DOI: 10.3901/JME.2021.17.086

基于两阶段深度迁移学习的面料疵点检测算法^{*}

赵树煊^{1,2} 张洁^{1,2} 汪俊亮^{1,2} 徐楚桥³

- (1. 东华大学人工智能研究院 上海 201620;
2. 上海工业大数据与智能系统工程技术研究中心 上海 201620;
3. 上海交通大学机械与动力工程学院 上海 200240)

摘要: 针对针织格纹面料疵点检测存在检测实时性差和疵点数据稀缺的问题, 提出一种基于两阶段深度迁移学习的面料疵点检测算法, 实现对疵点的实时高精度检测与检测模型的高效训练。第一阶段迁移: 设计面料疵点先验知识迁移算法, 通过聚类算法求得交并比最优的四类疵点预选框尺寸参数, 使用带有先验知识的疵点预选框替代基于特征的定位方法, 实现面料疵点尺寸特征先验知识的迁移, 提高面料疵点的定位速度; 第二阶段迁移: 设计面料特征提取能力迁移算法, 利用不同种面料之间具有通用特征的特性, 通过将纯色棉麻布检测模型参数迁移至格纹面料检测模型, 实现对面料通用特征提取能力的迁移, 减少检测模型训练所需的样本数量, 提高检测模型训练效率。实验结果表明, 在检测性能方面, 提出的面料疵点检测算法检测精度为 95%、检测速度可达 30 m/min, 优于传统的目标检测算法, 能够满足面料生产中对于检测性能的要求; 在模型训练方面, 检测模型训练所需疵点样本数量减少 50%以上、检测模型训练速度同比提高 3 倍。

关键词: 面料疵点检测; 深度学习; 迁移学习

中图分类号: TP391

Fabric Defect Detection Algorithm Based on Two-stage Deep Transfer Learning

ZHAO Shuxuan^{1,2} ZHANG Jie^{1,2} WANG Junliang^{1,2} XU Chuqiao³

- (1. Institute of Artificial Intelligence, Donghua University, Shanghai 201620;
2. Shanghai Industrial Big Data and Intelligent Systems Engineering Technology Center, Shanghai 201620;
3. School of Mechanical Engineering, Shanghai Jiao Tong University, Shanghai 200240)

Abstract: To solve the problem of low real-time detection and lack of defect images data in fabric defect detection. The fabric defect detection algorithm based on two-stage deep transfer learning is proposed, realizing the real-time detection and efficient training of four types of defects in plaid fabric. First stage transfer, fabric defect prior knowledge transfer algorithm which takes the feature of defects as the transfer object is designed and four kinds of defect pre-boxes parameters with optimal intersection ratios are obtained by clustering algorithm. The pre-boxes with prior knowledge are used to replace the method based on fabric features in defects location, realizing the transfer of the fabric defect features' prior knowledge and improving the location speed of fabric defects. Second stage transfer, a fabric feature extraction ability transfer algorithm is designed to take advantage of the universal feature among different fabrics, the universal feature extraction abilities of convolutional neural network are realized by transferring parameters of linen detection model to patterned plaid detection model, so as to reduce the number of samples that model training need and improve the effectiveness of model training. The experimental results show that, in terms of detection performance, the detection algorithm we proposed has a detection accuracy of 95%, which is better than traditional algorithm and can satisfy the requirements of detection. In terms of model training, the number of fabric defects are reduced at least 50%, and the speed of model training is increased by more than 3 times.

Key words: fabric defects detection; deep learning; transfer learning

0 前言

面料疵点检测是纺织品质量控制过程中的关键

环节之一, 当前主流的面料疵点检测方法仍为人工检测。然而人工检测方法不仅费时费力, 且准确率不高, 对于一些颜色差异不明显、尺寸微小的疵点, 人工检测的方法远远无法满足实际生产的检测需求。使用机器视觉技术来实现面料疵点的高精度自动检测从而替代人工检测, 对于纺织品生产提质增效有着重要意义^[1]。

^{*} 国家自然科学基金(51905091)、上海市教育发展基金会和上海市教育委员会“晨光计划”(20CG41)和上海市科技计划(20DZ2251400)资助项目。20210115 收到初稿, 20210420 收到修改稿

在机器视觉技术中, 高效的面料疵点检测算法是实现自动检测的关键所在。现有的面料疵点检测算法主要分为三种^[2]: 一是基于频域的算法, 如小波变换^[3-5]、Gabor 滤波算法^[6-7], 通过对图像进行傅里叶变换^[8]获得频谱图像并从中提取出疵点信息; 二是基于模型的算法, 如高斯混合模型法^[9-10], 通过对面料图像进行自回归建模, 提取面料的误差区域, 从而得到疵点的形状; 以上两种方法可以实现对背景特征简单的面料疵点检测(多为纯色面料), 对纹理复杂的面料检测精度较低; 三是基于空间域的方法, 如灰度共生矩阵算法^[11-12], 通过学习面料图像的纹理特征从而将正常纹理与疵点进行区分, 该方法虽然可检测纹理较为复杂的面料, 然而其检测所需计算量巨大且不具有鲁棒性, 难以实际应用。传统的面料疵点检测算法尽管已经得到了长足的发展, 但是由于其检测精度、泛化性以及实时性的限制, 仍无法应用于实际生产。

近年来随着深度学习的发展, 卷积神经网络在图像识别领域取得了优异的成绩, 并迅速应用于各个行业。在面料疵点检测领域, MEI^[13]提出多尺度卷积神经网络模型对面料图像进行多尺度特征提取与融合, 并通过对各分辨率特征图的合成与对比, 实现对针织面料疵点的分割。景军锋等^[14]建立深度卷积神经网络获取无缺陷样本的映射函数, 利用映射函数及特征字典重构图像并根据 Meanshift 算法实现疵点的分割。LIU^[15]使用 Fast R-CNN 算法通过构建卷积神经网络对色织面料进行特征提取, 并使用基于候选区域的目标检测算法对疵点进行定位, 实现对色织面料两类疵点的高精度检测与定位。

尽管基于深度学习的检测方法已经被证明具有较高的精度与泛化性, 但是仍存在两点问题。首先, 现有基于深度学习的疵点定位方法通过卷积神经网络对面料进行特征提取后对疵点部分进行分割或者位置预测, 实现对面料疵点的定位。然而在实际检测中, 有效的疵点特征区域仅仅占到整个图像很小的一部分像素, 其疵点特征往往较难精确提取, 需要经过大量的特征提取之后才能得到最终的精确的疵点定位, 严重影响了面料疵点检测的实时性。其次, 检测模型的训练需要足够的样本数据, 而面料生产具有多品种、小批量的特点以及较高的产品良率, 导致样本数据缺乏, 严重限制了检测模型训练的精度。而使用迁移学习的方法, 通过共享网络模型的权重将特征提取能力迁移至指定的网络, 能够提高模型的训练效率、降低模型训练对数

