

基于残差网络的虹膜图像性别分类

于福升^{1,2,3}, 余江^{1*}, 鲁远甫^{2,3**}, 周志盛^{2,3}, 李光元^{2,3}

¹ 云南大学信息学院, 云南 昆明 650000;

² 中国科学院深圳先进技术研究院, 广东 深圳 518000;

³ 中国科学院人机智能协同系统重点实验室(深圳先进技术研究院), 广东 深圳 518055

摘要 生物特征的识别是计算机科学技术一个有吸引力的研究领域,虹膜作为一种软生物特征,具有唯一性、稳定性和防伪性等优点,从虹膜图像中识别一个人的性别在身份验证和安全监控等领域均具有广阔的应用前景。针对传统机器学习与浅层神经网络在虹膜图像性别分类中存在的不足以及卷积神经网络对图像特征提取的优势,提出一种基于残差网络(ResNet)的虹膜图像性别分类模型,采用 ResNet 结合迁移学习在 ImageNet 图像数据集上进行预训练。采用该模型在数据集上训练一个端到端的虹膜图像性别分类器,准确率达到 94.6%。将训练好的模型与其他相关模型在相同的数据集上进行对比,结果表明该模型的测试精度与识别效率均优于其他模型。

关键词 图像处理; 性别识别; 深度学习; 虹膜; 卷积神经网络; ResNet

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP202158.1610022

Gender Classification of Iris Image Based on Residual Network

Yu Fusheng^{1,2,3}, Yu Jiang^{1*}, Lu Yuanfu^{2,3**}, Zhou Zhisheng^{2,3}, Li Guangyuan^{2,3}

¹ School of Information, Yunnan University, Kunming, Yunnan 650000, China;

² Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen, Guangdong 518000, China;

³ Key Laboratory of Human-Machine Intelligence-Synergy Systems, Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen, Guangdong 518055, China

Abstract The recognition of biometrics is an attractive research field in computer science and technology. As a soft biometric, the iris has the advantages of uniqueness, stability and anti-counterfeiting. Recognizing the gender of a person from the iris image is used in identity verification and security. Monitoring and other fields have broad application prospects. Aiming at the shortcomings of traditional machine learning and shallow neural networks in gender classification of iris image and the advantages of convolutional neural networks in image feature extraction, a residual network (ResNet)-based gender classification of iris image model is proposed, which uses ResNet combined with transfer learning is used for pre-training on ImageNet image dataset. The model is used to train an end-to-end iris image gender classifier on the dataset, the accuracy rate reaches 94.6%. Comparing the trained model with other related models on the same dataset, the results show that the test accuracy and recognition efficiency of this model are better than other models.

Key words image processing; gender classification; deep learning; iris; convolutional neural networks; ResNet

OCIS codes 100.5010; 100.3008; 100.4994; 100.4996

收稿日期: 2020-08-05; 修回日期: 2020-09-22; 录用日期: 2020-10-10

基金项目: 国家重点研究计划(2017YFC0803506)

通信作者: *yujiang@ynu.edu.cn; **yf.lu@siat.ac.cn

1 引言

随着计算机技术的智能化发展,基于计算机的图像处理与深度学习技术在生物识别领域得到了迅速发展。虹膜识别是生物识别技术的一种,广泛应用于模式识别^[1]、图像处理^[2]和机器视觉^[3]等领域。虹膜图像性别识别作为生物特征识别技术的重要研究内容之一,在门禁、安防、身份认证和刑侦等方面具有重要的理论意义与应用价值。虹膜图像性别分类属于属性预测问题,主要采用如下两种方法进行,一是基于传统机器学习的虹膜图像性别分类,二是基于卷积神经网络(Convolutional Neural Networks, CNN)的虹膜图像性别分类。

