



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象学报 中国图形学报

2022
03
VOL.27

ISSN1006-8961
CN11-3758/TB



医学图像及临床应用



第27卷第3期（总第311期）
2022年3月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian | Monthly, Started in 1996


Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn


Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ


国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



慢阻肺患者CT图像中肺内血管分割及定量分析(第0762页)



基于特征选择与残差融合的肝肿瘤分割模型(第0838页)



面向乳腺超声计算机辅助诊断的两阶段深度迁移学习(第0898页)

专刊封面展示了上海科技大学生物医学工程学院和上海联影智能医疗科技有限公司合作的脑影像智能分析方向研究成果。

《中国图象图形学报》医学图像及临床应用专刊简介

沈定刚, 刘天明, 周涛, 夏勇, 白相志, 王乾, 李刚, 徐寿平, 刘昊, 韩向娣 0653

综述

中国医学影像人工智能20年回顾和展望

蒋希, 袁奕宣, 王雅萍, 肖振祥, 朱美芦, 陈泽华, 刘天明, 沈定刚 0655

迁移学习在医学图像分类中的研究进展

黎英, 宋佩华 0672

生成对抗式网络及其医学影像应用研究综述

张颖麟, 胡衍, 东田理沙, 刘江 0687

基于深度学习的心脏磁共振影像超分辨率前沿进展

李书林, 冯朝路, 于鲲, 刘鑫, 江鑫, 赵大哲 0704

CT图像肺及肺病变区域分割方法综述

冯龙锋, 陈英, 周滔辉, 胡菲, 易珍 0722

计算机断层扫描图像

结构图注意力网络的新冠肺炎轻重症诊断

刘彦北, 李赫南, 张长青, 肖志涛, 张芳, 陈英, 高耀宗, 石峰, 单飞, 沈定刚 0750

慢阻肺患者CT图像中肺内血管分割及定量分析

赵宏, 李璋, 张杰华, 王琨, 孙家兴, 廖玺铭, 阎昱升, 钟正, 张鑫, 孙健, 于起峰, 葛俊辉 0762

基础信息保持和细节强化的胸部CT图像增强

张余, 张顺利, 白相志, 张利 0774

面向小样本股骨骨折分型的多视角注意力融合方法

张亚东, 汪玲, 兰海, 翟禹樵, 程洪 0784

三维多尺度嵌套U结构CT影像肺结节检测

许正奎, 张少敏, 支力佳, 周涛 0797

融合多尺度残差和注意力机制的特发性肺纤维化进展预测

陈舞, 孙军梅, 李秀梅 0812

COVID-19肺部CT图像多尺度编解码分割

陆倩杰, 柏正尧, 樊圣澜, 周雪, 许祝 0827

基于特征选择与残差融合的肝肿瘤分割模型

乔伟晨, 黄冕, 刘利军, 黄青松 0838

磁共振图像

面向多模态MRI脑胶质瘤区域三维分割与生存期预测的级联U-Net网络

余力, 刘霄雪, 闫朝阳, 李建瑞, 张志强, 黄轲, 徐军 0850

心脏动态MRI图像分割的时空多尺度网络

徐佳陈, 肖志勇 0862

融合跨阶段深度学习的脑肿瘤MRI图像分割

夏峰, 邵海见, 邓星 0873

融入平滑组稀疏化的脑部MRI图像分类

黄帅辉, 王金凤 0885

超声图像

面向乳腺超声计算机辅助诊断的两阶段深度迁移学习

贡荣麟, 施俊, 周玮珺, 汪程 0898

结合注意力机制的乳腺双模态超声分类网络

赵绪, 龚勋, 樊琳, 罗俊 0911

中医图像

视觉Transformer与多特征融合的脑卒中检测算法

赵琛琦, 王华虎, 赵涓涓, 冀伦文, 王麒达, 李慧芝, 赵紫娟 0923

多分支深度特征融合的中医脑卒中辅助诊断

王麒达, 冀伦文, 强彦, 王华虎, 赵琛琦, 李慧芝, 赵紫娟 0935

研究应用

多区域融合注意力网络模型下的核性白内障分类

章晓庆, 肖尊杰, Risa Higashita, 陈婉, 胡衍, 袁进, 刘江 0948

面向高度近视条纹损伤的深监督特征聚合网络

谭晓, 刁逸超, 陈新建, 石霏, 樊莹, 谢嘉受, 朱伟芳 0961

结合目标检测与匹配修正的手腕骨感兴趣区域提取

毛科技, 汪敏豪, 陈立建, 陆伟, 武坤秀, 陈庆章, 赵小敏 0973

面向旷场实验视频分类的特征拼接矩阵学习方法


肖照林, 杨志林, 刘欢, 金海燕 0988

基于图像的介入器械前端变形建模与受力估计


任龙飞, 孟偲, 刘博, 白相志, 周付根 1001

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Segmentation and quantitative analysis of intrapulmonary vasculature in CT images from COPD patients(P0762)



Feature selection and residual fusion segmentation network for liver tumor(P0838)



Two-stage deep transfer learning for human breast ultrasound computer-aided diagnosis(P0898)

Review

- A 20-year retrospect and prospect of medical imaging artificial intelligence in China
Jiang Xi, Yuan Yixuan, Wang Yaping, Xiao Zhenxiang, Zhu Meilu, Chen Zehua, Liu Tianming, Shen Dinggang 0655
- Review of transfer learning in medical image classification
Li Ying, Song Peihua 0672
- A review of generative adversarial networks and the application in medical image
Zhang Yinglin, Hu Yan, Risa Higashita, Liu Jiang 0687
- Critical review of human cardiac magnetic resonance image super resolution reconstruction based on deep learning method
Li Shulin, Feng Chaolu, Yu Kun, Liu Xin, Jiang Xin, Zhao Dazhe 0704
- Review of human lung and lung lesion regions segmentation methods based on CT images
Feng Longfeng, Chen Ying, Zhou Taohui, Hu Fei, Yi Zhen 0722

Computerd Tomography Image

- Diagnosis of COVID-19 by using structural attention graph neural network
Liu Yanbei, Li Henan, Zhang Changqing, Xiao Zhitao, Zhang Fang, Wei Ying, Gao Yaozong, Shi Feng, Shan Fei, Shen Dinggang 0750
- Segmentation and quantitative analysis of intrapulmonary vasculature in CT images from COPD patients
Zhao Hong, Li Zhang, Zhang Jiehua, Wang Kun, Sun Jiaxing, Liao Ximing, Yan Yusheng, Zhong Zheng, Zhang Xin, Sun Jian, Yu Qifeng, Ge Junhui 0762
- Human chest CT image enhancement based on basic information preservation and detail enhancement
Zhang Yu, Zhang Shunli, Bai Xiangzhi, Zhang Li 0774
- Multi-view attention fusion method for few-shot femoral fracture classification
Zhang Yadong, Wang Ling, Lan Hai, Zhai Yuqiao, Cheng Hong 0784
- Detection of pulmonary nodules in three-dimensional multiscale nested U-structure computed tomography images
Xu Zhengxi, Zhang Shaomin, Zhi Lijia, Zhou Tao 0797
- Multi-scale residual and attention mechanism fusion based prediction for the progression of idiopathic pulmonary fibrosis
Chen Wu, Sun Junmei, Li Xiumei 0812
- Multiscale codec network based CT image segmentation for human lung disease derived of COVID-19
Lu Qianjie, Bai Zhengyao, Fan Shenglan, Zhou Xue, Xu Zhu 0827
- Feature selection and residual fusion segmentation network for liver tumor
Qiao Weichen, Huang Mian, Liu Lijun, Huang Qingsong 0838

Magnetic Resonance Image

- Brain glioma tumor segmentation and survival prediction from multi-modality MRIs via cascaded U-Net
Yu Li, Liu Xiaoxue, Yan Chaoyang, Li Jianrui, Zhang Zhiqiang, Huang Yunzhi, Xu Jun 0850
- A spatio-temporal multi-scale network for cardiac dynamic MRI image segmentation
Xu Jiachen, Xiao Zhiyong 0862
- Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation
Xia Feng, Shao Haijian, Deng Xing 0873
- Brain MRI image classification incorporating smooth group sparseness
Huang Shuaihui, Wang Jinfeng 0885

Ultrasound Image

- Two-stage deep transfer learning for human breast ultrasound computer-aided diagnosis
Gong Ronglin, Shi Jun, Zhou Weijun, Wang Cheng 0898
- Attention-based networks of human breast bimodal ultrasound imaging classification
Zhao Xu, Gong Xun, Fan Lin, Luo Jun 0911

Traditional Chinese Medical Image

- Cerebral stroke detection algorithm for visual Transformer and multi-feature fusion
Zhao Chenqi, Wang Huahu, Zhao Juanjuan, Ji Lunwen, Wang Qida, Li Huizhi, Zhao Zijuan 0923
- Multi-branch deep feature fusion method for traditional Chinese medicine intervened Human cerebral stroke aided diagnosis
Wang Qida, Ji Lunwen, Qiang Yan, Wang Huahu, Zhao Chenqi, Li Huizhi, Zhao Zijuan 0935

Research and Application

- Nuclear cataract classification based on multi-region fusion attention network model
Zhang Xiaoqing, Xiao Zunjie, Risa Higashita, Chen Wan, Hu Yan, Yuan Jin, Liu Jiang 0948
- Deep-supervision and feature-aggregation network for linear lesion segmentation of high myopia
Tan Xiao, Diao Yichao, Chen Xinjian, Shi Fei, Fan Ying, Xie Jiamin, Zhu Weifang 0959
- Hand-wrist region of interest extraction based on object detection and matching correction
Mao Keji, Wang Minhao, Chen Lijian, Lu Wei, Wu Kunxiu, Chen Qingzhang, Zhao Xiaomin 0973
- A spliced feature matrices learning method for open field test video classification
Xiao Zhaolin, Yang Zhilin, Liu Huan, Jin Haiyan 0988
- Image-based deformation modeling and force estimation of the front end of vascular interventional surgical apparatus
Ren Longfei, Meng Cai, Liu Bo, Bai Xiangzhi, Zhou Fugen 1001

