

基于 ResNet50-OC 模型的彩色眼底照片质量多分类方法效果评估

万程¹ 周雪婷¹ 游齐靖¹ 沈建新¹ 俞秋丽²

¹南京航空航天大学电子信息工程学院 211106; ²南京医科大学第二附属医院眼科 210003

通信作者:俞秋丽, Email:15905192943@163.com

【摘要】 目的 对基于深度学习的 ResNet50-OC 模型彩色眼底照片质量多分类的效果进行评估。

方法 纳入 2018 年 7 月在南京医科大学附属明基医院收集的彩色眼底照片 PD 数据集及 EyePACS 数据集, 临床医师根据眼底图像的成像质量将其大致分为质量较好、曝光不足、曝光过度、边缘模糊和镜头反光 5 类。在训练集中, 每个类别包含 1 000 张图像, 其中 800 张选自 EyePACS 数据集, 200 张选自 PD 数据集; 在测试集中, 每个类别包含 500 张图像, 其中 400 张选自 EyePACS 数据集, 100 张选自 PD 数据集。训练集总计 5 000 张图像, 测试集总计 2 500 张图像。对图像进行归一化处理和数据扩增。采用迁移学习方法初始化网络模型的参数, 在此基础上对比当前深度学习主流分类网络 VGG、Inception-resnet-v2、ResNet 和 DenseNet, 选取准确率和 Micro F1 值最优的网络 ResNet50 作为分类模型的主网络。在 ResNet50 训练过程中引入 One-Cycle 策略加快模型收敛速度, 得到最优模型 ResNet50-OC 并将其应用于眼底照片质量多分类, 评估 ResNet50 与 ResNet50-OC 对眼底照片进行多分类的准确率和 Micro F1 值。**结果** ResNet50 对彩色眼底照片质量多分类准确率和 Micro F1 值明显高于 VGG、Inception-resnet-v2、ResNet34 和 DenseNet。ResNet50-OC 模型训练 15 轮对眼底图像质量多分类准确率为 98.77%, 高于 ResNet50 训练 50 轮的 98.76%; ResNet50-OC 模型训练 15 轮对眼底图像质量多分类的 Micro F1 值为 98.78%, 与 ResNet50 训练 50 轮的 Micro F1 值相同。**结论** ResNet50-OC 模型可以准确、有效地对彩色眼底照片质量进行多分类, One-Cycle 策略可减少训练次数, 提高分类效率。

【关键词】 人工智能; 图像质量分类; 卷积神经网络; 单周期学习; 彩色眼底照片

基金项目: 国家自然科学基金项目 (61603182); 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.cn115989-20200107-00011

Evaluation of multi-classification method of color fundus photograph quality based on ResNet50-OC

Wan Cheng¹, Zhou Xueting¹, You Qijing¹, Shen Jianxin¹, Yu Qiuli²

¹College of Electronic Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China; ²Department of Ophthalmology, The Second Affiliated Hospital of Nanjing Medical University, Nanjing 210003, China

Corresponding author: Yu Qiuli, Email:15905192943@163.com

[Abstract] Objective To evaluate the efficiency of ResNet50-OC model based on deep learning for multiple classification of color fundus photographs. **Methods** The proprietary dataset (PD) collected in July 2018 in BenQ Hospital of Nanjing Medical University and EyePACS dataset were included. The included images were classified into five types of high quality, underexposure, overexposure, blurred edges and lens flare according to clinical ophthalmologists. There were 1 000 images (800 from EyePACS and 200 from PD) for each type in the training dataset and 500 images (400 from EyePACS and 100 from PD) for each type in the testing dataset. There were 5 000 images in the training dataset and 2 500 images in the testing dataset. All images were normalized and augmented. The transfer learning method was used to initialize the parameters of the network model, on the basis of which the current mainstream deep learning classification networks (VGG, Inception-resnet-v2, ResNet, DenseNet) were compared. The optimal network ResNet50 with best accuracy and Micro F1 value was selected as the main network of the classification model in this study. In the training process, the One-Cycle strategy was introduced to accelerate the model convergence speed to obtain the optimal model ResNet50-OC. ResNet50-OC was applied to multi-class

