

深度学习在磁共振图像超分辨率重建中的应用

于会昌¹, 刘士远²

1. 上海理工大学健康科学与工程学院, 上海 200093; 2. 海军军医大学附属长征医院放射诊断科, 上海 200003

【摘要】磁共振成像(MRI)是医学影像学中一项重要的非侵入性检查技术,受限于磁共振硬件设备和扫描时间,有些磁共振图像具有较低的空间分辨率;深度学习技术的兴起为解决MRI图像分辨率问题提供了新的途径。本研究首先概述了MRI图像超分辨率重建的背景;其次,深入探讨了在MRI图像超分辨率重建任务中,各种深度学习方法的应用,并对这些方法进行详细的分析,对每种算法的工作原理、优势及其在图像重建过程中的效能表现进行评估;最后,讨论了深度学习技术在MRI图像超分辨率重建中的关键挑战,并对未来研究趋势进行展望。

【关键词】磁共振成像;超分辨率重建;深度学习;神经网络;综述

【中图分类号】R318

【文献标志码】A

【文章编号】1005-202X(2024)10-1243-06

Application of deep learning in super-resolution reconstruction of magnetic resonance images

YU Huichang¹, LIU Shiyuan²

1. School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China; 2. Department of Diagnostic Radiology, Shanghai Changzheng Hospital, Naval Medical University, Shanghai 200003, China

Abstract: Magnetic resonance imaging (MRI) is a significant non-invasive diagnostic technique in medical imaging. Due to limitations in MRI hardware and scanning time, some MRI images have relatively low spatial resolution. The rise of deep learning technology offers a new approach to improve the resolution of MRI images. The study outlines the background of MRI super-resolution reconstruction, delves into the applications of various deep learning methods in MRI super-resolution reconstruction and offers a detailed analysis of these methods, evaluating their working principles, advantages, and performance efficiency in image reconstruction. Additionally, it also discusses the key challenges of deep learning technology in MRI super-resolution reconstruction, and provides prospects for future research trends.

Keywords: magnetic resonance imaging; super-resolution reconstruction; deep learning; neural network; review

前言

磁共振成像(Magnetic Resonance Imaging, MRI)是一种非侵入性、无辐射的医疗诊断工具,被广泛应用于疾病的诊断、评估和治疗,但由于各种原因(如仪器的物理限制、患者的移动、快速成像需求等),可能会产生低分辨率的图像,不利于早期疾病的检测以及精细结构的观察。超分辨率重建旨在从一个或多个低分辨率图像中恢复出一个高分辨率图像,在

许多领域都有广泛的应用,如卫星成像、摄影和视频处理等^[1-5],这为提高MRI图像的分辨率引导新的方向。对于图像的超分辨率重建,深度学习技术已超越传统技术,基于深度学习的MRI图像超分辨率重建技术不仅可以提升成像的空间分辨率,而且能缩短扫描时长,有助于减轻患者在扫描过程中的不适感^[6]。本研究综述了深度学习技术在MRI图像超分辨率重建领域的应用,并探讨了当前技术面临的挑战与未来的发展趋势。

1 深度学习技术与超分辨率重建

深度学习通过模拟人脑的工作方式来学习数据的内在规律和表示层次,以解决复杂的问题^[7]。图1展示了深度学习的工作流程,通过构建包含多个隐藏层的神经网络来实现。这些隐藏层可以自动学习输入数据的特征^[8]。深度学习已在语音识别、计算机

【收稿日期】2024-03-04

【基金项目】国家自然科学基金(81930049)

【作者简介】于会昌,硕士,研究方向:医学图像处理、磁共振图像优化, E-mail: xyuzai0226@163.com

【通信作者】刘士远,博士,教授,研究方向:慢性阻塞性肺疾患的功能影像学、人工智能在医学影像学中的应用, E-mail: cjr.liushiuyuan@vip.163.com

视觉等领域显示出强大的性能,将深度学习技术引入超分辨率重建领域也成为一种必然的发展趋势。




图1 基于深度学习的MRI图像超分辨率重建

Figure 1 Deep learning-based super-resolution reconstruction of magnetic resonance image

