

E2E-DRNet: 基于 EfficientNetV2 模型的糖尿病视网膜病变识别^①



刘圆圆¹, 陈 麓¹, 鲁 峰¹, 叶 阳¹, 安禹潼¹, 金明慧¹, 邢开原¹, 曾 光²

¹(哈尔滨医科大学(大庆)医学信息学系, 大庆 163319)

²(大庆市油田总医院 眼科, 大庆 163319)

通信作者: 邢开原, E-mail: xky1922@163.com

摘要: 本文提出一种名为 E2E-DRNet 的模型, 旨在解决当前人工 DR 诊断的分类性能差、耗时费力以及视网膜图像等级差异小、病灶不明显等问题。该模型基于 EfficientNetV2, 并结合了有效通道注意力模块。通过对 DR 数据集进行处理和优化, 引入了 Focal Loss 损失函数以解决样本不均衡问题, 并将模型分为两个阶段以实现 DR 分类的细分。实验结果表明, 该方法在公开数据集和临床数据集上表现良好, 提高了对眼底病变区域的可解释性, 有助于提高 DR 病变的筛查效率, 克服了人工诊断的局限性。

关键词: 糖尿病视网膜病变; EfficientNetV2; 有效通道注意力; 可解释性

引用格式: 刘圆圆, 陈麓, 鲁峰, 叶阳, 安禹潼, 金明慧, 邢开原, 曾光. E2E-DRNet: 基于 EfficientNetV2 模型的糖尿病视网膜病变识别. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9690.html>

E2E-DRNet: Diabetic Retinopathy Recognition with EfficientNetV2 Model

LIU Yuan-Yuan¹, CHEN Lu¹, LU Feng¹, YE Yang¹, AN Yu-Tong¹, JIN Ming-Hui¹, XING Kai-Yuan¹, ZENG Guang²

¹(School of Medical Informatics, Harbin Medical University (Daqing), Daqing 163319, China)

²(Department of Ophthalmology, Daqing Oilfield General Hospital, Daqing 163319, China)

Abstract: This study proposes a model called E2E-DRNet to address issues in manual diabetic retinopathy (DR) diagnosis, including poor classification performance, laborious processes, minimal differences in grades of retinal images, and inconspicuous lesions. This model is based on EfficientNetV2 and incorporates the efficient channel attention (ECA) module. By processing and optimizing a DR dataset, the Focal Loss function is introduced to address sample imbalance. The model achieves refined DR classification through two stages. Experimental results demonstrate that the proposed model performs well on both public and clinical datasets. Additionally, it enhances the interpretability of lesion regions in fundus images, thereby improving the efficiency of DR lesion screening and overcoming the limitations of manual diagnosis.

Key words: diabetic retinopathy (DR); EfficientNetV2; efficient channel attention; interpretability

近年来, 糖尿病视网膜病变 (diabetic retinopathy, DR) 已成为全球范围内引起关注的重要健康问题之一。随着糖尿病患者数量的增加, DR 的发病率也在不断上升, 给患者的生活质量和健康带来了严重影响^[1]。早期的 DR 诊断对于预防和治疗视网膜病变至关重要, 然

而, 目前的诊断方法存在着一系列问题。

传统的 DR 诊断方法主要依赖于人工眼底图像分析, 这种方法受限于医生个体经验和观察技巧, 容易出现分类性能差、耗时费力、视网膜图像等级差异小、病灶不明显等挑战。同时, 随着医疗技术的发展, 眼底

① 基金项目: 黑龙江省省属高等学校基本科研业务费基础研究项目 (JFQN202303)

收稿时间: 2024-05-14; 修改时间: 2024-06-12; 采用时间: 2024-06-26; csa 在线出版时间: 2024-10-25

图像的数量和质量不断增加,传统的人工诊断已经无法满足快速准确诊断的需求。为解决这一难题,研究人员提出了糖尿病视网膜病变分类算法,可准确分类病变程度,并为医生提供眼底图像的大规模筛查和诊治辅助。国际眼科协会将 DR 分为 5 大类别^[2],每个类别都具有特定的病变特征,可用于判断眼底图像的病变程度。然而,病变特征之间存在较高的重叠性和反复率,因此对眼底图像中最具代表性的病变特征进行提取,用于分类,是一项具有挑战性的任务^[3,4]。在过去的研 究中,研究人员已经利用机器学习、图像分类和模式识别等技术,开发了用于糖尿病视网膜病变自动筛查的系统。深度学习 (deep learning, DL) 技术以其出色的学习和分类能力,成为医学图像分析和诊断的重要工具。DL 有着潜力用于解决糖尿病视网膜病变的识别和分类问题。卷积神经网络 (CNN) 作为一种非常受欢迎且有效的深度学习技术,在医学图像处理领域得到了广泛应用^[5]。