classification of fundus image quality. The accuracy and Micro F1 value of multi-classification of color fundus photographs by ResNet50 and ResNet50-OC were evaluated. **Results** The multi-classification accuracy and Micro F1 values of color fundus photographs of ResNet50 were significantly higher than those of VGG, Inception-resnet-v2, ResNet34 and DenseNet. The accuracy of multi-classification of fundus photographs in the ResNet50-OC model was 98.77% after 15 rounds of training, which was higher than 98.76% of the ResNet50 model after 50 rounds of training. The Micro F1 value of multi-classification of retinal images in ResNet50-OC model was 98.78% after 15 rounds of training, which was the same as that of ResNet50 model after 50 rounds of training. **Conclusions** The proposed ResNet50-OC model can be accurate and effective in the multi-classification of color fundus photograph quality. One-Cycle strategy can reduce the frequency of training and improve the classification efficiency.

[**Key words**] Artificial intelligence; Image quality classification; Convolutional neural network; One-Cycle learning; Color fundus photograph

Fund program: National Natural Science Foundation of China (61603182); Chinese Postdoctoral Science Foundation (2019M661832); Jiangsu Planned Projects for Postdoctoral Research Funds (2019K226); Jiangsu Province Advantageous Subject Construction Project

DOI:10.3760/cma.j.cn115989-20200107-00011

通过眼底图像筛查糖尿病视网膜病变 (diabetic retinopathy, DR) 等常见眼底疾病是基本且有效的方法^[1-2]。随着计算机辅助诊断 (computer-aided diagnosis, CAD) 技术的成熟和便携式眼底照相机的普及,许多智能眼病诊断系统已应用于各类眼底疾病的筛查^[3-5]。彩色眼底照片质量是眼底疾病筛查过程中的重要因素,低质量眼底照片会导致诊断系统的漏诊,甚至误诊。目前,对于眼底图像的质量分类均为优劣二分类^[6-7]。据调查,在眼底图像数据库中有超过 25% 的图像因质量差而不能进行医学诊断^[8];而在远程医疗中通过眼底照相机拍摄并上传至阅片平台的图像有近一半质量差^[9]。临床中低质量眼底图像主要分为曝光不足、曝光过度、边缘模糊和镜头反光 4 种类型。曝光不足彩色眼底照片的整体亮度低、难以识别血管及病灶;曝光过度眼底图像的对比度低、白色调严重;边缘模糊眼底图像的分辨率低、血管及视盘边界不清晰;镜头反光眼底图像有光斑,影响病变部位的诊断。与图像质量二分类相比,图像质量多分类使医生进一步明确低质量图像的类型,对后期及时修正拍摄错误并提高眼底图像质量有重要的指导意义,同时也为 CAD 提供质量可控的图像,提高疾病筛查的准确率。因此,眼底图像的质量优劣二分类已经不能满足目前 CAD 的要求,对图像质量进行多分类是必要且紧迫的任务。传统眼底图像质量分类方法主要参考 2 类参数:一是通用图像质量参数,如对比度、清晰度等;二是结构性质量参数,如视盘和黄斑的可见度等^[6-7,10-11]。

传统图像质量分类方法需要进行复杂且容易出错的解剖标志分割,并不能够反映影响图像质量的各种因素。近几年来,深度学习方法因其更高的准确性以及更好的鲁棒性被广泛应用于眼底图像分类。本研究拟设计一种基于深度学习的彩色眼底照片质量多分类方法,并对其效率进行评估。

1 材料与方法

1.1 材料

纳入 EyePACS^[12] 数据集和 PD (proprietary dataset) 数据集的彩色眼底照片。EyePACS 数据集是 Kaggle 在 2015 年举办的一个机器学习竞赛中使用的数据集,旨在为 DR 等级分类设计一种全面的眼底图像诊断系统,包含 88 702 张彩色眼底照片,其中训练集 35 126 张图像,测试集 53 576 张图像,图像的分辨率为 433×289~5 184×3 456,图像拍摄质量差异较大。PD 数据集由南京医科大学附属明基医院于 2018 年 7 月收集的眼底照片构成,图像分辨率为 1 620×1 444 像素。临床医生根据眼底图像的成像质量将其大致分为质量较好、曝光不足、曝光过度、边缘模糊和镜头反光 5 类 (图 1)。在多分类任务中,训练数量少的类别

