

DOI:10.19651/j.cnki.emt.2211892

基于孪生网络的小样本轮胎花纹验证算法*

夏煜丹¹ 刘书朋¹ 田静² 商娅娜¹ 陈娜¹

(1. 上海大学通信与信息工程学院 上海 200444; 2. 东南大学成贤学院电子与计算机学院 南京 210088)

摘要: 为推进车辆安全检查中同轴轮胎类型判别自动化的实现,提出一种基于孪生网络的轮胎花纹图像验证算法。该算法面向小样本轮胎花纹图像,在孪生网络的基础架构上,增加方向矫正的图像预处理模块,实现轮胎花纹的对齐,消除轮胎图像间明显纹理的方向特征差异;在其子网络的低层级卷积网络中使用 Gabor 方向滤波器,提升网络对轮胎花纹纹理特征的学习速度以及对不同质量轮胎图像识别的鲁棒性。在 CIIP_TPID 和 WTP 数据集上的实验表明,该算法的准确率分别达到 0.926 和 0.849。

关键词: 图像验证;孪生网络;小样本;方向矫正;Gabor 方向滤波器

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Small sample tire pattern verification algorithm based on siamese network

Xia Yudan¹ Liu Shupeng¹ Tian Jing² Shang Yana¹ Chen Na¹

(1. School of Communication and Information Engineering, Shanghai University, Shanghai 200444, China;

2. School of Electron and Computer, Southeast University Chengxian College, Nanjing 210088, China)

Abstract: To promote the automatic realization of coaxial tire type discrimination in vehicle safety inspection, a tire pattern image verification algorithm based on siamese network was proposed. The algorithm is oriented to the tire pattern images of small data sets. On the infrastructure of the siamese network, an image preprocessing module of orientation correction is added to realize the alignment of tire patterns and eliminate the obvious orientation difference between tire images. The Gabor Orientation Filters are used in the low-level convolutional network of its subnetwork to improve the learning speed of the network on tire pattern texture features and the robustness of tire image recognition with different quality. Experimental results on CIIP_TPID and WTP datasets show that the accuracy of the proposed algorithm is 0.926 and 0.849 respectively.

Keywords: image verification; siamese network; small sample; correction of direction; Gabor orientation filter

0 引言

随着经济水平的发展,人们对汽车的购买量大幅增加,随之而来的是汽车安全检查任务的加重。据统计,发生在高速公路上的交通事故中,有 46% 源自轮胎故障。目前针对轮胎安全状况的检查,还是以人工目测或是手持工具检测为主。人工检测方法虽然适应性强,但耗费大量的人力和时间,无法对百万及千万数量级的机动车轮胎进行快速筛选检测,及时发现问题。自动化以及图像处理技术的发展,为此提供了一种新的解决方案。通过图像处理技术实现同轴轮胎花纹的类别判定,能够避免车主因配置不同类型轮胎,导致车辆与地面的摩擦系数不同、抓地力不平衡、排水性能不一致产生侧滑现象^[1-2],影响行车安全。

目前,在轮胎花纹识别方向的研究中,按照特征提取方

式可分为两种,基于低级空间特征和基于高级语义特征的轮胎图像识别。低级空间特征的提取对轮胎数据集大小的要求较低,主要通过手工提取的特征来衡量轮胎图像之间的相似度,如改进的 HOG 特征^[3]、灰度共生矩阵(gray-level co-occurrence matrix, GLCM)^[4-5]、局部二值模式(local binary pattern, LBP)^[6]、尺度不变特征(scale-invariant feature transform, SIFT)^[7-8]。手工特征对图像质量要求较为苛刻,轮胎胎面必须保持洁净,胎面异物或是不同拍摄环境、拍摄角度都会引起图像特征的极大变化。因此近年来,轮胎花纹的特征提取方式逐渐采用深度学习的方法。刘颖等^[9-10]在大型数据集 ImageNet^[11]预训练的网络模型基础上,通过迁移学习(transfer learning)^[12]完成轮胎花纹图像的类别判定;张素智等^[13]基于改进的

