

DOI: 10.13382/j.jemi.B2205564

# 融合改进 Padim 建模和 ResNet 网络的 喷涂质量检测算法\*

李亚舟<sup>1</sup> 曹江涛<sup>1</sup> 姬晓飞<sup>2</sup>

(1. 辽宁石油化工大学信息与控制工程学院 抚顺 113001; 2. 沈阳航空航天大学自动化学院 沈阳 110136)

**摘要:** 为了满足喷涂机器人对于喷涂质量检测的需求,采用迁移学习对改进 Padim 建模和 ResNet 网络进行融合,构建自主喷涂机器人喷涂质量检测一体化模型。该模型提取一次图像特征可同时用于缺陷定位和分类。在缺陷定位端,通过改进 Padim 模型以减少特征冗余所造成的网络的计算消耗,首先将 ResNet-18 网络获取的 patch 嵌入向量语义层由原先前 3 层改为单 2 层,然后特征表达由 100 维降维至 20 维,最后训练正样本得到正态分布模型与测试图像进行缺陷定位。在缺陷分类端,对预训练 ResNet-18 网络进行负样本二次训练,得到 ResNet-18 分类模型对测试图像进行缺陷分类。经过实验,将一体化模型移植在 jetson nano 移动端中,参数量仅为 11.69 M,定位精度 94.5%,分类准确率高达 99.6%,在机器人位移速度 0.02 m/s 下检测时间为 0.730 s,不会出现缺帧漏检情况,满足实时检测的要求。

**关键词:** 喷涂机器人;喷涂质量检测;迁移学习;Padim 建模;ResNet 网络

**中图分类号:** TP391.41 **文献标识码:** A **国家标准学科分类代码:** 510.40

## Spraying quality detection algorithm by fusing improved Padim modeling with ResNet network

Li Yazhou<sup>1</sup> Cao Jiangtao<sup>1</sup> Ji Xiaofei<sup>2</sup>

(1. School of Information and Control Engineering, Liaoning Petrochemical University, Fushun 113001, China;

2. School of Automation, Shenyang Aerospace University, Shenyang 110136, China)

**Abstract:** In order to meet the needs of spraying robots for spraying quality detection, the improved padim modeling and ResNet network are fused by using transfer learning to build an integrated model of spray quality detection for the autonomous spray robot. The model can be used for defect location and classification at the same time by extracting image features once. At the defect location end, the Padim model is improved to reduce the network computing consumption caused by feature redundancy, and the patch embedding vector semantic layer obtained by the ResNet-18 network is first changed from the original three layers to a single second layer. Then the dimension of feature expression is reduced from 100 to 20 dimensions. Finally, the normal distribution model obtained by training the positive samples and the test image are used for defect location. At the defect classification end, the pre-trained ResNet-18 network is re-trained with negative samples, and the ResNet-18 classification model is obtained to classify the test images for defects. After experiments, the integrated model is transplanted into the Jetson nano mobile terminal. The parameter quantity is 11.69 M, the positioning accuracy is 94.5%, and the classification accuracy is as high as 99.6%. The detection time is 0.730 s when the robot displacement speed is 0.02 m/s, and there will be no missing frame detection, which meets the requirements of real-time detection.

**Keywords:** spraying robot; spraying quality inspection; transfer learning; Padim modeling; ResNet network

## 0 引言

目前在室内装修领域,机器人结合计算机视觉进行

室内墙壁喷涂的方式逐步涌现<sup>[1]</sup>,但对喷涂的质量检测却仍然靠人工目检,这不仅对工作人员视力和身体造成极大损伤,而且在特殊的高度和角度区域,很难进行有效检测。在喷涂机器人平台上设计并实现相应的喷涂质量

检测算法需兼顾机器人成本、功耗及运算性能,既要满足实用性又要满足经济性,因此这一研究仍是一个具有挑战性的研究课题。目前针对工件表面的缺陷检测算法已经相对成熟<sup>[2]</sup>,但是没有专门搭载在机器人平台上的室内墙壁喷涂检测算法,因此只能借鉴具有相似特征的检测算法(如金属表面、纺织品、瓷砖、木材等)作为参考。目前缺陷检测算法可以大致分为两大类:基于传统特征提取的检测方法和基于深度学习的检测算法。