Shankar 等人^[6]提出了一种利用 EfficientNet 架构的深度学习方法来自动检测糖尿病视网膜病变。在实验中,研究者分别在两个具有不同类别比例的 Kaggle 子集上训练了 EfficientNet-B4 和 EfficientNet-B5 模型。实验结果显示,这种方法在自动早期诊断糖尿病视网膜病变方面取得了良好的效果。Pravin 等人^[7]提出了基于 EfficientNet 的深度学习。作为一种自主检测和分类糖尿病视网膜病变 (DR) 的方法。该系统由 4 个阶段组成:特征提取、图像增强、分类和图像预处理。作者通过将形态学方法与对比度限制自适应直方图均衡化相结合,提高了图像预处理步骤中视网膜图片的质量。作者还使用二值阈值技术对图像进行分割并消除非视网膜部分。作者在整个图像增强过程中逐步应用了通道和空间注意的双重注意技术,以进一步提高图像质量。通道间关系由通道注意机制跟踪,通道内关系由空间注意机制捕获。

尽管现有方法能够对糖尿病视网膜病变进行分类,但分类准确率有待提升。由于病变类别之间差异细微,不同拍摄环境和手法可能导致同类别图像的差异较大。为了解决上述问题,本文提出了一种名为 E2E-DRNet 的 DR 影像自动分类识别方法,旨在更准确地提取病变特征,通过融合了有效通道注意力机制 (efficient channel attention, ECA) 和高效率网络 (EfficientNetV2),实现对病变类型的精确诊断。

1 相关理论

1.1 EfficientNetV2 网络

2019 年, Tan 等人^[8]提出了一种称为 EfficientNet 的新颖架构。它提供了一种通过调整网络宽度、深度和图像分辨率来训练参数更少、精度更高的 CNN 模型的方法,使用了 MBConv 块的反转残差块, MBConv 块最初是在 MobileNet-V2 架构中引入的,大大减少了参数数量^[9]。对 EfficientNet 架构进行了进一步增强,并提出了新的 EfficientNetV2 模型^[10],该模型使用了另一个名为 Fused-MBConv 的块以及 MBConv 块。

1.2 有效通道注意力机制

近年来,注意力机制在图像处理领域取得了显著进展。其中,有效通道注意力网络 (ECANet)^[11]是对压缩和激励网络 (SENet)^[12]的改进。SENet 模块通过学习获取不同特征通道的重要程度,按照重要程度去提升或者抑制信息特征。SENet 模块流程结构如图 1 所示,卷积操作后依次执行压缩、激励和重加权这 3 个子过程。 $F_{sq}(\cdot)$ 是一个压缩函数,对特征图的单个通道进行平均池化,并产生 $1 \times 1 \times C_2$ 维的通道描述符。激励函数 $F_{ex}(\cdot, w)$ 是一个类似于循环神经网络中门的机制,由两个全连接层和一个 Sigmoid 非线性层组成,之后得到每个通道对应的权重。对 U 进行缩放,生成 SENet 的最终输出。




图 1 SENet 模块

ECANet 模块的流程结构如图 2 所示。与 SENet 模块相比, ECANet 模块将两个全连接层替换成一维卷积,其核大小可以通过通道维度的非线性映射自适应确定。首先在输入特征上实现通道全局平均池化 (channel-wise global average pooling, GAP),而不进行降维。然后通过尺寸为 k 的快速 1D 卷积,使得每个通道的权重能够综合考虑其邻近通道的信息。然后,利用 Sigmoid 函数生成每个通道的权重,将输入特征与通道权重 (与 SENet 中的最终处理过程相同) 相结合得到最终的输出。

SENet 使用全连接层进行全局信息聚合,会忽略局部交互信息。相比之下,ECANet 通过引入一维卷积

核,使得每个通道和其邻近通道的信息得以更好地保留和交互,从而更有效地捕捉到局部特征.SENet模块中全连接层的引入增加了计算量和参数数量.而ECANet通过使用一维卷积,避免了降维和升维操作,能够减少模型的复杂度,使得模型更轻量化.




