

## 基于深度融合网络研究糖尿病视网膜病变

张颖<sup>1</sup>, 赵祺旻<sup>1</sup>, 郝群<sup>2</sup>

1. 甘肃中医药大学信息工程学院, 甘肃 兰州 730000; 2. 兰州大学第二医院信息中心, 甘肃 兰州 730000

**【摘要】**基于深度学习提出一种融合网络,旨在高效、准确地辅助诊断糖尿病性视网膜病。采用数据增强技术与生成对抗网络相结合的手段,对EyePACS数据集内的眼底图像实施扩充操作,有效应对眼底图像分类不均衡的难题。使用Inception-Resnet-V2作为主网络,并融入深度残差收缩网络和金字塔分割注意力模块,有效地过滤掉特征学习过程中的无关信息,聚焦病灶信息,提高网络对重要特征的抓取能力。实验结果显示该优化模型能在无需事先指明病变特征的情况下,准确率、召回率、特异性、灵敏度以及F1分数达到0.951、0.950、0.990、0.950、0.950,表明本文模型在评价指标上都有较好的性能。

**【关键词】**糖尿病视网膜病变;深度学习;深度残差收缩网络;金字塔分割注意力模块

**【中图分类号】**R318;R774.1

**【文献标志码】**A

**【文章编号】**1005-202X(2025)03-0347-09

## Diabetic retinopathy research based on deep converged network

ZHANG Ying<sup>1</sup>, ZHAO Qiyang<sup>1</sup>, XI Qun<sup>2</sup>

1. School of Information Engineering, Gansu University of Chinese Medicine, Lanzhou 730000, China; 2. Information Center, Lanzhou University Second Hospital, Lanzhou 730000, China

**Abstract:** A converged network based on deep learning is proposed to realize the efficient and accurate diagnosis of diabetic retinopathy. Both data augmentation technology and generative adversarial network are used to augment the fundus images in EyePACS dataset for effectively addressing the problem of uneven classification of fundus images. The proposed model uses Inception-Resnet-V2 as the main network, and incorporates deep residual shrinkage network and pyramid split attention module for effectively filtering out the irrelevant information in the feature learning process and focusing on the lesion information, thereby improving the network's ability to capture important features. Experimental results show that the optimized model achieves accuracy, recall, specificity, sensitivity, and F1 score of 0.951, 0.950, 0.990, 0.950, and 0.950, respectively, without the need to specify lesion characteristics in advance, demonstrating its superiority in evaluation indicators.

**Keywords:** diabetic retinopathy; deep learning; deep residual shrinkage network; pyramid split attention module

### 前言

由糖尿病引起的糖尿病性视网膜病变(Diabetic Retinopathy, DR)是全球范围内位居首位的致盲性眼疾<sup>[1]</sup>。DR的发病原因是由于体内血糖水平不断增高,进而致使视网膜微血管受损,引发各类眼底病

变,其中黄斑水肿、视网膜脱离和玻璃体出血等<sup>[2]</sup>是临床中常见的病症。随着糖尿病患者数量的持续攀升,据报道约1/3的糖尿病患者患有不同程度的DR<sup>[3]</sup>。DR的根本问题在于糖尿病或其并发症引起的眼底盲是不可逆转的,因此DR的早期诊断很重要<sup>[4-6]</sup>。

目前,对糖尿病患者的视网膜状况进行临床诊断和评估常使用对眼部进行综合检查的方式进行,这是一个耗时费力的人工过程,一般情况下,需要1~2 d才能做出诊断,会造成治疗的不及时<sup>[7-9]</sup>。近年来,眼底成像中的深度学习一直是研究的主题,有研究利用深度学习的方法针对糖尿病视网膜诊断进行研究,结果发现利用深度学习对DR进行诊断是有效的<sup>[10-13]</sup>。丁蓬勃等<sup>[14]</sup>基于深度神经网络构建完备视网

