

基于循环生成对抗网络的低质量眼底图像增强效果评估

周雪婷¹ 杨卫华² 华晓³ 游齐靖¹ 孙晶¹ 沈建新¹ 方程¹

¹南京航空航天大学电子信息工程学院 211106; ²南京医科大学附属眼科医院眼科 人工智能大数据实验室 210001; ³南京星程智能有限公司 210046

通信作者: 方程, Email: wanch@nuaa.edu.cn

【摘要】 目的 构建循环生成对抗网络(CycleGAN)对模糊、曝光不足、曝光过度等低质量眼底图像进行质量提升,并对其效果进行评估。方法 从EyePACS数据集中分别选取700张高质量和700张低质量眼底图像作为本研究的数据集。对数据集图像进行裁剪并统一缩放至512×512分辨率。采用2个生成模型和2个判别模型构建CycleGAN,生成模型根据输入的低/高质量眼底图像生成匹配的高/低质量图像,判别模型判别原始图像和生成图像。将本研究提出的算法与限制对比度自适应直方图均衡化(CLAHE)、动态直方图均衡化(DHE)、带色彩恢复的多尺度Retinex(MSRCR)3种图像增强算法的结果进行视觉定性评估,并采用清晰度、BRISQUE、色度、饱和度作为定量指标进行评估。应用糖尿病视网膜病变(DR)诊断网络对原图及不同算法增强图像进行诊断;并比较其准确度和特异度。结果 CycleGAN算法对模糊、曝光不足、曝光过度3类低质量眼底图像的增强均取得最优效果,增强后的眼底图像对比度高、色彩丰富,视盘、血管结构清晰。CycleGAN算法增强的图像清晰度仅次于CLAHE算法;BRISQUE质量分数为0.571,比CLAHE、DHE和MSRCR算法分别高出10.2%、7.3%和10.0%;色度和饱和度分别为103.03、123.24,均高于其他算法;该算法增强100张图像仅需35s,仅次于CLAHE算法,在速度上具有明显优势。CycleGAN算法增强的图像在DR诊断中的准确率和特异度分别为96.75%和99.60%,均较原图有所提高。结论 CycleGAN可有效提升模糊、曝光不足、曝光过度眼底图像的质量,并有效提高计算机辅助DR诊断系统的准确率,可能在眼科临床诊断中有很大的应用价值。

【关键词】 深度学习; 图像增强; 循环生成对抗网络; 眼底图像

基金项目: 中国博士后科学基金项目(2019M661832); 江苏省博士后科研资助计划项目(2019K226); 江苏高校优势学科建设工程项目

DOI:10.3760/cma.j.cn115989-20201028-00718

Evaluation of low-quality fundus image enhancement based on cycle-constraint adversarial network

Zhou Xueting¹, Yang Weihua², Hua Xiao³, You Qijing¹, Sun Jing¹, Shen Jianxin¹, Wan Cheng¹

¹College of Electronic Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China; ²The Laboratory of Artificial Intelligence and Bigdata in Ophthalmology, The Affiliated Eye Hospital of Nanjing Medical University, Nanjing 210001, China; ³Nanjing Star-mile Technology Co., Ltd, Nanjing 210046, China

Corresponding author: Wan Cheng, Email: wanch@nuaa.edu.cn

[Abstract] Objective To propose and evaluate the cycle-constraint adversarial network (CycleGAN) for enhancing the low-quality fundus images such as the blurred, underexposed and overexposed etc. **Methods** A dataset including 700 high-quality and 700 low-quality fundus images selected from the EyePACS dataset was used to train the image enhancement network in this study. The selected images were cropped and uniformly scaled to 512×512 pixels. Two generative models and two discriminative models were used to establish CycleGAN. The generative model generated matching high/low-quality images according to the input low/high-quality fundus images, and the discriminative model determined whether the image was original or generated. The algorithm proposed in this study was compared with three image enhancement algorithms of contrast limited adaptive histogram equalization (CLAHE), dynamic histogram equalization (DHE), and multi-scale retinex with color restoration (MSRCR) to perform qualitative visual assessment with clarity, BRISQUE, hue and saturation as quantitative indicators. The original and enhanced images were applied to the diabetic retinopathy (DR) diagnostic network to diagnose, and the accuracy and specificity were compared. **Results** CycleGAN achieved the optimal results on enhancing the three types of low-quality fundus images including the blurred, underexposed and overexposed. The enhanced fundus images were of high contrast, rich colors, and with clear optic disc and blood vessel structures. The clarity of the images enhanced by

CycleGAN was second only to the CLAHE algorithm. The BRISQUE quality score of the images enhanced by CycleGAN was 0.571, which was 10.2%, 7.3%, and 10.0% higher than that of CLAHE, DHE and MSRCR algorithms, respectively. CycleGAN achieved 103.03 in hue and 123.24 in saturation, both higher than those of the other three algorithms. CycleGAN took only 35 seconds to enhance 100 images, only slower than CLAHE. The images enhanced by CycleGAN achieved accuracy of 96.75% and specificity of 99.60% in DR diagnosis, which were higher than those of original images. **Conclusions** CycleGAN can effectively enhance low-quality blurry, underexposed and overexposed fundus images and improve the accuracy of computer-aided DR diagnostic network. The enhanced fundus image is helpful for doctors to carry out pathological analysis and may have great application value in clinical diagnosis of ophthalmology.

