

# 注意力机制引导的多模态心脏图像分割

杨琬琪, 周子奇, 郭心娜

(南京师范大学计算机科学与技术学院, 江苏 南京 210023)

[摘要] 为有效挖掘模态间共享与模态特有的信息, 本文提出一种注意力机制引导的半孪生网络, 用于分割多模态(MRI 与 CT)心脏图像. 具体地, 首先运用循环一致的生成对抗网络(CycleGAN)进行双向的图像生成(即从 MRI 到 CT 以及从 CT 到 MRI), 这样可以解决模态间心脏图像不配对的问题; 其次, 设计一个新的半孪生网络, 将原始的 CT(或 MR)图像及其生成的 MR(或 CT)图像进行配对并同时输入, 先通过两个编码器(encoders)分别学习模态特有的特征, 再经过一个跨模态的注意力模块将不同模态的特征进行融合, 最后输入一个公共的解码器(decoder)来得到模态共享的特征, 用于心脏图像分割. 上述学习过程是端到端的方式进行训练. 本文将所提方法在真实的 CT 与 MR 不配对的心脏图像数据集上进行实验评估, 表明所提方法的分割精度超出基准方法.

[关键词] 注意力机制, 多模态心脏图像分割, 半孪生网络, 跨模态图像生成

[中图分类号] TP391.4 [文献标志码] A [文章编号] 1001-4616(2019)03-0027-05

## Attention-Guided Multimodal Cardiac Segmentation

Yang Wanqi<sup>1</sup>, Zhou Ziqi<sup>1</sup>, Guo Xinna<sup>1</sup>

(School of Computer Science and Technology, Nanjing Normal University, Nanjing 210023, China)

**Abstract:** With the goal of leveraging the modal-shareable and modal-specific information during cross-modal segmentation, we propose a novel cross-modal attention-guided semi-Siamese network for joint cardiac segmentation from MR and CT images. In particular, we first employed the cycle-consistency generative adversarial networks to complete the bidirectional image generation (i.e., MR to CT, CT to MR) to help reduce the modal-level inconsistency. Then, with the generated and original MR and CT images, a novel semi-Siamese network is utilized where 1) two encoders learn modal-specific features separately and 2) a common decoder makes full use of modal-shareable information from different modalities for a final consistent segmentation. Also, we implement the cross-modal attention to incorporate these shareable and specific information, and our model can be trained in an end-to-end manner. With extensive evaluation on the unpaired CT and MR cardiac images, our method outperforms the baselines in terms of the segmentation performance.

**Key words:** attention, multimodal cardiac segmentation, semi-siamese network, cross-modal image generation

根据美国心脏协会(AHA)2019年的心脏病和中风统计报告<sup>[1]</sup>指出,在美国,2019年预计将发生约1 055 000个病例罹患冠状动脉心脏病,其中包括720 000例新的和335 000例复发性冠状动脉病例.从这个意义上来说,早期诊断与治疗对降低心血管疾病的发病率和死亡率有非常重要的意义<sup>[2]</sup>.在早期诊断期间,医生通常从不同的模态(例如,MR和CT)收集图像信息以进行全面调查,其中一个重要的先决条件是准确地分割来自多个成像模态图像的心脏子结构.然而,通过手动标定的传统分割是非常费时费力的,因而研究出一个心脏图像自动分割的方法迫在眉睫.

虽然基于深度卷积神经网络的方法已经被广泛应用于其他器官的分割<sup>[3]</sup>,但对多模态心脏图像分割依然受限,原因在于:(1)模态不一致性:来自不同模态的图像具有明显的外观差异;(2)复杂结构:不同的心脏子结构是连通的,有时甚至会重叠;(3)模态间图像不配对:来自同一病人的不同模态数据缺乏.因而,以往的方法很难挖掘并利用不同模态间的相关信息,辅助其他模态进行心脏图像分割.

为此,在本文中我们提出了一种新颖的注意力机制引导的半孪生网络,以充分利用模态特有的和模态

收稿日期:2019-06-24.