据的依赖。刘尧^[16]使用 Imagenet 数据预训练模型对格纹面料样本进行迁移训练, 通过预训练网络参数的迁移, 减少检测模型训练所需的样本数据量; 罗俊丽等^[17]使用 Frozen 迁移学习^[18-20]方法, 对迁移之后的目标检测模型前端网络进行冻结, 仅对后端网络参数进行训练, 加快模型训练的收敛速度。然而, 以上的特征迁移方法在迁移中并未考虑源域数据与目标域数据之间的关系, 迁移效果并不理想。

针对以上问题, 本文提出了基于两阶段深度迁移学习的面料疵点检测算法, 使用带有先验知识的疵点预选框替代基于特征的定位方法, 实现面料疵点尺寸特征先验知识的迁移, 提高面料疵点的定位速度, 通过将纯色棉麻布检测模型参数迁移至格纹面料检测模型, 实现面料通用特征提取能力的迁移, 减少检测模型训练所需的样本数量。

1 面料疵点检测问题分析

面料疵点检测分为检测模型训练与疵点检测两个步骤, 如图 1 所示。

图 1 面料疵点检测流程

在面料疵点检测阶段, 使用已架设好的工业 CCD 线阵相机采集面料图像并设计检测算法对其进行疵点检测。但在实际生产的疵点检测过程中, 因生产工艺与疵点评价标准不同, 不同面料之间的疵点种类也存在差异, 实际生产中可能会出现疵点种类达二十余种。本文选取生产批次较多的机织棉麻布与格纹面料两类面料中最为常见的破洞、缺经、缺纬、多纬、渍类五类疵点展开研究, 如图 2 所示。其中, 不同疵点的形状千差万别且尺寸微小, 缺经、缺纬类疵点形状细小且狭长, 与周围背景的对比度较低; 污渍类疵点形状不规则且大小不一; 破洞类疵点尺度微小; 面料有效的疵点区域仅占到面料图像的很小一部分像素, 导致其需要经过大量的特征提取之后才能得

到最终的精确的疵点定位, 严重影响了面料疵点检测的实时性。但在同类疵点之间, 由于其疵点产生机理相同, 其疵点的尺寸与形状之间具有较高的相似度, 而现有的基于特征的疵点检测方法在进行疵点定位时, 并未将疵点尺寸特征考虑在内, 降低了检测的实时性。如何将疵点的形状特征作为先验知识迁入疵点检测过程, 是提高面料疵点检测实时性的关键所在。

图 2 针织格纹面料与机织棉麻布部分疵点

在检测模型训练阶段, 架设工业 CCD 线阵相机采集面料图像并对疵点进行标记, 建立面料数据集, 将其输入卷积神经网络中训练得到对应的检测模型。面料生产中不同种类面料产品批量不同、面料特征不同, 检测模型训练的难易程度也不尽相同。如机织棉麻布样本数量多且纹理特征简单, 易于训练检测模型; 针织格纹面料样本数量少且纹理特征复杂, 难以训练出足够精度的检测模型。尽管二者训练难度不同, 但是不同面料

图像之间存在如疵点尺寸、背景等通用特征, 而现有的面料疵点迁移训练方法并未考虑面料之间具有通用特征的特性, 迁移效果并不理想。如何将网络对面料通用特征的提取能力迁移到模型训练过程中, 是实现疵点样本缺乏情况下模型高精度训练的关键问题。

2 基于两阶段深度迁移学习的面料疵点检测算法

针对以上问题, 本文设计基于两阶段深度迁移学习的面料疵点检测算法。首先, 针对面料不同疵点尺度不一的特点, 设计多尺度卷积神经网络, 增强神经网络对不同尺度疵点特征的提取能力。其次, 设计面料疵点特征先验知识迁移算法, 使用带有先验知识的疵点预选框对面料疵点进行定位, 实现面料疵点尺寸特征的迁移。最后, 设计卷积神经网络特征提取能力迁移算法, 通过卷积神经网络对于面料通用特征提取能力的迁移, 减少模型训练所需的疵点样本数量, 其训练流程如图 3 所示。

图 3 基于两阶段深度迁移学习的面料疵点检测算法

2.1 多尺度卷积神经网络构建

针对面料疵点形状多变、尺度不一的特点, 本文借鉴特征金字塔的思想^[21], 设计了疵点检测卷积神经网络 (Fabric defect detection convolutional neural network, FDCNN) 算法。采用特征融合的方法构建多尺度卷积神经网络, 以增强卷积神经网络对于微小特征的提取能力, 实现对不同尺度疵点特征的有效提取, 其卷积神经网络结构如图 4 所示。

图 4 FDCNN 卷积神经网络结构

将工业相机采集到的原始面料图像作为输入，经标准化后得到图像矩阵 $X = [x_{1,1}, \dots, x_{i,j}]$ ，通过卷积神经网络对图像矩阵进行特征提取，得到 13×13 与 26×26 分辨率的特征图并将其分别输入检测模块进行特征分类与定位，最终输出面料疵点的定位与分类结果。

在卷积神经网络前端，采用卷积与池化协作的方式对面料图像特征进行提取。使用大小为 3×3 、步长为 1 的小尺寸卷积核对输入图像矩阵 X 进行下采样，以增强卷积层对于面料局部特征的提取能力，卷积计算公式如下所示

$$z_{u,v} = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} (x_{i,j} \cdot w_{u-i,v-j}) + b_{i,j} \quad (1)$$

式中， $x_{i,j}$ 代表图像矩阵对应的像素值， $w_{u-i,v-j}$ 代表卷积核所对应的权重， $b_{i,j}$ 表示卷积核对应的偏重参数。

使用 $\tanh$ 激活函数对卷积特征 $z_{u,v}$ 进行非线性化，以增强卷积神经网络的特征表达能力

$$h_1 = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2)$$

卷积层输出特征图矩阵 $H = [h_{1,1}, \dots, h_{u,v}]$ 之后，将 H 作为池化层输入，利用 2×2 尺寸的最大值池化 (MaxPooling) 对其进行特征降维，在保留面料图像关键特征的同时，减少卷积神经网络的参数，提高卷积神经网络的运算速度。在经过多次卷积与池化操作后，最终提取到尺度分别为 13×13 与 26×26 分辨率的特征图。