中图法分类号: TP389.1 文献标识码: A 文章编号: 1006-8961(2022)03-0704-18

论文引用格式: Li S L, Feng C L, Yu K, Liu X, Jiang X and Zhao D Z. 2022. Critical review of human cardiac magnetic resonance image super resolution reconstruction based on deep learning method. Journal of Image and Graphics, 27(03): 0704-0721 (李书林, 冯朝路, 于鲲, 刘鑫, 江鑫, 赵大哲. 2022. 基于深度学习的心脏磁共振影像超分辨率前沿进展. 中国图象图形学报, 27(03): 0704-0721) [DOI: 10.11834/jig.210150]

基于深度学习的心脏磁共振影像 超分辨率前沿进展

李书林¹, 冯朝路^{1,2*}, 于鲲^{1,2}, 刘鑫^{2,3}, 江鑫^{2,3}, 赵大哲^{1,2,3}

1. 东北大学医学影像智能计算教育部重点实验室, 沈阳 110169; 2. 东北大学辽宁省医学影像计算重点实验室, 沈阳 110169;
3. 东软医疗系统股份有限公司, 沈阳 110819

摘要: 心脏为人体血液流动提供动力, 是人体血液循环系统的重要组成部分。受人口老龄化影响, 心脏病诊疗已成为重大公共健康话题。非侵入式活体心脏成像对心脏疾病的检测、诊断与治疗意义重大。然而, 受活体心跳影响, 成像扫描时间与心脏影像分辨率成为难以调和的矛盾。为缓和这一矛盾, 基于快速扫描获得的低分辨率影像重建出心脏高分辨率影像的超分辨率(super-resolution, SR)重建技术成为研究热点。深度学习技术在医学影像处理领域中展现出强大生命力, 基于深度学习的SR技术因其强大的学习能力与数据驱动性, 在心脏影像SR重建领域中表现出明显优于传统方法的性能。目前领域内前沿成果较多, 但缺少对领域现状进行总结、对未来发展进行展望的综述性文献。因此, 本文对领域内现状进行梳理总结, 挑选出代表性方法, 分析方法特性, 总结文献中心脏影像数据来源与规模, 给出常用的评价指标, 以及模型得出的性能评价结论。分析发现, 基于深度学习的心脏SR重建技术取得了较大进展, 但在运动伪影抑制、模型简化程度与时间性能方面仍有进步空间。此外, 现有模型基本完全依靠网络强大的表达能力, 鲜有临床先验知识的引入。最后, 模型间性能对比相对较少, 且领域内缺少代表性的可用于评价不同心脏SR重建模型性能的数据集。基于深度学习的心脏影像SR技术仍有较大发展空间。

关键词: 深度学习; 心脏医学影像; 超分辨率重建; 磁共振成像; 心脏影像数据集; 卷积神经网络; 高分辨率影像

Critical review of human cardiac magnetic resonance image super resolution reconstruction based on deep learning method

Li Shulin¹, Feng Chaolu^{1,2*}, Yu Kun^{1,2}, Liu Xin^{2,3}, Jiang Xin^{2,3}, Zhao Dazhe^{1,2,3}

1. Key Laboratory of Intelligent Computing in Medical Image (MIIC), Ministry of Education, Northeastern University, Shenyang 110169, China; 2. Key Laboratory of Medical Image Computing (MIC), Liaoning Province, Northeastern University, Shenyang 110169, China; 3. Neusoft Medical Systems Co., Ltd., Shenyang 110819, China

Abstract: Heart diseases diagnosis and treatment has become one of the major public health issues for human beings where non-invasive cardiac imaging is of great significance. Unfortunately, imaging scan time and cardiac image resolution become

收稿日期: 2021-03-24; 修回日期: 2021-10-25; 预印本日期: 2021-11-01

* 通信作者: 冯朝路 fengchaolu@cse.neu.edu.cn

基金项目: 国家自然科学基金项目(U1708261, 61602101); 中央高校基本科研业务费专项资金项目(N2016003); 辽宁省自然科学基金项目(2021-MS-085)

Supported by: National Natural Science Foundation of China (U1708261, 61602101); Fundamental Research Funds for the Central Universities (N2016003); Natural Science Foundation of Liaoning Province, China(2021-MS-085)

an intensive contradiction due to the characteristics of living heartbeat. Super-resolution (SR) image reconstruction like low-resolution-images based high-resolution cardiac images reconstruction are obtained based on the determined tolerable error within a short imaging time. Deep learning methods have revealed great vitality in the field of medical image processing nowadays. In terms of its good learning ability and data-driven factors, deep-learning-based SR reconstruction is qualified based on deep residual networks, generative adversarial networks compared with traditional methods. Our research analysis reviews the field via analyzing characteristics of representative methods, summing up cardiac image resources and the scale, summarizing commonly used evaluation indicators, giving performance evaluation and application conclusions of the methods and discussing methods in other fields that can be adapted for SR reconstructing cardiac magnetic resonance (CMR) images. Our analysis is derived from 13 opted literature reviews from Google, database systems and logic programming (DBLP), and CNKI taking deep learning, cardiac and SR reconstruction as search keywords. This review first categorizes all methods by their evaluation datasets, which are open resource or not. Details on the datasets and links to the open-source datasets are also facilitated. By defining standard evaluation indicators based on the reconstructed SR images and their ground truth, namely high-resolution (HR) images, the performance of SR reconstruction methods can be evaluated quantitatively. This demonstration summarizes the 8 evaluation indicators in the cardiac SR reconstruction methods, including structural similarity, cardiovascular diameter measured value, dice coefficient. The evaluation indicators are divided into three categories with respect to the following aspects, those are evaluation of the quality of SR reconstructed images, evaluation of cardiac function and evaluation of the effectiveness of cardiac segmentation. Meanwhile, all 13 literature reviews are only used to increase the spatial resolution of the CMR images. Our research classifies the methods as CMR 2D SR reconstruction, CMR 3D SR reconstruction, and CMR SR reconstruction in other dimensions, depending on the dimension of the cardiac images processing based on the deep learning methods. In general, most CMR 2D SR reconstruction methods can reconstruct high resolution cardiac images in a relative short time span to assure SR reconstruction quality. In contrast, the CMR 3D SR reconstruction methods are involved 3D convolution, which take the spatial structure of the heart into account. The integrated information is analyzed amongst adjacent slices of CMR. Some of these methods achieve the SR reconstruction result qualified than CMR 2D SR reconstruction methods. However, a number of CMR data is small size and most of them are not open. The larger perceptual domain of the methods increases the computation complexity and reduces the temporal performance to some extent. As for CMR SR reconstruction in higher dimensions, corresponding methods meet the requirement of high-resolution image generation and image denoising in clinical analysis. All the selected CMR SR reconstruction methods can also be organized in accordance with network models and high-resolution image degradation methods, such as U-Net, generative adversarial network and long short-term memory network from the aspect of network models. Fourier degradation and different interpolation degradation methods are from the aspect of degradation methods. SR reconstructed high-resolution images can accurately facilitate heart anatomy, blood flow evaluation and heart tissue segmentation level. This research also reviewed the feasibility of adapting other SR reconstruction methods for CMR SR reconstruction as they are currently proposed and applied to images of other in vivo tissues and structures. Our research also tries to find some of the SR reconstruction methods from the field of natural images computer vision to discuss the feasibility that adapting them to CMR SR reconstruction, such as channel attention mechanisms, video SR methods and SR of real scenes. In summary, SR reconstruction of CMR images has its distinctive features than SR reconstruction of natural images like more diverse and purposeful evaluation metrics constraint of local reconstruction quality and to the difficulties of getting training data. It is found that deep-learning-based cardiac SR reconstruction has concerned more in motion artifact suppression, model simplification, and time performance further. In addition, current methods basically rely on the powerful expression ability of the CNN (convolutional neural network), and little clinical prior knowledge is melted to the network to guide its learning. Performance comparison between existing models is relatively less, and there is no representative image repository to evaluate performances of different cardiac SR reconstruction methods.