基于传统机器学习的虹膜图像性别分类属于模式分类问题,一般先对图像进行预处理,即提取小波、纹理和几何等特征,然后将特征输入到分类器中,即决策树和支持向量机(SVM)等。2007年,Thomas等^[4]采用50000多张归一化为20 pixel×240 pixel大小的虹膜图像基于虹膜纹理和几何特征进行预测,准确率接近80%。近年来,Singh等^[5]在ND-iris_0405数据集中选取60259张分辨率为48 pixel×64 pixel的近红外人眼图像,采用自动编码器的变体对图像进行分类,性别预测的准确率达到82.53%。随后,Bobeldyk等^[6]采用二值化统计图像特征(BSIF)和局部二值模式(LBP)在BioCOP2009数据集中对41780张图像进行分类,性别预测的准确率达到86%。虽然传统方法的准确率不断提高,但处理步骤繁多且复杂化,这会导致训练效率较低,不能快速对性别进行分类。

CNN多用于图像分类,与传统机器学习技术相比可以自动提取特征,而且能够避免传统算法设计和特征提取的复杂化,不仅训练效率得到提高,而且准确率也得到了进一步提升。Tapia等^[7]基于CNN并融合双眼虹膜图像进行分类,准确率能够达到84.66%。值得一提的是,Tapia等^[7]在实验过程中仅采用了3000张图像,但存在图像数量不足和神经网络层数较少等问题而导致准确率较低。

针对上述方法存在的问题,本文首先基于PyTorch搭建层数更多且更复杂的残差网络ResNet50深度学习模型,使用该模型对虹膜图像进行性别分类。同时,利用迁移学习并结合Python脚本扩增图像数据集的方法解决小样本训练容易过拟合的问题,提高虹膜图像性别分类的准确率,训练效率也得到大幅度提升,这为虹膜图像性别识别的

工程应用提供支持。最后采用ResNet50、VGG-16(Visual Geometry Group-16)^[8]和GoogleNet^[9]模型在同一数据集中进行对比分析验证,结果表明ResNet50模型在准确率和效率上均具有优势。

2 模型架构分析

针对传统机器学习与浅层神经网络在虹膜图像性别分类中存在的不足,提出一种基于ResNet的虹膜图像性别分类模型,该模型主要包括目标数据的预处理、迁移学习以及目标数据的微调 and 分类等处理步骤,模型的处理流程如图1所示。首先利用大型数据集预训练一个模型,然后将预处理后的虹膜数据集导入模型中并进行迁移学习训练以调整参数,最后通过Softmax分类器输出分类结果。




图1 ResNet模型的处理流程

Fig. 1 Process flowchart of ResNet model

2.1 ResNet 卷积神经网络

2.1.1 ResNet 架构

目前,基于深度学习的图像处理研究工作基本选择CNN^[10-15]作为图像处理的模型,CNN通过对图像的底层特征进行逐层提取,最终形成高度抽象的高层特征,因此卷积层数越深,CNN提取特征的能力就会越强,所以若要得到高的分类准确率,就需要更深层的网络^[16]。对于深层的神经网络,普遍存在梯度爆炸、梯度消失或网络退化问题。其中梯度问题可以通过数据的初始化与批量的标准化^[17]来解决;网络性能退化问题可由2016年He等^[18]提出ResNet模型中的“残差”模块来解决,值得一提的是该网络模型的准确率在当年的ImageNet图像分类大赛中获得了第一名,被该领域专业人士所认可。因此,在虹膜图像性别分类的任务中,将ResNet50作为特征提取骨干网络,并结合迁移学习来构建网络模型,结构如图2所示,其中BN为批标准化。首先输入经过预处理后的虹膜图像,接着对输入的图像采用卷积、标准化、加入非线性函数和最大池化下采样进行处理来减少过拟合,然后通过4个不同层数的残差结构来抑制梯度消失,最后使用Softmax层来实现分类。