[Key words] Deep learning; Image enhancement; Cycle-constraint adversarial network; Fundus image

Fund program: Chinese Postdoctoral Science Foundation (2019M661832); Jiangsu Planned Projects for Postdoctoral Research Funds (2019K226); Jiangsu Province Advantageous Subject Construction Project

DOI: 10.3760/cma.j.cn115989-20201028-00718

彩色眼底图像广泛用于糖尿病视网膜病变 (diabetic retinopathy, DR)、青光眼等疾病的筛查和诊断^[1-3]。低质量的眼底图像无法清楚展示视网膜血管、视杯、视盘异常等疾病诊断所需的关键信息, 容易造成医生和计算机辅助诊断 (computer-aided diagnosis, CAD) 系统的漏诊, 甚至误诊^[4]。目前采集的眼底图像数据集中, 因质量差而影响医学诊断的图像占比超过 1/4^[5]; 从基层医院上传至云平台的眼底图像中低质量图像占比近 1/2^[6]。对低质量眼底图像进行分析发现, 模糊、曝光不足和曝光过度是 3 个主要原因^[7]。除规范眼底照相采集流程外, 智能眼科专家一直尝试对眼底图像进行增强, 通过技术手段提高图像的清晰度、亮度和对比度, 进而降低后续的误诊率并提高 CAD 系统的准确率。目前主要采用基于直方图的方法增强眼底图像。基于直方图的方法可分为 3 类: 一是采用直方图均衡化, 通过增加最大和最小像素之间的差值来增强图像^[8]; 二是通过伽马矫正得到亮度增益矩阵, 再利用限制对比度自适应直方图均衡化 (contrast limited adaptive histogram equalization, CLAHE) 增强亮度通道的对比度^[9]; 三是对模糊直方图预处理, 去除眼底图像的不均匀光照^[10]。基于直方图算法的本质是提高图像对比度并使灰度分布均匀, 因此颜色过渡时会失真, 视觉效果不佳。动态直方图均衡化 (dynamic histogram equalization, DHE) 根据局部最小值对图像直方图进行分割, 并为每个分割分配特定的灰度范围, 然后分别进行均衡, 以保留更多细节信息^[11]。带色彩恢复的多尺度 Retinex (multi-scale Retinex with color restoration, MSRCR) 是一种基于 Retinex 理论的图像增强算法, 可以提高图像锐度并控制动态

参数实现色度调节^[12]; 但由于眼底图像背景和前景明暗差别较大, 经过对数处理的像素会超出可显示范围, 上述方法仍易造成色彩失真。为克服传统眼底图像增强方法中视觉效果不佳、细节丢失、色彩失真等缺陷, 解决低质量眼底图像无法用于医学诊断的问题, 本研究拟通过构建循环生成对抗网络 (cycle-constraint adversarial network, CycleGAN)^[13], 提出一种基于深度学习的眼底图像增强算法, 对模糊、曝光不足、曝光过度等低质量眼底图像进行增强。

1 材料与方法

1.1 材料

采用来自 Kaggle DR 检测竞赛的 EyePACS 公开数据集^[14]。EyePACS 数据集包含 88 702 张彩色眼底图像, 其中 35 126 张为训练集, 53 576 张为测试集, 每张图像均有专业医生评定的 DR 患病标签。该数据集包含大量不可用于医生临床分析或智能设备诊断的低质量眼底图像, 主要包含模糊、曝光不足和曝光过度 3 种类型 (图 1)。在 EyePACS 数据集中分别选取 700 张高质量和 700 张低质量眼底图像作为图像增强实验的数据集, 其中训练集中选取高质量和低质量眼底图像各 500 张, 测试集中选取高质量和低质量眼底图像各 200 张。

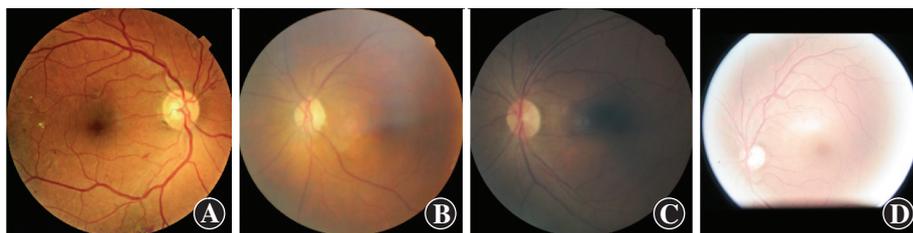


图 1 高/低质量眼底图像示例 A: 高质量图像 B: 模糊图像 C: 曝光不足图像 D: 曝光过度图像

Figure 1 Examples of high/low-quality fundus images A: High-quality image B: Blurred image C: Underexposed image D: Overexposed image

1.2 方法

1.2.1 眼底图像的预处理 由于数据集中图像分辨率不同且为矩形,因此需要对图像进行裁剪及缩放等归一化预处理。具体步骤如下:(1)以眼底图像的高作为边长,裁去矩形图像左右两边多余的黑色背景部分,保留正方形眼底图像(图 2A,B);(2)若图像的高小于眼底图像圆形区域的直径,则先裁剪为直径×高的矩形区域,再在矩形区域的上下两侧补充黑边使之成为直径×直径的正方形眼底图像(图 2C,D);(3)将正方形眼底图像尺寸统一缩放为分辨率 512×512。

