

融合金字塔切分注意力模块的视杯视盘分割

刘熠翕, 江旻珊, 张学典

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 视杯和视盘的垂直直径比是青光眼在临床诊断中的重要指标, 为了更加准确地测量杯盘比, 针对视网膜眼底图像中的视盘和视杯分割精度的问题, 提出了一个改进后的端到端的 U 型卷积神经网络框架, 采用 Resnet 34 作为新的编码部分, 并在每一个编码层的末端引入金字塔切分注意力 PSA 模块以提取更多的有效特征信息。同时使用 1×1 卷积代替 3×3 卷积来简化解码结构, 并且使用一个 3×3 卷积与一个通过跳跃连接的 1×1 卷积结构取代跳跃连接。该网络模型在内部数据集上完成训练后, 在 DRISHTI-GS 数据集进行测试, 对视盘和视杯的分割结果在 Dice 和 IOU 上分别表现为 97.61% 和 95.32%, 92.91% 和 86.75%, 证明了该模型具有良好的泛化性。

关键词: 卷积神经网络; 视杯视盘分割; 多尺度特征融合; 注意力机制

中图分类号: TP 18 **文献标志码:** A

An optic cup and disc segmentation network with pyramid split attention module

LIU Yixi, JIANG Minshan, ZHANG Xuedian

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

Abstract: The ratio of the vertical diameter of the optic cup to the optic disc is an important indicator in the clinical diagnosis of glaucoma. To measure the cup-to-disc ratio more accurately, an improved U-shaped convolutional neural network framework was proposed for the problem of segmentation accuracy of the optic disc and optic cup in retinal fundus images. Resnet 34 was used as the new encoder part and a pyramid squeeze attention module at the end of each encoder layer was introduced to extract more valid feature information. A 1×1 convolution was also used instead of 3×3 convolution to simplify the decoding structure, and a 3×3 convolution with a 1×1 convolution structure via a skip connection was used instead of a skip connection. The network model was tested on the DRISHTI-GS dataset after completing training on the in-house dataset, and the segmentation results for the optic disc and optic cup performed 97.61% and 95.32%, 92.91% and 86.75% on the Dice and IOU respectively, demonstrating the good generalization properties of the model.

收稿日期: 2022-11-11

基金项目: 国家自然科学基金资助项目 (61905144)

第一作者: 刘熠翕 (1997-), 女, 硕士研究生。研究方向: 医学图像处理。E-mail: liuyixi0624@163.com

通信作者: 张学典 (1974-), 男, 教授。研究方向: 人工智能、生物医学图像处理。E-mail: xdzhang@usst.edu.cn

Keywords: *CNN; optic cup and disc segmentation; multi-scale feature fusion; attention module*

青光眼是一种慢性眼科疾病，若不能及时对其进行诊断和治疗，可能会造成不可逆的视力损伤甚至是永久性失明^[1]。视盘和视杯之间的垂直直径比值 CDR 是青光眼在临床诊断中的重要指标^[2]。在彩色眼底图像中，视盘一般表现为视网膜的中央黄色部分，视杯是视盘上存在的可变尺寸的明亮中央凹陷。杯盘比的计算需要精确提取视盘和视杯的区域，由于手动分割视盘和视杯是一项耗时的专业工作，因此，各种分割算法被引入。随着深度学习技术的发展，应用卷积神经网络 (convolutional neural network, CNN) 提取图像特征在分割任务上取得了较传统算法更好的效果。全卷积神经网络 (fully convolutional networks, FCN)^[3]是目前很多语义分割方法的基础，在自然图像分割任务上取得了比传统方法更好的分割效果。因此，将深度学习技术引入到医学影像处理中，利用卷积神经网络来进行视杯视盘分割的研究越来越多，并取得了优于传统分割方法的分割结果。M-Net (multi-label deep network)^[4]在 U-Net 基础上增加了多尺度输入，引入了深度监督思想，在中间层添加额外的损失函数并且引入了极坐标转换操作，成功实现了视杯视盘的联合分割；DenseNet^[5]将全卷积网络应用于视杯视盘分割任务；CE-Net (context encoder network)^[6]提出了一个上下文编码模块，由一个多尺度的密集空洞卷积模块和一个残差多路径池化模块构成，可以多尺度捕获具有高水平语义信息的特征，但未用于视杯的分割中；CDED-Net^[7]采用了一种紧密连接的视杯视盘解码器网络结构，在杯盘的联合分割上实现了较好的结果；文献 [8] 提出了一种特征嵌入框架，有效提高了卷积神经网络在完成视杯视盘分割任务时的泛化能力。以上这些方法通过改进结构，强化了网络的信息提取能力，但是对网络中间的多层次特征的利用不够充分。为了解决以上问题，本文进行了一系列研究，并作出以下贡献：a. 基于 U-Net^[9] 设计并实现了一个端到端的深度学习算法来分割彩色眼底图像中的视盘和视杯；b. 使用预训练的 34 层 ResNet^[10] 代替了原 U-Net 中的下采样部分对图像特征进行提取；c. 在特征提取网络 Resnet 34 中融入金字塔切分注意力 PSA (pyramid squeeze attention) 模块^[11]，有效地获取了不同尺度

