



计算机科学

COMPUTER SCIENCE

基于注意力机制的糖尿病视网膜病变分类算法

孙福权, 邹彭, 崔志清, 张琨

引用本文

孙福权, 邹彭, 崔志清, 张琨. 基于注意力机制的糖尿病视网膜病变分类算法[J]. 计算机科学, 2022, 49(11A): 211000213-5.

SUN Fu-quan, ZOU Peng, CUI Zhi-qing, ZHANG Kun. [Classification Algorithm of Diabetic Retinopathy Based on Attention Mechanism](#) [J]. Computer Science, 2022, 49(11A): 211000213-5.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[云中满足截止时间约束且优化成本的工作流调度策略](#)

Workflow Scheduling Strategy for Deadline Constrained and Cost Optimization in Cloud
计算机科学, 2022, 49(11A): 210800154-6. <https://doi.org/10.11896/jsjcx.210800154>

[基于差分进化算法的字符对抗验证码生成方法](#)

Adversarial Character CAPTCHA Generation Method Based on Differential Evolution Algorithm
计算机科学, 2022, 49(11A): 211100074-5. <https://doi.org/10.11896/jsjcx.211100074>

[融合多层次视觉信息的人物交互动作识别](#)

Human-Object Interaction Recognition Integrating Multi-level Visual Features
计算机科学, 2022, 49(11A): 220700012-8. <https://doi.org/10.11896/jsjcx.220700012>

[基于注意力机制的手写体数字识别](#)

Handwritten Digit Recognition Based on Attention Mechanism
计算机科学, 2022, 49(11A): 211100009-5. <https://doi.org/10.11896/jsjcx.211100009>

[融合ViT卷积神经网络的木板表面缺陷识别](#)

Wood Surface Defect Recognition Based on ViT Convolutional Neural Network
计算机科学, 2022, 49(11A): 211100090-6. <https://doi.org/10.11896/jsjcx.211100090>

基于注意力机制的糖尿病视网膜病变分类算法

孙福权¹ 邹彭^{1,2} 崔志清^{1,2} 张琨¹

¹ 东北大学秦皇岛分校数学与统计学院 河北 秦皇岛 066000

² 东北大学信息科学与工程学院 沈阳 110000

(zpp17853266007@163.com)

摘要 糖尿病视网膜病变是糖尿病的重要并发症之一,是工作人群失明的主要原因。视网膜图像类间差距小,易混淆,由于医疗资源不足和缺乏有经验的眼科医生,难以进行大规模的视网膜图像筛查。为此,提出了一种基于注意力机制的糖尿病视网膜病变分类算法,实现对视网膜图像病变程度的精确分类。对数据集进行数据增强和图像增强等预处理操作,利用 Efficient-NetV2 作为主干分类网络,在网络中加入注意力机制对视网膜图像进行细粒度分类,同时采用迁移学习策略对网络进行训练。所提算法的分类准确率和二次加权 Kappa 值分别为 97.8% 和 0.843,能够有效地对视网膜图像进行病变程度分类,与其他模型相比具有优越性,对于糖尿病视网膜病变的诊断和治疗具有重要意义。

关键词 深度学习;糖尿病视网膜病变分类;注意力机制;数据预处理;迁移学习

中图分类号 TP393

Classification Algorithm of Diabetic Retinopathy Based on Attention Mechanism

SUN Fu-quan¹, ZOU Peng^{1,2}, CUI Zhi-qing^{1,2} and ZHANG Kun¹

¹ School of Mathematics and Statistics, Northeastern University at Qinhuangdao, Qinhuangdao, Hebei 066000, China

² School of Information Science and Engineering, Northeastern University, Shenyang 110000, China

