

基于卷积神经网络的数码印花缺陷分类算法

苏泽斌*, 高敏, 李鹏飞, 景军锋, 张缓缓

西安工程大学电子信息学院, 陕西 西安 710048

摘要 针对应用深度学习检测数码印花缺陷需准确分类的问题, 提出了基于卷积神经网络(CNN)的数码印花缺陷分类算法。该方法首先依次对图像进行 RGB 颜色空间直方图均衡化、高斯滤波、局部均值分辨率调整的图像预处理, 提升输入网络的图像质量, 并进行图像几何变换的数据增强, 扩充样本数据集; 然后, 设计拓扑结构为 2 个卷积层、2 个池化层、2 个全连接层的 CNN 网络对样本进行训练, 得出最优的数码印花缺陷分类 CNN 模型。经 600 张测试样本验证, 结果表明, 该算法对各类数码印花缺陷的分类准确率均超过 90.0%, 多分类任务 Kappa 系数值为 0.94, 能实现数码印花缺陷的准确分类。

关键词 图像处理; 卷积神经网络; 缺陷分类; 数码印花

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP57.241011

Digital Printing Defect Classification Algorithm Based on Convolutional Neural Network

Su Zebin*, Gao Min, Li Pengfei, Jing Junfeng, Zhang Huanhuan

College of Electrics and Information, Xi'an Polytechnic University, Xi'an, Shaanxi 710048, China

Abstract To accurately classify digital printing defects with deep learning, we propose a digital printing defect classification algorithm based on convolutional neural network (CNN). Firstly, this method performs image preprocessing of RGB color space histogram equalization, Gaussian filtering, and local mean resolution adjustment in sequence to improve the image quality of the input network. Meanwhile, the sample data set is expanded by geometrically transforming the image. Then, the topology of CNN network is designed with 2 convolutional layers, 2 pooling layers, and 2 fully connected layers, which is the optimized CNN model of digital printing defect classification. Finally, the model is verified by 600 test samples. Experimental results show that the classification accuracy of proposed algorithm for all types of digital printing defects reaches above 90.0%, and the Kappa coefficient value of multi-classification task is 0.94. The proposed method can accurately classify digital printing defects.

Key words image processing; convolution neural network; defect classification; digital printing

OCIS codes 100.4996; 150.1835

1 引言

针对当前重视个性化、快响应、高环保的市场需求, 数码印花技术在纺织品印花领域具有广阔的发展前景^[1]。数码印花工业生产中会因为喷头堵塞、漏墨、电机自控偏差、布匹褶皱等故障, 导致喷墨印花纺织品出现 PASS 道、漏墨、喷墨不均以及布匹褶皱等缺陷, 严重影响印花成品的质量和价格^[2]。

因此, 数码印花缺陷检测是印花纺织品质量控制的重要环节, 对印花缺陷进行准确分类, 可有针对性地指导工业生产, 提升数码印花产品质量。

早期纺织品缺陷分类方法以人工为主, 该方法存在主观性, 且分类成本高、效率低^[3-4]。近年来, 机器视觉技术已广泛应用在织物缺陷检测与分类领域^[5]。Jeyaraj 等^[6]提出基于机器视觉的纺织品缺陷检测系统, 该方法应用卷积神经网络(CNN)学习

收稿日期: 2020-04-27; 修回日期: 2020-06-01; 录用日期: 2020-06-09

基金项目: 陕西省重点研发计划(2019ZDLGY01-08)、陕西省教育厅科研计划(18JK0339)

*E-mail: suzebin@xpu.edu.cn

织物的颜色特征实现织物缺陷的分类,但在实际应用中,当目标区域周围邻域颜色特征相近时,该方法的分类精度较低。卓东等^[7]提出基于卷积神经网络的短切毡缺陷分类方法,该方法设计 CNN 提取织物缺陷特征,使用迁移学习思想优化短切毡缺陷分类算法。Mottalib 等^[8]提出一种使用贝叶斯分类器提取织物几何特征的纺织品疵点分类方法。赵鹏等^[9]提出改进 AlexNet 的无纺布缺陷分类方法,该方法通过对 AlexNet 网络增加归一化处理 and 卷积层数优化模型分类效果。景军锋等^[10]提出采用深度卷积神经网络实现色织物缺陷分类的方法。该方法利用色织物纹理特征建立 CNN,并进行样本训练得到映射函数,实现对色织物缺陷的有效分类。可以看出,这些缺陷分类方法主要针对白坯布、净色布、纹理单一的色织物以及专色印花纺织品,包括断纱、破洞、结头、油污、色差等缺陷均有较好的分类效果。而数码印花产品纹理结构复杂、色泽图案丰富^[11],目前还没有较为成熟的缺陷分类方法。