**【收稿日期】**2024-11-10

**【基金项目】**甘肃省自然科学基金(20CX9JA145);兰州市科技计划项目(2023-4-36)

**【作者简介】**张颖,硕士研究生,研究方向:医学图像处理,E-mail: zhang-ying19981212@163.com

**【通信作者】**郝群,硕士生导师,正高级工程师,研究方向:医院信息化、图像处理,E-mail: 28309495@qq.com

膜图像智能识别体系,设计一个紧凑神经网络模型 compact Net,基于训练数据自适应调整深度网络参数,实验结果表明分类准确率可达 0.87;Luo 等<sup>[15]</sup>提出一个基于图卷积的 DR 五分类诊断模型,自动提取出图像中不同层次的特征,并将这些特征组合起来分类识别,图像分类结果有所提高;Bravo 等<sup>[16]</sup>为提高 DR 的 5 级诊断模式的效能,使用卷积神经网络来检测眼睛图像中的 DR,运用深度网络把眼底视网膜图像划分为 DR 的 5 个阶段,将经过预处理的眼底视网膜图像进行整合,以获得 50.5% 的 ACA 评分;Zia 等<sup>[17]</sup>提出的深度学习框架凭借融合所提取的特征,充分发挥所选模型(VGG 和 Inception-V3)的优势,可精准地将静脉、液滴、渗出物、出血以及小型动脉瘤等亮点归为不同类别,分类准确率达 88.3%;Li 等<sup>[18]</sup>在收集的图像上对包括图像分类、语义分割以及目标检测在内的最先进深度学习算法展开评估,取得 0.828 4 的 DR 分类精度;李琼等<sup>[19]</sup>在 AlexNet 网络的基础上,引入一个批标准化层,实验结果表明分类精准率约为 90%,并且具备良好的稳健性与泛化性;占锐<sup>[20]</sup>利用 LANet 设计的病灶感知模块和特征融合模块在 3 个数据集上进行病灶分割实验,取得的 mAP 指标较 UNet、HED、EADNet 等 8 种网络模型有所提高。

当前绝大多数针对眼底图像的研究所采用的神经网络模型架构较为单一,影响训练性能;对于模型的改进,大部分还停留在仅增加神经网络层数的方面。针对上述情况,本研究运用一种新的深度融合网络来对眼底图像展开探究,将深度残差收缩网络(Deep Residual Shrinkage Network, DRSN)<sup>[21]</sup>和金字塔分割注意力模块(Pyramid Split Attention, PSA)<sup>[22]</sup>融入到主干网络模型中,以改善病灶图像的识别和诊断。

## 1 数据集信息与图像预处理

### 1.1 数据集

本次实验使用开源 EyePACS 数据,其中包含 35 126 张标记的眼底图像,基于 DR 的病变严重程度,将其细分为 5 个级别:无病变(0 级)、轻度病变(1 级)、中度病变(2 级)、重度病变(3 级)和增生性病变(4 级),具体数据分布见表 1。

正常的视网膜图像检查显示黄斑、视神经盘、视网膜血管等结构,无出血、水肿等症状<sup>[23]</sup>。在 DR 图像中,微动脉瘤发生在轻微病变阶段,在视网膜上呈现出一种深红色斑点;在中度病变中,血管的附近出现暗色出血点,可能伴随少量亮点状硬渗;当病情严重时,视网膜内会有大量的出血区域,并伴随着白色

棉絮般的软组织渗出物;增生性病变时,视网膜中不仅有新生血管形成,也有大量出血、渗出等病变,患者极有可能失明。图 1 为眼底结构和病理症状。

表 1 数据信息  
Table 1 Data information

类别	名称	图片数	占比/%
0	无病变	25 810	73.48
1	轻度非增生性病变	2 443	6.96
2	中度非增生性病变	5 292	15.07
3	重度非增生性病变	873	2.48
4	增生性病变	708	2.01




图 1 眼底结构及病变详情  
Figure 1 Details of fundus structures and lesions

### 1.2 图像预处理

1.2.1 数据筛选和去除黑边 剔除掉其中一些包含移位、失真、噪声导致无纹理、曝光过暗或曝光过度等严重影响训练效果的图像,通过裁剪算法去除眼睛背景图像周围的黑色冗余部分(图 2)。




图 2 裁剪算法处理黑边  
Figure 2 Cropping algorithm to handle black edges

**1.2.2 数据集扩充** 数据集中增生性病变视网膜图像数量仅占图像数量总数的2.01%,眼底图像0级和2级视网膜病变图片数占比过高。对于眼底图像类失衡问题<sup>[24]</sup>,可以通过数据增强来解决,如旋转、增加噪声、翻转、调整亮度等(图3);为增强模型泛化和

诊断性能,本研究创新性地采用生成对抗网络方法<sup>[25]</sup>来增强数据,生成网络可以凭借给定的随机杂讯输入输出类似于训练数据集的图像,截取一部分实验结果如图4所示。生成对抗网络工作原理如图5所示。