在卷积神经网络后端，将不同分辨率的特征图作为两个独立分支输入检测模块进行疵点检测，

26×26 特征图具有更高的特征分辨率，用于识别面料图像中如破洞、缺经等尺寸微小的疵点；而 13×13 特征图则用于识别面料图像中如污渍一类尺寸常规尺寸的疵点；同时，为增强卷积神经网络的特征提取能力，对 13×13 特征图进行二倍上采样后得到 26×26 特征图，并与原有 26×26 特征图进行特征融合，卷积神经网络参数如表 1 所示。

表 1 卷积神经网络参数

层数	卷积核尺寸	输入	输出
1 卷积层	$3 \times 3 / 1$	$416 \times 416 \times 3$	$416 \times 416 \times 16$
2 池化层	$2 \times 2 / 2$	$416 \times 416 \times 16$	$208 \times 208 \times 16$
3 卷积层	$3 \times 3 / 1$	$208 \times 208 \times 16$	$208 \times 208 \times 32$
4 池化层	$2 \times 2 / 2$	$208 \times 208 \times 32$	$104 \times 104 \times 32$
5 卷积层	$3 \times 3 / 1$	$104 \times 104 \times 32$	$104 \times 104 \times 64$
6 池化层	$2 \times 2 / 2$	$104 \times 104 \times 64$	$52 \times 52 \times 64$
7 卷积层	$3 \times 3 / 1$	$52 \times 52 \times 64$	$52 \times 52 \times 128$
8 池化层	$2 \times 2 / 2$	$52 \times 52 \times 128$	$26 \times 26 \times 128$
9 卷积层	$3 \times 3 / 1$	$26 \times 26 \times 128$	$26 \times 26 \times 256$
10 池化层	$2 \times 2 / 2$	$26 \times 26 \times 256$	$13 \times 13 \times 256$
11 卷积层	$3 \times 3 / 1$	$13 \times 13 \times 256$	$13 \times 13 \times 512$
12 池化层	$2 \times 2 / 1$	$13 \times 13 \times 512$	$13 \times 13 \times 512$
13 卷积层	$3 \times 3 / 1$	$13 \times 13 \times 512$	$13 \times 13 \times 256$
14 卷积层	$3 \times 3 / 1$	$13 \times 13 \times 256$	$13 \times 13 \times 256$
15 卷积层	$1 \times 1 / 1$	$13 \times 13 \times 256$	$13 \times 13 \times 27$
检测			
16 卷积层	$1 \times 1 / 1$	$13 \times 13 \times 256$	$13 \times 13 \times 128$
17 上采样	2	$13 \times 13 \times 128$	$26 \times 26 \times 128$
融合 17,9			
18 卷积层	$3 \times 3 / 1$	$26 \times 26 \times 384$	$26 \times 26 \times 256$
19 卷积层	$1 \times 1 / 1$	$26 \times 26 \times 256$	$26 \times 26 \times 27$
检测			

2.2 疵点特征先验知识迁移

在面料生产中，决定疵点形状大小的主要为面料种类以及生产设备两个因素，尽管不同面料之间

疵点的形状千差万别,但在同一设备下生产的同种面料,由于其疵点产生机理相同,因此同类疵点在形状尺寸上不存在显著的差别。针对该特点,本文提出疵点尺寸特征先验知识迁移算法:将疵点尺寸先验知识作为迁移对象,使用聚类算法迭代求得交并比最优的四类疵点预选框参数作为疵点尺寸特征先验知识,并使用带有先验知识的疵点预选框替代基于特征区域的定位方法,实现面料疵点特征先验知识的迁移,如图 5 所示。

图 5 基于两阶段深度迁移学习的面料疵点检测算法

(1) 为求得不同尺寸与宽高比疵点的预选框参数,本文使用 K-Means 算法对机织棉麻布数据集中四类形状不同的疵点边界框进行分类

$$J = \min \left(\sum_{k=1}^k \sum_{i=1}^n \|x_i - u_k\|^2 \right) \quad (3)$$

式中, x_i 为疵点边界框坐标 (w_{box}^i, h_{box}^i) , k 值为预选框种类个数, $k=4$, u_k 则对应每类疵点的预选框坐标 (w_{box}^k, h_{box}^k) , n 为每类疵点边界框的数量,通过最小化距离 J 将疵点边界框坐标 x_i 按照尺寸与宽高比分为 4 类。

(2) 求得疵点预选框坐标之后,分别计算每类预选框与对应疵点边界框的交并比(Intersection over union, IOU)。交并比表示预选框与疵点边界框地重合度,交并比越高,二者重合度越高,交并比为 1 时,表示预选框与疵点边界框完全重合,其中 $\text{Box}(w_{box}, h_{box})$ 表示长、宽为 (w_{box}, h_{box}) 对应的预选框

$$IOU_i = \frac{\text{Box}(w_{box}^i, h_{box}^i) \cap \text{Box}(w_{box}^k, h_{box}^k)}{\text{Box}(w_{box}^i, h_{box}^i) \cup \text{Box}(w_{box}^k, h_{box}^k)} \quad (4)$$

$$\text{Box}(w_{box}^i, h_{box}^i) \cap \text{Box}(w_{box}^k, h_{box}^k) = \min(w_{box}^i, w_{box}^k) * \min(h_{box}^i, h_{box}^k) \quad (5)$$

$$\begin{aligned} \text{Box}(w_{box}^i, h_{box}^i) \cup \text{Box}(w_{box}^k, h_{box}^k) = & w_{box}^i * h_{box}^i + w_{box}^k * h_{box}^k + \\ & \min(w_{box}^i, w_{box}^k) * \min(h_{box}^i, h_{box}^k) \end{aligned} \quad (6)$$

设交并比优化参数 D , 其中 N 为疵点边界框总数

$$D = \frac{1}{N} \sum_{i=0}^N (1 - IOU_i)^2 \quad (7)$$

利用梯度下降算法对参数 D 进行优化,经过多次迭代后,求得每类疵点交并比最大预选框尺寸参数 (w_{box}^k, h_{box}^k) , 其中 α 为人为设置的优化速率。

$$w_{box}^{t+1} = w_{box}^t - \alpha \frac{\partial D}{\partial w_{box}^t} \quad (8)$$

$$h_{box}^{t+1} = h_{box}^t - \alpha \frac{\partial D}{\partial h_{box}^t} \quad (9)$$

(3) 卷积神经网络虽然能够高效地对面料图像特征进行提取,但是并不具备对面料疵点进行定位地能力。在疵点特征先验知识迁移至疵点定位过程中,需要将面料疵点预选框与卷积神经网络最后一层卷积特征图进行匹配,根据卷积特征矩阵与原始图像矩阵行列比求得预选框缩放比例 p_w 与 p_h 。

