

## 基于图卷积网络的糖尿病视网膜病变分级模型

杨雨帆, 袁立明, 王珂, 李弘毅, 李奕璇, 姚雨佳, 王婧祎

### 引用本文

杨雨帆, 袁立明, 王珂, 李弘毅, 李奕璇, 姚雨佳, 王婧祎. [基于图卷积网络的糖尿病视网膜病变分级模型](#)[J]. 计算机科学, 2024, 51(11A): 231000042-5.

YANG Yufan, YUAN Liming, WANG Ke, LI Hongyi, LI Yixuan, YAO Yujia, WANG Jingyi. [Grading Model for Diabetic Retinopathy Based on Graph Convolutional Network](#) [J]. Computer Science, 2024, 51(11A): 231000042-5.

---

### 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)

#### [基于CNN结合BiGRU的恶意流量分类算法研究](#)

Study on Malicious Traffic Classification Algorithm Based on CNN Combined with BiGRU  
计算机科学, 2024, 51(11A): 231100106-9. <https://doi.org/10.11896/jsjcx.231100106>

#### [自适应指纹子空间匹配WiFi定位算法](#)

Adaptive Fingerprint Subspace Matching WiFi Location Algorithm  
计算机科学, 2024, 51(11A): 231000172-6. <https://doi.org/10.11896/jsjcx.231000172>

#### [FCTNet:基于双域深度学习的公交车到站时间预测方法](#)

FCTNet:Bus Arrival Time Prediction Method Based on Dual Domain Deep Learning  
计算机科学, 2024, 51(11A): 231000180-7. <https://doi.org/10.11896/jsjcx.231000180>

#### [基于全局时空图卷积神经网络的城市交通流量预测](#)

Urban Traffic Flow Prediction Based on Global Spatiotemporal Graph Convolutional NeuralNetwork  
计算机科学, 2024, 51(11A): 240200045-9. <https://doi.org/10.11896/jsjcx.240200045>

#### [基于骨架特征的瓶颈层多尺度图卷积动作识别方法](#)

Bottleneck Multi-scale Graph Convolutional Network for Skeleton-based Action Recognition  
计算机科学, 2024, 51(11A): 231000073-5. <https://doi.org/10.11896/jsjcx.231000073>

# 基于图卷积网络的糖尿病视网膜病变分级模型

杨雨帆 袁立明 王珂 李弘毅 李奕璇 姚雨佳 王婧祎

天津理工大学计算机科学与工程学院 天津 300384

(xwzjyqf@163.com)

**摘要** 糖尿病视网膜病变是一种高风险的致盲性疾病,若能及早发现病变情况,则可对症治疗,减缓或阻止患者进一步的视力丧失。目前已经有一些利用深度学习进行糖尿病视网膜膜疾病检测的成功案例。然而,这些方法通常只考虑了图像中像素之间的空间关系,而没有考虑到图像深层特征之间的关系。为此,提出了一种基于图卷积网络的糖尿病视网膜病变分级模型,旨在帮助医生和研究人员在临床实践和科研工作中更好地进行糖尿病视网膜病变图像的分级和诊断。本模型主要通过图卷积网络去捕捉图像深层特征间所蕴含的重要的分级信息,获得具有更强语义信息的特征,并在此基础上构建一个双路分支网络。此外,为了更好地进行特征融合,采用自适应权重机制来进一步提高分级性能。实验结果表明,所提出的方法利用图卷积网络可以充分学习到图像深层特征间的关系,从而提高分级性能,其分类准确率在 APTOS2019 数据集上达到约 84.8%,在 Messidor-2 数据集上达到约 68%。

**关键词:** 糖尿病视网膜病变分级;卷积神经网络;图卷积网络;双路分支网络;自适应权重机制

中图分类号 TP391

## Grading Model for Diabetic Retinopathy Based on Graph Convolutional Network

YANG Yufan, YUAN Liming, WANG Ke, LI Hongyi, LI Yixuan, YAO Yujia and WANG Jingyi

School of Computer Science and Engineering, Tianjin University of Technology, Tianjin 300384, China