Key words: deep learning; cardiac imaging; super-resolution reconstruction; magnetic resonance imaging; datasets of cardiac images; convolutional neural networks; high-resolution images

0 引言

作为人体血液循环系统的重要组成部分,心脏为人体血流提供动力,为维持人体生命体征起着至关重要的作用。《中国心血管报告 2018》指出,包括冠心病、高血压、心力衰竭、心率失常、心肌梗死和房颤等在内的心脏病诊疗已成为重大公共健康卫生问题。医学成像技术的发展,使得以非侵入方式获得活体心脏组织的结构影像成为现实。对心脏影像进行智能分析对心脏疾病的检测、诊断与治疗起着重要作用。

然而,受活体心跳影响与成像原理约束,心脏磁共振(cardiac magnetic resonance, CMR)成像难且慢。现有技术通过欠采样(under sampled)重建,加快成像速度,但对影像质量产生负面影响。成像设备需在较短时间内实现心脏影像信息采集与高质量重建。这给心脏高分辨率成像带来挑战。一种可行的解决办法是设备成像时尽可能保证时间性能,在由容许误差决定的成像时间内生成细节特征尽可能完整的心脏影像,此时为低分辨率(low-resolution, LR)心脏影像。然后采用后处理超分辨率(super-resolution, SR)重建技术进一步提升心脏影像分辨率,进而改善影像质量。SR 重建技术可显著提高心脏影像分辨率,进而解决为获取高分辨率心脏影像需要较长成像时间的问题。SR 重建技术可为心脏病筛查与诊断提供高分辨率(high-resolution, HR)影像,进而降低诊断难度,提升诊断效率。因此,自 Harris(1964)首次提出 SR 的概念后,陆续衍生出基于重构与样本学习的 SR 技术。但是,这些较为传统的方法普遍难以恢复心脏影像的高频细节,从而导致重建后的心脏影像更加模糊。另外,这些方法普遍存在计算复杂、实时性差,且不能满足大因子(8 倍及以上)缩放需求的问题,为心脏影像智能分析带来困难。深度学习技术在医学影像处理领域展现出强大生命力,基于深度学习的 SR 技术因其强大的学习能力与数据驱动性,在心脏影像 SR 重建领域中表现出明显优于传统方法的性能,已成为研究热点。

本文以“心脏”、“超分辨率”、“深度学习”为全文搜索关键词,通过谷歌学术、中国知网以及 DBLP(database systems and logic programming)文献数据库查阅近 5 年发表的基于深度学习模型实现心脏影

像 SR 重建的学术文献。共搜索到如表 1 所示的 13 篇文献,本文分别从心脏影像来源与规模、SR 方法评价标准、SR 方法的特色和 SR 技术的应用 4 个视角对深度学习技术在心脏影像 SR 领域的现状进行梳理总结,便于感兴趣的读者了解领域内的研究现状与发展趋势。

1 数据集

随着医学领域信息化的不断深入,医学影像数据也越来越丰富,文献集中处理的心脏影像主要源于公开心脏影像集与合作医疗机构。具体地,文献中用于训练、验证 SR 网络模型的数据集主要包括:

1) MICCAI2009 心脏 MR 左心室分割挑战赛数据集(<https://www.midasjournal.org/browse/journal/49>)。该数据集包含 45 幅来自不同患者和病理的电影稳态自由进动(steady state free precession, SSFP)CMRI,是由心脏病学家确定的舒张末期和收缩末期的手动分段。Mahapatra 和 Bozorgtabar(2019)使用此数据集训练并验证提出的 SR 网络模型。

2) Kaggle 第 2 届数据科学碗心脏挑战赛数据集(<https://www.kaggle.com/c/second-annual-data-science-bowl/data>)。该数据集中包含数百幅电影 CMR 2 维影像,每幅 2 维影像包含约 30 个时间序列,对应 1 个心跳周期。其中,所有影像均是屏息状态下获得。Lin 等人(2020)、Basty 和 Grau(2018)用此数据集训练并验证提出的 SR 网络模型。

3) 英国数码心脏计划数据集(UK digital heart project)(<https://digital-heart.org/>)。该数据集中共含有 1 200 对 LR 心脏短轴 2 维与 HR 3 维电影 CMRI。所有影像对均来自健康活体扫描。其中,心脏短轴 2 维序列在不同屏气状态下采集得到,故影像中可能存在运动伪影。LR 心脏短轴 2 维序列与 HR 3 维影像的体分辨率分别为 $1.25 \times 1.25 \times 10.00$ mm 与 $1.25 \times 1.25 \times 2.00$ mm,即数据集建立的初衷是实现分辨率 5 倍提升。Oktay 等人(2018)用此数据集训练并验证提出的 SR 网络模型。

4) MICCAI2017 自动心脏诊断挑战数据集(automated cardiac diagnosis challenge, ACDC)(<https://acdc.creatis.insa-lyon.fr/description/databases.html>)。该数据集由对 100 名患者扫描获得的心脏短轴

表 1 基于深度学习模型实现心脏影像 SR 重建的文献
Table 1 Summary of literature on SR reconstruction of cardiac images based on deep learning models

序号	文献	维度	模型	数据集	性能	特性
1	Lin 等人(2020)	2 维 + 时间维	ConvLSTM	Kaggle& ACDC	SSIM:0.969 6	考虑时间特性、迭代错误反馈
2	Steeden 等人(2020)	3 维	Res U-Net	合作医疗机构	SSIM: 0.96 ± 0.01	训练数据不足、受运动伪影影响
3	Basty 和 Grau(2018)	2 维 + 时间维	U-Net& LSTM	Kaggle	SSIM:0.81	考虑时间特性、受影像未配准影响
4	Mahapatra 和 Bozorgtabar(2019)	2 维	p-GANs	MICCAI2009	PSNR:43.7 dB	渐近式生成、结合三元组损失函数
5	Zhao 等人(2020)	2 维	LSRGAN	未公开	SSIM:0.948	渐近式生成、使用残差—稠密块、重建速度慢
6	Kobayashi 等人(2020)	2 维	SR-CNN	合作医疗机构	PSNR: 39.41 ± 1.37 dB	基于冠状动脉 MR 血管影像、超参未调优
7	Oktay 等人(2018)	3 维	ACNN&T-L 正则模型	UK digital heart	SSIM: 0.796 ± 0.041	解剖先验知识正则化
8	Oktay 等人(2016)	3 维	SR-CNN	未公开	SSIM: 0.818 ± 0.012	融合心脏多视角影像序列、受影像未配准影响
9	Zhao 等人(2019)	2 维	EDSR	未公开	PSNR: 25.300 2 dB	自学习、受运动伪影影响
10	Masutani 等人(2020)	3 维	U-Net/ SR-CNN	合作医疗机构	SSIM: 0.972 ± 0.014	考虑时间特性、训练数据不足
11	Sander 等人(2020)	2 维	自编码器	ACDC	SSIM:0.850	受影像未配准影响
12	Giannakidis 等人(2017)	3 维	SR-CNN	合作医疗机构	SSIM: 0.94 ± 0.02	基于晚期钆增强 CMR 影像
13	Ferdian 等人(2020)	其他维度	4DFlowNet	模拟数据集 & 合作医疗机构	RSE:7.05 ± 14.03	基于 4D MR 血流成像数据

CMR 影像构成,均匀分布于心功能正常、扩张型心肌病、肥厚型心肌病、心力衰竭伴梗塞和右心室异常 5 组中。Lin 等人(2020)、Sander 等人(2020)用此数据集训练并验证提出的 SR 网络模型。

5)院方合作且未公开具体来源的心脏影像集。除以上心脏影像集外,部分文献用于训练、验证 SR 网络模型的心脏影像来自于合作医疗机构或模拟数据集,并未在线公开。Steeden 等人(2020)、Kobayashi 等人(2020)、Masutani 等人(2020)、Giannakidis 等人(2017)用被支持的医疗机构提供的心脏影像训练并验证提出的 SR 网络模型;Ferdian 等人(2020)采用计算流体动力学模型构建的模拟 4D 心血管流数据,训练、验证提出的 SR 网络

模型。

2 性能评价

基于重建影像质量定义标准评价指标,可量化评价 SR 重建方法的性能,进而可有效减少选择 SR 方法的盲目性,对于新方法研发起到指导作用。就自然图像 SR 重建来说,常用的 SR 评价标准有峰值信噪比、结构相似性等,这些评价标准也广泛应用于心脏影像 SR 重建方法评价。除此之外,在心脏影像 SR 重建领域,包括射血分数、心室容积等心脏功能参数以及对于心脏影像分割的精度在内的指标,也用于评价 SR 重建质量。因此,本文将心脏 SR 重

建方法性能评价指标分为重建影像质量评价、心脏功能评价以及心脏分割效果评价3类。

2.1 重建影像质量评价

复用自然图像SR重建主流性能评价指标:

1) 均方误差(mean-square error, MSE)。均方误差是反映估计量与被估计量之间差异程度的一种度量。对于心脏影像SR重建来说,重建结果为估计量 I ,真实的HR影像为被估计量 J ,则心脏SR重建与真实HR影像像素间的MSE定义为

$$MSE = \frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n [I(i,j) - J(i,j)]^2 \quad (1)$$

式中, m, n 表示心脏影像尺寸, $I(i,j)$ 、 $J(i,j)$ 分别表示重建影像与参考HR影像在像素 (i,j) 处的灰度值。显然,当MSE取值较小时,心脏SR重建影像失真少,质量好。Steeden等人(2020)、Kobayashi等人(2020)采用MSE评价提出的SR重建方法的性能。

2) 峰值信噪比(peak signal-to-noise ratio, PSNR)。作为SR重建性能评价出现频率较高的指标,峰值信噪比用于衡量心脏SR重建影像失真或噪声水平。由MSE对心脏SR重建影像失真程度的定量描述,定义为

$$PSNR = 10 \times \lg \frac{(2^n - 1)^2}{MSE} \quad (2)$$

式中, n 为像素灰度值的比特数, MSE 为参考HR影像与SR重建影像之间的均方误差值。PSNR的单位为dB,且PSNR值越大,心脏SR重建影像失真越少,重建质量越好。Lin等人(2020)、Basty和Grau(2018)、Mahapatra和Bozorgtabar(2019)、Zhao等人(2020)、Oktay等人(2016)、Zhao等人(2019)、Sander等人(2020)、Giannakidis等人(2017)采用PSNR评价提出的SR方法的性能。

3) 结构相似性(structural similarity, SSIM)。结构相似性用于衡量心脏SR重建影像与参考HR影像之间的相似度,在心脏SR影像重建方法的性能评价中同样起重要作用。令 μ_I 与 μ_J 分别为SR影像与HR影像的灰度均值, σ_I^2 、 σ_J^2 与 σ_{IJ} 分别为SR影像与HR影像的灰度方差与协方差,则

$$SSIM(I, J) = \frac{(2\mu_I\mu_J + c_1)(2\sigma_{IJ} + c_2)}{(\mu_I^2 + \mu_J^2 + c_1)(\sigma_I^2 + \sigma_J^2 + c_2)} \quad (3)$$