(4) 求得预选框缩放比例后,依次对 4 类面料疵点预选框尺寸参数 (w_{box}^k, h_{box}^k) 进行缩放,求得其对应于特征图的预选框尺寸 b_w 与 b_h 。

$$b_w = p_w e^w \quad (10)$$

$$b_h = p_h e^h \quad (11)$$

(5) 根据特征图矩阵行列数将特征图等分为 $N \times N$ 个单元格,其中 N 为特征图所对应分辨率,求得每个单元格中心点 (t_x, t_y) 作为锚点坐标。由于疵点类型未知,因此选择在每个锚点坐标上都匹配相应的 4 类预选框,生成共计 $N \times N \times 4$ 数量的疵点预选框,并计算疵点预选框置信度。

$$\text{Confidence} = P(i) * IOU_i \quad (12)$$

$P(i)$ 为卷积神经网络最终输出的疵点分类概率,计算公式如下,其中 h_i 表示最后一层卷积层对应卷积核的值, j 为卷积核数目。

$$P(i) = \frac{e^{h_i}}{\sum_j e^{h_j}} \quad (13)$$

最后,根据检测需求设置疵点预选框阈值,并运用非极大值抑制的方法,去除置信度低于阈值的预选框,得到最终的面料疵点检测结果。

2.3 通用特征提取能力迁移

现有迁移训练方法只考虑网络参数的迁移,未针对面料本身特点设计深度迁移学习方法,无法解决因疵点样本稀缺带来的检测模型精度低、训练效

率差的问题。

针对这一问题, 本文提出面料特征提取能力迁移算法。将面料的底层背景纹理特征与形状相似的同类疵点特征视为面料之间的通用特征, 将面料的独有的花纹特征视为其专有特征, 利用面料图像之

间具有通用特征的特性, 将源域网络权重参数迁移至目标域 FDCNN 网络卷积层, 实现面料通用特征提取能力的迁移, 并通过改进迁移损失函数提高网络对于面料专有特征的提取能力, 提高检测模型训练效率, 如图 6 所示。

图 6 卷积神经网络通用特征提取能力迁移

机织棉麻布较之格纹面料背景纹理简单, 易于提取到面料图像以及疵点的通用特征, 本文以其作为源域数据集训练预迁移模型。首先, 利用 PCA 算法对格纹面料与机织棉麻布面料图像特征进行降维与主成分分析。将面料图像转化为高维矩阵对其特征进行描述, 设面料数据集中共有 N 张图片, 每张图片 I 采用 K 维矢量描述, 则面料数据集可采用一个 $K \times N$ 的矩阵表示, 记为 $\mathbf{X} = [I_1, I_2, \dots, I_N]$, 求得平均疵点图像特征 $I_{average}$

$$I_{average} = \frac{1}{N} \sum_{i=1}^N I_i \quad (14)$$

进而对 $\mathbf{X}$ 进行中心化后得到矩阵 $\mathbf{S}$, 表示为

$$\mathbf{S} = [I_1 - I_{average}, \dots, I_N - I_{average}] \quad (15)$$

构造协方差矩阵

$$\mathbf{C} = \frac{1}{N-1} \mathbf{S} \times \mathbf{S}^T \quad (16)$$

求出协方差矩阵 $\mathbf{C}$ 的特征矩阵 $\mathbf{W}^T$, 进而求得格纹面料与棉麻布两类面料组成的高维特征矩阵在二维平面上的特征分布 $\mathbf{Y} = \mathbf{W}^T \mathbf{X}$, 如图 7 所示。

图 7 两种面料 PCA 主成分分析

其中 $\times$ 符号代表机织棉麻布特征分布、菱形符号表示针织格纹面料特征分布,由图可知,二者具有近似的包含关系。因此,本文选择机织格纹面料作为源域数据提取面料图像通用特征 $F_{general}$;对检测模型进行迁移训练时,选择将卷积神经网络对面料通用特征 $F_{general}$ 的提取能力作为迁移对象,只针对目标域针织格纹面料图像的专有特征 $F_{special}$ 进行特征提取,从而减少检测模型训练所需的迭代次数。

(1) 源域机织棉麻布检测模型训练。

以机织棉麻布作为源域数据集,构建 FDCNN 卷积神经网络,利用梯度下降法通过最小化损失函数 $Loss$ 对卷积神经网络进行迭代训练,更新卷积神经网络权重参数 $w_{i,j}$ 与偏置参数 $b_{i,j}$,提取面料图像的通用特征 $F_{general}$ 。

$$w_{i,j} = w_{i,j} - \alpha \frac{\partial Loss}{\partial w_{i,j}} \quad (17)$$

$$b_{i,j} = b_{i,j} - \alpha \frac{\partial Loss}{\partial b_{i,j}} \quad (18)$$

损失函数 $Loss$ 包括定位与分类两部分,其中,通过优化定位损失函数实现对边界框中心坐标与尺寸参数的优化,从而提高定位精度,定位损失函数包含中心坐标损失 XY_{loss} 与边界框损失 WH_{loss} 。

$$XY_{loss} = \lambda \sum_{i=0}^{N^2} \sum_{j=0}^B \ell_{ij}^{obj} \left[(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2 \right] \quad (19)$$

$$WH_{loss} = \lambda \sum_{i=0}^{N^2} \sum_{j=0}^B \ell_{ij}^{obj} \left[(\sqrt{w_{box}^i} - \sqrt{\hat{w}_{box}^i})^2 + (\sqrt{h_{box}^i} - \sqrt{\hat{h}_{box}^i})^2 \right] \quad (20)$$

通过优化分类损失实现对面料疵点分类精度的优化,分类损失包含类别损失 $Class_{loss}$ 与置信度损失 $Confidence_{loss}$ 。

$$Class_{loss} = \sum_{i=0}^{N^2} \sum_{j=0}^B \ell_{ij}^{obj} \left[(p_i(c) - \hat{p}_i(c))^2 \right] + \sum_{i=0}^{N^2} \sum_{j=0}^B \ell_{ij}^{obj} \left[(C_i - \hat{C}_i)^2 \right] \quad (21)$$

$$Confidence_{loss} = \lambda \sum_{i=0}^{N^2} \sum_{j=0}^B \ell_{ij}^{noobj} \left[(C_i - \hat{C}_i)^2 \right] \quad (22)$$

以上四式中, N^2 表示特征图划分的单元格数量, B 为每个单元格内预选框数目, ℓ_{ij}^{obj} 表示第 i 单元格中第 j 个预选框中有无疵点,有疵点时 $\ell_{ij}^{obj} = 1$,无疵点时 $\ell_{ij}^{obj} = 0$, (x_i, y_i) 为第 i 个单元格

