

一种基于残差网络改进的牙齿颜色分类模型

刘博文¹, 步 扬², 邹多宏³, 李建郎¹

(1.上海理工大学光电信息与计算机工程学院, 上海 200093;

2.中国科学院上海光学精密机械研究所, 上海 201899;

3.上海交通大学医学院附属第九人民医院, 上海 200011)

✉ 2385836330@qq.com; buyang@siom.ac.cn; zouduhongyy@163.com; lijianlang@usst.edu.cn



摘 要:针对传统牙齿比色方法准确率低和效率低等问题,提出一种基于残差网络改进的牙齿颜色分类模型。该模型通过融合多层卷积结果以及引入压缩与激励注意力机制模块的方式,使网络能学习到更多的图像颜色特征。基于典型牙齿所建数据集进行颜色分类实验,在该数据集上对文中模型与 GoogleNet、MobileNet-V1、ResNet-34 和 ResNet-50 等模型进行颜色分类预测结果比较。实验结果表明,文中模型优于传统模型,预测分类准确度达到 91.16%,有效提高了牙齿颜色分类准确率和效率。

关键词:牙齿比色;颜色分类;深度学习;ResNet-18 网络

中图分类号:TP751.2 **文献标志码:**A

A Tooth Color Classification Model Improved by Residual Network

LIU Bowen¹, BU Yang², ZOU Duohong³, LI Jianlang¹

(1.School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2.Shanghai Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Shanghai 201899, China;

3.Shanghai Ninth People's Hospital, Shanghai Jiao Tong University School of Medicine, Shanghai 200011, China)

✉ 2385836330@qq.com; buyang@siom.ac.cn; zouduhongyy@163.com; lijianlang@usst.edu.cn

Abstract: This paper proposes an improved tooth color classification model based on residual network to increase the accuracy and efficiency of traditional tooth colorimetric methods. This model enables the network to learn more image color features by fusing multilayer convolutional results and by introducing Squeeze-and-Excitation (SE) attention mechanism module. Color classification experiments are conducted on a typical teeth dataset, on which the color classification prediction results of the proposed model are compared with those of GoogleNet, MobileNet-V1, ResNet-34 and ResNet-50. The experimental results show that the proposed model is better than the traditional models, and the prediction classification accuracy reaches 91.16%, which effectively improves the accuracy and efficiency of tooth color classification.

Key words: tooth colorimetry; color classification; deep learning; ResNet-18 network

0 引言(Introduction)

牙体缺损和牙齿病变是口腔常见病^[1]。常见的应对方法是采用烤瓷修复体对患者牙齿进行修复^[2]。准确识别牙齿颜色是牙齿比色领域面临的挑战^[3],牙齿修复体颜色与牙齿形态协调匹配对于患者口腔中牙齿修复与治疗具有重要意义^[4]。

色彩识别与匹配是修复体重建的关键^[5],直接影响牙齿修复体的视觉效果。临床常用的比色方法是人工视觉比色法或

仪器比色法。人工视觉比色法受主观因素影响较多,比色准确性、一致性较差^[6]。基于色度计或分光光度计的仪器比色法,一般选取患者牙齿的某点或整面进行测量,但由于牙齿的表面颜色非常复杂,因此该方法的比色效率较低且准确性较差。

数字化比色是一种具有快速量化且不受环境干扰等优点的比色方法。加拿大 Cynovad 公司生产的基于 RGB 系统的 ShadeScan 比色仪^[7],通过分光光度计获取牙齿表面颜色信息。

根据 KIM-PUSATERI 等^[8]的研究表明,该仪器的准确率为 66.8%,对牙齿颜色评估不够准确。董磊^[9]设计了一种基于 K 近邻域法的颜色分类方法,但该方法分类不均衡且计算较为复杂,准确性较低。

本文将牙齿比色问题转换为图像分类问题,建立 ResNet-18 神经网络完成工作。为了提高模型性能,提出一种新型的残差结构,在残差模块中引入卷积层和非线性函数。改进后的模型准确度和效率均有所提升,能够高效且准确地获得牙齿颜色比色结果。

