

GTCG-Net: 一种基于门控 Transformer 的 CycleGAN 视网膜图像增强方法

熊冰清, 余元辉

(集美大学计算机工程学院, 福建 厦门 361021)

[摘要] 提出一个基于门控 Transformer 的 CycleGAN 视网膜图像增强方法 (GTCG-Net)。通过使用生成对抗网络和循环一致性损失来实现视网膜图像的自动增强, 从而改善图像质量和病变部分的可视化效果。并利用门控 MLP 提取更有用的特征, 将生成器设计为类 U-Net 结构, 使用跳跃连接进行特征融合, 以得到丰富的局部特征和细节信息。实验结果显示与其他视网膜图像增强方法 GFE-Net、SCRNET、I-SECRET 等相比, GTCG-Net 不仅可以有效的去除伪影、恢复眼底结构和病理特征, 同时在多个数据集上表现出了较好的泛化能力。

[关键词] CycleGAN; Transformer; 门控 MLP; 跳跃连接; 视网膜图像增强

[中图分类号] TN 911.73

GTCG-Net: an Improved CycleGAN Retinal Image Enhancement Method Based on Gated Transformer

XIONG Bingqing, YU Yuanhui

(College of Computer Engineering, Jimei University, Xiamen 361021, China)

Abstract: A retinal image enhancement method based on CycleGAN with Gated Transformer (GTCG-Net) is proposed. Automatic retinal image enhancement is achieved by using Generative Adversarial Networks and Cyclic Consistency Loss to improve the image quality and visualization of the lesion section. And more useful features are extracted using gated MLP, and the generator is designed as a U-Net-like structure using skip connections for feature fusion to obtain rich local features and detail information. The experimental results show that compared with other retinal image enhancement algorithms GFE-Net, SCRNET, I-SECRET, etc., GTCG-Net not only effectively removes artifacts and restores fundus structure and pathological features, but also shows better generalization ability on multiple datasets.

Keywords: CycleGAN; Transformer; Gated MLP; skip connections; retinal image enhancement

0 引言

随着计算机视觉和医学影像处理的发展, 视网膜图像在视网膜病变检测、眼底结构分析、疾病预

[收稿日期] 2024-04-06

[基金项目] 厦门市科技补助项目 (2022CX0301)

[通信作者] 余元辉 (1973—), 教授, 硕导, 从事智能信息处理、移动安全技术、数字图像处理等研究。
E-mail: aiaa0212@163.com

测、诊断和治疗等方面应用广泛。例如，基于深度学习的 AI 系统分析眼底图像以辅助诊断糖尿病、青光眼、黄斑变性等疾病^[1-4]。然而，由于各种因素的影响，原始视网膜图像可能存在质量不佳、细节模糊等问题，影响眼科医生的诊断准确性。因此，研究和开发有效的视网膜图像增强方法具有重要的临床意义。

在医学图像领域，获取大规模的配对数据非常困难，无监督学习凭借其自主学习优势成为视网膜图像增强任务中的主流方法。例如，基于 CycleGAN^[5]，You 等^[6]提出了一种名为 Cycle-CBAM 的视网膜图像增强方法，它采用卷积注意力模块（CBAM）^[7]解决结构信息退化的问题。然而，由于卷积感受野受限，模型难以充分捕捉到全局上下文信息。基于这个问题，Ma 等^[8]提出了一种名为 StillGAN 的基于结构和光照约束的 CycleGAN 图像增强方法，StillGAN 引入局部结构和照明约束，用于学习整体特征和局部细节。而 T-CycleGAN 是一种由 Transformer 和 CNN 结合的 CycleGAN 模型^[9]。受对比学习非配对转换（CUTGAN）^[10]的启发，Cheng 等^[11]提出了一种名为重要性引导的半监督对比约束（I-SECRET）的眼底图像增强方法。然而，对比学习保留正对之间的共享信息，这可能会导致眼底图像中病理特征的丢失。