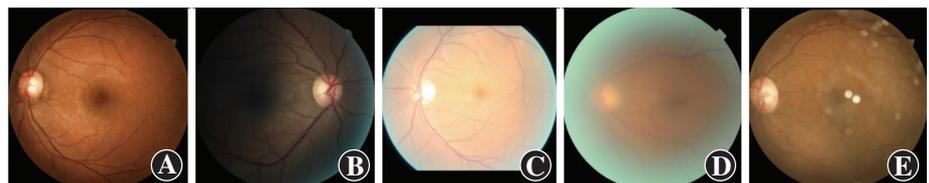


图 1 彩色眼底照片质量分类 A:质量较好 B:曝光不足 C:曝光过度 D:边缘模糊 E:镜头反光
Figure 1 Quality classification of color fundus photograph A:High quality B:Underexposure
C:Overexposure D:Blurred edges E:Lens flare

很难具有代表性,无法获得准确的分类结果。为使每一类数据都被充分考察,采用均衡数据训练多分类网络。在训练集中,每个类别包含 1 000 张图像,其中 800 张选自 EyePACS 数据集,200 张选自 PD 数据集。在测试集中,每个类别包含 500 张图像,其中 400 张选自 EyePACS 数据集,100 张选自 PD 数据集。训练集总计 5 000 张图像,测试集总计 2 500 张图像。数据集和训练集中眼底图像均由专业医生筛选足够数量并标注图像质量等级标签。将同时具有多种分类特征的彩色眼底照片分至多个对应类别进行训练。

1.2 方法

原始彩色眼底照片经过预处理后输入卷积神经网络(convolutional neural network, CNN),网络输出眼底照片质量的 5 分类预测结果。首先,将数据集内的彩色眼底照片进行归一化处理和数据扩增操作;然后,使用迁移学习的方法训练主流 CNN(VGG^[13]、GoogLeNet^[14]、ResNet^[15]、DenseNet^[16])对训练集图像进行质量分类,并从中选出分类性能最优的模型。在此基础上结合 One-Cycle 策略,使用先增再降的学习率训练网络,由此提出 ResNet50-OC 网络。最后,将经典 CNN 与 ResNet50-OC 网络的分类准确率、Micro F1 值以及训练轮数进行对比。基于深度学习的彩色眼底照片质量分类系统总体框架如图 2 所示。

1.2.1 眼底图像预处理 (1)归一化处理 图像输入 CNN 之前需对其尺寸进行归一化:①对不同眼底图像分别选取适当阈值(5~10)进行二值化,获得图像中的圆形区域半径 R;②对眼底图像进行裁剪,得到一个以圆形区域圆心为中心、边长为 2R 的正方形图像;③将得到的正方形眼底图像统一缩放至 512×512 分辨率(图 3A, B)。(2)数据扩增 数据扩增采用以下任意 2 种方法的组合:①对图像随机进行水平和垂直方向的翻转;②对图像进行随机角度旋转,旋转后的留白部分使用黑色像素点代替;③将图像随机放大 1~1.1 倍,再在放大的图像中随机截取原始图像大小的区域;④使用对数函数调整眼

底图像的亮度(图 3C)。对于上下被截断的不完整眼底图像,可先将裁减部分以黑色填充,再进行与完整眼底图像相同的裁剪缩放及数据扩增(图 3D~F)。

1.2.2 迁移学习 把主流 CNN 用于眼底照片质量多分类任务,不同的网络模型均使用 ImageNet 数据集上对应的预训练权重对其进行参数初始化。训练过程中采用学习率区间对网络进行微调操作,即对网络初始层采用较低的学习率,对网络输出全连接层采用较高的学习率^[17]。

1.2.3 分类模型的选择 权衡网络模型分类的准确性、模型参数数量和计算复杂度选择最适合的眼底照片质量分类网络模型。选择 5 种在当前分类任务中表现良好的网络模型(VGG19、Inception-Resnet-V2、ResNet34、ResNet50、DenseNet)进行对比实验。采用预训练模型对训练集图像进行分类,且对输入不同 CNN 模型的训练图像都进行相同的预处理和数据扩增,即在搭载 4 块具有 NVIDIA TITAN Xp 的工作站上用 PyTorch 框架进行所有训练和测试,每块 NVIDIA TITAN Xp 显卡具有 12 GB GPU 显存。