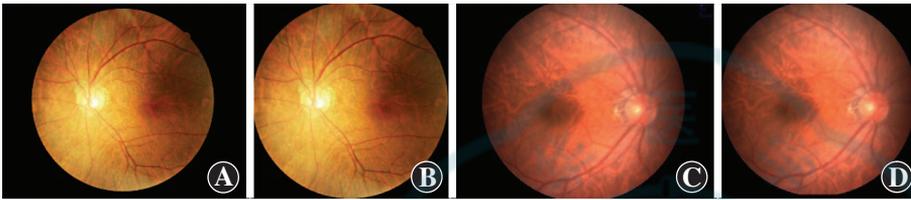


图 2 眼底图像预处理结果 A:眼底图像原图 图像圆形区域直径小于图像高度 B:图 A 的裁剪和缩放 C:眼底图像原图 圆形区域直径大于图像高度 D:图 C 的裁剪和缩放

Figure 2 Preprocessed fundus images A:Original fundus image The diameter of the circular region was smaller than the image height B:Cropped and scaled image A C:Original fundus image The diameter of the circular region was larger than the image height D:Cropped and scaled image C

1.2.2 生成模型的构建 生成模型是一个神经网络,包括下采样模块、特征整理模块和上采样模块 3 个部分。下采样模块由 3 层卷积构建,输出通道数分别为 32、64 和 128;卷积核尺寸分别为 7×7、3×3 和 3×3;步长均为 1,在每层卷积操作之后执行归一化并使用 ReLU 激活函数解决训练过程中的梯度消失现象。特征整理模块包括 9 个卷积层,每层卷积分别进行 2 次 3×3 的卷积和归一化操作,将输出与该层的输入融合后作为下一层卷积的输入;每次卷积操作的步长均为 1,输出通道数均为 128。上采样模块先进行 2 次转置卷积,卷积核尺寸为 3×3,步长为 2,输出通道分别设置为 64 和 32,再进行卷积核尺寸为 7×7,步长为 1 的卷积,最后使用 tanh 激活函数增强网络的拟合能力(图 3)。

1.2.3 判别模型的构建 判别模型由 4 个卷积层和 1 个输出层构成。卷积层均使用尺寸为 4×4 的卷积核,输出通道数分别为 64、

128、256 和 512;步长分别为 2、2、2 和 1;第 1 层不使用归一化,后 3 层卷积均进行归一化操作。输出层进行 4×4 的卷积,卷积方式采用 SAME,即卷积前后的特征图保持大小不变,输出层的步长和通道数均为 1,对于输入大小为 512×512×3 的 3 通道彩色眼底图像,判别网络输出大小为 64×64(图 4)。

1.2.4 CycleGAN 的构建 采用 2 个生成模型和 2 个判别模型构建 CycleGAN。生成模型 G_{A2B} 根据低质量图像生成对应的高质量图像,生成模型 G_{B2A} 与其相反;判别模型 D_A 和 D_B 分别用于判断输入的低质量图像和高质量图像是原始图像还是生成图像并输出概率值。在 CycleGAN 中,低质量眼底图像通过生成模型 G_{A2B} 生成增强后的高质量眼底图像,继而输入判别模型 D_B 进行判别;同样地,高质量图像通过生成模型 G_{B2A} 生成低质量眼底图像,继而进入 D_A 判别模型(图 5)。在网络训练过程中,生成模型和判别模型相互博弈,逐步提高生成器的图像生成能力和判别器的真假鉴别能力,生成的图像越来越接近真实图像的特征,判别模型的判别能力也越来越强。