基金项目:国家自然科学基金(61603193,61876087).

通讯联系人:杨琬琪,博士,研究方向:机器学习,深度学习,医学图像处理. E-mail: yangwq@njnu.edu.cn

可共享的信息,用于指导心脏图像的有效分割. 具体来说,本文方法主要包含两个阶段:

第一阶段,采用循环一致性生成对抗网络(CycleGAN)<sup>[4]</sup>进行双向图像生成,即从原始 CT(或 MR)图像转换生成假的 MR(或 CT)图像. 这样不仅有助于减少模态间的不配对性,还可以扩充有限的训练样本.

第二阶段,提出了一种新的半孪生网络进行图像分割. 为了既保留特有信息并寻求共同表示,首先使用两个单独的编码器分别学习模态特有的特征,然后使用一个公共解码器来学习不同模态之间的可共享信息. 更重要的是,在编码器和解码器之间,设计了跨模态的注意力机制<sup>[5]</sup>,可以很好地融合这些模态特有的特征,挖掘不同模态间的相关性,用于图像分割.

本文工作的主要贡献可归纳为:(1)采用 CycleGAN 进行跨模态图像生成,来解决不同模态间图像不配对的问题;(2)开发一种新颖的跨模态注意力引导的半孪生网络,学习模态特有及模态间共享的特征.

1 相关工作

近年来,有一些关于多模态心脏图像分割的尝试性工作<sup>[6]</sup>,例如,Dou 等人<sup>[7]</sup>提出了一种无监督的领域适应框架,运用生成对抗学习跨模态医学图像分割. Zhang 与 Zheng 等人<sup>[8]</sup>提出了一种跨模态图像生成的图像分割方法,通过增加形状一致性损失,以防止在跨模态图像生成过程中出现形变的问题,该方法能够从不配对的图像生成数据中学习并保持解剖学(即形状)的一致性. 目前,常见的医学图像分割方法有许多,包括 U-net、V-net、DeepLab 等. Ronneberger 等人<sup>[9]</sup>受“全卷积神经网络 FCN”的启发,提出了一个 U 型的 U-net 网络结构,包含了一个收缩路径来捕获上下文信息和一个对称的扩张路径用来得到准确的局部信息,常用于医学图像分割. 然而上述方法均不能充分挖掘不同模态间的相关性,不能有效解决上一章提到的局限性.

关于图像到图像的转换,文献[4]提出了循环一致性损失的生成对抗网络 CycleGAN,能够将未配对的图像从一个域迁移生成到另一个域,但它没有利用标签信息有可能存在形变. 在计算机视觉领域,注意力机制已广泛用于各种任务中. 例如,Hong 等人<sup>[10]</sup>设计了一个带有注意力机制的解耦合的编码器-解码器架构,以使得分割知识可以跨类别迁移.

2 本文方法

本节首先介绍多模态心脏图像分割模型的整体架构,然后针对其中跨模态图像生成和注意力机制引导的半孪生网络这两个部分进行详细阐述,重点讨论模型损失函数和注意力模块,最后介绍实现模型训练的具体细节.

本文所提方法的主要目标是挖掘并利用不同模态间的相关性进行多模态图像分割. 为实现这一点,所提方法主要包括两个部分:(1)跨模态合成图像,(2)注意力机制引导的半孪生网络,学习模态特有的特征,并通过注意力引导机制充分挖掘模态间可共享的特征进行分割.

本文多模态心脏图像分割网络的整体架构图如图 1 所示. 具体地,CT 和 MRI 两个模态的原始图像分别通过生成器  $G_B$  和  $G_A$  后得到对应另一个模态的合成图像,这样形成了 CT 与 MRI 模态配对的心脏图像. CT(或 MRI)真实图像和由它生成的 MRI(或 CT)合成图像首先分别通过各自的编码器,再同时进入注意力机制模块学得模态相关的特征,最后通过一个共同的解码器,输出对心脏图像的分割结果.