收稿日期:2022-10-30

* 基金项目:国家自然科学基金(62175142,61875118)项目资助

AlexNet^[11]卷积神经网络实现了破损轮胎图像的识别; Qiang 等^[14]使用孪生网络^[15]结构,将普通卷积替换为可分离卷积^[16],在卷积网络提取的高级语义特征中结合小波变换^[17]的低级纹理特征,实现轮胎花纹图像检索。在上述轮胎花纹识别研究中,主要用于轮胎花纹检索或分类,在已有的多个轮胎类别中,找到最相似的某一个图像或某一个类别作为输出结果。而本文的研究重点在于轮胎图像验证,实现对输入轮胎图像对的类型判别。该方向的研究相对较少。其关键在于,是否能够在小样本数据集的输入图像对训练之下,获得一个泛化性较强的距离函数,实现在测试时,输入未知类型的图像对,能够通过预先得到的距离函数判别该图像对是否匹配。此外,我们希望当轮胎图像的拍摄环境变化时,该函数仍然具有较强的鲁棒性,使得算法能够普遍应用于不同的车检环境。

在图像验证领域,人脸验证已经得到了极其广泛的研究,不少经典的人脸验证网络框架被提出,如 DeepFace^[18]、DeepID^[19]、FaceNet^[20] 和 SphereFace^[21],这些框架大都基于大型的人脸数据集。相比于人脸验证,轮胎图像验证存在如下难点:1)开源的大型轮胎花纹数据集极少;2)实际场景的轮胎图像质量不可保证,每张图片中轮胎的方位、光照、嵌入物和磨损可能都大有不同;3)轮胎花纹不具有类似人脸验证中用于对齐或是局部特征提取的关键特征,如眼、鼻、嘴等。

考虑到上述问题,本文选取孪生网络作为基本架构,该架构能够在小数据集的轮胎花纹图像中学习得到高表达的嵌入函数,并在识别未知类型轮胎花纹时无需重复训练网络模型;通过轮胎图像方向矫正减少网络对于图像明显纹理的方向信息的学习,有助于在有限的样本中提取更多的纹理特征;使用 Gabor 方向滤波器构建初级特征提取的卷积层,提高网络对轮胎细节纹理的方向和尺度变化的不变性,增强网络的特征提取能力,并使用 CHIP-TPID 和 WTP 两个数据集进行分析验证。

1 相关工作

1.1 孪生网络

孪生网络是小样本学习中最简单且常用的模型之一。最早用来解决签名验证问题,后被广泛应用于图像匹配^[22-23]、人脸识别^[24-25] 和目标跟踪^[26-27] 等领域。孪生网络由一对结构相同、权值共享的子网络组成,两张待验证的图像通过这一对子网络被映射到一个低维空间中。再通过规定好的距离计算公式得到低维空间中两个特征向量间的距离,表示输入图像间的差异。

相比于其他网络模型,孪生网络只需要在开始时,从包含足够样本的数据集中学习通用嵌入函数,就可直接将此嵌入函数用于测试数据的识别,而无需重新训练;得益于其结构特点,使用小数据集图像同样也能训练出良好的模型;其子网络一般为卷积神经网络,针对不同各具特色的图像

识别任务,便于选择合适的网络结构。适合用于轮胎花纹图像的验证识别。

1.2 Gabor 方向滤波器

Gabor 方向滤波器(gabor orientation filters, GoFs)由 Luan 等^[28]提出,属于可导向滤波器的一种,替换普通卷积层中的滤波器,能够提升网络特征处理空间变换的能力。

$$C_i^v = (C_{i,1}^v, \dots, C_{i,u}^v, \dots, C_{i,U}^v) \quad (1)$$

$$C_{i,u}^v = C_{i,o} \circ G(u, v) \quad (2)$$

假设普通卷积层的学习滤波器 $C_{i,o}$ 是一个 $N \times K \times K$ 的二维滤波器, N 为图像通道数量, $K \times K$ 为图像大小。GoF C_i^v 则是一个由 U 个方向的滤波器共同组成的大小为 $U \times N \times K \times K$ 的三维滤波器, U 为方向数, v 为指定的尺度大小。调制滤波器 $C_{i,u}^v$ 由 v 尺度的 $G(u, v)$ 调制 $C_{i,o}$ 得到,即对普通的学习滤波器进行方向编码,并嵌入了尺寸信息。

因此,当卷积层输入为 F 时输出特征图 \hat{F} 为:

$$\hat{F} = GCConv(F, C_i) \quad (3)$$

反向传播时,只需要更新学习滤波器 $C_{i,o}$,即可实现 $C_{i,u}^v$ 的参数更新:

$$\delta = \frac{\partial L}{\partial C_{i,o}} = \sum_{u=1}^U \frac{\partial L}{\partial C_{i,u}^v} \circ G(u, v) \quad (4)$$