**Abstract** Diabetic retinopathy is a high-risk blinding disease. If it is detected early, it can be treated to slow or stop further vision loss in patients. There have been some successful cases of using deep learning to conduct diabetic retinal disease detection. Nevertheless, these methods usually only consider the spatial relationship between pixels in images and do not take into account the relationship between deeper features of the images. For this reason, a graph convolutional network based diabetic retinopathy grading model is proposed with the aim of helping doctors and researchers to better grade and diagnose diabetic retinopathy images in clinical practice and scientific research. This model mainly uses the graph convolutional network to capture the important grading information embedded among deep features of an image, to obtain features with stronger semantic information, and to construct a two-way branching network based on it. In addition, for better feature fusion, an adaptive weighting mechanism is used to further improve the grading performance. Experimental results show that the proposed method can fully learn the relationship between the deep features of the image by using the graph convolutional network, so as to improve the classification performance, and its classification accuracy reaches about 84.8% on the APTOS2019 dataset and about 68% on the Messidor-2 dataset.

**Keywords** Diabetic retinopathy grading, Convolutional neural network, Graph convolutional network, Two-way branch network, Adaptive weighting mechanism

## 1 引言

糖尿病视网膜病变(Diabetic Retinopathy, DR)是一种常见的糖尿病并发症,是导致全球成年人失明的主要原因之一<sup>[1]</sup>。据统计,全球约有 9 300 万人患有糖尿病视网膜相关疾病,其中一些患者可能需要进行治疗或手术来避免失明<sup>[2]</sup>。因此,DR 的早期检测非常重要,可以帮助医生提前识别病情并采取适当的治疗措施,以避免疾病的进一步恶化<sup>[3]</sup>。

医学研究发现,糖尿病患者的眼底常常会出现视盘水肿、散在的大量丝状出血、渗出、大量的微血管瘤和黄斑区水肿等病变。眼科医生会根据 DR 的严重程度进行定级。现行的国际临床分级标准,通常将 DR 的严重程度划分为 5 个等级<sup>[4]</sup>,

严重程度由低到高分别是眼底正常、轻度非增殖期、中度非增殖期、重度非增殖期和增殖期。

传统的 DR 检测和分级方法需要专业的医生对患者的眼底图像进行视觉检查和分析,这种方法需要耗费大量的人力和时间<sup>[5]</sup>。因此,开发一种自动化的、快速准确的 DR 检测和分级系统对于提高临床效率和诊断准确度至关重要。随着深度学习技术的快速发展,特别是卷积神经网络(CNN)<sup>[6]</sup>的广泛应用,目前已经有许多关于 DR 的自动检测和分级系统被提出。然而,这些方法通常只考虑了图像中像素之间的空间关系,而没有考虑到 DR 图像深层特征之间的关系。

Shi 等<sup>[7]</sup>认为宫颈癌图像的深层特征间关系蕴含着重要的分级信息,提出基于图卷积网络(GCN)<sup>[8]</sup>的宫颈癌细胞分

基金项目:天津理工大学大学生创新创业训练计划项目(202110060108);天津理工大学研究生教育教学研究与改革项目(YBXM2318)

This work was supported by the Program of Undergraduate Innovation and Entrepreneurship Training in Tianjin University of Technology (202110060108) and Program of Research and Reform on Graduate Education and Teaching in Tianjin University of Technology(YBXM2318).

通信作者:袁立明(yuanliming@tjut.edu.cn)

类模型<sup>[9]</sup>。该模型通过 CNN 学习图像的深层特征,将学习到的深层特征通过 K-means<sup>[10]</sup>聚类后,利用其质心构图,进而借助 GCN 强大的关系捕获能力学习宫颈癌图像深层特征间关系。GCN 的输出结果在 CNN 的高级特征表示上做投影,可认为 GCN 丰富了图像的深层特征,极大地提高了 CNN 的判别能力,实验结果论证了该想法的有效性。同样, Wang 等<sup>[11]</sup>借鉴这种思想,认为新冠肺炎图像的深层特征间关系蕴含着重要的分级信息,提出基于 CNN 和 GCN 深层特征融合的新冠肺炎图像分类模型 FGCNet。FGCNet 通过对新冠肺炎图像的潜在特征进行聚类并构图,经过两层 GCN 学习新冠肺炎图像深层特征之间的关系,进而丰富图像的深层特征,实验结果也证明了该想法的有效性。