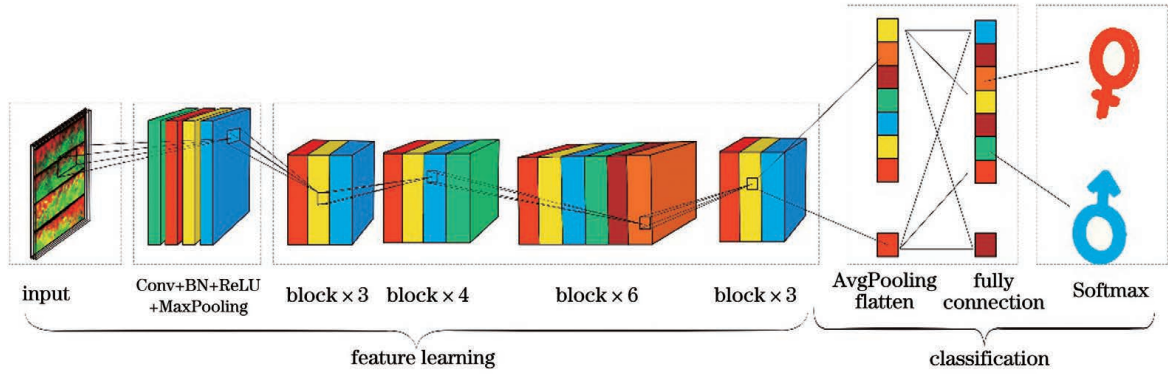


图 2 ResNet50 结构

Fig. 2 Structure of ResNet50

ResNet50 模型包含 49 个卷积层和 1 个全连接层。卷积层是对图像进行卷积操作,最开始经过大小为 7×7 的卷积层,卷积层所用的激活函数为 ReLU 激活函数。最大池化层是对图像进行最大池化下采样操作,大小为 3×3 。模型依次经过 4 个残差块,分别包含在三个残差层、4 个残差层、5 个残差层和三个残差层中,每一个残差块包括一个改变维度的残差层,目的是保证输入的维度与输出相同。使用整个网络对图像进行特征提取,然后加入平均池化层与全连接层对图像进行处理,处理后的特征作为输出,最后在 Softmax 层中将输出转化成概率分布。

但是通过第一次卷积层后,得到的特征图不一定满足所期望的分布规律,因此采用 BN 方法来调整特征图的尺寸,将 BN 层加入卷积层与池化层的中间并对图像进行标准化处理,使输入图像数据调整到满足某一分布的规律,就可以加速网络训练的速度和准确率,使一批特征图满足均值为 0 和方差为 1 的分布规律。首先使用 BN 方法分别求得每一个通道所对应的均值和方差(指的是一批数据在同一个通道中所有数据的均值和方差),然后将原参数减去均值再除以方差就可以得到标准化的数值,最后通过权值参数 τ 和 β 对标准化的数值进行进一步调整以提高训练速度和效率。

针对模型随着卷积层数的加深而出现梯度消失、爆炸或网络退化问题,在 ResNet 模型中增加残差结构,如图 3 所示。残差结构采用一种新的连接方式,即对输入特征 x 进行跨层传递。首先在原网络结构的基础上增加一个新的同等映射,然后将学习的函数与输入数据进行求和,最后通过 ReLU 激活函数对分类的准确率进行计算。残差结构在降低网络计算复杂度的同时不会增加额外的参数,这对提高准确率以及提升训练效率有着重要的作用。




图 3 残差单元的结构

Fig. 3 Structure of residual element

2.1.2 Softmax 分类器

Softmax 分类器大多应用在分类问题方面,其将目标变量映射到 $0 \sim 1$ 之间的实数,并且归一化后保证和为 1。Softmax 分类器接收全连接层传递的特征向量,输出所对应的每个种类的概率值。假设有 N 个输入目标,即 $\{x_1, x_2, \dots, x_N\}$,目标的类别 $y_i \in \{1, 2, \dots, k\}$, i 为样本数, $k \geq 2$ 。对男女性别进行二分类实验, k 值取为 2。对于给定的输入 x_i ,估计其对应类别 j 的概率值,表达式为

$$P(y_i = j | x_i) = f_{\theta}(x_i) = P(y_i = 1 | x_i; \theta) = \frac{\exp(\theta_j^T x_i)}{\sum_{j=1}^k \exp(\theta_j^T x_i)} \quad (1)$$