加入了方向和尺度信息的 Gabor 卷积层拥有比普通卷积层更紧凑的结构,在同等参数数量的情况下, Gabor 卷积层能够获得更多关于纹理特征的信息,加快网络对于输入图像纹理特征的学习。

2 实验设计

2.1 基于 Hough 变换的方向矫正

Hough 变换是将图像空间中的点转换到参数空间上,可以用来检测图像中点集的形状。这里主要用它来检测直线。基本原理为:将原始图像空间多个散点中的每两点设为一组,每组数据可通过 Hough 变换变换公式:

$$r = x_0 \cos \theta + y_0 \sin \theta \quad (5)$$

式中: r 为原点距, θ 为方向角, x_0, y_0 为散点的坐标。带入两个散点的坐标后,便可求出这两个参数的值。当多组数据在横坐标为 θ , 纵坐标为 r 的坐标系上相交时,交点所在的原点距和方向角即可构成一条直线,若存在多个交点,即可获得多条直线。本文使用 Hough 变换检测轮胎图像沟槽线中接近直线的边缘线,然后根据直线矫正图像方位,实现轮胎花纹的对齐。

轮胎花纹按照沟槽走向分为直沟花纹、横沟花纹、纵横沟花纹和块状花纹。这些花纹都有明显的线状结构,若找到明显的沟槽线,便可通过沟槽线中接近直线的线段方向角来旋转图像,保持轮胎之间的方向一致性。图像处理流程如图 1 所示。

原始轮胎图像(灰度图)输入后通过中值滤波进行中

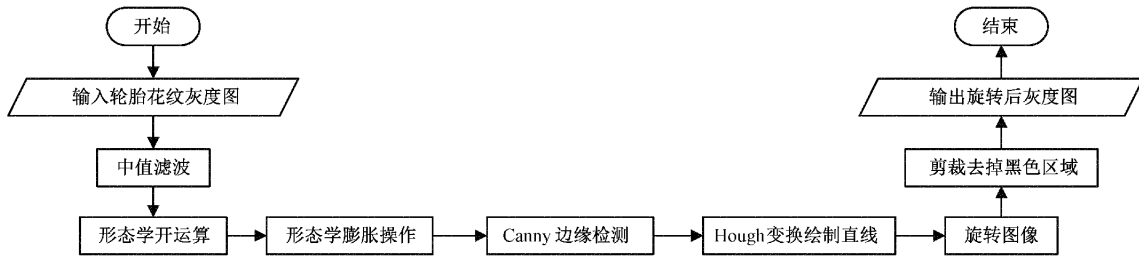


图 1 方向矫正实现流程

值模糊,消除噪声以及轮胎花纹表面杂质产生的细小斑驳。形态学开运算将保留图像局部中的大色块,剔除小色块,达到去除轮胎花纹细节纹理的目的。形态学膨胀操作进一步消除短小纹理,保留宽度较大且颜色差异较大的沟槽部分。Canny 边缘检测保留图像边缘轮廓。Hough 变换设置阈值后,根据已有的边缘绘制直线,并以极坐标方式记录这些边缘的拟合直线。计算得到的所有直线的角度,取与角度众数相同的任一直线作为花纹沟槽的拟合直线(一般为纵向沟槽线),并根据拟合直线的方向角 θ 逆时针旋转图像,使得拟合直线呈竖直方向。由于单单旋转会让图像四周产生黑色三角区域,根据式(6)得到新图像大小的边长 b 。

$$b = \frac{a}{\sin\theta + \cos\theta} \quad (6)$$

a 为原图像边长, θ 为图像沟槽拟合直线的方向角。按新边长 b 剪切图像,得到没有黑色区域的最终图像。至此,方向矫正基本完成。主要处理过程及矫正结果如图 2 所示。其中,第 1 列为原始图像,第 2 列为中值滤波后图像,第 3 列为形态学开运算后图像,第 4 列为形态学膨胀操作后图像,第 5 列为 Canny 边缘检测后图像,第 6 列为 Hough 变换后图像,第 7 列为旋转后图像,第 8 列为剪切后图像也为最终方向校正后图像;第 1 行为直沟花纹,第 2 行为横沟花纹,第 3 行为纵横沟花纹,第 4 行为块状花纹。




