

基于空间注意力多尺度特征融合的 织物缺陷分类算法

宋智勇, 潘海鹏*

浙江理工大学机械与自动控制学院, 浙江 杭州 310018

摘要 针对织物表面纹理复杂以及缺陷类型多样易混淆导致缺陷分类精度低的问题,设计了一种基于空间注意力多尺度特征融合的织物表面缺陷分类算法。使用多尺度金字塔池化模块保持特征图信息完整,同时将从高层特征图提取到的丰富语义信息作为先验信息指导底层特征,实现高低层特征的融合;将改进的空间注意力模块融合到卷积神经网络中,增强特征差异性表达;通过改进的类激活映射方法获取缺陷分类信息和位置信息。在数据增强和迁移学习方法的基础上对织物表面缺陷图像进行识别检测。实验结果表明,所提算法可以有效提高织物缺陷分类的准确率,同时可以在没有人工位置标注的情况下获得缺陷的位置信息。

关键词 图像处理; 卷积神经网络; 空间注意力; 多尺度融合; 缺陷检测

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.1010005

Fabric Defect Classification Algorithm Based on Multi-Scale Feature Fusion of Spatial Attention

Song Zhiyong, Pan Haipeng*

School of Mechanical and Automatic Control, Zhejiang Sci-Tech University, Hangzhou 310018, Zhejiang, China

Abstract A fabric surface defect classification technique based on spatial attention multiscale feature fusion is designed to address the problem of low-classification accuracy caused by complex texture and varied defect kinds of the fabric surface. The multiscale pyramid pooling module is used to maintain the information integrity of the feature map, and the rich semantic information extracted from the high-level feature map is used as a priori information to guide the low-level features, realizing the fusion of high-level and low-level features; the improved spatial attention module is integrated into a convolutional neural network to enhance the differential expression of features. The improved class activation mapping method is used to obtain the defect classification information and location information. The fabric surface defect image is recognized and detected using data augmentation and transfer learning methods. The experimental results show that the proposed algorithm can effectively increase the accuracy of fabric defect classification and obtain defect location information without manual location labeling.

Key words image processing; convolutional neural network; spatial attention; multi-scale fusion; defect detection

1 引言

纺织行业是经济产业的重要组成部分,织物表

面缺陷的存在影响了纺织品的质量,使得产品价格大幅度下降,严重影响企业效益。随着织物缺陷的日益多样化,设计一种高效高精度的织物缺陷检测

收稿日期: 2021-04-14; 修回日期: 2021-05-08; 录用日期: 2021-05-18

通信作者: *pan13989896598@163.com

算法成为一个亟待解决的问题。传统方法采用人工目测的方式对织物缺陷进行检测,这种方式对经验要求较高,工作效率低,存在漏检情况。织物缺陷自动检测替代人工检测方法能够提供更加稳定、客观的性能,因此采用智能化、自动化的方法解决缺陷检测问题成为大势所趋。

自动缺陷检测技术可以笼统地分为基于传统机器视觉图像处理的方法与基于卷积神经网络的深度学习方法。传统的机器视觉图像处理方法依据图像处理方式的不同可以分为基于统计^[1-2]、频谱^[3-4]、模型^[5-6]、结构^[7]和字典学习^[8-9]的方法。然而这些方法依赖于手工设计的特征,对纹理背景变化敏感,受到用户手工设置参数的影响,只适用于检测特定产品种类,且复杂度高,不适用于变化的工业环境,泛化性能较差。深度学习方法因强大的自动提取特征能力成为研究主流,在织物缺陷检测中取得了广泛的应用^[10-12]。Anh等^[13]使用了深层卷积神经网络 VGG16 和 Darknet 对织物缺陷进行分类。Gao等^[14]研究了织物缺陷检测问题,将织物检测问题视为一个二值分类问题,提出了一种包含多层卷积和池化层的卷积神经网络,总体检测准确率达 96.52%。Jeyaraj等^[15]利用基于 ResNet512 的卷积神经网络来学习织物的深层特征并成功地对织物缺陷进行分类。文献^[16]提出了一种基于人工神经网络的缺陷分类方法。Jing等^[17]提出了一种基于改进 AlexNet 结构的卷积神经网络,用于彩色织物缺陷检测。史甜甜^[18]将深度可分离卷积与 Fisher 准则约束相结合对周期性图案缺陷进行检测。