图3 传统数据增强  
Figure 3 Traditional data augmentation




图4 生成对抗网络生成结果  
Figure 4 Results obtained by generative adversarial network

**1.2.3 眼底图像预处理** 为更准确地展现眼底图像中的病变情况并提升特征提取的准确率,运用限制对比度自适应直方图均衡化手段处置眼底图像<sup>[26]</sup>,以提升图像对比度,同时借助伽马校正手段改善图像质量,如图6所示。

图像归一化能有效消除图像中的干扰仿射变换,减少图像中几何失真的影响。本实验使用最大最小值归一化技术,以确保数据达到标准化和一致

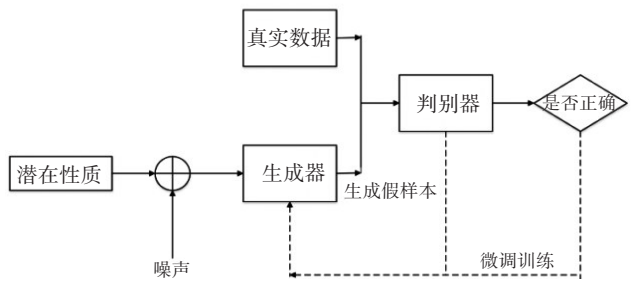


图5 生成对抗网络基本框架  
Figure 5 Basic framework of generative adversarial network

性的标准,具体如式(1)所示:

$$\text{norm} = \frac{x_i - \min(x)}{\max(x) - \min(x)} \tag{1}$$

其中,norm为图像归一化结果,变量 $x_i$ 为图像的像素值, $\min(x)$ 为像素值中的极小值, $\max(x)$ 为像素值中的极大值。

2 深度学习模型

2.1 Inception-Resnet-V2 网络结构

将Inception模块与Resnet模块进行创新性深度结合,旨在最大化两者的优势,实现更高效、精准的性能表现。Inception模块利用并行卷积核处理来自不同尺度的信息,融合Resnet残差连接方法,并对深






图 6 眼底图像处理  
Figure 6 Fundus image processing

层神经网络梯度学习方法进行改进,提高其学习效能。Inception-Resnet-V2 的网络结构包括输入层、核心模块、过渡层和输出层等,其中,核心模块包括 3 个组件: Inception-Resnet-A、Inception-Resnet-B 和 Inception-Resnet-C,每一个部分都包含若干残差部分,旨在提升性能。

首先,利用 ImageNet 数据集进行 Inception-Resnet-V2 网络的预训练,将这些初始参数为基准建立新的网络体系作为主干网络;随后,利用这一预训

练的网络模型来执行对特定数据集的特征提取与分类任务。图 7 为 Inception-Resnet-V2 模型的具体架构和层次。

2.2 优化网络模型

将 DRSN 引入主干网络进行优化,为显著提升模型在图像识别任务中的精确度,本研究将新的注意力机制模块融入至模型特征提取阶段内,提升模型在糖尿病眼底图像特征提取与识别层面的能力(图 8)。