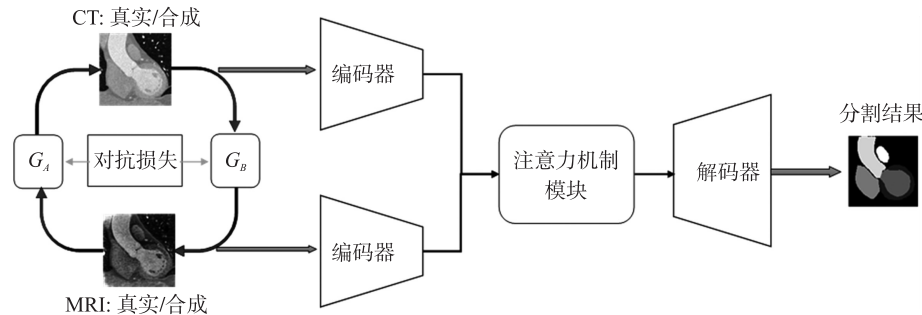


图 1 多模态心脏图像分割网络的整体架构图

Fig. 1 The framework of multimodal cardiac segmentation network

## 2.1 跨模态图像生成

考虑到 CycleGAN 能够有效地进行跨域图像生成,本文运用它来进行 CT 和 MRI 模态之间的图像合成,以解决多模态样本不配对的问题. 为简化起见,  $A$  和  $B$  被视为两种不同的模态(即 CT 和 MRI).  $x_A$  表示来自模态  $A$  的样本,遵循  $P_A$  分布.  $x_B$  表示来自模态  $B$  的样本,服从  $P_B$  分布. 在图像合成过程中,主要学习两个生成器  $G_A, G_B$  和两个鉴别器  $D_A, D_B$ ,生成器用于图像生成,判别器用于对生成的图像和真实的图像进行真假判别. 它们在学习的过程中通过对抗损失进行互相博弈,最终将生成判别器无法区分真假的合成图像,即与 CT 或 MRI 的分布非常相似的心脏图像. 对抗损失的公式如下:

$$\mathcal{L}_{GAN_A}(G_A, D_A) = E_{x_A \sim P_A(x_A)} [\log D_A(x_A)] + E_{x_B \sim P_B(x_B)} [\log(1 - D_A(G_A(x_B)))] \quad (1)$$

$$\mathcal{L}_{GAN_B}(G_B, D_B) = E_{x_B \sim P_B(x_B)} [\log D_B(x_B)] + E_{x_A \sim P_A(x_A)} [\log(1 - D_B(G_B(x_A)))] \quad (2)$$

式中,  $G_A(x_B)$  表示 MRI 图像样本  $x_B$  通过生成器  $G_A$  得到的 CT 合成图像,  $D_A(x_A)$  表示对 CT 图像样本  $x_A$  的真假判别结果,值可为 0 或 1, 0 为假, 1 为真.

由于模态  $A$  与  $B$  间的样本往往是不配对的,为使得生成的结果更加逼真, CycleGAN 提出循环一致损失函数,使得依次通过两个生成器的生成结果  $G_A(G_B(x_A))$  (或者  $G_B(G_A(x_B))$ ) 与原始的图像  $x_A$  (或者  $x_B$ ) 尽可能一致. 循环一致损失函数形式化如下:

$$\mathcal{L}_{cyc}(G_A, G_B) = E_{x_A \sim P_A(x_A)} [\|G_A(G_B(x_A)) - x_A\|_1] + E_{x_B \sim P_B(x_B)} [\|G_B(G_A(x_B)) - x_B\|_1]. \quad (3)$$

## 2.2 注意力机制引导的多模态心脏图像分割

在跨模态图像合成之后,本文设计了一个半孪生多模态分割网络,以两个模态为例,包括两个独立的编码器,一个注意力机制模块和一个公共的解码器. 具体来说,每个模态有一个独立的编码器,用于学习每个模态特有的图像底层特征,不同模态之间共享一个解码器,用于学习模态共享的高层语义特征. 在编码器与解码器之间设计一个注意力机制模块,学习跨模态的注意力图谱来挖掘不同模态之间的相关信息,并与自身模态的特征进行融合,用于多模态心脏图像分割. 以两个模态为例,注意力机制模块的主要结构如图 2 所示.