图 2 ECANet 模块

1.3 Focal Loss 损失函数

医学分类任务中,由于健康样本相对更容易获取,数据分布通常不平衡.在 DR 分类中,数据不均衡严重.常用的交叉熵(cross-entropy, CE)损失函数未考虑这一问题,可能导致模型偏向预测多数类别.为解决这一挑战,本文引入 Focal Loss^[13]作为损失函数,减轻易学样本的权重,提高对少数类别的关注,改善分类性能.

Focal Loss 是基于 CE 损失函数的改进. CE 损失函数的表达式如下:

$$L_{CE}(p, y) = - \sum_i y_i \log(p_i) \quad (1)$$

其中, p_i 是模型预测的类别概率, y_i 是真实的标签, i 表示类别索引.

使用 Softmax 将数据集中的 DR 样本分为 5 类, p_t ($t = 1, 2, \dots, 5$) 代表 5 个节点的离散概率. 其中 p_t 的计算公式为:

$$p_t = \frac{e^{(a_t)}}{\sum_{i=1}^5 e^{(a_i)}} \quad (2)$$

其中, a_t ($t = 1, 2, \dots, 5$) 代表 Softmax 节点的输出.

在式 (2) 基础上改进的 Focal Loss 公式如下:

$$FL = -\alpha(1-p_t)^\gamma \log(p_t) \quad (3)$$

其中, α 代表平衡参数, γ 代表聚焦参数.

2 本文算法

2.1 改进的 MBConv 模块

EfficientNetV2 网络的核心组成部分是 Fused-MBConv 模块. 本文对该模块进行了改进, 旨在减少模

型复杂度的同时提高对 DR 样本的识别率. 改进后的 Fused-MBConv 模块如图 3 所示. 在该模块中, 首先执行 Conv 3×3 的升维操作, 然后利用注意力机制 SENet 模块调整特征矩阵, 通过学习自动确定每个特征通道的重要性, 以更好地保留关键的特征信息, 最后通过 Conv 1×1 进行降维输出. 在调整注意力机制时, 使用 ECANet 模块替换了原始模型中的 SENet 模块, 确保自动学习到每个通道的重要性, 同时有效降低模型的复杂度, 从而提升性能.




图 3 改进后的 MBConv 模块

2.2 E2E-DRNet

本文在 EfficientNetV2 基础上, 提出一种融合有效通道注意力机制的网络模型(E2E-DRNet), 如图 4 所示. 这种网络可以自主学习到重点患病区域并且提供一定的医学可解释性, 实现性能的进一步提升. E2E-DRNet 模型的结构由 16 个的改进的 Fused-MBConv 模块、2 个卷积层和 1 个全连接层组成. 本文的 E2E-DRNet 的主要区别在于将原来的 Fused-MBConv 模块替换为新的 Fused-MBConv 模块. E2E-DRNet 架构有以下 3 个阶段: 首先, 将待分类的 DR 图像输入模型中, 进行图像预处理, 得到第 1 阶段的结果. 经过卷积操作, 112×112×32 的输出特征图进入下一阶段; 上一阶段输出的 112×112×32 特征图进入改进的 Fused-MBConv 模块层. 接下来, 7×7×320 的输出特征图进入下一阶段; 将输入的 7×7×320 图像按照以下顺序进行操作, 得到模型的最终分类结果.