基于以上背景,本文设计了一种基于 CNN 的数码印花缺陷分类算法,可以实现针对数码印花 PASS 道、漏墨、喷墨不均、布匹褶皱等 4 类缺陷的有效分

类。该方法首先对印花图像进行预处理,制作训练样本;然后,通过设计的 CNN 模型学习缺陷特征和分类标签之间的映射关系;最后,用训练好的最优模型实现数码印花缺陷的准确分类。将本文算法与现有的 LeNet-5、AlexNet、VGG16 以及 GoogLeNet 等 CNN 模型进行对比^[12-15],结果显示,本文算法的多分类任务 Kappa 系数最高,并且模型训练和测试时间最短。

2 相关基础工作

2.1 印花图像缺陷特征分析

数码印花技术是将印制图案输入计算机进行像素级分色处理,利用孔径微米级的喷头,进行固定方向的往复叠印喷绘,形成预期高精度印花图像。因此,数码印花会由于喷孔堵塞、电机步进偏差、喷墨气压不稳定、喷头出墨调试不均匀、设备压布不平整等故障,导致印花产品出现 PASS 道、漏墨、喷墨不均以及布匹褶皱等缺陷。图 1 展示了部分数码印花缺陷样例,可以看出,数码印花缺陷按照其外观形状可划分为狭窄线状缺陷、点状缺陷、面状缺陷以及条状缺陷。表 1 对比了不同数码印花缺陷的形成原因、外观形状以及出现概率等特征。

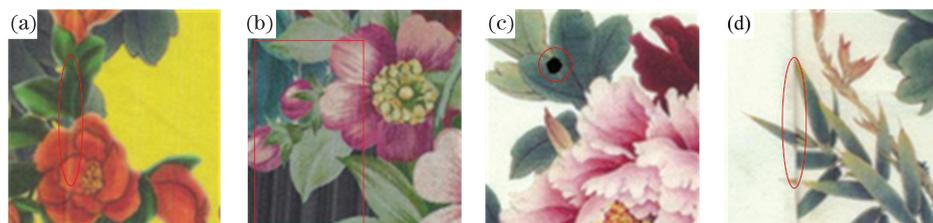


图 1 数码印花缺陷样例。(a) PASS 道;(b)喷墨不均;(c)漏墨;(d)布匹褶皱

Fig. 1 Examples of digital printing defects. (a) PASS tracks; (b) uneven inkjet; (c) ink leakage; (d) fabric wrinkles

表 1 数码印花缺陷特征对比

Table 1 Comparison of defect features in digital printing

Type of defect	Cause of formation	Appearance shape	Probability of occurrence
PASS tracks	Nozzle clogging, motor step deviation	Narrow linear	High
Uneven inkjet	Uneven inkjet output debugging	Flat	Low
Ink leakage	Inkjet pressure instability	Dotted	Medium
Fabric wrinkles	Uneven cloth press	Strip	Low

2.2 印花缺陷图像预处理

本文使用 Canon Scanner 9000F 扫描仪获取工业生产中的数码印花缺陷,而数字图像在其获取、传输以及处理过程中通常会受到多种噪声的干扰。因此,本文首先对印花图像依次进行 RGB 颜色空间直方图均衡化、高斯滤波图像平滑、局部均值法分辨率调整以及图像几何变换的数据增强等图像预处理,提升输入 CNN 的图像质量,并扩充样

本集。

2.2.1 基于 RGB 颜色空间的直方图均衡化

数码印花缺陷与邻域的背景纹理对比度相当接近,其中,以 PASS 道和布匹褶皱缺陷尤为明显。为了提升分类算法的准确性,需要对印花图像进行增强,提高图像全局对比度。基于 RGB 色彩空间的直方图均衡化原理是分别在彩色图像的 R、G、B 各分量分别进行灰度直方图均衡化,然后再将三个分量合

并,得到对比度增强的印花图像。图2为RGB颜色空间直方图均衡化后印花样本处理结果,图中印花图

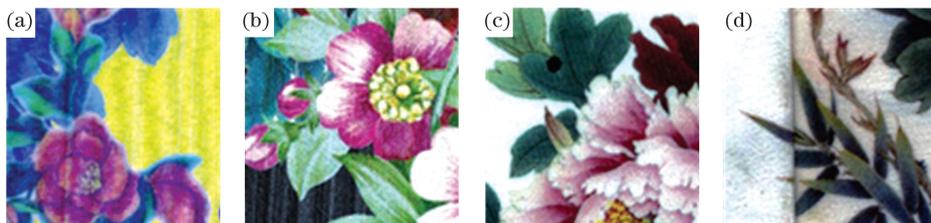


图2 RGB颜色空间直方图均衡化处理结果。(a) PASS道;(b)喷墨不均;(c)漏墨;(d)布匹褶皱

Fig. 2 RGB color space histogram equalization processing results. (a) PASS tracks; (b) uneven inkjet; (c) ink leakage; (d) fabric wrinkles