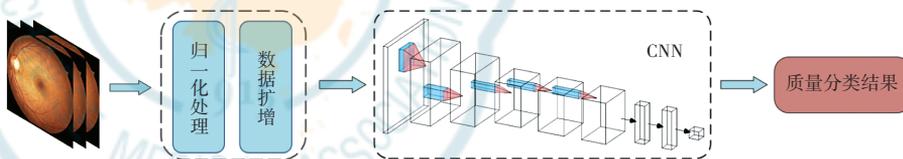


图 2 基于深度学习的彩色眼底照片质量分类流程图 CNN:卷积神经网络

Figure 2 Flow chart for color fundus photograph quality classification based on deep learning CNN:convolutional neural network

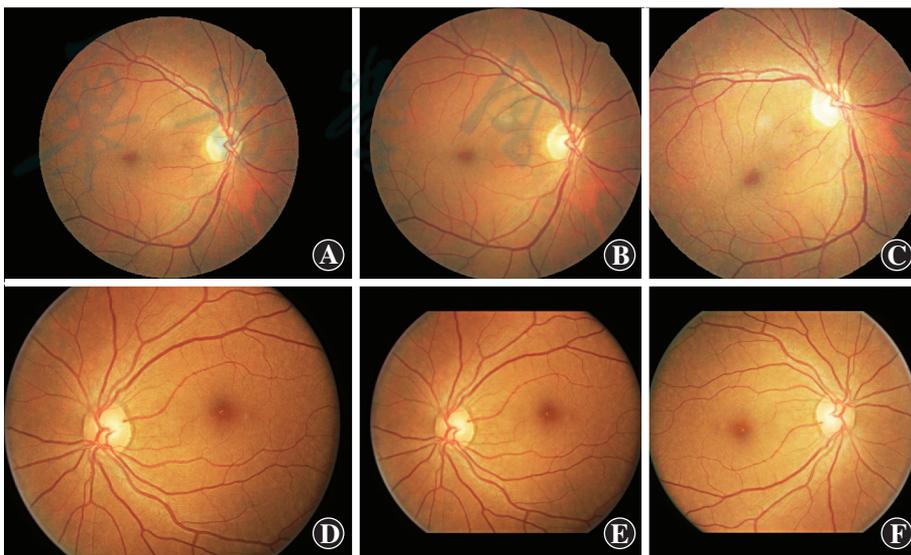


图 3 眼底图像预处理结果 A:完整眼底图像原图 B:图 A 裁剪和缩放 C:图 B 放大和旋转 D:不完整眼底图像原图 E:图 D 裁剪和缩放 F:图 E 翻转和亮度调整

Figure 3 Color fundus photograph preprocessing results A:Complete original fundus image B:Cropped and scaled image A C:Scaled and rotated image B D:Incomplete original fundus image E:Cropped and scaled image D F:Flipped image E with brightness adjusted

1.2.4 One-Cycle 策略 采用 One-Cycle 策略^[18]对 ResNet50 分类模型进行训练,训练过程中的最大学习率通过 Learning Rate Finder^[19]方法获得,从初始的小学习率开始训练,每个小批次后指数级提高学习率,直到网络训练过程的损失函数开始爆炸,选取损失函数爆炸前下降斜率最大的点作为最大学习率。在 One-Cycle 策略的最后阶段,再将学习率缓缓减小到 0,同时使动量的变化与学习率的变化相反,即在增加学习率的同时减少动量,在减少学习率的同时增加动量(图 4)。

1.2.5 评价指标 引入准确率和 Micro F1 值作为五分类网络的评价指标,对不同 CNN 的分类结果进行比较,并验证 One-Cycle 策略的有效性。在多分类任务中计算 Micro F1 需要统计各个类别的真阳性(true positive, TP)、假阳性(false positive, FP)和假阴性(false negative, FN)值。Micro F1 同时兼顾了分类模

型的精确率和召回率。准确率 = $\frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + \sum_{i=1}^n FN_i}$,其中 n

