

# 基于特定领域解码的域泛化医学图像分割方法

叶怀泽<sup>1,2</sup>, 周子奇<sup>1,2</sup>, 祁磊<sup>3</sup>, 史颖欢<sup>1,2</sup>

(1. 南京大学计算机软件新技术国家重点实验室, 南京 210023; 2. 南京大学健康医疗大数据国家研究院, 南京 210023; 3. 东南大学计算机科学与工程学院, 南京 210023)

**摘要:** 多源域领域泛化是模型利用多个不同领域中的语义信息, 并且能够很好地泛化到未知领域上。在医学图像中, 不同领域之间的跨度比较大, 模型泛化性能在未知域上会有较大程度的下降。为了解决这一问题, 本文提出了一种编码特征再针对特定领域进行解码的网络结构。该模型使用一个通用编码器来学习所有领域上的领域不变特征, 并通过特定领域解码器还原原有图像以加强其对图像特征的复原能力。此外, 该模型还通过生成特征迁移图像与源域图像进行对抗学习来加强编码器学习领域不变特征的能力。同时, 本文在模型中还引入了特殊构造的分割融合预处理步骤来扩充数据集以增强模型的泛化能力, 并进一步提高了本文提出网络结构的性能。在两个医学图像的分割任务中, 大量实验数据表明, 本文提出的模型相比现有先进模型表现出了优异的性能, 此外本文还进行了一系列消融实验, 证明了模型的有效性。

**关键词:** 领域泛化; 医学图像分割; 迁移学习; 对抗学习; 数据增广

**中图分类号:** TP391      **文献标志码:** A

## Domain Generalization via Domain-Specific Decoding for Medical Image Segmentation

YE Huaize<sup>1,2</sup>, ZHOU Ziqi<sup>1,2</sup>, QI Lei<sup>3</sup>, SHI Yinghuan<sup>1,2</sup>

(1. State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023, China; 2. National Institute of Healthcare Data Science, Nanjing University, Nanjing 210023, China; 3. School of Computer Science and Engineering, Southeast University, Nanjing 210023, China)

**Abstract:** Multi-source domain generalization (DG) aims to train a model uses semantic information of different domains and can be generalized to unknown domains. In the medical image, the gap between different domains is relatively large, and the model will suffer from performance drop in the unknown domain. In order to solve this problem, this paper proposes a network structure which encodes images for features and decodes domain specific features. The model uses a generic encoder, which learns all source domains for the domain-invariant features, and several domain-specific decoders to reconstruct the original images to promote the ability of extracting image features. Meanwhile, these decoders also help to generate transferred image to engage in adversarial learning with images of source domains in order to improve the encoder's ability of learning invariant features. In addition, we also introduce a special Cutmix strategy which change foreground information of different domain images to augment the data set in the model to

**基金项目:** 国家重点研发计划(2019YFC0118301); 国家自然科学基金(81927808)。

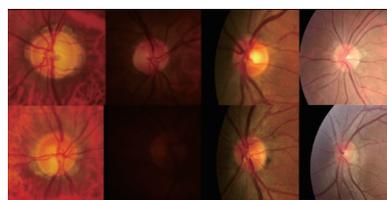
**收稿日期:** 2022-04-08; **修订日期:** 2022-10-12

enhance the generalization ability of the model and further improve the performance of our network structure. In two medical image segmentation tasks, a large number of experimental data show that the proposed model has excellent performance compared with the existing advanced models. In addition, a series of ablation experiments are carried out to prove the effectiveness of the model.

**Key words:** domain generalization; medical image segmentation; transfer learning; adversarial learning; data augmentation

## 引言

深度网络的不断成熟与发展,在医学图像分割任务方面表现出强大的性能。在较多的医学图像分割任务上,目前主流的假设是训练集图像和测试集图像相互独立且来自同一分布,然而在真实情况中,训练集和测试集通常存在域间隙<sup>[1]</sup>。因此,目前主流的假设条件可能无法满足。尤其是在医学图像领域,不同设备的数据采集参数不同,成像模型也各不相同,因此很容易造成测试集与训练集领域的域间隙。例如在如图1所示的Fundus数据集中,可以明显地观察到不同设备采集的眼底图像在颜色、光照等方面存在明显的差异。然而目前的大部分网络模型在面对域间隙时都会出现不同程度的性能下降。目前一种流行的对抗域间隙的做法是无监督领域适应(Unsupervised domain adaptation, UDA)。UDA是在有标签的原数据集训练一个可以适应到无标签目标域数据集的鲁棒模型,该模型可以有效抑制领域之间差异的影响,在保证源域分割性能的同时,在目标域相比无适应手段的监督学习也有更高的性能。目前一些无监督领域适应方法<sup>[2-3]</sup>在医疗图像领域中已经取得了优异的性能。但是当这些模型被应用到另一个未经过适应的领域时,需要重新训练网络模型以适应新的领域。这样的重新训练过程无疑需要消耗额外的时间和计算资源。另一个需要考虑的因素是,由于隐私保护等原因,有些领域图像可能无法获得,这会影响无监督领域适应在某些场景中的可行性。



Domain 1 Domain 2 Domain 3 Domain 4

图1 Fundus数据集中不同领域的成像对比

Fig.1 Comparison of different domains of Fundus dataset

领域泛化(Domain generalization, DG)是解决上述问题的一个重要途径。领域泛化训练一个鲁棒全能模型,从多个领域中学习信息,在其他未知领域中能够表现出良好的分割性能,而不需要在额外的未知领域进行训练。目前主流的领域泛化思路是学习领域不变特征(Domain invariant feature)<sup>[4-5]</sup>,训练中要求模型能够从多个源域中提取出最一般、最基本信息的特征,从而能够在任意未知领域中也获得其领域不变特征,在分割结果中表现出优异的性能。目前已有的一些学习领域不变特征的方法着重于对抗学习方面<sup>[4-5]</sup>。然而,这种对抗模型往往不够稳定,而且训练过程难以调试。因此,可能会错误地学习有害的语义分割信息,从而损害最终的分割结果。本文改进了对抗模型的方式,采用一种更加新颖的模型结构,有效缓解了这样的问题。