在图像超分辨率领域的研究中,最早的研究是应用卷积神经网络(Convolutional Neural Networks, CNN)。Dong等^[9]设计了一个端到端模型(Super-Resolution CNN, SRCNN),通过对低分辨率图像进行特征提取和非线性映射,实现低分辨率图像到高分辨率图像的重建,结果证明深度学习技术在图像超分辨率重建领域中的可行性和有效性。Wang等^[10]首次将深度学习技术应用于MRI图像快速重建,旨在提升图像质量并缩短数据采集时间,标志着深度学习在医学成像领域的应用迈出了重要的一步。

2 深度学习技术在MRI图像超分辨率重建中的应用

2.1 基于深度CNN的MRI图像超分辨率重建

基于深度CNN的MRI图像超分辨率的研究发展经历了传统算法与深度学习相结合的阶段,突显了两者的相互补充的优势。传统重建算法通过数学模型和信号处理技术在MRI图像超分辨率重建中发挥关键作用;然而,随着数据量的增加和深度学习算法的成熟,研究者们逐渐认识到深度学习的潜力,深度学习模型能从大规模数据中学到复杂的特征表示,对非线性关系进行建模,并在超分辨率重建等任务中取得显著的性能提升。Yang等^[11]融合ADMM(Alternating Direction Method of Multipliers)算法与CNN,将ADMM的迭代过程转化为网络的层数,将ADMM的超参数转化为网络中的可学习参数,通过将原问题分解为多个子问题,并以交替迭代的方式求解,有效地降低计算复杂度;利用CNN的并行计算能力,加速重建过程,提高重建效率;在MRI图像重建中通过引入先验信息和约束条件,提高重建质量并减少伪影,使得重建图像更清晰和准确。Cheng等^[12]提出PD-Net(Primal Dual Network),将原始对偶混合梯度算法^[13]的迭代过程展开为可学习的深度网

络架构,通过深度学习的优势提高图像重建的质量和准确性,利用深度网络中的卷积层和全连接层来更新原始变量和对偶变量,并通过激活函数来更新约束,逐渐放宽约束以重建高度欠采样k空间数据的MRI图像。传统算法的稳健性和理论基础为深度学习提供指导和启示,而深度学习则通过端到端学习的方式更好地适应实际复杂性,这种协同作用能充分利用传统方法的经验和深度学习的数据驱动优势,取得在MRI图像超分辨率重建等任务上的显著进展。

随后的研究中,深度学习技术以其能从大规模数据中学到非线性特征表示、端到端学习以及对复杂关系的高度适应性脱颖而出。Qiu等^[14]提出一种创新的膝部MRI图像超分辨率重建方法,通过结合SRCNN和高效子像素卷积网络(Efficient Sub-Pixel CNN, ESPCN)的技术特点,构建一个既快速又能高效处理图像的深度学习框架,其核心思想在于利用SRCNN的强大学习能力来捕获图像中的细节信息,同时借助ESPCN的高效子像素卷积层精确地提升图像的分辨率,而不是单纯放大图像尺寸。这种方法能确保重建后的图像在视觉上更接近于高分辨率的真实图像,特别是在复杂的膝关节区域可以保持较好的细节和边缘的清晰度;在重建过程中,通过精简网络参数和优化计算流程,减少训练时间和资源消耗,有效提高处理速度,这对于临床应用而言具有极为重要的意义。更深层次的网络模型能提高超分辨率性能,残差学习成为深度模型的必要结构,其必要性体现在解决梯度消失问题、促进可解释性、特征重用以及加速训练过程,使得更深的神经网络能更好地捕捉特征和模式。Muhammad等^[15]提出一种基于Inception-ResNet^[16]的MRI图像超分辨率网络,通过使用去卷积层代替双三次插值作为上采样方法,并引入残差跳跃连接与Inception块相结合来重建高分辨率输出图像。通过将Inception模块和残差网络结合,优化超分辨率过程,克服传统CNN方法在放大低分辨率MRI图像时引入额外噪声和内存消耗的问题。实验结果表明,该方法在重建清晰度和纹理细节方面优于现有技术,提供了一种有效的医学图像超分辨率解决方案。Zhu等^[17]提出一种基于残差密集网络的MRI图像超分辨率方法,引入多残差块来处理深度网络的退化问题,并通过短跳跃连接和长跳跃连接来提高图像特征信息的获取准确性,利用深层网络结构捕获图像中的丰富局部特征,并通过残差学习机制有效地恢复高分辨率图像细节,这种方法特别关注于如何从低分辨率图像中提取深层次的、复杂的特征,并利用这些特征恢复出高质量的高