式中, $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$ 为控制因子。通常

地, k_1 与 k_2 分别取0.01与0.03, L 为灰度取值范围; $2^n - 1$ 。不难验证,SSIM的取值范围为-1到1,且SSIM值越趋近于1,则SR重建影像与HR影像的相似度越高,即SR重建效果越好。表1中除Ferdian等人(2020)的方法,其他文献都采用了SSIM评价提出的SR方法的性能。

4) 每秒帧速率(frames per second, FPS)。与以上指标均关注SR重建影像的质量不同,每秒帧速率用于评价SR重建方法的时间性能。FPS取值较大时,代表对应的SR重建方法能够在较短的时间内处理生成更多的心脏SR影像,效率更高。Lin等人(2020)采用FPS评价提出的SR方法的性能。

2.2 心脏功能评价

除复用自然图像SR重建主流性能评价指标之外,因心脏影像SR重建的根本目的是提升后续影像智能分析性能,测量重建影像中血管直径、心室容积以及射血分数等心脏功能指数,故检验SR重建影像与参考HR影像的心功能指数的差异性已广泛用于心脏影像SR重建性能评价(Steeden等人(2020)、Oktay等人(2016)、Masutani等人(2020))。

1) 管径测量。血管直径测量值可用于验证心脏SR重建影像相较于HR影像在血管显示上有无明显失真。测量对象包括升主动脉、降主动脉、主肺动脉、右肺动脉、左肺动脉和近端左冠状动脉。测量手段为临床医生基于多平面重建技术进行手动测量。对分别由SR影像和HR影像测量的结果采用Bland-Altman方法进行一致性分析:分别计算两组测量值中对应值的差值,记差值的均值为 μ ,差值的标准差为 S 。若两组血管直径测量值的差值服从正态分布,则95%的差值落在一致性界限区间 $[\mu - 1.96S, \mu + 1.96S]$ 内。若绝大多数血管直径差值位于一致性界限内,则表示这两组血管直径测量值具有较好的一致性,对应的SR重建影像与HR影像在血管直径估计方面一致性较好。Steeden等人(2020)用此指标评价提出的SR方法的性能。

2) 左心室容积与组间心肌表面的豪斯多夫距离。作为心脏的重要组成部分,心室功能评价意义重大。左心室(left ventricle, LV)容积与心肌(myocardium, MYO)表面距离估计可用于验证心脏SR重建影像相较于HR影像在心功能评估方向上是否存在明显差异。为计算上述两个指标,通常需要将心室内外膜边界标记出来。左心室容积定义为内膜

边界内体素的和。豪斯多夫距离定义为边界曲线点集之间的距离度量。具体地,若SR重建影像中边界曲线点集为 $A = \{a_1, a_2, \dots\}$, HR影像中对应边界曲线点集为 $B = \{b_1, b_2, \dots\}$, 则豪斯多夫距离定义为

$$H(A, B) = \max[h(A, B), h(B, A)] \quad (4)$$

$$h(A, B) = \max_{a \in A} \min_{b \in B} \|a - b\| \quad (5)$$

$$h(B, A) = \max_{b \in B} \min_{a \in A} \|b - a\| \quad (6)$$

显然,SR重建影像中测得的LV容积与参考HR影像中测量的LV值越接近,且对应的豪斯多夫距离越小,则表明SR重建影像与参考HR影像在心脏容积评估与心肌表面距离测试方面一致性越好。Oktay等人(2016)采用以上两个指标评价提出的SR方法的性能。

3)左心室心博量与射血分数差值的配对t检验。左心室心博量(left ventricle stroke volume, LV SV)与射血分数(ejection fraction, EF)可用于检验SR重建影像相较于参考HR影像在心功能评估方面是否存在评估偏差。对测量后的两组心功能参数,进行配对t检验,检测两组测量值的均值是否存在显著性差异。配对t检验统计量为

$$t = \frac{\mu - \mu_0}{S \sqrt{n}} \quad (7)$$

式中, μ 为两组测量值均值之差,零假设即 $\mu_0 = 0$, n 为配对测量的数量。显然,该统计量服从自由度为 $n - 1$ 的t分布。计算p值,判断是否达到显著水平。p值小于显著性水平,则接受零假设。此时,SR重建影像重建效果好,对心脏功能评估影响小。Masutani等人(2020)采用以上指标评价提出的SR方法的性能。

2.3 心脏分割效果评价

Dice系数。通过比较Dice系数可检测对心脏SR重建影像与HR影像分割的精度是否存在差异。对SR重建影像与HR影像基于同一分割方法分割,常见的方法有基于U-Net、多图谱的心脏分割方法。分别计算相对于金标准分割图像的Dice系数,最后比较系数差异。具体地,若金标准分割图像为 X ,对SR与HR影像分割得到的图像为 Y ,则Dice系数定义为

$$s = \frac{2|X \cap Y|}{|X| + |Y|} \quad (8)$$

式中, $|\cdot|$ 操作表示求区域内所有像素点的个数。Dice系数的取值范围为 $0 \sim 1$, Dice系数的值越趋近于1,则代表分割的精度越高。当对SR影像分割的Dice系数与HR影像Dice系数越接近时,则表明SR重建影像与HR影像在心脏分割的精度一致性越好,即SR重建效果越好。Mahapatra和Bozorgtabar(2019)采用以上指标评价提出的SR方法的性能。

3 心脏超分辨率深度学习方

虽然临床上可用于心脏病诊断的影像模态包括计算机断层扫描(computed tomography, CT)、超声(ultrasound, US)、MR等多种模态,表1所列的13篇基于深度学习模型的心脏影像SR重建文献均基于MR模态。根据不同的临床分析需求,可以提升心脏影像的时间分辨率或空间分辨率,本文所分析总结的文献中的CMR SR重建方法都为提升心脏影像的空间分辨率,即层间与层内分辨率。本文基于深度学习模型处理心脏影像维度的不同,将其分为CMR 2维超分辨率重建、CMR 3维超分辨率重建,以及其他维度的CMR超分辨率重建3类。

3.1 CMR 2维超分辨率重建

Mahapatra和Bozorgtabar(2019)提出一个基于逐步生成对抗网络(progressive generative adversarial networks, p-GANs)的CMR SR重建方法,p-GANs网络结构如图1所示,图1中 G_1 与 D_1 , G_2 与 D_2 对应两组用于 $2 \times$ 分辨率提升任务的生成器与鉴别器。生成器与鉴别器网络结构如图2所示。该方法以




图1 p-GANs网络结构

Fig.1 Architecture of the p-GANs




图2 p-GANs的生成器与鉴别器网络结构图

Fig. 2 Structure of the generator and discriminator networks of p-GANs((a) generator; (b) discriminator)

CMR 2 维影像为操作对象,用三元组损失函数,将上一阶段的重建结果作为基准,逐阶段提升影像分辨率。每阶段分辨率提升 2 倍,满足了大因子缩放的需求。该方法解决了低分辨率下 CMR 影像中心脏组织的微小病变难以检测以及对于 CMR 影像分割精度不足的问题。为评估提出方法的性能,Mahapatra 和 Bozorgtabar (2019) 采用 MICCAI 2009 心脏 MR 左心室分割挑战赛数据集中的 150 幅心脏 SSFP 短轴影像作为心脏 HR 影像。LR 影像通过对 HR 影像施以高斯滤波后,降采样获得。将 150 幅影像扩展生成 75 000 幅影像用于训练。实验结果表明,4 倍缩放因子下,重建影像较传统卷积神经网络(convolutional neural network, CNN)方法(Dong 等,2016) PSNR 指标提升 11 dB 左右,达到 43.7 dB;SSIM 系数达到 0.83,高于传统 CNN SR 方法的 0.69。

Zhao 等人(2020)提出结合拉普拉斯金字塔的生成对抗网络(Laplacian pyramid based on generative adversarial network, LSRGAN)实现 CMR 2 维 SR 重建。该方法与 p-GANs 类似,影像分辨率提升为渐进式,实现了高缩放因子($16 \times$)下心脏影像 SR 重

建。该方法实现 SR 重建的过程如图 3 所示。其中,拉普拉斯金字塔有利于不同分辨率下高频信息的保留。除此之外,LSRGAN 生成器网络中引入如图 4 所示的残差—稠密块(residual dense block, RDB)作为基础网络原件,用于进一步保证重建影像质量。该方法抑制了心脏影像经 SR 重建后常出现的伪影。为评估提出方法的性能,Zhao 等人(2020)将来自于 64 位患者的 2 560 幅 CMR 影像作为 HR 影像。LR 影像由对 HR 影像进行双三次插值后下采样得到。实验结果表明,引入 16 个 RDB 后网络模型的整体 PSNR 系数达到 31.3 dB,相较于仅使用残差块的网路提升 0.2 dB。结合拉普拉斯金字塔结构后,重建 PSNR 系数达到 27.1 dB,较之前提升 0.6 dB。SSIM 系数达到了 0.74,提升 0.04。但是,由于 LSRGAN 网络结构复杂度较高,该方法的 SR 重建速度较慢。

Kobayashi 等人(2020)采用 CNN 实现全心动脉 MR 血管造影 2 维 SR 重建。该方法解决了全心动脉 MR 影像中冠状动脉组织处分辨率不足的问题。为评估提出方法的性能,Kobayashi 等人(2020)




