



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

许正玺, 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, 黄轶枢, 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: TP391 文献标识码: A 文章编号: 1006-8961(2022)03-0672-15

论文引用格式: Li Y and Song P H. 2022. Review of transfer learning in medical image classification. Journal of Image and Graphics, 27(03):0672-0686
(黎英, 宋佩华. 2022. 迁移学习在医学图像分类中的研究进展. 中国图象图形学报, 27(03):0672-0686) [DOI:10.11834/jig.210814]

迁移学习在医学图像分类中的研究进展

黎英, 宋佩华*

南宁师范大学广西人机交互与智能决策重点实验室, 南宁 530001

摘要: 医学影像作为医疗数据的主要载体,在疾病预防、诊断和治疗中发挥着重要作用。医学图像分类是医学影像分析的重要组成部分。如何提高医学图像分类效率是一个持续的研究问题。随着计算机技术进步,医学图像分类方法已经从传统方法转到深度学习,再到目前热门的迁移学习。虽然迁移学习在医学图像分类中得到较广泛应用,但存在不少问题,本文对该领域的迁移学习应用情况进行综述,从中总结经验和发现问题,为未来研究提供线索。1) 对基于迁移学习的医学图像分类研究的重要文献进行梳理、分析和总结,概括出3种迁移学习策略,即迁移模型的结构调整策略、参数调整策略和从迁移模型中提取特征的策略;2) 从各文献研究设计的迁移学习过程中提炼共性,总结为5种迁移学习模式,即深度卷积神经网络(deep convolution neural network, DCNN)模式、混合模式、特征组合分类模式、多分类器融合模式和二次迁移模式。阐述了迁移学习策略和迁移学习模式之间的关系。这些迁移学习策略和模式有助于从更高的抽象层次展现迁移学习应用于医学图像分类领域的情况;3) 阐述这些迁移学习策略和模式在医学图像分类中的具体应用,分析这些策略及模式的优点、局限性及适用场景;4) 给出迁移学习在医学图像分类应用中存在的问题并展望未来研究方向。

关键词: 医学图像;图像分类;迁移学习;迁移学习策略;迁移学习模式

Review of transfer learning in medical image classification

Li Ying, Song Peihua*

Guangxi Key Laboratory of Human-machine Interaction and Intelligent Decision, Nanning Normal University, Nanning 530001, China

Abstract: Medical image classification is a key element of medical image analysis. The method of medical image classification has been evolving in deep learning and transfer learning. A large number of important literatures of medical image classification are analyzed based on transfer learning. As a result, three transfer learning strategies and five modes of medical image classifying are summarized. The transfer learning modes are constructed based on general characteristics which extracted from designed transfer learning processes theoretically. The relevance of the transfer learning strategies and the modes is illustrated as well. These transfer strategies and modes illustrated the application of transfer learning in this field from a higher level of abstraction. The applications, advantages, limitations of these transfer learning strategies and modes are analyzed. The transfer learning in the context of medical image feature extraction and classification is the model-based transfer learning. Most of the migrated models are deep convolution neural network (DCNN). High classifying efficiency is obtained due to ImageNet (a large public image database) training results. To migrate model from the source domain to the target domain, the model needs to be adapted to the tasks of the targeted domain. From the important literature of medi-

收稿日期:2021-09-08;修回日期:2021-11-18;预印本日期:2021-11-25

* 通信作者: 宋佩华 455756282@qq.com

基金项目: 国家自然科学基金项目(62062051, 62066032)

Supported by: National Natural Science Foundation of China(62062051, 62066032)

cal image classification, three transfer model adaptive strategies were sorted out. They are structure fit, parameter option and migrated model based features extraction. The strategies of fitted structure are to modify the structure of the migrated model. Layers can be deleted or added as needed. These layers can be as convolution layer, full connection layer, feature smoothing layer, feature extracting layer, and batch normalizing layer, respectively. The optional strategies of parameter are to re-train the migrated model to adjust the model parameters via using the target domain data. Both the parameters of convolution layer and the parameters of full connection layer can be fitted. The migrated-model-based strategy of features extraction is only used for feature extraction. Image features can be extracted from the convolution layer and the full connection layer. Five transfer learning modes were sorted out based on the literature of medical image classification. They are the DCNN mode, the hybrid mode, the mode of fused feature and classification. The mode of multi-classifier fusing and the mode of transferring are conducted two times all. For instance, the fitting strategies of structure and parameters of convolution layer are used in the DCNN mode to get more accurate features. The transfer learning modes can basically cover all kinds of transfer learning processes in medical image classification researches. The DCNN mode is to use a DCNN to complete image feature extraction and classification. The hybrid model is composed of a DCNN and a traditional classifier. The former is used for feature extracting and the latter is used for classifying. It has the advantage of DCNN feature extraction and advantage of traditional classified classifier. The mode of integrated feature and classification is composed of feature extraction methods and a classifier. Feature extracting methods can be a DCNN or manual features. The mode of multi-classifier fusing is composed of multiple classifiers. The final classifying result is obtained based on multiple classified integrating results. The integrating result is more reliable than the result from single classifier mode (i.e., the DCNN mode and the hybrid mode). In the twice mode of transferring, the initial model is trained in the source domain, then it is migrated to the temporary targeted domain to be trained for the second time, and finally it is migrated to the final targeted domain to be trained for the third time. Compared to first transfer, this mode priority is that the triple migrated model accumulates more knowledge of training. The transfer-learning based issues and of medical image classification potentials are illustrated as below: 1) It is difficult to pick an efficient transfer learning algorithm. Due to the diversity and complexity of medical images, the generalization capability of transfer learning algorithm is to be strengthened. Manual option for a specific image classifying task is often based on continuous high computational cost tests. A low cost automatic transfer learning algorithm is a challenging issue. 2) The modification of transfer model and the setting of mega parameters are lack of theoretical mechanism. The structure and parameters of the migrated model can only be modified through the existing experiences and continuous experiments, and the setting of mega parameters is not different, which lead to the low efficiency of transfer learning. 3) It is challenged to classify rare disease images due to pathological image data samples of rare diseases. The antagonistic transfer learning can generate and enhance target domain data. The heterogeneous transfer learning yield to transfer the knowledge of different modalities or the source domain to target domain. Therefore, the two methods of transfer learning can be further developed in image classification of rare diseases.

Key words: medical images; image classification; transfer learning; transfer learning strategies; transfer learning mode

0 引言

医学图像分类在计算机辅助疾病预测、诊断和治疗中发挥着重要作用。图像分类的建模核心是提取图像特征和构建分类器(俞益洲等,2019)。传统医学图像分类方法采用人工设计特征,计算复杂、效率低下、分类效果不理想、建立的特征抽取和模型选择难以泛化(郑光远等,2018)。卷积神经网络(convolution neural network, CNN)可以直接采用原

始图像作为输入,自动学习和提取特征,避免传统算法的特征定义和参数设置的复杂过程,在各领域的表现比单纯使用传统算法更加优秀,有些甚至达到专业技术人员水平(杨培伟等,2021)。目前,深度学习已经在医学图像分类领域广泛应用(陈诗慧等,2017;俞益洲等,2019;陈弘扬等,2021;杨培伟等,2021)。但是,生物医学图像公开数据量少,限制了CNN模型优势的发挥。

迁移学习具有克服医学影像标注数据稀缺问题而获得更好分类效果的优势(俞益洲等,2019),是

该领域有潜力的研究方向(陈弘扬等,2021),已逐渐应用于癌症、肺部、肝脏、脑部、眼部、骨科和皮肤等各种疾病病理图像的分类检测。赵宸等人(2021)提出一种对抗生成网络,用来生成皮肤癌图像样本,通过增加样本的方法提高皮肤癌分类准确性,该研究属于对抗式迁移学习。李赵旭等人(2021)通过模型改进和迁移学习对网络模型进行优化,用来对乳腺癌图像进行分类,该研究属于基于模型的迁移学习。然而,迁移学习在医学图像分类应用中还存在不少问题,不利于迁移学习进一步应用。本文对医学图像分类领域的迁移学习应用情况进行综述,从中总结经验和发现问题,为未来研究提供线索。首先,围绕医学图像分类的特征提取和分类两大核心任务,通过梳理和分析相关重要文献,总结其中包含的迁移学习策略;其次,分析各研究文献的迁移学习过程,从中提炼出迁移学习模式,并阐述迁移学习策略和模式的关系。这些迁移学习策略和模式有助于从更高的抽象层次展现迁移学习在医学图像分类领域的应用;然后,详细阐述迁移学习策略和模式在医学图像分类中的具体应用及优缺点;最后,总结存在的问题并展望未来的研究方向。