的感受野，提取了不同尺度的信息；d. 使用一个 3×3 卷积与一个通过跳跃连接的 1×1 卷积代替原连接结构^[12]；e. 使用 DiceLoss 损失函数代替交叉熵损失函数，有效地提升了分割精度；f. 在 Drishti-GS 数据集^[13]上验证了改进网络的性能，对视盘和视杯的分割结果在 Dice 和 IOU 上分别表现为 97.61% 和 95.32%，92.91% 和 86.75%。

1 方 法

1.1 网络模型

在改进后的 U 型网络中，整体采用了端到端的编码器-解码器结构，具体网络结构如图 1 所示。对于编码器结构，使用了预训练的 ResNet 34 来提取具有高水平语义的图像特征。从第一个 7×7 卷积层和最大池化层出发，依次经过个数为 3, 4, 6, 3 的残差块。其中，残差块由两个 3×3 卷积、批标准化层^[14]和 ReLU 激活函数组成。特别的是，在每个编码层即残差块的末端引入金字塔切分注意力 PSA 模块以获取不同尺度信息。在编码器提取了具有高水平语义信息的图像特征后，解码器则采用步长为 2 的 2×2 转置卷积来实现上采样。转置卷积不仅能使图像恢复到初始时的尺寸，还能拥有可训练的卷积核参数。解码结构与编码结构对称，采用多个模块对特征进行逐级还原，其中，每个解码层由一个 1×1 卷积、批标准化层和 ReLU 激活函数组成。1×1 卷积可以在降低网络训练参数的同时调整输入、输出特征通道数，有助于与解码器中通道数相同的特征图进行拼接，同时也可以使网络进一步融合特征通道之间的信息。除此之外，本文还对编码层和解码层的连接方式作了改进，将原 U-Net 网络中的跳跃连接使用一个 3×3 卷积层伴随一个通过跳跃连接的 1×1 的卷积层代替，结构如图 2 所示。改进后的连接方式能够让下采样部分的特征信息更加充分地融合至上采样部分，使得网络获得多种维度的图像特征信息，帮助提高网络的分割效果。

1.2 金字塔切分注意力模块

注意力机制在图像处理领域广受关注，大多数注意力机制只引入了通道注意力，却忽略了空间信息，或者只考虑了局部区域的信息，而金字




图 1 改进后的 U 型网络结构图

Fig.1 Improved U-shaped network structure




图 2 改进后的连接

Fig. 2 Improved connection

塔切分注意力 PSA (pyramid split attention) 模块可以高效地提取更细颗粒度的多尺度空间信息,同时建立更远距离的通道依赖关系,在神经网络中嵌入该模块后可在减小计算量的同时有效提高网络性能。