式中: $\{\theta_1, \theta_2, \dots, \theta_i\}$ 为 Softmax 分类器的参数,使用 $1 / \sum_{j=1}^k \exp(\theta_j^T x_i)$ 可以保证概率和为 1。Softmax 分类器的损失函数,可表示为

$$J(\theta) = -\frac{1}{N} \left\{ \sum_{i=1}^N \sum_{j=1}^k \{y_i = j\} \ln \left[\frac{\exp(\theta_j^T x_i)}{\sum_{j=1}^k \exp(\theta_j^T x_i)} \right] \right\} \quad (2)$$

若指标性函数 $\{y_i = j\}$ 成立,则值为 1,否则为 0。使用 Adam 优化器最小化代价函数,代价函数

越小,说明模型参数符合训练样本。

2.2 迁移学习

迁移学习是将一个原始大型数据集上训练后的 CNN 模型迁移到一个新的目标数据集中进行训练^[19]。一般来说,迁移学习有两种,一是在目标数据集上训练所有层,二是仅冻结并训练最后一层,而其他层的权重不变,或者冻结前几层微调其他层。

在人脸性别分类数据集 ImageNet 上预训练一个模型,即将全连接层之前的各层参数进行初始化后添加全连接层和 Softmax 层,使用目标数据集对整个网络进行微调并进行迁移训练。为了防止过拟合,卷积层的学习率设为 1×10^{-6} ,后面的全连接层的学习率设为 1×10^{-4} ,这不仅可以更好地提取特征,防止过拟合,提高分类精度,还可以加快收敛速度。为了对比迁移学习的效果,在所有实验条件相同的情况下,迁移学习与非迁移学习的结果对比曲线如图 4 所示。从图 4 可以看到,当不使用迁移学习时,模型的收敛速度非常慢,而且泛化能力非