图 2 4 种类型轮胎花纹方向矫正的过程

2.2 建议的网络框架

本文提出如图 3 所示的网络框架。训练时,一对图像按规则进行方向矫正并调整大小后,经过两个卷积网络分支,分支将输出一对描述图像特征的低维空间向量 h_1, h_2 , 完成图像对的特征提取。使用欧氏距离公式计算出这两个向量的距离 $|h_2 - h_1|$, 与此同时,通过标签确定输入的图像对是否为一类,然后根据损失函数进行学习参数的惩罚,不断调整特征图。

损失函数使用对比损失函数^[29],公式如下:

$$L = \frac{1}{2}lD^2 + \frac{1}{2}(1-l)\{\max(0, m - D)\}^2 \quad (7)$$

l 为标签值,当图像对为同类时, l 为 1,反之则为 0。 m

是一个大于零的可设置的边界值, D 为两个特征向量的距离,即 $|h_2 - h_1|$ 。

由式(7)可得,标签为同类时,图像对的损失为 $\frac{1}{2}D^2$,不同类的图像对只有距离小于 m 时,损失存在,为 $\frac{1}{2}(m - D)^2$ 。该损失函数鼓励同类图像对在特征空间中不断靠近,不同类图像对不断远离。

测试图像对数据时,将计算得到的图像对距离与设定阈值进行比较,完成类别判定,即图像验证。在阈值范围内的图像对被判为同类,反之判为不同类。

孪生网络的分支一般采用简单卷积神经网络,特别是

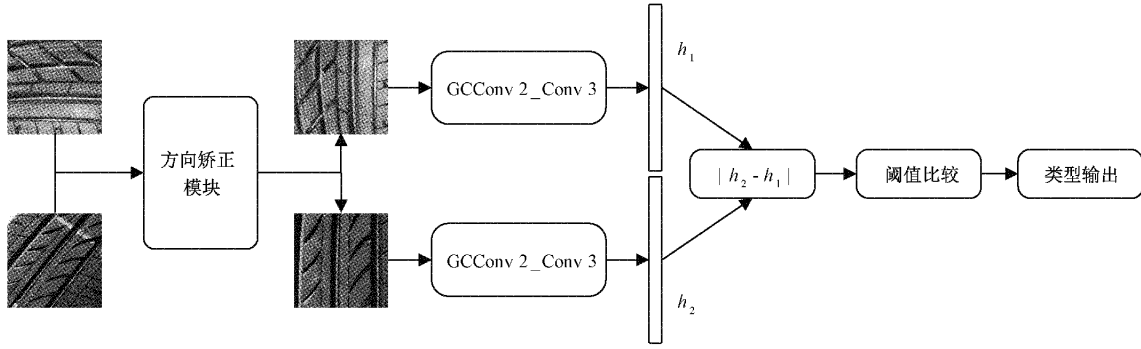


图 3 整体网络框架示意图

对于小数据集图像而言。本文采用图 4 所示,一种 Gabor 卷积层与普通卷积层结合的增强网络模型 GCCConv2_Conv3。该模型包括两个 Gabor 卷积层、3 个普通卷积层和一个全连接层。Gabor 卷积层中的 GoF 集中在 4 个方向(45°,90°,135°,180°)。输入图像大小为 1×224×224 的灰度轮胎花纹图像,经复制后扩展为 4 通道。图中“4×5×

5×16”表示 16 个大小为 4×5×5 的 GoF。 v 代表尺度,其大小随着层数的增多而增加。激活函数为 Relu,最大池化层核大小为 2×2。在两个 Gabor 卷积层后,取 4 个方向的特征图中权值最大的一个作为选定层,传入后续卷积层。3 个普通卷积层后连接一个有 512 个神经元的全连接层,输出一个长度为 512 的特征向量。




图 4 子网络结构 GCCConv2_Conv3 示意图

3 实验与分析

3.1 实验数据集

CIIP-TPID 轮胎表面花纹数据集,来自西安邮电大学。共 35 类轮胎花纹,每类 80 张,共 2 800 张图像,其中 25 类生成训练和验证图像对,10 类生成测试集图像对。该数据集原始图像是大小为 384×384 的彩色图像,在进行方向矫正后,图像大小不一,需要调整大小至 224×224,并转变为灰度图像。WTP 野外场景轮胎花纹数据集,由我们自行拍摄并制作得到。拍摄时,摄像头的俯仰角和偏航角设置在 -15°~15°之间,来模拟实际场景下硬件设备的拍摄位置。共 40 类轮胎花纹,每类 10 张,同样制作成 224×224 的灰度图像,用于野外场景测试。图 5 为两个数据集的样本举例。