1.2.1 SE Weight 模块

通道注意力机制允许网络有选择性地权衡每个通道的重要性,从而输出更多的有效特征信息。对网络输入特征映射为 X , $X \in \mathbb{R}^{C \times H \times W}$, C , H 和 W 分别表示特征图像的通道数、高度和宽度。SE (squeeze and excitation) 模块主要由挤压和激励两部分组成,结构如图 3 所示。首先通过使用全局池化操作来聚合全局上下文信息,第 c 个通道的为输入 x , 全局池化计算公式为

$$g_c = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W X_c(i,j) \tag{1}$$

输入特征在经过全局池化层后,随后经过全连接层、ReLU 激活函数层、全连接层及 Sigmoid

函数层,则第 c 个通道的注意力权重可表示为

$$w_c = \sigma(W_1 \delta(W_0(g_c))) \tag{2}$$

式中: δ 表示 ReLU 激活函数; σ 表示激励函数 Sigmoid; W_0 和 W_1 代表两个全连接层, $W_0 \in \mathbb{R}^{C \times \frac{C}{r}}$, $W_1 \in \mathbb{R}^{\frac{C}{r} \times C}$ 。两个全连接层可更有效地组合通道之间的线性信息,有利于通道中的高维度信息和低维度信息之间进行相互作用。再通过使用激励函数为每个通道重新分配权重,从而更有效地提取信息。

1.2.2 SPC 模块

在金字塔切分注意力模块中主要通过 SPC (squeeze and concat) 模块实现多尺度特征提取,即采用多分支的方法提取输入特征图的空间信息,其结构如图 4 所示。每个分支将独立学习多尺度空间信息,以局部方式建立跨通道交互,通过这样做,可以获得更丰富的输入向量的空间信息,并在多个尺度上并行处理它。相应地,采用金字塔结构的多尺度卷积可以提取不同维度的空间信息,同时通过压缩输入向量的通道维数,可以有效地提取每个通道特征图上不同尺度的空间信息。假设输入为 X , SPC 模块首先将输入切分为 S 个部分,分别为 $[X_0, X_1, \dots, X_{S-1}]$, 且每个部分的通道数都为 $C' = \frac{C}{S}$ 。随着内核尺寸的增加,为了在




图 3 SE Weight 模块结构

Fig.3 SE Weight structure




图 4 SPC 模块结构

Fig.4 SPC module structure

不增加计算成本的情况下处理不同核尺度下的输入向量，SPC 引入了一种分组卷积方法，可在不增加参数数量的情况下选择群组的大小，群组 G 和卷积核 K 的大小满足下式：

$$G = 2^{\frac{K-1}{2}} \quad (3)$$

综上所述，多尺度特征核图的生成函数可表示为

$$F_i = \text{Conv}(k_i \times k_i, G_i)(X), \quad i = 0, 1, 2, \dots, S-1 \quad (4)$$

式中，第 i 个卷积核尺寸 $k_i = 2 \times (i+1) + 1$ ，第 i 个分组大小为 $G_i = 2^{\frac{k_i-1}{2}}$ ， $F_i \in \mathbb{R}^{C' \times H \times W}$ 。

最后可以得到完整的融合后的多尺度特征图为

$$F = \text{Cat}([F_0, F_1, \dots, F_{S-1}]) \quad (5)$$

1.2.3 PSA 模块

PSA (pyramid squeeze attention) 模块主要通过 4 个步骤实现：a. 利用 SPC 模块来对通道进行切分，然后针对每个通道特征图上的空间信息进行多尺度特征提取；b. 利用 SE Weight 模块提取不同

尺度特征图的通道注意力，得到每个不同尺度上的通道注意力向量；c. 通过使用 Softmax 重新校准通道方向的注意力向量，获得新的多尺度通道交互之后的注意力权重；d. 对重新校准的权重和相应的特征图按元素进行点乘操作，从而获得多尺度且特征信息更丰富的细颗粒度特征图作为输出，详细结构如图 5 所示。

1.3 损失函数

因本文的工作是对视杯视盘进行分割，DiceLoss 可以有效地解决图像不均衡的问题，因此，本文使用 DiceLoss 函数代替传统的交叉熵损失函数，即

$$L_{\text{Dice}} = 1 - \frac{\sum_{k=1}^K \frac{2w_k \sum_{i=1}^N p(k,i)g(k,i)}{\sum_{i=1}^N p(k,i) + \sum_{i=1}^N g(k,i)}}{\quad} \quad (6)$$