DR 图像与宫颈癌图像、新冠肺炎图像同属于医学图像,通过对上述两种模型的思考,本文认为 DR 图像深层特征间关系也蕴含着重要的分级信息。因此,本文提出了一个新的基于图卷积网络的糖尿病视网膜病变图像分级模型,利用 GCN 强大的关系捕获能力去学习 DR 图像深层特征间的关系,并以此来构建了一个双路分支网络。与宫颈癌细胞分类模型和 FGCNet 模型不同的是,我们将 CNN 提取的特征直接构图作为 GCN 的输入,与通过 K-means 聚类后利用质心构图相比,这样可充分利用 CNN 所提取的深层特征,进一步提升 DR 图像分级的性能。同时,本文也提出一种新的融合机制——自适应权重机制,将所提出的双路分支网络进行融合分类,进一步提高分级的准确率。

## 2 数据集介绍

为了评估本文所提出的方法对 DR 图像分级的性能,使用 APTOS2019 (APTOS2019 Blindness Detection<sup>[12]</sup> 和 Messidor-2<sup>[13]</sup> 两个公共数据集进行实验。APTOS2019 数据集由 2019 年 Kaggle 竞赛 APTOS 提供,包括 3662 张眼底图片;Messidor-2 由 Messidor 项目合作伙伴提供,包括 1749 张眼底图片。

### 2.1 APTOS2019 数据集

APTOS2019 是印度 Aravind Eye Hospital 为了筛查乡村地区人群的病情采集的,它的全称是 Asia Pacific Tele-Ophthalmology Society (APTOS) Symposium。训练和测试的图像是由多个相机在不同的时间、多个不同的诊所中收集的图像。依据病变的严重程度,图片被标注为 5 个级别,其中训练样本有标注,测试样本无标注。因此,本文采用 3662 张训练样本进行五分类来评价模型。

### 2.2 Messidor-2 数据集

Messidor-2 数据集是一个公开可用的数据集,已经被很多组织用作 DR 图像检测算法性能测试的基准。研究人员使用相应的国际分级参考标准对此数据集的视网膜图像进行分级,图片被标注为 5 个级别。此数据集采集了 874 个实验者眼部视网膜情况,共计 1748 张视网膜彩色图片。本文对整个 Messidor-2 数据集进行五分类来评价模型的性能。

## 3 模型分析

本章主要介绍本文所设计的网络结构,包括整体架构设计和核心模块设计。首先,整体介绍了本文所提出的基于图卷积网络的糖尿病视网膜病变分级模型,分析了其中的 GCN 学习图像深层特征间关系模块的设计过程。其次,为进一步

提高分级准确率,我们分析了两路分支网络融合模块。最后讨论了损失函数。

### 3.1 模型整体架构设计

本文设计的网络模型包含 3 个模块:特征提取模块,图卷积模块以及两路分支网络融合模块,如图 1 所示。特征提取模块选用当下最流行的卷积神经网络 DenseNet<sup>[14]</sup> 提取特征,并得到图像的高级特征表示,从而获得 DR 图像对应每个级别的分值。图卷积网络模块用来学习 DenseNet 所提取的深层特征之间的关系,从而得到 DR 图像在每个级别上的分值。融合模块将特征提取模块和图卷积模块的输出通过自适应权重完成融合,以此控制两路分支网络对最终分级结果的贡献比例。