领域适应中另一个出发点是对数据的处理方面,常见的处理方法是进行数据增广。传统的数据增广方法是在源域上翻转、平移等操作。目前在很多研究方向上采用了Mixup<sup>[6]</sup>、Cutmix<sup>[7]</sup>等操作,其中Mixup将随机的两张图片按比例混合,Cutmix将图片的一部分切割掉而替换成随机其他图片的像素值,这样的增广方法能够有效提高模型的鲁棒性。本文重新构建了一个针对医学图像分割任务的特殊Cutmix策略。

本文提出了一种泛化策略,采用编码—解码的方式。具体而言,使用基于UNet的编码器,该编码器为所有源域共享,负责将图片信息转换为高维特征信息。为了让编码器提取到更多领域不变的特征,引入了多个特定领域的解码器,负责将来自不同领域的特征解码到编码器所属的领域。同时,还配备了同等数量判别器,用于辨别解码出来的重构图像。这相当于在任意两组源域之间形成了一次双向学习。因此,可以有效地缓解域间隙所带来的性能下降。同时,还针对每个领域泛化方向进行了特定的Cutmix处理步骤,以增加图像特征的多样性,从而提高模型的鲁棒性。

本文在两个医学图像分割任务Fundus<sup>[8]</sup>和Prostate<sup>[9]</sup>上进行了大量的实验。实验结果表明,本文的模型相比目前最先进的模型具有优越性。同时,大量的消融实验证明了本文模型中每个模块的有效性。

具体地,本文的主要贡献包括:

(1)提出了一种用于跨模态医学图像分割的泛化网络,该网络由分割子网络、各个特定领域的迁移网络和各个特定领域的判别网络组成。

(2)提出了一种针对任意两组领域的双向对齐方案,同时备有领域对抗模块对解码结果进行强化。

(3)采用了一种为任意泛化方向而专门生成的Cutmix数据扩充,参与正常的分割网络,提高模型鲁棒性。

(4)对两个典型的医学图像分割任务,即视网膜眼底图像<sup>[8]</sup>(Fundus)分割和前列腺(Prostate)MRI图像<sup>[9]</sup>分割分别在4个数据集和6个数据集上进行了广泛的实验。实验数据和消融实验结果证明了本文方法的有效性。

## 1 相关工作

领域泛化的目的是从多个领域中训练模型,在不额外训练的情况下,将模型直接泛化到其他未知领域。本文着重说明与本文相关的两个主要方面。

### 1.1 基于学习领域域不变表示的领域泛化

基于域不变表示的领域泛化的目的是提取图像特征,并使这些特征在不同领域中保持不变,即具有一般性,从而能够将这些特征转移到不同的领域中使用。目前有许多领域泛化方法都基于这种思想。对于领域泛化来说,其目标是将特定特征空间中多个源域之间的特征差异减小为域不变特征,使学习到的模型具有对不可见域的可泛化能力。目前主要有4种基于学习领域不变表示的方法:基于核的方法、领域对抗学习、显式特征对齐和不变风险最小化<sup>[10]</sup>。

领域对抗学习是其中常用且有效的方法。Ganin等<sup>[11-12]</sup>提出了领域对抗神经网络(Domain-adversarial neural network, DANN)进行域自适应,对生成器和鉴别器进行对抗训练。训练判别器来区分域,同时训练生成器欺骗判别器来学习域不变特征表示。Li等<sup>[13]</sup>在领域泛化中采用了这一思想。Gong等<sup>[14]</sup>通过在流形空间中逐渐减小域差异来使用对抗训练。Li等<sup>[15]</sup>提出了一种条件不变对抗网络(Conditional invariant adversarial network, CIAN)用于领域泛化。除对抗式领域分类外,Zhao等<sup>[16]</sup>通过最小化不同训练域的条件分布之间的KL散度,引入额外的熵正则化,推动网络学习领域不变特征。然而,以上的大部分方法均会由于对抗网络的不稳定性从而导致模型受到低质量领域图片分割信息的影响。

文献[17]提出了一种新的实例选择性白化损耗算法,以提高不可见领域域分割网络的鲁棒性。其方法分解了在特征表示的高阶统计量(即特征协方差)中编码的领域特定风格和领域不变内容,并有选择地只删除导致领域迁移的风格信息。

文献[18]提出了一种StableNet的网络结构,致力于通过训练样本的学习权值去除特征之间的依赖

关系来解决训练和测试数据之间特征分布变化的影响,这有助于深度模型摆脱虚假的相关性,进而更专注于区别特征和标签之间的真正联系。

## 1.2 基于数据增广的领域泛化

数据增广是训练机器学习模型最有用的技术之一。典型的增广操作包括翻转、旋转、缩放、裁剪、添加噪声等。它们被广泛应用于有监督学习中,以提高模型的泛化性能,减少过拟合现象的发生<sup>[19]</sup>。因此目前有很多领域适应的方法也采用了类似的数据增广方法。领域随机化是其中的一种主流方法<sup>[10]</sup>。

领域随机化是一种有效的数据增广方法。这通常是通过生成新的数据来实现,因此这种方法可以利用有限的训练样本从而模拟出复杂的环境。常见的做法包括改变物体的位置和纹理、改变物体的数量和形状、修改光照和相机视图以及在数据中添加不同类型的随机噪声等。Tobin等<sup>[20]</sup>首先使用该方法从模拟环境中生成更多的训练数据,用于在真实环境中进行泛化。Prakash等<sup>[21]</sup>在随机放置对象进行数据生成时,进一步考虑了场景的结构,使得神经网络在检测对象时能够学习利用上下文。

目前新兴的主流增广方法是Mixup<sup>[6]</sup>及其变种和Cutmix<sup>[7]</sup>等操作,他们的操作一般是将两张来自不同领域的图片进行不同比例的混合,或者是从其中的一张切取一部分图片信息并直接覆盖到另一张图片中,并根据切割的大小分配标签的信息。本文对其进行了适应性改造,并取得了较好的性能。

Pan等<sup>[22]</sup>提出了一种简单的数据增广方法。该方法在训练过程中使用高斯噪声干扰特征嵌入,并进一步在训练过程中迭代估计完整的类条件特征协方差矩阵。为随后的联合随机特征增广提供了一种有效的领域随机化方法,对特征进行扰动,包括类内和域间变异方向,最终在不同的数据集验证上取得了不错的效果。