本文针对深度学习应用在复杂纹理织物缺陷检测中存在的问题,提出了基于空间注意力多尺度特征融合的织物缺陷分类算法,通过空间注意力与多尺度特征融合模块相结合,进一步提高了织物缺陷检测的准确率。

2 相关理论

2.1 迁移学习

迁移学习^[19]将已经在源域训练好的模型迁移到目标中进行学习,通过迁移学习技术与卷积神经网络的结合可以有效地解决样本数据不足的问题,有效地提高模型的泛化能力。基于迁移学习的特征迁移方法可以分为特征提取和微调。特征提取将卷积神经网络冻结为固定的特征抽取器,只重新训练分类输出层。微调是另一种应用迁移学习的

方式,具体步骤为首先选择一个在源域训练过的模型,从这个预训练模型开始改变一些模型的架构,然后根据自己的数据集训练调整整个模型的参数。

2.2 空洞卷积

卷积神经网络通过多层卷积和池化层进行下采样操作,获取图像的高层抽象信息,在下采样这个过程中虽然扩大了感受野,但是由于图像分辨率的不断下降,还是不可避免地造成图像的局部细节信息损失,对分类准确率造成影响。空洞卷积^[20]为了解决这个问题,引入了一个表示卷积核扩张大小的新参数——扩张率,与普通的卷积相比,虽然卷积核大小没有发生变化,但是大大地增加了感受野,因此也被称为扩张卷积。空洞卷积的优势在于在不通过池化操作的情况下通过内部扩张结构获得较大的感受野。

2.3 注意力概述

注意力机制模型的目的是让系统学会从大量信息中把注意力放在感兴趣或者高价值的地方。循环神经网络首先开始应用注意力模型,现在已经成功地应用于各种任务,包括机器翻译、物体识别等,获得了非常好的性能提升。

2.4 类别激活映射

卷积神经网络在图像分类任务中表现出良好的性能,最后的高层特征映射图中包含了丰富的语义信息,如何可视化内部特征以及对卷积神经网络分类决策进行良好的解释是一个困难的问题。Zhou等^[21]发现卷积神经网络不仅有良好的分类能力,而且还具有定位能力,然而这些定位能力在将特征映射图送入全连接层后就丢失了,为了保留空间信息,使用全局平均池化操作来计算每个特征图的空间平均值并将其作为全连接的输入进行分类。针对某一类别,将训练得到的特征权重与最后一层卷积操作得到的特征图加权并累加求和,即可得到该类别激活热图,这种方法称为类别激活映射(CAM)。CAM 的计算为:定义 $f_k(x, y)$ 为最终的卷积层特征图在空间位置 (x, y) 处的激活,则在执行全局平均池化后的输出可表示为 $F_k = \sum_{x, y} f_k(x, y)$ 。对于类别 C 来说,全连接层激活值也即 Softmax 层的输入值记为 $y_c = \sum_k w_k^c F_k$,其中 w_k^c 为特征图第 k 通道的权重,表示了第 k 通道特征图对分类结果为 C 的重要性。通过引入全局平均池化操作,将权重 w_k^c 与特征图相乘,得到类别 C 的类别激活图 $F_{(x, y)}^C = \sum_k w_k^c f_k(x, y)$ 。