1 模型构建 (Model building)

1.1 ResNet-18

卷积神经网络能够提取图像中颜色更深层次的数据特征,弥补人类对于图像中颜色特征认识不足的缺陷^[10],并且随着网络深度的增加,网络学习能力会逐渐增强,因此训练结果会越来越好。但是实际结果并非如此,随着卷积神经网络达到一定深度时,其训练过程中会出现梯度消失、梯度爆炸等问题,导致网络无法收敛,网络训练精度随着网络层数增加而降低。深度残差网络 (Deep residual network, ResNet) 是一种经典的卷积神经网络模型,具有深层网络结构和残差连接的特点。由于其他网络模型缺少跳跃连接这类独特的结构,或是因网络层次不够深,导致其颜色特征提取能力有限。相比之下,ResNet-18 模型可以通过残差连接的方式缓解梯度消失的问题^[11],使得模型在训练过程中能够更好地学习到图像中的颜色特征,故对颜色特征具有更好的提取能力。

ResNet-18 网络主要是由多个残差模块堆叠而成,由于传统卷积网络无法获得完全拟合的恒等映射函数 $H(x) = x$,导致随着网络深度增加而出现梯度消失或梯度爆炸等现象^[12],因此在某些任务上无法取得很好的效果。ResNet-18 网络的优点在于结构中的残差模块通过引入短路连接 (Shortcut Connection) 实现输入端与输出端的跨层连接,该方法可以实现让输入信息跳过一层或多层,然后使输入信息到达网络更深层进行恒等映射,之后与基础映射通过卷积操作相加。假设输入图像为 x ,输出图像为 $H(x)$,中间部分通过卷积操作输出的图像为 $F(x)$,那么最后输出的结果为 $H(x) = F(x) + x$ 。当网络中某层残差模块难以训练,网络学不到新的信息时,即 $F(x) = 0$,那么残差模块只做恒等映射,即 $H(x) = x$,这样可以避免梯度消失或梯度爆炸问题的产生,不会导致网络因层次加深而无法收敛^[13]。残差模块图如图 1 所示。




图 1 残差模块图

Fig. 1 Residual module

1.2 注意力机制模块

ResNet-18 网络虽然在计算资源有限的情况下可以进行高

效的训练和推理^[14],但是在处理牙齿颜色分类这种颜色特征并不显著的分类任务时,其能力有限,分类效果不够理想,因此需要改进模型以此提高模型性能。压缩与激励 (Squeeze-and-Excitation, SE) 注意力机制模块可以通过学习每个通道的权重,提高网络对颜色特征的感知和表达能力^[15]。SE 注意力机制模块还可以自适应地调整特征图的通道权重,对于光照和颜色变化具有鲁棒性,能提高模型的鲁棒性和泛化能力^[16]。文章采用 ResNet-18 和 SE 注意力机制模块结合的方式提高网络的性能,以此增强网络模型对颜色特征的提取能力。

SE 模块又称压缩和激进模块,模块流程图如图 2 所示,该模块由压缩 (Squeeze) 和激进 (Excitation) 两个模块组成^[17],然后通过压缩、激励、重构操作得到一个 $1 \times 1 \times C$ 的权重矩阵,通过该矩阵与原图相乘,使图像的不同位置获得不同的权重,实现对图像特征信息的筛选^[18]。




图 2 SE 模块流程图

Fig. 2 Flow chart of the Squeeze-and-Excitation module

首先,通过全局平均池化将每个通道的二维特征 ($H \times W$) 压缩为一个实数,使特征图从 (H, W, C) 转变为 $(1, 1, C)$,得到每个通道的全局特征,如公式(1)所示:

$$Z_C = F_{sq}(u_C) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_C(i, j) \quad (1)$$