2.2.2 基于高斯滤波的图像平滑

印花图像在数字化处理过程中,会引入较多的随机噪声,为了进行高层次的缺陷特征提取,需要对图像做平滑处理。高斯滤波器定义距离掩模中心较近的像素权重较高,因此其平滑效果较为柔

和,可以较好地保留图像边缘、轮廓等细节信息。图3展示了对印花图像进行高斯滤波的处理结果,可以看出,图像噪声抑制明显,缺陷位置的图像局部对比度得到了进一步增强。

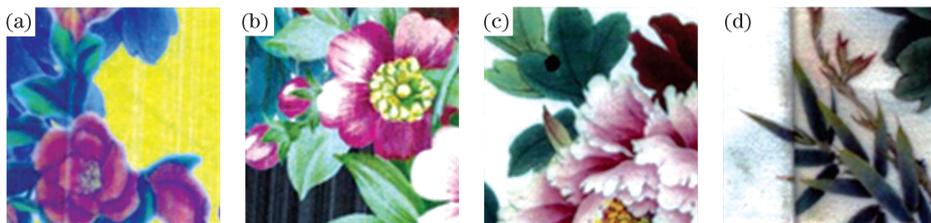


图3 高斯滤波处理结果。(a) PASS道;(b)喷墨不均;(c)漏墨;(d)布匹褶皱

Fig. 3 Gaussian filtering processing results. (a) PASS tracks; (b) uneven inkjet; (c) ink leakage; (d) fabric wrinkles

2.2.3 基于局部均值法的图像分辨率调整

为了完整展现印花图案信息,同时降低CNN输入图像尺寸,采用局部均值法进行图像分辨率调整。其原理是在掩模确定的邻域内,采用邻域像素的平均灰度值代替中心像素灰度。图4展示

了算法处理结果,通过对图像进行局部放大可以看出,对图像采用局部均值法下采样后,印花图案信息得以完整表达的同时纺织品织物纹理得到平滑,进一步提升了输入网络的图像质量,减小了图像尺寸。

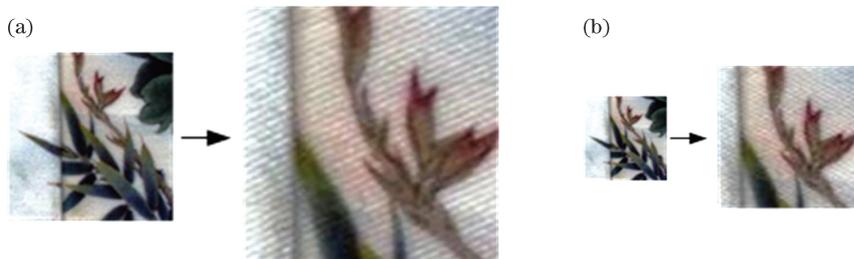


图4 局部均值法的图像分辨率调整结果。(a)分辨率调整前;(b)分辨率调整后

Fig. 4 Adjustment results of image resolution based on local mean algorithm. (a) Before resolution adjustment; (b) after resolution adjustment

2.2.4 基于图像几何变换的数据增强

深度学习样本越丰富,模型的泛化能力就越强。目前采用的保留标签生成数据增强集是较为有效的数据扩充方法。考虑到尽可能地保留具有丰富颜色信息和空间信息特性的数码印花图案,本

文选择垂直翻转、左右镜像、旋转 90° 、 180° 和 270° 的方法进行数据增强,使得具有特定标签的数码印花缺陷样本较原来扩充5倍。图5展示了印花图像数据增强结果,可以看出,翻转等几何变换不会改变图像大小,本文选用针对输入尺寸固定的网络,故

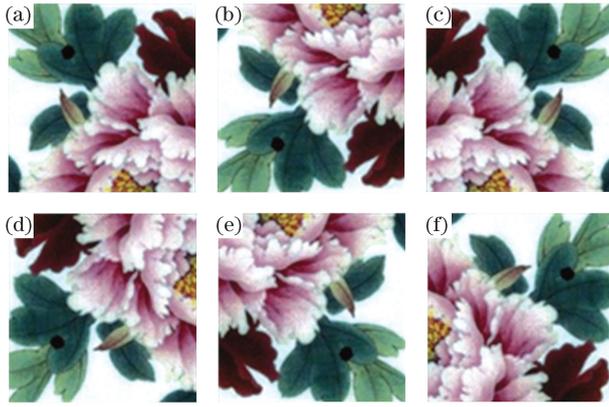


图 5 图像数据增强结果。(a)原图;(b)垂直翻转;(c)水平镜像;(d)旋转 90°;(e)旋转 180°;(f)旋转 270°

Fig. 5 Image data enhancement results. (a) Original image; (b) flip vertically; (c) horizontal mirroring; (d) rotate 90°; (e) rotate 180°; (f) rotate 270°

