

基于深度学习的糖尿病视网膜病变诊断方法

孙雨琛, 刘宇红, 张达峰, 张荣芬*

贵州大学大数据与信息工程学院, 贵州 贵阳 550025

摘要 针对糖尿病患者出现视网膜病变的现象, 提出一种基于深度学习的糖尿病视网膜病变诊断模型。在保证图像识别模型深度的前提下, 通过修改 Inception 模块的组成减少模型参数, 从而提升收敛速度; 通过引入残差模块, 解决了模型深度增加带来的梯度消失和梯度爆炸等问题; 利用数据扩充和设置 Dropout 的方法, 有效避免了数据集不足导致模型出现过拟合的现象, 从而实现了对糖尿病视网膜病变患病等级的检测。实验结果表明, 所提出的 DetectionNet 深度卷积神经网络对糖尿病视网膜病变患病程度等级分类任务的识别率达到 91%, 相对于 LeNet、AlexNet 和 CompactNet 等网络模型均有 20% 以上识别率的提升。该研究对糖尿病患者的早期预防和治疗、避免出现糖尿病视网膜病变具有重要意义。

关键词 图像处理; 糖尿病视网膜病变; 深度学习; 卷积神经网络; 数字图像处理

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.241701

Diagnosis Method of Diabetic Retinopathy Based on Deep Learning

Sun Yuchen, Liu Yuhong, Zhang Dafeng, Zhang Rongfen*

College of Big Data and Information Engineering, Guizhou University, Guiyang, Guizhou 550025, China

Abstract Aiming at the phenomenon of retinopathy of diabetic patients, a diagnosis model of diabetic retinopathy based on deep learning is proposed. First, under the premise of ensuring the depth of image recognition model, the composition of Inception module is modified to reduce the model parameters and improve the convergence speed. Next, the residual module is introduced to solve the problems of gradient disappearance and gradient explosion caused by the increase of model depth. Last, by using the method of data expansion and setting the Dropout, the phenomenon that the model is over-fitting due to the insufficient data set is effectively avoided, thereby realizing the detection of the disease level of diabetic retinopathy. Experimental results show that the deep convolutional neural network DetectionNet proposed in this paper has a recognition rate of 91% for the classification of diabetic retinopathy. Compared with network models such as LeNet, AlexNet, and CompactNet, the proposed DetectionNet improves the recognition rate by more than 20%. This research is of great significance for the early prevention and treatment of diabetic patients and the avoidance of diabetic retinopathy.

Key words image processing; diabetic retinopathy; deep learning; convolutional neural networks; digital image processing

OCIS codes 100.2000; 100.3008; 100.4996

1 引言

糖尿病视网膜病变(DR)是糖尿病的一种眼部表现,也是当今世界上造成视力损害和失明的主要原因^[1]。研究证明,高血糖、高血压、高血脂及糖尿病都是糖尿病视网膜病变发生的重要危险因素^[2]。根据 WHO 数据统计,中国糖尿病患者的人数高达

1.1 亿,是拥有糖尿病患者人数最多的国家。而糖尿病视网膜病变在糖尿病人群中的患病率为 65%,也就意味着在中国有 6700 万人可能患糖尿病视网膜病变^[3]。糖尿病视网膜病变如果没有得到及时的治疗,发展到后期使患者的视力急剧下降,最终会导致患者失明,严重影响患者的正常生活^[4-5]。根据研究表明,患糖尿病的时间越长,糖尿病视网膜病

收稿日期: 2020-01-19; 修回日期: 2020-06-01; 录用日期: 2020-06-17

基金项目: 贵州省科学技术厅科技基础条件平台专项计划(黔科合基础[2019]1099)