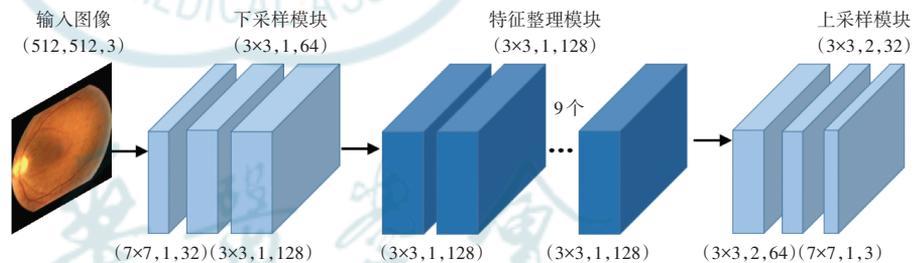


图 3 生成模型的网络结构
Figure 3 The network structure of generative model

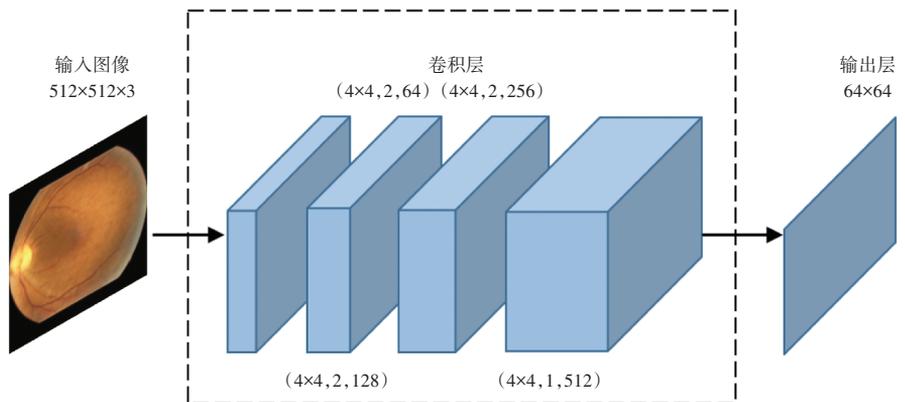


图 4 判别模型的网络结构
Figure 4 The network structure of discriminative model

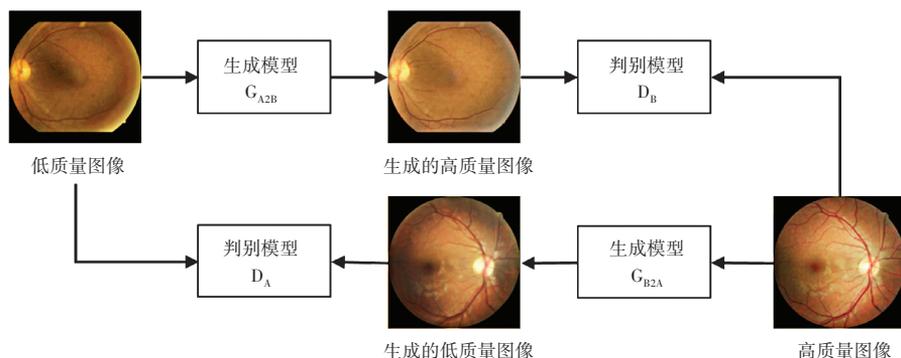


图 5 基于 CycleGAN 的眼底图像增强算法流程图
Figure 5 Fundus image enhancement algorithm flowchart based on CycleGAN

本研究采用 Tensorflow 深度学习框架,设置训练轮数为 200,生成器和判别器的学习率均为 2×10^{-4} ,采用 Adam 优化器。软件配置:Tensorflow-GPU 1.11.0, keras 2.2.4, numpy 1.19.2, opencv 3.4.2.16。硬件配置:CPU 为 E5-1620, GPU 为 NVIDIA GeForce GTX 1080,内存 16 GB,显存 8 GB。

1.2.5 评价指标 对测试集低质量眼底图像原图经本研究提出的算法与 CLAHE、DHE、MSRCR 算法增强的图像进行视觉定性评估,同时引入清晰度、BRISQUE^[16]、色度、饱和度作为眼底图像增强网络的定量评估指标。清晰度是评价图像质量的基本指标。BRISQUE 是一种基于空域特征的评价指标,利用支持向量机学习图像的相关性特征和广义高斯分布特征,训练质量分数与图像的回归模型,从而得出图像的质量分数。色度是色调饱和度 (Hue-Saturation-Value, HSV) 模型中的一个属性,色度值越高代表图像的色调越饱满、色彩越丰富。饱和度是 HSV 模型的另一个属性,饱和度越高则图像越明亮,反之则图像的色彩越暗淡。对于色度和饱和度越高的图像,人体视觉观感越好。

1.2.6 DR 诊断网络的构建 采用 Inception-ResnetV2 网络^[15]作为 DR 诊断模块,对增强前后的眼底图像进行 DR 疾病的诊断。采用 ImageNet 预训练的模型初始化网络参数,再用 EyePACS 数据集训练网

络。分别用测试集中低质量原图及各方法增强后的眼底图像作为 DR 测试集进行 DR 诊断。

中存在大块暗色区域,照度不均匀,视觉效果不佳。DHE 算法提高了原图的亮度,但对清晰度无明显提升,难以分辨视盘边缘。MSRCR 算法产生的图像颜色偏白,色彩失真严重,亮度高且对比度低,无法清晰展示眼底信息。CycleGAN 算法的视觉效果最佳,提高了原图的对比度、亮度及视觉分辨率,视盘边缘及内部血管交叉处都得以清晰地显现,血管末梢及微小血管的可见度较原图更高。

曝光不足的眼底图像整体亮度、对比度和眼底信息可见度低,图 7 为不同算法对曝光不足眼底图像的增强结果。CLAHE 算法增强的图像明暗分布不均,血管为黑色,整体颜色不自然。DHE 算法增强的图像视盘区域呈橘色,黄斑区域呈黑青色,对低光照区域增强效果不理想;MSRCR 算法使图像产生蓝色调,色差严重,同时图像对比度低,对图像的增强效果不明显。CycleGAN 算法提高了图像的亮度和对比度;图像照度均匀,视盘周围的细小血管、血管末梢的纹理均能清晰地显示;同时该算法对色彩进行了还原,图像整体偏红色调,更符合眼底实际情况。

曝光过度的眼底图像亮度高、对比度低且图像泛白,图 8 为不同算法对曝光过度眼底图像的增强结果。CLAHE 算法提高了图像对比度但对图像增强过度,且亮度分布不均。DHE 算法在眼底图像周边产生灰色