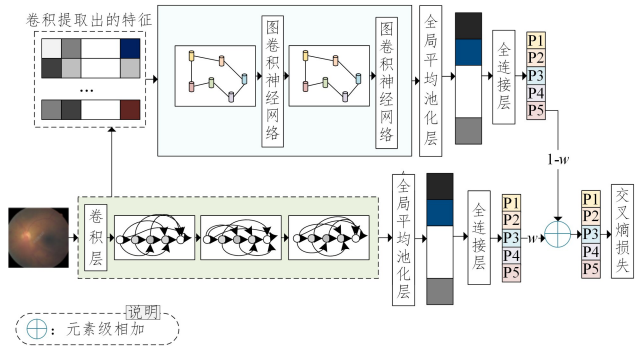


图 1 DR 图像智能分级网络

Fig. 1 Intelligent grading network of DR image

### 3.2 特征提取模块

特征提取模块用来提取 DR 图像的深层特征,选用在 ImageNet 上预训练的 DenseNet121 和 ResNet50<sup>[15]</sup> 模型作为基础的 CNN 模型,在提取特征过程中,去除最后一个全连接层。具体过程如下:将 DR 图像压缩成  $256 \times 256$  的固定大小,输入到处理后的 DenseNet121 或 ResNet50 网络中用于提取 DR 图像特征,从而得到 1024 个特征图,其尺寸大小为  $7 \times 7$ 。将 1024 个特征图经过全局平均池化层,得到该 DR 图像的高级特征表示  $\mathbf{I}_C \in \mathbb{R}^D$ ,  $D$  代表向量的维度是 1024。

### 3.3 图卷积网络模块

首先,将特征提取模块得到的 1024 个  $7 \times 7$  特征图分别展开成向量,共得到 1024 条向量表示每个特征图展开后的向量维度。由于每个特征图大小为  $7 \times 7$ ,因此,展开的向量维度为  $d=49$ 。将每条向量作为图的节点,边的信息用邻接矩阵  $\mathbf{A}_{ij}$  表示,图的邻接矩阵按如下方式得到:

$$\mathbf{A}_{ij} = \begin{cases} 1, & \text{if } X_i \in \text{KNN}(X_j) \text{ or } X_j \in \text{KNN}(X_i) \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

其中,  $\text{KNN}(X_i)$ <sup>[16]</sup> 表示用余弦相似性来得到节点  $i$  的  $k$  个邻居节点,如图 2 中举例说明,  $k$  为可调节的超参数。假设设置  $k=4$ ,则节点  $i$  和节点  $j$  的 3 个最近邻居分别为  $\text{KNN}(X_i) = (1, 2, 3, j)$ ,  $\text{KNN}(X_j) = (4, 5, 6, 7)$ 。因此,可以得到  $X_j \in \text{KNN}(X_i)$  且  $X_j \notin \text{KNN}(X_j)$ 。然后,将节点特征  $\mathbf{X} = \mathbf{H}^{(0)}$  和正则化的邻接矩阵  $\hat{\mathbf{A}}$  作为两层 GCN 的输入经过两层 GCN 后,如图 3 所示,有:

$$\mathbf{H}^{(1)} = f_{\text{relu}}(\hat{\mathbf{A}}\mathbf{X}\mathbf{W}^{(0)}) \quad (2)$$

$$\mathbf{H}^{(2)} = f_{\text{relu}}(\hat{\mathbf{A}}\mathbf{X}\mathbf{W}^{(1)}) \quad (3)$$

其中,  $\mathbf{W}^{(0)} \in \mathbb{R}^{d_0 \times d_1}$  和  $\mathbf{W}^{(1)} \in \mathbb{R}^{d_1 \times d_2}$  是可训练的权重矩阵;经过第一层 GCN 后得到节点的特征  $\mathbf{H}^{(1)} \in \mathbb{R}^{1024 \times d_1}$ , 经过第二

层 GCN 后得到最终的节点特征表示  $\mathbf{H}^{(2)} \in R^{1024 \times d_2}$ ;  $d_0, d_1, d_2$  在实验中都被设置为可调节的超参数。将  $\mathbf{H}^{(2)}$  同样经过全局平均池化层后可得到考虑了图像深层特征间关系的更为准确的高级特征表示  $\mathbf{I}_G \in R^{1024}$ 。





图 2 基于 KNN 的邻接矩阵的举例

Fig. 2 Example of adjacency matrix based on KNN



注:不同的颜色代表了经过 GCN 后不同的节点特征。

图 3 两层 GCN

Fig. 3 Two layers of GCN

### 3.4 两路分支网络融合模块

将上述两个模块分别得到的高级特征表示  $\mathbf{I}_C$  和  $\mathbf{I}_G$  分别经过全连接层,可得到每个分支对于各个分级的分值:

$$\mathbf{R}_l = (\mathbf{W}^{(0)})^T \mathbf{I}_C + \mathbf{b} \quad (4)$$

$$\mathbf{S}_l = (\mathbf{W}^{(1)})^T \mathbf{I}_G + \mathbf{b} \quad (5)$$

其中,  $\mathbf{W}^{(0)}, \mathbf{W}^{(1)} \in R^{1024 \times C}$ ,  $C$  是类别数,  $\mathbf{b}$  是偏置, 得分  $\mathbf{R}_l \in R^C, \mathbf{S}_l \in R^C$ 。通过自适应权重  $\omega$  将两路分支网络完成融合 ( $\omega$  初始化为 0.5), 得到最终的得分  $\mathbf{O}_l$ 。

$$\mathbf{O}_l = (1 - \omega) \times \mathbf{R}_l + \omega \times \mathbf{S}_l \quad (6)$$

$$\mathbf{P}_l = \text{Softmax}(\mathbf{O}_l) \quad (7)$$

其中,  $\mathbf{P}_l$  为 DR 图像在每个级别上的预测得分。因此, 每一张图片的分类结果融合了 CNN 的分类结果与 GCN 捕获深层特征间关系后的分类结果。

### 3.5 损失函数

用交叉熵损失 (Cross Entropy Loss) 函数<sup>[17]</sup>来进行端到端的训练本文模型。Cross Entropy Loss 用来描述数据的真

实概率分布与预测概率分布之间的相似度。本模型的网络融合模块用 Softmax 作用于原始的网络输出, Softmax 可将特征向量转化为预测类别的概率分布  $\mathbf{q}(x_i)$ , 有:

$$\mathbf{q}(x_i) = \frac{\exp(z_i)}{\sum_{k=1}^K \exp(z_k)} \quad (8)$$

其中,  $\mathbf{x}$  为特征向量, 设训练样本的真实概率分布为  $p(x_i)$ , 因此, 交叉熵损失函数公式为:

$$\mathbf{H}(\mathbf{p}, \mathbf{q}) = - \sum_{i=1}^n p(x_i) \log(\mathbf{q}(x_i)) \quad (9)$$

在糖尿病视网膜病变智能分级任务中, 采用 one-hot 编码。Cross Entropy Loss 的计算方式是: 只需要计算与训练样本真实标签相对应的预测标签概率的值, 剩余项为  $0 \cdot \log(\mathbf{q}(x_i)) = 0$ 。因此, 结合式 (8) 和式 (9), 可得出 CrossEntropy Loss 的表达式:

$$\text{Softmax}(x_i) = - \frac{1}{N_{\text{batch}}} \sum_i \log \left( \frac{\exp(\mathbf{W}_i)}{\sum_k \exp(\mathbf{W}_k)} \right) \quad (10)$$

其中,  $N_{\text{batch}}$  表示每个 batch 中训练样本的个数。

## 4 实验结果与分析

在本章中, 将通过大量的实验验证本文所提出方法的先进性。首先, 介绍了本文训练网络时采用的实验设置。其次, 与多个最先进的方法进行结果对比。然后, 为了突出本文核心方法的有效性, 进行了消融对比实验。最后, 分析了两路分支网络融合模块采用的自适应权重  $\omega$ 。本文所有实验均是在 APTOS 2019 Blindness Detection (APTOS2019) 和 Messidor-2 两个数据集上进行, 现有的 SOTA 方法基本上也使用了这两个数据集进行实验, 以保证实验效果的公平性。

### 4.1 实验设置

本文采用在 ImageNet 上预训练的 Dense-Net121 和 Res-Net50 作为 DR 图像分类的主干网络, DR 图像经过主干网络提取特征后得到若干个特征图, 邻居节点个数  $k$  的调整范围为  $\{3, 4, 5, 6, 7, 8, 9, 10\}$ , 第一层 GCN 输出维度的调整范围是  $\{32, 64, 128\}$ , 第二层 GCN 输出维度的调整范围是  $\{32, 64, 128\}$ 。该网络基于 Pytorch 框架, 采用随机梯度下降 (Stochastic Gradient Descent, SGD) 作为优化器, 初始学习率调整  $\{0.0001, 0.0005, 0.001, 0.005, 0.01, 0.05\}$ , 一次选取的样本数的大小设置为 64, 并将网络停止在第 64 个轮回处。在所有实验中, 都采用五折交叉验证以尽可能充分利用数据, 随机选择数据集中的 80% 作为训练集, 剩下的 20% 作为测试集, 共进行 5 次训练和测试。最终的实验结果为 5 次训练和测试结果的平均值。所有的实验都是在配有 3.60GHz Intel Xeon Gold 5122CPU 和 NVIDIA GTX2080Ti GPU 的计算机上进行的。

