

文章编号:1007-2780(2019)01-0081-09

基于深度学习的乳液泵缺陷检测算法

马浩鹏¹, 朱春媚^{2*}, 周文辉^{1,2}, 殷 春¹

(1. 电子科技大学 自动化工程学院, 四川 成都 611731;

2. 电子科技大学 中山学院, 广东 中山 528400)

摘要:为了实现对工业产品乳液泵的缺陷检测,本文采集泵顶、泵上端、泵下端、尾管 4 个角度的样本图像,并基于深度学习中迁移学习和卷积神经网络的原理分别构建各角度的分类模型以检测缺陷样本。首先,使用 Mini-ImageNet 数据集预训练网络模型。然后,调整模型结构并加载预训练网络的参数,并将乳液泵各角度的训练集和验证集经过图像预处理算法后输入至卷积神经网络中训练,根据训练过程中验证集准确率的变化调整网络超参数,得到最终网络模型。最后,将预处理后的乳液泵测试样本输入至训练好的模型中,检测最终模型的缺陷识别效果。最终 4 个角度检测准确率均在 93% 以上,单样本检测用时为 2.52 s,优于传统方法。本文算法可用于设计乳液泵缺陷检测系统,该系统能与工业结构相结合筛选出有缺陷的泵体,也可拓展到工业其他物件的缺陷检测。

关键词:深度学习; 迁移学习; 卷积神经网络; 乳液泵; 缺陷检测

中图分类号:TP394.1; TH691.9 **文献标识码:**A **doi:**10.3788/YJYXS20193401.0081

Defect detection algorithm of lotion pump based on deep learning

MA Hao-peng¹, ZHU Chun-mei^{2*}, ZHOU Wen-hui^{1,2}, YIN Chun¹

(1. College of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. Zhongshan Institute, University of Electronic Science and Technology of China, Zhongshan 528400, China)

Abstract: In order to realize the defect detection of lotion pump in the industrial production, the sample images at four angles: the top section of pump, the upper section of pump, the lower section of pump and the tail tube of pump were collected. The classification models of each angle were also constructed respectively to detect defect samples at various angles based on the principle of migration learning and convolutional neural network in deep learning. Firstly, the network model was pre-trained by the Mini-ImageNet data set. Then, the model structure was adjusted and the parameters of the pre-training network were loaded. The training set and validation set of each part of the lotion

收稿日期:2018-08-06; **修订日期:**2018-11-06.

基金项目:广东省公益研究与能力建设项目(No.2017A010102002); 中山市社会公益科技研究重大专项(No.2016B2119)

Supported by Guangdong Province Public Welfare Research and Capacity Building Project (No.2017A010102002); Major Special Projects of Social Public Welfare Science and Technology Research in Zhongshan City (No.2016B2119)

* 通信联系人, E-mail: cmzhu@zsc.edu.cn

pump which were processed with the image pre-processing algorithm were input into the convolutional neural network for training. According to the accuracy of the verification set during the training process, the network hyperparameters were adjusted to get the final network model. Finally, the pre-processed lotion pump test samples were input into the trained model to detect the defect recognition effect of the final model. The accuracy of the final four angles of defect detection is over 93%, and the single sample detection time is 2.52 s. The algorithm is superior to the traditional algorithm. The algorithm can be used to design the lotion pump defect detection system which can combine with the industrial structure to screen out the defective pump body. It can also be extended to the defect detection of other industrial objects.

Key words: deep learning; transfer learning; convolutional neural network; lotion pump; defect detection

1 引言

乳液泵是洗液容器的重要组成部分,其社会需求量巨大,市场广阔,因此需要大批量生产。但在生产过程中会出现表面沾染污渍、尾管倒插的问题。因此需要进行严格的表面检测,以保证它的质量,提升其商业价值和使用价值。传统的乳液泵缺陷检测方法大多是以人工检测为主,人工检测法易受到检测人员的思维、情绪、人眼疲劳、经验差异、工作强度等因素的影响而降低检测结果的可靠性,最终导致检测效率低下,不利于产品生产。本文设计表面缺陷检测算法,将其应用于乳液泵缺陷检测系统中,让机器检测替代人为检测,实现检测自动化,可以有效的解决上述问题,提高产品质量,推动企业技术转型升级。