Abstract Diabetic retinopathy is one of the important complications of diabetes and the main cause of blindness in the working population. The gap between retinal images is small and easy to be confused. Due to insufficient medical resources and lack of experienced ophthalmologists, it is difficult to carry out large-scale retinal image screening. Therefore, a classification algorithm for diabetic retinopathy based on attention mechanism is proposed to achieve accurate classification of the degree of retinal image lesions. The preprocessing operations such as data enhancement and image enhancement are carried out on data set. Using Efficient-NetV2 as the backbone classification network, the attention mechanism is added to the network for fine-grained classification of retinal images, and the transfer learning strategy is used to train the network. The classification accuracy and the second weighted Kappa value of the proposed model are 97.8% and 0.843 respectively, which can effectively classify the disease degree of retinal images. Compared with other models, it has advantages and is of great significance for the diagnosis and treatment of diabetic retinopathy.

Keywords Deep learning, Classification of diabetic retinopathy, Attention mechanism, Data preprocessing, Transfer learning

1 引言

糖尿病视网膜病变简称糖尿病(Diabetic Retinopathy, DR),是糖尿病的重要并发症之一,也是导致工作人群失明人数攀升的主要原因^[1]。根据国家卫生计生委疾病预防控制中心的数据显示,我国现已成为全球患糖尿病人数最多的国家,调查显示,约 1/3 的糖尿病患者会发生糖尿病视网膜病变,糖尿病是导致不可逆转性失明的主要因素^[2]。目前糖尿病的临床诊断检查主要是眼科医生根据眼底视网膜图像中的病变特征信息对病变进行诊断^[3]。通过早期对视网膜图像进行筛查和诊治,可以有效避免糖尿病病的进一步恶化而最终导致失明的严重后果。但是,我国部分地区医疗资源匮乏,缺少专业的眼科医生,无法进行大规模的眼底图像筛查,这将导致糖尿病

患者无法了解自身的病变情况,不能进行及时的诊断和治疗。糖尿病视网膜病变分类算法可以对病变程度进行准确的分类,辅助医生进行大规模的视网膜图像筛查和诊治,对于糖尿病的早期诊断和治疗具有重要意义。

国际眼科协会将糖尿病视网膜病变程度分为 5 个类别,分别为正常、轻度非增殖性病变、中度非增殖性病变、重度非增殖性病变和增殖性病变。不同的病变等级存在不同的病体特征,用于判断眼底图像的病变程度类别。每个类别中的病变特征不会单一出现,具有较高的重叠性和反复率,这为分类任务带来了较大的挑战,需要对眼底图像中最具代表性的病变特征进行提取用于眼底图像的分类^[4-6]。目前,针对糖尿病视网膜病变分类,主要有以下两种方法:1)基于传统机器学习的方法。该方法通过图像预处理分割出眼底图像中的病变

基金项目:国家重点研发计划(2018YFB1402800);河北省高教研究与实践项目(2018GJJG422)

This work was supported by the National Key R & D Program of China(2018YFB1402800) and Hebei Higher Education Research and Practice Project(2018GJJG422).

通信作者:邹彭(zpp17853266007@163.com)