### 4.2 实验结果

#### 4.2.1 APTOS2019 数据集上实验分析

以 DenseNet121 作为主干网络, 在 APTOS-2019 数据集上超参数的最终设置情况如表 1 所列。

表 1 APTOS2019 数据集上超参数设置

Table 1 Hyperparameter settings on APTOS2019

Hyperparameters	Value
learning rate	0.01
$k$	3
$d_1$	347
$d_2$	75

将本文方法与当下对 DR 图像进行分级最典型的网络 DLI<sup>[18]</sup>, CANet<sup>[19]</sup>, GREEN<sup>[20]</sup> 进行对比。DLI 通过随机增强噪声来提高分类的性能; CANet 通过考虑 DR 与糖尿病性黄斑水肿之间的关系来提高对 DR 图像分类的性能; GREEN 通过考虑 DR 图像病变级别之间的关系来提高模型对 DR 图像分类的性能。使用 Acc, Kappa, F1 score 作为模型的 3 个评价指标<sup>[21]</sup>。Acc 是所有样本中预测正确的样本占比; Kappa 是度量观察者之间一致性的指标, 介于 0~1 之间, 值越高越好; F1 score 是精确率和召回率的调和平均数, 能反映模型整体的性能。本文使用 ResNet50 作为主干网络, 在消融实验中用 DenseNet121 作为主干网络。

表 2 列出了在 APTOS2019 数据集上的实验结果。由表 2 知: 在相同的主干网络下, 本文模型在 3 个评价指标上比现有先进方法效果更好。此外, 本文还验证了 DenseNet121 作为主干网络下, 本文方法的优越性。图 4 给出了不同网络分类效果的对比图, 由图可以得出: 总体来说, DLI, CANet 和 GREEN 网络并不能够精确地对 DR 图像进行分类, 这是因为它们没有考虑图像深层特征间的关系, 因此得到的高级语义特征表示不够准确, 影响了最终的分类性能。相比之下, 本文提出的模型通过两层 GCN 学习图像深层特征之间的关系, 对原始网络的分类结果进行辅助调节, 这样能进一步提高网络分类的性能, 而且实验验证了本文模型对不同级别的 DR 图像进行分级时都有较好的效果。

表 2 在 APTOS2019 数据集上与最先进方法的对比

Table 2 Comparison with state-of-the-art methods on APTOS2019

Method	Backbone network	Acc	Kappa	F1 score
DLI	ResNet50	0.825	0.895	0.803
CANET	ResNet50	0.832	0.900	0.813
GREEN	ResNet50	0.844	0.908	0.836
Ours	ResNet50	0.848	0.909	0.843



图 4 在 APTOS2019 数据集上可视化的分类结果

Fig. 4 Visualization of classification results on APTOS2019

#### 4.2.2 Messidor-2 数据集上实验分析

以 DenseNet121 为主干网络, 表 3 列出了在 Messidor-2 数据集上超参数的最后设定结果。将本文方法与当下最流行的网络 GREEN 进行了对比, 表 4 列出了在 Messidor-2 数据集上的实验结果。用主干网络 (Base) 进行分类时 DenseNet121 比 ResNet50 在各个评分指标上都表现好, 在相同的主干网络下, 与 GREEN 相比本文模型在三个指标上都提升。图 5 展示了可视化的结果, 在 Messidor-2 数据集上与 GREEN 网络以及真实的标签进行了对比。实验结果证明, 本文方法在对不同级别 DR 图像进行分级时能够取得更好的效果, 其主要原因是本文方法考虑了图像深层特征间关系。

表 3 Messidor-2 数据集上超参数设置

Table 3 Hyperparameter settings on Messidor-2

Hyperparameters	Value
learning rate	0.005
$k$	5
$d1$	64
$d2$	64

表 4 在 Messidor-2 数据集上与最先进方法的对比

Table 4 Comparison with state-of-the-art methods on Messidor-2

method	backbone network	Acc	kappa	F1 score
Base	ResNet50	0.652	0.585	0.456
Base	DenseNet121	0.655	0.627	0.627
GREEN	ResNet50	0.668	0.621	0.630
GREEN	DenseNet121	0.668	0.650	0.642
Ours	ResNet50	0.671	0.663	0.655
Ours	DenseNet121	0.680	0.673	0.660