目前工业上存在的表面缺陷检测算法大多是以图像处理法或者特征提取、机器学习算法分类为主,即人工提取图像代表性的特征并将得到的特征输入至机器学习分类器中以训练工件缺陷分类模型。文献[1]采用 Gabor 小波和核保局投影法 (Kernel locality preserving projections, KLPP)提取热轧钢板表面特征,并将其输入至多层感知机 (Multi-layer perception, MLP)中训练缺陷分类器,最终成功检测出热轧钢板表面缺陷。文献[2]利用局部二值模式 (Local Binary Pattern, LBP)提取药瓶的纹理特征,并将其输入至支持向量机 (Support Vector Machine, SVM)训练药瓶缺陷检测模型,实现药瓶表面缺陷检测。文献[3]基于小波钝化原理提出一种嵌入式图像处理算法,该算法统计样本的像素值,并引入支持

向量机进行分类,有效的解决了由图像偏移而产生的干扰,实现了对注塑模具残留物的检测,其平均检测准确率能达到 85.71%。而乳液泵的缺陷检测是三维检测,需要多镜头拍摄每一个样本,各镜头采集到的样本角度不同,通过观察各镜头采集样本的情况以判断该样本是否存在缺陷。由于不同镜头采集到的样本形状特性、缺陷特征各异,因此需要根据各拍摄角度的具体形态设计相应的特征提取算法以及分类算法,这将会增加检测算法实现的复杂度,影响算法检测速率。

深度学习是机器学习的一个新领域,它源于人工神经网络,由多层网络结构组成。它通过对点、边、角等低层特征的学习,形成抽象的属性类别等高层特征以增强机器识别、分类的能力^[4]。自“神经网络之父”Geoffrey Hinton 于 2006 年提出以来^[5],深度学习在无人驾驶汽车^[6]、网络推荐系统^[7]、语音识别^[8]等领域效果显著,从而受到各国学者的广泛关注。

将深度学习应用于工业物件的表面缺陷检测,用深度网络自动提取样本特征,捕捉目标的高级特征,并将其输入至高层网络进行分类识别,可以提高样本特征提取的全面性和鲁棒性,从而提高检测准确率。文献[9]基于深度学习特征匹配的原理,利用特征矢量的相似度成功实现对铸件微小缺陷的自动定位,误差小于 5.57%。文献[10]采用深度置信网络 (Deep Belief Nets, DBN)重构法生成太阳能电池表面模板,再和有缺陷的电池表面作差分,最终成功检测出缺陷电池板。文献[11]参考 AlexNet 网络结构设计深度卷积网络,最终成功实现输电线路中的塔材和绝缘子的目标检测。上述文献采用的方法大多是通过深

度网络提取特征并与正常样本进行匹配而实现,而乳液泵的泵顶存在旋转干扰,泵上身存在随机注塑点干扰,会严重影响算法的准确率,所以并不适用于乳液泵缺陷样本的检测。

大多数深度网络虽然能免去人为特征提取的复杂过程,但训练过程中需要大量样本,而乳液泵具有缺陷样本少、正负样本分布极不均匀的特点,在训练的过程中会导致参数过拟合,影响缺陷检测效果。为解决上述提出的问题,本文针对乳液泵基于深度学习的原理提出一种适用于较少样本量训练的缺陷检测算法。首先为确保网络结构的合理性,参考 CaffeNet^[12] 搭建 14 层卷积神经网络,并基于迁移学习^[13] 原理利用 Mini-ImageNet 样本集预训练网络。然后对乳液泵数据集进行预处理操作,提取目标区域,将预处理后样本的训练集和验证集输入至卷积神经网络中训练,调整网络参数,生成训练模型,最终利用测试集测试模型的检测准确率。实验结果表明本文算法能有效避免泵顶旋转以及泵上端注塑点的干扰,成功识别有缺陷的样本,具有检测准确率高、速率快的特点。

