

DOI:10.19651/j.cnki.emt.2106000

基于 GoogleNet 网络与残差网络的织物纹理分析

邓宇平 王桂棠

(广东工业大学 机电工程学院 广州 510006)

摘要: 针对目前织物自动开幅设备无法准确识别复杂织物纹理背景下的开幅引导线的问题,设计了一种基于迁移学习的 GoogleNet 网络与非迁移学习的残差网络的织物纹理特性分类系统。所使用的样本数据集分为密集型花纹等 7 种纹理特性,共计 1 543 张图,随机选取 80% 的图片作为训练集,剩余 20% 图片作为测试集。两种不同的卷积神经网络在现有的数据集中达到了 100% 的识别准确率,并且在后续的系统测试中,新增了 300 张样品,最终系统的识别准确率达到了 98%。实验结果表明,将 GoogleNet 网络与残差网络应用于织物纹理特性的分析与分类切实可行,以此为算法基础构建的系统具有实用价值。

关键词: 纹理特性分析;迁移学习;GoogLeNet;残差网络

中图分类号: TP23;TP274 文献标识码: A 国家标准学科分类代码: 510.8060

Fabric texture analysis based on GoogleNet network and residual network

Deng Yuping Wang Guitang

(School of Electromechanical Engineering, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Aiming at the problem that the current fabric automatic opener can't accurately identify the opener guide line under the complex fabric texture background, this paper designs a fabric texture feature classification system based on GoogleNet network of transfer learning and residual network of nontransfer learning. The sample data set is divided into seven texture characteristics, such as dense pattern, a total of 1 543 images, randomly selected 80% of the images as the training set, the remaining 20% of the images as the test set. Two different convolutional neural networks achieve 100% recognition accuracy in the existing data set, and in the subsequent system test, 300 samples are added, and the final recognition accuracy of the system reaches 98%. The experimental results show that the application of GoogleNet network and residual network to the analysis and classification of fabric texture characteristics is feasible, and the system based on this algorithm has practical value.

Keywords: texture feature analysis; transfer learning; GoogleNet; residual network

0 引言

智能制造的高端化、智能化、绿色化、服务化是产业先进水平的体现^[1]。在纺织领域内,我国智能化起步较晚,纺织行业仍旧是劳动密集型行业。以自动开幅设备为例,国内尚未有成熟稳定的产品进入市场。国外的产品除了价格昂贵之外,对复杂纹理的织物也不能准确识别开幅引导线。因此,自动开幅设备目前仍未在行业普遍应用,亟需新技术和新产品研发。阻碍自动开幅设备研发与应用的主要原因是织物复杂的纹理特性使得设备不具有普适性,不能满足绝大多数织物自动识别的需求。现如今,开幅引导线识别的主要方式依旧是光电式检测,其原理是利用开幅引导线与其背景透光的差异性,从而判断开幅引导线的位置^[2-3]。

这种方法在识别对象为素色或纹理较为简单的织物时,准确率有足够的保障。但是复杂的纹理特性(颜色、密度、花纹)成为准确识别的关键因素和技术瓶颈。因此本文的目标是构建一个织物纹理特性分析和分类系统,在开幅引导线识别之前,完成对织物纹理的分类,为后续进行针对性纹理滤除以及织物引导线识别提供一个良好的基础。

织物纹理的分析目前采用的方式主要分为基于光谱以及频谱两种。薛乐等^[4]研究基于频谱图对机织物的纹理进行分析,得出了经纬向频率与织物纹理特性的关系。裘柯槟等^[5]用光谱成像技术与分光光度法测量完成了织物颜色的比较分析。采用传统的方法对织物的分析能从最细节的角度阐述织物的纹理特性,但是无法对其进行分类与应用。因此,为了达到对织物纹理特性准确分类,本文提出了两种