区域,将人工设计的图像特征输入到分类器(如 SVM^[7-8])中进行病变分类。但这种方法需要人工提取特征,易受到操作者的专业能力的影响,成本高且易出错,同时建立在手工特征基础上的模型泛化性不足。2)基于深度学习的方法。这种方法不需要手工特征提取,将大量的眼底图像输入到网络中,根据标签值和预测值之间的误差进行反向传播自动更新权重参数,实现端到端的分类。Pratt 等^[9]基于经典的 VGG^[10]网络结构,提出了一种端到端的糖尿病视网膜病变分类方法,取得了准确率为 75% 的成绩。Ding 等^[11]在 AlexNet 模型的基础上进行改进,搭建了 CompactNet 模型,用于病变分类,准确度为 69%,较 AlexNet 模型的 62% 有所提升。Arkadiusz 等^[12]在 VGG16 网络的基础上进行了算法优化改进,增加了迁移学习,搭建 VGG-D 模型,取得了较好的分类效果,准确度为 82%。上述方法虽然能够实现糖尿病视网膜病变的分类,但分类准确率仍有待进一步提升。视网膜图像病变类别之间差别细微,拍摄环境和手法的不同会导致同类差异较大,类间差异较小,属于细粒度分类问题,需要对病变特征进行更准确有效的提取。本文使用注意力机制来对局部区域的病变特征进行准确有效的提取。Wang 等^[13]和 Zhao 等^[14]分别在 Zoom-in-net 和 BiRA-Net 中也采用了注意力机制,但只是针对空间的,在空间上使需要关注的像素点拥有较高的权重,但是忽视了通道注意力,对每一层通道都进行相同的处理。事实上,每一层通道所包含的信息是不同的。基于上述不足,本文提出了一种空间注意力与通道注意力相结合的混合注意力机制,从特征图的全局特征中进一步锁定关键的局部特征,实现对视网膜图像的细粒度分类以提高分类准确度。另外还引入迁移学习来解决医疗图像中高质量且有标签的图像数量不足的问题,探索研究不同的迁移学习策略对模型性能的影响,同时还采用了数据增强技术来降低过拟合的风险,引入多种改进策略来提高网络的分类准确度。工作流程图如图 1 所示。




图 1 工作流程图
Fig. 1 Work flow chart




图 4 本文模型的网络结构
Fig. 4 Network structure of the proposed model

注意力机制能够以低权重忽略非重点信息,以高权重聚焦重要信息,具有很高的可扩展性和鲁棒性^[17],可以从特征图的全局特征中进一步锁定关键的局部特征,进而解决眼底图像多分类中类间差距小、易混淆的问题。

2 网络结构

在分类主干网络的选择上,本文综合考虑了网络结构、参数数量、训练速度、分类性能等因素,选取 EfficientNetV2^[15]作为基础模型,其结构图如图 2 所示。EfficientNetV2 在 EfficientNetV1^[16]的基础上进行了改进,在网络的浅层中使用深度可分离卷积(Depthwise Convolutions)训练速度会很慢,因此将浅层的 MBConv 结构替换为 Fused-MBConv 结构,其结构如图 3 所示。Fused-MBConv 将原来的 MBConv 结构中的 1×1 卷积和 3×3 的深度可分离卷积替换成一个普通的 3×3 卷积,以提升网络的训练速度。EfficientNetV2 将 EfficientNetV1 中的 5×5 卷积都替换为 3×3 卷积,使用更小的膨胀系数减少内存访问开销。同时针对训练图像的尺寸对训练模型的效率有很大影响,采用了渐进学习策略,在训练早期使用较小的训练尺寸以及较弱的正则方法,这样网络可以快速学习到一些简单的表达能力,然后逐渐增大尺寸,同时增强正则方法,可以有效提升训练速度并且能小幅提升准确度。本文以 EfficientNetV2 为基础模型,提出了一种基于注意力机制的糖尿病视网膜病变分类算法,改进后的网络架构如图 4 所示。




图 2 EfficientNetV2 网络结构

Fig. 2 Network structure of EfficientNetV2

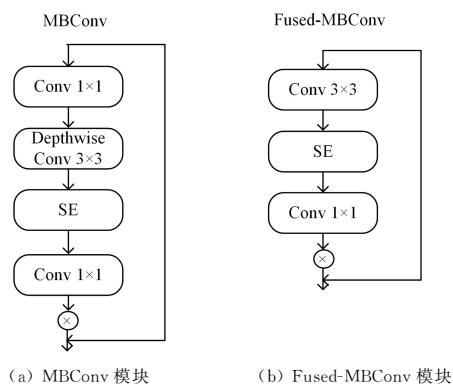


图 3 卷积模块

Fig. 3 Convolution block

本文在主干网络和全局均值池化之间加入了注意力机制模块,因为若在主干网络内部的每个卷积模块后都引入注意力机制,不仅会造成训练参数的增加,还会出现预训练参数无法导入的问题,进而导致网络模型在训练过程中难以收敛,