Xu等<sup>[23]</sup>开发了一种新的基于傅里叶的数据增强策略,称为振幅混合,它在两幅图像的振幅频谱之间线性插值,在原图像和增广图像的预测之间引入了一种称为协同教师正则化的双形式一致性损失。

目前还有比较新兴的元学习方法。Shu等<sup>[24]</sup>采用元学习方法进行数据增广,提出了一个学习开放域可泛化表示的元学习框架。通过一个新的Dirichlet混合在特征级上扩充域,提炼软标签在标签级上扩充域,以弥补每个域缺少的类和其他领域知识。通过设计新的元学习任务和元学习损耗来实现跨领域的元学习,既保留了领域特有的知识,又实现了跨领域的知识泛化。

除此以外,还有一些与本文内容相关的方法,在此不做过分类,例如Han等<sup>[25]</sup>在医学图像分割任务的领域适应中采用了一种基于提取特征再翻译的源域双向对齐网络方法。本文参考这种思路,并将这种双向对齐的思路运用于多源领域的泛化任务中。Liu等<sup>[26]</sup>将联合学习(Federated learning, FL)应用到医学图像分割任务的领域泛化中,在Fundus数据集和Prostate数据集中取得了较好的结果。

## 2 基于特定领域解码的域泛化医学图像分割方法

如图2所示,本文网络主要由1个编码器、若干个特定领域重构迁移网络和1个分割器组成,其中按其功能主要可以分为两个模块。第一个是重构迁移模块,主要由和源域相同数量的解码器 $U_1, U_2, \dots, U_n$ 和判别器 $D_1, D_2, \dots, D_n$ 组成,主要负责对源域图像的重构和转义到不同领域的功能;另一个是分割模块,主要由编码器 $E$ 和分割模块 $C$ 组成。本文研究重点是:(1)利用多个对称翻译子网络实现任意两个领域特征分布的双向对齐;(2)利用分割子网络提取出所有领域中更多领域不变的特征。下面将从这两个方面详细介绍本文的方法。

### 2.1 基本定义

定义 $X_1, X_2, \dots, X_n$ 分别为来自领域1、领域2、 $\dots$ 、领域 $n$ 的集合,其中 $x_1^j, x_2^j, \dots, x_n^j$ 分别为来自领域1、领域2、 $\dots$ 、领域 $n$ 的第 $j$ 个图像样本, $Y_1, Y_2, \dots, Y_n$ 分别为来自领域1、领域2、 $\dots$ 、领域 $n$ 的标签集合,

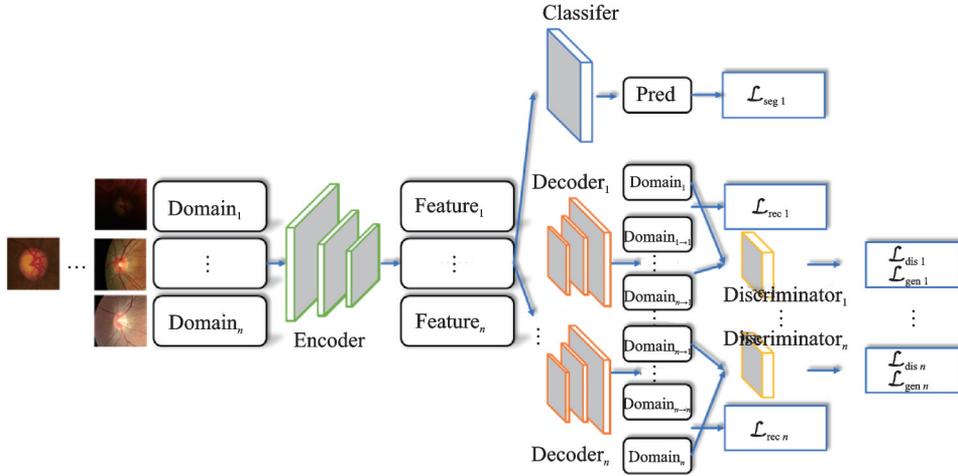


图2 本文方法框架

Fig.2 Framework of the proposed method

$f_1^j, f_2^j, \dots, f_n^j$  分别为  $x_1^j, x_2^j, \dots, x_n^j$  经过编码器后得到的图像特征,  $y_1^j, y_2^j, \dots, y_n^j$  分别为来自领域 1、领域 2、 $\dots$ 、领域  $n$  的第  $j$  个样本的标签。定义  $x_{a \rightarrow b}$  为领域  $a$  图像经过解码器  $b$  得到的迁移图像。

## 2.2 重构迁移模块

该模型目标是减少域间隙对医学分割结果的影响。由于目标域不可知,因此需要尽量利用现有领域充分地获取足够的信息,学到更多领域不变的特征。因此,本文设计与源领域数量相同的迁移子网络模块,每个领域的图片都会参与到所有的迁移子网络,包括自己的子网络。对于领域图片  $X_i$  来说,它参与到解码器  $U_i$  子网络中,得到  $X_{i \rightarrow i}$  的过程可概括为一种重构的过程,因此,引入重构损失来约束网络,使得每个专属的解码器都能将编码器提取到的特征重新解构为原网络。这个过程不仅能够提高单个解码器的解码能力,也同时加强了编码器的提取领域不变特征的能力。对于领域  $X_i$  参与到其他解码器如  $U_j$  的过程,得到  $X_{i \rightarrow j}$  的迁移图像,迁移后的图像与迁移目标域的源图像进行一次对抗训练,最终使得判别器无法正确区分迁移图像和迁移目标领域源图像所属领域。因为只有编码器提取出来足够水平的领域不变特征时,解码器才能正确地将特征转义到其他领域。下面是迁移对抗子网络和重构网络的具体细节。