未进行图像剪裁和缩放等操作。

3 基于 CNN 的数码印花缺陷分类算法

3.1 分类算法流程设计

基于 CNN 的数码印花缺陷分类算法流程如图 6 所示。首先,采集的数码印花缺陷样本随机裁剪后,经过上述图像预处理制作样本集;然后,针对数码印花缺陷特征,设计特定的 CNN 分类模型,包

括 CNN 拓扑结构设计、分类器选取、目标函数和优化算法寻优等步骤;最后,通过随机选取的测试样本,采用训练得到的最优 CNN 分类模型测试算法的性能。

3.2 CNN 网络拓扑结构设计

典型的 CNN 网络(如 LeNet、AlexNet、VGGNet、GoogLeNet 等)通过增加网络深度来提取高层次语义信息,在大目标分类任务中具有较高的

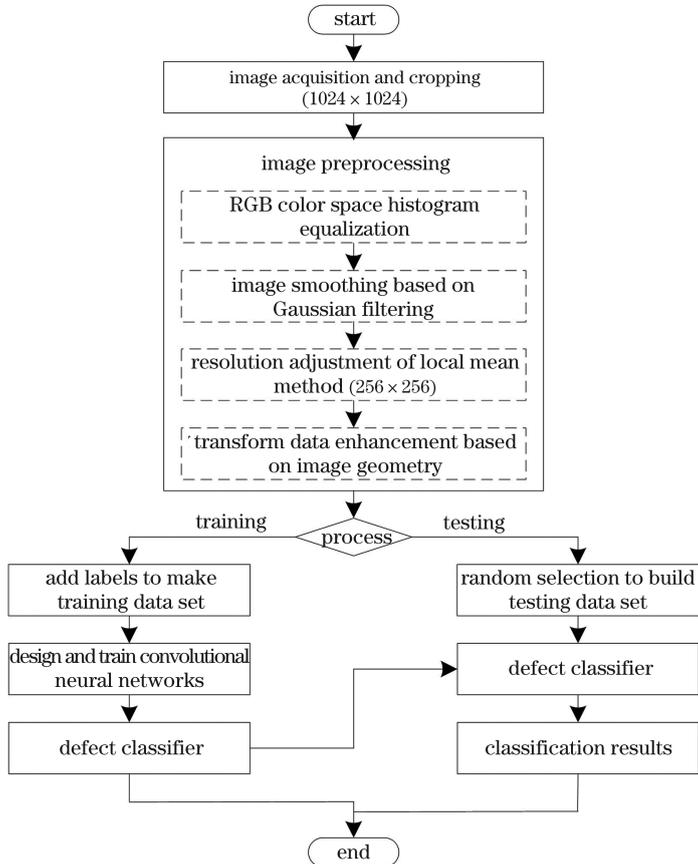


图 6 分类算法流程图

Fig. 6 Flow chart of classification algorithm

准确率。对于数码印花 PASS 道、漏墨、布匹褶皱等小目标缺陷,提取高层次特征导致图像的分辨率减小,丢失了很多细节信息,加之池化层的存在,降低了小目标语义信息,因此深度 CNN 网络分类小目标缺陷的准确率有所降低,而且网络结构越深,模型计算复杂度越大。综合考虑数码印花缺陷小目标特性和网络运算性能等因素,本节设计如图 7 所示的 CNN 拓扑结构。

从图 7 可以看出,CNN 由 2 个卷积层、2 个池化层和 2 个全连接层组成。首先将数码印花图像输入至第 1 卷积层 C1,卷积层过滤器尺寸为 3×3 ,深

度为 64,使用全 0 填充,步长为 1,故该卷积层输出为 64 个 256×256 大小的特征图。再经过池化层 S2,池化层过滤器为 3×3 ,使用全 0 填充,步长为 2,故该池化层输出 $128 \times 128 \times 64$ 矩阵。接着进入第 2 个卷积层 C3,卷积层过滤器尺寸为 3×3 ,深度为 16,使用全 0 填充,步长为 1,故该卷积层形成 16 个 128×128 大小的特征图。再经过池化层 S4,池化层过滤器为 3×3 ,使用全 0 填充,步长为 1,故该池化层输出 $128 \times 128 \times 16$ 矩阵。第 5 层和第 6 层为全连接层,神经元个数分别为 128 和 128。最后一层为分类输出层。