1 迁移学习在医学图像分类中的应用

1.1 迁移学习分类

迁移学习从不同角度可分为多种类型。1)按迁移知识,迁移学习分为基于数据和基于模型的迁移学习。基于数据的迁移学习按迁移内容分为基于样本和基于特征的迁移学习,按是否引入对抗学习分为传统和对抗式迁移学习。基于样本的迁移学习是在源域数据和目标域数据有相同或相似特征情况下,从源域中筛选出与目标域数据具有相似分布的有标签样本,用来帮助训练目标域模型以便提高模型精度。基于特征的迁移学习是通过学习一对映射函数,将源域和目标域数据映射到共同的特征空间,从而减少域间的差异。如果基于样本的迁移学习的前提条件不满足,可以考虑基于特征的迁移学习。传统迁移学习仅利用原有数据进行迁移,而对抗式迁移学习利用生成对抗网络(generative adversarial network, GAN)生成和增强目标域数据,增加了额外的目标域数据,极大提高了数据迁移学习的效率。基于模型的迁移学习也称为基于参数的迁移学习,

是将模型参数、模型先验知识或模型架构等模型层次上的知识迁移到目标域(杨强等,2020)。2)按源域和目标域特征空间是否可通约或标签空间是否相同,迁移学习分为同构和异构迁移学习。目前迁移学习领域大部分工作属于同构迁移学习,少数属于异构迁移学习。在基于特征的迁移学习中,如果源域和目标域的特征空间没有重叠,但是可能存在某些转换方式实现迁移学习,就属于异构迁移学习(杨强等,2020)。3)按是否自动利用以前的迁移学习经验,迁移学习分为自动和非自动迁移学习。自动迁移学习通过经验自动选择性能较好的迁移学习算法,可以避免人工选择迁移学习算法的昂贵计算代价。迁移学习的各种分类如图1所示。




Fig. 1 Classification of transfer learning

1.2 迁移学习在医学图像分类中的应用

针对医学图像特征提取和分类这两大核心任务,绝大多数研究采用基于模型的迁移学习,并且主要采用深度卷积神经网络(deep convolution neural network, DCNN)作为迁移模型。这样做的一个原因是绝大部分 DCNN 都是为 ImageNet 大规模视觉识别挑战(imagenet large scale visual recognition challenge, ILSVRC)比赛开发的,具有较高的图像分类性能。另一个原因是 ImageNet 这个大型图像数据集中丰富的图像数据包含了一般图像的通用特征,甚至可能包含与医学图像相似的某些深度特征,因此在该数据集上预训练的 DCNN 可以迁移到医学图像分类领域。

DCNN 迁移到目标域后,一般要经过结构调整或者参数调整以便更好地符合目标域的任务要求。调整结构或参数需要一定的策略,这就是结构调整策略和参数调整策略。迁移模型在目标域完成再训练后,如果要从模型中提取特征作为其他分类器的输入,则需要一定策略从模型中提取特征,这就是特征提取策略。

在目标域,从医学图像中提取特征可以采用传统方法或迁移模型来完成,对医学图像分类可以采用传统分类器或迁移模型来完成。根据目标域图像特征提取和分类的完成方式,从相关研究文献中总结出 5 种迁移学习模式:DCNN 模式、混合模式、特征组合分类模式、多分类器融合模式和二次迁移模式。

2 医学图像分类中的迁移学习策略及应用

医学图像分类中的迁移学习策略包括结构调整、参数调整和从迁移模型中提取特征 3 种策略。

2.1 结构调整策略

结构调整策略指修改迁移模型结构的方式,根据需要删除某些层或增加某些层,包括卷积层、完全连接(full connection, FC)层和其他层。其他层属于卷积层或 FC 层,例如池化层属于卷积层,而 softmax 层属于 FC 层。结构调整策略如图 2 所示。




图 2 结构调整策略示意图

Fig. 2 Strategies of structure adjustment

在 ImageNet 上预训练的 DCNN 的目的是将图像分为 1 000 个类,因此至少需要修改它们的分类层以适应目标域的分类数量,同时为了提高分类性能,还需对 FC 层进行其他修改。通过修改迁移模型 FC 层进行医学图像分类的策略已用于多种疾病。例如,肺部疾病中的肺癌(Wang 等,2020)、肺结节(Huang 等,2020)和肺炎(Mohammadi 等,2020),脑部疾病中的阿尔茨海默病(Maqsood 等,

2019)、癫痫(Si 等,2020)和酒精中毒(Wang 等,2019),以及癌症疾病中的乳腺癌(Samala 等,2017)等。以新冠肺炎(corona virus disease 2019, COVID-19)图像分类和肺癌图像分类为例说明修改 FC 层策略的具体应用。针对新冠肺炎图像, Mohammadi 等人(2020)利用预训练的 VGG-16(Visual Geometry Group)、VGG-19、MobileNet 和 InceptionResNet_V2 的卷积层提取胸部 X 线图像的特征,用新建立的一个全连通层完成对 COVID-19 图像的二元分类。该全连通层由 averagepooling2D、flatten、dense、dropout 和最后一层 dense 组成,通过 softmax 层进行 COVID-19 感染与没有感染二分类。实验结果表明,建立的模型能够对 COVID-19 进行二元分类,准确率达 90.0% 以上。针对肺癌图像, Wang 等人(2020)使用在 LUNA16(lung nodule analysis 16)公共医学图像数据集上预训练的残差神经网络 ResNet-34 作为迁移模型,在原有模型只有一个 FC 层的基础上增加另一个 FC 层来提高模型的迁移能力,并在山东省医院收集的肺癌知识产权数据集上微调,用来进行肺癌图像的特征提取和分类。首先,冻结迁移模型的前 27 个卷积层的权值,用于提取图像的一般特征(如边缘检测和颜色检测),后面的卷积层用于抽象与特定类别相关的特征。然后,对这些卷积层和 FC 层重新训练,从零开始识别肺癌图像类。实验结果表明,该模型优于 AlexNet、VGG-16 和 DenseNet。

除了修改 FC 层的结构外,也可以修改其他层的结构。Zhang 等人(2020b)提出使用深度残差网络框架解决基于胸部 X 射线图像的 COVID-19 检测问题。借用 ResNet34 的一些残差块构建提出的深度学习框架,使用 ResNet34 的输入层和接下来的 3 个残差块,分别在第 2 个残差块前后各插入一个特征平滑层,在第 3 个残差块后插入特征提取层。实验数据表明,该研究改进的 ResNet34 框架的性能优于 ResNet34 的原始版本。Akter 等人(2021)使用迁移模型 MobileNet-V1 对儿童面部图像进行自闭症或者正常二分类,对迁移模型的修改包括将 3 个批处理规范化(batch normalization, BN)层和两个 FC 层依次附加到输出层之前。BN 层用于通过重新确定中心和缩放输入值来规范化全局平均池层的输出。对所有用于比较的 DCNN(包括 DenseNet121、ResNet50、VGG-16、VGG-19 和 MobileNet-V2)也进行同样的结构修改,并用目标域数据集对所有模型进

行训练。实验结果表明, MobileNet-V1 表现最好。

2.2 参数调整策略

参数调整指通过使用目标域数据对迁移模型进行再训练以调整模型参数, 目的是获得更好的分类效果。可以调整卷积层参数, 也可以调整 FC 层参数, 或者两者都调整。对于不需要调整参数的层, 可以冻结这些层的参数。调整卷积层参数可以获得更准确的特征, 调整 FC 层参数能提高分类性能。该策略如图 3 所示。




图3 参数调整策略示意图

Fig. 3 Strategies of parameter adjustment

通过调整卷积层参数进行医学图像分类的策略已经应用于多种疾病。例如, 癌症疾病中的乳腺癌(吴英等, 2019; Liu等, 2021; Zhuang等, 2020)和前列腺癌(Abbasi等, 2020), 肺部疾病中的肺结节(Huang等, 2020)、普通肺炎(Irfan等, 2020)、新冠肺炎(Apostolopoulos和Mpesiana, 2020)和小儿肺炎(Liang和Zheng, 2020), 脑部疾病中的阿尔茨海默病(Wee等, 2019; 金祝新等, 2019), 眼科疾病中的青光眼(Gómez-Valverde等, 2019)、视盘偏侧(Liu等, 2020)和视网膜病变(Le等, 2020), 肝脏疾病中的肝脏纤维化(Xue等, 2020)和肝硬化(Li等, 2021a), 以及牙科疾病(Lee等, 2020; Kim等, 2020)等。下面以阿尔茨海默病为例说明调整卷积层参数策略的应用。金祝新等人(2019)将ImageNet上预训练的MCINet前两层卷积层参数迁移到目标域模型的卷积层前两层, 采用冻结和不冻结前两层卷积层的迁移学习策略, 用磁共振成像(magnetic resonance imaging, MRI)数据集进行再训练以微调参数, 最终完成阿尔茨海默病的图像分类。结果表明, 允许部分卷积层参与训练过程可以获得更好的实验结果。