2 算法流程

基于深度学习的图像识别模型主要包括两大




图 1 算法的总体框图

Fig.1 Overall block diagram of the algorithm

2.2 预训练阶段

预训练阶段采用 Mini-ImageNet 数据集,是 ImageNet^[16] 数据集的一部分。ImageNet 数据集是目前深度学习图像领域应用最广泛的数据集之

类;基于有监督学习的卷积神经网络^[14] 和基于无监督学习的深度置信网络^[15]。本文采用带有标签的样本,是在有监督的情况下训练检测模型,故采用卷积神经网络建模。本节中,我们先概述算法的总体框图,然后详细介绍各阶段的实现流程。

2.1 算法的总体流程

算法的总体框图如图 1 所示,主要包括 3 个阶段:网络预训练阶段、模型训练阶段、测试阶段。

(1)网络预训练阶段。使用 Mini-ImageNet 数据集提前训练网络模型,并基于迁移学习的原理在第二阶段开始之前加载预训练的模型参数。目的是提高模型训练阶段网络的特征学习效率,解决因样本量不足而导致的模型过拟合的问题

(2)模型训练阶段。将样本经过图像预处理后输入至卷积神经网络中进行训练,根据训练过程中验证集准确率的变化调整网络超参数,得到最终网络模型。其中,样本的特征提取与缺陷分类过程均在网络内部自动实现。输入样本包括乳液泵训练集和验证集,训练集用于拟合网络模型,主要用于获得损失函数以及调整参数;验证集则直观的展示网络在训练过程的动态,用于调整网络模型的复杂度及参数。

(3)测试阶段。将预处理后的乳液泵测试样本输入至第二阶段训练好的模型中,获得最终模型缺陷识别的准确率。

一,大多图像分类、定位、检测等研究工作都是基于此数据集展开。ImageNet 中有 1 400 多万幅图片,涵盖两万多个类别。由于实验条件有限,本文参照 Cifar-10 数据集的合理性,选取其中 10 个

类别,每类 6 000 个样本,共 60 000 张图像。其中,训练集 50 000 张,测试集 10 000 张。

2.2.1 卷积神经网络结构

本文参照 CaffeNet 定义了 14 层的网络结构,如图 2 所示。Data@ 227×227 表示输入层样本尺寸是 227×227 ,横线上 3 表示输入层深度为 3。Conv-11 表示核尺寸为 11 的卷积层,relu 表示卷积层的激活函数,横线上 96 表示特征图深度,仅与卷积核的深度有关,故仅在卷积层之后有数值的变化。Pool-3 表示核尺寸为 3 的最大池化层,Stride 表示核的移动步长,Pad 表示零填充的个数。LRN 表示侧抑制层,对上一层的局部区域进行归一化,增强反应敏感的神经元抑制反应弱的神经元以实现“侧抑制”的效果。Flatten 表示平坦层,将上一层提取的所有特征图平铺用于后面全连接层的输入。FC 表示全连接层,横线上 4 096 表示全连接层神经元的个数,为防止训练过

程中参数过拟合,本文采用神经元局部失活的方式,drop 参数设定为 0.5。Softmax 层,将全连接层的结果转换成样本属于不同种类的概率分布,用来分类和归一化。其中层内神经元个数等于样本类别数,预训练阶段设为 10。

2.2.2 预训练阶段超参数设定

预训练阶段需要设定训练批次(Batchsize)、学习率、训练周期(epoch)等超参数。训练批次 Batchsize 表示单次网络传播所用的输入样本量,该参数能够减轻训练的计算负担和参数存储负担,本文设定为 128。Epoch 负责控制网络循环次数,1 个 epoch 表示遍历一遍训练集,本文设定为 100。为了逼近损失函数最小值,实验设定梯度型学习率,1~30 epoch 学习率为 0.001,30~60 epoch 学习率为 0.000 1,60~100 epoch 学习率为 0.000 01,反向传播的优化算法采用耐斯特洛夫随机梯度下降法(Nesterov&SGD)。