图3 LSRGAN SR重建示意图

Fig. 3 Diagram of LSRGAN SR reconstruction




图4 RDB 结构图

Fig. 4 Structure of RDB

将合作院方提供的80例患者影像均分为两部分,一半用作训练,一半用作测试。实验结果表明,提出模型深度为3时重建效果最好。与参考HR影像相比,提出方法重建影像的MSE值为7.07,PSNR系数与SSIM系数分别为39.41 dB与0.998。但是,提出方法参数调优基于12组给定超参数,存在模型参数非最优的风险。

Zhao等人(2019)提出基于加强的深度残差网络(enhanced deep residual network, EDSR)(Lim等,2017)的综合多方向分辨率增强(synthetic multi-orientation resolution enhancement, SMORE)方法,用于提升猪的CMR影像层间分辨率。方法利用已有层内HR影像构建的LR/HR影像对训练模型,以自学习形式实现CMR影像的SR重建,在不借助外界图谱或样本的同时实现了心脏影像的抗锯齿化。解决了心肌梗死的心脏影像中心肌、瘢痕的边界细节不清晰的问题。Zhao等人(2019)采用两头猪的T1加权影像序列评估SMORE方法的性能。实验结果表明,SSIM系数达到0.5146,优于sinc插值的0.5070。PSNR系数低于sinc插值法0.5 dB,为28.8816

dB。但是,SMORE方法的性能受影像层内分辨率影响较大,且对含呼吸伪影的影像重建效果不佳。

Sander等人(2020)提出如图5所示的基于无监督学习的SR重建方法,图中 X_n 、 X_{n+1} 为CMR影像中相邻的切片, Z_n 、 Z_{n+1} 对应其在编码器潜空间的表示。 $Z_\alpha(Z_n, Z_{n+1})$ 为对切片插值后的表示, $X_\alpha^{n,n+1}$ 为方法最终合成的中间切片。方法基于自编码器(auto encoder, AE)的空间插值能力训练各向异性的心脏影像,对相邻切片插值进而提升层间分辨率。解决了SR方法训练所需的各向同性的HR心脏影像难以采集的问题。为评估提出方法的性能,Sander等人(2020)将MICCAI 2017自动心脏诊断数据集集中的100例短轴CMR影像序列中70例用于自编码器训练,30例用于模型验证。数据集集中的影像作为HR影像,隔层去除部分切片构建LR影像。实验结果表明,提出方法的重建影像与HR影像的SSIM系数达到0.85,高于线性插值方法0.02。PSNR系数达到28 dB,高于线性插值方法4 dB。




图5 无监督SR方法示意图

Fig. 5 Diagram of unsupervised SR method

Basty 和 Grau (2018) 提出基于 U-Net 与长短期记忆网络 (long short-term memory, LSTM) 的模型, 网络结构如图 6 所示。模型用于实现心脏长轴电影 MR 影像的 SR 重建, 与 Steeden 等人 (2020) 的 3 层 U-Net 不同, Basty 和 Grau (2018) 的 U-Net 为 5 层 2 维卷积。其中模型前两层中 LSTM 能更好地提取电影 MR 影像序列的时间信息从而改善重建影像质量。方法解决了由于心跳导致的长轴心脏影像序列的 SR 重建效果不佳的问题。为评

估方法的性能, Basty 和 Grau (2018) 将 Kaggle 第 2 届数据科学院心脏挑战赛数据集中的长轴心脏影像用作 HR 影像, 对 HR 影像降采样后进行立方插值获得对应的 LR 影像。为保证精度, 训练集中包含 3 000 对 LR/HR 影像。采用 171 对 LR/HR 影像验证模型性能。实验表明, PSNR 系数达到 26.57 dB, SSIM 系数达到 0.81, 均高于常规 U-Net 的 25.23 dB 与 0.77。但是, 模型重建精度易受影像伪影以及影像间灰度不匹配问题的影响。




图 6 U-Net + LSTM 网络结构图

Fig. 6 Network structure of U-Net + LSTM

Lin 等人 (2020) 提出基于常规卷积层与 LSTM 的端到端网络模型用于 CMR 视频影像 SR 重建。网络的结构图如图 7 所示。方法结合心脏周期的相关概念, 提出用于提取时间信息的阶段融合模型。该方法基于残差学习方案逐步细化恢复残差, 并采用分治的思想, 具有根据任务难度调整迭代细化的自适应能力。方法解决了心跳导致的重建影像质量不佳问题。为评估网络模型的性能, Lin 等人 (2020) 采用 MICCAI 2017 自动心脏诊断挑战数据集中的 150 例 4 维 CMR 影像与 Kaggle 第 2 届数据科学碗心脏挑战赛数据集中的 440 例电影 CMR 作为 HR 影像。对 HR 影像进行傅里叶变换, 然后滤去高频信息, 进行反傅里叶变换再降采样构建 LR 影像。实验结果表明, 模型在两个数据集上的 PSNR 与 SSIM 分别达到 30.41 dB/0.866 8 与 30.91 dB/0.895 6, 并获得了较高的 FPS

(frames per second), 效率与性能上达到了较好的平衡。

综上所述, 多数 CMR 2 维 SR 重建方法可以在较短的时间内实现心脏影像 SR 重建, 且能保证 SR 重建质量, 而且领域内可供分析的心脏影像数据充足, 但普遍方法对于心脏结构信息考虑较少。

3.2 CMR 3 维超分辨率重建

为解决 HR 3 维 CMR SSFP 影像序列成像时间长的问題, Steeden 等人 (2020) 提出基于残差 U-Net 的网络模型, 用于实现心脏影像序列的 SR 重建。网络基于 3 维卷积, 其结构如图 8 所示。方法利用多尺度下的残差学习实现了 SR 重建的加速。为评估网络模型的性能, Steeden 等人 (2020) 采用合作院方医疗机构提供的 500 例患有小儿心脏病或先天性心脏病儿童或成人影像序列作为 HR 影像。LR 影像通过傅里叶变换方法由 HR 影像构建。实验结果




图7 ConvLSTM 网络结构图

Fig. 7 Network structure of ConvLSTM




图8 3维残差 U-Net 结构图

Fig. 8 Network structure of 3D residual U-Net

表明,模型 SR 重建影像与 HR 影像的 SSIM 系数达到 0.96 ± 0.01 , MSE 系数达到 0.68 ± 0.00045 。除此之外, Steeden 等人(2020)测量了影像中血管管径,并计算获得测量差值的一致性界限 $[-2.0, 2.0]$, 且几乎所有差值都落于此区间。结果表明, SR 重建影像与 HR 影像在血管直径估计方面一致性较好。但是,训练集中无罕见先天性心脏缺陷的代表性影像,可能导致方法普适性不强,且模型易受心跳影响。

Okta 等人(2016)提出用于心脏长/短轴 MR 影像序列 SR 重建的深层残差网络 SC-CNN (single image channel CNN) 模型。网络结构如图 9 所示。

其中,在升采样阶段使用反卷积层代替固定的卷积层,使网络具有更好的数据自适应性。采用 $3 \times 3 \times 3$ 尺寸卷积核,以及增加深度的方式提升网络性能。方法旨在解决 3 维 CMR 影像成像时间长的问题。为评估网络性能, Oktay 等人(2016)将 1 080 例 3 维 CMR 短轴影像序列作为 HR 影像。通过转换模型 (Greenspan, 2009) 构造 LR 影像。训练集与测试集规模分别为 930 与 150。实验结果表明,提出的 7 层 SC-CNN 模型 PSNR 达到 24.45 ± 1.20 dB, SSIM 系数达到 0.88 ± 0.02 。相较于浅层 CNN 取得更好的重建质量。




图9 SC-CNN 网络结构图

Fig. 9 Network structure of SC-CNN

晚期钆增强的 CMR (late gadolinium enhancement CMR, LGE-CMR) 技术可用于区分正常与病变的心肌组织, 从而进行病理分析, 然而常见临床 LGE-CMR 影像为 2 维各向异性的序列, 存在层间分辨率不足的问题, 为解决该问题, Giannakidis 等人 (2017) 将 SC-CNN 模型用于 3 维 LGE-CMR 影像的 SR 重建, 提升了心脏影像的层间分辨率, 模型深度为 6。Giannakidis 等人 (2017) 将 28 位成人先天性心脏病患者的扫描影像作为 HR 影像。LR 影像采用 Greenspan (2009) 和 Gholipour 等人 (2010) 给出的方法降采样 HR 影像获得。实验结果表明, 提出方法在数据集上的 PSNR 系数达到 40.1 dB, SSIM 系数达到 0.94, 优于基于多图谱像素块匹配的 SR 方法 (Shi 等, 2013) 的 36.7 dB 与 0.91。

为进一步提升心脏影像的 SR 重建质量, Oktay 等人 (2016) 将 SC-CNN 网络进一步扩展为支持多输入通道的残差网络 (multi-image channel CNN, MC-CNN), 通过借鉴孪生神经网络 (Bromley 等, 1993) 的思想, 支持不同成像平面 (长轴与短轴) CMR 序列

多通道输入, 以获得更多的图像特征。为评估网络模型性能, Oktay 等人 (2016) 将 1 233 位健康成人 CMR 电影序列中舒张末期影像作为 HR 影像, LR 影像基于降采样转换模型 (Greenspan, 2009) 获得。训练集与测试集规模为 143 与 10。SR 重建质量对比如表 2 所示, MC-CNN 模型相较于 SC-CNN 模型在 PSNR 系数上有 0.5 dB 的提升, 达到 25.26 dB; 在 SSIM 系数上有 0.01 的提升, 达到 0.818。MC-CNN 模型有较高的自由度, 相较于孪生网络模型重建质量更好, 但模型复杂度较高, 需要较长的训练时间。最后, Oktay 等人 (2016) 测量了 18 例 SR 重建短轴影像的左心室 (LV) 容积与心肌 (MYO) 距离, 并计算与参考 HR 影像测量值间的豪斯多夫距离, 用以评价 SR 重建影像在心脏功能评估方面的表现。其中, MYO 分割采用多图谱分割方法 (Bai 等, 2013) 实现。重建影像心脏功能评价如表 3 所示。结果表明, CNN 模型重建影像与 HR 影像在心功能评估方面无明显差异。但是, 不同成像平面间的错位问题, 可能导致 MC-CNN 模型 SR 重建质量变差。