**对抗损失。** 给定一张来自领域  $X_i$  的图像  $x_i$ , 经过编码器  $U$  提取信息后得到特征  $f_i$ 。特征  $f_i$  再经过除解码器  $D_i$  以外的其他解码器得到若干迁移图像  $x_{i \rightarrow j} (j \neq i)$ 。从生成式对抗网络的角度来看,迁移对抗网络扮演生成器的角色,与判别器形成对抗。对抗损失表达为

$$L_{advij}(U, D_i, x_i, x_j) = E(\lg D_i(x_i)) + E\left(\lg\left(1 - D_i\left(U_i\left(E(x_j)\right)\right)\right)\right) \quad (1)$$

其中,判别器在优化过程中使目标最大化。同时,编码器和解码器鼓励翻译后的图像与目标图像不可区分,从而使目标不断降低。

**重构损失。** 给定一张来自领域  $X_i$  的图像  $x_i$ , 经过编码器  $U$  提取信息后得到特征  $f_i$ , 特征  $f_i$  在经过解码器后得到重构图像  $x_{i \rightarrow j}$ 。重构损失表达为

$$L_{reci}(U, D_i, x_i) = \mathbb{E}\left\|U_i\left(E(x_i)\right) - x_i\right\|_1 \quad (2)$$

因此,整个模块的损失可以表示为

$$L_{\text{gen}} = \sum_i^n \left( \lambda_{\text{rec}} L_{\text{rec}i} + \lambda_{\text{adv}} \sum_{j(j \neq i)} L_{\text{adv}ij} \right) \quad (3)$$

式中  $\lambda_{\text{rec}}$  和  $\lambda_{\text{adv}}$  为超参数。

### 2.3 分割网络

在编码器逐步提取更加领域不变的特征外,还需要对训练分割器  $C$  分割特征的能力。除了对分割结果需要与标签做交叉熵损失外,本文还额外引入了特殊的 Cutmix。

**领域特定 Cutmix。**对每一个泛化的方向都专门生成了一个 Cutmix 数据集,具体操作为任意从所有源域中取出两张图片,根据标签的情况找到其分割中心,然后根据分割中心位置交换其分割前景,以此组成新的图像。新的图像混合两个领域的前景和背景信息,因此网络可以从中习得更加丰富的语义信息,提高获得领域不变特征的能力。图3展示了领域特定 Cutmix 的可视化样例。

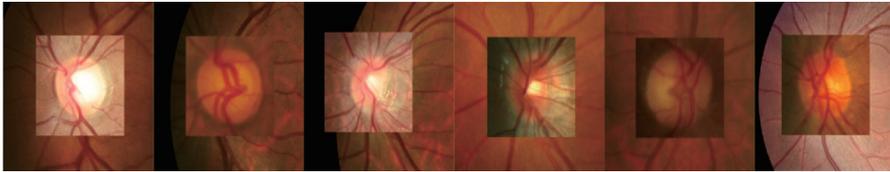


图3 部分领域特定 Cutmix 的结果

Fig.3 Some samples of domain specific Cutmix

将  $X_i$  中的  $x_i$  经过 Cutmix 处理过后的图像记作  $c_i$ , 因此分割损失可以记作

$$L_{\text{seg}i}(x_i, c_i, y_i) = L_{\text{CE}}(x_i, y_i) + L_{\text{CE}}(c_i, y_i) + L_{\text{DICE}}(x_i, y_i) + L_{\text{DICE}}(c_i, y_i) \quad (4)$$

$$L_{\text{seg}} = \sum_i L_{\text{seg}i} \quad (5)$$

### 2.4 总损失

综上所述,总损失可以表示为

$$\text{Loss} = \lambda_{\text{gen}} L_{\text{gen}} + \lambda_{\text{seg}} L_{\text{seg}} + \lambda_{\text{rec}} L_{\text{rec}} \quad (6)$$

整个框架由分割子网络和若干个翻译子网络组成,他们都共享一个基于 Unet 的编码器,分割子网络包括编码器  $E$  和分类器  $C$ 。翻译子网络由共享编码器和其所属特定领域的解码器组成。这些基于特定领域的解码器具有相同的体系结构,但它们不共享任何权重。它们由4个残余模块和4个反卷积层组成。判别器用于区分源域的真图像和生成图像。所有判别器都有相同的架构,包括4个卷积层,但彼此之间不共享任何参数。

## 3 实 验

将从定性和定量的角度评估所提出方法的有效性。具体来说,将本文方法与几种最先进的方法进行了比较,并进行消融实验来研究各种约束条件对模型性能的影响。

### 3.1 数据集

实验在两个数据集上进行,分别是视网膜眼底图像(Fundus)<sup>[8]</sup>和前列腺 T2 加权 MRI 图像数据集(Prostate)<sup>[9]</sup>,其中 Fundus 数据集进行 disc 和 cup 的分割,该数据集来自4个不同临床中心。Prostate 数据集有6个来自不同数据源的图像。在训练过程中将图像均重新采样至 256 像素 × 256 像素,并且做相同的归一化操作,以便网络模型的训练。

### 3.2 实验细节

所有超参数在所有实验方向上均采用相同的设置,其中编码器和分割器是基于Unet的模型,模型优化器采用Adam, batch\_size 设定为16。判别器学习率为0.000 1,其余模块学习率为0.001,所有学习率随训练周期而减少。损失中的比例 $\lambda_{rec}$ 设定为1.0, $\lambda_{gen}$ 设定为0.1, $\lambda_{seg}$ 设定为1.0, $\lambda_{adv}$ 设定为0.5。代码为Pytorch实现,Fundus需要1块NVIDIA2080TiGPU完成实验,Prostate需要3块GPU,单个方向单次训练时长约4 h。

### 3.3 评价指标

为了评估实验结果,采用两个常用的度量:Dice系数(Dice)和平均表面距离(ASD),分别对整个物体区域和表面形状的分割结果进行定量评价。Dice主要用于计算预测结果与真实标签的相似度,Dice值越高,分割性能越好。然后引入ASD来测量预测结果和真实标签之间的平均距离,ASD值越低,表示性能越好。

### 3.4 与其他领域泛化方法的实验结果比较

遵循其他领域泛化文献中的实践,采用排除一个域进行训练的策略,即在 $K-1$ 分布式源域上进行训练,最后在排除的不可见目标域上进行测试。因此,眼底图像分割任务有4个泛化方向,前列腺MRI分割任务有6个泛化方向。本文中其他方法的结果采集于先前发布的文献[26]。