图 2 卷积神经网络的网络结构

Fig.2 Network structure of convolutional neural networks

2.2.3 迁移学习

乳液泵的缺陷样本有限,不足以训练出高精度模型,这便需要在训练网络的过程中引入迁移学习。由于低层次的网络提取的是样本的边缘、纹理、颜色等信息,在目标识别领域具有很强的共性,所以迁移学习会提高训练效率和模型准确率。迁移学习原理是将源域模型学习到的参数信息推广到目标域学习。其中,已经训练好的模型称为源域模型,待学习的模型称为目标域模型。本文的源域模型是 Mini-ImageNet 预训练的模型,目标域模型是模型训练阶段的乳液泵缺陷检测模型。其具体步骤如下:首先将目标域模型参数初

始化;然后将网络的初始化参数设定为预训练得到的模型参数;最后定义学习率,微调网络参数,完成模型参数拟合。

2.3 模型训练阶段与测试阶段

模型训练阶段的样本集采用乳液泵的真实样本,本文利用工业 CCD 相机采集样本的 4 个角度,包括泵顶、泵上身、泵下身、尾管。每个角度采集样本 1 000 余张,其中包括训练集、测试集、验证集,每个样本集均含缺陷样本和正常样本,样本如图 3 所示。

2.3.1 图像预处理

图像采集的过程中,CCD 镜头捕获的图像信




图 3 乳液泵 4 个角度的样本图像

Fig.3 Four-angle sample image of the pump

息存在问题如下:(1)初始样本是百万像素级图像,为求清晰度包含大量像素点,加重网络更新参数负担,影响模型的训练效率。(2)采集到的图像信息包含背景干扰,影响深度网络的特征提取速度以及缺陷分类准确率。(3)初始样本不规则,样本图像为 $1\,292 \times 964$ 而网络模型要求图像长宽相同,所以初始样本不能作为数据集直接输入网络进行训练。为解决上述问题,本文设计了图像预处理算法。首先人工切割图像大致区域并进行灰度变换,通过低通滤波器获得图像大致轮廓;然后采用双线差值阈值分割法对图像进行阈值分割,泵顶阈值设为 15,泵上端为 25,泵下段为 30,尾管由于倒插缺陷较明显不需要阈值分割。选取面积最大区域,并生成外接矩形。最后在原始图像上分割外接矩形,获得目标区域图像,利用等间隔采样原理缩小图像,使用 0 填充的方式将图像的尺寸填充为 227×227 。

2.3.2 模型训练阶段超参数设定

与预训练阶段类似,模型训练阶段也需要设定超参数。训练阶段的超参数设定如下:由于模型训练阶段样本量相比于预训练阶段较少,所以训练批次 (Batchsize) 设定为 32,训练周期 (epoch) 设定为 60。学习率仍然设定为梯度渐进型,1~20 epoch 学习率为 0.001,20~40 epoch 学习率为 0.000 1,40~60 epoch 学习率为 0.000 01,优化算法采用耐斯特洛夫随机梯度下降法 (Nesterov&SGD)。

2.3.3 优化算法

本文采用如式(1)所示的对数损失函数。其中 m 值等于参数 Batchsize, y_i 表示第 i 个样本的标签值。 $f(x_i; \theta)$ 表示网络前向传播的预测值。为了表述方便,本文将网络层的权重偏置参数用 θ 表示,通过优化算法优化损失函数,不断更新 θ 值以获得最优模型,本文优化算法采用耐斯特洛夫随机梯度法 (Nesterov&SGD)^[17]。

$$L(f(x_i; \theta), y_i) = \log \sum_{i=0}^m e^{f(x_i; \theta)} - y_i, \quad (1)$$

该算法引入 Nesterov 动量,在随机梯度下降的过程中,通过超前梯度来修正当前的梯度方向。具体算法如下:初始动量 $v=0$,设置动量参数 $\alpha=0.9$,参数临时更新:

$$\tilde{\theta} \leftarrow \theta + \alpha v, \quad (2)$$

获得超前梯度:

$$g \leftarrow \frac{1}{m} \nabla_{\tilde{\theta}} \sum_{i=1}^m L(f(x_i; \tilde{\theta}), y_i), \quad (3)$$