*E-mail: rfzhang@gzu.edu.cn

变发生的概率就越高,但是如果进行有效的早期诊断和治疗,可以使糖尿病视网膜病变患者出现视力下降或者失明的概率降低 90%^[6]。

临床上诊断糖尿病视网膜病变的传统方法是进行全面的眼科检测,包括视觉敏感度、散瞳等检查,检测流程复杂,需要耗费一定的人力物力。由于糖尿病视网膜病变的病灶种类多样,在早期筛查过程中,若能对眼底图像进行自动分类,就可以为临床医生节省大量的诊断时间,因此借助机器学习和深度学习的方法实现糖尿病视网膜病变诊断的研究得到人们的重视。现阶段,利用机器学习方法对患者眼底图像进行分类的精确度较高,但是目前大多机器学习算法需要高质量的图像作为数据集,并且在获取图像数据时需要通过有经验的眼科医生对眼底图像进行分类标注,因此在模型搭建前期仍需要做大量的准备工作^[7]。与此同时,利用深度学习进行糖尿病视网膜病变诊断的方法也在快速发展,现有研究大多是通过眼底图片中血管和视盘的分割来间接进行病变检测^[8-9]。随着深度学习网络模型的规模和深度不断增加,其在图像识别任务中的准确率得到提升,但是目前医学影像数据集偏小是导致深度学习方法在该领域中识别效果不佳的主要原因^[10]。

本文提出一种基于深度学习的糖尿病视网膜病变诊断模型,首先对采集到的视网膜眼底图像进行分析,利用数字图像处理算法对分析后的眼底图像进行去背景、去噪声、归一化等图像预处理操作,以减小图像质量对模型训练结果的影响;同时,为了避免视网膜眼底图像数据量过小引起的网络模型过拟合等现象,需要对经过预处理的图像进行数据扩充;随后将处理得到的数据集载入到深度卷积神经网络(DCNN)模型中进行训练,经过训练得到模型,最后可以自动对患者的视网膜眼底图像进行病变级别检测。采用深度学习算法自动提取视网膜眼底图像的特征时,避免了传统的支持向量机(SVM)、K近邻算法等需要对视网膜图像进行特征检测、人工提取特征的步骤^[11-12],减少了人为因素导致误诊的现象,还极大地缩短对糖尿病视网膜病变的诊断时间,该方法对于糖尿病视网膜病变患者的早期预防和治疗具有重要意义。

2 数据预处理

数据集的质量直接关系到后续模型结果的准确率,本文采用公认的 Kaggle-Diabetic Retinopathy

Detection 竞赛中的数据集(Kaggle-DR),该数据集包含多个患者左、右两只眼的高分辨率彩色图像,且左、右眼的眼底图像分辨率相同。根据视网膜病变的程度可将 Kaggle-DR 数据集中图像划分为正常、轻度、中度、重度和增殖型糖尿病视网膜病变 5 个等级,其病变特征主要表现为微动脉血管瘤、硬性渗出、棉絮斑、出血点等。0 对应于正常健康状态,1~4 代表患病程度依次严重。

2.1 图像归一化

通过对数据集进行分析,发现来自训练数据集和测试数据集的图像具有不同的分辨率、长宽比、颜色,以及对应各种不同的裁剪方式,并且有的数据图像的质量非常差,存在失焦情况等。而利用深度卷积神经网络对数据集图像进行训练时,需要一个固定的输入维度,因此需要调整眼底图像的大小使所有数据集具有固定的分辨率。图像分辨率过低时,眼底图像的细节特征会丢失,而分辨率过高会增加模型的训练成本,本文将图像分辨率固定为 512 pixel×512 pixel,这样做一方面可以保证眼底图像的细节特征,另一方面可以加快模型的训练速度。

2.2 图像预处理

在对图像进行预处理时,本文通过边缘检测算法增强视网膜眼底图像的血斑,但是经过训练测试发现该边缘检测算法将镜片上的灰尘或者其他光学问题识别为血斑。如图 1 所示,原始健康视网膜眼底图像[图 1(a)]经过边缘检测后被识别为增殖性糖尿病视网膜病变[图 1(b)]。因此,为了提高模型识别的准确率,需避免使用经过滤波器处理的图像。




图 1 原始健康视网膜眼底图像和经过边缘检测算法后的图像。(a)原始健康视网膜眼底图像;(b)经过边缘检测后的图像

Fig. 1 Original healthy retinal fundus image and image after edge detection. (a) Original healthy retinal fundus image; (b) image after edge detection