影响网络模型的准确度。本文引入的注意力模块包括通道注意力机制和空间注意力机制,其结构如图 5 所示。通道注意力机制通过全局平均池化和全局最大池化对特征图进行压缩,共享多层感知机的有效权重。多层感知机由输入层、隐藏层和输出层构成,隐藏层用于特征降维,最后以逐个元素相加的方式对多层共享感知机输出的两个向量进行合并,合并后的向量被 Sigmoid 进行归一化操作得到注意力张量。通道注意力机制可以通过训练得到表示通道重要性的权重向量,进而实现对重要通道的重点关注。空间注意力机制对输入的特

征图进行均值池化和最大池化操作,然后将两个结果进行拼接,通过卷积进行降维操作,降维后的张量通过 Sigmoid 进行归一化得到注意力张量。空间注意力机制可以加强网络模型对重要位置的聚焦能力。但是,通道注意力机制和空间注意力机制都只会关注相应维度上的重要特征,从而导致网络对重要特征的关注能力有限。针对这个问题,本文采用混合注意力机制,将通道注意力机制与空间注意力机制相结合,使主干网络具备从全局特征中关注更重要的局部特征的能力,其结构如图 6 所示。





图 5 注意力机制

Fig. 5 Attention mechanism




图 6 混合注意力机制

Fig. 6 Mixed attention mechanism

针对带有标签的高质量医学图像数量较少的问题,本文采用了迁移学习。迁移学习作为一种机器学习范式,能够利用从其他应用场景中学习的知识去提升目标场景的网络模型性能。本文主要通过实验来研究基于整体微调和基于特征

提取的迁移学习方法对模型分类性能的影响。

3 实验设置

3.1 数据集

本文使用的糖尿病视网膜图像数据集来自 2019 年 Kaggle 比赛官网数据集¹⁾,该数据集包含训练集和测试集,共 5 590 张糖尿病视网膜图像,图像的标签由专业人员标注,0 表示正常,1 表示轻度病变,2 表示中度病变,3 表示重度病变,4 表示增殖性病变,如图 7 所示。由于测试集的标签并未给出,因此本文采用训练集数据用于网络的训练和测试,数据分布如表 1 所列。




图 7 糖尿病视网膜图像

Fig. 7 Diabetic retina images

表 1 原始数据分布

label	DR 程度	number
0	健康	1 710
1	轻度病变	344
2	中度病变	906
3	重度病变	181
4	增殖性病变	267

3.2 数据预处理

在计算机视觉领域中,数据预处理起着非常重要的作用,尤其是在医学图像分析中,多余的信息与不准确的数据可能导致模型的性能不佳。我们对获得的数据集进行了以下预处理操作:数据筛选,数据增强和图像增强。

首先,对数据集中的图像进行数据筛选,去除存在曝光、信息丢失和光照不均等严重缺损的图像。由于数据集中各

样本分布不均衡,为防止在训练过程中出现过拟合现象,我们采用数据增强技术^[18]。数据增强是对数据进行缩放、翻转、旋转等操作,本文采用了裁剪、随机旋转和随机翻转 3 种类型的增强方法。数据增强后的分布如表 2 所列。

表 2 增强后的数据分布

label	DR 程度	number
0	健康	1 710
1	轻度病变	1 967
2	中度病变	1 812
3	重度病变	2 074
4	增殖性病变	2 072

由于图像实际拍摄的设备、手法不同,因此图像的尺寸、颜色、亮度也各不相同,直接使用原图进行训练会增加网络的训练难度,不容易找到病变特征。本文对数据集中的图像

¹⁾ <http://www.kaggle.com>

进行了图像增强。首先,以眼球半径为基准,对图像进行重新缩放;然后对图像进行高斯滤波,增强图像特征;最后去除图像中的边界区域,防止不是病理特征的边缘信息对分类模型的学习造成影响。预处理后的图像如图 8 所示。