利用动量参数 α 、学习率 ϵ 、超前梯度 g 更新动量 v :

$$v \leftarrow \alpha v - \epsilon g, \quad (4)$$

利用动量 v 更新参数 θ :

$$\theta \leftarrow \theta + v. \quad (5)$$

2.3.4 测试阶段

先将测试样本集通过 2.3.1 节的图像预处理算法获得目标区域,减少原始样本中与缺陷检测无关的冗余信息。再将其依次通过 2.3.3 节中训练阶段的模型,获得模型预测的值;最后将模型预测值与标注的真实值作对比,得到模型最终缺陷检测的准确率。

3 实验结果与分析

本次实验在 Intel Core i7-6700@3.40 GHz, 独立显卡 GTX1080Ti, 内存 8GB 的 GPU 平台上利用深度学习框架 Caffe 完成。以泵顶为例(其余 3 个角度的训练方式与之相同),实验具体步骤如下:

Step1 采集 Mini-ImageNet 数据和泵顶数据,制作预训练阶段数据集和泵顶数据集。

Step2 参照 2.2.1 节构建网络结构 (FC 为 10),并设置超参数,预训练网络。

Step3 利用上文提到的迁移学习的方法对网络进行参数初始化。

Step4 使用图像预处理算法对泵顶的训练集和验证集进行批预处理。

Step5 参照 2.3 节超参数的设定方式,修改网络结构(FC 为 2),重新设定网络超参数。

Step6 卷积神经网络的前向传播和反向传播。采用 Nestorv&SGD 法对其进行优化以更新各网络层的权重和偏置参数。选择验证集精度最高的优化算法,获得缺陷检测模型。

Step7 使用图像预处理算法对泵顶的测试集进行批预处理。再输入至缺陷检测模型中获得预测结果,将其与标签作对比得到泵顶模型缺陷检测的准确率。

图像样本采用泵顶、泵上端、泵下端、尾管等 4 个角度的图像,每个角度采集 1 500 张图像:训练集 750 张,验证集 250 张,测试集 500 张,各样本集的缺陷样本与正常样本的比为 1 : 1。按照上述实验步骤,利用训练集和验证集训练 4 个角度的检测模型,测试集作为算法论证的样本。实

验设定 1 为缺陷样本,2 为正常样本。检测结果如图 4 所示,前四幅图是泵上端、泵顶、泵下端以及尾管的缺陷样本,检测模型对其预测值是 1 的概率远大于 2,能准确的检测出缺陷样本。后两幅图分别是含有注塑点干扰以及嘴部旋转干扰的正常样本,检测模型对其预测是 2 的概率远大于 1,算法能够有效的避免注塑点的干扰和嘴部干扰。

为分析算法预训练阶段的意义,验证迁移学习对网络的优化效果,实验分别比较泵顶、泵上端、泵下端、尾管在迁移学习和无迁移学习训练过程中的验证集准确率和训练周期的曲线图,如图 5 所示。图(a)、图(b)分别是泵上身和泵顶的曲线图,由于图像表面较复杂,缺陷特征不明显,无迁移学习曲线往往在 40 个周期左右才达到收敛,而迁移学习曲线在 5 个周期左右便可收敛,其准确度也高于无迁移学习。图(c)、图(d)表示是泵下身和尾管的曲线,由于缺陷特征较明显,迁移学习作用相对较小,但仍然能加快网络收敛速率,提高网络模型的检测精度。




图 4 乳液泵缺陷检测结果
Fig.4 Result of lotion pump defect detection




图 5 基于迁移学习和无迁移学习的样本验证集准确率和训练周期曲线图
Fig.5 Sample validation set accuracy and training cycle graph based on transfer learning and transfer-free learning

表 1 算法检测准确度

Tab.1 Detection accuracy of the algorithm

算法	泵顶	上端	泵下端	尾管
DBN 重构法	67.8%	67.2%	74.6%	98.8%
LBP+SVM	70.6%	79.8%	92.4%	100.0%
Garbor+KLPP+MLP	83.8%	85.2%	91.6%	99.2%
本文方法	93.4%	95.2%	97.6%	100.0%