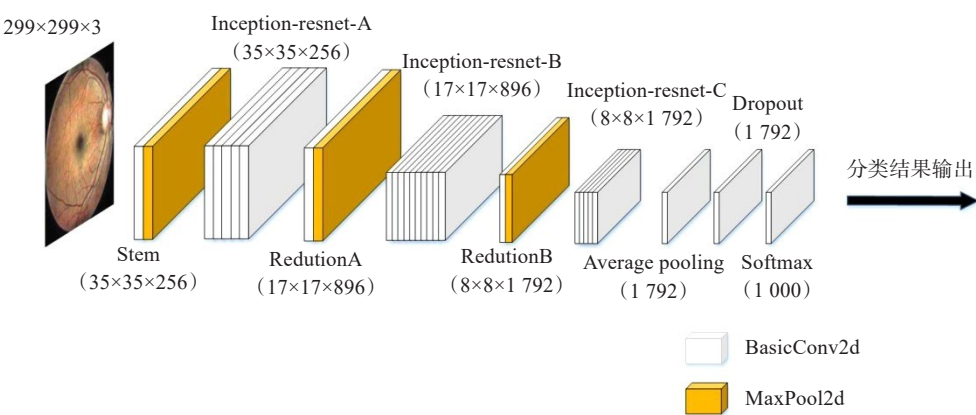


图 7 Inception-Resnet-V2 网络结构  
Figure 7 Inception-Resnet-V2 network structure

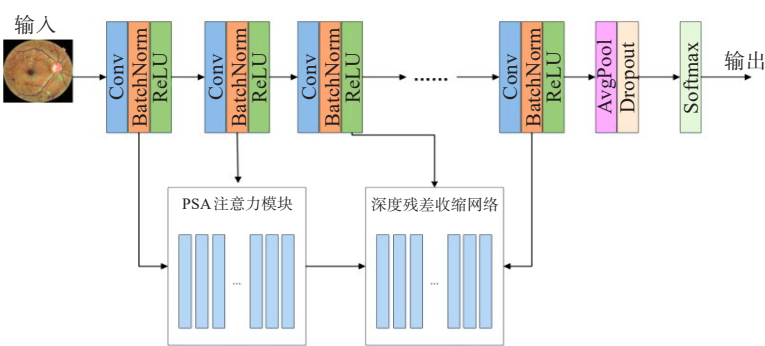


图 8 深度融合网络结构  
Figure 8 Deep converged network architecture

**2.2.1 DRSN** 在图像的识别与分类任务中,常会遇到高斯和椒盐噪声等干扰,即便是在同一样本集中,不同样本所携带的噪声量也往往存在显著的差异,这些噪声成分对分类的精确性与可信度构成威胁。为解决上述问题,本研究引入的DRSN以残差网络为支撑,核心在于通过与软阈值函数的融合应用,达成解

决前述问题的目标。DRSN降噪的核心为:首先,由卷积层对输入信息进行分解;接着,在设定阈值内对已分解的全部信息进行筛选;最终,将筛选出的全部信息进行重建。在DRSN中,软阈值函数所需阈值能自动设定,进而避免人工设定的繁杂步骤<sup>[27]</sup>。图9为残差模块与DRSN模块。

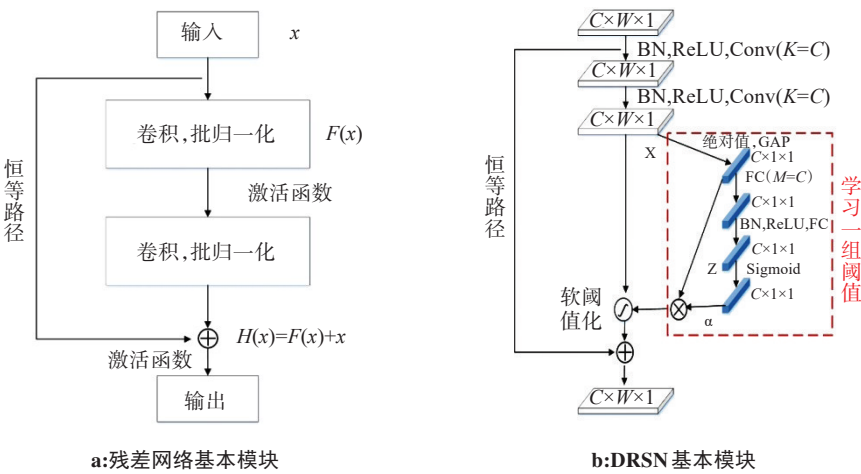


图9 残差网络与DRSN网络的比较

Figure 9 Comparison of residual network with deep residual shrinkage network

软阈值方法旨在移除绝对值低于特定阈值的元素,当绝对值大于某个门限时,将超出某个门限的特征向0方向缩减。软阈值法的另一项优势为,在完成导数运算后,梯度的数值仅为0和1,有利于避免梯度的激增和消散。软阈值化具体实现方式如式(2)和式(3)所示:

$$y = \text{soft}(x, \tau) = \begin{cases} x - \tau, & x \geq \tau \\ 0, & |x| \leq \tau \\ x + \tau, & x \leq -\tau \end{cases} \quad (2)$$

$$f(x) = \frac{\partial x}{\partial x} = \begin{cases} 1, & x \leq \tau \\ 0, & |x| \leq \tau \\ 1, & x \geq \tau \end{cases} \quad (3)$$

其中, $x$ 为输入, $y$ 为输出, $\tau$ 为阈值。

**2.2.2 注意力机制** 在深入探究注意机制的分类过程中可依据其作用层面,将其细分为通道注意力与空间注意力。常见的SE(Squeeze-and-Excitation)机制在通道注意力方面表现突出,然而在空间注意力维度则略显不足。BAM(Bottleneck Attention Module)和CBAM机制(Convolutional Block Attention Module)兼顾通道和空间注意力,但局限是未整合多尺度空间信息丰富特征空间,仅依赖局部信息未构建长距离依赖。为解决上述问题,本研究采用金字塔分割注意力模块(Pyramid Split Attention, PSA),将各种大小的卷积核组合成金字塔状的特征图,并利

用注意力机制来提取更丰富的特征信息。相较于其他注意力模块,PSA模块呈现出轻量、简洁高效等特点。

PSA模块的核心操作为运用SPC(Squeeze Pyramid Concat)模块来对不同通路加以确切辨别,并利用这些通道的空间数据,成功地提取多尺度特征。为进一步深化探索,采用一种SEWeight模型,该模型以不同尺度特征图为基础,聚焦于通道关注度,从而高效提取各尺度内的独特通道关注向量。接着,利用Softmax函数修正通道注意向量,以便更优地优化权重分配。最终,通过利用经过精确矫正的注意力向量对多尺度的特征图进行适当调整,进而得出最后的准确度输出。PSA模块见图10。