调整 FC 层参数进行医学图像分类的策略同样应用广泛, 已经用于多种疾病。例如, 脑部疾病中的阿尔茨海默病(Maqsood等, 2019)、酒精中毒(Wang

等, 2019)和癫痫(Si等, 2020)等, 癌症疾病中的乳腺癌(Samala等, 2017, 2019)、胶质瘤(Yang等, 2018)和肺癌(Wang等, 2020), 肺部疾病中的肺结节(黄鸿等, 2020)和新冠肺炎(Minaee等, 2020; Mohammadi等, 2020), 前列腺疾病(Chen等, 2019), 以及眼科疾病中的黄斑病变(Karri等, 2017)等。下面以前列腺病变分类为例说明调整 FC 层参数策略的应用。Chen等人(2019)提出了一种基于迁移学习的深度学习方法, 用于多参数磁共振成像图像中前列腺病变的分类。首先在ImageNet上对InceptionV3和VGG-16进行预训练, 然后修改最后的分类层, 生成良性和恶性两类图像, 迁移到目标域后只调整最后一层的权重, 并在多参数磁共振成像数据集再训练。实验结果表明, 两个模型分类结果都达到了放射科医生的水平, VGG-16的分类结果好于InceptionV3。

同时调整卷积层参数和 FC 层参数进行医学图像分类的策略主要用于肺部疾病。例如, 结核病和肺癌(Tan等, 2018)、肺炎(Hashmi等, 2020; Romero等, 2020)、肺结节(张驰名等, 2020)等, 也可以用于神经胶质瘤(Yang等, 2018)。下面以神经胶质瘤为例说明同时调整卷积层和 FC 层参数策略的应用。Yang等人(2018)将ImageNet上预训练的AlexNet和GoogLeNet模型迁移到目标域, 随机初始化并重新训练 FC 层以适应新的对象类别, 冻结其他卷积层的权值, 微调第一卷积层以适应目标域的特征提取。用胶质瘤核磁共振图像对迁移模型再训练后对胶质瘤进行分类。实验结果表明, 与传统的基于手工特征的机器学习方法, 甚至是从头开始训练的DCNN相比, 基于迁移学习和微调训练的DCNN提高了神经胶质瘤分级的性能。

2.3 从迁移模型中提取特征的策略

从迁移模型中提取特征的策略指从模型的某个或某些层提取特征, 可以从卷积层提取特征, 也可以从 FC 层提取特征。该策略如图 4 所示。

从 DCNN 不同的卷积层提取的图像特征不同, 较深卷积层提取的特征更加高层、抽象, 较浅卷积层提取的特征则包含诸如图像边缘轮廓、纹理等底层信息。褚晶辉等人(2018)从 DCNN 不同的层提取特征对乳腺癌进行分类, 实验结果表明, 随着 DCNN 卷积层的加深, 卷积层提取的特征对于最终分类任务的性能呈现上升趋势。从 DCNN 不同的 FC 层提




图4 从迁移模型中提取特征策略

Fig. 4 Strategies of extracting features from the migrated model

取的图像特征也不同,最靠近卷积层的FC层包含卷积层提取的全部图像特征。离卷积层越近,FC层节点越多,包含的图像特征越详细;离卷积层越远,FC层节点越少,包含的图像特征越笼统。Deniz等

人(2018)设计了两个不同的实验,第1个实验先从 AlexNet 和 VGG-16 模型的 FC6 层中提取特征向量,然后进行拼接。第2个实验利用 AlexNet 和 VGG-16 模型的 FC7 层进行特征提取,并将得到的特征向量串联起来,将两个实验提取的特征用来分类。实验结果表明,第1次实验结果优于第2次实验结果,说明从越靠近卷积层的FC层中提取的特征越能提高分类性能。

2.4 迁移学习策略的比较

3种迁移学习策略有各自的优缺点及适用场景,具体如表1所示。在实际应用中要根据具体情况选用合适的策略。

表1 迁移学习策略的比较

Table 1 Comparison of transfer learning strategies

策略	优点	缺点	适用场景
参数调整	可以优化模型,更加适应目标域任务,提高了模型精度。	难以确定调整哪些层的参数。	不调整模型而直接使用但达不到精度的场景;模型结构调整后需要调整参数的场景。
结构调整	有利于改进模型以适应目标域任务,提高了模型精度,提升了目标域特征提取和分类性能。	难以确定删除或增加哪些层。	源域和目标域分类数量不同,需要修改分类层结构以适应目标域分类的场景;使用参数调整策略后仍达不到精度的场景。
从模型中提取特征	可以根据需要从不同的层提取不同的特征,为分类提供更准确的数据。	难以确定从哪一层提取特征。	迁移模型只用于特征提取的场景。

3 医学图像分类中的迁移学习模式及应用

迁移学习模式根据是否包含其他模式可分为简单模式和复杂模式。简单模式包括 DCNN 模式、混合模式和特征组合分类模式;复杂模式包括多分类器融合模式和二次迁移模式,它们都可以包含若干个 DCNN 模式或者混合模式。各种迁移学习模式的目标函数要根据其中包含的 DCNN 和传统分类器来计算。不同的分类器有不同的目标函数,这些目标函数要求最小化,否则求解5种模式的目标函数时,无法与 DCNN 的目标函数(即损失函数)相加。DCNN 的损失函数为交叉熵,主要有二分类交叉熵和多分类交叉熵。

二分类交叉熵计算为

$$L_1 = \frac{1}{N} \sum_i - [y_i \cdot \log(p_i) + (1 - y_i) \cdot \log(1 - p_i)] \quad (1)$$

式中, L_1 表示二分类交叉熵值, N 为样本数量, y_i 表示样本 i 的标签,正类为1,负类为0, p_i 表示样本 i 预测为正类的概率。

多分类交叉熵计算为

$$L_2 = - \frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \cdot \log(p_{ic}) \quad (2)$$

式中, L_2 表示多分类交叉熵值, N 为样本数量, M 表示类别数量, y_{ic} 是一个符号函数,如果样本的真实类别等于 c 取1,否则取0, p_{ic} 是观测样本 i 属于类别 c 的预测概率。

3.1 DCNN 模式

DCNN 模式就是用同一个 DCNN 完成图像特征提取和分类,如图5所示。

DCNN 能够通过卷积层提取医学图像的深层特




图5 DCNN 模式示意图

Fig. 5 DCNN model

征,同时还可以通过全连接层完成图像的分类任务,比传统图像分类方法更为准确和高效,因此 DCNN 模式已经成为医学图像分类领域广泛使用的模式。在 DCNN 模式中,根据目标域分类任务选用合适的损失函数,二分类任务用式(1),多分类用式(2)。例如,Maqsood 等人(2019)对预先训练好的卷积网络 AlexNet 进行微调后用于脑 MRI 分类以检测阿尔茨海默病,就采用 k 个互斥类的交叉熵函数(交叉熵)作为损失函数。该研究的损失函数属于多分类交叉熵。

使用 DCNN 模式进行医学图像分类已经应用于多种疾病。例如,癌症疾病中的乳腺癌(Samala 等,2017,2019;吴英等,2019;Zhuang 等,2020;Liu 等,2021;Munien 和 Viriri,2021)、肺癌(Tan 等,2018;Wang 等,2020)、胶质瘤(Yang 等,2018;Im 等,2021)、直肠癌(Li 等,2021b)和前列腺癌(Liu 等,2021);肺炎疾病中的一般肺炎(Hashmi 等,2020;Irfan 等,2020;Romero 等,2020)、新冠肺炎(Apostolopoulos 和 Mpesiana,2020;Minaee 等,2020;Mohammadi 等,2020;Bahgat 等,2021;Chen 等,2021;Taresh 等,2021)和小儿肺炎(Liang 和 Zheng,2020);各类结节分类(Han 等,2020),主要是肺结节(黄鸿等,2020;Huang 等,2020;张驰名等,2020;陈道争和江倩,2021);脑部疾病中的阿尔茨海默病(金祝新等,2019;Maqsood 等,2019;Wee 等,2019)、自闭症(Akter 等,2021)、癫痫(Si 等,2020)和酒精中毒(Wang 等,2019);以及眼科(Karri 等,2017;Gómez-Valverde 等,2019;Le 等,2020;Liu 等,2020)、牙科(Lee 等,2020;Kim 等,2020)、肝脏疾病(Xue 等,2020;Li 等,2021a)、前列腺疾病(Chen 等,2019)和肺结核(Tan 等,2018)等。下面以结节检测分类研究为例说明 DCNN 模式的应用。Han 等人(2020)探索了一种自动诊断方法预测结节,采用