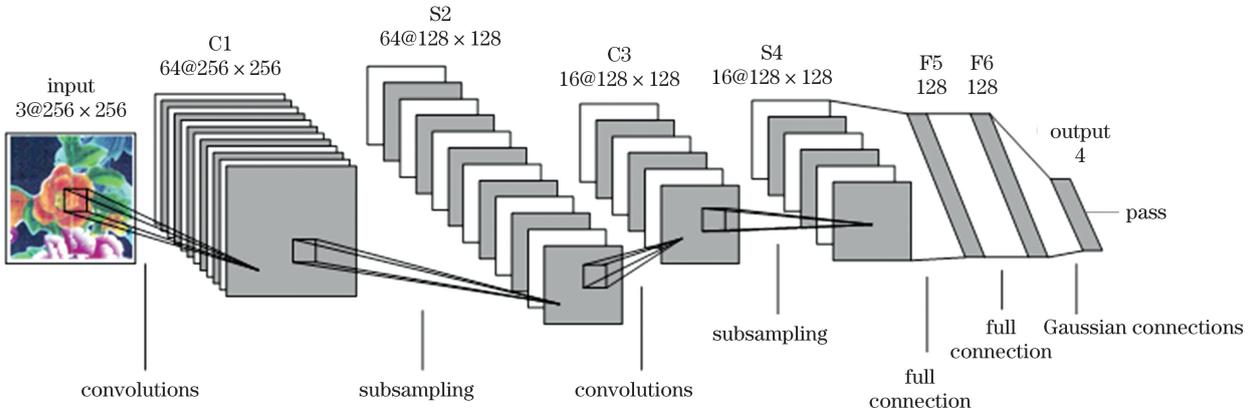


图 7 卷积神经网络拓扑结构

Fig. 7 Topological structure of convolutional neural network

卷积神经网络以图片的形式作为输入,卷积是在图像每个位置进行线性变换映射成新值,提取数据的某一简单特征。多层卷积逐层进行映射,可以提取图像更为复杂的抽象特征,卷积后通过激活函数得到特征映射。多层卷积操作的过程可表示为

$$g(i) = f\left(\sum_{x=1}^n \sum_{y=1}^n \sum_{z=1}^m a_{x,y,z} \times w_{x,y,z}^i + b^i\right), \quad (1)$$

式中: $a_{x,y,z}$ 表示过滤器中输入节点 (x,y,z) 的取值; $w_{x,y,z}^i$ 表示过滤器输入节点 (x,y,z) 的权重; b^i 表示输出节点对应的偏置项参数; $f(\cdot)$ 表示激活函数; n 表示过滤器的长宽尺寸; m 表示过滤器深度。

池化层是对图像特征进行下采样,主要用于特征降维,在保留有效信息的同时压缩数据处理量,有效减小过拟合,提高模型容错性^[16]。对输入的特征图,通过池化操作获得新的输出特征。

$$X_j^{i+1} = \text{down}(X_j^i) + b_j^{i+1}, \quad (2)$$

式中: $\text{down}(\cdot)$ 表示图像特征下采样方式,一般可以在过滤器确定的邻域内像素选择最大池化或平均池化; b_j^{i+1} 表示偏置项参数。本文卷积神经网络池化层,采用最大池化图像特征下采样方法。

在 CNN 池化操作后引入批量归一化(BN)层^[17-18]。BN 层将池化输出的数据进行归一化处理,规范输入下一层的数据服从方差为 1、均值为 0 的标准正态分布,避免网络训练时出现梯度消失问题,加快网络收敛的同时增强模型泛化能力。算法原理如下:设 CNN 池化层输出结果为 $X = x_1, x_2, \dots, x_m$, 则批量归一化输出 $\{y_i = \text{BN}_{\gamma,\beta}(x_i)\}$ 计算过程如下:

1) 计算上一层 CNN 池化层输出数据的均值 μ_β ,

$$\mu_\beta = \frac{1}{m} \sum_{i=1}^m (x_i), \quad (3)$$

式中: m 是训练样本 batch 的大小。

2) 计算上一层 CNN 池化层输出数据的标准差 σ_β^2 ,

$$\sigma_\beta^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_\beta)^2. \quad (4)$$

3) 归一化处理,得到 \hat{x}_i ,

$$\hat{x}_i = \frac{x_i + \mu_\beta}{\sqrt{\sigma_\beta^2 + \epsilon}}, \quad (5)$$

式中: ϵ 是为了避免分母为 0 而加进去的接近于 0

的很小值。

4)对经过上述步骤归一化处理得到的数据进行重构得到输出 y_i ,

$$y_i = \gamma \hat{x}_i + \beta, \quad (6)$$

式中: γ, β 为可学习参数。

3.3 分类器的选择

Softmax 回归模型是 Logistics 回归模型在多元分类问题上的推广,其引入 Softmax 代价函数将 x 分类为类别 j 的概率,表示为

$$p(y^{(i)} = j | x^{(i)}; \theta) = \frac{\exp[\theta_j^T x^{(i)}]}{\sum_{i=1}^k \exp[\theta_i^T x^{(i)}]}, \quad (7)$$

式中: θ 表示输入 x 经卷积神经网络计算后的输出值; T 表示分类的类别总数。由(1)式可以看出,Softmax 回归可以有效减小远离分类平面的点的权重,相对增加与分类最相关的数据点的权重。且经 Softmax 运算后可以更方便地与离散标签计算误