深度学习网络,即基于迁移学习的 GoogleNet 网络以及非迁移学习的残差网络进行学习和分类,网络训练的结果,预期能达到 98% 的分类准确性。然后以这两种网络算法为基础,完成织物纹理特性分析和分类的系统,系统预期的分类准确性应达到 95% 以上。

1 原理与实验设计

1.1 数据集的构成

由于绝大多数的开幅引导线都是沿开幅方向分布的,因此专门选择了最常见以及最易混淆的以下 7 种织物特征:不等宽横纹、等宽横纹、等宽竖纹、格状花纹、密集型花纹、交错式花纹、条纹格状,如图 1 所示。考虑到实际生产的过程中,织物难免会出现各样的瑕疵,为了排除瑕疵对实验结果的影响,在数据集中有大约 20% 的样品中存在着各种类型的瑕疵。

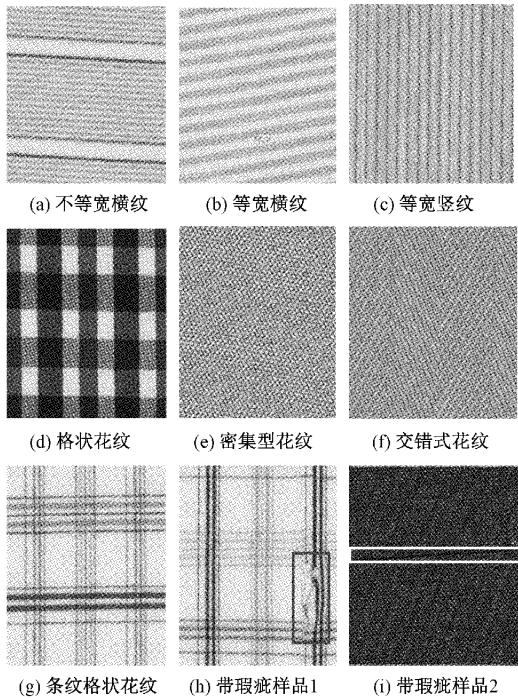


图 1 纹理特征数据集

1.2 GoogleNet 网络的搭建

1) GoogleNet 网络

网络的深度与宽度是其网络精度性能的决定性因素之一^[6],但是过深或者过宽的网络都会带来很多问题。网络的深度和宽度到达一定程度并且在训练集的数量有限的情况下,容易导致网络的过拟合从而导致网络的泛化能力下降,甚至会发生梯度消失的问题,从而导致训练无法正常进行^[7]。

GoogleNet 网络针对上述深度和宽度过大的网络模型出现的问题进行研究,使用了一种结构—Inception 来保证模型的稀疏性同时又利用密集矩阵来进行高性能计算^[8-9],

从而解决了上述问题,其中 Inceptionv1 的结构模型如图 2 所示。Inceptionv1 的实质是 1×1 、 3×3 、 5×5 的卷积核和 3×3 的池化核堆叠在一起,使用了不同的大小的卷积核使得网络在进行卷积时在特征图上具有不同尺寸的感受野,并且最后进行了一定程度的特征融合。但是这种结构涉及到的 5×5 卷积核必然会给网络带来巨大的计算量,例如:对于一个 $32 \times 32 \times 256$ 的特征图,用 32 个 $5 \times 5 \times 256$ 的卷积核进行卷积操作,要得到输出为 $32 \times 32 \times 32$ 的特征图,则总计算量为 2.1×10^8 次,其卷积核计算量是 3×3 的 2.78 倍^[10-11]。为了降低整体的计算量,对 Inceptionv1 的结构进行改进,借助了非对称卷积来令计算量减少,同时在 3×3 与 5×5 的卷积层以前借助 1×1 的网络降维卷积的数据,进而可以令计算量减少。改进后的结构模型如图 3 所示。