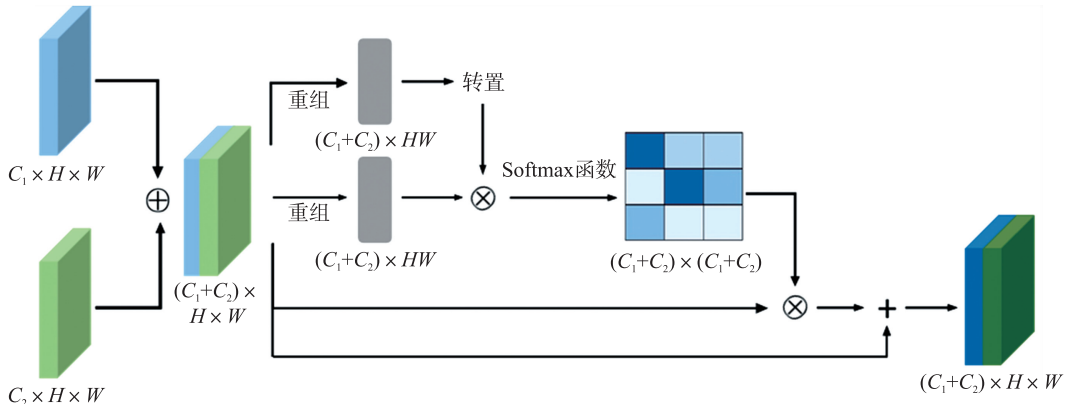


图 2 注意力机制模块的主要结构图

Fig. 2 Illustration of the proposed attention module

注意力机制模块的主要流程如下: 首先将两个编码器输出的特征图谱经通道层连接得到初步融合图谱  $((C_1 + C_2) \times H \times W)$ , 将初步融合图谱经矩阵重组得到图谱 1, 将初步融合图谱依次经矩阵重组和转置得到图谱 2; 然后将图谱 1 和图谱 2 作矩阵乘积后的结果经 softmax 函数得到注意力图谱, 计算得到跨模态的注意力图谱 (attention map), 大小为  $(C_1 + C_2) \times (C_1 + C_2)$ ; 最后将注意力图谱与初步融合图谱作矩阵相乘, 再与初步融合图谱进行逐元素相加, 得到最终的特征融合图谱, 大小为  $(C_1 + C_2) \times H \times W$ .

因为两个模态都用于描述同一个心脏器官, 注意力图谱能够挖掘不同模态的图像间许多相关的特征, 主要体现在注意力图谱的非对角块  $C_1 \times C_2$  和  $C_2 \times C_1$  部分. 不仅如此, 同一图像内部也存在相关性, 这在对角块  $C_1 \times C_1$  和  $C_2 \times C_2$  部分也可以得到体现.

本文使用 U-net<sup>[9]</sup> 实现半孪生网络的编码器和解码器. U-net 中的收缩路径完成编码器部分, 可以定位底层的高分辨率特征并捕获更细节的信息, 而 U-net 中的扩张路径完成解码器部分, 可以将上下文信息

传播到高层,同时获取高层语义信息,学得心脏图像的各个子结构.

本文采用交叉熵(Cross Entropy)损失函数来计算分割网络输出结果与医生标注的真实标签之间的分割损失,通过最小化这一损失来优化网络参数. 分割损失的计算公式如下:

$$\mathcal{L}_{\text{seg}}(S, G_A, G_B) = E_{x_A \sim P_A(x_A)} \left[ -\frac{1}{N_A} \sum_i y_A^i \log(S(G_B(x_A))_i) \right] + E_{x_B \sim P_B(x_B)} \left[ -\frac{1}{N_B} \sum_i y_B^i \log(S(G_A(x_B))_i) \right], \quad (4)$$

式中,  $S$  表示本文设计的半孪生多模态分割网络,  $N_A$  和  $N_B$  分别为模态  $A$  和  $B$  的样本个数.