Kaggle-DR 数据集是具有高分辨率的 BGR 彩色图像(图 2),它给出的是含蓝色(B)、绿色(G)、红色(R)通道的图像的糖尿病视网膜眼底图像,不仅对计算机的内存要求高,还会增加模型训练的时间并对提取病变特征造成困难。由于本文提出的糖尿病视网膜病变检测方法通常是从血管、凹窝和视盘的图像中提取视觉特征^[13-14],为了减轻彩色图像在训练模型时给计算机带来的内存压力,通过实验发现,绿色通道比其他通道更能保留图像的特征信息,并可通过结合直方图均衡技术来提高图像的对比度,增强图像病变特征^[10]。




图 2 原始图像和 B、G、R 通道分量。(a)原始图像; (b) B 通道分量; (c) G 通道分量; (d) R 通道分量

Fig. 2 Original image, and components of B, G, and R channels. (a) Original image; (b) B channel component; (c) G channel component; (d) R channel component

2.3 数据扩充

Kaggle-DR 数据集包含 35126 张被标记过患病等级的图像,根据患病程度分为 0(正常)、1(轻度)、2(中度)、3(重度)和 4(增殖型)5 个等级。表 1 为糖尿病视网膜病变眼底图像分类表及其各患病等级图像占总数据的比例。从表 1 中可知,不同患病等级的图像分布极其不均匀,而卷积神经网络(CNN)对这种图像分布极其敏感,会导致在训练模型时出现过拟合的现象,使得在训练集上进行测试可得到较高的识别率,但是测试集的准确率很低。

表 1 糖尿病视网膜病变眼底图像分类

Table 1 Classification of fundus images of diabetic retinopathy

Grade	Degree of illness	Number of data images	Classification accuracy /%
0	Healthy	25810	73.48
1	Light	2443	6.95
2	Moderate	5292	15.07
3	Severe	873	2.49
4	Value-added	708	2.02

过拟合是机器学习、深度学习的通病,如果出现过拟合现象,经过训练生成的模型基本是无用的。解决模型出现过拟合现象的方案为设置 Dropout^[15]或者增加训练数据集。在模型训练时设置 Dropout,即在训练阶段按照一定的概率使某些神经元不工作,在测试阶段激活所有的神经元。Dropout 不仅可以解决训练模型出现过拟合的现象,而且减小了网络结构的复杂度,训练时间更少。图 3(a)为原始神经网络,图 3(b)为将隐含层中某些神经元丢弃后的神经网络结构。




图 3 原始神经网络结构和加入 Dropout 后的网络结构。(a)原始神经网络结构; (b)加入 Dropout 后的网络结构

Fig. 3 Original neural network structure, and network structure with Dropout. (a) Original neural network structure; (b) network structure with Dropout

增加训练数据集是解决训练模型过拟合最直接的方案,但是由于数据集短缺,不能再提供额外的数据图像,因此可以在不改变原数据集图像患病等级的基础上对其进行缩放、旋转、翻转、改变亮度等操作,使各个患病等级的数据集图像数量相等。数据扩充对样本数目较多的类别影响较小,而使数目较少的类别向数目多的类别扩充。图 4 为经过转换后的数据集图像。




图 4 经过转换后的数据集图像

Fig. 4 Transformed dataset image

3 卷积神经网络模型设计

卷积神经网络是人工神经网络的一种,其网络结构类似于生物体的神经网络。相比于传统的人工神经网络,卷积神经网络模型可以直接输入原始图像、自动提取图像特征,具有更好的泛化能力,即使当图像发生变形或者存在噪声时也不会对识别结果造成明显的影响;卷积神经网络通过局部感知和共享权值的方法降低网络模型的复杂度,减少网络参数,比传统模型的精确度更高^[16]。本文使用深度卷积神经网络作为糖尿病视网膜病变等级识别的训练模型。

训练网络模型借鉴了谷歌的 Inception 图像分类识别模型^[17],但是视网膜病变图像具有其自身的特性,通过进行参数设置、网络模型配置等网络参数的调整,使其更适用于视网膜病变等级分类的训练和识别。