以上方法虽然取得了一定进展，但仍面临着以下两大挑战：1）缺乏监督信号可能导致伪影或错误细节；2）增强图像存在对比度不足或病变区域缺失。为此，本文提出基于门控 Transformer^[12]的 CycleGAN 视网膜图像增强方法（GTCCG-Net）。本方法拟通过门控机制^[13]和使用跳跃连接^[14-15]的多特征融合策略，实现视网膜结构恢复和整体对比度提升的动态平衡。

1 GTCCG-Net

本文的主要目标是提升低质量视网膜图像增强方法在精细眼底结构和病理特征恢复中的准确性。如图 1 所示，模型是基于门控 Transformer 搭建的 CycleGAN^[9]网络，并在生成器中使用跳跃连接。它由两个生成器 G_e 、 G_d ，两个判别器 D_e 、 D_d 组成。其中： G_e 表示增强图像生成器， G_d 表示退化图像生成器； D_e 表示高质量图像判别器， D_d 表示低质量图像判别器。

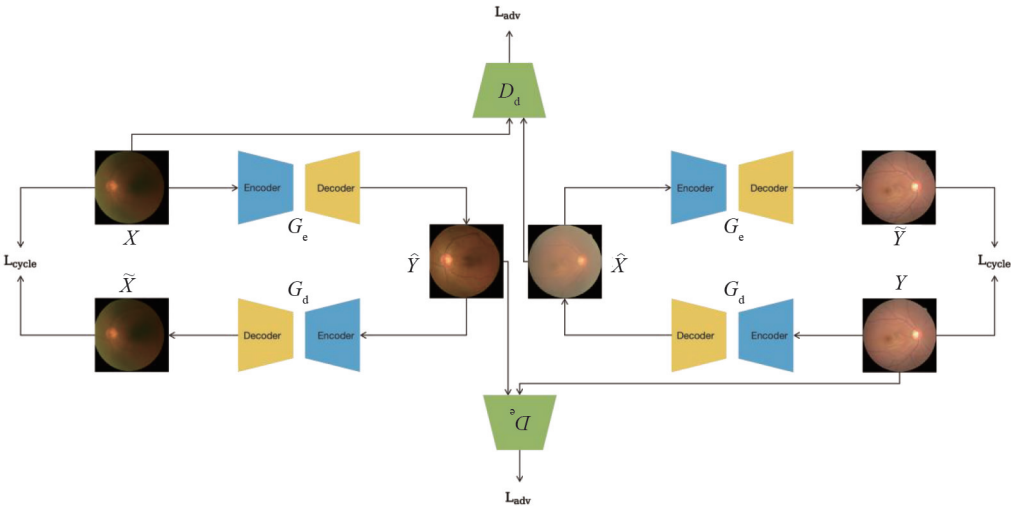


图 1 GTCCG-Net 的整体框架图
Fig.1 The overall framework of GTCCG-Net

1.1 生成器

如图 1 所示，两次循环中生成器工作的流程是：1）真实低质量图像 X 通过 G_e 生成增强图像 \hat{Y} ， \hat{Y} 再通过 G_d 得到退化图像 \tilde{X} ；2）真实高质量图像 Y 通过 G_d 生成低质量图像 \hat{X} ， \hat{X} 再通过 G_e 得到增

强图像 \tilde{Y} 。可表示为: $G_e(X) = \hat{Y}, G_d(\hat{Y}) = \tilde{X}, G_e(Y) = \hat{X}, G_d(\hat{X}) = \tilde{Y}$ 。其中: \hat{X}, \hat{Y} 是 Y, X 生成的图像; \tilde{X}, \tilde{Y} 是 \hat{X}, \hat{Y} 再生成的图像。