对应预选框的中心坐标, $(\hat{x}_i, \hat{y}_i)$ 为疵点区域实际中心点坐标, (w_{box}^i, h_{box}^i) 表示第 i 单元格对应预选框的长、宽尺寸, $(\hat{w}_{box}^i, \hat{h}_{box}^i)$ 为疵点区域实际框的长、宽尺寸, $p_i(c) - \hat{p}_i(c)$ 为第 i 单元格中存在疵点 c 的概率, $C_i - \hat{C}_i$ 为预测框与真值框置信度差值, λ 为可变常量,四部分损失中重复出现的参数为同一变量。

$$Loss = XY_{loss} + WH_{loss} + Class_{loss} + Confidence_{loss} \quad (23)$$

(2) 对训练完成的源域卷积神经网络进行通用特征 $F_{general}$ 提取能力的迁移。

提取源域网络权重参数 W 与偏置参数 B ,构建目标域 FDCNN 卷积神经网络,并将源域网络参数 W 与 B 等价迁移至目标域网络对应的卷积层,通过网络权重的迁移实现通用特征提取能力的迁移,其中 $W = [w_1, w_2, \dots, w_i]$, w_i 表示卷积层 i 对应权重参数 $w_{i,j}$ 的集合, $B = [b_1, b_2, \dots, b_i]$, b_i 表示卷积层 i 偏置参数 $b_{i,j}$ 的集合, j 对应每层卷积层的卷积核。

(3) 迁移训练针织格纹面料检测模型。

在迁移训练过程中,为了增强卷积神经网络对目标域专有特征的提取能力,在设计迁移训练损失函数 $Loss$ 时,本文在交叉熵损失的基础上引入 $Focal\ loss$ 机制,加设 F_{loss} 损失函数。

$$p_i(c) = \begin{cases} p & y = 1 \\ 1 - p & \text{其他} \end{cases} \quad (24)$$

$$F_{loss} = \sum_{i=0}^{N^2} \sum_{j=0}^B \left[-(1 - p_i(c)) \log(p_i(c)) \right] \quad (25)$$

在 F_{loss} 中, $p_i(c)$ 为卷积神经网络最终输出的疵点正确分类的概率,其值越小,则损失函数 F_{loss} 越大。

在进行迁移训练时,目标与面料图像通用特征占比越多,则对其具有更好的特征提取能力,相应的预测精度也就越高,其 $p_i(c)$ 越大,从而最后的 F_{loss} 值更小,对网络参数更新的作用更小;而对于通用特征占比少,专有特征占比大的面料图像,特征提取能力差、预测精度低, $p_i(c)$ 值小,则其损失函数 F_{loss} 值更大,卷积神经网络更倾向于利用 F_{loss} 更大的样本进行参数更新。通过减少易分类样本在训练的权重,从而增强卷积神经网络对目标域专有特征的提取能力。

以针织格纹面料为目标域数据集,通过最小化迁移训练损失函数 $Loss_t$,对网络参数进行微调,在保留通用特征 $F_{general}$ 的情况下对针织格纹面料的专

有特征 $F_{special}$ 进行提取, 减少检测模型训练所需的迭代次数。

$$Loss_t = XY_{loss} + WH_{loss} + Class_{loss} + Confidence_{loss} + F_{loss} \quad (26)$$

3 实验与结果分析

3.1 实验环境

本文选用上海嘉麟杰典型面料及疵点作为实验样本, 自行搭建面料疵点检测设备采集面料图像数据集, 实验平台硬件部分参数如表 2 所示。

表 2 面料疵点实验平台硬件参数

名称	品牌型号	参数
相机	MV-CL042-70CC	分辨率 4 095×2, 最大行频 50 kHz, 像元尺寸 5 μm
镜头	SA1220M-10MP-DH	12 mm 焦距, 4/3", F2.0 光圈
光源	DCM-2C050-24S	功率 9.7 W, 输入电压 24 VDC

面料图像数据包括机织棉麻布与针织格纹面料两个种类的面料, 疵点类型为生产中经常出现的缺经、缺纬、渍类和破洞四类疵点, 如表 3 所示。

表 3 面料疵点数据集

种类	渍类	缺经	缺纬	破洞
机织棉麻布	236	212	196	201
针织格纹面料	109	104	96	106

实验平台软件部分使用 Python3.6 和 Pytorch 搭建深度学习模型, 在 GPU 为 GTX1060 的工作站完成检测模型的训练与测试。

3.2 检测实时性与精度验证

本节将 FDCNN 算法与其他目标检测算法进行对比, 对本算法的检测精度与实时性进行验证。整个训练过程中共进行 1 000 次迭代, 其中动量和权重衰减分别配置为 0.95 和 0.000 5, 初始学习率为 10^{-4} , 批量大小设置为 16, 预选框阈值设置为 0.4, 使用均值精度(Mean average precision, MAP)作为评价检测模型检测精度的指标, 使用每秒可检测的图片数量(Frames per second, FPS)作为检测速度的指标。按照 8:2 的比例划分训练集与测试集, 对本文所提出的 FDCNN 两阶段深度迁移学习算法性能进行验证。表 4 为 Fast R-CNN^[22]、Faster R-CNN^[23]、Yolo^[24]、Yolov3^[25]、SSD^[26]以及本文提出的 FDCNN 方法的实验结果。

表 4 检测算法性能对比结果

方法	FPS		MAP(%)	
	机织棉麻布	针织格纹面料	机织棉麻布	针织格纹面料
Fast R-CNN	0.9	0.7	60.4	65.7
Faster R-CNN	13.7	13.6	82.1	85.6
Yolo	20.1	20	70.4	71.2
Yolov3	21.6	21.3	93.9	95.9
SSD	23.1	22.7	89.3	91.2
FDCNN	29.3	29.1	93.7	95.6

由实验结果可知, 在检测效率方面, 本文提出的 FDCNN 检测算法的 FPS 达到了 29(平均每秒钟检测 29 张图片)明显优于其他的目标检测算法。传统的目标检测算法在定位过程中采用基于候选区域方法或使用随机生成的预选框进行定位, 需要大量的计算后才能得到最终精确的疵点定位结果。而 FDCNN 检测算法通过第一阶段疵点特征先验知识的迁移, 使用带有先验知识的疵点预选框对疵点进行定位, 有效减少了疵点定位所需的计算量, 因此在疵点检测速度上要远远优于其他检测算法。

在检测精度方面, 在检测速度明显优于其他检测算法的情况下, FDCNN 算法的 MAP 精度与 Yolov3 算法基本相当, 且明显高于其他检测算法, 可以满足面料生产中对于疵点检测精度的需求。