分辨率图像,尤其适用于医学图像的精细化重建,如MRI或CT图像。由于密集连接和残差学习的设计,该算法能更好地保留图像的细节和结构信息,显著提高重建图像的质量;此外,尽管深层网络可能增加计算量,但通过优化网络结构和训练策略,可以在一定程度上平衡重建时间和资源消耗,不过,高效实施这一算法需要较高的计算资源,这在一定程度上限制了其在资源受限环境下的应用。Datta等^[18]提出一种基于深度反投影网络(Deep Back-Projection Networks, DBPN)和生成对抗网络(Generative Adversarial Network, GAN)的结合,专注于 T_1 加权对比增强病理脑MRI图像的超分辨率技术。该算法通过利用DBPN的深层特征提取能力和GAN的生成能力,综合利用多种损失函数,有效地提高图像的分辨率和感知质量,同时引入归一化谱能量(Normalized Spectral Energy, NSE)作为一种新的诊断信息失真测量参数,确保重建图像在维持高空间精度的同时保留重要的诊断信息。实验结果表明,该方法在细节、边缘和诊断信息的保留方面优于现有方法。

基于CNN的方法在MRI图像超分辨率重建任务中能显著提高图像的视觉质量和解剖学细节的可见性,有效地捕获医学图像中的局部和全局特征,并在重建过程中保留重要的结构信息,从而生成更清晰和准确的图像。

2.2 基于GAN的MRI图像超分辨率重建

GAN是一种包括生成器和判别器的深度学习架构,通过对抗性训练生成逼真的数据样本。GAN应用于高分辨率MRI图像生成,可以提高图像质量、减少噪声、保留细节,有助于改善医学影像分析^[19]。

Ledig等^[20]提出一种使用GAN进行图像超分辨率重建的方法,通过采用深度残差网络与GAN相结合的方法,在重建高分辨率图像时恢复照片级的真实纹理。其提出了一种基于感知的损失函数,结合对抗损失和内容损失,旨在推动解决方案更接近自然图像的流形,这为GAN在图像超分辨率领域的应用提供基本思路。损失函数在GAN中起着关键的作用,它们定义了模型优化的目标,从而影响生成器和判别器的学习过程;生成器的目标是通过最小化生成样本与真实样本之间的差异来学习生成逼真的数据,不同的损失函数可以强调不同方面,如均方误差损失可用于生成连续型数据,而对抗性生成网络通常采用对抗损失,使生成样本难以被判别器区分;判别器的训练目标也受损失函数选择的直接影响,判别器的任务是准确地区分生成样本和真实样本,因此其损失函数通常被设计为最大化这种区分度。在MRI图像超分辨率领域中,Mardani等^[21]提出

GANCS(GAN Compressive Sensing)方法,通过采用最小二乘GAN(Least Squares GAN, LSGAN)以及像素级L1损失的混合损失,显著提升重建MRI图像的质量。混合损失的策略旨在充分利用LSGAN对生成图像的全局一致性建模和像素级L1损失对局部细节精细控制的优势,LSGAN被引入以取代传统的对抗损失,其平滑的生成器建模有助于减轻模式崩溃等问题,从而提高生成图像的整体质量;与此同时,像素级L1损失强调了生成图像与真实图像之间的细微差异,特别是在图像的局部区域,使得生成图像更真实且保留重要的细节信息。该方法通过深度学习模型的能力,从低分辨率的 k 空间数据中重建出高分辨率的图像,大幅度减少MRI图像的重建时间,重建得到的图像在保持细节和边缘信息方面表现出色,相比传统方法能提供更准确的空间信息,由于其高度的泛化能力,可以应用于各部位的MRI图像重建,包括但不限于脑部、心脏和腹部等。Gu等^[22]提出MedSRGAN(Medical Images Super-Resolution GAN),引入多任务损失函数,其中包括内容损失、对抗损失和对抗特征损失。内容损失通过最小化生成图像与目标图像之间的内容差异,模型被鼓励学习保留关键的结构和特征,从而提高超分辨率图像的可靠性;对抗损失以最大化生成图像与真实图像之间的差异,有助于超分辨率模型生成更真实、更自然的图像,从而提高可行性和视觉质量;对抗特征损失通过比较生成图像和真实图像在判别器中间层的特征表示,引导生成器学习更具有真实感的图像结构。这种多层次损失函数的结合能在训练过程中同时优化不同方面,为超分辨率图像生成任务提供更全面的引导。通过对242个胸部CT扫描和110个脑部MRI扫描的训练和评估,MedSRGAN不仅保留了更多的纹理细节,还在重建的高分辨率图像上生成了更真实的模式,表明使用该超分辨率方法能在临床获取的低分辨率图像如低剂量CT、低磁场MR和MR波谱成像中检索更多的图像细节,值得进行更深入的研究以评估其重建性能。