本文与以下最新方法进行比较。JiGen<sup>[27]</sup>:通过自监督学习方法学习领域不变表示信息。BigAug<sup>[28]</sup>:一种通过大量数据转换从而进行正则化一般表示学习的方法。FedDG<sup>[26]</sup>:一种对联邦学习的改进使其能够运用于领域泛化分割任务中。DST<sup>[29]</sup>:采用一系列数据增广策略进行域泛化,包括随机锐化、模糊化、噪声、亮度调整、对比度变化、扰动、旋转、缩放、变形和裁剪。SAML<sup>[9]</sup>:基于梯度的元学习,通过在训练过程中使用虚拟元训练和元测试明确地模拟领域转移。

表1和表2反映了本文方法在Fundus数据集上对视杯和视盘分割结果的情况。可以观察到不同的

表1 本文方法在Fundus数据集Disc、Cup分割结果的Dice指标与其他方法结果的比较

Table 1 Comparison of the proposed method's Dice results on Optic Disc/Cup segmentation from Fundus images %

分割任务 (未知领域)	视杯分割 (Dice)					视盘分割 (Dice)					总体
	A	B	C	D	平均	A	B	C	D	平均	
JiGen	80.81	<b>79.46</b>	82.65	84.3	81.81	95.03	90.47	91.94	91.06	92.13	86.97
BigAug	81.62	69.46	82.64	84.51	79.55	93.49	86.18	92.09	93.67	91.36	85.46
DST	75.63	80.8	84.32	86.24	81.75	92.2	<b>90.77</b>	94.02	90.66	91.91	86.83
FedDG	<b>84.13</b>	71.88	83.94	85.51	81.37	<b>95.37</b>	87.52	93.37	<b>94.5</b>	92.69	87.03
Ours	83.58	78.92	<b>85.31</b>	<b>85.67</b>	<b>83.37</b>	95.25	87.14	<b>94.72</b>	94.05	<b>92.79</b>	88.08

表2 本文方法在Fundus数据集Disc、Cup分割结果的ASD指标与其他方法结果的比较

Table 2 Comparison of the proposed method's ASD results on Optic Disc/Cup segmentation from Fundus images

分割任务 (未知领域)	视杯分割 (ASD, voxel)					视盘分割 (ASD, voxel)					总体
	A	B	C	D	平均	A	B	C	D	平均	
JiGen	19.56	13.99	11.90	8.92	13.60	8.55	14.09	11.35	12.57	11.64	12.62
DST	24.42	<b>12.89</b>	10.91	<b>7.05</b>	<b>13.82</b>	13.24	<b>14.00</b>	8.52	10.05	11.45	12.31
Ours	<b>16.73</b>	15.52	9.94	8.45	12.66	<b>8.42</b>	18.82	<b>7.21</b>	<b>6.43</b>	<b>10.22</b>	<b>11.44</b>

方法在不同的泛化方向上的性能不同。本文方法在  $C$ 、 $D$  两个泛化方向上表现较为良好,在  $C$  方向的视杯分割中达到 85.31% 的 Dice 指标,领先于其他方法 1%~2%。同时在总体表现上 Dice 指标达到了 88.08%,相比其他方法提高 1% 左右,ASD 指标达到 11.44,相比其他方法提升 1.0 左右。

表 3 和表 4 反映了本文方法在 Prostate 数据集上的表现情况。虽然整体情况相比先进方法在 Dice 上提升不足,但是比一般的方法还是有一定优势。由表中数据可见,无论在 Dice 指标还是 ASD 指标上,本文方法的结果在所有方向相比基准方法(Baseline)结果都有较大幅度的提升,在 Dice 指标上比基准方法高 5.93%,在 ASD 指标上比基准方法减少 1.57,说明本文所提方法的有效性。在 ASD 指标中,本文的结果相较于其他方法都有明显优势。Dice 指标中,在部分泛化方向上相比其他方法有较大提高,在  $B$  方向和  $D$  方向分别比 FedDG<sup>[26]</sup> 提升 2.21% 和 0.75%,在总方向上也接近于当前先进水平。

表 3 本文方法在 Prostate 数据集分割结果的 Dice 指标与其他方法结果的比较

Table 3 Comparison of the proposed method's Dice results on segmentation from Prostate images %

分割任务 (未知领域)	前列腺 MRI 分割 (Dice)						平均
	A	B	C	D	E	F	
Baseline	85.30	87.56	82.33	87.37	80.49	81.40	81.40
JiGen	89.95	85.81	84.06	87.34	81.32	89.11	86.26
BigAug	88.62	86.22	83.76	87.35	85.53	85.83	86.21
SAML	89.66	87.53	84.43	88.67	<b>87.37</b>	88.34	<b>87.67</b>
FedDG	<b>90.19</b>	87.17	<b>85.26</b>	88.23	83.02	<b>90.47</b>	87.39
Ours	87.33	<b>89.38</b>	84.43	<b>88.98</b>	85.28	88.58	87.33

表 4 本文方法在 Prostate 数据集分割结果的 ASD 指标与其他方法结果的比较

Table 4 Comparison of the proposed method's ASD results on segmentation from Prostate images

分割任务 (未知领域)	前列腺 MRI 分割 (ASD, voxel)						平均
	A	B	C	D	E	F	
Baseline	1.22	0.98	4.68	1.51	3.95	4.23	2.76
BigAug	1.70	1.56	2.72	1.98	1.90	1.75	1.93
SAML	1.38	1.46	<b>2.07</b>	1.56	1.77	1.22	1.58
Ours	<b>0.98</b>	<b>0.79</b>	2.75	<b>0.79</b>	<b>1.64</b>	<b>0.77</b>	<b>1.29</b>

由于部分未知领域图像的风格分布与已知领域图像具有随机性、不确定性等特点,因此在少部分领域中无法做好成绩,但是差距在合理的范围内,对综合效果的影响有限且多数领域中均达到了最高的结果。

在图 4 展示了本文模型的预测结果,图中红色为真实标签,绿色和蓝色为模型预测标签。可以看到,在列举的图像中本文方法较好地贴合了真实标签。DeepAll 方法面对分割任务时还会有不同程度的噪声以及不能够很好拟合标签的情况,这些情况在本文方法的训练下得到了极大的改善。