图 8 预处理前后的视网膜图像

Fig. 8 Diabetic retinal images before and after pretreatment

3.3 损失函数

损失函数是用来衡量真实值与预测值之间的差异程度,损失函数越小,模型的预测值就越接近真实值。在本文的实验中,采用交叉熵损失函数作为分类任务中的损失函数,交叉熵是常用的分类任务中的损失函数,其表达式如式(1)所示:

$$H(p, q) = - \sum_{i=1}^n p(x_i) \log(q(x_i)) \quad (1)$$

其中, x_i 表示某个分类样本, $p(x_i)$ 表示该样本的真实值, $q(x_i)$ 表示该样本的预测值。

3.4 评价指标

由于本文使用的数据集是 kaggle 比赛数据集,因此本文使用两种评价指标来评估模型的性能,分别是准确率(Accuracy, Acc)和加权 Kappa 值,各项评价指标定义如下:

$$Acc = \frac{TP + TN}{TP + FN + TN + FP} \quad (2)$$

其中, TP 表示真阳性, TN 表示真阴性, FP 表示假阳性, FN 表示假阴性。

Kappa 系数是评价诊断一致性程度的重要指标,主要分为简单 Kappa 和加权 Kappa 两种。本文采用平方加权 Kappa 系数来作为评价指标,其计算式如下:

$$K = 1 - \frac{\sum_{i,j} w_{i,j} \mathbf{O}_{i,j}}{\sum_{i,j} w_{i,j} \mathbf{E}_{i,j}} \quad (3)$$

$$\mathbf{E}_{i,j} = (\sum_j \mathbf{O}_{i,j}) \times (\sum_j \mathbf{O}_{i,j})^T \quad (4)$$

$$W_{i,j} = \frac{(i-j)^2}{(N-1)^2} \quad (5)$$

假设 N 为类别数, $\mathbf{O}_{i,j}$ 和 $\mathbf{E}_{i,j}$ 均为 $N \times N$ 的矩阵,其中 $\mathbf{O}_{i,j}$ 中的每个元素表示将类别 i 预测为类别 j 的样本数量。 w 为惩罚矩阵,其中的每个元素表示将类别 i 预测为 j 的惩罚权重值,当预测正确时,权重值为 0;当预测错误时,随着类别之间距离的增大,权重值也会增大。

4 实验结果与分析

本文的实验在 Intel Core i7-7800X CPU、251 G 内存、NVIDIA GeForce RTX 2080Ti 显卡的 Ubuntu 16.04 服务器上进行调试,使用的框架为 Pytorch。为了保证实验结果的公平性,所有的实验均在相同设置下进行。

本文的算法是基于 EfficientNetV2 网络的改进,采用了注意力机制、迁移学习以及数据增强多种改进策略,能够有效地提高网络对糖尿病视网膜病变程度的分类准确度。为了证明所选用模型的有效性,我们将 EfficientNetV2 与其他主流分类网络进行对比实验,实验结果如表 3 所列。

表 3 模型对比

Table 3 Model comparison

(单位: %)

Model	Acc
Xception	91.32
ResNet101V2	88.00
EfficientNet	95.80
EfficientNetV2	97.00

从表 3 可以看出, EfficientNetV2 的准确率优于其他模型,证明了本文选用的网络适用于糖尿病视网膜病变分类任务。

为了证明引入注意力机制能够提高网络的分类准确度,本文进行了对比试验,在网络中加入注意力机制,实验结果如表 4 所示。在网络中加入注意力机制后,将通道注意力与空间注意力相结合,对局部的病变特征进行更准确有效的提取,模型的分类准确率均有所提升。通过表 3 和表 4 的对比能够证明在网络中引入注意力机制的有效性。

表 4 注意力机制对模型准确度的影响

Table 4 Influence of attention mechanism on accuracy of model

(单位: %)