差,有利于离散值模型的预测和训练,故本文选择 Softmax 分类器。

4 实验结果与分析

4.1 制作数据集

扫描仪获取的原始样本尺寸为 5100×7014 ,水平和垂直分辨率为 600×600 dpi(dot per inch)。通过对样本中存在缺陷的部位进行裁剪,得到 PASS 道、漏墨、喷墨不均以及布匹褶皱 4 类常见缺陷,裁剪后图像大小为 1024×1024 ,每类缺陷有 100 张。经图像预处理后图像大小调整为 256×256 ,水平和垂直分辨率为 96×96 dpi(dot per inch),并经数据增强将每类缺陷扩增至 600 张,共 2400 张样本图片。图 8 展示了数据集中部分缺陷样例。实验采用 TFRecord 格式构建图像数据集。TFRecord 文件以二进制存储数据,适合用串行的方式读取大批量的数据。图像标签采用二进制独热编码格式。



图 8 数码印花缺陷数据集样本。(a)~(d) PASS 道;(e)~(h)喷墨不均;(i)~(l)漏墨;(m)~(p)布匹褶皱

Fig. 8 Samples of digital printing defect data set. (a)~(d) PASS tracks; (e)~(h) uneven inkjet; (i)~(l) ink leakage; (m)~(p) fabric wrinkles

4.2 模型训练与优化

针对数码印花缺陷分类模型的训练,实验硬件配置为 CPU Intel (R) Core (TM) i5-8400 2.80 GHz, GPU NVIDIA GeForce GTX 2080 Ti,

内存为 16 G,硬盘为 1 TB, Windows10 操作系统。采用 Matlab R2018b 软件完成印花图像预处理。模型训练使用 Python 语言、TensorFlow 深度学习框架、Spyder 4.0.0rc1 集成开发环境、第三方函数库

Anaconda3.4.1完成。训练时随机从数据集每类印花图像中抽取150张作为测试集,其余450张作为训练集。网络训练共迭代50000次,期间每迭代100次将当前训练的模型保存一次,训练结束后用测试集验证最终模型分类效果。

本文通过对数码印花缺陷图像进行预处理,设计了拓扑结构为2个卷积层、2个池化层和2个全连接层的CNN分类网络,然后采取不同目标函数对CNN进行分类准确率验证,结果如表2所示。经与分类交叉熵、二元交叉熵、均方损失、铰链损失以及接收器工作特性(ROC)曲线下面积(AUC)分数等目标函数比较可知,Softmax交叉熵分类准确率最高,为98.14%。之后采取不同优化算法对CNN进行分类准确率验证,结果如表3所示。经与随机梯度下降算法、前向均方根梯度下降算法、动量梯度下降算法以及自适应次梯度算法等优化算法比较可知,采用自适应矩估计(Adam)优化算法分类准确率最高,为98.21%。

表2 不同目标函数对应的分类准确率

Table 2 Classification accuracy corresponding to different objective functions

Objective function	Accuracy/%
Softmax cross entropy	98.14
Classification cross entropy	96.42
Binary cross entropy	81.29
Mean square loss	88.02
Hinge loss	74.92
ROC AUC score	77.33

表3 不同优化函数对应的分类准确率

Table 3 Classification accuracy corresponding to different optimization algorithms

Optimization	Accuracy/%
Adaptive moment estimation	98.21
Stochastic gradient descent	74.84
Root mean square propagation	65.38
Momentum gradient descent	92.73
Adaptive sub-gradient method	81.67

表4 每类缺陷分类性能指标

Table 4 Performance index of each defect classification

Defect classification	Performance /%										Average accuracy /%	Standard deviation
	1	2	3	4	5	6	7	8	9	10		
Validation set	98.17	98.53	96.33	95.00	98.33	96.17	95.61	98.41	95.27	96.18	96.80	0.0133
Test set												
PASS tracks	92	94	89	95	85	93	86	90	88	91	90.30	0.0316
Uneven inkjet	94	98	97	96	91	89	92	92	93	90	93.20	0.0286
Ink leakage	98	100	93	97	94	95	100	98	96	97	96.80	0.0223
Fabric wrinkles	100	93	96	95	98	96	97	94	95	94	95.80	0.0199

综上所述,本文选择以Softmax交叉熵作为评估网络分类效果的目标函数,以Adam算法作为网络梯度优化算法的CNN分类模型。由于CNN训练时迭代次数直接影响训练模型的优化程度,故统计模型训练过程中迭代50000次的总损失率,结果如图9所示。从图9可以看出,模型训练的总损失率随着迭代次数的递增总体呈下降趋势,并在30000次迭代时,曲线逐渐收敛至最小值且接近于0,此时训练模型达到最优,因此本文综合考虑模型检测准确率、效率等因素,选择取迭代次数为30000时训练的CNN模型,进行数码印花缺陷分类测试。