其次,将每个通道特征通过一个全连接层进行降维,其目的是减少参数计算量,通过 ReLU 函数添加层与层之间的非线性关系,再通过一个全连接层恢复到 $1 \times 1 \times C$ 的维度,由 Sigmoid 函数将其映射到 0~1 得到每个通道的权重,具体如公式(2)所示:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (2)$$

经上述操作得到 $1 \times 1 \times C$ 个权重,将其与原特征图 (H, W, C) 对应通道的二维矩阵进行权重相乘得到最后的结果,如公式(3)所示:

$$\tilde{x}_0 = F_{scale}(u_C, s_C) = s_C u_C \quad (3)$$

公式(1)至公式(3)中, Z_C 为单个通道经全局平均池化压缩成的一个实数; F_{sq} 为全局平均池化操作; u_C 为输入的单通道特征向量;高为 H ,宽为 W ; s 为最后输出的通道权重值; F_{ex} 为两个全连接层、一个 ReLU 激活函数和一个 Sigmoid 函数组成的激励操作; δ 为 ReLU 激活函数操作; σ 为 Sigmoid 函数操作; W_1, W_2 为全连接层 1 和全连接层 2; z 为 Squeeze 操作产生的实数; $\tilde{x}_0$ 为最后输出的特征图; s_C 为 Squeeze 和 Excitation 两个操作所产生的 $1 \times 1 \times C$ 个权重; u_C 为原特征图 (H, W, C) 向量。

1.3 残差模块的改进

残差模块采用了一种非常有效的结构,其独特的跳跃连接方式可以完美地解决梯度消失问题^[19]。但该模块也存在一些局限性,例如模块设计较为简单,主要捕捉图像的局部细节,因此提取到的特征多样性受限,故模型在处理复杂任务时性能有所不足。在牙齿颜色多分类任务中,不同颜色牙齿之间的差异

通常不够明显,因此标准的残差结构难以实现出色的性能。为了解决这一问题,提高模型的分类能力,本文设计了一种新的残差模块(图3)。该模块在特征提取分支中引入了更多的卷积层,每层之后跟随一个 ReLU 激活函数,这种方式有效增强了模型的非线性表征。首先将不同层次的卷积结果逐层相加,以此获得图像中的高级特征信息;其次将叠加后的特征信息通过 SE 注意力机制模块抑制无用特征信息;最后将 SE 注意力机制模块输出的特征图与原始输入相加,实现残差结构的跳跃连接作用。改进后的 ResNet-18 网络结构图如图4所示。




图3 改进后的残差模块

Fig. 3 Improved residual module




图4 改进后的 ResNet-18 网络结构图

Fig. 4 Improved ResNet-18 network structure

由图3可知,输入 x 经过第一层卷积运算,输出为 y_1 ,公式如下:

$$y_1(i, j) = \sum_{m=1}^3 \sum_{n=1}^3 x[i+m, j+n] \cdot W_1[m, n] + b_1 \quad (4)$$

第一层卷积输出的结果 y_1 经过第二层的 ReLU 激活函数和卷积运算得到 y_2 :

$$\text{ReLU}_1(i, j) = \max(0, y_1) \quad (5)$$

$$y_2(i, j) = \sum_{m=1}^3 \sum_{n=1}^3 \text{ReLU}_1[i+m, j+n] \cdot W_2[m, n] + b_2 \quad (6)$$

公式(4)和公式(6)中, i 和 j 表示输入、输出的特征图索引, m 和 n 表示卷积核的索引。

第二层卷积输出的结果 y_2 同样经过 ReLU 激活函数和卷

积层依次得到 y_3, y_4 和 y_5 ,最后将 y_2, y_3, y_4 和 y_5 相加,将相加后的结果通过 SE 注意力机制模块,增强特征图中有用的特征信息,抑制无用的特征信息,公式如下:

$$y_{\text{out}} = y_2 + y_3 + y_4 + y_5 \quad (7)$$

将 y_{out} 与公式(3)中的 s_C 相乘,即得到 y_{out} ,通过 SE 注意力机制模块后输出的结果如下:

$$y_{\text{out}} = s_C y_{\text{out}} \quad (8)$$

y_{out} 与原始输入特征 x 相加,并通过激活函数得到最终的 $\tilde{x}$:

$$\tilde{x} = \max(0, (x + y_{\text{out}})) \quad (9)$$

2 实验与分析 (Experiment and analysis)

