器把输入图像压缩成潜在特征表示, 再由解码器完成图像重建。在做图像去噪同时, 有效学习图像的关键特征并把噪声成分去除。变分自编码器(VAE)在自编码器的基础上, 加入概率分布的假设, 让潜在空间的鲁棒性更佳。编码器会输出均值和对数方差, 对潜在变量采样之后, 解码器再从这些潜在变量里重建图像, 同时通过KL散度来约束潜在空间的分布特点。VAE能生成多种不同的降噪结果, 尤其适合噪声分布复杂的场景。比如处理不同光照下产生的图像噪声时, VAE能更好地适应噪声的变化规律, 输出更精准的降噪图像。

(四) 多尺度特征融合与注意力机制的应用

为充分挖掘图像的多尺度信息, 进一步提升去噪效果, 多尺度特征融合技术现在在深度学习图像去噪里应

作者简介:

马芸娟(2001.4——), 女, 汉族, 山西运城人, 硕士在读, 西京学院, 研究方向: 模式识别与机器视觉。

马海英, 女, 汉族, 西京学院, 博士, 副教授, 研究方向: 机械工程领域的机械系统设计与状态监测; 机器人工程领域的机器人应用与人工智能。

用广泛。可以搭建不同尺度的特征提取模块，比如采用不同尺寸的卷积核或者金字塔结构，获取图像在不同尺度下的特征表示，再把这些特征融合后让模型既能捕捉图像的局部细节，也能把握全局结构。注意力机制引入了权重分配的思路，使模型重点关注图像里的关键区域和核心特征。在图像去噪过程中，注意力机制可以引导模型聚焦到噪声集中区域，提升区域的去噪效果，同时尽量保留图像细节。把多尺度特征融合和注意力机制结合起来，进一步优化深度学习图像去噪模型的综合性能。

二、深度学习图像去噪的应用场景与实际效果

（一）医学影像分析中的应用

医学影像分析在疾病诊断里占据重要位置，图像质量直接关系到临床医生的诊断决策。医学图像采集时，受设备噪声、患者运动等多种因素干扰，噪声问题普遍存在，而深度学习图像去噪技术正好给这一问题提供了有效的解决办法。在X射线图像去噪方面，这项技术的优势明显。X射线成像时，噪声导致病变部位模糊。深度学习模型通过学习学习配对数据，去除噪声后病变细节更清楚，帮助医生更准确判断病变的位置、大小和性质。在CT图像去噪中，深度学习技术的效果同样突出。CT成像过程中常见的伪影问题会拉低图像分辨率，影响诊断的准确性，深度学习模型能分析伪影产生的规律，有针对性地减少伪影的影响，提升图像分辨率。在复杂病情诊断中，高分辨率、低伪影的CT图像能让医生更仔细地观察器官结构与病变特征，进一步提升诊断准确率。

（二）卫星遥感图像处理中的应用

卫星遥感图像在资源勘探、环境监测、灾害预警等领域应用广泛，但因为成像距离远、受大气干扰等因素影响，图像容易出现噪声和模糊的问题。深度学习图像去噪技术，给提升遥感图像质量提供新的技术路径。在高分辨率遥感图像处理里，椒盐噪声和高斯噪声是比较常见的类型。深度学习模型通过学习大量含噪和干净的遥感图像样本，摸清噪声的分布规律，能精准去掉这两种噪声，恢复图像细节。超分辨率重建技术是深度学习在遥感图像处理里的另一大重要应用，其靠深度学习模型学习低分辨率和高分辨率图像之间的映射关系，把低分辨率遥感图像重建成交清晰的高分辨率图像。在农业领域，经去噪与超分辨率重建的遥感图像可监测作物长势及病虫害迹象，为农业生产提供科学指导。

（三）安防监控领域的应用

安防监控系统在城市安全维护和交通管理中起着必

不可少的作用，但监控图像在采集和传输过程中容易受到噪声干扰，进而影响监控效果。深度学习图像去噪技术，为提升监控图像质量给出了有效的解决办法。在夜间监控场景里，光照不足会让图像出现大量噪声，画面昏暗模糊。深度学习模型会针对夜间图像的特点，学习噪声和真实图像的特征差异，既能精准去掉噪声，又能提高图像亮度，处理后的图像能清晰展现监控场景的细节，帮助监控人员准确识别目标物体和行为。在交通监控中，车辆高速运动导致模糊与噪声，深度学习去噪结合去模糊算法可有效消除图像模糊和噪声，处理后的图像可以准确识别车辆类型、车牌号码等信息，还能支持分析车辆行驶轨迹和速度，为交通管理提供数据支撑。

（四）消费电子领域的应用

随着消费电子产品的普及，大家对图像质量的要求日益提高，深度学习图像去噪技术在这个领域应用广泛，显著提升了拍摄图像的质量。在智能手机摄像头里，深度学习算法能实时处理拍出来的图像，对于拍摄时因为环境光线、传感器这些因素产生的噪点和模糊问题，快速分析图像特征，专门去掉噪点、减少模糊，使照片看起来清晰细腻。在不同拍摄场景下，算法能自动调整参数，比如在光线暗的地方提升图像亮度和细节，光线强的地方避免照片过曝，保证照片质量稳定。数码相机借助深度学习去噪，动态范围与色彩还原度均可提升。