生成器的神经网络是在门控 Transformer (G-Transformer) 的基础上搭建起来的, 是一种形如编码器-解码器的结构。如图 2a 所示, 编码器由四个部分组成, 每个部分包含一个下采样层 (downsampling layer) 和一个 G-Transformer 层, 每经过一个部分都会得到一个新的特征图, 即 F_0, F_1, F_2, F_3 。解码器的构造与编码器类似, 由四个部分组成, 每个部分包含一个上采样层 (upsampling layer) 和一个 G-Transformer 层, F_3 输送后依次经过每一个部分得到特征图 F'_2, F'_1, F'_0, F_4 。

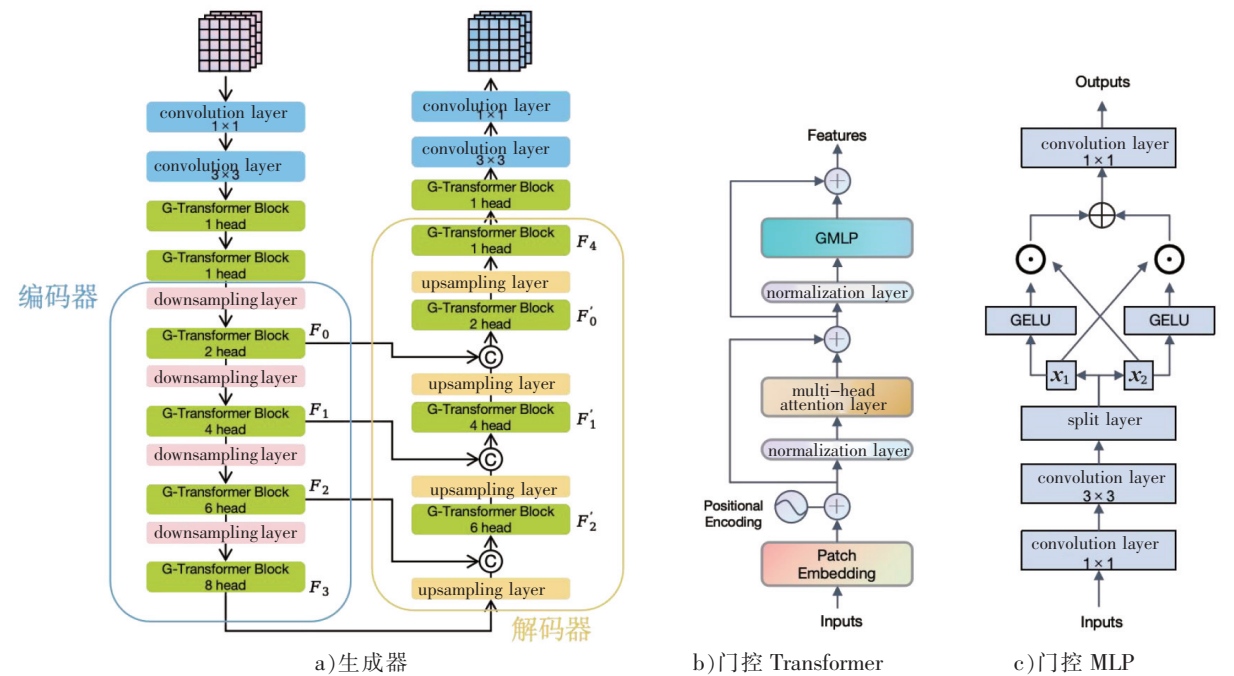


图 2 生成器结构图
Fig.2 Structure of the generator

1.1.1 G-Transformer

如图 2b 所示, G-Transformer 由两个归一化层 (normalization layer)、一个多头注意力层 (multi-head attention layer) 和一个门控 MLP 构成。假设输入是 x , 输出是 y , 则该过程可表述为:

$$x' = x + \text{Attention}(\text{Norm}(x)), y = x' + \text{GMLP}(\text{Norm}(x')). \tag{1}$$