2.1 数据集

本文使用的实验数据均在自然光照下拍摄。考虑到患者牙齿颜色的实际情况,数据集共包含 27 种不同颜色牙齿的图片,每张图片均由口腔医生拍摄患者牙齿所得,口腔医生参考对比牙齿比色板后(图5),给出牙齿符合的色号,口腔医生比色过程如图6所示。牙齿比色板由 27 种色号组成,不同色号牙齿之间的区别体现在明度和色调上,牙齿比色板有 5 个明度等级,图5中,从左到右的明度逐渐降低,伴随着色调也逐渐加深,最左侧的牙齿又亮又白,而最右侧的牙齿又黄又暗。




图5 27色牙齿比色板

Fig. 5 27-color dental shade guide



图6 口腔医生比色过程

Fig. 6 Stomatologist's colorimetric process

本文实验数据集如图7所示,标签分为 27 类,对应牙齿比色板上 27 种色号,每颗牙齿的标签均由口腔医生参照牙齿比色板给出。由于神经网络需要使用大量数据进行训练学习,因此需要先对现有图片进行数据增强。实验人员采用旋转、翻转以及添加椒盐噪声等方式扩充数据集,以提高网络模型的泛化能力。数据集共包含 16 000 余张图片,每一类颜色约有 600 余张图片,每张图片的分辨率为 256×256 ,实验样本按 8 : 2 的比例分为训练集和验证集。




图7 牙齿数据集

Fig. 7 Teeth dataset

2.2 实验环境及超参数设置

实验环境基于 Windows 10 操作系统,处理器为 11th Gen Intel(R) Core(TM) i7-11800H @ 2.30 GHz, GPU 为 NVIDIA GeForce RTX 3060, 显存大小为 6 GB, 编程语言为 Python 3.8.13, 采用 PyTorch 1.12.1 进行训练学习。使用交叉熵损失函数计算预测值与真实值之间的误差, 采用随机梯度下降优化器对神经网络的数值参数及权重进行更新^[20], 学习率为 0.01, 每 5 个 epoch 更新一次学习率, epoch 设置为 20, batchsize 设置为 32。

2.3 评价指标

为了分析模型对每一种牙齿颜色的预测精度, 选择准确率作为模型的整体指标, 并选择精确率、召回率和 F1 值作为每一类颜色的分类指标。对于第 i 类颜色, 计算 4 个指标。

(1) 准确率 (Accuracy): 正确预测的样本数量与总样本数量之间的比率, 如公式(10)所示:

$$Acc = \frac{\sum_{i=1}^n TP_i}{\sum_{i=1}^n (TP_i + FN_i)} \times 100\% \quad (10)$$

(2) 精确率 (Precision): 正确预测为正类别的样本数量与所有被模型预测为正类别的样本数量的比例, 如公式(11)所示:

$$P_i = \frac{TP_i}{TP_i + FP_i} \times 100\% \quad (11)$$

(3) 召回率 (Recall): 正确预测为正类别的样本数量与实际正类别的样本数量的比例, 如公式(12)所示:

$$R_i = \frac{TP_i}{TP_i + FN_i} \times 100\% \quad (12)$$

(4) F1 值 (F1 Score): 精确率和召回率的调和平均值, 用于综合评估模型性能, 如公式(13)所示:

$$F1_i = \frac{2 \times P_i \times R_i}{P_i + R_i} \times 100\% \quad (13)$$

其中: 真阳性 (TP_i) 表示预测的类别与真实的类别都是第 i 类; 假阳性 (FP_i) 表示预测的类别是第 i 类, 但真实的样本类别不是第 i 类; 假阴性 (FN_i) 表示预测的类别不是第 i 类, 但真实的类别是第 i 类。