在 K 空间融合领域, Lee等^[23]提出的CollaGAN(Collaborative GAN)采用跨域GAN的思想,其中包括多个生成器和多个判别器,这些生成器和判别器的设计允许模型同时处理多个数据域的信息,通过引入全面的周期一致性概念,图像在经过生成器和判别器的循环迭代后,能回到原始数据域,确保在不同数据域之间生成的图像保持一致性。对于MRI图像重建, CollaGAN可以同时处理不同扫描序列或不同磁场强度下的MRI图像,更全面地利用不同数据域的信息,提高重建图像的质量和准确性。

Narnhofer等^[24]的InverseGAN同时处理了K空间和图像空间的正向和反向映射,其独特之处在于其能在K空间和图像空间之间进行双向的映射,这意味着该模型不仅能从K空间到图像空间执行正向映射,还能执行反向映射,这样的设计使得模型能更全面地理解和学习图像与K空间之间的关系,为周期一致性学习提供有力支持。

2.3 基于注意力机制的MRI图像超分辨率重建

注意力机制模拟人认知过程中的“注意力”,允许模型在处理数据时集中关注重要信息,实现更精确的预测和处理^[25]。在MRI图像超分辨率重建中,注意力机制可用于加强感兴趣区域、抑制噪声和自适应分辨率调整,提高医学影像的质量和准确性。

结合GAN和注意力机制可以增强模型的感知能力,提高生成结果的质量。He等^[26]提出一种基于深度注意力GAN的MRI图像超分辨率方法,引入深度监督和注意力机制,以实现端到端的编码和解码学习。算法的核心思想是利用深度学习网络预测和补全在采样过程中遗漏的K空间数据,通过这种方式加速图像的获取过程,同时尽量保持图像的高空间分辨率和质量,其在适用部位方面具有较好的通用性,可应用于脑部、腹部等多个部位的MRI图像重建,但其性能可能受到特定应用场景的限制,如对于特定类型的疾病或特殊的成像需求,可能需要进一步调整模型参数或设计特定的网络结构。Song等^[27]提出一种基于通道注意力机制的GAN,旨在提高脑胶质瘤MRI图像分辨率。算法通过引入基于通道注意力机制的残差密集块来增强网络对图像细节的学习能力,同时采用相对平均判别器来提高生成图像的质量,加入均方误差损失以优化训练过程。这种方法在重建脑胶质瘤MRI图像时,能在提高分辨率的同时保持较高的空间精度,对于揭示肿瘤的精细结构非常有益。这一方法相比于现有技术,显著提升图像的清晰度和细节表现,能更好地辅助医生进行脑胶质瘤的检测与分级。尽管重建时间和资源消耗相对较高,但考虑到其在提高诊断准确性方面的潜在价值,这种投入也是合理的。此外,该方法在不同部位和不同类型的脑胶质瘤MRI图像重建中均表现出良好的适用性和稳定性,显示了广泛的应用前景。

Transformer在低层视觉任务中的优势在于其自注意力机制(Self-Attention Mechanism, SAM),为模型提供全局感知能力,能捕捉图像中像素之间的长距离依赖关系^[28]。这种全局性的关注机制为处理复杂的图像场景提供优势,有助于更好地理解上下文信息。另外,与传统的CNN不同,Transformer的可扩