综上所述,通过汇总式(1)到式(4),本文所设计的心脏图像分割网络的损失函数可写为:

$$\mathcal{L}(G_A, G_B, D_A, D_B, S) = \mathcal{L}_{\text{GAN}_A}(G_A, D_A) + \mathcal{L}_{\text{GAN}_B}(G_B, D_B) + \lambda \mathcal{L}_{\text{cyc}}(G_A, G_B) + \gamma \mathcal{L}_{\text{seg}}(S, G_A, G_B), \quad (5)$$

式中,  $\lambda$  和  $\gamma$  是循环一致性损失和分割损失的权重参数.

关于模型训练,采用 Adam 方法<sup>[11]</sup>进行随机梯度下降,学习率为 0.000 2,其他设定基本参照 CycleGAN 的设置去训练生成器和判别器. 为了加速训练过程,选择先预训练生成器和判别器,然后再完整地训练端到端的分割网络.

3 实验

3.1 数据集及评价指标

本文方法实验评估的数据集是医学图像领域旗舰会议 MICCAI 2017 Challenge 上的 Multi-Modality Whole Heart Segmentation 竞赛主办方提供的公开数据集. 该数据集中包含来自 20 个病人的 MRI 图像和来自另外 20 个病人的 CT 图像,均为 3D 图像. 放射科医生已经对每一个图像的心脏子结构做好了标记. 此次分割的主要任务是分割出心脏的 7 个子结构,包括:左心室、左心房、右心室、右心房、主动脉、肺动脉和心肌. 在训练过程中,将该数据集平均分成两折,分别为训练集和测试集,进行二折交叉验证.

由于数据采集的方向不同,所以通过 ITK-SNAP 软件将所有的样本方向都改成了冠状位. 所有存在有效标签的部分都被裁剪出来,然后被切分成 2D 的切片共有 2 534 张 CT 和 2 208 张 MRI. 这些形状不一的切片最后被 resized 到了 128×128 的大小,作为输入分割网络的图像.

为衡量分割结果的精度,采用 Dice 系数作为评价指标. Dice 用于衡量真实标记与分割结果之间重合的比例. Dice 越高则分割精度越高.

3.2 实验结果

本文将所提的方法与 3 种基准方法进行比较,分别是两个流行的医学图像分割方法全卷积神经网络 FCN<sup>[13]</sup>、Unet<sup>[9]</sup>,以及非常新的用于心脏图像分割的方法 Zhang&Zheng<sup>[8]</sup>. 这些方法应用于 CT 与 MR 两个模态的分割结果对比如表 1 所示.

表 1 不同方法的心脏图像子结构分割结果比较

Table 1 Comparison of segmentation performance on cardiac substructures in CT and MR images between different methods								
方法	主动脉	左心房	左心室	心肌	右心室	右心房	肺动脉	平均
FCN_CT <sup>[13]</sup>	0.886 3	0.816 3	<b>0.883 8</b>	<b>0.854 1</b>	0.788 5	0.794 0	0.775 8	0.828 4
FCN_MRI <sup>[13]</sup>	0.693 1	0.688 2	0.800 6	0.716 1	0.675 9	0.759 3	0.669 3	0.714 6
Unet_CT <sup>[9]</sup>	0.899 2	0.770 4	0.838 1	0.816 2	0.764 3	0.800 3	0.794 7	0.811 9
Unet_MRI <sup>[9]</sup>	0.771 9	<b>0.694 2</b>	0.775 1	0.696 1	<b>0.698 3</b>	0.782 9	<b>0.717 1</b>	0.733 6
Zhang&Zheng_CT <sup>[8]</sup>	<b>0.940 7</b>	<b>0.827 7</b>	0.836 2	0.794 2	0.806 4	0.813 4	0.810 3	0.832 7
Zhang&Zheng_MRI <sup>[8]</sup>	0.768 6	0.655 5	0.761 2	0.703 8	0.663 7	0.765 8	0.697 3	0.716 5
Ours_CT	0.928 2	0.813 1	0.849 7	0.786 9	<b>0.806 6</b>	<b>0.825 5</b>	<b>0.839 1</b>	<b>0.835 6</b>
Ours_MRI	<b>0.787 5</b>	0.694 0	<b>0.803 1</b>	<b>0.718 9</b>	0.673 3	<b>0.796 7</b>	0.714 7	<b>0.741 2</b>