络。分别用测试集中低质量原图及各方法增强后的眼底图像作为 DR 测试集进行 DR 诊断。

2 结果

2.1 增强图像定性评估

不同算法对模糊眼底图像的增强结果如图 6 所示。CLAHE 算法提高了图像的对比度,血管纹路清晰,但血管变粗、颜色棕红影响了临床上对疾病的诊断,并且图像

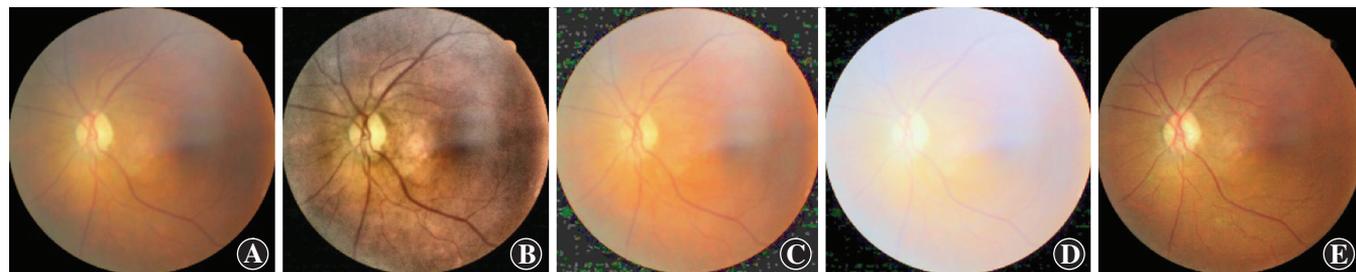


图 6 不同算法对模糊图像增强结果 A:原图 B:CLAHE 算法增强图 C:DHE 算法增强图 D:MSRCR 算法增强图 E:CycleGAN 算法增强图
Figure 6 Results of blurry image enhanced by different algorithms A:Original image B:CLAHE enhanced image C:DHE enhanced image D:MSRCR enhanced image E:CycleGAN enhanced image

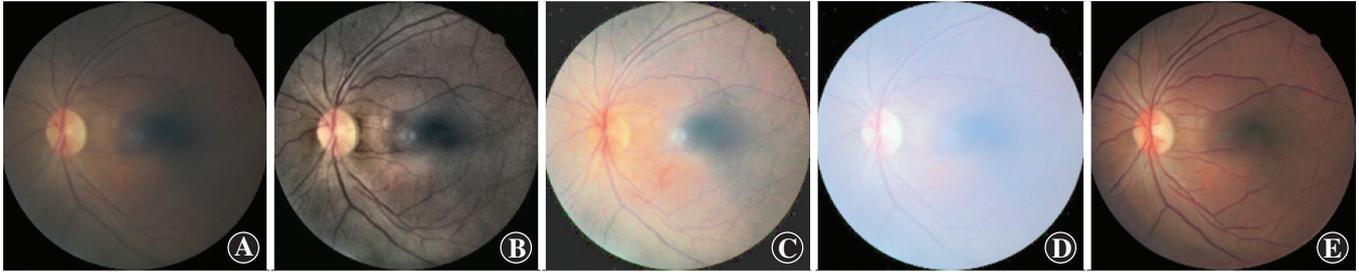


图 7 不同算法对曝光不足图像增强结果 A:原图 B:CLAHE 算法增强图 C:DHE 算法增强图 D:MSRCR 算法增强图 E:CycleGAN 算法增强图
Figure 7 Results of underexposed image enhanced by different algorithms A:Original image B:CLAHE enhanced image C:DHE enhanced image D:MSRCR enhanced image E:CycleGAN enhanced image

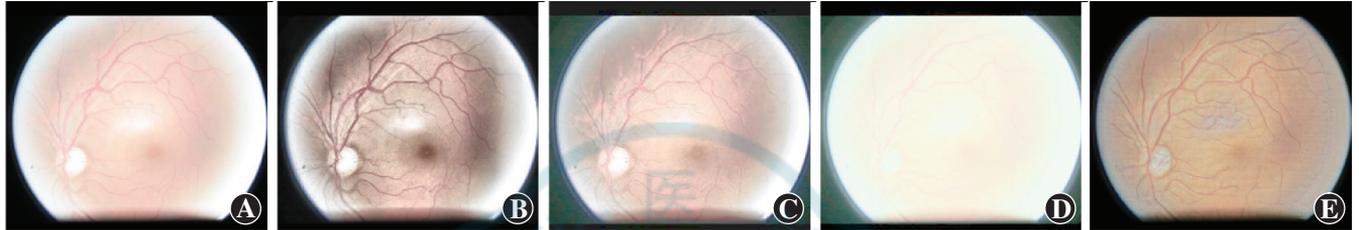


图 8 不同算法对曝光过度图像增强结果 A:原图 B:CLAHE 算法增强图 C:DHE 算法增强图 D:MSRCR 算法增强图 E:CycleGAN 算法增强图
Figure 8 Results of overexposed image enhanced by different algorithms A:Original image B:CLAHE enhanced image C:DHE enhanced image D:MSRCR enhanced image E:CycleGAN enhanced image

阴影,遮盖了此区域的眼底情况。MSRCR 算法进一步提高了图像亮度,导致图像纹理可见度更低,该算法不适用于曝光过度图像的增强。CycleGAN 算法增强后图像颜色有一定的恢复,消除了原图中的白色光环,亮度分布均匀,原图中心亮斑处的细小血管也可清晰展示。