图 5 在 Messidor-2 数据集上可视化的分类结果

Fig. 5 Visualization of classification results on Messidor-2 dataset

#### 4.3 消融实验

本文模型的主要贡献是使用 GCN 捕获 DR 图像潜在特征间的关系。本节通过消融实验分析该方法的有效性。

首先, 本文通过在 APTOS2019 数据集上使用 DenseNet121 作为主干网络进行消融实验, 结果如表 5 所列, 可见此模型的分级性能较之其他模型也有不小的提升。随后, 选取一种由谷歌人工智能提出的高效卷积神经网络 EfficientNet-b0<sup>[22-23]</sup>, 分别在 APTOS2019 数据集和 Messidor-2 数据集上, 将其作为主干网络进行消融实验。实验结果如表 6、表 7 所列, 可见此模型的分级性能较之其他模型也有一定的提升。

表 5 APTOS2019 数据集 DenseNet121 作为主干网络的实验

Table 5 Experimental results on APTOS2019 with DenseNet121 as backbone network

method	backbone network	acc	kappa	F1 score
Base	DenseNet121	0.828	0.738	0.824
GREEN	DenseNet121	0.838	0.889	0.826
Ours	DenseNet121	0.855	0.906	0.849

表 6 APTOS2019 数据集 EfficientNet-b0 作为主干网络的实验

Table 6 Experimental results on APTOS2019 with EfficientNet-b0 as backbone network

method	backbone network	acc	kappa	F1 score
Base	EfficientNet-b0	0.803	0.850	0.803
GREEN	EfficientNet-b0	0.840	0.890	0.830
Ours	EfficientNet-b0	0.845	0.905	0.840

表 7 Messidor-2 数据集 EfficientNet-b0 作为主干网络的实验

Table 7 Experimental results on Messidor-2 with EfficientNet-b0 as backbone network

method	backbone network	acc	kappa	F1 score
Base	EfficientNet-b0	0.649	0.620	0.588
GREEN	EfficientNet-b0	0.665	0.632	0.635
Ours	EfficientNet-b0	0.675	0.660	0.650

上述两个消融实验都表明本文模型的 GCN 学习图像深层特征间关系模块对于分类性能有着不小的提升, 这也从侧

面印证了该模块的有效性,说明了 DR 图像深层特征间关系蕴含着重要的分级信息。

#### 4.4 自适应权重

本文模型的另一贡献是构造了一个自适应权重  $w$ ,将 CNN 作为原始分类网络对 DR 图像进行分类的结果与经过两层 GCN 学习图像深层特征之间关系后得到的分类结果完成融合:CNN 作为原始分类网络对最后输出结果的贡献比例为  $w$ ,而 GCN 学习图像深层特征间关系模块,对最后输出结果的贡献比例为  $1-w$ ,以此控制两路网络分支对最终分类结果的贡献比例。为了验证其有效性,在 APTOS2019 数据训练后可以得出  $w$  的值为 0.7365。在 Messidor-2 数据集上可以得出  $w$  的值为 0.7138。由此可以得出,原始的分类网络对最终结果的贡献相对较大,而 GCN 学习图像深层特征之间关系的网络分支对最终分类结果起到了辅助调节的作用,能够进一步提升原始分类网络的分类性能,符合预期设想。

**结束语** 本文考虑了 DR 图像深层特征间关系,提出了一种基于 GCN 的 DR 图像智能分级方法。该方法使用 CNN 来学习图像的深层特征,用两层 GCN 学习图像深层特征之间的关系。因此,本文模型可以得到 DR 图像更具有级别信息的高级语义特征表示,从而提高了分类的性能。在 APTOS2019 数据集和 Messidor-2 数据集上的实验结果相比最先进的神经网络模型有了明显提升,说明了本文方法的可行性。