为验证不同卷积神经网络特征融合尺度对检测精度与实时性的影响, 本节分别选用第 7 层卷积层中 13×13 的特征图、第 9 层卷积层中的 26×26 的特征图和第 17 层卷积层中的 52×52 的特征图对其进行特征融合对比实验, 其中网络结构 1 使用 13×13 的特征图进行检测, 网络结构 2 使用 26×26 的特征图进行检测, 网络结构 3 使用 52×52 的特征图进行检测, 网络结构 4 使用尺寸分别为 13×13 与 26×26 的双通道网络结构进行检测, 网络结构 5 使用尺寸分别为 13×13 与 52×52 的双通道网络结构进行检测, 网络结构 6 使用尺寸分别为 26×26 与 52×52 的双通道网络结构进行检测, 网络结构 7 使用尺寸为 13×13 与 26×26 与 52×52 的三通道网络结构进行检测, 由实验结果可知, 在选用 13×13 与 26×26 尺度的特征图进行双通道疵点检测时, 检测网络具有最高的检测精度(MAP), 因此本文选用 13×13 与 26×26 尺度的特征图, 设计面料疵点检测卷积神经网络, 实验结果如表 5 所示。

表 5 网络不同尺度特征融合对比结果

方法	FPS		MAP(%)	
	机织棉 麻布	针织格纹 面料	机织棉 麻布	针织格纹 面料
网络结构 1	30.7	30.8	91.2	92.3
网络结构 2	35.1	35.3	89.5	87.4
网络结构 3	37.4	37.6	70.4	69.5
网络结构 4	29.3	29.4	93.7	95.6
网络结构 5	30.4	30.9	90.7	90.3
网络结构 6	32.6	32.9	80.5	79.6
网络结构 7	27.1	27.4	90.9	92.4

3.3 检测模型训练时间与样本数验证

(1) 本节通过对 FDCNN 两阶段迁移对算法性能的影响,对本文所提出的两阶段深度迁移学习算法性能进行验证。

其中 FDCNN-0 训练中,两阶段迁移均不进行;FDCNN-1 只对检测模型进行第一阶疵点特征先验知识的迁移,不进行通用特征提取能力的迁移;FDCNN-2 只进行网络通用特征提取能力的迁移,不进行特征先验知识的迁移,设置随机预选框数量为 8;FDCNN 为完整的两阶段深度迁移学习算法,实验结果如表 6 所示。

表 6 两阶段迁移训练对比结果

训练方法	第一阶 段迁移	第二阶 段迁移	MAP (%)	FPS/ s ⁻¹	模型训练 时间/h
FDCNN-0	×	×	90.9	23.4	16.1
FDCNN-1	✓	×	95.5	29.1	15.9
FDCNN-2	×	✓	91.2	23.4	6.7
FDCNN	✓	✓	95.6	29.1	6.3

与 FDCNN-1 算法相比,FDCNN 算法检测精度与实时性基本保持不变,但由于其没有进行通用特征提取能力的迁移,选择从零开始训练卷积神经网络,因此需要更长的模型训练时间;FDCNN-2 算法检测精度有着略微的降低,且由于没有进行面料疵点特征先验知识的迁移而选择使用随机预选框对疵点进行定位,需要增加预选框数目以保证检测精度,因此其定位中需要进行更多的计算,检测实时性有着明显的下降,模型训练时间也因为预选框数目的增多有着少许的提高。由实验结果可知使用两阶段迁移的 FDCNN 算法在各方面性能上都优于只进行某一阶段迁移的训练方法。

(2) 本实验对检测模型迁移训练所需疵点样本数量进行了实验验证。其中 FDCNN 与 FDCNN-1 与(1)中相同;Normal-transfer 对检测模型进行第一阶疵点特征先验知识的迁移,但第二阶段迁移使用文^[8]的方法将 Imagenet 标准数据集训练的检测模型

作为源域进行网络参数迁移。本实验以检测模型 MAP(均值精度)高于 90%作为满足面料生产对疵点检测精度的要求;在评价检测模型训练速度时,由于三种方法在模型训练时仅存在网络初始参数的差别,每次迭代所用时间基本一致,因此以达到 90%MAP 所需的迭代次数作为评价检测模型训练速度的指标,实验结果如表 7 所示。

表 7 迁移学习样本数实验结果

训练方法\性能	训练集 数量	最高 MAP(%)	达到 90%MAP 所需迭代次数
Normal-transfer	320	95.5	542
FDCNN-1	320	95.5	756
FDCNN	320	95.6	241
Normal-transfer	200	91.3	836
FDCNN-1	200	86.5	—
FDCNN	200	93.3	299
Normal-transfer	100	76.9	—
FDCNN-1	100	65.1	—
FDCNN	100	91.7	377

由实验结果可知,随着训练集数量减少,检测模型的最高 MAP 也随之降低。在训练集数量为 320 时,三种算法均能超过 90%的 MAP,满足疵点检测对精度的要求;在训练集数量为 200 时,FDCNN-1 的最高 MAP 为 86.5%,无法满足疵点检测对精度的要求,而 Normal-transfer 尽管能达到 90%的 MAP,但需要经过 836 的迭代,模型训练效率较慢;在训练集数量为 100 时,只有 FDCNN 方法能够达到 90%的 MAP,且仅需要 377 次迭代。与另外两种方法相比,FDCNN 方法通过对面料图像通用特征提取能力的迁移,避免了因为图像数量不足、难以提取通用特征而造成的检测精度下降,使得检测模型训练所需的训练集样本数量减少了 50%,且依然保持着较高的检测精度。

(3) 本实验在疵点数据集为 400 的情况下对不同的迁移训练方法进行了对比,其中 FDCNN、FDCNN-1 与 Normal-transfer 方法均与前文相同。Frozen 迁对检测模型进行第一阶疵点特征先验知识的迁移,在第二阶段迁移中使用文^[9]的方法将 Imagenet 标准数据集训练的检测模型作为源域进行网络参数迁移,并冻结前端网络参数,只针对卷积神经网络后端特定层数进行更新,本实验中只更新网络后 2 层与后 4 层,分别对应 Frozen2 与 Frozen4。实验评价标准与(2)相同,实验结果如图 8、表 8 所示。