### 3.5 消融实验

为了证明本文网络中提出的每个模块的有效性,针对文中参与网络计算每个模块,进行了一系列的消融实验。

在 Fundus 数据集上,针对重构模块、对抗模块和 Cutmix 模块进行了与本文网络设定相同的测试,结果分别见图 5 和图 6。由图 5、6 可知,取消任意模块,本文网络相比 Baseline 的结果都有一定程度的提

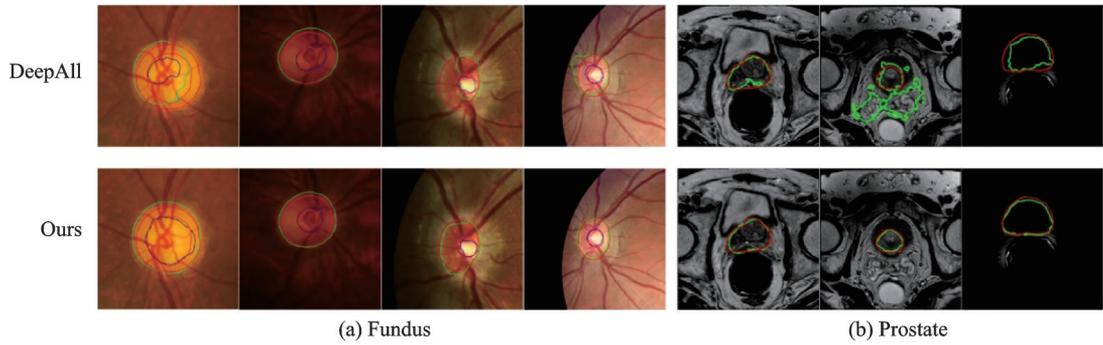


图4 本文方法预测结果

Fig.4 Visual results of the proposed method

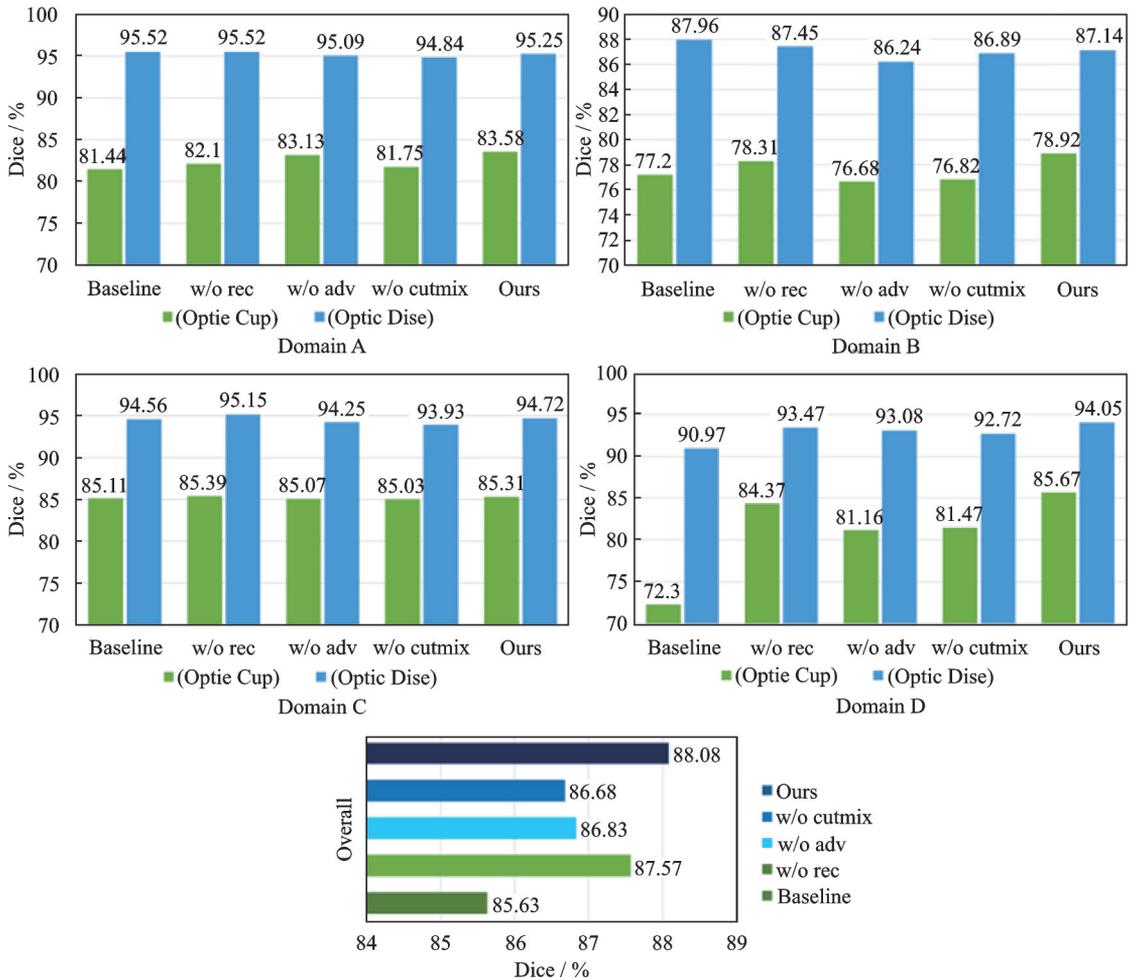


图5 本文方法在Fundus数据集分割结果的Dice指标的消融学习

Fig.5 Ablation study of the proposed method's Dice results on segmentation from Fundus images

升。若取消对抗模块,在Dice上相比本文结果有下降接近1.2%,在ASD上也有近2.5的下降。取消重构模块的下降比取消对抗的下降程度较小,Dice上有0.5%左右的下降达到87.57%,ASD上有0.3的下