其中: Norm 表示归一化; Attention 表示注意力; GMLP 表示门控 MLP。

为获得更丰富的表征能力, 线性 MLP 通常由两个线性层和一个激活函数层组成, 但它对重要信息的捕捉能力有限。因此, 设计了一个门控 MLP, 帮助模型关注更有价值的特征信息, 防止信息冗余。如图 2c 所示, 首先, 给定输入 x , 依次通过卷积核为 1×1 、 3×3 的卷积层 (convolution layer), 以丰富局部特征表达。接着, 通过分割层 (split layer) 将卷积层输出在通道维度上分为两个大小一样的张量 x_1, x_2 。然后, 使用激活函数 GELU 分别对 x_1, x_2 进行非线性变换, x_1 的变换结果再与 x_2 进行矩阵点乘, x_2 的变换结果也与 x_1 进行矩阵点乘。最后, 叠加两个点乘结果并通过卷积核为 1×1 的卷积层得到特征图 y 。数学公式表示为:

$$[x_1, x_2] = S(W_{3 \times 3} W_{1 \times 1} x), y = W_{1 \times 1}(G(x_1) \cdot x_2 + G(x_2) \cdot x_1).$$

其中: $W_{3 \times 3}, W_{1 \times 1}$ 分别表示 $3 \times 3, 1 \times 1$ 卷积; S 表示分割; G 表示 GELU 激励; \cdot 表示矩阵点乘。

1.1.2 跳跃连接

在生成器的编码器和解码器之间使用跳跃连接, 编码器逐步减小图像分辨率, 也逐渐增大感受野,

有利于模型捕捉上下文信息和全局语义。解码器将编码器输出的特征图逐步恢复到原始输入的分辨率,有利于获取更细节的特征。将编码器中的特征图与解码器中的对应特征图进行融合,这样的跳跃连接将低级特征与高级特征相结合,允许信息在不同层级之间进行直接传递,不仅保留了丰富的空间细节和上下文信息,还有助于更好地恢复边界和细节。在图 2a 中可看到,编码器中的特征图 F_0 、 F_1 、 F_2 分别与解码器中上采样后的特征连接,经过 G-Transformer 后,得到特征图 F'_0 、 F'_1 、 F'_2 。

1.2 判别器

判别器是基于 CNN 的分类器。当输入是真实图像时,输出概率接近于 1;当输入是生成图像时,输出概率接近于 0。它由卷积层、ReLU 激励层和归一化层组成。首先,将大小为 $256 \text{ px} \times 256 \text{ px}$ 的视网膜图像输入卷积核大小为 4×4 的卷积层。然后,使用 ReLU 激活函数。接着,将结果发送到三个连续的降采样块,降采样块包含:核大小为 4×4 的卷积层、归一化层和 ReLU 激励层。最后,结果被送入最后的卷积层,最终得到了一个 30×30 的补丁,并使用 sigmoid 激活函数进行预测。

1.3 损失函数

通过构建损失函数来优化模型参数,包括对抗性损失、循环一致性损失和身份损失。可表示为: $L = L_{\text{adv}} + \lambda_1 L_{\text{cycle}} + \lambda_2 L_{\text{id}}$ 。其中: λ_1 、 λ_2 分别是 L_{cycle} 、 L_{id} 的权重系数。

对抗性损失为: $L_{\text{adv}} = L_{G_e-\text{adv}} + L_{G_d-\text{adv}} + L_{D_e-\text{adv}} + L_{D_d-\text{adv}}$ 。即有

$$L_{G_e-\text{adv}} + L_{G_d-\text{adv}} = D_d(\hat{X}) - 1)^2 + (D_d(\hat{X}) - 1)^2, \quad (2)$$

$$L_{D_e-\text{adv}} + L_{D_d-\text{adv}} = (D_e(\hat{Y}) - 1)^2 + (D_e(Y) - 1)^2 + (D_d(\hat{X}) - 1)^2 + (D_d(X) - 1)^2. \quad (3)$$