表示多分类任务的类别数量,本研究中 $n = 5$ 。Micro F1 = $2 \cdot \frac{P \cdot R}{P + R}$,其中 P 和 R 分别为分类的精确率和召

回率, $P = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + \sum_{i=1}^n FP_i}$, $R = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n TP_i + \sum_{i=1}^n FN_i}$ 。在

ResNet50-OC 和 ResNet50 的分类实验中采用 Epoch 表示网络从开始训练到最后拟合所需要的训练轮数。

2 结果

2.1 各 CNN 模型对眼底照片质量分类的效果

眼底照片质量五分类任务中,ResNet50 网络准确率和 Micro F1 值均最高,分别为 98.76% 和 98.78%,均高于其他 4 种 CNN 模型(表 1)。因此选择 ResNet50 作为本次彩色眼底照片质量分类研究的主网络。

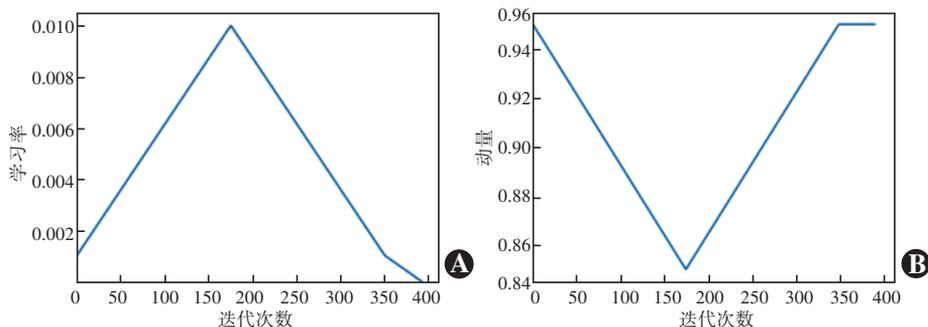


图 4 学习率及动量随迭代次数变化示例 A:学习率的变化 B:动量的变化
Figure 4 Examples of learning rate and momentum changing with the number of iterations
A: Changes in the learning rate B: Changes in the momentum

表 1 不同 CNN 模型在彩色眼底照片质量五分类任务中的效果(%)

Table 1 Results of different CNN models in classification tasks of five types of color fundus photograph quality (%)

CNN 模型方法	准确率	Micro F1
VGG19	93.15	93.22
InceptionResnet-V2	97.11	97.23
ResNet34	96.53	96.56
ResNet50	98.76	98.78
DenseNet	96.99	97.01

注:CNN:卷积神经网络
Note:CNN:convolutional neural network

2.2 ResNet50-OC 和 ResNet50 网络分类效果评估

ResNet50 网络在 50 轮训练后准确率为 98.76%, Micro F1 值为 98.78%。引入 One-Cycle 策略的 ResNet50-OC 网络 15 轮训练后准确率达 98.77%,稍高于 ResNet50 网络, Micro F1 值与 ResNet50 网络相同(表 2)。

表 2 ResNet50-OC 和 ResNet50 网络分类效果
Table 2 Classification results of ResNet50-OC and ResNet50 networks

分类模型方法	Epoch(轮数)	准确率(%)	Micro F1(%)
ResNet50	50	98.76	98.78
ResNet50-OC	15	98.77	98.78

3 讨论

彩色眼底照片是筛查和诊断眼底疾病的关键,诊断的效果在很大程度上取决于图像的质量。本研究采用深度学习 ResNet50-OC 模型实现对彩色眼底照片的质量分类。质量较好的图像可以直接用于医生或眼科

智能诊断系统进行疾病筛查、病种分类、病变分级等医学诊断。对部分低质量类型的图像进行对应处理可提高图像质量,从而获得能够诊断的图像,如提高曝光不足图像的亮度和对比度,降低曝光过度图像的亮度并提高其对比度,对边缘模糊的图像进行锐化处理;对于严重影响质量的图像,如屈光介质混浊导致的眼底图片模糊、部分病灶区域被镜头