VGG-16 进行特征提取和分类,卷积层参数不变,用目标域数据集调整 FC 层参数;为了对比,采用了一种传统的机器学习方法,通过支持向量机(support vector machine, SVM)提取纹理特征并进行分类。实验表明,来自医学图像和自然图像的特征具有聚焦于更简单和抽象程度较低的对象相似性,即迁移的卷积层越多,分类效果越好。

3.2 混合模式

混合模式由 DCNN 和分类器组成,前者进行特征提取,后者用于分类,如图 6 所示。分类器一般是传统分类器。手动选择(或特征设计)可能导致一组特征不太理想,并且过度专用于特定的数据集,从而导致对更大或未知数据集的泛化能力较差,而 DCNN 可以通过训练而不是“手工制作”或专门设计来找到图像特征;传统分类器可解释性强且训练参数少,所以将 DCNN 与传统分类器结合起来能发挥二者优势。混合模式的目标函数由 DCNN 损失函数和分类器目标函数组成。具体为

$$F = L + f \quad (3)$$

式中, F 表示混合模式的目标函数, L 表示 DCNN 的损失函数, f 表示分类器的目标函数。




图6 混合模式

Fig. 6 The hybrid model

使用混合模式进行医学图像分类已经应用于多种疾病。例如,癌症疾病中的乳腺癌(Trivizakis 等,2019)、淋巴瘤(Zhang 等,2020a)和甲状腺乳头状癌(Yu 等,2020);脑部疾病中的阿尔茨海默病(程波等,2016;Oh 等,2019)、脑功能连接(Li 等,2018)和脑出血(Dawud 等,2019)以及眼科疾病(Burlina 等,2017)等。下面以眼科疾病为例说明混合模式的应用。Burlina 等人(2017)将 ImageNet 上预训练的 OverFeat 迁移到一个大型的年龄相关性黄斑变性(age-related macular degeneration, AMD)图像公开数据集上用于特征提取,从该模型的一个 FC 层中提取通用深度特征,再使用 SVM 或随机森林(random

forrest)对AMD进行多类分类。结果表明,在几乎不需要额外处理的情况下,通用深度特征与支持向量机相结合,提供了引人注目的性能;OverFeat提取通用特征之前,没有对该迁移模型进行优化,但效果不错;从OverFeat的一个FC层提取的通用特征以紧凑的方式封装了低层特征和空间特征,很好地适应了视网膜眼底图像的分析。

3.3 特征组合分类模式

某些医学图像分类研究(Paul等,2016;褚晶辉等,2018;Pei等,2019;Deniz等,2018;Paul等,2016)发现,组合DCNN提取的医学图像特征和传统方法获得的传统图像特征,比单纯使用DCNN提取的特征或者传统图像特征能获得更好的图像分类效果;还有一些研究(Pei等,2019;Wang等,2021)发现,组合多种DCNN提取的相同图像的特征,也比单独使用单个DCNN提取图像特征获得了更好的图像分类效果。特征组合分类模式就是基于这两种发现的。该模式由DCNN或手工设计特征等其他特征提取方法以及一个分类器组成,其中特征提取由DCNN和其他特征提取方法完成,分类则由分类器完成。该模式的核心是使用多种方法分别提取同一个图像数据集的特征,得到的多种特征再通过某些方法进行融合。该模式中,特征来源有两种情况,一种是图像特征由不同DCNN分别提取;另一种是由DCNN和传统方法分别提取。该模式如图7所示,图中“传统方法提取特征”是可选的,选择与否分别对应两种特征来源情况。




图7 特征组合分类模式

Fig.7 Mode of feature combing and classifying

特征组合分类模式的目标函数由参与其中的所有DCNN的损失函数和分类器的目标函数组成。具体为

$$F = \sum_i L_i + f \quad (4)$$

式中, F 表示特征组合分类模式的目标函数, L_i 表示第*i*个DCNN的损失函数, f 表示分类器的目标函数。

特征组合分类模式主要用于乳腺肿瘤病理图像分类(Pei等,2019;褚晶辉等,2018;Deniz等,2018;Huynh等,2016)。其他疾病类型的图像也有应用。例如,COVID-19(Wang等,2021)、肺癌(Paul等,2016)、肾脏(Zheng等,2019)。下面分别以肺癌和乳腺癌图像分类为例说明特征组合分类模式的应用。Paul等人(2016)用肺癌图像对预训练的MatConvNet-VGG-m、MatConvNet-VGG-f和MatConvNet-VGG-s进行再训练,用于提取肺癌深度特征,然后再将其与传统特征混合后,分别用来训练各种分类器(决策树、随机森林、朴素贝叶斯和最近邻),以便预测肺癌短期和长期患者。实验结果表明,将提取的深度神经网络特征与传统的定量特征相结合,从预训练MatConvNet-VGG-f中提取的5个最佳后校正线性单元特征和5个最佳传统特征的精度为90%,曲线下面积(area under curve,AUC)为0.935。该研究中的特征来源是DCNN和传统方法。Pei等人(2019)使用VGG-16、ResNet-50和Inception-v3提取乳腺癌组织病理学图像的特征,将3个DCNN提取的特征合并在一起,再使用一种称为最小冗余最大相关(minimum redundancy maximum relevance,mRMR)的特征选择方法搜索最少特征,然后使用主成分分析(principal component analysis,PCA)降维,最后使用提升树和SVM区分癌变和非癌变斑块。研究结果验证了该方法与病理学专家的估计结果的一致性。该研究中的特征来源是不同的DCNN。

3.4 多分类器融合模式

多分类器融合模式由多个分类器组成,其核心是得到多个分类结果再进一步整合得到最终分类结果,分为包含DCNN模式和包含混合模式两种,如图8所示。

包含DCNN模式的多分类器融合模式的目标函数由所有DCNN的损失函数组成。具体为

$$F = \sum_i L_i \quad (5)$$

式中, F 表示多分类器融合模式的目标函数, L_i 表示第*i*个DCNN的损失函数。

包含混合模式的多分类器融合模式的目标函数

由 DCNN 的损失函数和两个传统分类器的目标函数组成。具体为

$$F = L + f_1 + f_2 \quad (6)$$

式中, F 表示多分类器融合模式的目标函数, f_1 用于传统特征分类, f_2 用于对 DCNN 提取的特征进行分类。




图8 多分类器融合模式

Fig. 8 Mode of multi classifier fusing ((a) including DCNN model; (b) including hybrid model)

多分类器融合模式已经用于皮肤病 (Mahbod 等, 2020)、脑肿瘤 (Hao 等, 2021) 和 COVID-19 (Altaf 等, 2021) 等多种疾病的医学图像分类。

在皮肤病图像分析研究中, Mahbod 等人 (2020) 提出并评估了一种基于三级集成策略的多尺度多 CNN (multi-scale multi-CNN, MSM-CNN) 融合方法, 该策略利用 EfficientNetB0、EfficientNetB1 和 SeReNeXt-50 训练不同尺度的皮肤镜图像, 调整了卷积层参数以提取更准确的特征, 并修改最后一个完全连接层以适应目标域的分类任务, 最后将 3 个微调网络的结果融合在一起得到最终的分类结果。实验结果表明, 在国际皮肤成像协作组织 (International Skin Imaging Collaboration, ISIC) 2018 皮肤病变分类挑战测试集上, MSM-CNN 算法的平衡多类准确率为 86.2%, 是目前在线排行榜排名第 2 的算法。该研究使用了 3 次 DCNN 模式, 分别对应 EfficientNetB0、EfficientNetB1 和 SeReNeXt-50, 并且采取了调整卷积层参数的策略及调整 FC 层结构的策略。Altaf 等人 (2021) 提出的用于 COVID-19 分类及检测其他胸腔疾病的迁移学习方法中, 使用了 VGG、ResNet、DenseNet 和 Inception-V3 等 4 个迁移模型, 得到 4 个分类结果再融合。而 Hao 等人 (2021) 提出的基于迁移学习的脑肿瘤分类主动学习框架中, 使用 AlexNet 作为迁移模型, 使用 3 个不同的学习率进行训练, 冻结卷积层参数, 微调 FC 层参数, 得到 3 个分类概率, 再计算总的分类概率, 这