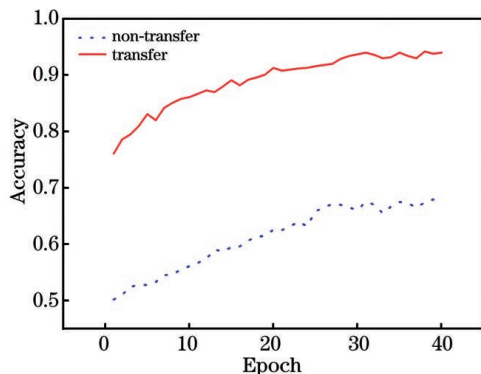


图 4 迁移学习与非迁移学习的效果对比

Fig. 4 Effect comparison between transfer learning and non-transfer learning

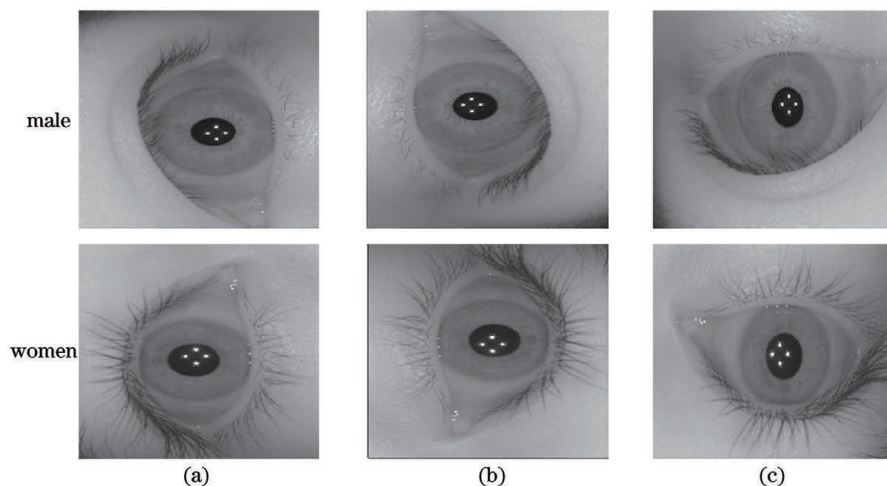


图 6 数据集扩充图像。(a)左旋 90° ; (b)右旋 90° ; (c)上下翻转

Fig. 6 Dataset expansion images. (a) 90° left rotation; (b) 90° right rotation; (c) flip upside down

常差。

2.3 数据集处理

实验研究选用的图像数据集来自中国科学院深圳先进技术研究院所采集的虹膜数据(简称 CAS-IAT-Iris dataset),这些虹膜图像是通过深圳先进技术研究院自研的手持式虹膜仪进行采集的,近红外光下采集的虹膜图像比可见光下的虹膜图像具有更清楚的纹理特征和更适合特征被提取的优点。实验共采集 3365 对包含双眼的虹膜图像,对这些图像的清晰度进行筛选,合格的图像共有 3200 张,图像的分辨率为 $640 \text{ pixel} \times 480 \text{ pixel}$,其中男性、女性的图像各有 1600 张。图 5(a)为拍摄的女性图像示例,图 5(b)为拍摄的男性图像示例。




图 5 不同性别的虹膜图像。(a)女性;(b)男性

Fig. 5 Different gender iris images. (a) Women; (b) male

因深度学习需要大量的样本数据,为了解决深度学习过程中由数据量不足导致的过拟合,需要对每一张图像执行图像扩充处理,为此使用 Python 脚本语言对图像进行随机裁剪和旋转等处理,扩充图像如图 6 所示。将数据集扩增了 5 倍,共计 16000 张,图像按照 7:3 的比例分为训练集和验证集两部分,标签信息分为男、女两类。

将整个数据集随机分成三个部分,即训练集、验证集和测试集,划分比例及数量如表 1 所示。其中训练集、验证集和测试集的划分比例为 7 : 2 : 1,按照这个比例可以使训练集得到很好的训练,验证集可以随时保证监视训练结果。

表 1 实验数据的划分

Table 1 Partition of experimental data

Dataset type	Proportion of data / %	Data
Training dataset	70	11200
Validation dataset	20	3200
Test dataset	10	1600

首先对图 7(a)的虹膜图像进行预处理,用来提取虹膜的纹理特征。训练数据集和测试数据集都来自虹膜图像中虚线圆环所标记出来的虹膜纹理区

域,这个过程称为虹膜定位。为了提高分类的准确性,需要将环形虹膜归一化为矩形并去掉不属于虹膜的部分。同时,网络模型需要处理的是方形图像,为此使用虹膜识别软件 Osiris 将虹膜的环形区域展开成一个分辨率为 224 pixel × 224 pixel 的方形图像。虹膜定位过程中,采用 Daugman 算法^[20]对虹膜图像进行标准化,然后使用直方图均衡化进一步增强归一化虹膜图像的对比度,从而提高虹膜纹理的清晰度,如图 7(b)所示。实验使用的模型为改进的三通道 CNN 模型,每个通道均使用不同的卷积核来提取不同的特征,这可以充分提取虹膜图像的特征并减少模型过拟合,从而提升图像的分类精度,此时需要将原来的 8 bit 的灰度虹膜图像合成为 24 bit 的 RGB(Red, Green, Blue)图像,如图 7(c)所示。



图 7 不同过程所得的图像。(a)定位过程;(b)标准化过程;(c)融合过程

Fig. 7 Images of different processes. (a) Positioning process; (b) standardization process; (c) integration process