其中:式 (2) 表示两个生成器的对抗损失和;式 (3) 表示两个判别器的对抗损失和。

循环一致性损失为 $L_{\text{cycle}} = \|\tilde{X} - X\|_1 + \|\tilde{Y} - Y\|_1$,即使用 L_1 损失函数来计算循环一致性损失。身份损失为 $L_{\text{id}} = \|G_e(Y) - Y\|_1 + \|G_d(X) - X\|_1$ 。

2 实验结果与分析

2.1 实验环境

本文使用 PyTorch 框架和 NVIDIA Tesla V100 SXM2 32 GB GPU 来实现所提出的方法,并在云服务器上进行实验。在训练时,使用 8×8 的卷积对图像进行 Patch embedding,选择 Adam 优化器来更新参数,设置学习率 $= 1 \times 10^{-5}$,batch $= 1$,损失函数权重 $\lambda_1 = 12$ 、 $\lambda_2 = 6$,epoch $= 600$ 。当平均损失梯度不再下降,训练提前结束。

2.2 数据集

本文使用 RVS、EyeQ、Kaggle、DRIVE 四个数据集来进行实验。其中,在 RVS 上训练模型,并使用 EyeQ、Kaggle、DRIVE 对模型的增强性能进行评估。同时,使用数据集 RVS 和 DRIVE 来训练视网膜血管分割模型 DeepLab-ResNet^[16],观察视网膜增强图像对下游任务的影响。

RVS:包含 100 张高分辨率视网膜图像和 100 张对应标注的血管分割图。EyeQ:来自 EyePACS 的一个子集,包含 28 792 张不同质量的视网膜图像 (16 817 张 ‘Good’、6 435 张 ‘Usable’、5 540 张 ‘Reject’)。Kaggle:包含 300 张正常视网膜图像和 100 张白内障视网膜图像。DRIVE:包含 40 张高分辨率视网膜图像和 40 张对应标注的血管分割图。

RVS 中的所有清晰图像和利用退化模型^[17]合成的退化图像构成训练集。在训练开始前,对输入图像进行预处理。为抑制非关注区域的干扰,先使用霍夫圆变换检测圆形结构,得到与图像尺寸匹配的掩膜。然后,将掩膜与图像进行矩阵点乘。最后将图像尺寸调整为 $256 \text{ px} \times 256 \text{ px}$ 。

2.3 评估指标

采用五种评估指标对增强图像的质量进行评估,包括全参考指标峰值信噪比 (PSNR)、结构相似性指数 (SSIM)、学习感知图像块相似性 (LPIPS)^[18],无参考指标视网膜图像质量得分 (质量

“好”占比 FIQA、平均得分 WFQA)。其中: LPIPS 是使用深度学习方法学习得到的感知图像相似性指标^[18], 数值范围在 0 到 1 之间。FIQA 是计算被视网膜质量评估系统 MCF-Net^[19]预测为质量“好”的增强图像在测试集图像总数中的占比, 占比越高, 增强效果越好。WFQA 是计算每幅图像的平均得分。MCF-Net 的评分标准为: “好”(2 分)、“可用”(1 分)、“差”(0 分)。同时, 为了分析模型对视网膜图像细节信息的恢复情况, 用训练好的 DeepLab-ResNet 模型对图像进行血管分割。

2.4 实验结果

本文将 RVS 上训练的模型与其他六种视网膜图像增强方法进行比较, 它们分别是 I-SECRET^[11]、cofe-net^[17]、SCRNET^[20]、ArcNet^[21]、GFE-Net^[22]、T-CycleGAN^[9]。并对实验结果进行定量和定性分析。