反光光斑覆盖的图像,需及时反馈医师进行重新拍摄。通过本研究的彩色眼底照片质量多分类反馈信息,医生可即时掌握照片质量信息,根据低质量照片的分类对眼底照相机操作和设置做出调整,避免更多低质量眼底照片的产生,有效提高图像的质量和诊断效率,对缺乏高性能智能诊断系统的基层医院有重要意义。在 CAD 系统前可以引入彩色眼底照片质量多分类网络并对不同质量的照片进行相应的预处理。将预处理后的眼底照片送入 CAD 进行诊断可以排除照片质量对诊断的干扰,提高诊断的准确率,降低漏诊率和误诊率。

本研究使用的深度学习方法可以在深层的 CNN 中提取图像潜在的高级特征,避免了传统方法中结构特征的手工设计。本研究对比当前深度学习主流分类网络,最终选择准确率和 Micro F1 表现优越的 ResNet50 作为眼底图像质量五分类网络。本研究采用迁移学习方法把预训练的网络参数用于本研究中模型训练的初始化,避免了大量标记工作的同时使分类模型具有更优越的性能。在深度学习网络模型的训练过程中,学习率、动量和权重衰减率是至关重要的超参数。本研究采用 One-Cycle 策略在训练过程中使用先升再降的学习率。对比引入 One-Cycle 策略前后 ResNet50 网络,即 ResNet50 和 ResNet50-OC 的训练过程,可以看到 One-Cycle 策略大大加快了网络的训练速度。

本研究选择的网络和使用方法仍存在许多可以改进的地方。我们接下来可以尝试使用更加简洁的网络框架,如 MobilNet 等轻量级模型,在保障分类准确率的同时大幅度降低模型运行的硬件成本,使分类模型可以更加广泛地应用到各种不同的设备上,包括但不限于手持眼底照相机等便携设备。我们还可以尝试更多的训练参数调节技巧,在加速网络训练的同时尝试提高网络的分类性能,得到各方面更优的眼底图像多分类模型。

综上所述,本研究提出了一种 CNN 的彩色眼底照片质量五分类方法。本研究以迁移学习方法为基础,用 ResNet50 网络实现图像的五分类并在准确率和 Micro F1 指标上取得了优越的表现,并在训练过程中引入 One-Cycle 策略、切片学习率等方法通过修改学习率、动量和权重衰减率等因素得到最适于眼底图像质量分类的 ResNet50-OC 网络模型。实验结果验证了使用 One-Cycle 策略优化的网络模型在训练过程中可以更快达到拟合,且在分类性能上表现更优,能够更加准确地对眼底图像的质量做出分类。然而,本研究仍

然存在一些不足之处,如根据单次实验结果选择模型具有一定的不确定性,后期可以尝试多次实验得出 95% 的置信区间或设置随机数生成器使同样数据训练同一网络时得到稳定的结果。

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] 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.2095-0160.2019.08.009.
Wan JL, Hu JB, Jin WD, et al. Fundamental screening and classification of diabetic retinopathy with visual attention [J]. Chin J Exp Ophthalmol, 2019, 37(8): 630-637. DOI: 10.3760/cma.j.issn.2095-0160.2019.08.009.
- [2] Li X, Hu X, Yu L, et al. CANet: cross-disease attention network for joint diabetic retinopathy and diabetic macular edema grading [J]. IEEE Trans Med Imaging, 2020, 39(5): 1483-1493. DOI: 10.1109/TMI.2019.2951844.
- [3] Gargeya R, Leng T. Automated identification of diabetic retinopathy using deep learning [J]. Ophthalmology, 2017, 124(7): 962-969. DOI: 10.1016/j.ophtha.2017.02.008.
- [4] Chalakkal RJ, Abdulla WH, Thulaseedharan SS. Quality and content analysis of fundus images using deep learning [J]. Comput Biol Med, 2019, 108: 317-331. DOI: 10.1016/j.combiomed.2019.03.019.
- [5] 万程,游齐靖,孙晶,等.基于 FA-Net 的视网膜眼底图像质量评估[J].中华实验眼科杂志,2019,37(8):608-612. DOI:10.3760/cma.j.issn.2095-0160.2019.08.004.
Wan C, You QJ, Sun J, et al. Evaluation of retinal fundus image quality based on FA-Net [J]. Chin J Exp Ophthalmol, 2019, 37(8): 608-612. DOI: 10.3760/cma.j.issn.2095-0160.2019.08.004.
- [6] Wang S, Jin K, Lu H, et al. Human visual system-based fundus image quality assessment of portable fundus camera photographs [J]. IEEE Trans Med Imaging, 2016, 35(4): 1046-1055. DOI: 10.1109/TMI.2015.2506902.
- [7] Niemeijer M, Abramoff MD, van Ginneken B. Image structure clustering for image quality verification of color retina images in diabetic retinopathy screening [J]. Med Image Anal, 2006, 10(6): 888-898. DOI: 10.1016/j.media.2006.09.006.
- [8] 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 [2019-12-16]. <http://www.ncbi.nlm.nih.gov/pubmed/26000792>. DOI: 10.1371/journal.pone.0127914.
- [9] 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.
- [10] Abdel-Hamid L, El-Rafei A, El-Ramly S, et al. Performance dependency of retinal image quality assessment algorithms on image resolution: analyses and solutions [J]. Signal Image Video P, 2017, 12(1): 9-16. DOI: 10.1007/s11760-017-1124-5.
- [11] Shen Y, Sheng B, Fang R, et al. Domain-invariant interpretable fundus image quality assessment [J/OL]. Med Image Anal, 2020, 61: 101654 [2021-07-27]. <http://www.ncbi.nlm.nih.gov/pubmed/32066065>. DOI: 10.1016/j.media.2020.101654.
- [12] 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.
- [13] Ardakani A, Condo C, Ahmadi M, et al. An architecture to accelerate