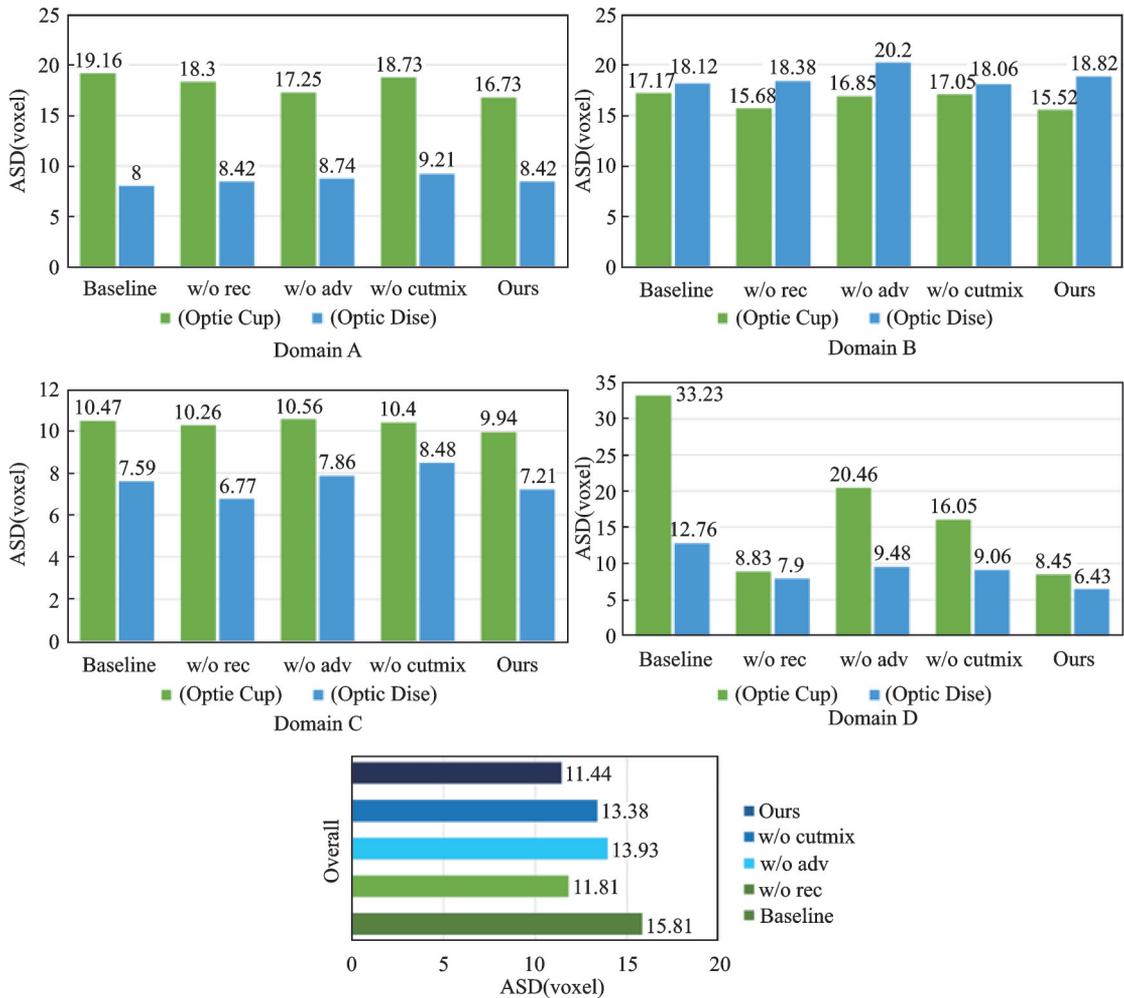


图6 本文方法在Fundus数据集分割结果的ASD指标的消融学习

Fig.6 Ablation study of the proposed method's ASD results on segmentation from Fundus images

降。值得注意的是,如果没有Cutmix的预处理操作,在Dice和ASD上的结果也会下降近2%。

图7展示了消融实验的可视化结果,可见缺少部分模块的结果在预测边缘相比完整的模块都有不同程度的不吻合现象。图中,红色为真实标签,绿色和蓝色为模型预测标签。

#### 4 结束语

本文提出了一种新颖的医学图像分割泛化模型,该模型由分割子网络和若干重构迁移子网络组成。该模型实现了任意两个领域之间的特征对齐和风格转换,同时利用特殊处理的Cutmix丰富了源域语义信息。通过一系列实验和消融实验,证明了本文方法各个模块的有效性,同时也展示出模型相比当前先进模型在两个医学图像分割任务中取得了更加先进的性能。

将来,面对来自不同机构不同设备的不同风格的医学图像,本文方法可以有效避免传统分割模型需要重新训练的弊端。在不需要额外训练的情况下,本文模型能够在风格差异较大的医学图像中取得良好的分割性能,节约了大量时间和计算资源,并且能够适应大量不同风格的图像。