3 所提算法内容

设计的织物缺陷检测模型是基于 ResNet50 网

络结构进行改进的,改进后的结构如图 1 所示,包括缺陷的自动分类阶段和定位阶段。

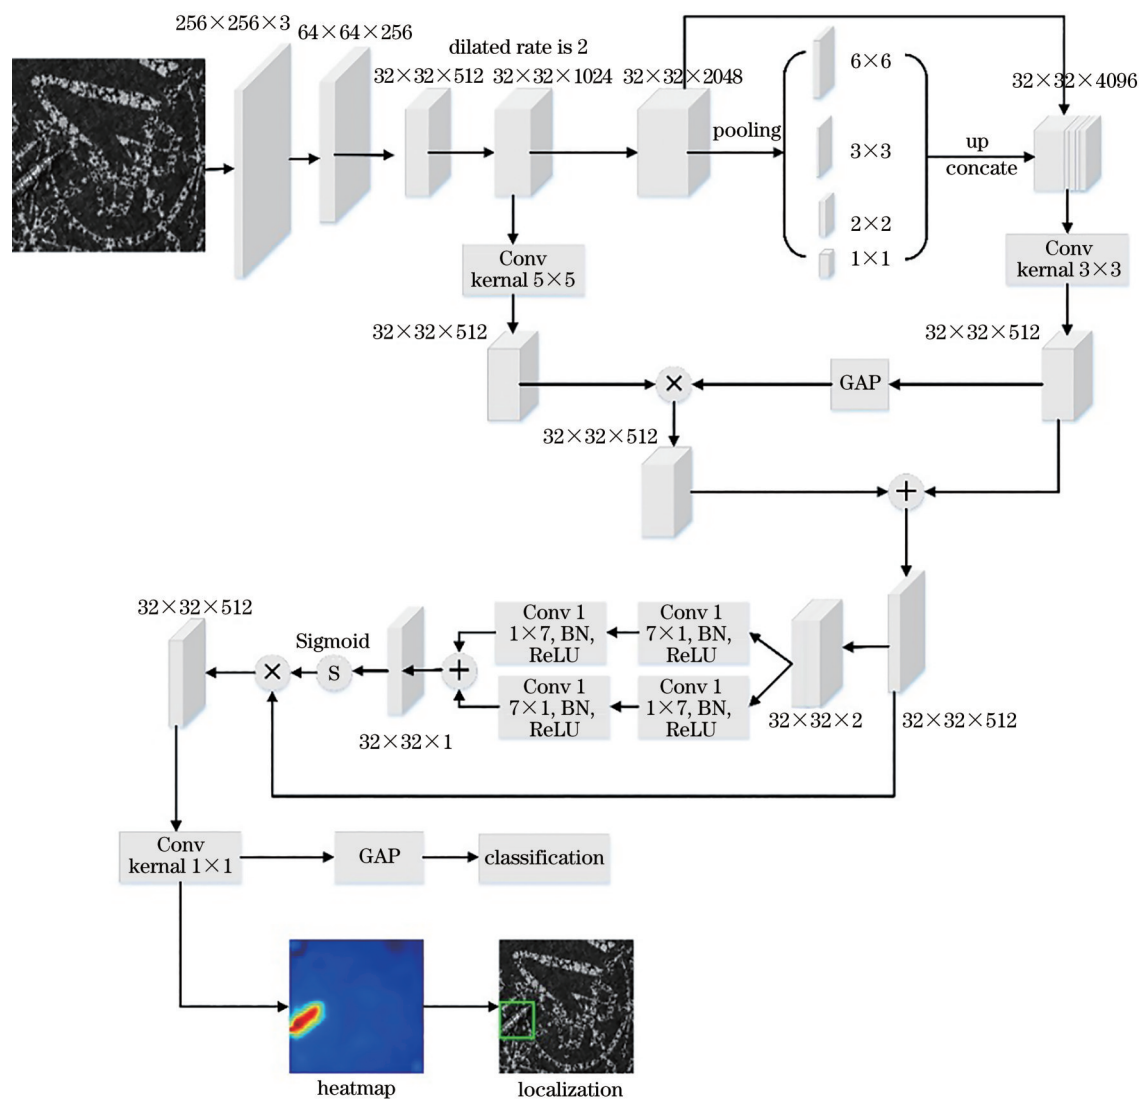


图 1 整体网络结构

Fig. 1 Overall network structure

3.1 分类阶段

输入图像首先经特征提取阶段进行处理,对于特征提取部分,对 ResNet50 网络的最后两个阶段进行改进。layer4 和 layer5 的下采样率变为 1,网络整体的下采样率由原始的 1/32 变为 1/8;为了保持相同的感受野,在 layer4 卷积过程中使用了扩张率为 2 的空洞卷积;在网络特征提取阶段 layer5 的最后输出部分,建立了一个空间注意力多尺度特征融合模块。空间注意力多尺度特征融合模块包括多尺度特征融合模块和空间注意力模块。多尺度特征融合模块包含两部分。首先在最后一层的输出后使