展性使其能处理不同尺寸和分辨率的输入,为各种计算机视觉任务提供灵活性。Feng等^[29]首次将Transformer应用于MRI图像重建,提出一个名为MTrans(Multi-Modal Transformer)的用于加速多模态MRI的统一变换器框架,其核心思想是通过融合不同模态的特征图,学习多模态MRI图像的全局信息,从而获得更高质量的重建图像并显著减少伪影,适用于多种部位的MRI,可以用于不同的模态和病灶类型,能有效地处理多模态图像的特征融合和重建任务,提供一种全局信息学习的方法,为医学影像领域的研究和临床应用提供有力的工具。Liang等^[30]基于Swin Transformer的图像恢复方法,通过融合CNN和Transformer的优点,结合局部注意力机制和长程依赖建模,能同时处理图像的全局和局部信息,从而提高图像恢复的质量和准确性。该方法具有较好的可扩展性和适应性,适用于不同类型的图像恢复任务,为图像恢复任务提供一个强大的基线模型。随后,Huang等^[31]将Swin Transformer应用于MRI图像重建。在MRI图像重建中,传统方法需要耗费大量的时间和资源;而Swin Transformer通过利用移位窗口多头SAM,可以在保持图像细节的同时提高重建速度。移位窗口机制可以将图像分割成多个窗口,并通过SAM来关注窗口之间的关系,从而减少计算量并提高效率。采用多通道损失函数考虑不同特征通道之间的差异,从而更好地保持图像细节;另外,使用灵敏度图可以帮助模型更好地理解图像中的细节信息,并在重建过程中进行更准确的调整。Huang等^[32]提出一种包括反馈网络和SAM的重建方法;反馈网络通过循环神经网络,校正浅层特征并生成更多细节信息;SAM被整合到反馈网络中,用于提取重要信息以促进图像层次化,实现脑部MRI图像超分辨率重建,适用于脑部病变的诊断和治疗。反馈网络和SAM这些复杂的算法需要较长的重建时间和较高的计算能力,因此,在实际应用中,需要考虑计算资源的限制和硬件设备的支持。由于MRI图像对于脑部软组织的成像效果较好,因此该方法可以在脑部疾病的诊断和治疗中发挥重要作用。

这些研究表明通过在网络中嵌入注意力机制,可以更好地捕捉MRI图像中的局部特征,并在生成过程中更好地保留细节,这对于提高超分辨率图像的感知质量和临床可用性具有显著的影响;此外,注意力机制还有助于减轻对图像全局信息的过度依赖,使得模型更具鲁棒性,能适应不同的MRI场景和病例。

3 目前的挑战与发展趋势

3.1 目前的挑战

3.1.1 图像标注质量问题 MRI图像超分辨率重建的深度学习方法极大地依赖于大量、高质量的训练数据,准确的标签通常需要经验丰富的放射科医生进行手动标注,这个过程不仅耗时而且成本高昂。由于MRI图像的复杂性和细微差别,即使是专业人士也可能在标注过程中产生主观性差异,从而影响训练数据的一致性和可靠性^[33]。因此,可用于训练和验证深度学习模型的高质量数据集相对稀缺,如何有效利用有限的的数据,甚至是少量的标注数据,仍然是一个亟待解决的问题。

3.1.2 深度学习模型的泛化能力 MRI图像的特点多种多样,且不同机器、不同参数设置下获取的图像有很大差异^[34]。训练出的深度学习模型需要具备强大的泛化能力,这意味着它能适应来自不同MRI扫描机器、不同患者群体,甚至不同操作条件下的数据,从而处理各种不同的图像特性。因此,提升网络的泛化能力,使其在真实世界的临床应用中更为可靠,是一个亟待攻克的难题。

3.1.3 深度学习模型的可解释性 深度学习模型通常被视为“黑箱”,难以解释其内部决策过程,即模型的内部工作机制对于用户来说是不透明的^[35],这种挑战在多个层面上影响着深度学习模型的应用和信任度。在医学应用中,了解模型的决策基础是至关重要的。如何提高深度学习模型的透明性和可解释性也是未来研究的一个重要方向。

3.1.4 深度学习模型的可信度 在医学影像处理中,误诊可能带来严重的后果,深度学习模型的可信度和安全性是一个至关重要的问题。如何确保模型在各种情况下都能稳定可靠地工作,同时保护患者隐私,确保医学数据的安全性也是一个亟待解决的挑战。

3.2 未来发展趋势

3.2.1 强化学习与深度学习结合 强化学习具有探索未知领域和优化决策的能力,可以被引入到MRI图像超分辨率重建中。未来的研究可以探索将强化学习与深度学习相结合,设计更智能、自适应的超分辨率模型,以适应不同临床场景的需求。

3.2.2 多模态信息融合 MRI图像通常包含多个模态如 T_1 加权、 T_2 加权等^[36]。将多模态信息融合到深度学习模型中,可以提供更全面、准确的信息,增强模型的性能。未来的研究可以探索多模态信息的有效融合方法,以及如何更好地利用这些信息进行训练和推理。