基于传统特征提取的检测方法主要利用颜色、纹理等底层特征作为缺陷特征表示,并通过分类器进行分类识别。Zhang 等<sup>[3]</sup>针对瓷砖表面复杂纹理,提取缺陷的颜色直方图特征,并输入支持向量机(support vector machine, SVM)分类器进行识别。Li 等<sup>[4]</sup>针对不同纹理的灰度纺织图像,提出一种基于多项二值算子与灰度共生矩阵(gray level co-occurrence matrix, GLCM)的表面缺陷检测方法。Sulistyaningrum 等<sup>[5]</sup>用 Gabor 滤波器方法对沥青路面进行裂缝缺陷检测分割,然后采用形态学方法对分割结果进行处理。Mentouri 等<sup>[6]</sup>针对钢板表面缺陷,提出一种基于多尺度二值化统计图像特征与 K 最近邻方法(K-nearest neighbors, KNN)的检测方法。Chaudhari<sup>[7]</sup>同样针对钢板表面缺陷分别通过提取 GLCM 特征、Gabor 滤波特征、方向梯度直方图(histogram of oriented gradient, HOG)特征,最后使用随机森林算法进行分类识别。该类方法针对特定场景可以获得较好的检测效果,但缺点是在不同场景下或者缺陷纹理不规则时都需要人为动态调整参数,从而导致该类算法适应性差,效率不高,通用性不强。

基于深度学习的缺陷检测算法能够很好的解决以上问题。在有监督算法中,向宽等<sup>[8]</sup>在 Faster R-CNN 网络中引入特征金字塔网络(feature pyramid network, FPN),构建针对铝材缺陷的目标检测模型。Jing 等<sup>[9]</sup>针对织物疵点,在 YOLOv3 算法中将低层特征与深层特征结合在不同尺寸的特征图上添加 YOLO 检测层,对灰布和格布进行缺陷检测。该类方法虽然检测速度较快,精度较高,但缺点是过分依赖数据集,并需要自制大量缺陷数据进行标注,在一定程度上,数据集的优劣程度和数量多少直接影响到算法的检测效果,从而导致该类算法人工成本高,前期准备难度大。在无监督算法中,Liu 等<sup>[10]</sup>针对铝型材表面缺陷构建了一种双编码器网络,由两个编码器和一个解码器组成,只需要训练正样本,即可通过两个编码器的输出特征差异进行缺陷定位。Hu 等<sup>[11]</sup>提出了一种基于深度卷积的生成对抗网络(deep convolutional generative adversarial network, DCGAN)的织物缺陷检测算法,一部分利用 GAN 判别器生成缺陷分布似然图,其中每个像素值表示该位置可能是缺陷的概率;另一部分将编码器加入到标准 DCGAN 网络,进行检测图像的重构。

Napoletano 等<sup>[12]</sup>针对纤维材料扫描电镜图缺陷,提出了一种基于卷积神经网络(convolutional neural networks, CNN)自相似性的区域检测方法。该方法利用 CNN 进行提取特征,然后对正样本图像特征集进行降维处理,最后计算缺陷图像和正样本特征集的欧氏距离,大于阈值设定为异常。Defard 等<sup>[13]</sup>提出一种 Padim 建模方法,通过预训练 CNN 获取特征构建正态分布模型,通过计算缺陷图像和正态分布模型的马氏距离,大于阈值设置为异常。该类方法前期准备难度小,只需采集一定量的正常样本和少量缺陷样本,无需人工标注,这大大减少了检测效果对于数据集的依赖程度。考虑到喷涂检测异常样本收集难度大,Padim 模型为喷涂质量检测提供了解决方案。然而 Padim 模型较大、计算速度慢,无法进行实时处理,并且只能实现缺陷定位无法满足分类需求,因此需要针对实际的需求,对模型进行压缩,提高检测效率,并增加分类识别功能。