用金字塔池化模块将特征图划分为多个区域,每个区域中的像素都可以看为全局表示,包含 1×1, 2×2, 3×3, 6×6 这四种不同尺寸的池化操作;通过四种不同尺寸的池化操作得到四个尺寸的特征图,通过双线性插值对这些特征图进行上采样,对不同级别的特征进行通道级联合融合特征,作为最后的金字塔池化全局特性,融合不同区域的上下文信息。然后将提取到的高层聚合特征图信息通过全局池化操作处理,结果作为全局指导信息;对经过 5×5 卷积的 layer4 特征图进行加权,通过一个残差结构实现高低层特征融合。将融合后的多尺度特征图送

入空间注意力模块,使得网络更加集中于特征的位置信息。

改进的空间注意力模块如图 1 的下半部分所示。输入特征图 F 在通道维度上分别经平均池化层 (AvgPool) 和最大池化层 (MaxPool), 作用是对 F 进行通道维度的压缩。对于得到的两个一维通道特征图 $F_{\text{avg}} \in \mathbf{R}^{H \times W \times 1}$ 和 $F_{\text{max}} \in \mathbf{R}^{H \times W \times 1}$, 通过通道级联聚合两个一维通道特征图的信息, 此时通道变为 2。为了提取多尺度位置信息, 增加感受野, 使用对称分离卷积的形式将大小为 32×32 的卷积核的通道维度变为 1, 此时得到了大小为 $H \times W \times 1$ 的特征图。然后, 使用激活函数 Sigmoid 得到该特征图的空间注意力权重矩阵 $M_s(F) \in \mathbf{R}^{H \times W \times 1}$, 将此权重矩阵与输入特征 F 进行矩阵乘法运算, 得到含有空间位置信息的空间注意力模块输出特征图。

3.2 定位阶段

利用改进的类激活映射方法得到原始输入图像的热图, 具体地说, 将最后的全连接层换成 1×1 卷积层, 并将其移动到全局平均池化前, 此时权重矩阵为 $w^{\text{Conv}} = \mathbf{R}^{K \times C}$, 1×1 卷积输出的特征图就是类别映射特征图, 类别 C 的激活映射图为

$$F_C^{\text{Conv}} = \sum_K w_{K,C}^{\text{Conv}} F, \quad (1)$$

式中: K 是特征图数量。

通过插入 1×1 卷积输出的类别映射特征图为

热值图, 为了获取准确的缺陷位置信息, 首先要对输出的热力图进行分割, 即通过阈值分割算法变为二值图像。实验发现, 阈值分割方法可以通过缺陷类型和缺陷在整个图像中的分布来确定。大津法 (OTSU) 通过使待分割的缺陷部分与织物图像纹理背景类间方差最大来确定织物图像二值化分割的阈值, 避免了手工获取阈值, 计算也比较简单。因此针对所研究的织物数据集样本缺陷分布形式, 选择 OTSU 进行阈值分割, 然后通过连通区域法定位缺陷。

4 实验结果与分析

4.1 织物图像数据库与数据增强

所用织物缺陷样本图像均来源于德国汉堡-哈尔堡工业大学 TILDA 织物数据集。TILDA 织物数据集包含 4 个文件夹, 选择的是印花织物数据集, 如图 2 所示, 包含正常、破洞、油污、刮擦、线头、褶皱 6 种类别的图像。原始数据集的样本图片大小为 $768 \text{ pixel} \times 512 \text{ pixel}$ 。由于从织物数据集获取的原始训练样本数据量有限, 为了满足深度学习对大数据量的要求以及考虑到获取织物缺陷图像时受到相机、照明以及噪声等因素的影响, 在训练数据集之前, 使用深度学习 imgaug 的 Python 库对图像样本进行了数据增强处理。数据增强方法如下: 随机旋转、镜像翻转、噪声扰动、图像模糊、图像锐化、亮度变化。




图 2 印花织物数据集织物缺陷类型

Fig. 2 Fabric defect types of printed fabric data set

4.2 模型训练策略与参数设置

首先将 TILDA 织物数据库中 6 个类别的图像

按照 6:4 随机划分训练集和测试集, 输入训练集图像, 将输入图像下采样为 $256 \text{ pixel} \times 256 \text{ pixel}$ 的图