由实验结果可知,Normal-transfer 深度迁移方法,其 MAP 指标最高可达 95.5%,检测模型需要经

过 542 次迭代后，MAP 值达到 90%并趋近于收敛；而文献[9]提出的Frozen 深度迁移学习方法，其 MAP 指标仅能达到 50%，无法满足面料疵点检测对于精度的要求，并不适合面料疵点检测模型的迁移；FDCNN 两阶段深度迁移学习方法，其 MAP 指标最高可达 95.6%，只需要 241 次迭代，MAP 便可达到 90%且收敛趋势更加明显；FDCNN-1 未进行网络权重参数的迁移，从头开始训练卷积神经网络，需要经过 756 次迭代后 MAP 指标达到 90%。

图 8 迁移训练方法对比实验

表 8 迁移训练方法对比实验结果

训练方法/性能	最高 MAP(%)	达到 90%MAP 所需迭代次数
Normal-transfer	95.5	542
Frozen 2	52.1	—
Frozen 4	50.5	—
FDCNN (本文方法)	95.6	241
FDCNN-1	95.5	756

与 FDCNN-1 相比，Normal-transfer 使用 Imagenet 权重参数进行深度迁移训练，节省了因训练中随机初始化网络参数而带来的不必要更新，提高了检测模型的训练效率；而 FDCNN 深度迁移方法，通过对面料通用特征提取能力进行迁移，省去了卷积神经网络提取通用特征所需的迭代训练，只针对面料专有特征进行网络参数的微调，与 Normal-transfer 方法相比，能够更有效地提高检测模型的训练效率，其模型训练速度约是 Normal-transfer 的 2.3 倍，FDCNN-1 的 3.1 倍。由实验结果可知，进行网络参数迁移的模型训练方法具有更快的模型训练速度，而源域数据集与目标域数据集相关性越高，网络参数迁移对模型训练速度的提高越明显。

3.4 面料疵点检测现场验证

将面料疵点图像输入检测模型，得到带有定位与分类结果的检测结果。图 9 所示为机织棉麻布疵

点检测结果，图 10 所示为针织格纹面料疵点检测结果，检测结果包括疵点种类、边界框及置信度三类信息，每种颜色的疵点边界框对应不同种类的疵点。检测结果表明，对于复杂纹理区域以及疵点特征重叠区域，也能够实现面料疵点的精准的分类与定位。

检测算法 FPS29.1(平均每秒钟检测 29.1 张图片)，每张图片所需检测时间为 30~40 ms，具有良好的实时性。在实际面料疵点检测中，面料幅宽为 1.2 m，使用分辨率为 4 096×2 的工业线阵相机采集 4 096×512 像素的图像，相当于每次采集 1.2×0.15 m 的尺寸面料图像，并将其拆分成 8 个 512×512 的图像输入检测模型中进行疵点检测，即每检测 8 张图片等价于检测 0.15 m 的面料幅长。经过计算，其检测速度可达 30 m/min 左右，快于人工检测并且可以满足生产中疵点检测对于实时性的要求。

图 9 机织棉麻布检测结果

图 10 针织格纹面料检测结果

4 结论

本文提出了一种基于两阶段深度迁移学习的面料疵点检测算法，实现对针织格纹面料四类疵点的实时检测与检测模型的高效训练。在第一阶段迁移中设计面料疵点特征先验知识的迁移算法，使得检测精度指标 MAP 达到了 95.6%、检测速度指标 FPS 达到了 29，优于传统的目标检测算法，且能够满足面料生产中对于检测性能的要求；在第二阶段迁移中，设计卷积神经网络特征提取能力迁移算法，使得检测模型训练速度提高了 3 倍、模型训练所需的样本数量减少 50%。在后续工作中，本文将就如何提升检测算法泛化性，使其能够适应更多种面料的迁移进行进一步研究。

参 考 文 献

- [1] KUMA R A. Computer-vision-based fabric defect detection: A survey[J]. IEEE Transactions on Industrial Electronics, 2008, 55(1): 348-363.
- [2] CHEN J, JAIN A K. A structural approach to identify defects in textured images[C]// Proceedings of the 1988 IEEE International Conference on Systems, August 8-12, 1988, Beijing, China, Institute of Electrical and Electronics Engineers, 1988: 29-32.
- [3] 李立轻, 黄秀宝. 基于织物自适应正交小波的疵点检测[J]. 东华大学学报, 2001(4): 82-87.
LI Liqing, HUANG Xiubao. Woven fabric defect detection with features based on adaptive wavelets[J]. Journal of Donghua University, 2001(4): 82-87.
- [4] 夏冬升, 汪军. 基于小波变换和图像分割的织物等级自动评定[J]. 东华大学学报, 2007(2): 221-226.
XIA Dongsheng, WANG Jun. Automatic fabric grading based on wavelet transform and image segmentation [J]. Journal of Donghua University, 2007(2): 221-226.
- [5] NGAN H Y T, PANG G K H, YUNG S P, et al. Wavelet based methods on patterned fabric defect detection[J]. Pattern Recognition, 2005, 38 (4): 559-576.
- [6] 邹超, 汪秉文, 孙志刚. 基于 Gabor 滤波器组的实时疵点图像分割[J]. 计算机工程与应用, 2010, 46(12): 185-187, 197.
ZOU Chao, WANG Bingwen, SUN Zhigang. Online defect segmentation based on Gabor filter bank[J]. Computer Engineering and Applications, 2010, 46(12): 185-187, 197.
- [7] KUMA R A, PANG G K H. Defect detection in textured materials using Gabor filters[J]. IEEE Transactions on Industry Applications, 2002, 38(2): 425-440.
- [8] 朱丹丹, 潘如如, 高卫东. 基于傅里叶特征谱和相关系数的织物疵点检测[J]. 计算机工程与应用, 2014, 50(19): 182-186, 198.
ZHU Dandan, PAN Ruru, GAO Weidong. Fabric defect detection using characteristic spectrum of Fourier transform and correlation coefficient[J]. Computer Engineering and Applications, 2014, 50(19): 182-186.
- [9] 李敏, 崔树芹, 谢治平. 高斯混合模型在印花织物疵点检测中的应用[J]. 纺织学报, 2015, 36(8): 94-98.
LI Min, CUI Shuqin, XIE Zhiping. Application of Gaussian mixture model on defect detection of print fabric[J]. Journal of Textile Research, 2015, 36(8): 94-98.
- [10] 梁久祯, 顾程熙, 常兴治. 基于相似关系的纺织品瑕疵检测方法[J]. 模式识别与人工智能, 2017, 30(5): 456-464.
LIANG Jiuzhen, GU Chengxi, CHANG Xingzhi. Fabric defect detection based on similarity relation[J]. Pattern Recognition and Artificial Intelligence, 2017, 30(5): 456-464.
- [11] 邹超. 布匹疵点在线检测系统研究[D]. 武汉: 华中科技大学, 2009.
ZOU Chao. Research on online fabric defect detection system[D]. Wuhan: Huazhong University of Science and Technology, 2009
- [12] 邹超, 朱德森, 肖力. 基于类别共生矩阵的纹理疵点检测方法[J]. 华中科技大学学报, 2006(6): 25-28.
ZOU Chao, ZHU Desen, XIAO Li. Textural defect detection based on label co-occurrence matrix[J]. Journal of Huazhong University of Science and Technology, 2006, 34(6): 25-28.
- [13] MEI S, WANG Y, WEN G. Automatic fabric defect detection with a multi-scale convolutional denoising autoencoder network model[J]. Sensors, 2018, 18(4): 1064.
- [14] 景军锋, 范晓婷, 李鹏飞, 等. 应用深度卷积神经网络的色织物缺陷检测[J]. 纺织学报, 2017, 38(2): 68-74.
JING Junfeng, FAN Xiaoting, LI Pengfei, et al. Yarn-dyed fabric defect detection based on deep-convolutional neural network[J]. Journal of Textile Research, 2017, 38(2): 68-74.
- [15] LIU Z, LIU X, LI C, et al. Fabric defect detection based on faster R-CNN[C]// Ninth International Conference on Graphic and Image Processing (ICGIP 2017), October 14-16, 2017, Qingdao, China International Society for Optics and Photonics, 2018: 106150A.
- [16] 刘尧. 卷积神经网络在纺织品缺陷检测中的应用研究[D]. 西安: 西安工程大学, 2019.
LIU Rao. The application of convolutional neural network in textile defect detection[D]. Xi'an: Xi'an Polytechnic University, 2019.
- [17] 罗俊丽, 路凯. 基于卷积神经网络和迁移学习的色织物疵点检测[J]. 上海纺织科技, 2019, 47(6): 52-56.
LUO Junli, LU Kai. Yarn-dyed fabric defect detection based on convolution neural network and transfer learning[J]. Shanghai Textile Science & Technology, 2019, 47(6): 52-56.
- [18] 张景祥, 王士同, 邓赵红, 等. 融合异构特征的子空间