3.2 实验环境和评价指标

本文实验的硬件环境为 CPU Core(TM) 3.6 GHz, GPU NVIDIA RTX3080,内存 32 G,软件环境为 python3.8.8, Torch1.9.0。在整个训练过程中使用 Adam 优化器来学习和更新网络参数,学习率为 0.001。训练的批处理大小 batch 为 32,训练次数(epoch)为 100。

用于评估本文提出的轮胎花纹识别卷积网络模型的




图 5 数据集样本

指标包括 ROC 曲线(receiver operating characteristic curve)、等错误点(equal error rate, EER)和识别准确率(accuracy)。ROC 曲线的纵轴为真正例率 TPR,横轴为假正例率 FPR,能够体现在选择分类的不同阈值时,该分类器预测性能的优劣。EER(equal error rate)为直线 TPR=1-FPR 与 ROC 曲线交点,即等错误率点,一般将其设为最佳阈值分割点,EER 越小,错误识别率越低,识别准确率越高。

3.3 实验结果分析

对于网络结构的选择,本文使用 CIIP-TPID 数据集对

比了不同数量的 Gabor 卷积层对网络训练速度以及图像验证识别效果。图 6 为训练 100 个 epoch 过程中不同网络结构对应的准确度。图 7 为不同数量卷积层的 ROC 曲线对比图。从两张图中可以看出,不同数量的 Gabor 卷积层会影响网络的训练速度以及网络的学习效果,并不是越多越好。GCconv2_Conv3 结构的训练速度最快,并且在 ROC 曲线中得到的 EER 最小,证明它对图像的错误识别率最低。

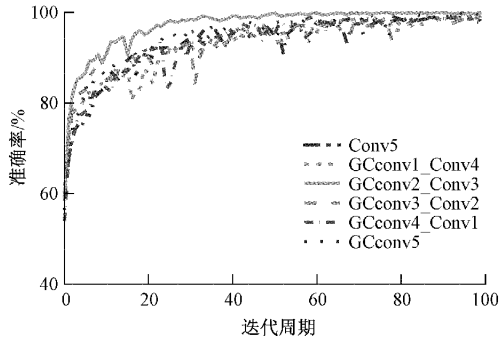


图 6 对比不同数量 Gabor 卷积层的训练准确率图




图 7 对比不同数量 Gabor 卷积层的 ROC 曲线图

图 8 对比了在方向矫正模块及 Gabor 卷积层加入前后的 ROC 曲线图, $_NDC$ 代表未使用方向矫正模块。可以看到 Conv5 和 GCconv2_Conv3 的 EER 都分别高于 Conv5_NDC 和 GCconv2_Conv3_NDC, 证明方向矫正模块的确存在数据增强的效果。GCconv2_Conv3 的 EER 是四条曲线中最小的, 由此可见, 方向矫正模块与 Gabor 卷积层的加入共同提升了该模型对轮胎花纹图像的识别准确率。

为进一步验证 GCconv2_Conv3 结构的有效性, 在加入方向矫正模块的情况下, 对比一些经典的卷积神经网络, 如 VGG16^[30]、AlexNet^[11]、RestNet18^[31] 和 Densenet_BC^[32], 结果如图 9 所示。图中 GCconv2_Conv3 的 EER 最小, Densenet_BC 次之。说明在只有小数据集轮胎花纹图像的情况下, 本文提出的 GCconv2_Conv3 结构能够提取更有效的图像特征。

表 1 显示了在加入方向矫正模块的前提下, 不同网络结构在 CIIP-TPID 和 WTP 两个数据集的识别准确率, 以

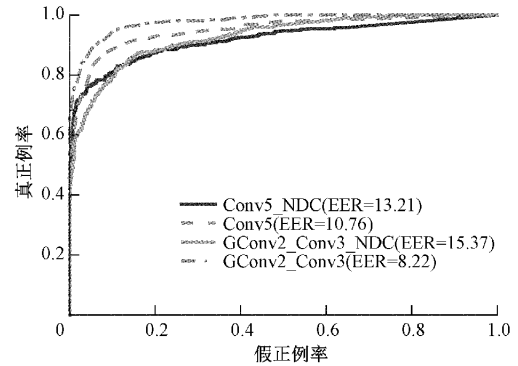


图 8 Gabor 卷积层加入前后的 ROC 曲线图。Conv5_NDC、GCconv2_Conv3_NDC 为未使用方向矫正模块的 Conv5 和 GCconv2_Conv3 模型