3 实验分析

3.1 数据集简介

实验选择 DDR 数据库^[14], 由 7 名经过训练的评分员将这些图像分为 5 类. 没有清晰可见病灶的低质量

图像被认为是不可分级的。在本文的实验中，只关注DR分级任务；即不使用属于不可分级类的图像。因此，训练、验证和测试图像分别为6320幅、2503幅和

3759幅。并且本文还收集了来自某医院的临床数据集，共50张临床数据眼底图像和临床信息。具体数据分布信息如图5所示。




图4 E2E-DRNet 网络模型




图5 原始数据集类别分布

3.2 数据预处理


在神经网络训练之前，对眼底图像进行预处理，包括剔除质量差的图像、去除无关黑色背景、统一分辨率为 224×224 、使用 CLAHE 进行图像增强、进行数据增强以解决数据不均衡问题。经过预处理后，图像数据准备好用于神经网络训练。预处理前后的图像分别如图6(a) 和图6(b) 所示，DDR 数据集数据分布如图7 所示。

3.3 实验环境与参数设置

硬件设备参数包括 NVIDIA GeForce RTX 4090 GPU、13th Gen Intel(R) Core(TM) i5-13400F CPU 和 32 GB 运行内存。软件环境包括 Windows 操作系统，PyTorch 1.10.1 深度学习框架，Python 3.8 开发语言，以

及 PyCharm 集成开发环境。

模型的超参数设置如下：学习率为 $1E-4$ ，batch size 为 16，训练轮数为 150，优化器选用 Adam 优化器。



(a) 未处理图像 (b) 预处理后图像

图6 预处理前后的糖尿病视网膜图像




图 7 扩充后数据分布图

3.4 评价指标

评估指标在决定一个训练好的模型的性能方面发挥着巨大的作用。使用测试准确率、精确率、召回率、 $F1$ 分数和混淆矩阵评估 E2E-DRNet 模型在该数据集上的性能。评估指标相关公式在式(4)–式(7)中给出：

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

$$F1\text{-score} = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (7)$$

其中, TP (true positive) 指的是正例被正确识别的样本, TN (true negative) 是负例被正确识别为负例的样本, FP

(false positive) 是负例被错误识别为正例的样本和 FN (false negative) 是正例被错误识别为负例的样本。

3.5 实验结果

本文首先进行了第 1 阶段的粗分类, 将眼底图像分为两类: DR 患者和 No DR 患者。接下来, 进行了第 2 阶段的细分类, 将 DR 患者的眼底图像进一步分为 4 类: 轻度非增殖性糖尿病视网膜病变 (Mild NPDR)、中度非增殖性糖尿病视网膜病变 (Moderate NPDR)、重度非增殖性糖尿病视网膜病变 (Severe NPDR) 和增殖性糖尿病视网膜病变 (PDR)。

3.5.1 DDR 数据集的实验结果

为了验证改进的 Fused-MBConv 模块在 DR 分类任务中的有效性以及减少模型复杂性方面的有效性, 本文进行了实验验证。将 Fused-MBConv 模块中的 SENet 替换为 ECANet, 表 1 显示了使用原始和改进模块的对比结果。实验结果表明, 在二分类任务中, 改进的 Fused-MBConv 模型在各项指标上均优于原始 Fused-MBConv 模型, 且在参数量和计算量方面有明显的减少, 表明改进后的模型更加高效。在四分类任务中, 改进的 Fused-MBConv 模型同样表现出更高的正确率、精确率、召回率和 $F1$ 分数, 进一步验证了其在多分类任务中的有效性。通过引入 ECANet 替换 SENet, 改进后的 Fused-MBConv 模块在提升分类性能的同时显著减少了模型复杂性。

表 1 不同模块的对比结果表

分类任务	模块名	准确率 (%)	精确率 (%)	召回率 (%)	$F1$ 分数	模型参数量 (M)	计算量 (GFLOPs)
二分类	Fused-MBConv	96.65	92.44	96.54	0.9641	17.2	2.8
	改进的 Fused-MBConv	97.29	97.33	97.29	0.9729	15.8	2.3
四分类	Fused-MBConv	93.32	84.69	90.12	0.8415	22.4	4.7
	改进的 Fused-MBConv	96.06	88.43	91.76	0.8975	19.7	4.1

图 8(a) 和 (b) 分别是模型在测试集二分类和四分类任务的混淆矩阵图, 表 2 为评价指标结果表, 可以直观地看出:

在二分类任务中, 模型的整体性能表现出色。No DR 类别的精确度高达 98.74%, 这表示在所有被模型预测为 No DR 的样本中, 有 98.74% 是真正属于 No DR 类别的; 同时, DR 类别的召回率达到了 98.78%, 这说明模型能够有效地捕捉到 DR 类别的大部分实例。这两者的结合使得模型在准确度和 $F1$ 分数上都取得了很好的结果。