2.2 增强图像定量评估

增强后的眼底图像清晰度均得到提高。CLAHE 算法增强的图像清晰度高达 155.34,其次为 CycleGAN 算法的 61.75。在 BRISQUE 质量分数评估指标中,采用 CycleGAN 算法增强后的图像取得最大值,即图像质量最优,而其他算法增强后的 BRISQUE 质量分数均低于原图。CycleGAN 算法的 BRISQUE 质量分数分别比 CLAHE、DHE 和 MSRCR 算法高出 10.2%、7.3% 和 10.0%。对于色度指标,CycleGAN 在 4 种增强算法中取得最大值 103.03,CLAHE、DHE 和 MSRCR 算法的色度值分别比原图降低 18.66、7.47 和 8.31。在饱和度指标中,原图的饱和度为 158.26,CycleGAN 和 MSRCR 算法均有良好表现,其中 CycleGAN 增强后的图像饱和度以 0.08 的优势在该指标中取得最优值(表 1)。DHE 算法处理图像速度最慢,每增强 100 张图像需要 4 711 s,平均每张图像耗费 47.11 s,在处理图像时有明显的等待时间;CLAHE、MSRCR 和 CycleGAN 算法增强 100 张图像分别耗费 5、101 和 35 s。

2.3 增强图像 DR 诊断效果

增强前后的眼底图像在 DR 诊断应用中的准确率如表 2 所示。对原图进行诊断的准确率和特异度分别

为 93.00% 和 96.70%。DHE 算法增强的图像在诊断应用中表现不佳,准确率和特异度较原图均有所下降。MSRCR 算法增强图在诊断准确度上较原图有所提高,但在特异度上有下降。CLAHE 和 CycleGAN 算法增强后的图像在诊断准确率和特异度上均得到提升,其中 CycleGAN 算法增强的图像取得最优值。

表 1 增强图像定量评估结果
Table 1 Quantitative evaluation results of enhanced images

图像增强方法	图片数 (张)	清晰度 [M(Q ₁ , Q ₃)]	BRISQUE (mean±SD)	色度 (mean±SD)	饱和度 (mean±SD)
原图	200	7.81(5.94, 13.05)	0.556±0.067	106.47± 7.34	158.26±51.34
CLAHE	200	155.34(104.93,236.82)	0.518±0.145	87.81± 6.06	87.96±30.50
DHE	200	16.24(7.71, 39.33)	0.532±0.147	99.00± 7.09	112.56±48.86
MSRCR	200	5.59(3.61, 8.94)	0.519±0.071	98.16±20.59	123.16±45.82
CycleGAN	200	61.75(49.30, 75.69)	0.571±0.095	103.03± 3.58	123.24±41.40

注:CLAHE:限制对比度自适应直方图;DHE:动态直方图均衡化;MSRCR:带色彩恢复的多尺度 Retinex;CycleGAN:循环生成对抗网络
Note: CLAHE: contrast limited adaptive histogram equalization; DHE: dynamic histogram equalization; MSRCR: multi-scale Retinex with color restoration; CycleGAN: cycle-constraint adversarial network

表 2 增强图像 DR 诊断结果 (%)
Table 2 DR diagnosis results of enhanced images (%)

	原图	CLAHE	DHE	MSRCR	CycleGAN
准确率	93.00	95.75	88.75	94.00	96.75
特异度	96.70	98.48	92.39	95.91	99.60

注:DR:糖尿病视网膜病变;CLAHE:限制对比度自适应直方图;DHE:动态直方图均衡化;MSRCR:带色彩恢复的多尺度 Retinex;CycleGAN:循环生成对抗网络
Note: DR: diabetic retinopathy; CLAHE: contrast limited adaptive histogram equalization; DHE: dynamic histogram equalization; MSRCR: multi-scale Retinex with color restoration; CycleGAN: cycle-constraint adversarial network

3 讨论

彩色眼底图像是筛查、诊断眼科疾病常用的影像资料,通常由眼底照相机拍摄。由于在图像的获取过程中存在拍摄环境不佳、设备参数设置错误等客观因素及医务人员操作不当、患者配合度不高等主观因素,现有的眼底图像数据库中存在大量低质量的眼底图像。这些低质量眼底图像不利于眼科医生和 CAD 系统进行分析。临床眼底照相采集过程中,一些患者由于存在屈光介质混浊,如白内障、玻璃体混浊及角膜斑翳等,也无法获取清晰的视网膜图像。因此,增强低质量眼底图像使其清晰地展示眼底情况对眼科疾病的临床诊断和基于数据库的眼科 AI 辅助诊断都非常重要。

与其他深度学习网络不同,本研究构建的 CycleGAN 网络是一种依靠数据驱动的弱监督卷积神经网络。眼底相同拍摄角度的高/低质量配对图像的采集难度大、周期长,因此目前研究多采用非配对的高/低质量眼底图像数据。本研究中 CycleGAN 的训练集只需相同数量的低质量图像集和高质量图像集,但两者无需一一匹配,避免了深度学习网络配对数据难以获得的问题。