GTCG-Net 与其他方法的测试结果对比如表 1 所示, 图 3 则直观地体现了不同方法在不同数据集(DRIVE、EyeQ、Kaggle)上对低质量视网膜图像的增强效果。面对在光照不均、伪影、模糊这三种情况下合成的退化图像 DRIVE, GTCG-Net 在三个全参考指标中都表现出较好的性能, 尤其是与 cofe-net 和 ArcNet 对比, PSNR 指数相较 cofe-net、ArcNet 分别高出 6.072、6.849 dB, SSIM 指标分别高出 0.214、0.275, 这也与 LPIPS 人眼感知结果相对应。cofe-net 和 ArcNet 都是使用合成数据进行训练的, 为了使模型修复图像时保留完整的结构特征, 都引入图像的结构信息作为引导。但在图 3 中可观察到, 由于低质量图像的结构分割不准确, 增强时引入了不希望的伪影。GTCG-Net 虽然在 SSIM 和 LPLPS 指标上略逊色于 I-SECRET, 但 PSNR 指数比 I-SECRET 高出 0.664 dB。从图 3 也可以观察到, I-SECRET 增强图像与参考清晰图像相比存在一定的色彩失真。

在 EyeQ 的 435 张 ‘Usable’ 测试集上, GTCG-Net 的无参考指标 FIQA、WFQA 比表现最优的 SCRNET 分别少 10%、0.12。但由图 2 中的增强图像可发现 SCRNET 和 GFE-Net 存在过度增强的现象, 视网膜中的病理特征黄斑区域在增强后几乎消失, 而病变特征对眼疾的诊断和治疗有着重要意义。本文的 GTCG-Net 模型在增强后保留了完整清晰的病变特征, 同时图 4 中的血管分割图也表示 GTCG-Net 恢复出更多的血管细节。

在 Kaggle 的 100 张白内障测试集上, GTCG-Net 的性能最好, FIQA、WFQA 比 I-SECRET 分别高出 1%、0.18, 比 T-CycleGAN^[9] 分别高出 2%、0.07。并且从图 3 和图 4 中可看出, GTCG-Net 的去模糊能力最强, 保留了最完整的结构特征。

综合分析, 当面对不同数据集时, GTCG-Net 在伪影去除、病理特征恢复、细节信息等方面表现出胜于其他方法的效果。这反映了 GTCG-Net 的泛化能力和临床意义。

表 1 GTCG-Net 与其他六种方法的测试结果对比
Tab. 1 Comparison of test results of GTCG-Net with six other methods

方法	全参考			无参考			
	DRIVE			EyeQ		Kaggle	
	PSNR/dB	SSIM	LPIPS	FIQA/%	WFQA	FIQA/%	WFQA
I-SECRET	22.434	0.895	0.072	0.78	1.77	0.76	1.54
cofe-net	17.026	0.677	0.242	0.52	1.45	0.29	0.69
SCRNET	20.911	0.704	0.229	0.93	1.90	0.69	1.49
ArcNet	16.249	0.616	0.285	0.61	1.51	0.66	1.44
GFE-Net	21.196	0.725	0.214	0.92	1.89	0.64	1.37
T-CycleGAN	19.496	0.863	0.115	0.82	1.77	0.75	1.65
GTCG-Net	23.098	0.891	0.074	0.83	1.78	0.77	1.72




图 3 DRIVE、Kaggle 和 EyeQ 数据集上视网膜图像增强效果对比图
Fig.3 Comparison of retinal image enhancement on DRIVE, Kaggle and EyeQ datasets




图 4 EyeQ 和 Kaggle 数据集上增强图像的血管分割对比图
Fig.4 Comparison of blood vessel segmentation in enhanced images on EyeQ and Kaggle datasets

2.5 消融实验

本文通过测试跳跃连接和门控 MLP 2 个因素的贡献来进行消融研究，测试结果见表 2。

表 2 GTCG-Net 消融研究的测试结果对比
Tab.2 Comparison of test results from GTCG-Net ablation studies