其实是使用了 3 次 DCNN 模式。上述研究使用的是包含 DCNN 模式的多分类器融合模式。

还有研究使用了混合模式。Zheng 等人 (2019) 使用 ImageNet-CAFFE-Alex 通过两种不同方法从 2 维超声肾脏图像中提取特征, 通过预训练的 DCNN (AlexNet) 从像素数据中自动提取特征 (方法 A) 并通过基于肿瘤的分段分析方法 (方法 B) 进行提取。然后在每个特征集上训练支持 SVM 分类器。在分别使用 CNN 特征 (方法 A) 和分析提取特征 (方法 B) 进行分类后, 使用一种称为软投票的简单集成技术来组合两个分类器的输出。通过这种技术, 将每个分类器的输出概率平均, 然后作为最终的预测概率。该研究使用的是包含混合模式的多分类器融合模式。

3.5 二次迁移模式

二次迁移模式有一个源域、一个中间目标域 (也称为中间源域) 和一个最终目标域。在源域对模型进行第 1 次预训练, 然后将模型迁移到中间目标域进行第 2 次预训练, 再将经过二次预训练的模型迁移到最终目标域进行再训练。二次迁移学习可以使用 DCNN 模式, 也可以使用混合模式。该模式如图 9 所示, 其中最终目标域中的分类器是可选的, 若选择则表示使用混合模式, 即在最终目标域中进行特征提取和分类用的是不同模型。

二次迁移模式的目标函数由两个目标域的 DCNN 的损失函数组成。具体为




图9 二次迁移模式

Fig. 9 Mode of transferring two times

$$F = L_1 + L_2 \quad (7)$$

式中, F 表示二次迁移模式的目标函数, L_1 表示临时目标域 DCNN 的损失函数, L_2 表示最终目标域 DCNN 的损失函数。

如果二次迁移模式在最终目标域使用分类器, 则还需加上它的目标函数。具体为

$$F = L_1 + L_2 + f \quad (8)$$

式中, f 表示分类器的目标函数。

二次迁移模式已经应用于宫颈癌前病变检测、乳腺癌分类和 COVID-19 的分类检测。

李燕云等人 (2021) 基于 ImageNet 预训练的 Resnet101 模型, 通过宫颈转化区分类的开源阴道镜数据进行第 1 次迁移学习, 再以自有数据的病变分类为目标进行第 2 次迁移学习得到特征提取器。将经过二次迁移的 ResNet101 作为特征提取器整合到 Faster-RCNN 中, 替换 Faster-RCNN 的数层卷积层, 用于病变区域特征提取。以开源 Faster-RCNN 代码进行实验, 参数采用源代码的默认参数, 目标输出为病变区域及类型。实验结果表明, 构建的高级别和 3 类 (低级别、高级别和癌) 病变定位检测模型在宫颈癌前病变检测中取得了较好效果。该研究将迁移模型进行二次迁移, 作用都是提取特征, 通过调整卷积层参数提高提取特征的准确度, 并采用 softmax 分类。该研究采用了两次混合模式, 并且采取了调整 FC 层参数的策略。

褚晶辉等人 (2018) 采用迁移学习研究乳腺癌分类, 迁移模型为 VGG-16, 第 1 次迁移的源域为 ImageNet, 目标域为乳腺 X 光数字乳腺图像数据库, 第 2 次迁移的源域为第 1 次迁移的目标域, 目标域为乳腺核磁共振图像 (MRI) 肿瘤数据集。两次迁移都冻结了用于提取特征的卷积层的权重, 只调整 FC 层; 实验结果表明, 二次迁移比一次迁移更有效。该研究采用了两次 DCNN 模式, 并且采取了调整 FC 层结构及参数的策略。

Zhang 等人 (2020b) 提出了一个两步转移学习途径和一个深度残差网络框架来解决基于胸部 X 射线图像的 COVID-19 检测问题, 最终的 FC 层是 $512 \times k$, k 是所研究问题中的类数。用预训练的 ResNet34 进行两阶段分类训练, 第 1 阶段用胸部 X 射线图像来微调所提出的模型 ($k = 2$), 进行肺炎和正常的二分类, 第 2 阶段是用 COVID-19 图像来微调第 2 阶段的模型 ($k = 3$), 进行 COVID-19、其他肺炎和正常的三分类。研究表明, 采用两步转移学习策略可以在小数据集上建立一个具有良好预测性能的深度学习模型。实验数据表明, 采用两步转移学习策略对基于 X 射线图像的深度学习模型进行改进是必要的, 该模型仅使用 189 幅带注释的 COVID-19 X 射线图像。由于两个阶段分类数量不同, 因此这两个阶段至少要调整分类层; 另外, 两个阶段的训练都需要学习新特征, 因此这两个阶段都需要调整卷积层。该研究采用两次 DCNN 模式完成二次迁移, 并且还采用了调整卷积层的参数策略和调整 FC 层的结构及参数策略。

3.6 迁移学习模式的比较

上述 5 种迁移学习模式有各自的适用场景及优缺点, 具体如表 2 所示。选用何种迁移学习模式需要通过分析实际情况并结合各种模式的适用场景及优缺点来决定。

4 迁移学习策略和模式的关系

DCNN 模式中, 至少要修改迁移模型最后的分类层, 并且要重新调整该层参数, 因此该模式使用参数调整策略和结构调整策略。混合模式中, 需要使用从模型中提取特征的策略来获得特征, 并且根据实际应用情况, 还可能用到结构调整策略和参数调整策略来调整模型的结构和参数以获得更准确的特征。特征组合分类模式中, 有部分特征是从迁移模型中提取的, 因而也要用到从模型中提取特征的策略, 还可能用到参数调整策略及结构调整策略。包含 DCNN 模式的多分类器融合模式使用策略的情况与 DCNN 模式类似, 包含混合模式的多分类器融合模式使用策略的情况与混合模式类似。综上所述, 迁移学习模式包含了迁移学习策略。

表 2 迁移学习模式的比较
Table 2 Comparison of transfer learning modes

模式	优点	缺点	使用场景
DCNN	可以充分利用 DCNN 进行特征提取并分类的优点,使用比较简单方便。	模式简单,得到理想分类效果的可能性小于特征组合分类模式、多分类器融合模式及二次迁移模式。	在 5 种模式中应用场景最广泛。只要能找到与目标域相似的源域,都可以采用。
混合	可以充分利用 DCNN 提取特征和传统分类器分类的优点。	需要训练用于特征提取的 DCNN 和分类器两种模型,增加了训练复杂性。	单独使用传统方法或 DCNN 模式进行特征提取和分类达不到理想效果的场景。
特征组合分类	能够融合多个来源特征,形成更加完整的特征,为分类任务提供更高质量数据,提升了分类性能。	从多个来源获取特征进行融合,增加了计算量和计算时间,计算复杂性更高,需要更多的计算资源。	单特征分类模式(如 DCNN 模式、混合模式)不能得到理想分类效果的场景。
多分类器融合	获得“集思广益”的结果,比单分类器模式(即 DCNN 模式和混合模式)结果更可靠。	需要进行多次特征提取和多次分类,以及融合多个分类结果,计算更复杂更费时。	单分类器模式得不到理想效果的场景。
二次迁移	迁移模型经过一次预训练和两次再训练,比一次迁移积累的知识要多,模型的分类精度更高。	迁移次数增多的同时,增加了训练时间,并且消耗更多的计算资源。	当一次迁移得不到理想效果、存在 3 个相似数据源且其中 1 个数据源包含数量巨大样本的场景。

5 结 语

目前迁移学习已经广泛应用于医学图像分类领域,其中基于模型的迁移学习应用最广泛,其他迁移学习应用较少。本文从基于迁移学习的医学图像分析研究文献中归纳总结了 3 种迁移学习策略,提炼了 5 种迁移学习模式,并阐述了各种策略和模式之间的关系,分析了各种迁移学习策略及模式在医学图像分析中的具体应用、适用场景、优点和局限性。最后,给出迁移学习在医学图像分类应用中存在的问题及未来研究方向,具体如下:

1)难以选择高效的迁移学习算法。由于医学图像的多样性和复杂性,以及医学图像分类的迁移模型 DCNN 的可解释性较弱,导致迁移学习算法泛化能力不强。为某个特定类别的医学图像分类设计的迁移学习算法不一定适用其他种类的医学图像分类,因此需要从已有迁移学习算法中选择合适的算法。使用人工选择的方法需要不断尝试各种算法,消耗大量的计算资源,而自动迁移学习通过经验自动选择迁移学习算法,因此可以考虑用自动迁移学习解决迁移学习算法的选择问题。

2)迁移模型的修改和超参数的设置缺乏理论指导。迁移模型的结构中,容易修改的部分是最后的分类层,其他层的结构修改则比较困难,特别是卷

积层。选择调整哪些卷积层和 FC 层的参数也是比较困难的。对这些难以修改的结构和参数,只能通过结合已有的经验和不断进行实验来完成,超参数的设置也是如此。这导致迁移学习效率低下。研究能够指导修改迁移模型的结构和参数,以及设置超参数的理论,可以提高迁移学习的效率,促进迁移学习在医学图像分类中的应用。