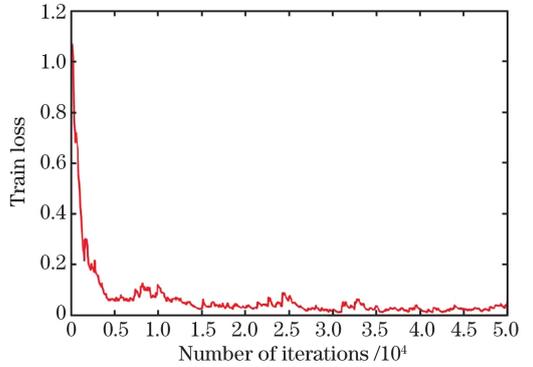


图9 总损失率曲线

Fig. 9 Total loss rate curve

4.3 测试结果与分析

为了验证该模型针对每一类缺陷的分类效果,采用留出法对数据集进行10次交叉验证。表4统计了每类印花缺陷验证集和测试集的分类准确率和标准差,可以看出,针对PASS道、漏墨、喷墨不均以及布匹褶皱4类缺陷,均有超过90%的分类准确率。横向对比4类缺陷分类结果,PASS道缺陷检测准确率的标准差最高为0.0316。其中,由于PASS道缺陷呈狭窄突变线状,特征相较于其他种类缺陷在复杂印花背景纹理中不明显,使得该缺陷检测准确率较低。

为了验证不同网络模型对数码印花缺陷分类的性能,将本文设计的 CNN 与 LeNet-5、AlexNet、VGG16 以及 GoogLeNet 模型进行对比实验。采用 Kappa 系数评估数码印花缺陷多分类任务的准确度^[19]。Kappa 系数取值越高,则表明模型多分类准确度越高。统计上述 5 种 CNN 模型的分 Kappa 系数值,结果如图 10 所示。可以看出,随着网络深度逐渐加深,采用高层次特征描述数码印花 PASS 道等小目标缺陷,语义信息的丢失会引起分类准确率逐渐降低。而本文设计的 CNN 网络预测 Kappa 系数值最大为 0.94,数码印花缺陷分类准确率最高。

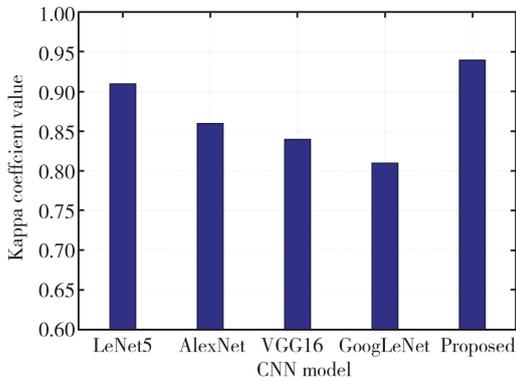


图 10 不同 CNN 模型预测 Kappa 系数值

Fig. 10 Kappa coefficient value predicted by different CNN models

为了评估不同模型的运算效率,表 5 展示了不同 CNN 分类模型的训练用时,以及在 GPU 下运行每张样本的平均测试时间,可以看出,本文提出的 CNN 模型层数少,网络参数简单,故训练和测试用时最短分别为 65 min 和 10 ms。

表 5 不同 CNN 模型训练和测试用时

Table 5 Training and testing time of different CNN models

CNN model	LeNet5	AlexNet	VGG16	GoogLeNet	Proposed
Training/min	76	92	114	136	65
Testing/ms	15	64	153	124	10

5 结 论

本文提出了一种基于卷积神经网络的数码印花缺陷检测算法,有效解决了现有算法针对数码印花产品缺陷分类检测不足的问题。该算法对印花样本进行预处理,提升输入网络的图像质量;根据数码印花小目标缺陷特性,设计特定的 CNN 拓扑结构;通过实验确定最优的分类模型参数。实验结果表明,相较于现有的网络,本文算法在数码印花缺陷分类准确率和高效性方面都具有明显优势。下一