convolution in deep neural networks [J]. IEEE T CIRCUITS- I , 2018, 65(4) : 1349-1362. DOI:10. 1109/tcsi. 2017. 2757036.

[14] 彭冬亮, 王天兴. 基于 GoogLeNet 模型的剪枝算法 [J]. 控制与决策, 2019, 34(6) : 1259-1264. DOI:10. 13195/j. kzyjc. 2017. 1556.

Peng DL, Wang TX. Pruning algorithm based on GoogLeNet model [J]. Control Decision, 2019, 34(6) : 1259-1264. DOI:10. 13195/j. kzyjc. 2017. 1556.

[15] Zhang K, Sun M, Han TX, et al. Residual networks of residual networks; multilevel residual networks [J]. IEEE T Circ Syst Vid, 2018, 28(6) : 1303-1314. DOI:10. 1109/tcsvt. 2017. 2654543.

[16] Wen R, Fu K, Sun H, et al. Image super-resolution using densely connected residual networks [J]. IEEE Signal Proc Let, 2018, 25(10) : 1565-1569. DOI:10. 1109/LSP. 2018. 2861989.

[17] Pan SJ, Tsang IW, Kwok JT, et al. Domain adaptation via transfer

component analysis [J]. IEEE Trans Neural Netw, 2011, 22(2) : 199-210. DOI:10. 1109/TNN. 2010. 2091281.

[18] Smith LN. A disciplined approach to neural network hyper-parameters: part I—learning rate, batch size, momentum, and weight decay [J/OL]. arXiv, 2018 : 1803. 09820 [2020-12-01]. https://arxiv.org/abs/1803. 09820.

[19] Wang J, Yang J, Wu W. Convergence of cyclic and almost-cyclic learning with momentum for feedforward neural networks [J]. IEEE Trans Neural Netw, 2011, 22(8) : 1297-1306. DOI:10. 1109/TNN. 2011. 2159992.

(收稿日期:2020-12-07 修回日期:2021-07-28)

(本文编辑:张宇)

· 病例报告 ·

成人 Still 病伴双眼类远达性视网膜病变诊疗 1 例

成拾明¹ 张翼² 阮坤炜¹ 王玲丽¹ 张勇¹

¹十堰市太和医院眼科中心,湖北省十堰市 442000; ²湖北省竹山县人民医院眼科,湖北省竹山县 442200

通信作者:张勇, Email: inforzy@163. com

基金项目:湖北省卫生厅面上项目(WJ2019M056);湖北省十堰市科技局指导项目(B2016115)

Diagnosis and treatment of adult-onset Still's disease with binocular Purtscher's-like retinopathy: a case report