片,对下采样的图片进行数据增强操作扩充训练样本。通过迁移学习的微调方法,将 ResNet50 模型的预训练参数迁移到所搭建的织物缺陷分类模型。训练前需要先人工配置卷积神经网络的超参数,包括子训练集大小、学习率和训练时间等,超参数设置如表 1 所示。将选定的训练集分成若干小批量进行训练,采用 Adam 优化算法和误差反向传播法进行模型参数优化,直到损失函数的值达到最小值。印花织物训练过程的准确率曲线和损

表 1 超参数设置
Table 1 Super parameter setting

Parameter	Value
Learning rate	0.0001
Batch size	5
Epoch	50
Image dimension	256×256×1

失曲线如图 3 所示,损失不断下降,说明网络训练正常。




图 3 印花织物训练过程。(a)精确率曲线;(b)损失曲线
Fig. 3 Training process of printed fabric. (a) Accuracy curve; (b) loss curve

4.3 评价指标

通过设计卷积神经网络模型分类检测织物缺陷图像,在图像分类任务中,分类模型将输入的图像样本预测为置信度最高的类,当已知图像样本的实际标签时可以对分类结果与实际值进行关联比较,分类模型混淆矩阵就是这样一种非常直观的方法,通过可视化分类模型预测结果来表征模型性能。根据分类结果是否正确,可以确定 TP、TN、FP 和 FN。TP 表示实际为正样本,分类结果也为正样本;TN 表示实际为负样本,分类结果也为负样本;FP 表示实际为负样本,而错误分为正样本;FN 表示实际样本为正样本,而预测结果为负样本。为了更加全面地衡量分类模型的性能,通过混淆矩阵引入更加高级的如准确率(accuracy)、精确率(precision)、召回率(recall)、特异性(specificity)分类指标对不同方法进行评价。

$$P_{accuracy} = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{TN} + N_{FP} + N_{FN}}, \quad (2)$$

$$P_{precision} = \frac{N_{TP}}{N_{TP} + N_{FP}}, \quad (3)$$

$$P_{recall} = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (4)$$

$$P_{specificity} = \frac{N_{TN}}{N_{FP} + N_{TN}}. \quad (5)$$

4.4 实验结果分析

对印花织物测试集进行测试的分类结果以混淆矩阵的形式展示,如图 4 所示,可以很容易地看到模型具有很高的分类准确率。

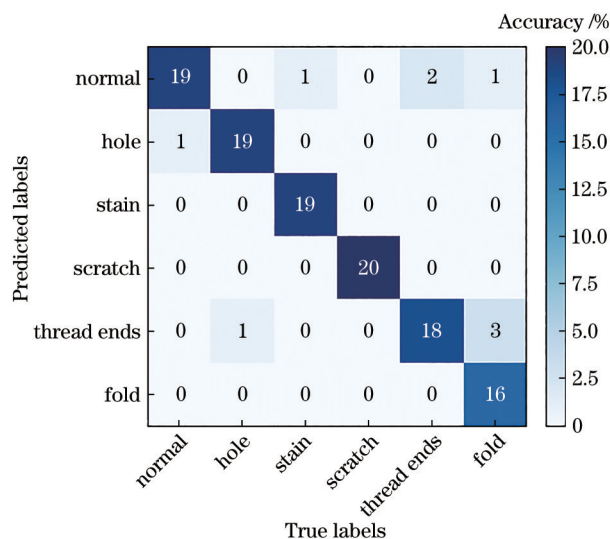


图 4 混淆矩阵
Fig. 4 Confusion matrix

表 2 给出了印花织物每一类别缺陷检测的性能指标。在训练集和测试集的比例相同的情况下,对所提模型与其他神经网络进行了比较,结果如表 3 所示。从实验结果可以看出:传统的深度学习方

表 2 印花织物每一类别缺陷检测指标

Table 2 Defect detection index of each type of printed fabric

Defect type	Precision / %	Recall / %	Specificity / %
Normal	82.61	95.00	96.00
Hole	95	95.00	99.00
Stain	100	95.00	100.00
Scratch	100	100.00	100.00
Thread ends	81.82	90.00	96.00
Fold	100	80.00	100.00
Average	93.23	92.5	98.5