Model	Acc
Xception + Attention	91.89
ResNet101V2 + Attention	89.44
EfficientNet + Attention	97.20
EfficientNetV2 + Attention	97.80

为了验证基于特征提取和整体微调的不同迁移学习策略对网络性能的影响,我们进行了对比实验。基于特征提取的迁移学习策略是冻结网络除最后一个卷积层和全连接层外的所有卷积层的权重,只重新训练最后一个 1×1 卷积层和全连接层。基于整体微调的迁移学习策略是不冻结网络卷积层的权重,利用网络的预训练权重代替随机初始化来对网络的所有层进行微调。实验结果如表 5 所示。从表中可以看出,基于整体微调的迁移学习策略效果更好。

表 5 不同迁移学习策略对模型的影响

Table 5 Influence of different transfer learning strategies on

model

Method	Acc/%	Kappa
EfficientNetV2 + attention + 特征提取	81.4	0.772
EfficientNetV2 + attention + 整体微调	97.8	0.843

为证明所提方法在糖尿病视网膜病变分类任务中的有效性,本文与 Wang 等^[19]的结果进行了对比。Wang 等利用卷积神经网络提取视网膜图像特征,然后利用提升树(Boosting Tree)算法进行预测。结果如表 6 所列,本文提出的方法在各个类别的分类准确度上均有所提高。同时与现有的其他五分类方法进行对比,结果如表 7 所列。Doshi 等^[20]根据病情的严重程度将视网膜影像划分为 5 个等级,利用深度卷积神经网络来实现 DR 智能诊断; Zhou 等^[21]将高分辨率眼底图像通过深度神经网络进行训练,通过多单元结构节省训练时间,提出了一种多任务学习策略来考虑不同病变等级影像之间的关系; IBM 通过深度学习算法对眼底图像的病变区域进行识别并评估病变的严重程度。从表 7 可以看出,本文方法的准确率和 Kappa 值相比上述方法均有所提升。

表6 本文方法与Wang等对五分类DR的分类准确率

Table 6 Classification accuracy of methods of Wang and ours for five-class DR

Method	R0	R1	R2	R3	R4
Wang et al.	0.920	0.700	0.640	0.670	0.690
Proposed Method	0.968	0.854	0.885	0.761	0.844

表7 本文方法与其他五分类方法的比较

Table 7 Comparison between the proposed method and other classification methods

Model	Acc/%	Kappa
Zhou et al.	—	0.841
Doshi et al.	—	0.386
IBM	86.0	—
Proposed Method	97.8	0.843


结束语 本文提出了一种融合注意力机制和迁移学习的EfficientNetv2分类算法用于糖尿病视网膜病变程度分类,在Kaggle竞赛数据上验证了模型的有效性。由于数据集中各类别之间分布不均衡,在训练中容易造成过拟合,本文采用了数据增强方法对各个类别的数据进行了均衡化处理。针对视网膜图像类间差距小、易混淆的问题,首先对图像进行增强处理,然后在网络中引入注意力机制对图像进行细粒度分类。同时针对医学数据集不足的问题,本文采用了基于整体微调的迁移学习策略来提升模型的性能。实验表明,本文提出的算法分类精度和二次加权Kappa值分别为97.8%和0.843,相比其他的分类模型有一定的提升,说明了本文提出的方法具有优越性。虽然在五分类中分类精度都有所提升,但是重度病变和增殖性病变的准确度仍有待进一步提升,在后续的工作中将会继续对网络进行改进,来实现辅助医生进行眼底图像筛查的目的。