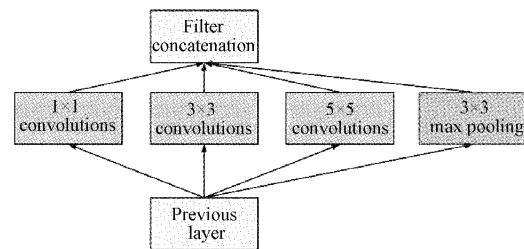


图 2 Inceptionv1 的结构模型

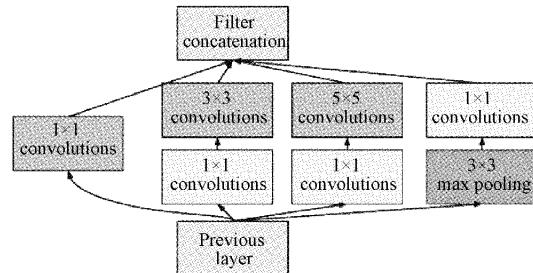


图 3 Inceptionv1 的改进结构

为了更进一步提高将针对 GoogleNet 网络对织物纹理的学习能力,针对原本的池化操作进行改进。根据研究显示,特征提取的误差主要来源于以下两个方面:邻域大小受限造成的估计值方差增大;卷积层参数误差造成估计均值的偏移^[12]。原 GoogleNet 网络采用的是 max-pooling(最大池化),最大池化能有效减少来自第 1 个方面的影响,会更多的保留背景信息。但是,背景信息并不是我们织物纹理特性所需要重点学习的。因此,将选用 average-pooling(平均池化)来代替原有的最大池化层,更多的保留纹理信息,提高网络的学习能力。

最后构建的 GoogleNet 网络模型如图 4 所示。由图 4 可知,在网络结构中的 Inception 部分处,新增加了两个 softmax 辅助分类器。其目的在于抵抗梯度,即在网络前部再给予一部分梯度,这部分梯度就来自于两个辅助 softmax loss。

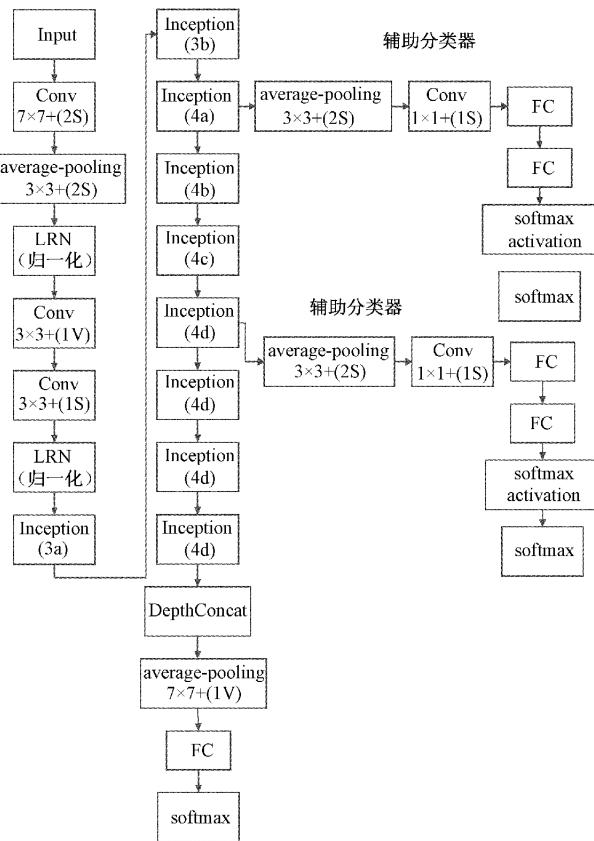


图 4 本文 GoogleNet 网络结构

2) CNN 与迁移学习的模型建立

与 ImageNet 大型图像数据集相类似的,本文构建的纹理特性数据集与其的差别在于类型以及每个类型图像数量上的差距^[13]。因此,针对本文创建的纹理特性数据集,可以由 CNN 预训练分类模型作为基础,结合迁移学习开展对数据集的训练。