在印花织物缺陷分类上表现不佳,仅有 56.67% 和 65.00% 的准确率;相比较而言,所提方法在每一类缺陷中都表现出较高的准确率,同时在与其它深度

表 3 所提算法与其他算法的结果比较

Table 3 Result comparison between proposed algorithm and other algorithms

Algorithm	Precision / %	Recall / %	Specificity / %	Accuracy / %
VGG16	57.33	56.67	91.33	56.67
ResNet50	49.93	65	93	65
Proposed algorithm	93.23	92.5	98.5	92.5

学习模型的对比中所有性能指标都具有最大值,表明所提方法具有最好的分类性能。

印花织物缺陷定位效果如图 5 所示。

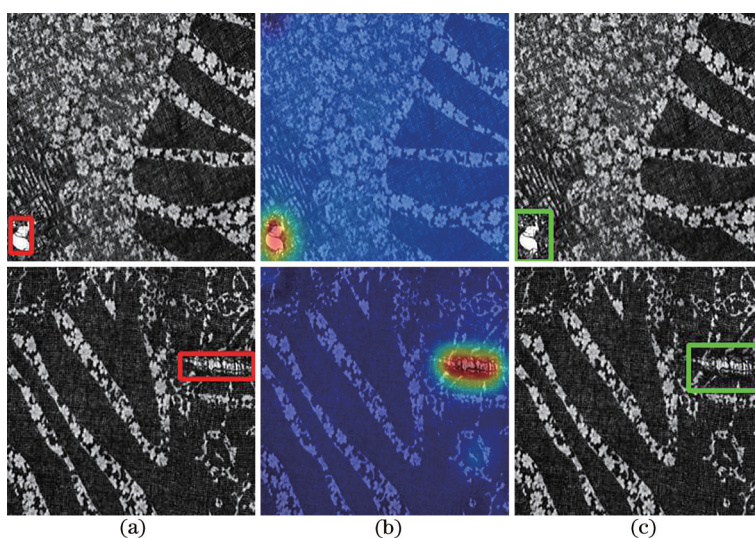


图 5 印花织物的定位效果。(a)原图;(b)热力图;(c)定位结果

Fig. 5 Positioning effect of printed fabric. (a) Original picture; (b) heatmap; (c) location result

实验结果所示,在复杂纹理织物表面缺陷检测任务中,传统深度神经网络 VGG16 和 ResNet50 对印花织物的检测表现不佳。相比较而言,所提模型对印花织物的缺陷检测获得了更好的检测效果,同时还可额外地提供缺陷的位置信息,因此所提模型对织物表面缺陷的检测具有很强的适用性。

5 结 论

提出了一种基于空间注意力多尺度特征融合的织物表面缺陷分类算法。通过改进空间注意力与多尺度特征融合相结合的方法,获取全局多尺度信息,同时增强了特征差异性;为了解决卷积神经网络中小数据集训练带来的过度拟合问题,使用迁移学习微调与数据增强结合的方法对深度学习模型进行训练,并用包括正常、破洞、油污、刮擦、线头

和褶皱 6 类织物图像进行了测试。实验结果表明,所提模型在复杂纹理织物缺陷分类方面具有良好的性能,分类的同时可以进一步地获取缺陷的位置信息。未来将致力于获得高分类准确率的同时获得更加精确的位置信息。

参 考 文 献

- [1] Kaynar O, Işık Y E, Görmez Y, et al. Fabric defect detection with LBP-GLMC[C]//2017 International Artificial Intelligence and Data Processing Symposium (IDAP), September 16-17, 2017, Malatya, Turkey. New York: IEEE Press, 2017: 17333828.
- [2] Hu J J, He Z Y, Weng G R, et al. Detection of chemical fabric defects on the basis of morphological processing[J]. The Journal of the Textile Institute, 2016, 107(2): 233-241.