三、深度学习图像去噪面临的挑战与应对策略

（一）数据标注与获取难题及应对

深度学习图像去噪模型训练，需要依靠海量标注数据。但在实际应用时，想拿到高质量的标注数据面临不少现实问题。人工标注成本高，且易带主观误差。像医学图像这种特定领域，因为涉及患者隐私，数据获取受严格限制，想公开共享比较困难。要解决这个问题，数据增强技术发挥重要作用，通过对现有数据做旋转、缩放、翻转等操作，生成各种各样数据样本，丰富数据分布，让模型能更好地适应不同视角、不同尺度的图像，提升泛化性。自监督学习则是利用像素之间的关联性，通过设计特定的预任务，让模型自主学习提取图像特征、理解图像结构，无需大量标注数据就能建立目标和输入像素的映射关系，有效降低对标注数据的依赖。还有，建立公开的数据共享平台，能打破数据孤岛，促进研究机构和企业之间的数据交流合作。各方协同制定数据标准和规范，在保护隐私的前提下把分散的数据整合起来，建出大规模、高质量的图像数据集。

(二) 模型泛化能力不足及提升策略

深度学习图像去噪模型在训练集上通常表现良好,但面对新的噪声类型或图像场景时,泛化能力往往不足。不同场景下的噪声特性存在显著差异,导致模型难以适配所有应用情况。迁移学习技术能够有效提升模型泛化能力,利用在ImageNet等大型通用数据集上预训练的模型,此类模型已学习到丰富的图像特征,将其迁移至特定图像去噪任务时,保留部分网络结构并微调相关参数,既能加速模型收敛,又能借助通用特征提升模型对新场景的适应能力。设计通用噪声模型需结合信号相关噪声与成像物理机制,使模型在训练过程中接触更复杂的噪声场景,从而更好地适应不同类型与强度的噪声。多任务学习让模型同时学习多个相关去噪任务,如不同噪声水平、不同类型噪声的去除任务,模型在不同任务间共享特征表示,能够学习到更具通用性的特征,进而提高对不同场景的适应能力。

(三) 计算资源需求大及优化方法

深度学习图像去噪模型的训练与推理过程需要消耗大量计算资源,高性能GPU等硬件设备成本较高,而移动设备与嵌入式系统的资源有限,难以满足模型运行的需求。模型压缩技术能够有效减少计算资源消耗,剪枝技术通过去除模型中不重要的神经元或连接,减少参数数量,降低计算量;量化技术是将模型参数从高精度浮点数,转换为低精度整数。在保证模型性能基本稳定的前提下,减少存储与计算开销,同时让计算速度加快;知识蒸馏让大模型指导小模型,在保持性能的同时减少参数与计算量。MobileNet、ShuffleNet这些专门为移动和嵌入式设备设计的轻量级网络架构,MobileNet采用深度可分离卷积,将标准卷积分解为深度卷积与逐点卷积,显著减少计算量与参数数量;另外,分布式计算和云计算技术,能把训练和推理任务分到多个计算节点上,借助集群并行处理能力,加快训练与推理,减轻单设备压力,让资源有限的设备也能完成复杂的图像去噪任务。

(四) 真实噪声建模不准确及改进方向

真实噪声受多物理因素耦合,分布复杂,难以用具体参数描述清楚。所以,准确模拟真实噪声,是深度学习图像去噪要解决的关键难题。传统合成噪声模型基于简单分布假设,与真实噪声差异较大,导致模型处理真实噪声时效果不佳。改进的关键在于深入探究其产生机

制与分布特征,充分纳入传感器特性及光照、温度等成像环境因素,让模型贴近实用场景。

无监督学习可让模型自动挖掘数据内在特征,半监督学习结合少量标注与大量未标注数据,既明确学习方向又扩大数据规模,减少对合成噪声数据的依赖。融合物理模型与深度学习,融入物理先验知识,为模型提供约束指导,使学习到的映射关系更符合物理规律,提升处理准确性与鲁棒性。此外,引入跨场景噪声迁移学习技术,挖掘不同成像条件下噪声的共性特征,同时优化模型损失函数,增强模型对真实噪声复杂分布的适配能力,进一步提升去噪泛化性能。

结束语

深度学习图像去噪技术靠着强大的特征提取和模式识别能力,在提升图像质量上效果明显,现已经广泛应用于医学影像、卫星遥感、安防监控、消费电子等领域。不过,这项技术现在仍面临不少难题:数据标注和获取困难、模型的泛化能力不足、需要大量计算资源,以及真实噪声建模不够准确等。采用数据增强、迁移学习、模型压缩这些针对性方法,能有效解决这些问题,推动深度学习图像去噪技术继续发展。未来,随着技术不断创新完善,深度学习图像去噪技术有望在更多领域拓展应用场景,为人们的生产生活和社会发展带来更大的便利和价值。

参考文献

- [1] 刘迪, 贾金露, 赵玉卿, 等. 基于深度学习的图像去噪方法研究综述[J]. 计算机工程与应用, 2021, 57(07): 1-13.
- [2] 蒲秋梅, 沈林林, 田景龙, 等. 基于深度学习的低剂量CT图像去噪方法综述[J]. 中国体视学与图像分析, 2023, 28(04): 369-379. DOI: 10.13505/j.1007-1482.2023.28.04.005.
- [3] 郝昱权. 基于NSST与深度学习的红外图像与可见光图像融合算法[J]. 河北软件职业技术学院学报, 2024, 26(04): 12-17. DOI: 10.13314/j.cnki.jhbsi.2024.04.001.
- [4] 贺钰茹, 王方虎, 黄衍超, 等. 基于深度学习的超低计数全身PET图像去噪方法[J]. 分子影像学杂志, 2024, 47(09): 904-912.