病理图像对卷积神经网络的要求更高,需要更深的网络才能更好地拟合整个数据集,模型的表达能力更强。但是在实际中,网络深度的增加会导致梯度消失和梯度爆炸等现象,造成网络的深度与模型的性能并不是一直呈正相关关系。为了解决上述问题,本文通过引入残差块来训练一个更深的网络^[18]。

图 5 为一个残差模块,假设激活函数 $g(\cdot)$ 为 ReLU,则有

$$\begin{aligned} a[l+2] &= g(z[l+2] + a[l]) \\ &= g(w[l+2] * a[l+2] + b[l+2] + a[l]), \end{aligned} \quad (1)$$

式中: $w[\cdot]$ 为权重参数; $a[\cdot]$ 和 $b[\cdot]$ 为偏置参数, $a[\cdot] \geq 0$ 。假设 $w[l+1]=0, b[l+2]=0$, 则有

$$a[l+2] = g(a[l]) = a[l]. \quad (2)$$

由(2)式可知,残差网络优化目标函数更逼近于一个恒等映射,没有引入额外的参数和计算复杂

度,这表明神经网络更加容易实现一个恒等映射学习。因此,引入残差模块不仅不会影响网络的性能,而且可将输入信息直接传到输出端,这样能够保护信息的完整性,简化学习目标并减小学习难度。




图 5 残差模块

Fig. 5 Residual module

传统的 Inception 模块如图 6 所示,通过不同尺寸大小的卷积和池化运算,使 M 通道变成 N 通道,由于 M, N 的数值很大,这种结构模型的大小和计算量很大。为了节省计算成本,本文网络引入 1×1 的瓶颈层(图 7),使得 Inception 模块中有 1×1 的瓶颈层时的计算成本要比没有时低 90%。另外,视网膜眼底图像细节特征丰富,卷积视野过大不利于细节特征的提取,本文中的卷积神经网络使用两个 3×3 卷积替换 Inception 模块中的一个 5×5 的卷积(图 8),这样不仅可以达到相同的计算结果,而且增加了网络深度,减少了参数数量,提高了计算速度。




图 6 传统的 Inception 模块

Fig. 6 Traditional Inception module




图 7 1×1 瓶颈结构

Fig. 7 Bottleneck structure of 1×1




图 8 优化后的 Inception 模块
Fig. 8 Optimized Inception module

另一方面,为加大网络的深度,传统的 ResNet 网络牺牲了网络的宽度,在参数规模相同的条件下,通过增加网络的宽度使整个网络更容易训练^[19],基于 Inception 和 ResNet 的双重优势,本文在 Inception 结构的基础上加入了 ResNet 以提升整个网络的性能。加入 ResNet 后的 Inception 模块如图 9 所示。




图 9 加入 ResNet 后的 Inception 模块
Fig. 9 Inception module with ResNet

在本文提出的 DetectionNet 模型结构中,不同的卷积层使用多个卷积核来提取糖尿病视网膜病变特征,经过卷积之后还需要一个 ReLU 激活函数,以确保神经网络各层之间的非线性关系:

$$\text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (3)$$

与传统的 Sigmoid 和 tanh 函数相比,使用 ReLU 函数作为激活函数可以极大地提高模型的性

能^[20-21]。图 10 给出了 Sigmoid 函数和 ReLU 函数的曲线图。在使用梯度下降法时,当梯度接近 0 时,模型参数会变化得很慢,学习过程也会变得很慢。Sigmoid 函数在机器学习、深度学习领域的应用就存在这个问题,从图 10(a)中可以看出,在 A、B 处,函数的斜率梯度接近 0,因此模型在学习训练时会变得非常缓慢。而 ReLU 激活函数对于所有正值的输入,斜率梯度都为 1,这表明使用 ReLU 激活函数能使梯度下降运行得更快,有效地减少训练时间^[22]。




图 10 Sigmoid 函数和 ReLU 函数。(a) Sigmoid 函数;
(b) ReLU 函数

Fig. 10 Sigmoid function and ReLU function. (a) Sigmoid function; (b) ReLU function