针对以上问题,利用迁移学习的手段对改进的 Padim 建模和 ResNet 网络进行融合,构建了自主喷涂机器人质量检测一体化模型,该模型只需提取一次测试图像特征,可同时用于缺陷定位和分类,大大降低了网络的计算复杂度,提高了网络的性能。本文的主要工作有:1)缺陷定位端:针对喷涂图像特点将原有的 3 层 patch 向量语义层改为单 2 层,采用随机降维实现特征维度大幅度降低,检测时间大幅度减少并维持准确率不变。2)缺陷分类端:在预训练 ResNet-18 网络上对缺陷样本进行二次训练,获得喷涂最优分类模型,准确率达到 99.6%。3)利用预训练网络将缺陷检测定位端和分类端进行融合,并成功移植在 jetson nano 移动端中,机器人移动过程中不会出现缺帧漏检情况,满足实时的喷涂缺陷在线检测。

## 1 算法框架

本文提出的喷涂质量检测算法模型如图 1 所示,在采用迁移网络的基础上分为定位端、分类端和测试端 3 部分。1)定位端。在改进的 Padim 模型中将  $N$  幅正样本图像数据送入预训练 ResNet-18 网络,生成正样本 patch 向量特征集,再将得到的向量特征集进行正态化处理,得到正样本的正态分布模型。2)分类端。将负样本数据集通过预训练的 ResNet-18 网络后,将获得的负样本 patch 向量特征集经过二次训练,得到喷涂缺陷检测模型。3)测试端。喷涂机器人通过高清摄像头采集到的缺陷图像送入预训练的 ResNet-18 网络,获得负样本 patch 向量特征,然后分别送往定位端和分类端,在定位端中与正样本正态分布模型计算马氏距离,输出异常区域进行缺陷定位;在分类端中送入喷涂缺陷检测模型进行缺陷

分类,得到分类结果。最后将定位和分类结果融合实现喷涂瑕疵检测。

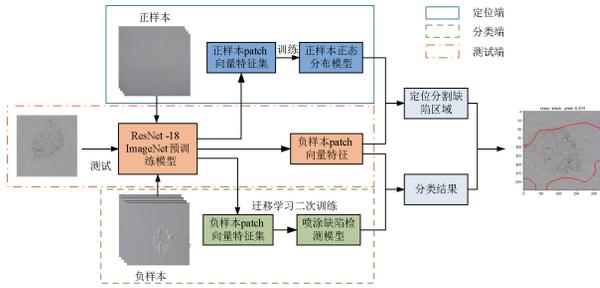


图 1 算法框架

Fig. 1 Algorithmic framework

## 2 Padim 建模

在无监督算法中,Padim 建模分为 Patch 嵌入向量和定位分割两部分。主要思想是利用预训练深度神经网络提取整幅图像中用于异常检测<sup>[14]</sup>的 Patch 向量,然后将获得的特征向量计算异常分数,最后定位分割得到异常区域。

Patch 嵌入向量的本质是量化相似性,将相似性在多个维度上进行量化,从而通过判断两个向量的距离来判断相似性。预训练的 CNN 网络模型能够提取图像的特征,并用于生成 patch 嵌入向量<sup>[15]</sup>,结构如图 2 所示,这样的处理方式能够避免网络不断训练来获取图像特征和复杂的优化问题。首先将采集的正常图像的每个 patch 嵌入向量与 CNN 空间中相对应的激活向量进行关联。然后,将 layer1、layer2、layer3 层的激活向量连接起来,实现多特征融合,最后将携带不同语义层次和分辨率信息的嵌入向量特征进行编码。产生的激活图分辨率要比原始图像低,因此多张正常图像同一位置存在相似嵌入,形成的激活图像素块与原始图像分辨率不会产生重叠。将输入图像划分成  $(i, j) \in [1, W] \times [1, H]$  位置网格,其中  $W \times H$  是用于生成嵌入向量的最大激活图分辨率。最后,将该网格中的每个 patch 位置  $(i, j)$  与嵌入向量  $x_{ij}$  相关联。

因为 patch 嵌入向量来自前 3 层语义层,将其进行叠加会造成信息冗余,采用随机选择适用维度的方法来表达特征信息比主成分分析(principal component analysis, PCA)算法<sup>[16]</sup>更有效。这种方法不仅降低了模型训练测试的时间和复杂性,而且不会影响定位精确度。