从表 1 可以看出,本文方法成功地提取了不同模态之间的相关信息来提升 MRI 图像的分割精度. 虽然比较实验体现了本文方法在提高 CT 的分割精度上作用不是很明显,但是 MRI 分割精度的显著提高表明了注意力机制是有效的. 并且,注意力机制挖掘模态间的相关性,有效地避免了“坏的”MRI 图像影响“好的”CT 图像所产生的风险.



此外,本文列举了一组跨模态图像生成结果和两组多模态心脏图像分割结果. 心脏图像跨模态生成结果如图3所示,其中左图是CT到MRI图像的生成,右图是MRI到CT的生成过程. 图4展示了不同方法的CT与MRI心脏图像分割结果,其中左图是CT图像,右图是MRI图像. 可以看出,本文方法的分割结果与真实结果非常接近,并且没有明显的形变和分割误差.




图3 心脏图像生成结果示例(左图表示从CT图像生成MRI图像,右图表示从MRI图像生成CT图像)

Fig. 3 Typical synthesized results of our method. The left part shows the original CT images and the corresponding synthesis the original MRI images and their synthesis CT images, respectively




图4 CT与MRI心脏图像分割结果示例

Fig. 4 Visualization of segmentation results of different methods on CT(left) and MR(right) images

## 4 结论

本文提出了一种新的注意力机制引导的多模态心脏图像分割方法,解决了心脏图像分割应用当前面临的主要问题:由于模态间外观差异大和模态间样本不配对,导致很难挖掘模态间的相关信息. 本文将注意力机制(attention)应用于多模态心脏图像的分割任务,挖掘不同模态间相关的特征,用于辅助其他模态的分割. 大量的实验验证了本文所提方法的有效性.

## [参考文献]

- [1] Benjamin E J, Muntner P, Alonso A, et al. Heart disease and stroke statistics 2019 update: a report from the American heart association[J]. Circulation, 2019, 139(10): 56–528.
- [2] Ruan Y, Guo Y, Zheng Y, et al. Cardiovascular disease (CVD) and associated risk factors among older adults in six low-and middle-income countries: results from SAGE wave 1[J]. BMC public health, 2018, 18(1): 778.
- [3] Zhang Z, Xie Y, Xing F, et al. MDNet: a semantically and visually interpretable medical image diagnosis network[C]//IEEE Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, Honolulu, HI, 2017: 3549–3557.
- [4] Zhu J, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//IEEE International Conference on Computer Vision (ICCV), IEEE, Venice, 2017: 2242–2251.
- [5] Zagoruyko S, Komodakis N. Paying more attention to attention: improving the performance of convolutional neural networks via attention transfer[J]. arXiv preprint arXiv:1612.03928, 2016.
- [6] Zhuang X, Shen J. Multi-scale patch and multi-modality atlases for whole heart segmentation of MRI[J]. Medical image analysis, 2016, 31: 77–87.
- [7] Dou Q, Ouyang C, Chen C, et al. Unsupervised cross-modality domain adaptation of ConvNets for biomedical image segmentations with adversarial loss[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. AAAI Press, Stockholm, 2018: 691–697.