虽然本研究以准确率作为评价模型总体性能的指标, 但是并不局限于某一类别的分类精度, 故结合精确率、召回率及 F1 值共同评估模型对不同类别牙齿颜色的分类能力, 从而对模型进行全面且客观的评估。

2.4 实验结果与分析

为了研究该模型在牙齿颜色分类数据集上的分类能力, 设计了 4 组消融对比实验, 使用 ResNet-34、ResNet-50、GoogleNet 及 MobileNet-V1 作为对照组。

为了体现模型的训练效果, 采取控制变量法, 不同的算法均在同一机器上运行, 避免造成不同算力对准确率、精确率、召回率和 F1 值结果产生差异, 取每种算法的 20 个 epoch 中准确率最佳的一轮模型用于与其他算法进行结果比较。

2.4.1 未引入 SE 注意力机制模块

ResNet-18 模型与本文模型在牙齿颜色分类数据集上的分类指标如表 1 所示。本文模型仅在残差网络中改换了每一个

残差模块结构, 模型的准确率提升了 3.98%, 精确率提高了 4.23%, 召回率提高了 4.03%, F1 值提高了 4.13%, 证明改进后的残差结构可以从牙齿颜色分类数据集上提取更深层次的颜色特征信息, 从而提升模型的分类性能。


表 1 ResNet-18 模型与本文模型的各项性能指标对比

Tab.1 Comparison of various performance indicators between


ResNet-18 model and the proposed model

模型	准确率/%	精确率/%	召回率/%	F1 值/%
ResNet-18	87.18	86.79	87.09	86.94
本文模型	91.16	91.02	91.12	91.07

由图 8(a)可知, 本文模型相较于传统的 ResNet-18 模型在曲线收敛之后可以达到更高的准确率, 表明本文模型在验证过程中可以达到更高的性能水平。由图 8(b)可知, 本文模型在第 5 轮之后仍然可以持续降低损失, 表明可以提取到更深层次的颜色特征信息, 并通过继续训练进一步提高对颜色特征信息的拟合能力, 为牙齿颜色分类任务带来了显著的改进。



(a) 准确率变化



(b) 损失函数变化

图 8 ResNet-18 模型与本文模型的准确率和损失函数对比

Fig. 8 Comparison of accuracy and loss function between

ResNet-18 model and the proposed model

2.4.2 引入 SE 注意力机制模块

SEResNet-18 模型与本文模型在牙齿颜色分类数据集上的分类指标如表 2 所示。为避免 SE 注意力机制模块插入位置对模型性能的影响, SE 注意力机制模块皆在特征提取支干的末端插入, 以此对比不同模型的性能。由表 2 可知, 在 ResNet-18 模型的基础上引入 SE 注意力机制模块后, 模型的性能并没

有提升,表明原残差结构对特征信息的提取能力较弱,故引入SE注意力机制模块并不能增强模型对颜色特征信息的学习能力。本文模型的各项指标相较于 SEResNet-18 模型均提升了8%左右,表明本文模型的残差模块能够提取丰富的颜色特征信息,可以通过 SE 注意力机制模块加强学习有用的特征信息,故模型的性能得以提升。

表2 SEResNet-18 模型与本文模型的各项性能指标对比

Tab.2 Comparison of various performance indicators between SEResNet-18 model and the proposed model

模型	准确率/%	精确率/%	召回率/%	F1 值/%
SEResNet-18	83.54	82.78	83.44	83.11
本文模型	91.16	91.02	91.12	91.07

由图 9 可知,本文模型在损失曲线和准确率曲线上的结果都优于引入 SE 注意力机制模块的 ResNet-18 模型,表明本文模型性能的提升并非仅依赖 SE 注意力机制模块,而是得益于本文在特征提取架构上的设计创新,从而验证了本文模型在结构设计上的有效性,尤其是在特征提取能力方面的显著改进。