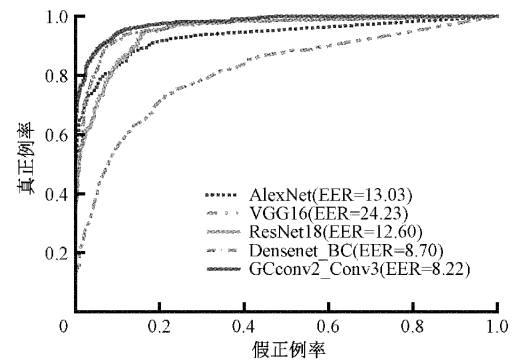


图 9 对比不同网络结构的 ROC 曲线图

及使用 CIIP-TPID 数据集训练时, 每个 epoch 的耗时情况。在两个数据集的测试中 GCconv2_Conv3 的准确率都为最佳, 分别为 0.926 和 0.849。WTP 数据集的准确率明显低于 CIIP-TPID 数据集, 是因为 WTP 模拟了实际场景的轮胎状况和硬件拍摄装置, 导致轮胎图像质量不理想, 图像验证准确率下降。此外, 从表中的耗时情况可以看到, 与 GCconv2_Conv3 准确率接近的 Densenet_BC, 每个训练 epoch 的耗时几乎是前者的两倍, 表明本文的网络模型的确在识别准确率和训练时间上都有明显的优势。

表 1 采用不同网络结构的实验准确率与耗时对比

CNN	准确率		每个迭代周期 所需时间 (CIIP-TPID)
	CIIP-TPID	WTP	
VGG16	0.746	0.690	17.14 s
AlexNet	0.831	0.656	9.89 s
RestNet18	0.865	0.766	14.31 s
Densenet_BC	0.912	0.818	13.40 s
GCconv2_Conv3(OURS)	0.926	0.849	7.02 s

4 结 论

本文提出了一种针对小样本轮胎花纹图像验证的新

颖算法。该算法通过孪生网络实现轮胎花纹图像的嵌入函数学习,用来识别未知轮胎对的类别。算法的创新点在于,通过方向矫正模块和 Gabor 卷积层的结合,提升卷积网络的特征提取能力,提高图像识别准确率。实验结果表明,本文提出的模型相比于经典特征提取模型,其识别准确率、训练速度在小数据集的轮胎花纹图像数据集中均显现出优势,在轮胎类型判别自动化的应用上有重要意义。在后面的实验中,可进一步优化方向矫正模块的泛化性和准确性,并结合轮胎花纹纹理的特点改进网络结构,提高模型在实际场景下的识别准确率。