#### 参考文献

- [1] Fundus Diseases Group, Chinese Academy of Ophthalmology. Guidelines for Diabetic Retinopathy Clinical Diagnosis and Treatment in my country[J]. Chinese Journal of Ophthalmology, 2014, 50(11): 851-865.
- [2] FAN J, ZHANG R, LU M, et al. Application of deeplearning methods in the diagnosis of diabetic retinopathy[J]. Acta Automatica Sinica, 2021, 47(5): 20.
- [3] ACHARYA U R, NG E, TAN J H, et al. An Integrated Index for the Identification of Diabetic Retinopathy Stages using Texture Parameters[J]. Journal of Medical Systems, 2012(3): 36.
- [4] WONG T Y, SUN J, KAWASAKI R, et al. Guidelines on Diabetic Eye Care[J]. Ophthalmology, 2018(10): 125.
- [5] LING Y, XI S. Correlation between diabetic retinopathy and dry eye[J]. International Journal of Ophthalmology, 2018, 18(4): 4.
- [6] CUN L, JACKEL L D, BOSER B, et al. Handwritten Digit Recognition: Applications of Neural Network Chips and Automatic Learning[J]. IEEE Communications Magazine, 1989, 27(11): 41-46.
- [7] SHI J, WANG R, ZHENG Y, et al. Cervical cell classification with graph convolutional network[J]. Computer Methods and Programs in Biomedicine, 2021, 198: 105807.
- [8] KIPF T N, WELING M. Semi-Supervised Classification with Graph Convolutional Networks[J]. arXiv: 609. 02907, 2017.
- [9] SAJID S, HUSSAIN S, SARWAR A. Brain Tumor Detection and Segmentation in MR Images Using Deep Learning[J]. Arabian Journal for Science and Engineering, 2019, 44(11): 9249-9261.
- [10] WONG J A H A. Algorithm AS 136: A K-Means Clustering Algorithm[J]. Journal of the Royal Statistical Society, 1979,

28(1): 100-108.

- [11] WANG S H, GOVINDARAJ V V, ÓRRIZ J M, et al. Covid-19 Classification by FGCNet with Deep Feature Fusion from Graph Convolutional Network and Convolutional Neural Network[J]. Information Fusion, 2020, 67: 208-229.
- [12] Asia Pacific Tele-Ophthalmology Society. APTOS 2019 blindness detection [EB/OL]. <https://kaggle.com/competitions/aptos2019-blindness-detection>.
- [13] DECENCIÈRE E, ZHANG X, CAZUGUEL G, et al. Feedback on A Publicly Distributed Image Database: the Messidor Database[J]. Image Analysis & Stereology, 2014, 33(3): 231-234.
- [14] HUANG G, LIU Z, LAURENS V, et al. Densely Connected Convolutional Networks[C] // IEEE Conference on Computer Vision and Pattern Recognition. 2017: 2261-2269.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition[C] // IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.
- [16] KELLER J M, GRAY M R, GIVENS J A. A fuzzy K-nearest neighbor algorithm[J]. IEEE Transactions on Systems Man & Cybernetics, 1985, SMC-15(4): 580-585.
- [17] DE BOER P T, KROESE D P, MANNOR S, et al. A tutorial on the cross-entropy method[J]. Annals of Operations Research, 2005, 134(1): 19-67.
- [18] RAKHLIN A. Diabetic Retinopathy Detection through Integration of Deep Learning Classification Framework[J]. bioRxiv. 2017, 225508.
- [19] LI X, HU X, YU L, et al. CANet: Cross-Disease Attention Network for Joint Diabetic Retinopathy and Diabetic Macular Edema Grading[J]. IEEE Transactions on Medical Imaging, 2020, 39(5): 1483-1493.
- [20] LIU S T, GONG L J, MA K, et al. GREEN: A Graph Residual Re-Ranking Network for Grading Diabetic Retinopathy[C] // Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Lima, Peru, 2020: 585-594.
- [21] POWERS D. Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness and Correlation[J]. Journal of Machine Learning Technologies, 2011, 2(1): 37-63.
- [22] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2019: 4700-4708.
- [23] TAN M, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C] // International Conference on Machine Learning. PMLR, 2019: 6105-6114.



**YANG Yufan**, born in 2002, undergraduate. His main research interests include machine learning and deep learning.



**YUAN Liming**, born in 1982, Ph.D., associate professor, postgraduate supervisor. His main research interests include machine learning and medical image analysis.