定位分割采用计算异常分数的方式,主要思路是将上面获得正常图像的 patch 向量,通过学习高斯参数计算出正态参考向量,然后计算测试图像的嵌入向量与正态参考向量之间的距离,得分异常的地方表示缺陷。

为了学习位置  $(i, j)$  处的正常图像特征,从  $N$  张正

常图像中计算在  $(i, j)$  处的 patch 嵌入向量集合,  $X_{ij} = \{x_{ij}^k, k \in [1, N]\}$ ,如图 2 所示。将集合所携带的信息进行汇总,采用由多元高斯分布  $N(\mu_{ij}, \sum ij)$  产生的  $X_{ij}$  进行表达,其中  $\mu_{ij}$  是样本均值,  $\sum ij$  样本协方差估计如下:

$$\sum ij = \frac{1}{N-1} \sum_{k=1}^N (x_{ij}^k - \mu_{ij})(x_{ij}^k - \mu_{ij})^T + \varepsilon I \quad (1)$$

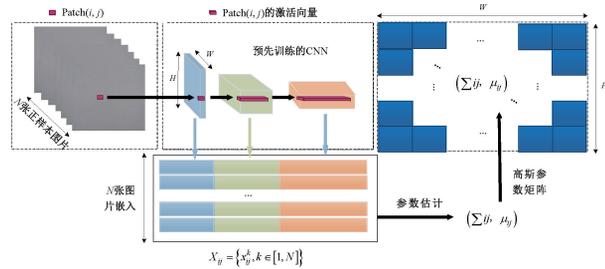


图 2 patch 嵌入向量与定位分割

Fig. 2 Patch embedding vectors and localization segmentation

对于位置  $(i, j)$  处对应的每个图像的 patch 向量,训练从  $N$  个图像的嵌入向量集合  $X_{ij} = \{x_{ij}^k, k \in [1, N]\}$  中学习高斯参数  $(\mu_{ij}, \sum ij)$ ,其中正则化项  $\varepsilon I$  使样本协方差矩阵  $\sum ij$  满秩可逆。最后,通过高斯参数矩阵将每个 patch 位置与多元高斯分布相关联。因此,每个估计的多元高斯分布  $N(\mu_{ij}, \sum ij)$  捕获了不同特征层对应的同一个坐标点的相似性。

借鉴 Rippel 等<sup>[17]</sup>采用马氏距离计算异常分数,  $M(x_{ij})$  给测试图像位置  $(i, j)$  的 patch 一个异常分数。  $M(x_{ij})$  为嵌入  $x_{ij}$  的测试 patch 与学习分布  $N(\mu_{ij}, \sum ij)$  之间的距离,其中  $M(x_{ij})$  的计算公式如下:

$$M(x_{ij}) = \sqrt{(x_{ij} - \mu_{ij})^T \sum_{ij}^{-1} (x_{ij} - \mu_{ij})} \quad (2)$$

因此,可以计算出构成异常图的马氏距离矩阵:

$$M = (M(x_{ij}))_{1 < i < W, 1 < j < H} \quad (3)$$

## 3 质量检测一体化模型

针对 Padim 算法计算复杂度高、速度慢,难于应用于移动设备且无法实现分类识别的问题,首先对 Padim 建模进行改进,构建喷涂缺陷定位模型,然后采用迁移学习手段<sup>[18-19]</sup>构建分类模型以解决网络训练问题,在缺陷数据较少的情况下,加快整体模型开发和训练时间<sup>[20]</sup>。最后借助预训练 ResNet-18 网络提取一次缺陷特征,将缺陷定位模型和缺陷分类模型进行融合,同时完成缺陷定位和分类识别功能,并将一体化模型移植于移动端。

### 3.1 改进 Padim 模型构建定位模型

Padim 模型应用于 MVTec 数据集上待检测物体一共有 14 个类别,并且各种类别的特征形态都较为复杂,需要获取深度信息才能对目标进行像素级检测,但是对于喷涂这种背景相对单一、特征相对简单的缺陷,采用 Padim 模型会造成大量冗余特征,而且无法提高检测效果,因此对预训练 ResNet-18 网络提取 patch 嵌入向量语义层和随机降维特征层进行简化,如图 3 所示,改进的 Padim 模型将 patch 嵌入向量语义层由原先前 3 层改为单 2 层,把降维后的特征表达由 128 维改为 20 维,该操作既能够不丢失语义信息和分辨率,又能够缩小模型参数量,减少了特征计算所需要的时间。