3.2.3 自监督学习和无监督学习 自监督学习和无监督学习是深度学习中的热门研究方向,其核心思想是利用数据本身的特点进行训练,而无需依赖大量标注数据^[37]。未来的研究可以探索在MRI图像超分辨率重建中如何利用自监督学习和无监督学习的方法,降低对标注数据的依赖,提高模型的可用性。

3.2.4 探索新的深度学习算法 提高深度学习模型的可解释性和透明性是未来研究的一个重要方向,可以探索新的算法和方法,使深度学习模型的决策过程更透明,同时提供可靠的解释,使医生和临床工作者能更好地理解模型的输出结果,增加对模型的信任。医学图像处理和深度学习技术本身就是一个跨学科的研究领域。未来的研究可以借鉴计算机视觉、机器学习、数学等领域的最新研究成果,引入新的理论和方法,为MRI图像超分辨率的发展注入更多创新的思路和可能性。

4 总结

深度学习在MRI图像超分辨率重建领域的发展为医学诊断和治疗提供了更准确、更高质量的图像数据。本研究深入总结了基于深度学习的MRI图像超分辨率重建领域的研究进展,提供了对于深度学习方法在提高MRI图像质量方面潜在优势和挑战的全面认识。未来的研究将不断推动MRI图像重建技术的创新,以满足医疗领域对高质量MRI图像的需求。

【参考文献】

- [1] Wu CY, Wang D, Bai YP, et al. HSR-diff: hyperspectral image super-resolution via conditional diffusion models [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2023: 7060-7070.
- [2] Zhang MJ, Zhang C, Zhang QM, et al. ESSAformer: efficient transformer for hyperspectral image super-resolution [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2023: 23016-23027.
- [3] Ma JQ, Liang ZT, Xiang WM, et al. A benchmark for Chinese-English scene text image super-resolution [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2023: 19395-19404.
- [4] Chen YH, Chen SC, Chen YH, et al. MoTIF: learning motion trajectories with local implicit neural functions for continuous space-time video super-resolution [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2023: 23074-23084.
- [5] Tuo ZX, Yang H, Fu JL, et al. Learning data-driven vector-quantized degradation model for animation video super-resolution [C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2023: 13133-13143.
- [6] Chen YT, Schönlieb CB, Liò P, et al. AI-based reconstruction for fast MRI-a systematic review and meta-analysis [J]. Proc IEEE, 2022, 110 (2): 224-245.
- [7] Narayan V, Awasthi S, Fatima N, et al. Deep learning approaches for human gait recognition: a review [C]//2023 International Conference on Artificial Intelligence and Smart Communication (AISIC). Piscataway, NJ, USA: IEEE, 2023: 763-768.