参考文献

- [1] 钱浩. 轮胎滑水与噪声性能关系及协同提升方法研究[D]. 镇江:江苏大学,2019.
- [2] 胡德斌,王剑波,李磊. 轮胎滚动阻力与花纹特性的相关性研究[J]. 轮胎工业,2022,42(5):272-276.
- [3] LIU Y, GE Y, WANG F, et al. A rotation invariant HOG descriptor for tire pattern image classification [C]. International Conference on Acoustics, Speech and Signal Processing(ICASSP), 2019;2412-2416.
- [4] 李宏玲,董玉德,黄智豪,等. 基于相似性理论的轮胎花纹相似度检测与分析[J]. 中国机械工程,2021,32(14):7.
- [5] 贾世英,马姣婷. 基于小波变换和灰度共生矩阵的轮胎花纹检索[J]. 计算机测量与控制,2016,24(6):4.
- [6] CAI C, LIN M. Tire pattern similarity detection based on template matching and LBP [C]. 2019 3rd International Conference on Electronic Information Technology and Computer Engineering (EITCE), 2019;419-423.
- [7] YAN H, LIU Y. An improved texture feature extraction method based on radon transform[C]. 2014 Seventh International Symposium on Computational Intelligence and Design, 2014;481-485.
- [8] GUO F, YANG J, CHEN Y, et al. Research on image detection and matching based on SIFT features[C]. 2018 3rd International Conference on Control and Robotics Engineering(ICCRE), 2018;130-134.
- [9] 刘颖,葛瑜祥. 基于 CNN、SVM 和迁移学习的轮胎花纹分类[J]. 西安邮电学院学报,2018,23(3):38-43.
- [10] LIU Y, ZHANG S, WANG F, et al. Tread pattern image classification using convolutional neural network based on transfer learning[C]. 2018 IEEE International Workshop on Signal Processing Systems (SiPS), 2018;300-305.
- [11] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6):84-90.
- [12] OQUAB M, BOTTOU L, LAPTEV I, et al. Learning and Transferring mid-level image representations using convolutional neural networks [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014;1717-1724.
- [13] 张素智,吴玉红,常俊. 基于改进 AlexNet 卷积神经网络的轮胎图像识别[J]. 计算机技术与发展:2021, 31(7):182-186.
- [14] QIANG Y, SHANG C, YIN D. Method of tire pattern image retrieval based on wavelet transform and Siamese network [C]. Proceedings of the 2020 International Conference on Aviation Safety and Information Technology, Association for Computing Machinery, 2020;587-592.
- [15] CHICCO D. Siamese neural networks: An overview[J]. Methods in Molecular Biology, 2021, DOI: 10. 1007/978-1-0716-0826-5_3.
- [16] HOWARD A, ZHU M, CHEN B, et al. MobileNets: Efficient convolutional neural networks for mobile vision applications[J]. ArXiv Preprint, 2017, ArXiv. 1704. 04861.
- [17] AGARWAL S, VERMA A, SINGH P. Content based image retrieval using discrete wavelet transform and edge histogram descriptor[C]. 2013 International Conference on Information Systems and Computer Networks, 2013;19-23.
- [18] TAIGMAN Y, YANG M, RANZATO M, et al. DeepFace: Closing the gap to human-level performance in face verification [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014;1701-1708.
- [19] SUN Y, WANG X, TANG X. Deep learning face representation from predicting 10,000 Classes [C]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014;1891-1898.
- [20] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: A unified embedding for face recognition and clustering[C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015: 815-823.
- [21] LIN W, WEN Y, YU Z, et al. SphereFace: Deep hypersphere embedding for face recognition[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2017;6738-6746.
- [22] MELEKHOV I, KANNALA J, RAHTU E. Siamese network features for image matching[C]. 2016 23rd International Conference on Pattern Recognition(ICPR), 2016;378-383.

- [23] NEPOVINNYKH E, EEROLA T, KALVIAINEN H. Siamese network based pelage pattern matching for ringed seal re-identification [C]. 2020 IEEE Winter Applications of Computer Vision Workshops(WACVW), 2020:25-34.
- [24] WU H, XU Z, ZHANG J, et al. Face recognition based on convolution siamese networks[C]. 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), 2017:1-5.
- [25] HEIDARI M, FOULADI-GHALEH K. Using siamese networks with transfer learning for face recognition on small-samples datasets [C]. 2020 International Conference on Machine Vision and Image Processing(MVIP), 2020:1-4.
- [26] BERTINETTO L, VALMADRE J, HENRIQUES J, et al. Fully-convolutional siamese networks for object tracking [C]. Computer Vision-ECCV 2016 Workshops, 2016:850-865.
- [27] ZHANG J, SUN J, WANG J, et al. An object tracking framework with recapture based on correlation filters and Siamese networks [J]. Computers & Electrical Engineering, 2022, 98: 107730.
- [28] LUAN S, CHEN C, ZHANG B, et al. Gabor convolutional networks [J]. IEEE Transactions on Image Processing, 2018,27(9):4357-4366.
- [29] HADSELL R, CHOPRA S, LECUN Y. Dimensionality reduction by learning an invariant mapping[C]. 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR), 2006:1735-1742.
- [30] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [J]. ArXiv Preprint, 2014, ArXiv: 1409.1556.
- [31] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [32] HUANG G, LIU Z, VAN D M L, et al. Densely connected convolutional networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 4700-4708.

作者简介

夏煜丹, 硕士, 主要研究方向为计算机视觉、深度学习。

E-mail: yudanxia11@163.com

刘书朋(通信作者), 博士, 副教授, 主要研究方向为生物医学光子技术、计算机视觉。

E-mail: liusp@shu.edu.cn