3 实验过程及分析

实验环境为 Windows 系统,处理器为 Intel® Xeon® E5-2699 V4 (2.20 GHz) 256 GB RAM 和 NVIDIA® Quadro GP100 GPU。实验所有代码均采用 Python 语言进行编写,并在 PyCharm 平台和 PyTorch 开源框架中实现。对于 ResNet50 模型的训练参数,学习率设为 1×10^{-4} ,损失函数为交叉熵损失函数,批处理大小设为 128,优化器选择为 Adam。最优的参数组合:迭代次数为 40 轮,批处理大小选择 128,学习率选择 1×10^{-4} 。对得到的模型进行保存以便预测。

采用正确率 (ACC) 和训练时间作为模型的评价指标,正确分类的图像数 (M_r) 与图像总数 (M_{all}) 的比就是正确率,表达式为

$$A_{ACC} = \frac{M_r}{M_{all}} \quad (3)$$

ACC 值越大,说明模型的预测能力越强,性能越好。训练时间越短,说明模型的识别效率越高。实验共进行 27 次,每次模型的迭代次数分别为 20、

40 和 60 轮,批处理大小分别设为 64、128 和 256,优化器分别为随机梯度下降 (SGD)、Adagrad 和 Adam。每次固定其中两个参数,改变一个参数,并记录训练结果,最终得到的最佳分类效果如表 2 所示。从表 2 可以看到,最佳的迭代次数为 40,批处理大小为 128,优化器选择 Adam,虹膜图像性别识别的准确率达到 94.6%。

表 2 不同参数下的实验结果

Table 2 Experimental results under different parameters

Epoch	Batch size	Optimizer	Time /s	ACC /%
20	64	SGD	310	87.56
20	64	Adam	334	89.12
20	64	Adagrad	406	88.36
20	128	SGD	180	88.61
20	128	Adam	209	91.53
20	128	Adagrad	228	88.43
20	256	SGD	103	89.21
20	256	Adam	127	91.40
20	256	Adagrad	139	89.13
40	64	SGD	605	89.23

表 2(续)

Epoch	Batch size	Optimizer	Time /s	ACC /%
40	64	Adam	701	91.91
40	64	Adagrad	823	90.34
40	128	SGD	346	92.62
40	128	Adam	384	94.60
40	128	Adagrad	420	93.38
40	256	SGD	182	91.57
40	256	Adam	208	93.36
40	256	Adagrad	234	93.80
60	64	SGD	850	89.35
60	64	Adam	943	91.86
60	64	Adagrad	1100	90.68
60	128	SGD	432	93.12
60	128	Adam	510	94.30
60	128	Adagrad	623	93.70
60	256	SGD	225	93.83
60	256	Adam	274	93.62
60	256	Adagrad	328	93.70

图 8(a)为模型在训练集与验证集上的损失率变化曲线。从图 8(a)可以看到,随着训练次数的不断增加,损失率不断降低,训练到40轮损失率几乎

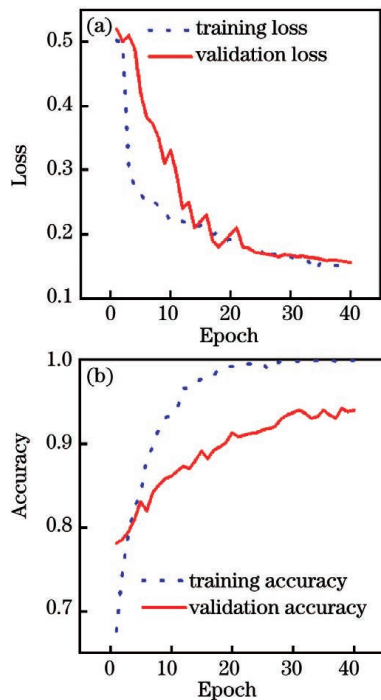


图 8 不同参数下的性能曲线。(a)损失率;(b)准确率
Fig. 8 Performance curves under different parameters.
(a) Loss rate; (b) accuracy