Cheng Shiming¹, Zhang Yi², Ruan Kunwei¹, Wang Lingli¹, Zhang Yong¹

¹Taihe Hospital Eye Center, Shiyan 442000, China; ²Department of Ophthalmology, Zhushan People's Hospital, Zhushan County 442200, China

Corresponding author: Zhang Yong, Email: inforzy@163. com

Fund program: General Program of Hubei Provincial Department of Public Health (WJ2019M056);

Guidance Project of Shiyan Science and Technology Bureau (B2016115)

DOI:10. 3760/cma. j. cn115989-20190725-00325

患者女, 26 岁, 因双眼视物模糊半月余于 2015 年 8 月 28 日到十堰市太和医院眼科中心就诊。患者生命体征稳定, 全身皮肤黏膜未见明显皮疹及出血点, 全身浅表淋巴结触诊未发现明显肿大, 无明显关节肿痛及畸形。眼科专科检查: 视力右眼为 0.04, 左眼为 0.4, 均矫正无提高; 眼压右眼为 17 mmHg (1 mmHg=0.133 kPa), 左眼为 14 mmHg; 双眼前节未见明显异常, 双眼视盘边界清、色正, 视盘周围可见较多大小不一的棉絮斑, 累及黄斑区, 可见多个小火焰状视网膜出血灶(图 1)。既往史: 发病前持续高热(体温>39℃)约 2 周, 静脉滴注抗生素无效, 加用糖皮质激素后缓解; 3 个月前因全身四肢近端肌群, 双侧肘关节、肩关节、髋关节、膝关节呈持续性酸胀、闷胀样疼痛 5 d 曾就诊于十堰市太和医院疼痛科治疗, 病程中出现咽痛、荨麻疹; 否认食物、药物过敏史。既往全身检查: 血液 C 反应蛋白浓度为 68.0 mg/L, 红细胞沉降率为 28 mm/h (↑), 白细胞计数为 26.2×10⁹/L (↑), 中性粒细胞百分比为 87.3%; HLA-B27(-)、类风湿因子(-)、抗中性粒细胞胞浆抗体(-)、自身抗体谱(-); 胸部和骨盆 CT 未见异常, 心脏

彩色超声未见异常。诊断为双眼类远达性视网膜病变, 并收治入院。入院后眼底荧光素血管造影(fundus fluorescein angiography, FFA)检查显示双眼部分视网膜小动脉阻塞, 考虑为视网膜血管炎(图 2)。入院当天检查白细胞计数 16.8×10⁹/L, 中性粒细胞百分比为 82.6%, 给予患者糖皮质激素静脉滴注治疗; 入院后第 2 天检查红细胞沉降率为 35 mmol/L; 入院后第 3 天检查血清铁蛋白浓度>1650 μg/L、人类免疫缺陷病毒抗体(-)、丙型肝炎抗体(-)、梅毒螺旋体抗体(-)、类风湿因子(-)、自身抗体谱(-)、抗中性粒细胞胞浆抗体(-), 肝肾功能检查(-)、抗心磷脂抗体(-); 入院后第 6 天, 骨髓穿刺检查示增生性骨髓像, 上腹部 CT 显示肝右叶胆管结石或钙化灶、脾

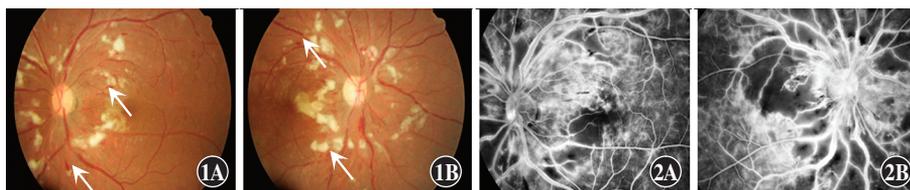


图 1 患者初诊时双眼彩色眼底照相 可见视盘周围较多棉絮斑并累及黄斑区, 多个火焰状小视网膜出血灶(白色箭头) A:左眼 B:右眼 图 2 患者入院后双眼眼底 FFA 图 双眼视网膜血管多处无灌注区、小片荧光遮蔽, 絮状荧光, 视网膜血管管壁部分荧光染色, 视盘荧光增强 A:左眼 B:右眼