步研究重点是将本文数码印花缺陷分类算法扩展至缺陷检测领域,以定位产品存在缺陷的具体位置。

参 考 文 献

- [1] Li M, Zhao Y, Zhang L P, et al. Factors influencing printing accuracy of digital printing for knitted polyester fabric [J]. Journal of Textile Research, 2018, 39(5): 62-66.
李敏, 赵影, 张丽平, 等. 涤纶针织物数码印花清晰度的影响因素 [J]. 纺织学报, 2018, 39(5): 62-66.
- [2] Deng X. Development of defects detection algorithms for digital textile printing based on embedded GPU [D]. Hangzhou: Zhejiang University, 2018: 14-16.
邓新. 基于嵌入式 GPU 的数码印花缺陷检测算法研发 [D]. 杭州: 浙江大学, 2018: 14-16.
- [3] Ren H H, Jing J F, Zhang H H, et al. Cross-printing defect detection of printed fabric using GIS and FTDT [J]. Laser & Optoelectronics Progress, 2019, 56(13): 131005.
任欢欢, 景军锋, 张缓缓, 等. 应用 GIS 和 FTDT 的织物错花缺陷检测研究 [J]. 激光与光电子学进展, 2019, 56(13): 131005.
- [4] Wang C Y, Jing J F, Zhang H H, et al. Defect detection of yarn-dyed fabric based on rolling guide filtering and FT saliency [J]. Cotton Textile Technology, 2019, 47(6): 28-33.
王晨煜, 景军锋, 张缓缓, 等. 基于滚动引导滤波与 FT 算法的色织物疵点检测 [J]. 棉纺织技术, 2019, 47(6): 28-33.
- [5] Lu R S, Wu A, Zhang T D, et al. Review on automated optical (visual) inspection and its applications in defect detection [J]. Acta Optica Sinica, 2018, 38(8): 0815002.
卢荣胜, 吴昂, 张腾达, 等. 自动光学(视觉)检测技术及其在缺陷检测中的应用综述 [J]. 光学学报, 2018, 38(8): 0815002.
- [6] Jeyaraj P R, Nadar E R S. Computer vision for automatic detection and classification of fabric defect employing deep learning algorithm [J]. International Journal of Clothing Science and Technology, 2019, 31(4): 510-521.
- [7] Zhuo D, Jing J F, Zhang H H, et al. Classification of chopped strand mat defects based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(10): 101009.
卓东, 景军锋, 张缓缓, 等. 基于卷积神经网络的短切毡缺陷分类 [J]. 激光与光电子学进展, 2019, 56(10): 101009.

- [8] Mottalib M M, Rokonzaman M, Habib M T, et al. Fabric defect classification with geometric features using Bayesian classifier [C] // 2015 International Conference on Advances in Electrical Engineering (ICAEE), December 17-19, 2015, Dhaka, Bangladesh. New York: IEEE Press, 2015: 137-140.
- [9] Zhao P, Tang Y J, Yang M, et al. Application of convolutional neural network in classification and detection of non-woven fabric defects [J]. Packaging Engineering, 2020, 41(5): 192-196.
赵鹏, 唐英杰, 杨牧, 等. 卷积神经网络在无纺织缺陷分类检测中的应用 [J]. 包装工程, 2020, 41(5): 192-196.
- [10] Jing J F, Fan X T, Li P F, et al. Yarn-dyed fabric defect detection based on deep-convolutional neural network [J]. Journal of Textile Research, 2017, 38(2): 68-74.
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.
- [11] Wang Q, Song L Y, Wang Y Q, et al. Design and application of digital printing in silk garments [J]. China Textile Leader, 2019(3): 82-85.
王巧, 宋柳叶, 王伊千, 等. 数码印花图案及其在丝绸服装设计中的应用路径 [J]. 纺织导报, 2019(3): 82-85.
- [12] Li Y, Lin X Z, Jiang M Y. Facial expression recognition with cross-connect LeNet-5 network [J]. Acta Automatica Sinica, 2018, 44(1): 176-182.
李勇, 林小竹, 蒋梦莹. 基于跨连接 LeNet-5 网络的面部表情识别 [J]. 自动化学报, 2018, 44(1): 176-182.
- [13] Wang R, Xu J W, Han T X. Object instance detection with pruned AlexNet and extended training data [J]. Signal Processing: Image Communication, 2019, 70: 145-156.
- [14] Swasono D I, Tjandrasa H, Fathicah C. Classification of tobacco leaf pests using VGG16 transfer learning [C] // 2019 12th International Conference on Information & Communication Technology and System (ICTS), July 18-18, 2019, Surabaya, Indonesia. New York: IEEE Press, 2019: 176-181.
- [15] Zhang H W, Zhang L J, Li P F, et al. Pattern classification of yarn-dyed fabrics based on GoogLeNet [J]. Progress in Textile Science & Technology, 2017(7): 33-35, 52.
张宏伟, 张凌婕, 李鹏飞, 等. 基于 GoogLeNet 的色织物花型分类 [J]. 纺织科技进展, 2017(7): 33-35, 52.
- [16] Ma J C, Zhao H D, Yang D X, et al. Design and optimization of deep convolutional neural network for aircraft target classification [J]. Laser & Optoelectronics Progress, 2019, 56(23): 231006.
马俊成, 赵红东, 杨东旭, 等. 飞机目标分类的深度卷积神经网络设计优化 [J]. 激光与光电子学进展, 2019, 56(23): 231006.
- [17] Tan G H, Hou J, Han Y P, et al. Low-parameter real-time image segmentation algorithm based on convolutional neural network [J]. Laser & Optoelectronics Progress, 2019, 56(9): 091003.
谭光鸿, 侯进, 韩雁鹏, 等. 基于卷积神经网络的低参数量实时图像分割算法 [J]. 激光与光电子学进展, 2019, 56(9): 091003.
- [18] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-03-02) [2020-04-27]. <https://arxiv.org/abs/1502.03167>.
- [19] Tu B, Yang X C, Li N Y, et al. Hyperspectral image classification via superpixel correlation coefficient representation [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(11): 4113-4127.