SPC模块是PSA注意力机制的核心模块,数据 $X$ 被细分为 $S$ 部分,分别为 $[X_0, X_1, X_2, \dots, X_{s-1}]$ ,从不同尺度中提取其特性特征,最终使用Concat将每个尺度获取的内容合并起来,基于以上特征,对各局部特征进行关注权重的计算,为更好地进行注意信息的相互作用以及多维度信息的融合,将以上得到的注意力矢量进行拼接,即 $Z = Z_0 \oplus Z_1 \oplus \dots \oplus Z_{s-1}$ ,将所得到的注意力加权归一化,最终获得修正后的特征值,完整的SPC模块见图11。

2.3 评价指标

采用混淆矩阵来评估分类模型的性能。在评估

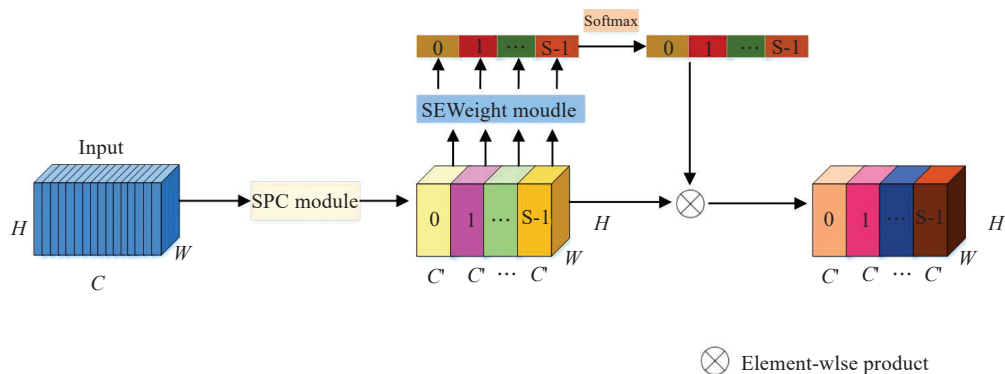


图10 PSA 模块

Figure 10 Pyramid split attention module




图11 SPC 模块

Figure 11 Squeeze pyramid concat module

模型性能时,使用4个关键指标:真正例(True Positive, TP)是指那些被模型精准识别并正确归类为正例的特定样本;真反例(True Negative, TN)是指那些被模型准确无误地判定为负样本的个例;假正例(False Positive, FP)是指错误地将原先为负的样本判定为正例的情况;假负例(False Negative, FN)是指那些原本应被视为正例的样本却被模型不恰当地预测为负的样本。

模型的好坏往往是基于图像类别的准确度和损失率这两个指标来评估的。正确预估出的数量与总样本数量的比例被认为是准确率(Accuracy),具体如式(4)所示:

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

实验过程中采用的损失函数是用于多种分类的交叉熵损失函数。当交叉熵损耗非常小时,这通常表示这种模型能更精确地拟合数据分布,从而提升其预测准确性,具体如式(5)所示:

$$L = \frac{1}{N} \sum_i L_i i = -\frac{1}{N} \sum_i \sum_c y_{ic} \log(p_{ic}) \quad (5)$$

其中, $L$ 表示损失函数值; $M$ 代表样品分类的数量; $y_{ic}$ 是用来表示一个符号函数(0或1);若样本 $i$ 的实际类别与 $c$ 一致则取1,反之则取0; $p_{ic}$ 被用来估算观测样本 $i$ 在 $c$ 类别下的预测几率。

在多分类任务中,F1分数为核心评价标准之一,值域位于0到1的闭区间内,其中,1代表完美的分类效果,而0则表示分类效果极差。具体如式(6)所示:

$$F1 - score = \frac{2 \times TP}{TP + FP + TP + FN} \quad (6)$$

特异性(Specificity)是指在整体阴性样品当中,确切预测的阴性样品占有的比率,具体如式(7)所示:

$$Specificity = \frac{TN}{TN + FP} \quad (7)$$

召回率(Recall)是描述模型所有真正正例中被精准预判正例所占比例的指标,灵敏度(Sensitivity)

是描述实际为阳性的样本中,判断为阳性的比例,两个指标计算公式相同,具体如式(8)所示:

$$\text{Recall} = \text{Sensitivity} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

(8)