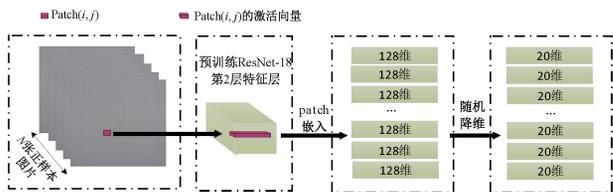


图 3 改进 Padim 模型特征提取层

Fig. 3 Improved Padim model feature extraction layer

### 3.2 迁移学习构建分类模型

为进一步减少模型复杂度,分类模型采用与定位端一致的 ResNet-18 网络进行迁移学习,构建喷涂分类模型流程如图 4 所示,源域为 ImageNet 数据集<sup>[21]</sup>,该数据集本身有超过 1 400 多万张图片,超过 2 万多的分类,其中有超过 100 万张图片有明确类别标注和物体位置标注。目标域为自建的少量缺陷喷涂数据集。首先导入预训练好的 ResNet-18 网络模型,然后针对喷涂缺陷的类别以及训练信息对网络结构进行调整,最后进行二次训练得到喷涂分类网络模型,准确率达到 99.6%。

### 3.3 模型融合

为构建一体化模型,本文在缺陷定位端和分类端均采用 ResNet-18 网络作为特征提取网络,对测试图像只需提取一次特征,同时用于缺陷定位和分类。将改进 Padim 定位模型和迁移学习分类模型进行融合,如图 5 所示,将待检测图像输入模型,首先经 ResNet-18 网络提取的缺陷特征分别输入缺陷定位模型和分类识别模型,然后将其预测结果融合,最后实现缺陷检测,这大大地减小了网络的计算复杂度和参数量,使其更容易移植于移动端,满足实时检测的要求。

## 4 实验测试与分析

### 4.1 数据集

本文所涉及的检测场景没有公开的测试数据集,文

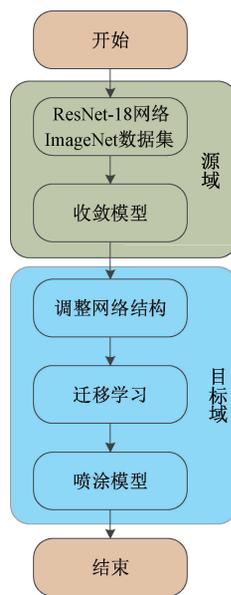


图 4 喷涂分类模型

Fig. 4 Spray classification model

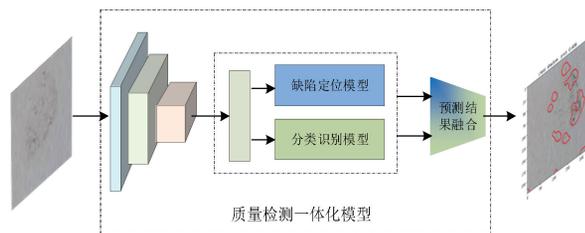


图 5 模型融合

Fig. 5 Model fusion

中通过喷涂机器人所搭载的摄像头进行采集,建立测试数据集。将获得的无缺陷图片输出保存为检测端缺陷定位分割的正样本,将检测到的有缺陷部分进行分割,输出保存为分类端迁移网络 ResNet-18 的数据集。喷涂缺陷主要分为黑影块、不均匀和墙孔 3 类,如图 6 所示,其中 500 张图像用作正样本训练,800 张图像用作负样本训练,其中负样本的训练集、测试集、验证集数量比例为 7 : 2 : 1,即训练集共 560 张图片,测试集共 160 张图片,验证集共 80 张。

### 4.2 图像增强

相较于大型开源数据集,本次实验所使用的数据集相对较小,在获得原始数据集后对训练集中的图像进行数据增强,数据增强是减少过拟合、提高机器学习模型泛化能力的一种常用方法,可以解决数据受限的问题,本文对图像进行旋转、位移、缩放、增加噪声以及颜色空间变换等使模型学习能力更强。