3)罕见疾病图像分类困难。罕见疾病病理图像数据样本很少,如何通过迁移学习提高罕见疾病图像分类也是一个问题。对抗式迁移学习通过一种新的迁移学习方法,即数据扩展,生成和增强目标域数据;异构迁移学习允许将不同模态或不同方面的源域知识迁移到目标域。因此,可以考虑在罕见疾病图像分类领域使用对抗迁移学习和异构迁移学习,一方面通过对抗迁移学习来生成符合要求的罕见疾病病理图像样本,增加样本数量;另一方面,通过异构迁移学习将其他符合要求的源域知识迁移到罕见疾病图像分类目标域。

参考文献 (References)

Abbasi A A, Hussain L, Awan I A, Abbasi I, Majid A, Nadeem M S A and Chaudhary Q A. 2020. Detecting prostate cancer using deep learning convolution neural network with transfer learning approach. Cognitive Neurodynamics, 14 (4): 523-533 [DOI: 10.1007/s11571-020-09587-5]


- Akter T, Ali M H, Khan M I, Satu M S, Uddin M J, Alyami S A, Ali S, Azad A and Moni M A. 2021. Improved transfer-learning-based facial recognition framework to detect autistic children at an early stage. *Brain Sciences*, 11 (6): # 734 [DOI: 10. 3390/brainsci11060734]
- Altaf F, Islam S M S and Janjua N K. 2021. A novel augmented deep transfer learning for classification of COVID-19 and other thoracic diseases from X-rays. *Neural Computing and Applications*, 30(20): 14037-14048 [DOI: 10. 1007/s00521-021-06044-0]
- Apostolopoulos I D and Mpesiana T A. 2020. Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, 43(2): 635-640 [DOI: 10. 1007/s13246-020-00865-4]
- Bahgat W M, Balaha H M, AbdulAzeem Y and Badawy M M. 2021. An optimized transfer learning-based approach for automatic diagnosis of COVID-19 from chest x-ray images. *Computer Science*, 7: #555 [DOI: 10. 7717/peerj-cs. 555]
- Burlina P, Pacheco K D, Joshi N, Freund D E and Bressler N M. 2017. Comparing humans and deep learning performance for grading AMD: a study in using universal deep features and transfer learning for automated AMD analysis. *Computers in Biology and Medicine*, 82: 80-86 [DOI: 10. 1016/j. complbiomed. 2017. 01. 018]
- Chen D Z and Jiang Q. 2021. Pulmonary nodule detection based on convolutional neural networks with transfer learning. *Computer Engineering and Design*, 42(1): 240-247 (陈道争, 江倩. 2021. 基于卷积神经网络和迁移学习的肺结节检测. *计算机工程与设计*, 42(1): 240-247) [DOI: 10. 16208/j. issn1000-7024. 2021. 01. 035]
- Chen H T, Guo S S, Hao Y B, Fang Y J, Fang Z X, Wu W H, Liu Z G and Li S L. 2021. Auxiliary diagnosis for COVID-19 with deep transfer learning. *Journal of Digital Imaging*, 34 (2): 231-241 [DOI: 10. 1007/s10278-021-00431-8]
- Chen H Y, Gao J Y, Zhao D, Wang H Z, Song H and Su Q H. 2021. Review of the research progress in deep learning and biomedical image analysis till 2020. *Journal of Image and Graphics*, 26(3): 475-486 (陈弘扬, 高敬阳, 赵地, 汪红志, 宋红, 苏庆华. 2021. 深度学习与生物医学图像分析 2020 年综述. *中国图象图形学报*, 26(3): 475-486) [DOI: 10. 11834/jig. 200351]
- Chen Q, Hu S L, Long P R, Lu F, Shi Y J and Li Y P. 2019. A transfer learning approach for malignant prostate lesion detection on multiparametric MRI. *Technology in Cancer Research and Treatment*, 18: #153303381985836 [DOI: 10. 1177/1533033819858363]
- Chen S H, Liu W X, Qin J, Chen L L, Bin G, Zhou Y X and Wang T F. 2017. Research progress of computer-aided diagnosis in cancer based on deep learning and medical imaging. *Journal of Biomedical Engineering*, 34(2): 314-319 (陈诗慧, 刘维湘, 秦璟, 陈亮亮, 宾果, 周翔翔, 汪天富. 2017. 基于深度学习和医学图像的癌症计算机辅助诊断研究进展. *生物医学工程学杂志*, 34(2): 314-319) [DOI: 10. 7507/1001-5515. 201609047]
- Cheng B, Zhu B L and Xiong J. 2016. Multimodal multi-label transfer learning for early diagnosis of Alzheimer's disease. *Journal of Computer Applications*, 36(8): 2282-2286, 2291 (程波, 朱丙丽, 熊江. 2016. 基于多模态多标记迁移学习的早期阿尔茨海默病诊断. *计算机应用*, 36(8): 2282-2286, 2291) [DOI: 10. 11772/j. issn. 1001-9081. 2016. 08. 2282]
- Chu J H, Wu Z R, Lyu W and Li Z. 2018. Breast cancer diagnosis system based on transfer learning and deep convolutional neural networks. *Laser and Optoelectronics Progress*, 55(8): 201-207 (褚晶辉, 吴泽葵, 吕卫, 李喆. 2018. 基于迁移学习和深度卷积神经网络的乳腺肿瘤诊断系统. *激光与光电子学进展*, 55(8): 201-207) [DOI: 10. 3788/LOP55. 081001]
- Dawud A M, Yurtkan K and Oztoprak H. 2019. Application of deep learning in neuroradiology: brain haemorrhage classification using transfer learning. *Computational Intelligence and Neuroscience*, 2019: #4629859 [DOI: 10. 1155/2019/4629859]
- Deniz E, Şengür A, Kadiroğlu Z, Guo Y H, Bajaj V and Budak ü. 2018. Transfer learning based histopathologic image classification for breast cancer detection. *Health Information Science and Systems*, 6: #18 [DOI: 10. 1007/s13755-018-0057-x]
- Gómez-Valverde J J, Antón A, Fatti G, Liefers B, Herranz A, Santos A, Sánchez C I and Ledesma-Carbayo M J. 2019. Automatic glaucoma classification using color fundus images based on convolutional neural networks and transfer learning. *Biomedical Optics Express*, 10(2): 892-913 [DOI: 10. 1364/BOE. 10. 000892]
- Han F F, Yan L K, Chen J X, Teng Y Y, Chen S, Qi S L, Qian W, Yang J, Moore W, Zhang S and Liang Z R. 2020. Predicting unnecessary nodule biopsies from a small, unbalanced, and pathologically proven dataset by transfer learning. *Journal of Digital Imaging*, 33(3): 685-696 [DOI: 10. 1007/s10278-019-00306-z]
- Hao R Q, Namdar K, Liu L and Khalvati F. 2021. a transfer learning-based active learning framework for brain tumor classification. *Frontiers in Artificial Intelligence*, 4: #635766 [DOI: 10. 3389/frai. 2021. 635766]
- Hashmi M F, Katiyar S, Keskar A G, Bokde N D and Geem Z W. 2020. Efficient pneumonia detection in chest Xray images using deep transfer learning. *Diagnostics*, 10(6): #417 [DOI: 10. 3390/diagnostics10060417]
- Huang C X, Lv W H, Zhou C S, Mao L, Xu Q M, Li X Y, Qi L, Xia F, Li X L, Zhang Q R, Zhang L J and Lu G M. 2020. Discrimination between transient and persistent subsolid pulmonary nodules on baseline CT using deep transfer learning. *European Radiology*, 30(12): 6913-6923 [DOI: 10. 1007/s00330-020-07071-6]
- Huang H, Peng C, Wu R Y, Tao J L and Zhang J Q. 2020. Self-supervised transfer learning of pulmonary nodule classification based on partially annotated CT images. *Acta Optica Sinica*, 40 (18): #1810003 (黄鸿, 彭超, 吴若愚, 陶俊利, 张久权. 2020. 基于部分注释 CT 图像的自监督迁移学习肺结节分类. *光学学报*, 40(18): #1810003) [DOI: 10. 3788/AOS202040. 1810003]