池化层可以减小网络的计算复杂度,减少图像的特征,提取图像的主要特征,避免过拟合的现象。同样地,本文提出的 DetectionNet 网络模型在卷积操作之后也需要加入相应的池化层来提取眼底图像的主要特征。

卷积层和池化层的后面是全连接层,本文的卷积神经网络模型中使用两个含有 256 个神经元的全连接层,实验证明本文模型比只有一个全连接层的模型的准确率要高 0.03。最后,在模型的结尾通过 Softmax 函数将数据集分为正常、轻度、中度、重度和增殖型糖尿病视网膜病变 5 个等级。经过充分训练后,网络结构模型随着迭代次数的增加可以达到接近 90%的精确度,说明本文提出的 DetectionNet 网络模型结构是可取的。

4 实验结果分析

4.1 模型性能评价指标

为了定量比较识别网络的分类结果,本文采用模型准确率、空间复杂度两个指标来客观评价各类识别网络的分类效果。

用于评估模型分类效果的指标有准确率 A 和平均准确率 A_{avg} ^[23],其计算公式分别为

$$A = \frac{m_{\text{correct}}}{m_{\text{total}}}, \quad (4)$$

$$A_{\text{avg}} = \frac{\sum_{i=1}^N A_i}{N}, \quad (5)$$

式中： m_{correct} 表示分类正确的样本个数； m_{total} 表示全部测试的样本个数； N 为模型分类类别数； A_i 表示第 i 个类别的识别准确率。

用模型空间复杂度^[24]来评估模型的好坏,模型空间复杂度决定了模型的参数数量,模型参数越多,训练模型所需的数据量就越大,当训练数据量不足以匹配模型参数时,训练模型出现过拟合等问题。模型空间复杂度主要由模型总参数量和各层输出特征图的空间占用两部分组成,计算公式为

$$S \sim O\left(\sum_{n=1}^D K_n^2 \cdot C_{n-1} \cdot C_n + \sum_{n=1}^D M^2 \cdot C_n\right), \quad (6)$$

式中： n 表示卷积神经网络中卷积层的标签； D 、 K_n 、 M 分别表示卷积神经网络的卷积层数、特征图尺寸以及卷积核尺寸； C_n 表示卷积层的输出通道数,同时也等于上一卷积层的输出通道数。(6)式等号右侧第一项表示神经网络模型的总参数量,第二项表示输出特征图的空间占用。

4.2 实验结果

在 TensorFlow 深度学习框架下,利用已训练好的 DetectionNet 模型对 5 个病变等级的各 60 张

视网膜眼底图像进行分类,识别结果的准确率和平均准确率如表 2 所示。

表 2 5 个病变等级视网膜眼底图像的识别结果

Table 2 Recognition results of retinal fundus images of five lesion grades

Lesion grade	Recognition result					Accuracy /%
	0	1	2	3	4	
0	54	0	1	0	5	90.00
1	2	57	1	0	0	95.00
2	3	1	53	2	1	88.33
3	0	5	3	52	0	86.67
4	0	0	1	0	59	98.33

由表 2 识别结果可知,利用本文深度学习网络模型对糖尿病视网膜病变患病程度等级分类的平均准确率约为 91.67%,相对于采用传统的支持向量机(SVM)、K 近邻算法的准确率要高^[11]。

图 11 是 DetectionNet 模型的损失函数(Loss)和平均准确率曲线,从图中可以看出模型在训练前期就很快实现收敛,收敛后模型分类的平均准确率稳定在 91.67%,而 Loss 曲线也在训练迭代次数达到 20000 后逐渐收敛。




图 11 DetectionNet 模型训练的损失和平均准确率曲线。(a)平均准确率;(b)损失

Fig. 11 Loss and average accuracy curves of training with DetectionNet model. (a) Average accuracy; (b) loss

为了对比不同深度学习神经网络模型对糖尿病视网膜病变检测的准确率,将所提网络与文献[25]中提到的 LeNet、AlexNet 和 CompactNet 神经网络模型进行对比检测,对比结果如表 3 所示。