在眼底图像增强的应用中,传统图像增强算法所获得的图像视觉效果较差或只擅长单一类型低质量眼底图像的增强。CLAHE 增强的图像取得异常高的清晰度是灰度梯度剧烈变化所致,且颜色过渡不自然、明暗分界线明显;DHE 算法增强曝光不足图像时色彩严重失真;MSRCR 算法增强后的图像普遍亮度偏高,对曝光过度图像没有增强效果反而降低了眼底信息的可见度。传统算法通过提高亮度和对比度达到图像增强的效果,不能对图像的色彩有较好的调节。然而在对彩色眼底图像的分析中,背景色彩对眼病的诊断至关重要。CycleGAN 网络在训练过程中学习低质量和高质量眼底图像的特征,如亮度、对比度、清晰度和色彩信息。在定量评估中,CycleGAN 增强的图像色度和饱和度虽低于原图,但与其他增强算法相比已最大程度地保留了图像的色彩信息。本研究提出的增强算法对眼底图像有色彩增强的能力,可对色彩失真的图像进行颜色矫正,这是其他增强算法所不具备的。

与其他眼底图像增强算法相比,CycleGAN 对低质量眼底图像的增强效果最好,增强后的眼底图像不仅可以更清晰地显示血管、视杯、视盘等关键诊断部位,而且不破坏原图像的结构特征。采用 CycleGAN 增强低质量眼底图像可以提高现有眼底图像数据库中图像的可诊断率。与原图和其他算法增强后的图像相比,

CycleGAN 增强后的高质量眼底图像 DR 诊断准确率和特异度分别达到最优值。CycleGAN 增强的眼底图像可直接用于医生临床诊断,并有效提高 CAD 系统诊断的准确率。

本研究提出的 CycleGAN 算法是一个端对端的图像增强网络,能够同时增强模糊、曝光不足、曝光过度等低质量类型的图像,平均处理 1 张图像只需 0.35 s,具有实时性和高效性,并可用在 CAD 系统前端。然而,本研究仍然存在可改进的地方,如在生成模型中引入注意力机制提高网络的特征提取能力,加强图像的细节信息等,同时可以在图像增强处理之前加入分类网络,先对图像进行质量分类再进行图像增强。

利益冲突 所有作者均声明不存在任何利益冲突

参考文献

- [1] 明帅,雷博.基于深度学习人工智能辅助诊断糖尿病视网膜病变研究现状及展望[J].中华实验眼科杂志,2019,37(8):684-688. DOI:10.3760/cma.j.issn.2095-0160.2019.08.019.
Ming S, Lei B. Research status and prospect of deep learning AI assisted diagnosis of diabetic retinopathy [J]. Chin J Exp Ophthalmol, 2019, 37(8): 684-688. DOI: 10.3760/cma.j.issn.2095-0160.2019.08.019.
- [2] 万加龙,胡建斌,金炜东,等.应用视觉注意力的糖尿病视网膜病变眼底影像筛查及分级[J].中华实验眼科杂志,2019,37(8):630-637. DOI:10.3760/cma.j.issn.2095-0160.2019.08.008.
Wan JL, Hu JB, Jin WD, et al. Screening and grading of fundus images of diabetic retinopathy based on visual attention [J]. Chin J Exp Ophthalmol, 2019, 37(8): 630-637. DOI: 10.3760/cma.j.issn.2095-0160.2019.08.008.
- [3] Diaz-Pinto A, Colomer A, Naranjo V, et al. Retinal image synthesis and semi-supervised learning for glaucoma assessment [J]. IEEE Trans Med Imaging, 2019, 38(9): 2211-2218. DOI: 10.1109/TMI.2019.2903434.
- [4] 张芳,赵东旭,肖志涛,等.眼底图像质量分类综述[J].计算机辅助设计与图形学学报,2020,32(3):501-512. DOI:10.3724/SP.J.1089.2020.17860.
Zhang F, Zhao DX, Xiao ZT, et al. A survey of fundus image quality classification [J]. J Comput-Aided Design Comput Graph, 2020, 32(3): 501-512. DOI: 10.3724/SP.J.1089.2020.17860.
- [5] MacGillivray TJ, Cameron JR, Zhang Q, et al. Suitability of UK Biobank retinal images for automatic analysis of morphometric properties of the vasculature [J/OL]. PLoS One, 2015, 10(5): e0127914 [2020-09-12]. <http://www.ncbi.nlm.nih.gov/pubmed/26000792>. DOI: 10.1371/journal.pone.0127914.
- [6] 苏炳男,李建军,徐亮,等.远程眼科阅片服务中基层医院上传图像的质量评估分析[J].眼科,2015,24(4):230-233. DOI:10.13281/j.cnki.issn.1004-4469.2015.04.004.
Su BN, Li JJ, Xu L, et al. Evaluation and analysis of the quality of the uploaded images from the primary hospitals in the remote ophthalmic film reading service [J]. Ophthalmol CHN, 2015, 24(4): 230-233. DOI: 10.13281/j.cnki.issn.1004-4469.2015.04.004.
- [7] Saha SK, Fernando B, Cuadros J, et al. Automated quality assessment of colour fundus images for diabetic retinopathy screening in telemedicine [J]. J Digit Imaging, 2018, 31(6): 869-878. DOI: 10.1007/s10278-018-0084-9.
- [8] Singh N, Kaur L, Singh K. Histogram equalization techniques for enhancement of low radiance retinal images for early detection of diabetic retinopathy [J]. Eng Sci Technol, 2019, 22(3): 736-745.