- Huynh B Q, Li H and Giger M L. 2016. Digital mammographic tumor classification using transfer learning from deep convolutional neural networks. *Journal of Medical Imaging*, 3(3): #034501 [DOI: 10.1117/1.JMI.3.3.034501]
- Im S, Hyeon J, Rha E, Lee J, Choi H J, Jung Y and Kim T J. 2021. Classification of diffuse Glioma subtype from clinical-grade pathological images using deep transfer learning. *Sensors*, 21(10): #3500 [DOI: 10.3390/s21103500]
- Irfan A, Adivishnu A L, Sze-To A, Dehkharghanian T, Rahnamayan S and Tizhoosh H R. 2020. Classifying pneumonia among chest X-rays using transfer learning//*Proceedings of the 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Montreal, Canada: IEEE: 2186-2189 [DOI: 10.1109/EMBC44109.2020.9175594]
- Jin Z X, Qin F W and Fang M E. 2019. Deep transfer learning-assisted early diagnosis of Alzheimer's disease. *Computer Applications and Software*, 36(5): 171-177 (金祝新, 秦飞巍, 方美娥. 2019. 深度迁移学习辅助的阿尔兹海默氏症早期诊断. *计算机应用与软件*, 36(5): 171-177) [DOI: 10.3969/j.issn.1000-386x.2019.05.029]
- Karri S P K, Chakraborty D and Chatterjee J. 2017. Transfer learning based classification of optical coherence tomography images with diabetic macular edema and dry age-related macular degeneration. *Bio-medical Optics Express*, 8(2): 579-592 [DOI: 10.1364/BOE.8.000579]
- Kim J E, Nam N E, Shim J S, Jung Y H, Cho B H and Hwang J J. 2020. Transfer learning via deep neural networks for implant fixture system classification using periapical radiographs. *Journal of Clinical Medicine*, 9(4): #1117 [DOI: 10.3390/jcm9041117]
- Le D, Alam M, Yao C K, Lim J I, Hsieh Y T, Chan R V P, Toslak D and Yao X C. 2020. Transfer learning for automated OCTA detection of diabetic retinopathy. *Translational Vision Science and Technology*, 9(2): #35 [DOI: 10.1167/tvst.9.2.35]
- Lee K S, Jung S K, Ryu J J, Shin S W and Choi J. 2020. Evaluation of transfer learning with deep convolutional neural networks for screening osteoporosis in dental panoramic radiographs. *Journal of Clinical Medicine*, 9(2): #392 [DOI: 10.3390/jcm9020392]
- Li H L, He L L, Dudley J A, Maloney T C, Somasundaram E, Brady S L, Parikh N A and Dillman J R. 2021a. DeepLiverNet: a deep transfer learning model for classifying liver stiffness using clinical and T2-weighted magnetic resonance imaging data in children and young adults. *Pediatric Radiology*, 51(3): 392-402 [DOI: 10.1007/s00247-020-04854-3]
- Li H L, Parikh N A and He L L. 2018. A novel transfer learning approach to enhance deep neural network classification of brain functional connectomes. *Frontiers in Neuroscience*, 12: #491 [DOI: 10.3389/fnins.2018.00491]
- Li J, Zhou Y, Wang P, Zhao H N, Wang X X, Tang N and Luan K. 2021b. Deep transfer learning based on magnetic resonance imaging can improve the diagnosis of lymph node metastasis in patients with rectal cancer. *Quantitative Imaging in Medicine and Surgery*, 11(6): 2477-2485 [DOI: 10.21037/qims-20-525]
- Li Y Y, Wang Y M, Zhou Q, Li Y X, Wang Z, Wang J, Meng Y, Cai Q Q, Sui L and Hua K Q. 2021. Deep learning model exploration of colposcopy image based on cervical epithelial and vascular features. *Fudan University Journal of Medical Sciences*, 48(4): 435-442 (李燕云, 王永明, 周奇, 李亦学, 王振, 王珏, 孟妍, 蔡青青, 隋龙, 华克勤. 2021. 基于宫颈上皮与血管特征的阴道镜图像深度学习模型探索. *复旦学报(医学版)*, 48(4): 435-442) [DOI: 10.3969/j.issn.1672-8467.2021.04.002]
- Li Z X, Song T, Ge M F, Liu J X, Wang H W and Wang J. 2021. Breast cancer classification from histopathological images based on improved Inception model. *Laser and Optoelectronics Progress*, 58(8): #0817001 (李赵旭, 宋涛, 葛梦飞, 刘嘉欣, 王宏伟, 王佳. 2021. 基于改进 Inception 模型的乳腺癌病理学图像分类. *激光与光电子学进展*, 58(8): #0817001) [DOI: 10.3788/LOP202158.0817001]
- Liang G B and Zheng L X. 2020. A transfer learning method with deep residual network for pediatric pneumonia diagnosis. *Computer Methods and Programs in Biomedicine*, 187: #104964 [DOI: 10.1016/j.cmpb.2019.06.023]
- Liu T Y A, Ting D S W, Yi P H, Wei J C, Zhu H X, Subramanian P S, Li T B, Hui F K, Hager G D and Miller N R. 2020. Deep learning and transfer learning for optic disc laterality detection: implications for machine learning in neuro-ophthalmology. *Journal of Neuro-Ophthalmology*, 40(2): 178-184 [DOI: 10.1097/WNO.0000000000000827]
- Liu W X, Cheng Y L, Liu Z Y, Liu C L, Cattell R, Xie X Y, Wang Y Y, Yang X J, Ye W T, Liang C S, Li J, Gao Y, Huang C and Liang C H. 2021. Preoperative prediction of Ki-67 status in breast cancer with multiparametric MRI using transfer learning. *Academic Radiology*, 28(2): e44-e53 [DOI: 10.1016/j.acra.2020.02.006]
- Mahbod A, Schaefer G, Wang C L, Dorffner G, Ecker R and Ellinger I. 2020. Transfer learning using a multi-scale and multi-network ensemble for skin lesion classification. *Computer Methods and Programs in Biomedicine*, 193: #105475 [DOI: 10.1016/j.cmpb.2020.105475]
- Maqsood M, Nazir F, Khan U, Aadil F, Jamal H, Mehmood I and Song O Y. 2019. Transfer learning assisted classification and detection of Alzheimer's disease stages using 3D MRI scans. *Sensors*, 19(11): #2645 [DOI: 10.3390/s19112645]
- Minaee S, Kafieh R, Sonka M, Yazdani S and Soufi G J. 2020. Deep-COVID: predicting COVID-19 from chest X-ray images using deep transfer learning. *Medical Image Analysis*, 65: #101794 [DOI: 10.1016/j.media.2020.101794]
- Mohammadi R, Salehi M, Ghaffari H, Rohani A A and Reiazi R. 2020. Transfer learning-based automatic detection of coronavirus disease