参考文献

- [1] WANG W, AMY L. Diabetic Retinopathy: Pathophysiology and Treatments[J]. International Journal of Molecular Ences, 2018, 19(6):1816.
- [2] XU Y, WANG L, HE J, et al. Prevalence and control of diabetes in Chinese adults[J]. Journal of American Medical Association, 2013, 310(9):948-959.
- [3] SALEH M, ESWARAN C. An Automated Decision-Support System for Nonproliferative Diabetic Retinopathy Disease Based on Mas and Has Detection[J]. Computer Methods and Programs in Biomedicine, 2012, 108(1):186-196.
- [4] WANG G L. The review and consideration on grading in diabetic retinopathy[J]. Ophthalmol, 2005(4):218-220.
- [5] LU G H. The blood glucose threshold of diabetic retinopathy: impact on the diagnostic criteria of diabetes[J]. Journal of Practical Diabetology, 2011, 7(2):55-59.
- [6] DU J H, ZHANG L, YAO Y, et al. Preliminary study on the grading diagnosis and treatment measures of diabetic retinopathy[J]. Diabetes New World, 2018, 21(7):190-191.
- [7] RAJENDRA A U, CHUA C K, NG E Y K, et al. Application of Higher Order Spectra for the Identification of Diabetes Retinopathy Stages[J]. Journal of Medical Systems, 2008, 32(6):481-488.
- [8] ADARSH P, JEYAKUMARI D. Multiclass SVM-Based Automated Diagnosis of Diabetic Retinopathy[C] // 2013 International Conference on Communications and Signal Processing. IEEE, 2013:206-210.
- [9] PRATT H, COENEN F, BROADBENT D M, et al. Convolutional Neural Networks for Diabetic Retinopathy[J]. Procedia Computer Science, 2016, 90(3):200-205.
- [10] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556, 2014.
- [11] DING P L, LI Q Y, ZHANG Z, et al. Deep neural network classification method for diabetic retinal images[J]. Computer Applications, 2017, 37(3):699-704.
- [12] ARKADIUSZ K, BARTLOMIEJ J, MICHALG. Deep CNN Based Decision Support System for Detection and Assessing the Stage of Diabetic Retinopathy[C] // 2018 International Interdisciplinary Ph.D Workshop (IIPh. DW). IEEE, 2018:111-116.
- [13] WANG Z, YIN Y, SHI J, et al. Zoom-in-net: Deep mining lesions for diabetic retinopathy detection[C] // International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2017:267-275.
- [14] ZHAO Z, ZHANG K, HAO X, et al. Bira-net: Bilinear attention net for diabetic retinopathy grading[C] // 2019 IEEE International Conference on Image Processing (ICIP). IEEE, 2019:1385-1389.
- [15] TAN M, LE Q V. Efficientnetv2: Smaller models and faster training[J]. arXiv, 2014. 00298, 2021.
- [16] TAN M, LE Q V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks[C] // International Conference on Machine Learning. PMLR, 2019, 6105-6114.
- [17] HAO S, LEE D H, ZHAO D. Sequence to sequence learning with attention mechanism for short-term passenger flow prediction in large-scale metro system[J]. Transportation Research Part C: Emerging Technologies, 2019, 107(10):287-300.
- [18] MIKOLAJCZYK A, GROCHOWSKIM. Data augmentation for improving deep learning in image classification problem[C] // 2018 International Interdisciplinary Ph.D Workshop (IIPh. DW). IEEE, 2018:117-122.
- [19] WANG Y, WANG G A, FAN W G, et al. A deep learning based pipeline for image of diabetic retinopathy[C] // International Conference on Smart Health. Cham: Springer, 2018:240-248.
- [20] DOSHI D, SHENOY A, SIDHPURA D, et al. Diabetic retinopathy detection using deep convolutional neural networks[C] // 2016 International Conference on Computing, Analytics and Security Trends (CAST). IEEE, 2016:261-266.
- [21] ZHOU K, GU Z, LIU W, et al. Multi-cell multi-task convolutional neural networks for diabetic retinopathy grading[C] // 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2018:2724-2727.



SUN Fu-quan, born in 1964, Ph.D, post-doctoral fellow, professor. His main research interests include medical image processing and big data analysis.



ZOU Peng, born in 1998, postgraduate. His main research interests include image processing and computer vision.