式中： N 表示像素点个数； k 表示种类个数，在本文中， k 值设置为 2； $p(k,i) \in [0, 1]$ ，表示像素点预测




图 5 PSA 模块结构

Fig.5 PSA module structure

为种类的概率; $g_{(k,i)} \in \{0,1\}$, 表示像素点*i*属于种类*k*的标签值。

2 实验设置

2.1 数据集

本次研究中, 采用上海市第一人民医院的一个内部数据集进行网络训练, 一个公共数据集即 DRISHTI-GS 数据集用作测试网络性能。该数据集包含 200 对彩色视网膜眼底图像, 分辨率为 2124×2056, 由 4 名专业眼科医生对该数据集的视杯和视盘进行手动标注, 同时对参与者是否患有青光眼进行标记。对于 OD 和 OC 的标注, 要求眼科医生在没有获得参与者患病信息的前提下独立完成。DRISHTI-GS 数据集由 101 幅彩色眼底图像组成, 分辨率为 2896×1944, 其中 30 幅为正常眼, 71 幅为青光眼, 且官方已对训练集和测试集进行划分, 包括 50 幅训练图像和 51 幅测试图像。

2.2 环境设置

整个框架基于 Python 中的 Tensorflow 和 Keras 实现, 使用的操作系统为 Ubuntu 18.04 Linux, 实验采用的 GPU 为 NVIDIA GeForce RTX 2080Ti。对于 OD 和 OC 分割, 使用内部数据集中的部分作为训练集, 用于拟合和优化模型参数, 随后在 DRISHTI-GS 数据集上进行测试用于评估网络的性能。在训练过程中, 采用了随机梯度下降(SGD)和反向传播来优化深度模型, 同时还设置了学习速率更新策略和提前停止机制。学习率从 0.001 开始逐渐下降, 当损失在 10 轮训练后不下降, 网络学习速率减为一半; 当损失在 30 轮训练后不下降, 网络会终止学习并保存参数。学习速率更新策略可以使网络更加精准地找到最优点, 提前停止机制可以防止网络参数过拟合导致测试性能下降。训练过程中, 将训练批次大小设置为 2, 最大训练轮次为 100。

2.3 图像预处理

数据预处理包括 3 个主要步骤: a. 对图像进行预处理, 将其尺寸调整为 512×512, 并在图像边界、缺乏对比度的情况下手动消除任何会对实验结果产生影响的危险; b. 针对对比度弱的彩色眼底图像, 使用限制对比度自适应直方图均衡技术, 将每个图像切割成 8×8 的 64 块, 并且对每一块使用直方图均衡化处理; c. 由于数据集数量有限, 以防出现过拟合、数据不平衡的情况, 对原

始数据集进行了数据增强。通过使用图像生成器每次将图像旋转 20°, 改变图像的高度和宽度, 并以随机的水平和垂直翻转方式翻转图像, 将原始训练集由 50 张增加到 1550 张。此外, 数据增强还可以减少模型的结构风险, 提高鲁棒性。d. 将训练集中的彩色眼底照片和标签融合至同一张图片, 如图 6 所示, 确保彩色眼底照片与标签一一对应。




图 6 预处理中图像与标签的融合
Fig.6 Pre-process image, label and their fusion

2.4 评价指标

为了评估本文中网络模型对视盘和视杯的分割性能, 本研究选择使用 Dice 系数和 IOU 这两个参数作为评价指标。Dice 系数描述了两个样本的相似度, 用 s_{Dice} 表示, IOU 值描述了两个样本交集与并集的重叠率, 用 I_{IOU} 表示, 即

$$s_{Dice}(A,B)=\frac{2|A\cap B|}{|A|+|B|} \tag{7}$$

$$I_{IOU}(A,B)=\frac{|A\cap B|}{|A\cup B|} \tag{8}$$

式中: *A* 表示真值; *B* 表示预测值。

Dice 系数的值在 0~1 之间, 越接近于 1, 表示分割结果越好。IOU 值也在 0~1 之间, IOU 值越大, 表示预测为视盘或视杯的区域与真值重叠越多, 分割结果也越好。

3 实验结果与分析

3.1 网络训练结果

首先使用内部数据集对网络进行训练, 图 7 为训练集中使用的彩色眼底图像及标签图。图 8 和图 9 分别为视盘和视杯分割网络训练的损失曲线、IOU 曲线、Dice 曲线和准确率曲线。从图中可以明显看出, 网络在训练前期曲线收敛速度较