### 4.3 网络训练与测试

为了便于模型的移植,本研究实验环境配置如表 1

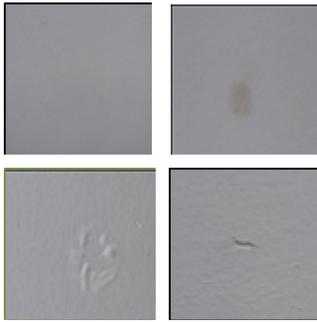


图 6 训练数据集(正常、黑影块、不均匀、墙孔)

Fig. 6 Training dataset (normal, shadow block, uneven, wall hole)

所示,分为 2 个阶段,为了节省训练时间,训练阶段使用图形工作站。测试阶段在移动端 jetson nano 上完成,以此验证网络架构的通用性和实用性。

表 1 不同实验平台配置

Table 1 Configuration of different experimental platforms

实验过程	训练阶段	测试阶段
测试平台	NVIDIA GTX 1080Ti	NVIDIA Tegra X1
编程语言	Python3. 6	Python3. 6
系统	Ubuntu16. 04LTS	Ubuntu18. 04
学习框架	Pytorch1. 5. 0	Pytorch1. 5. 0

训练阶段首先将机器人采集到的正样本图像和负样本图像同时批量输入预训练的 ResNet-18 网络,提取的正样本特征通过高斯正态化,得到正态分布模型用于检测缺陷,提取的负样本特征在迁移模型 ResNet-18 上进行二次训练,训练 epoch 为 4,学习率初始值为 0. 001, batch 为 128,得到喷涂缺陷检测模型用以分类缺陷种类,最后将 2 个模型融合在测试系统中,构建喷涂机器人质量检测一体化模型。

测试阶段将一体化模型移植到移动端处理器,通过摄像头采集缺陷图像进行测试,完成缺陷检测识别并将结果保存。

#### 4. 4 实验结果及分析

实验 1 对 Patch 建模不同语义层之间相关性进行实验对比,把多次实验获得的 ROC 曲线下面积( area under ROC, AUROC), PRO-SCORE 和检测时间的平均值作为检测指标,对比结果如表 2 所示。

表 2 不同语义层的影响对比实验

Table 2 Comparative experiments on the influence of different semantic layers

语义层	AUROC/%	PRO-SCORE/%	检测时间/s
Layer1	93. 1	84. 8	1. 061
<b>Layer2</b>	<b>94. 5</b>	<b>86. 5</b>	<b>0. 631</b>
Layer1+2(组合层)	95. 2	88. 1	1. 095

通过表 2 可以看出,针对喷涂数据特征在 AUROC 和 PRO-SCOR 方面,3 组对比结果相差不大, layer2 层承载更高语义级别的信息,而 layer1 层保留较多原始特征信息,进行组合虽然能够提高一定的精度,但在检测时间方面,单独的 layer2 层分辨率较低,检测速度更快。

实验 2 对随机降维( Rd) 和 PCA 降维效果进行实验对比,把多次实验获得的 AUROC, PRO-SCORE 和检测时间的平均值作为检测指标,对比结果如表 3 所示。

表 3 随机降维和 PCA 的对比实验

Table 3 A comparative experiment of PCA and random descent

降维方式	AUROC/%	PRO-SCORE/%	检测时间/s
<b>Rd 20</b>	<b>94. 5</b>	<b>86. 5</b>	<b>0. 631</b>
PCA 20	93. 6	80. 8	0. 794
Rd 40	95. 4	87. 4	0. 951
PCA 40	94. 5	86. 1	0. 987
ALL(128)	96. 3	89. 9	2. 396

通过表 3 可以看出,将嵌入向量同时降维到相同维度,随机降维( Rd) 在 AUROC、PRO-SCORE 和检测时间方面都要比 PCA 高,因为 PCA 降维选择具有最高方差的维度特点,而该维度不能保证是区分正常类别和异常类别的最优维度。同时可以看出,将嵌入向量大小随机减少到 20 维和 40 维对结果影响非常小,故采用更少的维度可以大大减少模型参数。