表 2 SC-CNN 与 MC-CNN 重建性能对比

Table 2 Performance comparison of SC-CNN and MC-CNN

	SC-CNN (仅短轴)	孪生神经网络 (短轴与四腔长轴)	MC-CNN (短轴与两腔长轴)	MC-CNN (短轴、两腔长轴与四腔长轴)
PSNR/dB	24.76 ± 0.48	25.13 ± 0.48	25.15 ± 0.47	25.26 ± 0.37
SSIM	0.807 ± 0.009	0.814 ± 0.013	0.814 ± 0.012	0.818 ± 0.012
p 值	0.005	0.016	0.017	-

注: “-”代表原文献中对应指标未给出。

结合器官的形状与位置的先验知识是提高图像分析性能的关键, Oktay 等人 (2018) 提出基于一种

新正则化模式的训练策略, 将心脏先验知识融入到 CNN 中, 结合该策略的网络称为解剖结构约束的神

表 3 CNN 模型与传统方法重建影像的心脏功能评价对比

Table 3 Evaluation of cardiac function on SR reconstruction images by CNN and traditional methods

评价指标	线性插值 SR 重建影像	CNN 模型 SR 重建影像	HR 影像
LV 容量/ml	11.72 ± 6.96	9.09 ± 5.36	8.24 ± 5.36
平均距离/mm	1.49 ± 0.30	1.38 ± 0.29	1.38 ± 0.28
豪斯多夫距离/mm	7.74 ± 1.73	6.67 ± 1.77	6.70 ± 1.85

神经网络(anatomically constrained neural network, AC-NN)。Oktay 等人(2018)通过自编码器与预测网络结合提出 T-L 正则化模型,模型结构如图 10 所示。模型学习得到该隐藏表示空间由影像标签空间与强度空间的映射获取,使 SR 网络模型训练过程中能更多地学习影像的全局信息而不只局限于像素级信息。方法很好地抑制了由呼吸、切片分辨率不足等因素导

致的运动伪影对临床分析造成的影响。为评估 AC-NN 模型的性能,Oktay 等人(2018)采用英国数码心脏计划数据集所提供的共 1 200 对 CMR 短轴序列作为 HR/LR 心脏影像。其中,1 000 对用于训练,200 对用于测试。实验结果表明,相比于 MC-CNN 模型,AC-NN 在 SSIM 系数上有 0.013 的提升,达到 0.796。同时,ACNN 模型的时间性能是 MC-CNN 模型的 5 倍。




图 10 T-L 正则化模型结构图

Fig. 10 Structural of the T-L regularization model

Masutani 等人(2020)分析了 4 种 CMR 影像 SR 重建网络模型(Retson 等,2019;Chartrand 等,2017;Zhu 等,2019)的性能。网络为作用于 CMR 影像的单帧与多帧处理浅层 CNN(k-SRNet 与 kt-SRNet)与深层 U-Net(k-UNet 与 kt-UNet);其中,kt-SRNet 与 kt-UNet 基于 3 维卷积,提取输入影像的时间特性。Masutani 等人(2020)采用合作院方提供的 367 位患者的短轴 CMR 影像序列作为 HR 影像。LR 影像通过对 HR 影像傅里叶变换后降采样获得。70% 用于训练,30% 用于验证。实验结果表明,99.2% 的重建影像均是深度模型,质量更高。浅层 CNN 与深层 U-Net 的 SR 重建性能对比如表 4 所示。结果表明,

深层网络 SSIM 系数更好,影像重建质量更高,但优势并不显著。除此之外,Masutani 等人(2020)测量了 10 位临床患者 CMR 影像的 LV 容积、LV SV 与 LV EF,并检验是否与参考值存在偏差,测量与检验结果如表 5 所示。结果表明,SR 重建影像在 LV 容积和 LV EF 等值上与 HR 参考值没有显著性差异。

综上,CMR 3 维 SR 重建方法引入 3 维卷积,使得方法更好地考虑了心脏的空间结构,结合了心脏影像相邻帧间信息进行分析。部分方法相较于 CMR 2 维 SR 重建方法取得了更好的 SR 重建效果。但是,方法分析的心脏影像数据量少且大多未公开,而且方法更大的感受域增加了计算量,一定程度上

表 4 深度与浅层网络重建性能对比

Table 4 Performance comparison of deep and shallow networks

比例因子	k-SRNet SSIM	k-UNet SSIM	kt-SRNet SSIM	kt-UNet SSIM
2 ×	0.989 ± 0.006	0.989 ± 0.006	0.989 ± 0.006	0.990 ± 0.006
4 ×	0.969 ± 0.016	0.971 ± 0.015	0.969 ± 0.017	0.972 ± 0.014
8 ×	0.940 ± 0.026	0.943 ± 0.025	0.941 ± 0.027	0.945 ± 0.025
16 ×	0.895 ± 0.036	0.902 ± 0.035	0.897 ± 0.036	0.900 ± 0.035
32 ×	0.839 ± 0.045	0.850 ± 0.044	0.842 ± 0.045	0.845 ± 0.045
64 ×	0.760 ± 0.056	0.776 ± 0.056	0.765 ± 0.057	0.780 ± 0.056

表 5 SR 影像、LR 影像与 HR 影像心功能评估值对比

Table 5 Evaluation of cardiac function on SR and LR images compared with HR images

测量项	HR 参考值	SR 测量	SR 成对 t 检验的 p 值	LR 测量	LR 成对 t 检验的 p 值
LV EDV/ml	152 ± 42	152 ± 42	0.99	151 ± 43	0.64
LV ESV/ml	56 ± 22	55 ± 23	0.40	56 ± 22	0.99
LV SV/ml	96 ± 24	97 ± 25	0.57	95 ± 23	0.54
LV EF/%	64 ± 7	65 ± 6	0.27	64 ± 6	0.90

降低了时间性能。

3.3 其他维度的 CMR 超分辨率重建

4D MR 血流成像是一种新兴的成像技术,其能获取全体积覆盖的时空 3 维血流速度,有助对心脏与大血管的血流动力学参数的定量、定性分析。Ferdian 等人(2020)提出一种 SR 深度学习方

于提升 4D MR 血流成像的空间分辨率并去除噪声。与 SRGAN 中的生成器(Ledig 等,2017)结构相似,提出的模型是深度残差网络,其结构如图 11 所示。网络包含血流速度与血管结构双通道输入,其中血流速度分量分别来自 x,y,z 3 个方向。方法解决了由 4D 血流数据分辨率不足与噪声对患者血流评估造成




图 11 4D 流网络结构图

Fig. 11 Structure of 4D flow network

影响的问题,为评估提出模型的性能,Ferdian 等人(2020)使用计算流体动力学(computational fluid dynamics, CFD)模型(Rispoli 等,2015)模拟得到4D 血流数据作为HR 影像。LR 影像通过对HR 影像在傅里叶变换后的频域进行降采样并添加高斯噪声获得。评价指标为相对速度误差(relative speed error, RSE)。实验结果表明,提出模型在高速与低速血流速度下的RSE 系数分别为7.05%与23.16%,均有较高的重建质量。Ferdian 等人(2020)还通过志愿者扫描数据验证提出模型的性能,血流速度在3个方向的误差分别为2.6%、-1.1%与-4.8%。

Ferdian 等人(2020)实现的4D 血流数据的SR 重建方法有着一定研究意义,满足了临床分析中高分辨率、去噪的需求。但可供做SR 分析研究的数据量相对于2维、3维重建方法小,且由于数据维度的提升,计算量会相应增大,目前对于更高维度CMR 影像SR 重建的研究相对较少,仍是值得深入探索研究的方向。

4 基于深度学习的超分辨率技术的应用

SR 重建技术为解决成像质量与设备扫描时间之间的矛盾提供了一条有效途径。凭借优于传统方法的表达能力,基于深度学习的SR 技术在这一领域取得了不错的成绩。高分辨率影像有助于对后续心脏影像进行智能分析,对心脏病筛查与诊断起着重要作用。

Steeden 等人(2020)将基于3D U-Net 的SR 方法应用于SSFP 影像序列,重建后的影像质量优于传统SR 重建影像和LR 影像,能更准确地描述心脏和血管的解剖结构,对先天性心脏疾病的诊断与治疗有很大帮助。Giannakidis 等人(2017)将基于CNN 的SR 方法应用于LGE-CMR 影像集,获得高质量LGE-CMR 影像,能更真实地描述心肌的瘢痕特征,从而更准确地对心脏病理进行风险分层和指导干预。Ferdian 等人(2020)将4D 流网络模型应用于4D 流数据集,快速准确地获得重建4D 流数据,在去噪的同时清晰显示了流体与非流体间的边界,能更好地计算血流参数,进而评价患者体内血流情况。