表 2 算法检测用时

Tab.2 Detection time of the algorithm

(s)

算法	泵顶	泵上端	泵下端	尾管
DBN 重构法	30.62	27.53	26.42	26.09
LBP+sVM	5.76	4.56	4.01	3.97
Garbor+KLPP+MLP	7.68	7.21	6.94	6.67
本文方法	2.52	2.13	1.98	1.87

在相同的实验条件下,实验对比了本算法与 3 种传统算法的缺陷识别效果。由于在工业生产过程中要求乳液泵缺陷检测的准确率和速率,所以对比指标设为测试集的准确度和单个样本的检测速率,分别如表 1、表 2 所示。其中 DBN(Deep Belief Nets)重构法利用样本集训练 DBN 网络以构建一个模板,再通过比较测试样本与模板的差异度最终验证样本是否存在缺陷。LBP(Local Binary Pattern)+SVM(Support Vector Machine),在训练过程中先提取样本的 LBP 特征,再结合 SVM 分类器训练缺陷检测模型以实现缺陷检测。Garbor+KLPP(Kernel locality preserving projections, KLPP)+MLP(Multi-layer perception)与上面方法类似,将样本进行 Gabor 变换并提取均值和方差特征,并使用 KLPP 法将特征进行降维,再输入至多层感知机(MLP)中训练分类器,实现缺陷乳液泵的检测。

由表 1、表 2 结果可以看出,由于受到泵嘴旋转和泵体注塑点的影响,泵上端和泵顶检测准确率会小于泵下端和尾管的准确率。由于乳液泵 4 个角度是一个整体,所以本文选择 4 个角度最低的准确率和最长的用时。基于 LBP+SVM 的方法准确率为 70.6%,单样本的检测时间为 5.76 s;基于 Garbor+KLPP+MLP 的方法准确率为 83.8%,单样本的检测时间为 7.68 s;基于 DBN 重构法准确率 67.8%,单样本的检测时间为 30.62 s;本文算法准

确率为 93.4%,单样本的检测时间为 2.52 s。由上述数据可以看出,本文算法在检测准确率和检测用时上明显优于其他算法。

4 结 论

本文将深度学习原理应用于工业乳液泵缺陷样本的检测,研究泵顶、泵上端、泵下端、尾管等样本的 4 个角度缺陷检测算法,最终能够排除泵顶嘴部旋转以及泵体随机注塑点的干扰,精确检测出有缺陷的乳液泵样本。本文搭建了 14 层卷积神经网络结构,为解决工业生产过程中缺陷样本不足问题,基于迁移学习原理采用 Mini-ImageNet 数据集预训练网络。然后根据不同角度样本图像的特性设计预处理算法,对图像进行预处理,提取乳液泵样本的目标区域。调整全连接层结构,再利用预处理后的乳液泵样本对网络进行训练,调整网络参数,生成缺陷检测模型。最后,利用测试集评估检测模型,验证模型的检测准确率和单位样本检测用时。网络训练均在深度学习框架 Caffe 中完成,本文算法最终检测准确率如下:泵顶 93.4%,泵上端 95.2%,泵下端 97.6%,尾管 100%,在缺陷检测准确率和单位样本检测用时方面均优于其他 3 个方法。同时,本文的方法可扩展到工业生产过程中其他物件的缺陷检测。

参 考 文 献:

- [1] 吴秀永, 徐科, 徐金梧. 基于 Gabor 小波和核保局投影算法的表面缺陷自动识别方法[J]. 自动化学报, 2010, 36(3):438-441.
WU X Y, XU K, XU J W. Automatic recognition method of surface defects based on gabor wavelet and kernel locality preserving projections [J]. *Acta Automatica Sinica*, 2010, 36(3):438-441. (in Chinese)
- [2] LIU Y, CHEN S, TANGT, *et al.* Defect inspection of medicine vials using LBP features and SVM classifier [C]// *Image, Vision and Computing (ICIVC)*, 2017 2nd International Conference on. IEEE, 2017: 41-45.
- [3] 周文辉, 宋晓莉, 程玉华. 基于小波钝化的嵌入式图像处理算法研究[J]. 液晶与显示, 2016, 31(11):1085-1091.
ZHOU W H, SONG X L, CHENG Y H. Embedded image processing algorithm based on wavelet passivation [J]. *Chinese Journal of Liquid Crystals & Displays*, 2016, 31(11):1085-1091. (in Chinese)
- [4] 常亮, 邓小明, 周明全, 等. 图像理解中的卷积神经网络[J]. 自动化学报, 2016, 42(9):1300-1312.
CHANG L, DENG X M, ZHOU M Q, *et al.* Automatic recognition method of surface defects based on gabor wavelet and Kernel locality preserving projections [J]. *Acta Automatica Sinica*, 2010, 36(3):438-441. (in Chinese)
- [5] HINTONG E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313(5786): 504-507.
- [6] CHEN C, SEFF A, KORNHAUSERA, *et al.* Deep driving: learning affordance for direct perception in autonomous driving [C]// *IEEE International Conference on Computer Vision*. IEEE, 2015:2722-2730.
- [7] ZHANG S, YAO L, SUN A. Deep learning based recommender system: A survey and new perspectives [J]. *arXiv preprint, arXiv:1707.07435*, 2017.
- [8] HINTON G, DENG L, YU D, *et al.* Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups [J]. *IEEE Signal Processing Magazine*, 2012, 29(6):82-97.
- [9] 余永维, 杜柳青, 曾翠兰, 等. 基于深度学习特征匹配的铸件微小缺陷自动定位方法[J]. 仪器仪表学报, 2016, 37(6):1364-1370.
YU Y W, DU L Q, ZENG C L, *et al.* Automatic localization method of small casting defect based on deep learning feature [J]. *Chinese Journal of Scientific Instrument*, 2016, 37(6):1364-1370. (in Chinese)
- [10] 王宪保, 李洁, 姚明海, 等. 基于深度学习的太阳能电池片表面缺陷检测方法[J]. 模式识别与人工智能, 2014, 27(6):517-523.
WANG X B, LI J, YAO M H, *et al.* Solar cells surface defects detection based on deep learning [J]. *Pattern Recognition & Artificial Intelligence*, 2014, 27(6):517-523. (in Chinese)
- [11] 周筑博, 高佼, 张巍, 等. 基于深度卷积神经网络的输电线路可见光图像目标检测[J]. 液晶与显示, 2018, 33(4): 317-325.
ZHOU Z B, GAO J, ZHANG W, *et al.* Object detection of transmission line visual images based on deep convolutional neural network [J]. *Chinese Journal of Liquid Crystals & Displays*, 2018, 33(4): 317-325. (in Chinese)
- [12] JIA Y, SHELHAMER E, DONAHUE J, *et al.* Caffe: Convolutional Architecture for Fast Feature Embedding [C]// *Acm International Conference on Multimedia*. ACM, 2014:675-678.
- [13] YOSINSKI J, CLUNE J, BENGIO Y, *et al.* How transferable are features in deep neural networks? [C]// *Advances in neural information processing systems*. 2014: 3320-3328.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]// *International Conference on Neural Information Processing Systems*. Curran Associates Inc. 2012: 1097-1105.
- [15] HINTON G E, OSINDERO S, TEHY W. A fast learning algorithm for deep belief nets [J]. *Neural Computation*, 2006, 18(7):1527-1554.
- [16] DENG J, DONG W, Socher R, *et al.* ImageNet: A large-scale hierarchical image database [C]// *Computer Vision and Pattern Recognition*, Miami, USA: IEEE, 2009:248-255.

- [17] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep Learning [M]. Cambridge:MIT Press, 2016;290-297.

作者简介:



马浩鹏(1994—),男,黑龙江大庆人,硕士研究生,2016 年于西南石油大学获得学士学位,主要从事深度学习及机器视觉方面的研究。E-mail: mhp8338@qq.com



朱春媚(1981—),女,广东河源人,硕士,讲师,2006 年于华南理工大学获硕士学位,主要研究方向为模式识别和智能算法。E-mail: cmzhu@zsc.edu.cn