图 9 SEResNet-18 模型与本文模型的准确率和损失函数对比

Fig. 9 Comparison of accuracy and loss function between SEResNet-18 model and the proposed model

2.4.3 本文模型与深度残差卷积网络对比

本文模型与深度残差卷积网络对比的分类指标如表 3 所示。由表 3 可知,单纯增加残差模块加深网络的深度并不能提升模型的性能。虽然残差结构可以避免梯度消失和梯度爆炸

的现象发生,但是在特征提取支干上的能力不足,所以模型提取不到足够的特征信息,证明单纯增加残差模块的数量并不能提升网络的性能。本文模型在残差模型的特征提取支干上增加了卷积的层数,并将多层卷积结果融合,使其可以提取到图像中更抽象的颜色特征信息,故改善后的模型性能相较于传统残差网络的性能显著提升。

表3 本文模型与 ResNet 系列模型的各项性能指标对比

Tab.3 Comparison of various performance indicators between the proposed model and the ResNet series models

模型	准确率/%	精确率/%	召回率/%	F1 值/%
ResNet-18	87.18	86.79	87.09	86.94
ResNet-34	84.69	84.14	84.62	84.38
ResNet-50	87.87	87.53	87.81	87.67
本文模型	91.16	91.02	91.12	91.07

由图 10(a)和图 10(b)可知,在传统的 ResNet 模型中,随着网络的深度增加,并不能使验证的准确率得以提高,表明单纯地增加网络的层数会使模型对牙齿颜色分类任务产生过拟合,从而在牙齿颜色分类任务上得不到很好的效果。相比之下,本文模型在牙齿颜色分类任务上所表现的性能不仅优于其他传统的 ResNet 模型,而且拥有更低的损失值,表明本文模型对牙齿颜色分类任务来说作用是有效且显著的。




图 10 本文模型与 ResNet 系列模型的准确率和损失函数对比

Fig. 10 Comparison of accuracy and loss function between the proposed model and the ResNet series models

2.4.4 本文模型与其他模型的对比

本文模型与其他模型的对比结果如表4所示。由表4可知,残差网络的性能要稍优于 GoogleNet 与 MobileNet-V1,再次证明残差模块的优越性。表4中,本文模型获得的准确率为91.16%,是7种模型中性能最好的,证明改进后的模型可以更好地学习牙齿颜色的特征信息。

表4 本文模型与其他模型的对比

Tab.4 Comparison between the proposed model and other models

模型	准确率/%	精确率/%	召回率/%	F1值/%
GoogleNet	85.85	85.28	85.76	85.52
MobileNet-V1	79.61	78.69	79.49	79.09
ResNet-18	87.18	86.79	87.09	86.94
SEResNet-18	83.54	82.78	83.44	83.11
ResNet-34	84.69	84.14	84.62	84.38
ResNet-50	87.87	87.53	87.81	87.67
本文模型	91.16	91.02	91.12	91.07

2.5 不同模型的结果对比

图11为不同模型对4个测试样本的分类结果对比,GroundTruth为口腔医生根据图5的牙齿比色板所给出的色号意见,图中的0M1、4M3等指代牙齿比色板上相应色号所对应的牙齿。




图11 不同模型对4个测试样本的分类结果对比

Fig. 11 Comparison of classification results of four test samples tested by different models

3 结论(Conclusion)

本文提出一种基于残差网络改进的牙齿颜色分类模型,它首先在残差结构的特征提取主干上加入了更多的卷积层,增强了残差模块的特征提取能力;其次将多层卷积结果融合,使提取到的特征更抽象,提升了图像特征信息的多样性;最后引入SE注意力机制模块关注各种颜色的不同通道之间的联系,从而快速地寻找出关键颜色所在区域并提取出特征信息,增强了网络对于颜色通道的感知和表达能力。实验结果表明,通过深度学习的方法可以获得较高的牙齿颜色分类准确率,并且能快速、量化和高准确度地对多颗牙齿颜色进行识别与匹配。