- 2019 (COVID-19) from chest X-ray images. *Journal of Biomedical Physics and Engineering*, 10(5): 559-568 [DOI: 10.31661/jbpe.v0i0.2008-1153]
- Munien C and Viriri S. 2021. Classification of hematoxylin and eosin-stained breast cancer histology microscopy images using transfer learning with efficient nets. *Computational Intelligence and Neuroscience*, 2021: #5580914 [DOI: 10.1155/2021/5580914]
- Oh K, Chung Y C, Kim K W, Kim W S and Oh I S. 2019. Classification and visualization of Alzheimer's disease using volumetric convolutional neural network and transfer learning. *Scientific Reports*, 9(1): #18150 [DOI: 10.1038/s41598-019-54548-6]
- Paul R, Hawkins S H, Balagurunathan Y, Schabath M, Gillies R J, Hall L O and Goldgof D B. 2016. Deep feature transfer learning in combination with traditional features predicts survival among patients with lung adenocarcinoma. *Tomography*, 2(4): 388-395 [DOI: 10.18383/j.tom.2016.00211]
- Pei Z A, Cao S L, Lu L J and Chen W F. 2019. Direct cellularity estimation on breast cancer histopathology images using transfer learning. *Computational and Mathematical Methods in Medicine*, 2019: #3041250 [DOI: 10.1155/2019/3041250]
- Romero M, Interian Y, Solberg T and Valdes G. 2020. Targeted transfer learning to improve performance in small medical physics datasets. *Medical Physics*, 47(12): 6246-6256 [DOI: 10.1002/mp.14507]
- Samala R K, Chan H P, Hadjiiski L M, Helvie M A, Cha K H and Richter C D. 2017. Multi-task transfer learning deep convolutional neural network: application to computer-aided diagnosis of breast cancer on mammograms. *Physics in Medicine and Biology*, 62(23): 8894-8908 [DOI: 10.1088/1361-6560/aa93d4]
- Samala R K, Chan H P, Hadjiiski L, Helvie M A, Richter C D and Cha K H. 2019. Breast cancer diagnosis in digital breast tomosynthesis: effects of training sample size on multi-stage transfer learning using deep neural nets. *IEEE Transactions on Medical Imaging*, 38(3): 686-696 [DOI: 10.1109/TMI.2018.2870343]
- Si X P, Zhang X J, Zhou Y, Sun Y L, Jin W P, Yin S Y, Zhao X, Li Q and Ming D. 2020. Automated detection of juvenile myoclonic epilepsy using CNN based transfer learning in diffusion MRI//Proceedings of the 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Montreal, Canada: IEEE: 1679-1682 [DOI: 10.1109/EMBC44109.2020.9175467]
- Tan T, Li Z, Liu H X, Zanjani F G, Ouyang Q C, Tang Y L, Hu Z Y and Li Q. 2018. Optimize transfer learning for lung diseases in bronchoscopy using a new concept: sequential fine-tuning. *IEEE Journal of Translational Engineering in Health and Medicine*, 6: #1800808 [DOI: 10.1109/JTEHM.2018.2865787]
- Taresh M M, Zhu N B, Ali T A A, Hameed A S and Mutar M L. 2021. Transfer learning to detect COVID-19 automatically from X-Ray images using convolutional neural networks. *International Journal of Biomedical Imaging*, 2021: #8828404 [DOI: 10.1155/2021/8828404]
- Trivizakis E, Ioannidis G S, Melissianos V D, Papadakis G Z, Tsatsakis A, Spandidos D A and Marias K. 2019. A novel deep learning architecture outperforming 'off-the-shelf' transfer learning and feature-based methods in the automated assessment of mammographic breast density. *Oncology Reports*, 42(5): 2009-2015 [DOI: 10.3892/or.2019.7312]
- Wang S D, Dong L Y, Wang X and Wang X G. 2020. Classification of pathological types of lung cancer from CT images by deep residual neural networks with transfer learning strategy. *Open Medicine*, 15(1): 190-197 [DOI: 10.1515/med-2020-0028]
- Wang S H, Nayak D R, Guttery D S, Zhang X and Zhang Y D. 2021. COVID-19 classification by CSHNet with deep fusion using transfer learning and discriminant correlation analysis. *Information Fusion*, 68: 131-148 [DOI: 10.1016/j.inffus.2020.11.005]
- Wang S H, Xie S P, Chen X Q, Guttery D S, Tang C S, Sun J D and Zhang Y D. 2019. Alcoholism identification based on an AlexNet transfer learning model. *Frontiers in Psychiatry*, 10: #205 [DOI: 10.3389/fpsy.2019.00205]
- Wee C Y, Liu C Q, Lee A, Poh J S, Ji H and Qiu A Q. 2019. Cortical graph neural network for AD and MCI diagnosis and transfer learning across populations. *NeuroImage: Clinical*, 23: #101929 [DOI: 10.1016/j.nicl.2019.101929]
- Wu Y, Luo L P, Xu B, Huang J and Zhao L Y. 2019. Classification and diagnosis of ultrasound images with breast tumors based on transfer learning. *Chinese Journal of Medical Imaging Technology*, 35(3): 357-360 (吴英, 罗良平, 许波, 黄君, 赵璐瑜. 2019. 基于迁移学习的乳腺肿瘤超声图像智能分类诊断. *中国医学影像技术*, 35(3): 357-360) [DOI: 10.13929/j.1003-3289.201807052]
- Xue L Y, Jiang Z Y, Fu T T, Wang Q M, Zhu Y L, Dai M, Wang W P, Yu J H and Ding H. 2020. Transfer learning radiomics based on multimodal ultrasound imaging for staging liver fibrosis. *European Radiology*, 30(5): 2973-2983 [DOI: 10.1007/s00330-019-06595-w]
- Yang P W, Zhou Y H, Xing G, Tian Z Q and Xu X Y. 2021. Applications of convolutional neural network in biomedical image. *Computer Engineering and Applications*, 57(7): 44-58 (杨培伟, 周余红, 邢岗, 田智强, 许夏瑜. 2021. 卷积神经网络在生物医学图像上的应用进展. *计算机工程与应用*, 57(7): 44-58) [DOI: 10.3778/j.issn.1002-8331.2009-0161]
- Yang Q, Zhang Y, Dai W Y and Pan J L. 2020. *Transfer Learning*. Beijing: Machinery Industry Press (杨强, 张宇, 戴文渊, 潘嘉林. 2020. 迁移学习. 北京: 机械工业出版社)
- Yang Y, Yan L F, Zhang X, Han Y, Nan H Y, Hu Y C, Hu B, Yan S L, Zhang J, Cheng D L, Ge X W, Cui G B, Zhao D and Wang W. 2018. Glioma grading on conventional MR images: a deep learning study with transfer learning. *Frontiers in Neuroscience*, 12: #804 [DOI: 10.3389/fnins.2018.00804]

- Yu J H, Deng Y H, Liu T T, Zhou J, Jia X H, Xiao T L, Zhou S C, Li J W, Guo Y, Wang Y Y, Zhou J Q and Chang C. 2020. Lymph node metastasis prediction of papillary thyroid carcinoma based on transfer learning radiomics. *Nature Communications*, 11(1): #4807 [DOI: 10.1038/s41467-020-18497-3]
- Yu Y Z, Shi D J, Ma J C and Zhou Z. 2019. Advances in application of artificial intelligence in medical image analysis. *Chinese Journal of Medical Imaging Technology*, 35(12): 1808-1812 (俞益洲, 石德君, 马杰超, 周振. 2019. 人工智能在医学影像分析中的应用进展. *中国医学影像技术*, 35(12): 1808-1812) [DOI: 10.13929/j.1003-3289.201909150]
- Zhang C M, Wang Q F, Liu Z Q, Huang J, Zhou Y, Liu Q Y and Xu W Y. 2020. Pulmonary nodule auxiliary diagnosis method based on deep transfer learning. *Computer Engineering*, 46(1): 271-278 (张驰名, 王庆凤, 刘志勤, 黄俊, 周莹, 刘启榆, 徐卫云. 2020. 基于深度迁移学习的肺结节辅助诊断方法. *计算机工程*, 46(1): 271-278) [DOI: 10.19678/j.issn.1000-3428.0053340]
- Zhang J F, Cui W S, Guo X Y, Wang B and Wang Z. 2020a. Classification of digital pathological images of non-Hodgkin's lymphoma subtypes based on the fusion of transfer learning and principal component analysis. *Medical Physics*, 47(9): 4241-4253 [DOI: 10.1002/mp.14357]
- Zhang R C, Guo Z H, Sun Y, Lu Q, Xu Z J, Yao Z M, Duan M Y, Liu S, Ren Y J, Huang L and Zhou F F. 2020b. COVID19XrayNet: a two-step transfer learning model for the COVID-19 detecting problem based on a limited number of chest X-Ray images. *Interdisciplinary Sciences: Computational Life Sciences*, 12(4): 555-565 [DOI: 10.1007/s12539-020-00393-5]
- Zhao C, Shuai R J, Ma L, Liu W J and Wu M L. 2021. The generation and classification of skin cancer images based on Self-Attention-StyleGAN. *Computer Engineering and Applications* [J/OL]. [2021-04-19]. <https://kns.cnki.net/kcms/detail/11.2127.tp.20210419.1440.067.html> (赵宸, 帅仁俊, 马力, 刘文佳, 吴梦麟. 2021. 基于 Self-Attention-StyleGAN 的皮肤癌图像生成与分类. *计算机工程与应用* [J/OL]. [2021-04-19]. <https://kns.cnki.net/kcms/detail/11.2127.tp.20210419.1440.067.html>) [DOI: 10.3778/j.issn.1002-8331.2102-0092]
- Zheng G Y, Liu X B and Han G H. 2018. Survey on medical image computer aided detection and diagnosis systems. *Journal of Software*, 29(5): 1471-1514 (郑光远, 刘峡壁, 韩光辉. 2018. 医学影像计算机辅助检测与诊断系统综述. *软件学报*, 29(5): 1471-1514) [DOI: 10.13328/j.cnki.jos.005519]
- Zheng Q, Furth S L, Tasian G E and Fan Y. 2019. Computer-aided diagnosis of congenital abnormalities of the kidney and urinary tract in children based on ultrasound imaging data by integrating texture image features and deep transfer learning image features. *Journal of Pediatric Urology*, 15(1): 75.e1-75.e7 [DOI: 10.1016/j.jpuro.2018.10.020]
- Zhuang Z M, Kang Y Q, Raj A N J, Yuan Y, Ding W L and Qiu S M. 2020. Breast ultrasound lesion classification based on image decomposition and transfer learning. *Medical Physics*, 47(12): 6257-6269 [DOI: 10.1002/mp.14510]

作者简介



黎英, 1973年生, 女, 副教授, 主要研究方向为医学影像处理、迁移学习、深度学习。
E-mail: 2313166529@qq.com



宋佩华, 通信作者, 男, 讲师, 主要研究方向为图形图像处理、迁移学习、智能计算。
E-mail: 455756282@qq.com