基于深度学习的SR 技术有助于提升心脏组织

分割精度,相较于LR 心脏影像,基于SR 重建影像可获得更准确的分割结果,对心脏疾病检测与诊断精度的提升有重大意义。Mahapatra 和 Bozorgtabar (2019)基于SR 重建SSFP 影像,采用U-Net 模型,实现LV 分割。结果表明,相较于LR 影像分割结果,Dice 由83.4%提升至90.1%,低于标准HR 影像(长时间扫描获得)分割的Dice 系数1.2%。Oktay 等人(2016)基于SR 重建后的短轴CMR 影像,采用多图谱方法(Bai 等,2013),实现MYO 分割。结果表明,由HR 影像与SR 重建影像获得MYO 分割结果的边界豪斯多夫距离仅为 4.73 ± 1.03 mm,相较于LR/HR 影像的 5.50 ± 1.08 mm 更加准确。综上,基于深度学习的SR 技术有助于提升心脏组织分割精度。

5 讨论

除按影像维度组织CMR SR 重建方法以外,从其他角度组织也是可行的。例如,根据方法所基于的不同网络模型,比较U-Net、GAN、LSTM、Res-Net 等不同模型在CMR SR 重建的性能差异。通过比较方法是否结合了时序信息,可探究时序信息对CMR SR 重建性能的影响。对于HR 影像退化处理构造LR 影像的方法,可按退化方法不同,分为基于插值函数退化、基于傅里叶域退化以及手动筛选切片退化的方法等。

有必要说明的是,仍有大量基于深度学习模型的非心脏影像重建的代表性方法,对心脏影像的SR 重建有借鉴意义。例如Peng 等人(2020)提出的一种空间感知的插值网络(spatially aware interpolation network, SAINT)用于提升肝脏、结肠等部位影像的层间分辨率,取得了优秀的重建效果。对于同样层间切片数少的LR 心脏影像而言,将SAINT 用于影像SR 重建是有意义的。Sui 等人(2020)提出了一种学习梯度先验信息用于指导脑部影像的各向同性SR 重建方法,在SR 重建各向同性的HR 心脏影像时同样可引入梯度先验信息以提高重建质量。Chen 等人(2020)提出了结合空间与小波域的双流SR 网络(spatial wavelet super-resolution network, SWD-Net)用于提升淋巴结组织影像的分辨率,可将SWD-Net 用于心脏影像SR 重建来满足医疗诊断中所需的高层内分辨率。柏正尧和陶劲宇(2022)提

出了基于伪 3D 可分离卷积的脑部 MR 影像的 SR 重建方法。方法通过伪 3D 卷积代替传统 3D 卷积,在保证 SR 重建质量的同时降低模型参数量与计算复杂度,并缓解了 3 维 SR 重建方法对于数据量的需求。Zhou 和 Zhou (2020) 提出了双域循环网络 (dual domain recurrent network, DuDoRNet), 在 T1 先验基础上,结合图像域和 k 空间域实现 MR 快速重建。该方法同样可用于心脏影像 SR 重建,在影像空间域重建以外,确保 k 空间域的一致性以进一步提升 SR 重建质量,同时循环学习可缓解过拟合问题。

另外有必要指出的是,值得心脏影像 SR 重建借鉴的方法不仅限于医学影像 SR 重建方法,计算机视觉 (computer vision, CV) 领域前沿 SR 技术对于 CMR SR 重建同样有借鉴意义,例如,深度 CNN 在视频超分辨率 (video SR, VSR) 重建任务中表现出良好的效率与效果,Tian 等人 (2020) 提出的时域可变的配准网络 (temporally-deformable alignment network, TDAN),以及 Xiang 等人 (2020) 提出基于 LSTM 与可变特征插值网络的单阶段 VSR 重建模型等。心脏的跳动特性使得心脏影像的 VSR 重建在临床诊断中同样至关重要,因此可与上述模型结合并应用于心脏影像 SR 重建。此外,可将心脏的周期性跳动作为先验知识 (Lin 等, 2020), 进一步改善重建效果。真实场景 SR 重建是计算机视觉 (CV) SR 中活跃的研究方向之一,其对于训练数据不足、未知退化场景有着优秀的重建效果,例如 Ji 等人 (2020) 提出了基于退化核估计与噪声注入的精确退化框架 RealSR, Bell-Kligler 等人 (2019) 提出了基于 KernelGAN 获得真实的退化图像的无监督学习方法。在心脏影像的 SR 重建任务中,HR 影像成像时间长、成本高,导致成对的训练数据难获取,且 LR 影像大多通过插值、抽层等退化手段获得,对真实退化场景以及噪声考虑不足。故可引入真实场景 SR 思想,但由于医学影像与自然图像的成像场景不同、医学影像没有颜色特征等原因,二者并未很好结合。近年来注意力机制广泛应用于各类 CV 任务中,成为先进网络模型中不可或缺的部分。Cai 等人 (2020) 通过引入通道注意力机制 (Hu 等, 2018), 提出基于残差通道注意力的 GAN。通道注意力机制考虑特征通道间的相互依赖关系以产生更好的 SR 效果。周波等人 (2021) 在通道注意力机制 (Hu 等,

2018) 的基础上结合考虑空间层面信息,提出了区域级通道注意力下的图像超分辨率方法,能自适应地关注不同通道和不同空间区域上的信息,获得了更好的 SR 重建效果。Mei 等人 (2020) 提出将非局部注意力机制 (Wang 等, 2018) 用于挖掘图像跨尺度特征相关性,获取内部先验知识,提升模型性能。对于心脏影像 SR 重建方法而言,可在网络模型中引入注意力模块,提升重建质量。

6 结 语

心脏影像 SR 重建有效地解决了成像质量与扫描时间的矛盾。相较于自然图像 SR 重建,心脏影像 SR 有其鲜明的特点:1) 评价指标更多样化、更目的化和更应用化;2) 重建质量关注重点更局部化;3) 训练数据获取更困难,数据量更少。

本文搜索并挑选了基于深度学习模型实现心脏影像 SR 重建的 13 篇学术文献,对心脏影像数据来源与规模、常用的评价指标进行了总结。对于文献中提出的网络模型,依据其操作影像数据的维度划分为 3 类,依次介绍模型的特色,给出模型结构图、模型数据集的构成,以及取得的性能评价结论。最后讨论了按其他维度组织 SR 重建方法的可行性与意义,以及对于心脏影像 SR 重建有借鉴意义的医学影像 SR 重建方法与 CV SR 前沿技术。

基于深度学习的心脏 SR 重建技术取得了较大进展,但在运动伪影抑制、模型简化程度与时间性能方面仍有进步空间,除此之外,现有模型基本完全依靠网络强大的表达能力,鲜有临床先验知识的引入,最后,模型间性能对比相对较少,且领域内缺少代表性的可用于评价不同心脏 SR 重建模型性能的数据集。综上,基于深度学习的 SR 技术在心脏影像 SR 重建领域仍有极大的发展空间。


参考文献 (References)

- Bai W J, Shi W Z, O' Regan D P, Tong T, Wang H Y, Jamil-Copley S, Peters N S and Rueckert D. 2013. A probabilistic patch-based label fusion model for multi-atlas segmentation with registration refinement: application to cardiac MR images. *IEEE Transactions on Medical Imaging*, 32(7): 1302-1315 [DOI: 10.1109/TMI.2013.2256922]
- Bai Z Y and Tao J Y. 2022. Super-resolution reconstruction of brain