- [8] Li Q, Peng H, Li JX, et al. A survey on text classification: from traditional to deep learning[J]. ACM Trans Intell Syst Technol, 2022, 13(2): 31.
- [9] Dong C, Loy CC, He KM, et al. Image super-resolution using deep convolutional networks[J]. IEEE Trans Pattern Anal Mach Intell, 2016, 38(2): 295-307.
- [10] Wang SS, Su ZH, Ying L, et al. Accelerating magnetic resonance imaging *via* deep learning [C]//2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI). Piscataway, NJ, USA: IEEE, 2016: 514-517.
- [11] Yang Y, Sun J, Li HB, et al. Deep ADMM-net for compressive sensing MRI[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Red Hook, NY, USA: Curran Associates Inc., 2016: 10-18.
- [12] Cheng J, Wang HF, Ying L, et al. Model learning: primal dual networks for fast MR imaging[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Cham: Springer International Publishing, 2019: 21-29.
- [13] Chambolle A, Pock T. A first-order primal-dual algorithm for convex problems with applications to imaging[J]. J Math Imaging Vis, 2011, 40(1): 120-145.
- [14] Qiu DF, Zhang SX, Liu Y, et al. Super-resolution reconstruction of knee magnetic resonance imaging based on deep learning [J]. Comput Methods Programs Biomed, 2020, 187: 105059.
- [15] Muhammad W, Bhutto Z, Masroor S, et al. IRMIRS: inception-ResNet-based network for MRI image super-resolution[J]. Comput Model Eng Sci, 2023, 136(2): 1121-1142.
- [16] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning[C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence. AAAI Press, 2017: 4278-4284.
- [17] Zhu DM, Qiu DF. Residual dense network for medical magnetic resonance images super-resolution[J]. Comput Methods Programs Biomed, 2021, 209: 106330.
- [18] Datta S, Deka B, Dandapat S, et al. Enhancement of diagnostic information in T₁-weighted contrast enhanced MRI using deep back-projection based super-resolution[C]//2022 IEEE 19th India Council International Conference (INDICON). Piscataway, NJ, USA: IEEE, 2022: 1-6.
- [19] Terada Y, Miyasaka T, Nakao A, et al. Clinical evaluation of super-resolution for brain MRI images based on generative adversarial networks[J]. Inform Med Unlocked, 2022, 32: 101030.
- [20] Ledig C, Theis L, Huszár F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 105-114.
- [21] Mardani M, Gong EH, Cheng JY, et al. Deep generative adversarial neural networks for compressive sensing MRI[J]. IEEE Trans Med Imaging, 2019, 38(1): 167-179.
- [22] Gu YC, Zeng ZT, Chen HB, et al. MedSRGAN: medical images super-resolution using generative adversarial networks[J]. Multimed Tools Appl, 2020, 79(29): 21815-21840.
- [23] Lee D, Kim J, Moon WJ, et al. CollaGAN: collaborative GAN for missing image data imputation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 2482-2491.
- [24] Narnhofer D, Hammernik K, Knoll F, et al. Inverse GANs for accelerated MRI reconstruction[C]//Wavelets and Sparsity XVIII. Bellingham, WA, USA: SPIE, 2019: 111381A.
- [25] Guo MH, Xu TX, Liu JJ, et al. Attention mechanisms in computer vision: a survey[J]. Comput Vis Media, 2022, 8(3): 331-368.
- [26] He XX, Lei Y, Fu YB, et al. Super-resolution magnetic resonance imaging reconstruction using deep attention networks[C]//Medical Imaging 2020: Image Processing. Bellingham, WA, USA: SPIE, 2020: 113132J.
- [27] Song ZY, Qiu DF, Zhao XQ, et al. Channel attention generative adversarial network for super-resolution of glioma magnetic resonance image[J]. Comput Methods Programs Biomed, 2023, 229: 107255.
- [28] Ma T, Wang WW, Chen Y. Attention is all you need: an interpretable transformer-based asset allocation approach[J]. Int Rev Financ Anal, 2023, 90: 102876.
- [29] Feng CM, Yan YL, Chen G, et al. Multimodal transformer for accelerated MR imaging[J]. IEEE Trans Med Imaging, 2023, 42(10): 2804-2816.
- [30] Liang JY, Cao JZ, Sun GL, et al. SwinIR: image restoration using Swin transformer [C]//2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Piscataway, NJ, USA: IEEE, 2021: 1833-1844.
- [31] Huang JH, Fang YY, Wu YZ, et al. Swin transformer for fast MRI[J]. Neurocomputing, 2022, 493: 281-304.
- [32] Huang Y, Wang WQ, Li M. FNSAM: Image super-resolution using a feedback network with self-attention mechanism[J]. Technol Health Care, 2023, 31(S1): 383-395.
- [33] Wang J, Zhu HD, Wang SH, et al. A review of deep learning on medical image analysis[J]. Mobile Networks Appl, 2021, 26(1): 351-380.
- [34] 罗明芳, 孙振博, 荣康, 等. 定量磁共振成像技术原理及研究进展[J]. 分子影像学杂志, 2020, 43(4): 572-576.
- [35] Luo MF, Sun ZB, Rong K, et al. Principle and research progress of quantitative magnetic resonance imaging[J]. Journal of Molecular Imaging, 2020, 43(4): 572-576.
- [36] Paudel D, De Wit A, Boogaard H, et al. Interpretability of deep learning models for crop yield forecasting[J]. Comput Electron Agric, 2023, 206: 107663.
- [37] Kotian RP, Koteswar P. History and basic principles of magnetic resonance imaging[M]//Kotian RP, Koteswar P. Diffusion tensor imaging and fractional anisotropy: imaging biomarkers in early Parkinson's disease. Singapore: Springer Nature Singapore, 2022: 1-18.
- [38] Le-Khac PH, Healy G, Smeaton AF. Contrastive representation learning: a framework and review[J]. IEEE Access, 2020, 8: 193907-193934.

(编辑:谭斯允)