消融实验	DRIVE			EyeQ
	PSNR/dB	SSIM	LPIPS	FIQA/%
线性 MLP	22.608	0.812	0.211	0.79
移除跳跃连接	22.768	0.838	0.125	0.80
GTGC-Net	23.098	0.891	0.074	0.83

如表 2 所示，在退化 DRIVE 上，移除跳跃连接后，PSNR 指标下降 0.33 dB，SSIM 下降 0.053，LPIPS 增加 0.051。使用线性 MLP 替换门控 MLP 后，PSNR 指标下降 0.49 dB，SSIM 下降 0.079，

LPIPS 增加 0.137。在无参考的 EyeQ 上,移除连接的 FIQA 减少 3%,线性 MLP 的 FIQA 减少 4%。对比来看,门控 MLP 对模型的贡献更大,门控 MLP 通过引入门控机制,可以对输入特征进行动态的选择和调整。它通过学习适应性的权重,能够根据输入的上下文信息自适应地决定哪些特征对于当前任务更重要,能够更好地强调与血管、病变等相关的重要特征,从而提升模型对关键特征的捕捉能力。由图 5a 可看出线性 MLP 在图像增强中对伪影去除的能力下降,结构信息的恢复不再精确,同时分析图 5b 的血管分割图,移除跳跃连接和使用线性 MLP 都会丢失部分细节信息,但线性 MLP 的丢失情况更严重。

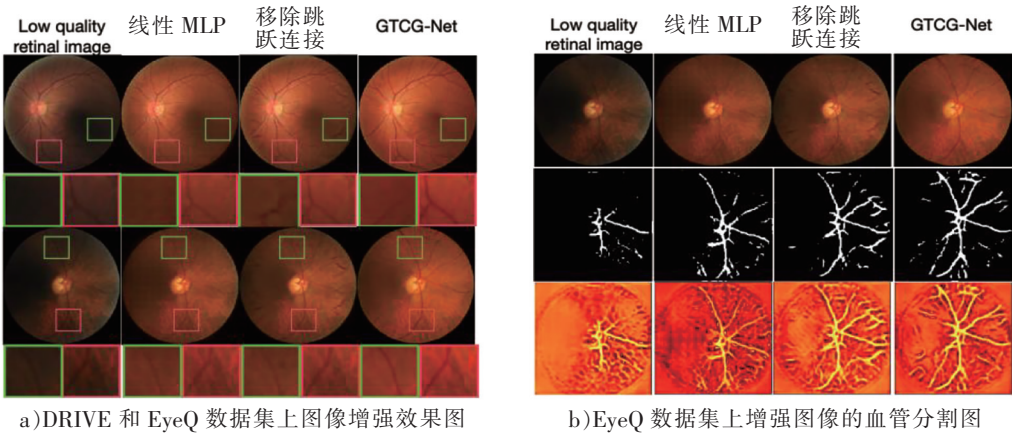


图 5 消融研究的增强效果对比图
Fig.5 Comparison of enhancement effects of ablation studies

3 结论

本文提出了一个端到端的视网膜图像增强方法 GTCTG-Net,旨在提升低质量视网膜图像增强算法在精细眼底结构和病理特征恢复上的准确性。本文的主要结论:1) 提出一种基于门控 Transformer 的新型 CycleGAN 方法 (GTCTG-Net),在 Transformer 的 MLP 层中引入门控机制来调节输入的权重,控制信息流动帮助模型捕捉关键信息。2) 在生成器的编码层和解码层之间使用跳跃连接。通过跳跃连接,将不同层级的特征融合起来,使得网络可以同时利用浅层和深层的特征表示。3) 通过实验展现了 GTCTG-Net 在视网膜图像增强任务中的优势,与其他的算法相比,GTCTG-Net 不仅可以有效地恢复眼底结构和病理特征,同时在多个数据集上表现出较好的泛化能力。但是,GTCTG-Net 的模型复杂度较高,对计算资源的需求大,如何高效地实现低质量视网膜图像的增强是未来研究的重点。

[参考文献]

[1] POPLIN R, VARADARAJANA V, BLUMER K, et al. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning[J]. Nature Biomedical Engineering, 2018, 2(3): 158-164.