- DOI:10.1016/j.jestch.2019.01.014.
- [9] Zhou M, Jin K, Wang S, et al. Color retinal image enhancement based on luminosity and contrast adjustment [J]. IEEE Trans Biomed Eng, 2018, 65(3): 521-527. DOI:10.1109/TBME.2017.2700627.
- [10] Malviya R. Retinal fundus image enhancement and segmentation [J]. J Med Imag Health In, 2013, 3(4): 568 - 574. DOI:10.1166/jmihi.2013.1206.
- [11] Abdullah-Al-Wadud M, Kabir MH, Dewan M, et al. A dynamic histogram equalization for image contrast enhancement [J]. IEEE T Consum Electr, 2007, 53(2): 593-600. DOI:10.1109/TCE.2007.381734.
- [12] Zhu MY, Su F, Li WJ. Improved multi-scale Retinex approaches for color image enhancement [J]. Appl Mech Mater, 2010, 39: 32-37. DOI:10.4028/www.scientific.net/AMM.39.32.
- [13] Kida S, Kaji S, Nawa K, et al. Visual enhancement of cone-beam CT by use of CycleGAN [J]. Med Phys, 2020, 47(3): 998-1010. DOI:10.1002/mp.13963.
- [14] Cuadros J, Bresnick G. EyePACS: an adaptable telemedicine system for diabetic retinopathy screening [J]. J Diabetes Sci Technol, 2009, 3(3): 509-516. DOI:10.1177/193229680900300315.
- [15] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning [J/OL]. AAAI Conf Artif Intell, 2016: 1602. 07261 [2020-09-30]. <http://arxiv.org/abs/1602.07261>.
- [16] 张淑芳, 张聪, 张涛, 等. 通用型无参考图像质量评价算法综述 [J]. 计算机工程与应用, 2015, 51(19): 13-23. DOI:10.3778/j.issn.1002-8331.1507-0044.
- Zhang SF, Zhang C, Zhang T, et al. Review on universal no-reference image quality assessment algorithm [J]. Comput Eng Appl, 2015, 51(19): 13-23. DOI:10.3778/j.issn.1002-8331.1507-0044.

(收稿日期:2020-12-28 修回日期:2021-07-17)

(本文编辑:张宇)

读者·作者·编者

眼科常用英文缩略语名词解释

- AMD:年龄相关性黄斑变性(age-related macular degeneration)
- ANOVA:单因素方差分析(one-way analysis of variance)
- BUT:泪膜破裂时间(breakup time of tear film)
- DR:糖尿病视网膜病变(diabetic retinopathy)
- EAU:实验性自身免疫性葡萄膜炎(experimental autoimmune uveitis)
- EGF:表皮生长因子(epidermal growth factor)
- ELISA:酶联免疫吸附测定(enzyme-linked immunosorbent assay)
- ERG:视网膜电图(electroretinogram)
- FFA:荧光素眼底血管造影(fundus fluorescein angiography)
- FGF:成纤维细胞生长因子(fibroblast growth factor)
- GFP:绿色荧光蛋白(green fluorescent protein)
- IFN- γ : γ 干扰素(interferon- γ)
- IL:白细胞介素(interleukin)
- IOL:人工晶状体(intraocular lens)
- IRBP:光间受体视黄类物质结合蛋白(interphotoreceptor retinoid binding protein)
- LASIK:准分子激光角膜原位磨镶术(laser in situ keratomileusis)
- ICGA:吲哚菁绿血管造影(indocyanine green angiography)
- LECs:晶状体上皮细胞(lens epithelial cells)
- miRNA:微小RNA(microRNA)
- MMP:基质金属蛋白酶(matrix metalloproteinase)
- mTOR:哺乳动物类雷帕霉素靶蛋白(mammalian target of rapamycin)
- MTT:四甲基偶氮唑盐(methyl thiazolyl tetrazolium)
- NF:核转录因子(nuclear factor)
- OCT:光相干断层扫描(optical coherence tomography)
- OR:优势比(odds ratio)
- PACG:原发性闭角型青光眼(primary angle-closure glaucoma)
- PCR:聚合酶链式反应(polymerase chain reaction)
- RGCs:视网膜节细胞(retinal ganglion cells)
- POAG:原发性开角型青光眼(primary open angle glaucoma)
- RB:视网膜母细胞瘤(retinoblastoma)
- RPE:视网膜色素上皮(retinal pigment epithelium)
- RNV:视网膜新生血管(retinal neovascularization)
- RP:视网膜色素变性(retinitis pigmentosa)
- S I t:基础泪液分泌试验(Schirmer I test)
- shRNA:小发夹RNA(short hairpin RNA)
- siRNA:小干扰RNA(small interfering RNA)
- α -SMA: α -平滑肌肌动蛋白(α -smooth muscle actin)
- TAO:甲状腺相关眼病(thyroid-associated ophthalmopathy)
- TGF:转化生长因子(transforming growth factor)
- TNF:肿瘤坏死因子(tumor necrosis factor)
- UBM:超声生物显微镜(ultrasound biomicroscope)
- VEGF:血管内皮生长因子(vascular endothelial growth factor)
- VEP:视觉诱发电位(visual evoked potential)

本刊对论文题目的要求

论文题目力求简洁、特异、明确、能准确反映文章主题和特定内容,具有可检索性。中文文题一般以20个汉字以内为宜,一般不设副标题,尽量不用标点符号,文题中避免使用不为同行熟知的符号、简称、缩略语和商品名。论著文章和综述须有与中文文题含意一致的英文文题。

(本刊编辑部)