实验 3 对迁移学习与原始训练进行实验对比,将识别准确率 Acc 和训练次数 Epoch 作为检测指标,对比结果如表 4 所示。

表 4 迁移学习与原始训练的对比实验

Table 4 A comparative experiment of transfer learning and primitive training

网络类型	Acc/%	Epoch
原始训练 ResNet-18	60. 5	50
迁移学习 ResNet-18	<b>99. 6</b>	<b>4</b>

从表 4 可以看出,通过原始训练的 ResNet-18 模型,训练 50 轮,准确率最高只有 60. 5%,而在预训练模型上进行二次训练,只需训练 4 轮,准确率可达 99. 6%,由此可以看出在小样本数据下,迁移学习能够提高模型的健壮性,并为难以采集实际样本问题提供可靠的解决方案。

实验 4 对一体化模型的不同预训练模型 ResNet-18 和 ResNet-50 进行迁移学习进行实验对比,把多次实验获得的识别准确率 Acc、参数量和检测时间的平均值作为检测指标,对比结果如表 5 所示。

表5 预训练模型 ResNet-18 和 ResNet-50 的对比实验

Table 5 Comparison of ResNet-18 and ResNet-50 pretraining models

预训练模型	Acc/%	参数量/M	检测时间/s
迁移学习 ResNet-18	99.6	11.69	0.730
迁移学习 ResNet-50	97.4	68.88	3.263

从表5可以看出,无论在识别准确率、参数量还是在检测时间方面,设计的一体化模型中采用预训练的 ResNet-18 模型都要比预训练的 ResNet-50 模型效果更佳,不仅能够很好的完成检测,成功移植到 jetson nano 移动端中,在机器人移动速度 0.02 m/s 下检测时间为 0.730 s,不会出现缺帧漏检情况满足实时检测的要求。

## 5 结论

针对喷涂质量检测问题,本文利用迁移学习的手段对改进的 Padim 建模和 ResNet 网络进行融合,构建了自主喷涂机器人质量检测一体化模型,该模型无需人为设计特征,也无需做标注,只需提取一次测试图像特征将其同时用于缺陷定位和分类。改进的 Padim 模型针对喷涂图像特点将原有的 3 层 patch 向量语义层改为单 2 层,采用随机降维实现特征维度大幅度降低,检测时间大幅度减少并维持准确率不变。同时在预训练 ResNet-18 网络上对缺陷样本进行二次训练,获得喷涂最优分类模型。实验证明,该一体化模型较好的实现了喷涂质量检测的各项性能要求,具有实际应用的价值。

## 参考文献

- [1] 张聪,郁汉琪,黄志鹏,等. 喷涂机器人研究综述[J]. 信息与电脑(理论版),2020,32(19):1-3.  
ZHANG C, YU H Q, HUANG ZH P, et al. A review of the research on spraying robots [J]. Information and Computer (Theoretical Edition), 2020, 32(19): 1-3.
- [2] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报,2022,43(1):198-219.  
ZHAO L Y, WU Y Q. Research progress of surface defect detection method based on machine vision [J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.
- [3] ZHANG H, PENG L, YU S, et al. Detection of surface defects in ceramic tiles with complex texture[J]. IEEE Access, 2021, 9: 92788-92797.
- [4] LI F, YUAN L, ZHANG K, et al. A defect detection method for unpatterned fabric based on multidirectional binary patterns and the gray-level co-occurrence matrix[J]. Textile Research Journal, 2020, 90(7-8): 776-796.
- [5] SULISTYANINGRUM D R, SETIYONO B, ANITA J N, et al. Measurement of crack damage dimensions on asphalt road using gabor filter[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1752(1): 012086.
- [6] MENTOURI Z, MOUSSAOUI A, BOUDJEHEM D, et al. Steel strip surface defect identification using multiresolution binarized image features[J]. Journal of Failure Analysis and Prevention, 2020, 20(6): 1917-1927.
- [7] CHAUDHARI C V. Steel surface defect detection using glcm, gabor wavelet, hog, and random forest classifier[J]. Turkish Journal of Computer and Mathematics Education (TURCOMAT), 2021, 12(12): 263-273.
- [8] 向宽,李松松,栾明慧,等. 基于改进 Faster RCNN 的铝材表面缺陷检测方法[J]. 仪器仪表学报,2021, 42(1): 191-198.  
XIANG K, LI S S, LUAN M H, et al. Surface defect detection method of aluminum material based on improved Faster RCNN [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 191-198.
- [9] JING J, ZHUO D, ZHANG H, et al. Fabric defect detection using the improved YOLOv3 model[J]. Journal of Engineered Fibers and Fabrics, 2020, 15: 1-10.
- [10] LIU J, SONG K, FENG M, et al. Semi-supervised anomaly detection with dual prototypes autoencoder for industrial surface inspection [J]. Optics and Lasers in Engineering, 2021, 136:106324.
- [11] HU G, HUANG J, WANG Q, et al. Unsupervised fabric defect detection based on a deep convolutional generative adversarial network[J]. Textile Research Journal, 2020, 90(3-4): 247-270.
- [12] NAPOLETANO P, PICCOLI F, SCETTINI R. Anomaly detection in nanofibrous materials by CNN-based self-similarity[J]. Sensors, 2018, 18(1): 209.
- [13] DEFARD T, SETKOV A, LOESCH A, et al. Padim: A patch distribution modeling framework for anomaly detection and localization [C]. International Conference on Pattern Recognition. Springer, Cham, 2021: 475-489.
- [14] BERGMAN L, HOSHEN Y. Classification-based anomaly detection for general data [J]. arXiv preprint arXiv:2005.02359, 2020.
- [15] BERGMAN L, COHEN N, HOSHEN Y. Deep nearest neighbor anomaly detection [J]. arXiv preprint arXiv:

2002. 10445, 2020.

- [16] HUANG D, JIANG F, LI K, et al. Scaled PCA: A new approach to dimension reduction [ J ]. Management Science, 2022, 68(3): 1678-1695.
- [17] RIPPEL O, MERTENS P, MERHOF D. Modeling the distribution of normal data in pre-trained deep features for anomaly detection [ C ]. 2020 25th International Conference on Pattern Recognition ( ICPR ). IEEE, 2021: 6726-6733.
- [18] SHOWKAT S, QURESHI S. Efficacy of Transfer learning-based ResNet models in chest X-ray image classification for detecting COVID-19 pneumonia [ J ]. Chemometrics and Intelligent Laboratory Systems, 2022, 224: 104534.
- [19] SHAH S A A, LUO H, PICKUPANA P D, et al. Automatic and fast classification of barley grains from images: A deep learning approach [ J ]. Smart Agricultural Technology, 2022: 100036.
- [20] SUBRAMANIAN M, SHANMUGAVADIVEL K, NANDHINI P S. On fine-tuning deep learning models using transfer learning and hyper-parameters optimization for disease identification in maize leaves [ J ]. Neural Computing and Applications, 2022: 1-18.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [ J ]. Advances in Neural Information Processing Systems, 2012, 25.

## 作者简介



**李亚舟**, 2017 年于山西大学获得学士学位, 现为辽宁石油化工大学硕士研究生, 主要研究方向为图像处理和模式识别。

E-mail: 18334786494@163.com

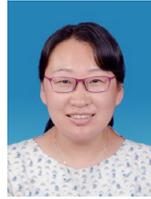
**Li Yazhou** received his B. Sc. degree in 2017 from Shanxi University. Now he is a M. Sc. candidate in Liaoning Petrochemical University. His main research interests include image processing and pattern recognition.



**曹江涛**, 2009 年于英国普茨茅斯大学获得博士学位, 现为辽宁石油化工大学教授、硕士生导师, 主要研究方向为智能方法及其应用、视频分析与处理等。

E-mail: cigroup@126.com

**Cao Jiangtao** received Ph. D. degree from University of Portsmouth in 2009. Now he is a professor and M. Sc. supervisor at Liaoning Petrochemical University. His main research interests include intelligent methods and applications, video analysis and processing, etc.



**姬晓飞**(通信作者), 博士, 副教授, 主要研究方向为视频分析与处理、模式识别理论等。

E-mail: jixiaofei7804@126.com

**Ji Xiaofei** ( Corresponding author ), Ph. D., associate professor and M. Sc. supervisor at Shenyang Aerospace University. Her main research interests include video analysis and pattern recognition theory, etc.