不再下降。图 8(b)为模型在训练集与验证集上的准确率变化曲线。从图 8(b)可以看到,随着训练次数的不断增加,准确率不断升高,训练到 40 轮准确率趋于平缓,不再升高。

VGG-16 采用大小为 3×3 的卷积核和池化层来提取特征,由于卷积核的尺寸较小,为此可以减少网络的参数数量,堆叠更多的卷积层,加深网络的深度,这有利于图像的分类。在网络的最后三层均使用全连接层,将最后一层全连接层的输出作为分类的预测结果。激活函数使用 ReLU 激活函数,加入 Dropout 层可以防止网络的过拟合。GoogleNet 主要特点是网络不仅有深度,还在横向上有宽度。GoogleNet 中加入一种被称为 Inception 模块,其在每个 3×3 和 5×5 的卷积层之前增加 1×1 的卷积层以控制输出的通道数,在最大池化层后面增加 1×1 的卷积层以减少输出的通道数。GoogleNet 在主体卷积部分中使用 5 个模块,每个模块之间使用最大池化层来减小输出的高宽,并且各个模块都是使用不同大小的卷积层,第 3~5 层加入了 Inception 块,其后连接输出层和全局平均池化层,最后连接输出为标签类别的全连接层。

为了增加实验的对比性以及突出残差网络的优势,在使用相同数据集的情况下使用 VGG-16 与 GoogleNet 进行分类实验,结果如图 9 所示。从图 9 可以看到,ResNet 模型的分类准确率高于 GoogleNet 和 VGG-16,而且在收敛速度上也快很多。

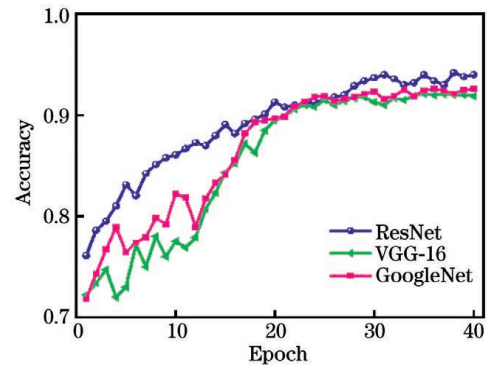


图 9 三种网络的准确率对比曲线

Fig. 9 Accuracy comparison curves of three networks

4 结 论

本文提出一种基于 ResNet50 模型的人类虹膜图像性别分类方法。对虹膜图像进行预处理后再分类,并将分类结果与传统的机器学习分类方法以及浅层神经网络进行比较。实验结果表明,使用卷积

神经网络提取特征比传统机器学习更便捷,分类的准确率更高。ResNet50 模型中的残差块有效地避免了深层卷积神经网络所带来的网络梯度消失、梯度爆炸以及网络退化问题,残差块的加入可以在保证网络深度加深的同时性能不会下降。

同时,本文采用了迁移学习结合图像扩充的方法,避免了数据量不足所导致的过拟合问题。采用该模型在数据集上进行训练和测试,虹膜图像性别识别的准确率达到 94.6%。数据量的增加可以使 ResNet50 模型的分类准确率有望进一步提高,所提方法为虹膜图像的性别识别提供参考和支持。