卷积神经网络迁移学习的优点在于不需要对模型全部权重参数进行随机初始化,在预训练好的 CNN 模型的参数的基础上进行微调,有利于快速实现对网络的收敛。其工作流程如图 5 所示。

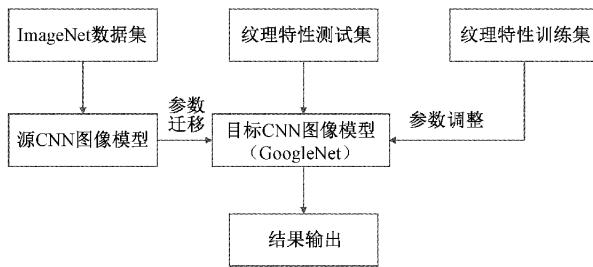


图 5 迁移学习的工作流程

3) 基于迁移学习的 GoogLeNet 算法流程

(1) 输入织物纹理特性样本。随机从建立的数据集中抽取 7 种不同织物纹理特性的图片 1 234 张(占图片总数的 80%),作为训练样本集进行输入。

输入的标签命名。不等宽横纹:BDKHW;密集型花纹:MJX;交错式花纹:PATTERN;格状花纹:GZ;等宽横纹:DKHW;等宽竖纹:DKXW;条纹格状:TWGZ;

(2) 输入图像预处理。为了将原始的输入图片转换为规定尺寸大小的图片,本文采取的是双线性插值法。双线性插值法原理如下:假设源图像大小为 $M \times N$, 目标图像为 $A \times B$ 。那么两幅图像的边长比分别为 M/A 和 N/B 。

目标图像的第 (i, j) 个像素点(i 行 j 列)可以通过边长比对应回源图像。其对应坐标为 $(i \times M/A, j \times N/B)$ 。双线性插值通过寻找距离这个对应坐标最近的 4 个像素点,来计算该点的值(灰度值或者 RGB 值)。

但是实际上,若是直接选取源图的左上角作为原点,那么会发现,尺度变换后的图片实际上更加偏向左上方,而右下方的像素点实际上没有参与计算。所以正确的转换方式应为:

$$x = (i + 0.5) \times M/A - 0.5$$

$$y = (j + 0.5) \times N/B - 0.5$$

(3) 根据现有的 7 种新创建的纹理特征标签替换原有的 softmax 分类层。

(4) 对迁移后的网络模型进行参数微调。通过动量参数、学习速率和训练时间等模型训练参数的设定,通过损失函数迭代,冻结部分卷积层和池化层的参数,训练并优化全连接层和 softmax 分类层的参数^[14]。

(5) 新网络模型的训练。用剩余的 7 种 309 张图片(占图片总数的 20%)作为测试集进行模型测试,验证新网络的精确度。

4) GoogleNet 网络的参数设置及优化

(1) 训练及测试的环境

模型训练和测试硬件环境: Intel @ Core (TM) i7-7700HQ CPU @ 2.80 GHz (8CPUs) 处理器, 16 G 内存, NVIDIA GeForce GTX 1080Ti 显卡加速图像处理。软件环境: 操作系统为 Windows 10 旗舰版, 开发软件为 MATLAB 2019b。

(2) 训练参数的设置

所有重要的训练参数设置如表 1 所示。

表 1 训练参数设置

类目	选择参数 类型
优化器	Mini-Batch(梯度下降算法)
学习率	2.56×10^{-5}
正则化参数	5×10^{-5}
训练迭代次数	50
训练批量	10

(3) 参数设置的依据

由表 1 可知,优化网络的算法选择的是 Mini-Batch, Mini-Batch 算法是对随机梯度下降算法(stochastic

gradient descent, SGD) 的优化, SGD 算法在计算梯度的时候是随机选取一个样本来计算梯度并进行梯度的更新, 其计算公式为:

$$\theta_j := \theta_j + \alpha (y^{(i)} - h_\theta(x^{(i)})) x_j^{(i)} \quad (1)$$