(下转第41页)

- [26] WEBER S A,INSAF T Z,HALL E S,et al. Assessing the impact of fine particulate matter(PM2.5)on respiratory-cardiovascular chronic diseases in the New York city metropolitan area using hierarchical bayesian model estimates[J]. Environment research, 2016,151:399-409.
- [27] CHIOU J H,PING H K. A Deep CNN-LSTM Model for Particulate Matter(PM2.5)Forecasting in Smart Cities[J]. Sensors, 2018,18(7):2220-2241.
- [28] CONG W,SHU L,XIAO J Y,et al. A novel spatiotemporal convolutional long short-term neural network for air pollution prediction[J]. Science of the total environment,2019,654:1091-1099.
- [29] PING W S,JIA W C,JEN W H. Adaptive deep learning-based air quality prediction model using the most relevant spatial-temporal relations[J]. IEEE access 6,neurocomputing,2018(6):38186-38200.
- [30] CHU D A,KAUFMAN Y J,ZIBORDI G,et al. Global monitoring of air pollution over land from the Earth observing system-terra moderate resolution imaging spectroradiometer( MODIS) [J]. Geophysis research,2003,108( D21 ):4661-4667.
- [31] KOELEMEEIJER R,HOMAN C,MATTHIJSEN J. Comparison of spatial and temporal variations of aerosol optical thickness and particulate matter over Europe[J]. Atmosphere environment,2013,40(27):5304-5315.
- [32] SAIDE P E,CARMICHAEL G R,SPAK S N,et al. Forecasting urban PM10 and PM2.5 pollution episodes in very stable nocturnal conditions and complex terrain using WRF-Chem CO tracer model[J]. Atmosphere environment,2011,45(16):2769-2780.
- [33] SU X,GOUGH W,SHEN Q. Correlation of pm 2.5 and meteorological variables in Ontario cities:statistical downscaling method coupled with artificial neural network[C]//Proceedings of the 24th International Conference on Modeling, Monitoring and Management of Air Pollution(AIR 2016). Crete,2016.
- [34] LIANG Z,GUANG Z,PEI Y S. Learning Spatiotemporal Features using 3DCNN and Convolutional LSTM for Gesture Recognition[C]//Proceedings of the International Conference on Computer Vision. Venice,2017.
- [35] DU T,BOURDEV L,FERGUS R,et al. Learning spatiotemporal features with 3D convolutional networks[C]//Proceedings of the International Conference on Computer Vision. Santiago,2015.
- [36] STUART G,ELIE B,RENE D. Neural networks and the bias/variance dilemma[J]. Neural computer,1992,41(1):1-58.
- [37] WIKRAM R,PAVAN Y,SHRESTHA M. Deep air:forecasting air pollution in Beijing, China. [C]//Proceedings of IEEE International Conference on Computer Vision. New York:IEEE Press,2017:1-9.
- [38] 赵文芳,王京丽,尚敏,等. 基于粒子群优化和支持向量机的花粉浓度预测模型[J]. 计算机应用,2019,39(1):98-104.

[责任编辑:顾晓天]

(上接第31页)

- [8] Zhang Z,Yang L,Zheng Y. Translating and segmenting multimodal medical volumes with cycle-and shape-consistency generative adversarial network[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR),IEEE,Salt Lake City, UT,2018:9242-9251.
- [9] Ronneberger O,Fischer P,Brox T. U-Net:convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI),Springer,Cham,Munich,2015:234-241.
- [10] Hong S,Oh J,Han B,et al. Learning transferrable knowledge for semantic segmentation with deep convolutional neural network[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR),IEEE,Las Vegas,NV,2016:3204-3212.
- [11] Kingma D P,Ba J. Adam:a method for stochastic optimization[J]. arXiv preprint arXiv:1412.6980,2014.
- [12] <http://www.itksnap.org/pmwiki/pmwiki.php>.
- [13] Shelhamer E,Long J,Darrell T. Fully convolutional networks for semantic segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition(CVPR),IEEE,Boston,MA,2015:3431-3440.

[责任编辑:陆炳新]