- 迁移学习算法[J]. 自动化学报, 2014, 40(2): 236-246.
- ZHANG Jingxiang, WANG Shitong, DENG Zhaohong, et al. A subspace transfer learning algorithm integrating heterogeneous features[J]. Acta Automatica Sinica, 2014, 40(2): 236-246.
- [19] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2009, 22(10): 1345-1359.
- [20] 张雪松, 庄严, 闫飞, 等. 基于迁移学习的类别级物体识别与检测研究与进展[J]. 自动化学报, 2019, 45(7): 1224-1243.
- ZHANG XueSong, ZHUANG Yan, YAN Fei, et al. Status and development of transfer learning based category-level object recognition and detection[J]. Acta Automatica Sinica, 2019, 45(7): 1224-1243.
- [21] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[J]. arXiv : 1612.0314-4v2, 2017.
- [22] GIRSHICK R. Fast r-cnn[C]// Proceedings of the IEEE International Conference on Computer Vision, December 7-13, 2015 Santiago, Chile, Institute of Electrical and Electronics Engineers, 2015: 1440-1448.
- [23] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [24] REDMON J, DIVVLAVA S, Girshick R, et al. You only look once: Unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. Institute of Electrical and Electronics Engineers, 2016: 779-788.
- [25] YANAN S, HUI Z, LI L, et al. Rail surface defect detection method based on yolov3 deep learning networks[C]// 2018 Chinese Automation Congress (CAC), Nov. 30 to Dec. 2, 2018, Xi'an Jiaotong University, Xi'an, China. Chinese Association of Automation, 2018: 1563-1568.
- [26] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]// European Conference on Computer Vision. October 11-14, 2016, Amsterdam, The Netherlands, Springer, Cham, 2016: 21-37.
- [27] 姜洪权, 贺帅, 高建民, 等. 一种改进卷积神经网络模型的焊缝缺陷识别方法[J]. 机械工程学报, 2020, 56(8): 235-242.
- JIANG Hongquan, HE Shuai, GAO Jianmin, et al. An improved convolutional neural network for weld defect recognition[J]. Journal of Mechanical Engineering, 2020, 56(8): 235-242.
- [28] 邵海东, 张笑阳, 程军圣, 等. 基于提升深度迁移自动编码器的轴承智能故障诊断[J]. 机械工程学报, 2020, 56(9): 84-90.
- SHAO Haidong, ZHANG Xiaoyang, CHENG Junsheng, et al. Intelligent fault diagnosis of bearing using enhanced deep transfer auto-encoder[J]. Journal of Mechanical Engineering, 2020, 56(9): 84-90.
- [29] WANG L M, SHAO Y M. Crack fault classification for planetary gearbox based on feature selection technique and k-means clustering method[J]. Chinese Journal of Mechanical Engineering, 2018, 31(1): 1-11.
- [30] YIN J, BAI Q, ZHANG B. Methods for detection of subsurface damage: A review[J]. Chinese Journal of Mechanical Engineering, 2018, 31(1): 1-14.
- [31] ZHAO S, YIN L, ZHANG J, et al. Real-time fabric defect detection based on multi-scale convolutional neural network[J]. IET Collaborative Intelligent Manufacturing, 2020, 2(4): 189-196.
- [32] 胡琨, 张树有, 赵昕玥, 等. 基于 Contourlet 变换的阴影恢复形貌方法及产品表面缺陷检测应用[J]. 机械工程学报, 2018, 54(6): 102-109.
- HU Kun, ZHANG Shuyou, ZHAO Xinyue, et al. Defect detection based on contourlet-based shape from shading[J]. Journal of Mechanical Engineering, 2018, 54(6): 102-109.
- [33] HUI Q, LI Y, TAO Y, et al. Triple-helix structured model based on problem-knowledge-solution co-evolution for innovative product design process[J]. Chinese Journal of Mechanical Engineering, 2020, 33(1): 1.
- [34] 王庆锋, 刘家赫, 卫炳坤, 等. 数据驱动的聚类分析故障识别方法研究[J]. 机械工程学报, 2020, 56(18): 7-14.
- WANG Qingfeng, LIU Jiahe, WEI Bingkun, et al. Research on data-driven clustering analysis fault identification method[J]. Journal of Mechanical Engineering, 2020, 56(18): 7-14.

作者简介: 赵树焯, 男, 1997 年出生。主要研究方向为机器视觉与深度学习。

E-mail: dhuzhaoshuxuan@163.com

张洁(通信作者), 女, 1963 年出生, 博士, 教授, 博士研究生导师。主要研究方向为智能制造系统、工业大数据。

E-mail: meizhangjie@dhu.edu.cn