图 7 训练集所用的彩色眼底图及标签图
Fig. 7 Color fundus image and label in training dataset




图 8 视盘分割网络训练过程中的各项参数曲线图

Fig.8 Log-loss graph, IOU graph, Dice graph and accuracy graph in disc segmentation net training




图 9 视杯分割网络训练过程中的各项参数曲线图

Fig.9 Log-loss graph, IOU graph, Dice graph and accuracy graph in cup segmentation net training

快, 从一定程度上说明了网络的学习能力较强。随着训练轮次的升高, 模型曲线斜率逐渐减小, 当训练轮次达到 20 次后, 网络训练的各项曲线开始趋于平稳, 仅呈现微小的波动。

3.2 网络测试结果

在内部数据集上对网络完成训练后, 使用 Drishti-GS 数据集对网络性能进行测试, 来证明本文提出的网络对视杯视盘分割的有效性。从图 10 可以看到, 在 Drishti-GS 数据集上验证时, 对于单张眼底图像视盘分割的最高 Dice 系数可达 98.74%, IOU 值可达 96.98%, 视杯分割的最高 Dice

系数可达 95.27%, IOU 值可达 90.97%; 从图 11 可以看到, 对于单张眼底图像视杯分割的最低 Dice 系数为 79.36%, IOU 值为 65.78%, 视杯分割的最低 Dice 系数为 68.13%, IOU 值为 51.67%。整体而言: 针对视盘分割, Dice 系数和 IOU 值可分别达到 97.61% 和 95.32%; 而对视杯分割, Dice 系数和 IOU 值可分别达到 92.91% 和 86.75%。

为了进一步评估本文所提出的网络分割性能, 将在 Drishti-GS 数据集上的分割结果与 U-Net, Deeplabv3+^[15], M-Net, CE-Net, Ensemble CNN^[16] 和 Robust^[17] 等方法的结果进行对比, 对比




图 10 DRISHTI-GS 数据集上对视盘和视杯进行分割的最佳表现

Fig.10 Best performance of disc and cup segmentation on DRISHTI-GS dataset




图 11 DRISHTI-GS 数据集上对视盘和视杯进行分割的最差表现

Fig.11 Worst performance of disc and cup segmentation on DRISHTI-GS dataset

数据如表 1 所示，可以看到本研究网络在指标上均有所提升。例如，与现有的先进模型 M-Net 相比，本文方法在视盘分割任务上将 Dice 系数和 IOU 值分别从 96.78% 和 93.86% 提高到 97.61% 和 95.32%，实现了 0.83% 和 1.46% 的提升；而在视杯的分割结果上，本文方法将 Dice 系数和 IOU 值分别从 CE-Net 能够实现的 91.57% 和 84.45% 提高到 92.91% 和 86.75%，实现了 1.34% 和 2.30% 的提升；而在与 U-shaped CNN 的结果对比中，尽管该网络对视盘分割的 Dice 值较本文网络模型要高出 0.19%，但本文网络在视杯分割任务中实现了更好的效果，Dice 系数和 IOU 值要高出 3.71% 和 4.45%。

表 1 不同方法在 DRISHTI-GS 数据集上的实验结果

Tab.1 Experimental results of different methods on DRISHTI-GS dataset

方法	OD		OC	
	Dice系数	IOU值	Dice系数	IOU值
U-Net	0.9660	0.9342	0.8611	0.7560
Deeplabv3+	0.9638	0.9301	0.8558	0.7479
M-Net	0.9678	0.9386	0.8618	0.7730
CE-Net	0.9759	0.9530	0.9157	0.8445
Ensemble CNN	0.9730	0.9140	0.8710	0.8500
Robust	0.9738	0.9492	0.8877	0.8042
U-shaped CNN ^[18]	0.9780	0.9490	0.8920	0.8230
CDED-Net	0.9597	0.9183	0.9240	0.8632
本文	0.9761	0.9532	0.9291	0.8675