- images using Pseudo-3D convolutional network. *Computer-Aided Design and Computer Graphics*, 34(柏正尧,陶劲宇. 2022. 采用伪3D卷积网络的脑部MRI图像超分辨率重建. 计算机辅助设计与图形学学报, 34) [DOI:10.3724/SP.J.1089.2022.18793]
- Basty N and Grau V. 2018. Super resolution of cardiac cine MRI sequences using deep learning//Proceedings of the 3rd International Workshop on Reconstruction and Analysis of Moving Body Organs. Granada, Spain: Springer; 22-31 [DOI: 10.1007/978-3-030-00946-5_3]
- Bell-Kligler S, Shocher A and Irani M. 2019. Blind super-resolution kernel estimation using an internal-GAN//Proceedings of the 33rd Conference on Neural Information Processing Systems. Vancouver, Canada: NeurIPS; 284-293
- Bromley J, Guyon I, LeCun Y, Säckinger E and Shah R. 1993. Signature verification using a “Siamese” time delay neural network//Proceedings of the 6th International Conference on Neural Information Processing Systems. Denver, USA: Morgan Kaufmann; 737-744 [DOI: 10.5555/2987189.2987282]
- Cai J, Meng Z B and Ho C M. 2020. Residual channel attention generative adversarial network for image super-resolution and noise reduction//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle, USA: IEEE; 1852-1861 [DOI: 10.1109/CVPRW50498.2020.00235]
- Chartrand G, Cheng P M, Vorontsov E, Drozdal M, Turcotte S, Pal C J, Kadoury S and Tang A. 2017. Deep learning: a primer for radiologists. *Radiographics*, 37(7): 2113-2131 [DOI: 10.1148/rg.2017170077]
- Chen Z, Guo X Q, Yang C, Ibragimov B and Yuan Y X. 2020. Joint spatial-wavelet dual-stream network for super-resolution//Proceedings of the 23rd International Conference on Medical Image Computing and Computer-Assisted Intervention. Lima, Peru: Springer; 184-193 [DOI: 10.1007/978-3-030-59722-1_18]
- Dong C, Loy C C, He K M and Tang X O. 2016. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38(2): 295-307 [DOI: 10.1109/TPAMI.2015.2439281]
- Ferdian E, Suinesiaputra A, Dubowitz D J, Zhao D, Wang A, Cowan B and Young A A. 2020. 4DFlowNet: super-resolution 4D flow MRI using deep learning and computational fluid dynamics. *Frontiers in Physics*, 8; #138 [DOI: 10.3389/fphy.2020.00138]
- Gholipour A, Estroff J A and Warfield S K. 2010. Robust super-resolution volume reconstruction from slice acquisitions: application to fetal brain MRI. *IEEE Transactions on Medical Imaging*, 29(10): 1739-1758 [DOI: 10.1109/TMI.2010.2051680]
- Giannakidis A, Oktay O, Keegan J, Spadotto V, Voges I, Smith G, Pierce I, Bai W, Rueckert D, Ernst S, Gatzoulis M A, Pennell D J, Babu-Narayan S and Firmin D N. 2017. Super-resolution reconstruction of late gadolinium cardiovascular magnetic resonance images using a residual convolutional neural network//Proceedings of the 25th Scientific Meeting of the International Society for Magnetic Resonance in Medicine. Honolulu, USA; [s. n.]
- Greenspan H. 2009. Super-resolution in medical imaging. *The Computer Journal*, 52(1): 43-63 [DOI: 10.1093/comjnl/bxm075]
- Harris J L. 1964. Diffraction and resolving power. *Optical Society of America*, 54: 931-936 [DOI:10.1364/JOSA.54.000931]
- Hu J, Shen L and Sun G. 2018. Squeeze-and-excitation networks//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE; 7132-7141 [DOI: 10.1109/CVPR.2018.00745]
- Ji X Z, Cao Y, Tai Y, Wang C J, Li J L and Huang F Y. 2020. Real-world super-resolution via kernel estimation and noise injection//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle, USA: IEEE; 1914-1923 [DOI: 10.1109/CVPRW50498.2020.00241]
- Kobayashi H, Nakayama R, Hizukuri A, Ishida M, Kitagawa K and Sakuma H. 2020. Improving image resolution of whole-heart coronary MRA using convolutional neural network. *Journal of Digital Imaging*, 33(2): 497-503 [DOI: 10.1007/s10278-019-00264-6]
- Ledig C, Theis L, Huszar F, Caballero J, Cunningham A, Acosta A, Aitken A, Tejani A, Totz J, Wang Z H and Shi W Z. 2017. Photo-realistic single image super-resolution using a generative adversarial network//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE; 105-114 [DOI: 10.1109/CVPR.2017.19]
- Lim B, Son S, Kim H, Nah S and Lee K M. 2017. Enhanced deep residual networks for single image super-resolution//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops. Honolulu, USA: IEEE; 1132-1140 [DOI: 10.1109/CVPRW.2017.151]
- Lin J Y, Chang Y C and Hsu W H. 2020. Efficient and phase-aware video super-resolution for cardiac MRI//Proceedings of the 23rd International Conference on Medical Image Computing and Computer-Assisted Intervention. Lima, Peru: Springer; 66-76 [DOI: 10.1007/978-3-030-59719-1_7]
- Mahapatra D and Bozorgtabar B. 2019. Progressive generative adversarial networks for medical image super resolution[EB/OL]. [2021-02-27]. <https://arxiv.org/pdf/1902.02144.pdf>
- Masutani E M, Bahrami N and Hsiao A. 2020. Deep learning single-frame and multiframe super-resolution for cardiac MRI. *Radiology*, 295(3): 552-561 [DOI: 10.1148/radiol.2020192173]
- Mei Y Q, Fan Y C, Zhou Y Q, Huang L C, Huang T. S and Shi H H. 2020. Image super-resolution with cross-scale non-local attention and exhaustive self-exemplars mining//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE; 5689-5698 [DOI: 10.1109/CVPR42600.2020.00573]

- Oktaç O, Bai W J, Lee M, Guerrero R, Kamnitsas K, Caballero J, de Marvao A, Cook S, O'Regan D and Rueckert D. 2016. Multi-input cardiac image super-resolution using convolutional neural networks//Proceedings of the 19th International Conference on Medical Image Computing and Computer-Assisted Intervention. Athens, Greece; Springer; 246-254 [DOI: 10.1007/978-3-319-46726-9_29]
- Oktaç O, Ferrante E, Kamnitsas K, Heinrich M, Bai W J, Caballero J, Cook S A, de Marvao A, Dawes T, O'Regan D P, Kainz B, Glocker B and Rueckert D. 2018. Anatomically constrained neural networks (ACNNs): application to cardiac image enhancement and segmentation. *IEEE Transactions on Medical Imaging*, 37(2): 384-395 [DOI: 10.1109/TMI.2017.2743464]
- Peng C, Lin W A, Liao H F, Chellappa R and Zhou S K. 2020. SAINT: spatially aware interpolation network for medical slice synthesis//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA; IEEE; 7747-7756 [DOI: 10.1109/CVPR42600.2020.00777]
- Retson T A, Besser A H, Sall S, Golden D and Hsiao A. 2019. Machine learning and deep neural networks in thoracic and cardiovascular imaging. *Journal of Thoracic Imaging*, 34(3): 192-201 [DOI: 10.1097/RTI.0000000000000385]
- Rispoli V C, Nielsen J F, Nayak K S and Carvalho J L A. 2015. Computational fluid dynamics simulations of blood flow regularized by 3D phase contrast MRI. *BioMedical Engineering OnLine*, 14(1): #110 [DOI: 10.1186/s12938-015-0104-7]
- Sander J, de Vos B D and Išgum I. 2020. Unsupervised super-resolution: creating high-resolution medical images from low-resolution anisotropic examples [EB/OL]. [2021-02-27]. <https://arxiv.org/pdf/2010.13172.pdf>
- Shi W Z, Caballero J, Ledig C, Zhuang X H, Bai W J, Bhatia K, de Marvao A M S M, Dawes T, O'Regan D and Rueckert D. 2013. Cardiac image super-resolution with global correspondence using multi-atlas patchmatch//Proceedings of the 16th International Conference on Medical Image Computing and Computer-Assisted Intervention. Nagoya, Japan; Springer; 9-16 [DOI: 10.1007/978-3-642-40760-4_2]
- Steeden J A, Quail M, Gotschy A, Mortensen K H, Hauptmann A, Arridge S, Jones R and Muthurangu V. 2020. Rapid whole-heart CMR with single volume super-resolution. *Journal of Cardiovascular Magnetic Resonance*, 22(1): #56 [DOI: 10.1186/s12968-020-00651-x]
- Sui Y, Afacan O, Gholipour A and Warfield S K. 2020. Learning a gradient guidance for spatially isotropic MRI super-resolution reconstruction//Proceedings of the 23rd International Conference on Medical Image Computing and Computer-Assisted Intervention. Lima, Peru; Springer; 136-146 [DOI: 10.1007/978-3-030-59713-9_14]
- Tian Y P, Zhang Y L, Fu Y and Xu C L. 2020. TDAN: temporally-deformable alignment network for video super-resolution//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA; IEEE; 3357-3366 [DOI: 10.1109/CVPR42600.2020.00342]
- Wang X L, Girshick R, Gupta A and He K M. 2018. Non-local neural networks//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA; IEEE; 7794-7803 [DOI: 10.1109/CVPR.2018.00813]
- Xiang X Y, Tian Y P, Zhang Y L, Fu Y, Allebach J. P and Xu C L. 2020. Zooming slow-mo: fast and accurate one-stage space-time video super-resolution//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA; IEEE; 3367-3376 [DOI: 10.1109/CVPR42600.2020.00343]
- Zhao C, Shao M H, Carass A, Li H, Dewey B E, Ellingsen L M, Woo J, Guttman M A, Blitz A M, Stone M, Calabresi P A, Halperin H and Prince J L. 2019. Applications of a deep learning method for anti-aliasing and super-resolution in MRI. *Magnetic Resonance Imaging*, 64: 132-141 [DOI: 10.1016/j.mri.2019.05.038]
- Zhao M, Liu X H, Liu H and Wong K K L. 2020. Super-resolution of cardiac magnetic resonance images using laplacian pyramid based on generative adversarial networks. *Computerized Medical Imaging and Graphics*, 80: #101698 [DOI: 10.1016/j.compmedimag.2020.101698]
- Zhou B and Zhou S K. 2020. DuDoRNet: learning a dual-domain recurrent network for fast MRI reconstruction with deep T1 prior//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA; IEEE; 4272-4281 [DOI: 10.1109/CVPR42600.2020.00433]
- Zhou B, Li C H and Chen W. 2021. Region-level channel attention for single image super-resolution combining high frequency loss. *Journal of Image and Graphics*, 26(12): 2836-2847 (周波, 李成华, 陈伟. 2021. 区域级通道注意力融合高频损失的图像超分辨率重建. *中国图象图形学报*, 26(12): 2836-2847) [DOI: 10.11834/jig.200582]
- Zhu G M, Jiang B, Tong L, Xie Y, Zaharchuk G and Wintermark M. 2019. Applications of deep learning to neuro-imaging techniques. *Frontiers in Neurology*, 10: #869 [DOI: 10.3389/FNEUR.2019.00869]

作者简介



李书林, 1998年生, 男, 硕士研究生, 主要研究方向为医学影像处理。

E-mail: 2001766@stu.neu.edu.cn



冯朝路, 通信作者, 男, 副教授, 博士生导师,
主要研究方向为图像增强、图像分割、图像
理解。

E-mail: fengchaolu@cse.neu.edu.cn

于鲲, 女, 讲师, 主要研究方向为医学影像智能分析。

E-mail: yukun@bmie.neu.edu.cn

刘鑫, 男, 工程师, 主要研究方向为医学影像智能分析。

E-mail: liu.x_neu@neusoftmedical.com

江鑫, 男, 工程师, 主要研究方向为医学影像智能分析。

E-mail: x-jiang@neusoftmedical.com

赵大哲, 女, 教授, 博士生导师, 主要研究方向为图像处理、机
器学习。E-mail: zhaodz@neusoft.com