对于四分类任务, 模型在轻度、中度和 PDR 类别

上表现良好, 具有较高的精确度、召回率和 $F1$ 分数。特别是中度 NPDR 类别, 其精确度和召回率均超过了 98%, 表明模型能够有效地将该类别与其他类别区分开来。本文与其他深度模型进行了对比, 表 3 是本文与其他方法的对比结果, 可以看出本文模型在二分类以及四分类准确率优于其他方法。

图 9 显示了使用 CE 和 Focal Loss 训练的 E2E-DRNet 模型在训练过程中的损失收敛曲线。从图 9 可以看出, 使用 Focal Loss 的模型收敛速度更快, 早期阶段的损失下降更显著, 表明 Focal Loss 更快地引导模型关注难分类样本。




图 8 混淆矩阵图

表 2 DDR 数据集的分类结果对比

分类任务	病变等级	Precision	Recall	F1-score	Accuracy
二分类	No DR	0.9874	0.9580	0.9724	0.9729
	DR	0.9592	0.9878	0.9733	
四分类	Mild NPDR	0.9189	0.9043	0.9115	0.9606
	Moderate NPDR	0.9866	0.9836	0.9851	
	Severe NPDR	0.6739	0.8732	0.7607	
	PDR	0.9579	0.9091	0.9328	

表 3 与其他方法的准确率对比结果 (%)

模型名	二分类	四分类
ResNet50 ^[15]	86.33	84.56
MobileNetV2 ^[9]	89.56	90.51
InceptionV3 ^[16]	90.56	91.57
DenseNet201 ^[17]	91.84	91.85
VGG19 ^[18]	92.75	92.58
EfficientNetV2 ^[10]	95.21	93.45
E2E-DRNet	97.29	96.06

3.5.2 临床数据集的实验结果

本文对临床数据集进行了深入的测试, 图 10(a)




图 10 混淆矩阵图

和 (b) 分别是模型在二分类和四分类任务的混淆矩阵图, 表 4 为评价指标结果表, 综合而言, 该模型在临床数据集上表现良好, 通过与 DDR 数据集的实验结果进行对比分析, 可以更全面地评估模型的稳定性和有效性。临床数据集的实验结果进一步证实了模型在不同类型数据集上的良好表现, 这为其在实际临床应用中的可行性提供了有力支持。




图 9 损失函数收敛曲线对比图

表4 临床数据集的分类结果对比

分类任务	病变等级	Precision	Recall	F1-score	Accuracy
二分类	No DR	0.8462	0.8800	0.8627	0.8600
	DR	0.8750	0.8400	0.8571	
四分类	Mild NPDR	1.0000	0.6667	0.8000	0.8333
	Moderate NPDR	0.6667	1.0000	0.8000	
	Severe NPDR	0.8333	0.8333	0.8333	
	PDR	0.9000	0.8182	0.8571	

3.5.3 模型可解释性分析

为了验证模型的可解释性,更好地理解 E2E-DRNet 的效果,本文使用 Grad-CAM^[19]对结果进行可视化。展示了 5 个 DR 等级(从左到右,分别为 No DR、Mild NPDR、Moderate NPDR、Severe NPDR 和 PDR)。顶行提供原始图像,其中黄色箭头指示病变区域。第 2 行显示了热图结果。通过图 11 的可视化结果,可以发现模型关注的区域与人工标注的病变区域一致,说明模型在定位病变方面的表现良好。这种可视化效果使得模型的工作过程更具可解释性,有助于与临床医生交流和理解模型的工作方式。




图 11 可视化结果图

4 结论与展望

本文提出了一种名为 E2E-DRNet 的分类模型,结合了融合有效通道注意力机制的 EfficientNetV2,用于糖尿病视网膜病变的识别。通过在公开数据集和某医院的临床数据上验证模型的有效性,研究证实了该模型在提高分类准确率和增强可解释性方面的有效性。通过引入注意力机制和使用 Grad-CAM 可视化技术,不仅提高了模型的分类准确率,还增强了模型的可解释性。

尽管该研究取得了积极的结果,模型在临床数据集上表现良好,尤其是在二分类任务中具有较高的准确度和 F1 分数,但是在四分类任务中仍存在一些挑

战。特别是在识别中度和重度 NPDR 类别时,模型的表现不尽如人意,可能需要进一步的优化和改进。例如,增加样本数据、调整模型参数或改进特征工程方法等,都是可能的改进方向。