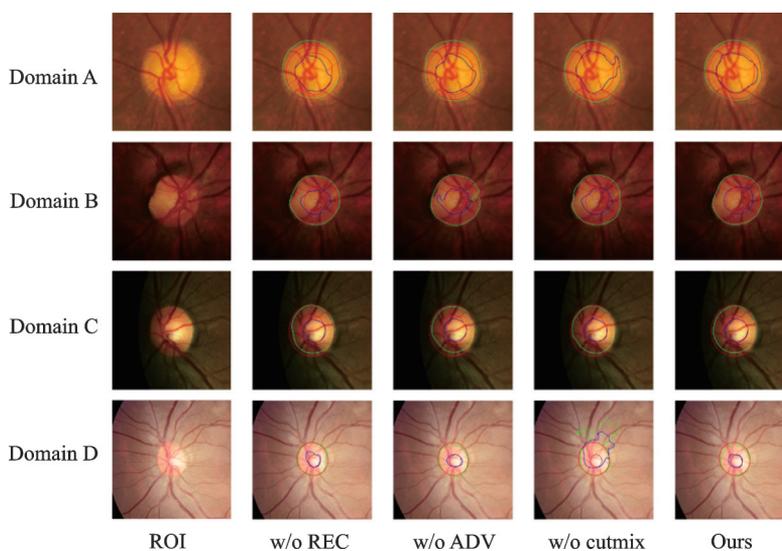


图7 消融实验对比结果

Fig.7 Visual results of ablation study

## 参考文献:

- [1] BEN-DAVID S, BLITZER J, CRAMMER K, et al. Analysis of representations for domain adaptation[C]//Proceedings of the Advances in Neural Information Processing Systems. Vancouver: MIT Press, 2006.
- [2] WEI Guoqiang, LAN Cuiling, ZENG Wenjun, et al. Metaalign: Coordinating domain alignment and classification for unsupervised domain adaptation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 16643-16653.
- [3] MELAS-KYRIAZI L, MANRAI A K. PixMatch: Unsupervised domain adaptation via pixelwise consistency training[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 12435-12445.
- [4] ZHOU Kaiyang, YANG Yongxin, HOSPEDALES T, et al. Deep domain-adversarial image generation for domain generalisation[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2020, 34(7): 13025-13032.
- [5] RAHMAN M M, FOOKES C, BAKTASHMOTLAGH M, et al. Correlation-aware adversarial domain adaptation and generalization[J]. *Pattern Recognition*, 2020, 100: 107124.
- [6] ZHANG Hongyi, CISSE M, DAUPHIN Y N, et al. Mixup: Beyond empirical risk minimization[C]//Proceedings of International Conference on Learning Representations. Vancouver: ICLR, 2018.
- [7] YUN S, HAN D, OH S J, et al. Cutmix: Regularization strategy to train strong classifiers with localizable features[C]//Proceedings of the IEEE Conference on Computer Vision. [S.l.]:IEEE, 2019: 6023-6032.
- [8] WANG Shujun, YU Lequan, LI Kang, et al. Dofe: Domain-oriented feature embedding for generalizable Fundus image segmentation on unseen datasets[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(12): 4237-4248.
- [9] LIU Quande, DOU Qi, HENG P A. Shape-aware meta-learning for generalizing Prostate MRI segmentation to unseen domains[C]//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Lima: Springer, 2020: 475-485.
- [10] WANG Jindong, LAN Cuiling, LIU Chang, et al. Generalizing to unseen domains: A survey on domain generalization[C]//Proceedings of International Joint Conference on Artificial Intelligence Organization. Montreal: Morgan Kaufmann, 2021: 4627-4635.
- [11] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//Proceedings of the International Conference on Machine Learning. Lille: ACM, 2015: 1180-1189.
- [12] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. *The Journal of Machine Learning Research*, 2016, 17(1): 2096-2030.
- [13] LI Haoliang, PAN S J, WANG Shiqi, et al. Domain generalization with adversarial feature learning[C]//Proceedings of the

- IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 5400-5409.
- [14] GONG Rui, LI Wen, CHEN Yuhua, et al. Dlow: Domain flow for adaptation and generalization[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 2477-2486.
- [15] LI Ya, TIAN Xinmei, GONG Mingming, et al. Deep domain generalization via conditional invariant adversarial networks[C]//Proceedings of the European Conference on Computer Vision. Munich: Springer, 2018: 624-639.
- [16] ZHAO Shanshan, GONG Mingming, LIU Tongliang, et al. Domain generalization via entropy regularization[C]//Proceedings of the Advances in Neural Information Processing Systems. Vancouver: MIT Press, 2020: 16096-16107.
- [17] CHOI S, JUNG S, YUN H, et al. Robustnet: Improving domain generalization in urban-scene segmentation via instance selective whitening[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 11580-11590.
- [18] ZHANG Xingxuan, CUI Peng, XU Renzhe, et al. Deep stable learning for out-of-distribution generalization[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 5372-5382.
- [19] SHORTEN C, KHOSHGOFTAAR T M. A survey on image data augmentation for deep learning[J]. Journal of Big Data, 2019, 6(1): 1-48.
- [20] TOBIN J, FONG R, RAY A, et al. Domain randomization for transferring deep neural networks from simulation to the real world[C]//Proceedings of the IEEE International Conference on Intelligent Robots and Systems. Vancouver: IEEE, 2017: 23-30.
- [21] PRAKASHA, BOOCHOON S, BROPHY M, et al. Structured domain randomization: Bridging the reality gap by context-aware synthetic data[C]//Proceedings of the International Conference on Robotics and Automation. Montreal: IEEE, 2019: 7249-7255.
- [22] PAN Li, LI Da, LI Wei, et al. A simple feature augmentation for domain generalization[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 8886-8895.
- [23] XU Qinwei, ZHANG Ruipeng, ZHANG Ya, et al. A Fourier-based framework for domain generalization[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 14383-14392.
- [24] SHU Yang, CAO Zhangjie, WANG Chenyu, et al. Open domain generalization with domain-augmented meta-learning[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 9624-9633.
- [25] HAN Xiaoting, QI Lei, YU Qian, et al. Deep symmetric adaptation network for cross-modality medical image segmentation [J]. IEEE Transactions on Medical Imaging, 2021, 41(1): 121-132.
- [26] LIU Quande, CHEN Cheng, QIN Jing, et al. Feddg: Federated domain generalization on medical image segmentation via episodic learning in continuous frequency space[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Virtual: IEEE, 2021: 1013-1023.
- [27] CARLUCCI F M, D'INNOCENTE A, BUCCI S, et al. Domain generalization by solving jigsaw puzzles[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 2229-2238.
- [28] ZHANG Ling, WANG Xiaosong, YANG Dong, et al. Generalizing deep learning for medical image segmentation to unseen domains via deep stacked transformation[J]. IEEE Transactions on Medical Imaging, 2020, 39(7): 2531-2540.
- [29] ZHANG Ling, WANG Xiaosong, YANG Dong, et al. When unseen domain generalization is unnecessary? Rethinking data augmentation[EB/OL]. (2019-06-07). <https://arxiv.org/abs/1906.03347>.

#### 作者简介:



叶怀泽(2001-),男,研究方向:计算机视觉、领域泛化与医学影像分析,E-mail: huaiz-eye@smail.nju.edu.cn。



周子奇(1997-),男,硕士研究生,研究方向:计算机视觉、领域泛化和医学影像分析。



祁磊(1989-),男,助理研究员,研究方向:领域泛化、领域适应和半监督学习。



史颖欢(1984-),通信作者,男,副教授,博士生导师,研究方向:人工智能和机器学习,E-mail:syh@nju.edu.cn。