参考文献(References)

[1] 诸葛通人. 研究口腔修复患者牙体缺损、牙列缺失和牙列缺损的临床特点[J]. 中国卫生标准管理,2018,9(4):54-55.
[2] 陈宏丽. 电脑比色仪与目测法比色在牙体修复中的比较[J]. 中国医疗器械信息,2018,24(4):15-16.
[3] 张浩霖,全作林. 透明保持器对牙齿颜色的影响[J]. 口腔医学,2020,40(12):1103-1106.

[4] MOUSSA R. Dental shade matching: recent technologies and future smart applications[J]. Athenaeum scientific publishers,2021,2103(1):1-10.
[5] 丁秀琴,黄晓峰. 复合树脂与聚合瓷在牙体缺损后修复术中的应用对比[J]. 中国医药导报,2013,10(28):34-36.
[6] HAMPÉ-KAUTZ V, SALEHI A, SENGHER B, et al. A comparative in vivo study of new shade matching procedures[J]. International journal of computerized dentistry, 2020,23(4):317-323.
[7] 张新媛,吴效民. 口腔比色技术的发展及现状[J]. 口腔颌面修复学杂志,2012,13(2):121-123.
[8] KIM-PUSATERI S, BREWER J D, DAVIS E L, et al. Reliability and accuracy of four dental shade-matching devices[J]. The Journal of prosthetic dentistry,2009,101(3):193-199.
[9] 董磊. 数字式高分辨比色仪的研制[D]. 西安:西安石油大学,2020.
[10] 张添福,钟舜聪,连超铭,等. 基于深度学习特征融合的视网膜图像分类[J]. 激光与光电子学进展,2020,57(24):266-273.
[11] 管淑贤,葛万成. 基于 ResNet18 的减速带识别及其环境影响研究[J]. 通信技术,2021,54(3):597-603.
[12] 李嘉琪,全星日. 基于改进 ResNet50 的心音分类算法研究[J]. 电脑知识与技术,2022,18(21):76-78.
[13] 赵洋,梁迎春,许军,等. 改进 ResNet18 网络模型的花卉识别[J]. 计算机技术与发展,2022,32(7):167-172.
[14] 张鑫鑫,朱荣光,孟令峰,等. 改进 ResNet18 网络模型的羊肉部位分类与移动端应用[J]. 农业工程学报,2021,37(18):331-338.
[15] 何彦弘,徐怡宁,傅嘉琪,等. 基于改进 Resnet18 的垃圾分类收运监管方法研究[J]. 软件工程,2023,26(1):24-33.
[16] 傅继彬,曹玉笠. 基于门控卷积和 SENet 的双判别生成对抗网络图像修复模型[J]. 计算机应用,2023,43(增刊1):212-216.
[17] 陈可心,乔焕,方玲玲. 基于 SENet 和 GBDT 的改进 CNN 视网膜疾病多分类[J]. 计算机系统应用,2023,32(8):286-294.
[18] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[J]. IEEE transactions on pattern analysis and machine intelligence,2020,42(8):2011-2023.
[19] 刘宁,孙萍,冯宇平,等. 基于 ResNet18 与胶囊网络结合的人脸表情识别[J]. 青岛科技大学学报(自然科学版), 2023,44(5):109-114.
[20] 赵杰,李絮,申通. 基于 SENet 注意力机制和深度残差网络的腹部动脉分割[J]. 科学技术与工程,2022,22(22):9529-9536.

作者简介:

刘博文(1998-),男,硕士生。研究领域:图像处理,深度学习。
步 扬(1973-),男,博士,教授。研究领域:光学精密检测技术。本文通信作者。
邹多宏(1977-),男,博士,教授。研究领域:智能检测,牙槽骨骨增量和牙齿种植工作。
李建郎(1970-),男,博士,教授。研究领域:新型光纤,固体激光器技术。