由表 3 的对比结果可知,虽然 LeNet、AlexNet、CompactNet 和 DetectionNet 都采用深度学习神经网络模型对同一数据集进行训练,但是训练模型的

表 3 不同网络模型的准确率对比

Table 3 Comparison of accuracy of different network models

Network model	Space complexity /MB	Accuracy
LeNet	0.72	0.42
AlexNet	60.00	0.62
CompactNet	14.16	0.69
DetectionNet	6.60	0.91

准确率却大不相同,这说明神经网络模型结构直接影响识别结果的准确率。LeNet 只有 8 层网络(其中包含 2 层卷积层),其空间复杂度最低,适用于一些简单的图像特征的提取,不适用于对病理这种复杂图像的特征提取。AlexNet 比较复杂,网络模型深度的增加会导致网络参数的增加,如果训练数据较少,常常会出现过拟合现象。本文设计的 DetectionNet 深度卷积神经网络是对 Inception 模型的改进,在保证准确率的前提下,极大地减小了模型的空间复杂度,其不仅可以加快模型的收敛,而且还可以有效地避免出现拟合现象,更适合于糖尿病视网膜病变检测。

5 结 论

所提出的糖尿病视网膜病变等级诊断方法,在对数据集进行归一化、图像预处理、数据集扩充等预处理操作后,利用深度学习神经网络模型对处理后的数据集进行训练,生成糖尿病视网膜病变诊断模型。该网络模型与其他方法相比具有较高的识别率,算法复杂度不高,不仅可以减少人为因素导致的误诊现象,还可以极大地缩短糖尿病视网膜病变诊断的时间,这对于糖尿病视网膜病变患者的早期预防和治疗具有重要意义。

参 考 文 献

- [1] Silberman N, Ahrlich K, Fergus R, et al. Case for automated detection of diabetic retinopathy[EB/OL]. (2010-03-16) [2020-01-19]. https://www.researchgate.net/publication/221250769_Case_for_Automated_Detection_of_Diabetic_Retinopathy.
- [2] Wu C Y, Yi B S, Zhang Y G, et al. Retinal vessel image segmentation based on improved convolutional neural network[J]. Acta Optica Sinica, 2018, 38(11): 1111004.
吴晨玥, 易本顺, 章云港, 等. 基于改进卷积神经网络的视网膜血管图像分割[J]. 光学学报, 2018, 38(11): 1111004.
- [3] Ni J Y. Research and design expert system for diabetes diagnosis based on decision tree [D]. Maanshan: Anhui University of Technology, 2016.
倪家远. 基于决策树的糖尿病诊断专家系统的研究与设计[D]. 马鞍山: 安徽工业大学, 2016.
- [4] Chen F H. Influencing factors of diabetic retinopathy and nursing countermeasures [J]. The Medical Forum, 2008, 12(3): 96.

陈福华. 糖尿病视网膜病变的影响因素及护理对策[J]. 基层医学论坛, 2008, 12(3): 96.