参考文献

- 刘婷婷,覃心宇,李芬,等.糖尿病视网膜病变国内外预防经验及启示.中国初级卫生保健,2023,37(5): 51–54. [doi: [10.3969/j.issn.1001-568X.2023.05.0013](https://doi.org/10.3969/j.issn.1001-568X.2023.05.0013)]
- 孙石磊,李明,刘静,等.深度学习在糖尿病视网膜病变分类领域的研究进展.计算机工程与应用,2024,60(8): 16–30. [doi: [10.3778/j.issn.1002-8331.2307-0330](https://doi.org/10.3778/j.issn.1002-8331.2307-0330)]
- Sunghetha A, Sharma RR. Design an early detection and classification for diabetic retinopathy by deep feature extraction based convolution neural network. Journal of Trends in Computer Science and Smart Technology (TCSST), 2021, 3(2): 81–94. [doi: [10.36548/jtcsst.2021.2.002](https://doi.org/10.36548/jtcsst.2021.2.002)]
- 赵爽,穆鸽,赵文华,等.基于特征融合网络的糖尿病视网膜病变分类.激光与光电子学进展,2023,60(14): 1417001.
- 张志强,赵可辉,牛惠芳,等.深度学习在糖尿病视网膜病变分级中的应用.计算机系统应用,2024,33(1): 231–244. [doi: [10.15888/j.cnki.cs.009368](https://doi.org/10.15888/j.cnki.cs.009368)]
- Shankar K, Sait ARW, Gupta D, et al. Automated detection and classification of fundus diabetic retinopathy images using synergic deep learning model. Pattern Recognition Letters, 2020, 133: 210–216. [doi: [10.1016/j.patrec.2020.02.026](https://doi.org/10.1016/j.patrec.2020.02.026)]
- Pravin SC, Sabapathy SPK, Selvakumar S, et al. An efficient DenseNet for diabetic retinopathy screening. International Journal of Engineering and Technology Innovation, 2023, 13(2): 125–136. [doi: [10.46604/ijeti.2023.10045](https://doi.org/10.46604/ijeti.2023.10045)]
- Tan MX, Le QV. EfficientNet: Rethinking model scaling for convolutional neural networks. Proceedings of the 36th International Conference on Machine Learning. Long Beach: ICML, 2019. 6105–6114.
- Sandler M, Howard A, Zhu ML, et al. MobileNetV2: Inverted residuals and linear bottlenecks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 4510–4520.
- Tan MX, Le QV. EfficientNetV2: Smaller models and faster training. Proceedings of the 38th International Conference on Machine Learning. ICML, 2021. 10096–10106.
- Wang QL, Wu BG, Zhu PF, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks. Proceedings of the 2020 IEEE/CVF Conference on Computer

- Vision and Pattern Recognition. Seattle: IEEE, 2020. 11531–11539.
- 12 Hu J, Shen L, Sun G. Squeeze-and-excitation networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 7132–7141.
- 13 Dina AS, Siddique AB, Manivannan D. A deep learning approach for intrusion detection in Internet of Things using focal loss function. Internet of Things, 2023, 22: 100699. [doi: [10.1016/j.iot.2023.100699](https://doi.org/10.1016/j.iot.2023.100699)]
- 14 Li T, Gao YQ, Wang K, et al. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening. Information Sciences, 2019, 501: 511–522. [doi: [10.1016/j.ins.2019.06.011](https://doi.org/10.1016/j.ins.2019.06.011)]
- 15 He KM, Zhang YX, Ren SQ, et al. Deep residual learning for image recognition. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016. 770–778.
- 16 Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016. 2818–2826.
- 17 Huang G, Liu Z, Van Der Maaten L, et al. Densely connected convolutional networks. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 2261–2269.
- 18 Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. Proceedings of the 3rd International Conference on Learning Representations. San Diego: ICLR, 2015.
- 19 Panwar H, Gupta PK, Siddiqui MK, et al. A deep learning and Grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-scan images. Chaos, Solitons & Fractals, 2020, 140: 110190.

(校对责编: 孙君艳)