### 3 实验结果与分析

本实验构建的模型依托 Python3.8 平台,采用深度学习框架 PyTorch 1.11.0 以及 Cuda 11.3, 配备 NVIDIA RTX3080 Ti GPU, 12 GB 显存, 80 G 固态硬盘。根据多次预实验结果分析,统一调节输入图像,将其尺寸定为 299×299;同时, epochs 的规格设定为 100, batch-size 的参数设定为 16, 并确定起始的学习速率为 0.000 1, 随后进行交叉验证操作。本研究使用的 EyePACS 数据集经过图像筛选后有效图像为 28 695 张, 除正常眼底图像外, 将各级别的 DR 图像数扩充为 5 000 张, 随机从 5 个级别中分别抽取 1 000 张图片组成实验数据集, 针对实验数据图像予以随机分为训练集(4 500 张)和测试集(500 张), 两部分中图像相互独立。

为验证优化的网络模型的性能,在试验阶段进行的对比实验主要分为 4 个部分:(1) Inception-Resnet-V2 网络与其他卷积网络的比较;(2) 实验验证网络优化性能;(3) 进行消融实验;(4) 比较优化后的网络模型对眼底图像的辅助诊断处理情况。

#### 3.1 Inception-Resnet-V2 网络与其他卷积网络的比较

将 Inception-Resnet-V2 网络模型与其他众多神经网络模型进行对比研究。以 DR 图像为研究对象, 通过对比目前备受关注的神经网络在眼底图像诊断中的性能, 可以观察到 Inception-Resnet-V2 网络于眼底图像分类诊断领域展现出相当可观的应用潜力。5 种模型的准确率见表 2。

表 2 不同模型的准确率对比  
Table 2 Accuracy comparison of different models

模型名称	准确率
Resnet-50	0.876
Inception-V3	0.922
GoogLeNet	0.856
MobileNet	0.640
Inception-Resnet-V2	0.932

#### 3.2 实验观察优化后的网络模型的性能

将图像传入网络模型迭代训练, 比较训练数据和测试数据对模型的准确率和损失率, 如图 12 所示, 其中, 训练损失(train loss)与训练准确率(train acc)分别代表本研究所构建模型在训练数据集上对 DR 图像进行诊断时的损失值及准确率, 而验证损失

(valid loss)与验证准确率(valid acc)则相应地体现该模型在测试数据集上对 DR 图像诊断的损失值与准确率。当模型执行 100 epochs 时, 无论是训练数据还是测试数据, 其准确性都在持续上升, 尤其是在测试集上, 准确率高达 0.95; 在数值损失方面, 损失函数逐渐减小, 尤其是在测试集上, 最终可以稳定在约 0.01 的水平。模型的准确率和损失值曲线的小幅波动表明该模型已进入收敛阶段。




图 12 优化模型 100 轮训练情况  
Figure 12 Optimized model with 100 epochs of training

采用混淆矩阵来对模型进行评价, 如图 13 所示, 实验结果表明 DR 图像预测值在对角线上的分布很集中, 表明该模型预测数量可以很好地接近真实数据, 证明本模型在该领域表现出色。

#### 3.3 消融实验结果

基于 Inception-Resnet-V2 框架, 融入 DRSN 与 PSA 模块进行优化。在这一模型上进行消融实验, 进一步对比和评估本文方法在糖尿病患者眼底图像学习方面的成效, 旨在分析每一块优化部分对网络模型的作用。进行消融实验的指标为: DRSN 模块、CBAM 模块、PSA 模块, 采用 Inception-Resnet-V2 网络作为空白对照, 消融实验结果见表 3。在 Inception-Resnet-V2 中融入 DRSN 模块后, 准确率、召回率、灵敏度、特异性以及 F1 分数等关键性能指标均有小幅提升, 证明 DRSN 模块对图像中的噪声具有一定去除效果; 对比 CBAM 模块和 PSA 模块对图像特征提取效果, 加入 PSA 模块较 CBAM 模块, 准确率提升 1.3%, 特异性达到 99.0%, 证明 PSA 模块可以整合多尺度空间信息, 从而提取更丰富的特征信息。在 F1 分数方面, 眼科专家的 F1 分数平均值大约是 90%<sup>[11]</sup>, 经过训练的网络模型 F1 分数均明显超过眼科专家的平均 F1 分数。实验数据表明本研究提出的优化策略在性能上具有明显的优势。






图13 优化过程中的混淆矩阵

Figure 13 Confusion matrixes during the optimization

表3 消融实验结果(%)

Table 3 Ablation study results (%)

消融模块	准确率	召回率	特异性	灵敏度	F1 分数
Inception-Resnet-V2	93.2	93.2	98.3	93.2	93.1
Inception-Resnet-V2+DRSN	93.6	93.6	98.4	93.6	93.5
Inception-Resnet-V2+DRSN+CBAM	93.8	93.8	98.5	93.8	93.7
本文模型	95.1	95.0	99.0	95.0	95.0