[2] 王文静, 张莉钊, 王欣, 等. 融合改进 Retinex 图像增强与深度学习的糖尿病视网膜分类检测方法[J]. 中国医学物理学杂志, 2024, 41(9): 1086-1092.

[3] 蔡蔓利. 眼底血管图像特征增强及分割算法研究[D]. 徐州: 中国矿业大学, 2022.

[4] 徐宏. 基于眼底图像的糖尿病视网膜病变智能诊断[D]. 成都: 电子科技大学, 2019.

[5] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]// Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2223-2232.

[6] YOU Q, WAN C, SUN J, et al. Fundus image enhancement method based on CycleGAN[C]// 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society. Berlin: IEEE, 2019: 4500-4503.

[7] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]// Proceedings of the European Confer-
<http://xuebaobangong.jmu.edu.cn/zkb>

- ence on Computer Vision. Munich:Springer,2018:3-19.
- [8] MA Y, LIU J, LIU Y, et al. Structure and illumination constrained GAN for medical image enhancement[J]. IEEE Transactions on Medical Imaging, 2021, 40(12):3955-3967.
- [9] ALIMANOV A, ISLAM M B. Retinal image restoration using transformer and cycle-consistent generative adversarial network [C]//International Symposium on Intelligent Signal Processing and Communication Systems. Penang:IEEE,2022:1-4.
- [10] PARK T, EFROS A A, ZHANG R, et al. Contrastive learning for unpaired image-to-image translation [C]//Computer Vision-ECCV 2020. Glasgow:Springer,2020:319-345.
- [11] CHENG P, LIN L, HUANG Y, et al. I-secret:importance-guided fundus image enhancement via semi-supervised contrastive constraining [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Strasbourg:Springer,2021:87-96.
- [12] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in neural information processing systems, 2017, 30:6000-6010.
- [13] LIU H, DAI Z, SO D, et al. Pay attention to mlps [J]. Advances in Neural Information Processing Systems, 2021, 34:9204-9215.
- [14] RONNEBERGER O, FISCHER P, BROX T. U-net:convolutional networks for biomedical image segmentation [C]//Medical Image Computing and Computer-assisted Intervention-MICCAI 2015. Munich:Springer,2015:234-241.
- [15] DU G, CAO X, LIANG J, et al. Medical image segmentation based on U-Net: a review [J]. Journal of Imaging Science & Technology, 2020, 64(2):5081-5092.
- [16] LISKOWSKI P, KRAWIEC K. Segmenting retinal blood vessels with deep neural networks [J]. IEEE Transactions on Medical Imaging, 2016, 35(11):2369-2380.
- [17] SHEN Z, FU H, SHEN J, et al. Modeling and enhancing low-quality retinal fundus images [J]. IEEE Transactions on Medical Imaging, 2020, 40(3):996-1006.
- [18] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Utah:IEEE,2018:586-595.
- [19] FU H, WANG B, SHEN J, et al. Evaluation of retinal image quality assessment networks in different color-spaces [C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2019. Shenzhen:Springer,2019:48-56.
- [20] LI H, LIU H, FU H, et al. Structure-consistent restoration network for cataract fundus image enhancement [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Singapore:Springer,2022:487-496.
- [21] LI H, LIU H, HU Y, et al. An annotation-free restoration network for cataractous fundus images [J]. IEEE Transactions on Medical Imaging, 2022, 41(7):1699-1710.
- [22] LI H, LIU H, FU H, et al. A generic fundus image enhancement network boosted by frequency self-supervised representation learning [J]. Medical Image Analysis, 2023, 90:102945.

(责任编辑 彭海滨 英文审校 黄振坤)