- [5] Liang P, Xiong B, Feng J J, et al. Classification methods for diabetic retinopathy from retinal images [J]. Journal of Shenzhen University (Science & Engineering), 2017, 34(3): 290-299.
梁平, 熊彪, 冯娟娟, 等. 糖尿病视网膜病变眼底图像分类方法[J]. 深圳大学学报(理工版), 2017, 34(3): 290-299.
- [6] 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), December 19-21, 2016, Pune, India. New York: IEEE Press, 2016: 261-266.
- [7] Liu F, Zhang J R, Yang H. Research progress of medical image recognition based on deep learning[J]. Chinese Journal of Biomedical Engineering, 2018, 37(1): 86-94.
刘飞, 张俊然, 杨豪. 基于深度学习的医学图像识别研究进展[J]. 中国生物医学工程学报, 2018, 37(1): 86-94.
- [8] Gao H J, Qiu T S, Chou Y T, et al. Blood vessel segmentation of fundus images based on improved U network [J]. Chinese Journal of Biomedical Engineering, 2019, 38(1): 1-8.
高宏杰, 邱天爽, 丑远婷, 等. 基于改进 U 型网络的眼底图像血管分割[J]. 中国生物医学工程学报, 2019, 38(1): 1-8.
- [9] Tang Y P, Wang L R, He X, et al. Optic disc localization based on regional proposal strategy [J]. Chinese Journal of Biomedical Engineering, 2019, 38(1): 9-17.
汤一平, 王丽冉, 何霞, 等. 基于区域建议策略的视盘定位方法[J]. 中国生物医学工程学报, 2019, 38(1): 9-17.
- [10] Ji C, Huang X B, Cao W, et al. Salient region detection of images based on deep learning[J]. Laser & Optoelectronics Progress, 2019, 56(9): 091007.
纪超, 黄新波, 曹雯, 等. 基于深度学习的图像显著区域检测[J]. 激光与光电子学进展, 2019, 56(9): 091007.
- [11] Pan Y H, Pan L. Detection of hard exudates in fundus images based on SVM [J]. Computer and Modernization, 2014(4): 33-37.
潘燕红, 潘林. 基于 SVM 的眼底图像硬性渗出检测[J]. 计算机与现代化, 2014(4): 33-37.
- [12] Sahebrao R, Sangramsing N, Sandip T, et al.

- Automated diagnosis non-proliferative diabetic retinopathy in fundus images using support vector machine [J]. *International Journal of Computer Applications*, 2015, 125(15): 7-10.
- [13] Pinz A, Bernogger S, Datlinger P, et al. Mapping the human retina[J]. *IEEE Transactions on Medical Imaging*, 1998, 17(4): 606-619.
- [14] Wu D, Zhang M, Liu J C, et al. On the adaptive detection of blood vessels in retinal images[J]. *IEEE Transactions on Biomedical Engineering*, 2006, 53(2): 341-343.
- [15] Srivastava N, Hinton G E, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. *Journal of Machine Learning Research*, 2014, 15(1): 1929-1958.
- [16] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning [EB/OL]. (2016-08-23) [2020-01-19]. <https://arxiv.org/abs/1602.07261>.
- [17] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision [EB/OL]. (2015-12-15) [2020-01-19]. <https://arxiv.org/abs/1512.00567>.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [19] Pang H, Wang C. Deep learning model for diabetic retinopathy detection[J]. *Journal of Software*, 2017, 28(11): 3018-3029.
庞浩, 王枫. 用于糖尿病视网膜病变检测的深度学习模型[J]. *软件学报*, 2017, 28(11): 3018-3029.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [21] Glorot X, Bordes A, Bengio Y. Deep sparse rectifier neural networks [C]//Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS), 2011, Fort Lauderdale, FL, USA. [S. l.]: [s. n.], 2011, 15: 312-323.
- [22] Maas A L, Hannun A Y, Ng A Y. Rectifier nonlinearities improve neural network acoustic models [C]// ICML Workshop on Deep Learning for Audio, Speech and Language Processing, Atlanta, Georgia, USA. [S. l.]: [s. n.], 2013, 28: 3.
- [23] Huang G, Liu X L. Automatic extraction and classification of road markings based on deep learning [J]. *Chinese Journal of Lasers*, 2019, 46(8): 0804002.
黄刚, 刘先林. 基于深度学习的道路标线自动提取与分类方法[J]. *中国激光*, 2019, 46(8): 0804002.
- [24] Zhang D F. Research on character recognition algorithm based on deep convolutional neural network [D]. Guizhou: Guizhou University, 2019.
张达峰. 基于深度卷积神经网络的文字识别算法研究[D]. 贵州: 贵州大学, 2019.
- [25] Ding P L, Li Q Y, Zhang Z, et al. Diabetic retinal image classification method based on deep neural network [J]. *Journal of Computer Applications*, 2017, 37(3): 699-704.
丁蓬莉, 李清勇, 张振, 等. 糖尿病性视网膜图像的深度神经网络分类方法[J]. *计算机应用*, 2017, 37(3): 699-704.