为了更为直观地展现本文提出网络的性能，将本文实验结果与 U-Net，M-Net，CE-Net 对视盘和视杯的分割结果进行可视化对比，如图 12 和图 13 所示。图片列从左到右分别为 Drishti-GS 数据集原图、标签图像、U-net 分割结果、M-Net 分割结果、CE-net 分割结果以及本文结果。通过对比发现，当原始图像对比度较清晰时，本文网络能够精准地识别视盘视杯的边界，分割精度相对较高；而当真值边缘较不规则图像亮度较低时，本文网络相比于其他方法能够更加有效地拟合出真值的形状，在分割结果中更好地展现图像细节。




图 12 不同方法在视盘分割任务上的结果对比

Fig.12 Comparisons of different methods in disc segmentation

3.3 更改训练图像尺寸的结果

本文研究主要使用 DRISHTI-GS 数据集作为测试集，该数据集图像的分辨率为 2896×1944。为了研究输入不同尺寸图像进行训练对网络性能的




图 13 不同方法在视杯分割任务上的结果对比

Fig. 13 Comparisons of different methods in cup segmentation

影响，本文将 DRISHTI-GS 数据集中图像的大小分别调整为 128×128、256×256 和 1024×1024 后作为新的训练集对网络重新进行训练。实验结果如表 2 所示，在输入图像信息和特征不变的情况下，分割性能随着输入图像分辨率的增加而提高，由此导致网络的训练时间大幅增加。当使用 128×128 尺寸的图像训练网络时，训练批次大小可设置为 6，而在 512×512 的尺寸下，仅能设置批量大小为 2。这说明随着图像分辨率的增大，网络的负荷也随之增大。当图像分辨率为 1024×1024 时，其分割结果与图像分辨率为 512×512 时基本相同。综合考虑训练时间与计算成本，在网络能够处理的限度内，需要选择合适的分辨率和分割精度来训练模型，因此选择 512×512 图像分辨率。

表 2 不同分辨率的分割结果

Tab.2 Segmentation results with different resolutions								
指标	128×128		256×256		512×512		1024×1024	
	OC	OD	OC	OD	OC	OD	OC	OD
Dice系数	0.90	0.92	0.92	0.95	0.93	0.98	0.93	0.98
IOU值	0.84	0.90	0.86	0.93	0.88	0.97	0.89	0.97
损失	0.17	0.11	0.15	0.06	0.13	0.03	0.15	0.03

4 结 论

提出了一种改进后的 U 型网络用于视盘视杯的分割。该网络采用 Resnet 34 作为编码部分，并在每一个编码层的末端引入金字塔切分注意力模块，同时使用 1×1 卷积简化解码结构，最后用残差连接代替跳跃连接。通过与当下主流的先进算

法在 Drishti-GS1 数据集上的验证结果进行对比，证明了本文方法在视盘和视杯分割中的有效性，为临床诊断青光眼提供了一种可行的方法。在未来的工作中，将进一步融合更多患者图像，以期实现更精确的病灶分割，从而更好地辅助青光眼筛查。

参考文献：

[1] THAM Y C, LI X, WONG T Y, et al. Global prevalence of glaucoma and projections of glaucoma burden through 2040: a systematic review and meta-analysis[J]. *Ophthalmology*, 2014, 121(11): 2081–2090.

[2] ALMAZROA A, BURMAN R, RAAHEMIFAR K, et al. Optic disc and optic cup segmentation methodologies for glaucoma image detection: a survey[J]. *Journal of Ophthalmology*, 2015, 2015: 180972.

[3] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]//*Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015: 3431–3440.

[4] FU H Z, CHENG J, XU Y W, et al. Joint optic disc and cup segmentation based on multi-label deep network and polar transformation[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(7): 1597–1605.

[5] AL-BANDER B, WILLIAMS B M, AL-NUAIMY W, et al. Dense fully convolutional segmentation of the optic disc and cup in colour fundus for glaucoma diagnosis[J]. *Symmetry*, 2018, 10(4): 87.

[6] GU Z W, CHENG J, FU H Z, et al. CE-Net: context encoder network for 2D medical image segmentation[J]. *IEEE Transactions on Medical Imaging*, 2019, 38(10): 2281–2292.