参 考 文 献

- [1] Wang Y H, Zhu Y, Tan T N. Biometrics personal identification based on iris pattern[J]. Acta Automatica Sinica, 2002, 28(1): 1-10.
王蕴红, 朱勇, 谭铁牛. 基于虹膜识别的身份鉴别[J]. 自动化学报, 2002, 28(1): 1-10.
- [2] Xing L, Shi P F. A quality evaluation method of iris images[J]. Chinese Journal of Stereology and Image Analysis, 2003, 8(2): 108-113.
邢磊, 施鹏飞. 虹膜图像的质量评价方法[J]. 中国体视学与图像分析, 2003, 8(2): 108-113.
- [3] Yan M J, Wang Y J. Principle of iris computer recognition[J]. Progress in Biochemistry and Biophysics, 2000, 27(4): 348-350.
严民军, 汪云九. 虹膜的计算机识别原理[J]. 生物化学与生物物理进展, 2000, 27(4): 348-350.
- [4] Thomas V, Chawla N V, Bowyer K W, et al. Learning to predict gender from iris images[C]//2007 First IEEE International Conference on Biometrics: Theory, Applications, and Systems, September 27-29, 2007, Crystal City, VA, USA. New York: IEEE Press, 2007: 9871360.
- [5] Singh M, Nagpal S, Vatsa M, et al. Gender and ethnicity classification of iris images using deep class-encoder[C]//2017 IEEE International Joint Conference on Biometrics (IJCB), October 1-4, 2017, Denver, CO, USA. New York: IEEE Press, 2017: 666-673.
- [6] Bobeldyk D, Ross A. Analyzing covariate influence on gender and race prediction from near-infrared ocular images [J]. IEEE Access, 2019, 7: 7905-7919.
- [7] Tapia J, Aravena C. Gender classification from NIR iris images using deep learning[M]//Bhanu B, Kumar A. Deep learning for biometrics. Advances in computer vision and pattern recognition. Cham: Springer, 2017, 84: 219-239.
- [8] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10) [2020-08-04]. <https://arxiv.org/abs/1409.1556>.
- [9] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 15523970.
- [10] LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [11] Wang M, Fan T F, Yun W G, et al. PFWG improved CNN multispectra remote sensing image classification[J]. Laser & Optoelectronics Progress, 2019, 56(3): 031003.
王民, 樊潭飞, 负卫国, 等. PFWG 改进的 CNN 多光谱遥感图像分类[J]. 激光与光电子学进展, 2019, 56(3): 031003.
- [12] Hu L, Shan R, Wang F, et al. Hyperspectral image classification based on dual-channel dilated convolution neural network [J]. Laser & Optoelectronics Progress, 2020, 57(12): 122803.
胡丽, 单锐, 王芳, 等. 基于双通道空洞卷积神经网络的高光谱图像分类[J]. 激光与光电子学进展, 2020, 57(12): 122803.
- [13] Wang Y N, Zhu D N, Wang H Q, et al. Multispectral image classification of mural pigments based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(22): 221001.
王燕妮, 朱丹娜, 王慧琴, 等. 基于卷积神经网络的壁画颜料多光谱图像分类[J]. 激光与光电子学进展, 2019, 56(22): 221001.
- [14] Liu Y Z, Jiang Z Q, Ma F, et al. Hyperspectral image classification based on hypergraph and convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(11): 111007.
刘玉珍, 蒋政权, 马飞, 等. 基于超图和卷积神经网络的高光谱图像分类[J]. 激光与光电子学进展, 2019, 56(11): 111007.
- [15] Meng T, Liu Y H, Zhang K Y. Algorithm for pathological image diagnosis based on boosting convolutional neural network[J]. Laser & Optoelectronics Progress, 2019, 56(8): 081001.
孟婷, 刘宇航, 张凯昱. 一种基于增强卷积神经网络的病理图像诊断算法[J]. 激光与光电子学进展, 2019, 56(8): 081001.
- [16] Wu Z F, Shen C H, van den Hengel A. Wider or deeper: revisiting the ResNet model for visual recognition[J]. Pattern Recognition, 2019, 90: 119-

- 133.
- [17] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[EB/OL]. (2015-03-02) [2020-08-04]. <https://arxiv.org/abs/1502.03167>.
- [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] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [20] Daugman J. How iris recognition works [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2004, 14(1): 21-30.