3.4 优化后的网络模型对眼底图像的辅助诊断

本研究致力于提升图像识别与分类的精准度及效率,利用不同网络模型对单幅眼底图进行辨识诊断,并对比不同模型在视网膜影像上的诊断效果和处理时间(表4)。实验结果表明,这些网络模型都可以正确诊断出 DR 所属类别;本文模型对图像的处理时间最短,表明本文网络优化的可行性与合理性,该模型可为 DR 图像研究临床诊断提供新思路。

表4 对1张图像处理时间对比(s)

Table 4 Comparison of processing time for an image (s)

模型	处理时间
Inception-Resnet-V2	0.103 8
Inception-Resnet-V2+DRSN	0.103 6
Inception-Resnet-V2+DRSN+CBAM	0.089 4
本文模型	0.087 1

4 结 论

本研究运用一种全新的深度融合网络来实现对 DR 图像的研究,凭借传统数据增强技术与生成对抗网络相融合的手段对 EyePACS 数据集进行扩充。以 Inception-Resnet-V2 为主干网络对多尺度信息进行处理和梯度学习,为增强深层神经网络在噪声干扰环境下的有效特征提取能力,在原有网络中融入

DRSN 模块,各项指标在原有基础上有小幅提升;进而融入 PSA 模块,聚焦图像的重要特征,对现有的神经网络与本文优化模型进行对比,展开相关的实验研究。此外,消融实验表明本文优化的网络模型在眼底图像分类诊断方面表现出色,各项指标都有显著的提升,并且正确判断图像类别所需时间最短,本文提出的优化模型对于 DR 图像在临床研究方面具有重要意义。今后可结合更多的数据源,不断对网络模型进行改进优化改善,使其在运行时间以及处理结果方面都可以得到更好的效果。

【参考文献】

[1] 雷凯杰. 基于深度学习的糖尿病视网膜病变图像分割方法研究[D]. 太原: 中北大学, 2023.  
Lei KJ. Research on image segmentation of diabetes retinopathy based on deep learning[D]. Taiyuan: North University of China, 2023.

[2] 曾芹. 保留黄斑中心凹的内界膜剥除术治疗黄斑水肿和高度近视性黄斑劈裂的效果研究[D]. 汕头: 汕头大学, 2021.  
Zeng Q. Study of the effectiveness of fovea-sparing internal limiting membrane peeling in the treatment of macular oedema and high myopic foveoschisis[D]. Shantou: Shantou University, 2021.

[3] 李成溪. 基于深度神经网络的糖尿病视网膜病变分类方法研究[D]. 长春: 吉林大学, 2023.  
Li CX. Research on classification method of diabetic retinopathy based on deep neural network[D]. Changchun: Jilin University, 2023.

[4] 张慧婷. 用于糖尿病视网膜病变分级的深度学习模型研究[D]. 太原: 太原理工大学, 2021.  
Zhang HT. The research of deep learning model for diabetic retinopathy grading[D]. Taiyuan: Taiyuan University of Technology, 2021.