- [3] Jing J F, Chen S, Li P. Automatic defect detection of patterned fabric via combining the optimal Gabor filter and golden image subtraction[J]. *Journal of Fiber Bioengineering and Informatics*, 2018, 8(2): 229-239.
- [4] Harinath D, Babu K R, Satyanarayana P, et al. Defect detection in fabric using wavelet transform and genetic algorithm[J]. *Transactions on Machine Learning and Artificial Intelligence*, 2015, 3(6): 10.
- [5] Zhang Y, Jiang G M, Yao J Z, et al. Intelligent segmentation of jacquard warp-knitted fabric using a multiresolution Markov random field with adaptive weighting in the wavelet domain[J]. *Textile Research Journal*, 2014, 84(1): 28-39.
- [6] 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 M, Cui S Q, Xie Z P. Application of Gaussian mixture model on defect detection of print fabric[J]. *Journal of Textile Research*, 2015, 36(8): 94-98.
- [7] Jia L, Chen C, Liang J Z, et al. Fabric defect inspection based on lattice segmentation and Gabor filtering[J]. *Neurocomputing*, 2017, 238: 84-102.
- [8] Qu T, Zou L, Zhang Q L, et al. Defect detection on the fabric with complex texture via dual-scale over-complete dictionary[J]. *The Journal of the Textile Institute*, 2016, 107(6): 743-756.
- [9] Tsang C S C, Ngan H Y T, Pang G K H. Fabric inspection based on the Elo rating method[J]. *Pattern Recognition*, 2016, 51: 378-394.
- [10] 赵志勇, 叶林, 桑红石, 等. 深度学习在布匹缺陷检测中的应用[J]. *国外电子测量技术*, 2019, 38(8): 110-116.
Zhao Z Y, Ye L, Sang H S, et al. Application of deep learning in fabric defect detection[J]. *Foreign Electronic Measurement Technology*, 2019, 38(8): 110-116.
- [11] 苏泽斌, 高敏, 李鹏飞, 等. 基于卷积神经网络的数码印花缺陷分类算法[J]. *激光与光电子学进展*, 2020, 57(24): 241011.
Su Z B, Gao M, Li P F, et al. Digital printing defect classification algorithm based on convolutional neural network[J]. *Laser & Optoelectronics Progress*, 2020, 57(24): 241011.
- [12] 周君, 景军锋, 张缓缓, 等. 基于 S-YOLOV3 模型的织物实时缺陷检测算法[J]. *激光与光电子学进展*, 2020, 57(16): 161001.
Zhou J, Jing J F, Zhang H H, et al. Real-time fabric defect detection algorithm based on S-YOLOV3 model[J]. *Laser & Optoelectronics Progress*, 2020, 57(16): 161001.
- [13] Anh N T H, Giao B C. An empirical study on fabric defect classification using deep network models[M]// Dang T K, Küng J, Takizawa M, et al. *Future data and security engineering. Lecture notes in computer science*. Cham: Springer, 2019, 11814: 739-746.
- [14] Gao C, Zhou J, Wong W K, et al. Woven fabric defect detection based on convolutional neural network for binary classification[M]// Wong W K. *Artificial intelligence on fashion and textiles. Advances in intelligent systems and computing*. Cham: Springer, 2018, 849: 307-313.
- [15] 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.
- [16] Das S, Wahi A, Sundaramurthy S, et al. Classification of knitted fabric defect detection using artificial neural networks[C]// 2019 International Conference on Advances in Computing and Communication Engineering (ICACCE), April 4-6, 2019, Sathyamangalam, India. New York: IEEE Press, 2019: 19575238.
- [17] Jing J F, Ma H, Zhang H H. Automatic fabric defect detection using a deep convolutional neural network[J]. *Coloration Technology*, 2019, 135(3): 213-223.
- [18] 史甜甜. 基于 Fisher 准则的深层卷积神经网络织物疵点检测[J]. *计算机系统应用*, 2019, 28(3): 140-145.
Shi T T. Deep convolutional neural network fabric defect detection based on Fisher criterion[J]. *Computer Systems & Applications*, 2019, 28(3): 140-145.
- [19] 富雅捷, 张宏立. 基于迁移学习的卷积神经网络森林火灾检测方法[J]. *激光与光电子学进展*, 2020, 57(4): 041010.
Fu Y J, Zhang H L. Forest fire detection method based on transfer learning of convolutional neural network[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041010.
- [20] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB/OL]. (2015-11-23)[2021-05-01]. <http://arxiv.org/abs/1511.07122>.
- [21] Zhou B L, Khosla A, Lapedriza A, et al. Learning deep features for discriminative localization[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2921-2929.