[7] TABASSUM M, KHAN T M, ARSALAN M, et al. CDED-Net: joint segmentation of optic disc and optic cup for glaucoma screening[J]. *IEEE Access*, 2020, 8: 102733–102747.

[8] WANG S J, YU L Q, LI K, 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] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[C]//*Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention*. Munich: Springer, 2015: 234–241.

- nanostructures: nanolithography for nanoarrays[J]. *Journal of Physics D: Applied Physics*, 2009, 42(12): 123001.
- [10] 李艳丽, 刘显和, 伍强. 先进光刻技术的发展历程与最新进展 [J]. *激光与光电子学进展*, 2022, 59(9): 0922006.
- [11] CAI J X, ZHU Z Y, ALKEMADE P, et al. 3D volumetric energy deposition of focused helium ion beam lithography: visualization, modeling, and applications in nanofabrication [J]. *Advanced Materials Interfaces*, 2018, 5(12): 1800203.
- [12] GUO L J. Nanoimprint lithography: methods and material requirements[J]. *Advanced Materials*, 2007, 19(4): 495–513.
- [13] GUERFI Y, CARCENAC F, LARRIEU G. High resolution HSQ nanopillar arrays with low energy electron beam lithography[J]. *Microelectronic Engineering*, 2013, 110: 173–176.
- [14] VAN WOLFEREN H, ABELMANN L. Laser interference lithography[M]//HENNESSY T C. *Lithography: Principles, Processes and Materials*. New York: Nova Science Publishers, Inc., 2011: 133–148.
- [15] YUE G, LEI Y, DIE J H, et al. Fabrication of 4-inch nano patterned wafer with high uniformity by laser interference lithography[J]. *Chinese Physics Letters*, 2018, 35(5): 054207.
- [16] KIM H, JUNG H, LEE D H, et al. Period-chirped gratings fabricated by laser interference lithography with a concave Lloyd's mirror[J]. *Applied Optics*, 2016, 55(2): 354–359.
- [17] 吴庭溪, 王强. 多次光刻晶圆涂胶工艺的实验研究 [J]. *大学物理实验*, 2018, 31(5): 31–35.
- [18] GAN Z F, FENG H T, CHEN L Y, et al. Spatial modulation of nanopattern dimensions by combining interference lithography and grayscale-patterned secondary exposure[J]. *Light: Science & Applications*, 2022, 11(1): 89.
- [19] 张笛, 王英, 瞿敏妮, 等. SU-8 光刻胶去胶工艺研究 [J]. *微电子学*, 2020, 50(6): 910–913.

(编辑: 石 瑛)



[上接第 539 页]

- [10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770–778.
- [11] ZHANG H, ZU K K, LU J, et al. EPSANet: an efficient pyramid squeeze attention block on convolutional neural network[EB/OL].(2021-05-30)[2022-11-11].<https://doi.org/10.48550/arXiv.2105.14447>.
- [12] 茅前, 江旻珊, 魏静. 基于改进 U-Net 的视盘视杯分割方法的研究 [J]. *光学仪器*, 2021, 43(1): 21–27.
- [13] SIVASWAMY J, KRISHNADAS S, CHAKRAVARTY A, et al. A comprehensive retinal image dataset for the assessment of glaucoma from the optic nerve head analysis[J]. *JSM Biomedical Imaging Data Papers*, 2015, 2(1): 1004.
- [14] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on Machine Learning. Lille: JMLR. org, 2015: 448–456.
- [15] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018: 833–851.
- [16] ZILLY J, BUHMANN J M, MAHAPATRA D. Glaucoma detection using entropy sampling and ensemble learning for automatic optic cup and disc segmentation[J]. *Computerized Medical Imaging and Graphics*, 2017, 55: 28–41.
- [17] YU S, XIAO D, FROST S, et al. Robust optic disc and cup segmentation with deep learning for glaucoma detection[J]. *Computerized Medical Imaging and Graphics*, 2019, 74: 61–71.
- [18] XU Y L, LU S, LI H X, et al. Mixed maximum loss design for optic disc and optic cup segmentation with deep learning from imbalanced samples[J]. *Sensors*, 2019, 19(20): 4401.

(编辑: 丁红艺)