- [5] 廖殷汉. 糖尿病性视网膜病变中的微动脉瘤检测和病变识别研究[D]. 桂林: 广西师范大学, 2021.  
Liao YH. Research on the microaneurysm detection and the lesion recognition in diabetic retinopathy[D]. Guilin: Guangxi Normal University, 2021.
- [6] 王宜匡. 基于深度学习的视网膜图像算法研究与应用[D]. 南京: 南京航空航天大学, 2021.  
Wang YK. Research and application of retinal image algorithm based on deep learning[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021.
- [7] 孙雨琛, 刘宇红, 张达峰, 等. 基于深度学习的糖尿病视网膜病变诊断方法[J]. 激光与光电子学进展, 2020, 57(24): 351-358.  
Sun YC, Liu YH, Zhang DF, et al. Diagnosis method of diabetic retinopathy based on deep learning[J]. Laser & Optoelectronics Progress, 2020, 57(24): 351-358.
- [8] 郭泽琪. 基于深度学习的糖尿病视网膜病变智能诊断方法研究[D]. 长春: 吉林大学, 2021.  
Guo ZQ. Research on diabetic retinopathy intelligent diagnostic method based on deep learning[D]. Changchun: Jilin University, 2021.
- [9] 董载斌. 基于深度学习的糖尿病视网膜病变识别技术研究[D]. 太原: 中北大学, 2023.  
Dong ZB. Deep learning-based research on the recognition technology for retinal lesions in diabetes[D]. Taiyuan: North University of China, 2023.
- [10] Tsiknakis N, Theodoropoulos D, Manikis G, et al. Deep learning for diabetic retinopathy detection and classification based on fundus images: a review[J]. Comput Biol Med, 2021, 135: 104599.
- [11] Gulshan V, Peng L, Coram M, et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs[J]. JAMA, 2016, 316(22): 2402-2410.
- [12] Zhang SL, Wu HQ, Murthy V, et al. The application of deep learning for diabetic retinopathy prescreening in research eye-PACS[C]//Imaging Informatics for Healthcare, Research, and Applications. Bellingham, WA, USA: SPIE, 2018: 1057913.
- [13] Mohamed JP, Banu S. Deep learning-based diabetic retinopathy detection: a survey[J]. Int J Organ Collect Intell, 2021(3): 11.
- [14] 丁蓬莉, 李清勇, 张振, 等. 糖尿病性视网膜图像的深度学习神经网络分类方法[J]. 计算机应用, 2017, 37(3): 699-704.  
Ding PL, Li QY, Zhang Z, et al. Diabetic retinal image classification method based on deep neural network[J]. Journal of Computer Applications, 2017, 37(3): 699-704.
- [15] Luo DM, Kamata SI. Diabetic retinopathy grading based on lesion correlation graph[C]//2020 Joint 9th International Conference on Informatics, Electronics & Vision (ICIEV) and 2020 4th International Conference on Imaging, Vision & Pattern Recognition (icIVPR). Piscataway, NJ, USA: IEEE, 2020: 1-7.
- [16] Bravo MA, Arbelaez PA. Automatic diabetic retinopathy classification[C]//13th International Symposium on Medical Information Processing and Analysis. Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series, 2017.
- [17] Zia F, Irum I, Qadri NN, et al. A multilevel deep feature selection framework for diabetic retinopathy image classification[J]. Comput Mater Contin, 2022, 70(2): 2261-2276.
- [18] Li T, Gao YQ, Wang K, et al. Diagnostic assessment of deep learning algorithms for diabetic retinopathy screening[J]. Inf Sci, 2019, 501: 511-522.
- [19] 李琼, 柏正尧, 刘莹芳. 糖尿病性视网膜图像的深度学习分类方法[J]. 中国图象图形学报, 2018, 23(10): 1594-1603.  
Li Q, Bai ZY, Liu YF. Automated classification of diabetic retinal images by using deep learning method[J]. Journal of Image and Graphics, 2018, 23(10): 1594-1603.
- [20] 占锐. 基于深度学习的糖尿病性视网膜病变自动检测方法研究[D]. 南昌: 江西财经大学, 2023.  
Zhan K. Research on automatic detection method of diabetic retinopathy based on deep learning[D]. Nanchang: Jiangxi University of Finance and Economics, 2023.
- [21] 李昊璇, 闫新艳. 基于深度残差收缩网络的商品图像识别[J]. 测试技术学报, 2021, 35(4): 294-299.  
Li HX, Yan XY. Commodity image recognition based on deep residual shrinkage network[J]. Journal of Test and Measurement Technology, 2021, 35(4): 294-299.
- [22] 吴建方. 注意力机制在糖尿病视网膜病变识别中的研究[D]. 广州: 广东技术师范大学, 2022.  
Wu JF. Research of attentional mechanisms involved in the diabetic retinopathy recognition of diabetic retinopathy[D]. Guangzhou: Guangdong Polytechnic Normal University, 2022.
- [23] 任刚. 基于深度学习的糖尿病视网膜病变的研究[D]. 济南: 山东大学, 2018.  
Ren G. Study of diabetic retinopathy based on deep learning method [D]. Jinan: Shandong University, 2018.
- [24] Asiri N, Hussain M, Al Adel F, et al. Deep learning based computer-aided diagnosis systems for diabetic retinopathy: a survey[J]. Artif Intell Med, 2019, 99: 101701.
- [25] Roy AG, Conjeti S, Karri SP, et al. ReLayNet: retinal layer and fluid segmentation of macular optical coherence tomography using fully convolutional networks[J]. Biomed Opt Express, 2017, 8(8): 3627-3642.
- [26] 李贺军. 基于深度学习的糖尿病视网膜病变分析与研究[D]. 桂林: 桂林理工大学, 2022.  
Li HJ. Analysis and research of diabetic retinopathy based on deep learning[D]. Guilin: Guilin University of Technology, 2022.
- [27] 林立媛. 基于深度残差收缩网络的水稻病害识别方法研究[D]. 大庆: 黑龙江八一农垦大学, 2023.  
Li LY. Research on rice disease identification method based on deep residual shrinkage network[D]. Daqing: Heilongjiang Bayi Agricultural University, 2023.

(编辑: 谭斯允)