与 SGD 不同的是, Mini-Batch 算法在每次迭代更新的时候从中随机算取 m 个样本进行梯度计算更新而不是仅选取其中的某一个样本, 虽然速度上有下降, 但是稳定性大大增加^[13]。其计算公式为:

$$\theta_j := \theta_j - \alpha \frac{1}{m} \sum_{k=i}^{i+m-1} (h_\theta(x^{(k)}) - y^{(k)}) x_j^{(k)} \quad (2)$$

训练的批量为 10 次, 与之相关的是预先设置的 batch-size(批次大小)。过大的 batch-size 会使训练时间增加造成内存崩溃, 反之则会对样本利用率下降, 容易陷入局部最优点, 得不到全局最优解^[16]。本文参与训练的图片有 1 234 张, batch-size=130, 即 10 次 Batch 就可以完成 1 次迭代。

学习率的设置对于卷积神经网络的训练尤为重要, 它能直接影响到网络收敛速度的快慢、分类能力的稳定性以及分类的准确度。为了能使网络模型达到一个优秀的分类效果, 以下试验以准确度以及分类能力为标准, 选取合适的学习率, 结果如图 6 所示。从试验结果可以清楚的得知, 当学习率低于 2.5×10^{-5} 的情况下, 分类的准确性相对较差, 而当学习率为 3×10^{-5} 时, 分类能力出现了下滑, 因此在最后确定学习率为 2.56×10^{-5} 。

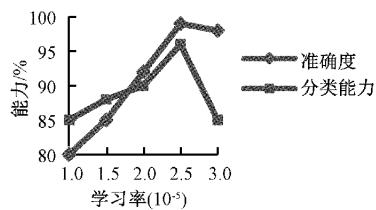


图 6 学习率与网络训练效果关系

1.3 残差网络的构建

1) 残差网络

GoogleNet 与另外一种网络 VggNet 能从不同的角度提升网络的精度, 但是经研究发现, 在进一步增加网络的深度的同时, 并不能取得预期效果, 反而网络的收敛速度变慢, 甚至精度也有所下降^[17]。在 2015 年微软亚洲研究院的 He 等^[18]提出了深度残差网络 (deep residual network)。在残差学习 (residual learning) 的启发下, 网络中引入了恒等映射的设计, 巧妙地缓解了由于深度增加带来的梯度爆炸或梯度消失以及网络退化的问题^[19 21]。

本文引入残差网络进行纹理特性的分析主要有 3 个目的: 与基于迁移学习的 GoogleNet 网络进行对比; 探索残差网络在小样本的分类能力, 残差网络主要应用的范围为人脸识别^[22]、目标检测^[23]等数据量较大的场景; 在织物纹理特性数据集的种类以及各种类数据数量有质的增加的时候, GoogleNet 网络可能会出现上述的梯度爆炸或梯度消

失的问题, 此时可以依据本文的残差网络进行新的分类研究。

2) 残差网络模型搭建

残差网络结构是由残差块叠加组成的残差网络, 残差块的组成如图 7 所示, 简单的残差块是由卷积层、非线性激活函数 (ReLU) 以及对应的归一化 (batch normalization, BN) 组成^[24]。

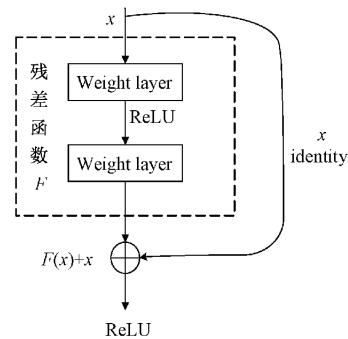


图 7 残差块结构

假设残差块的输入为 x , 输出为 x_{t+1} , 残差块可以由式(3)表示。由式(3)可知, 残差块一般分为直接映射和残差部分, 其中, $F(x_t, W_t)$ 函数代表的残差块的残差部分, 这也是需要学习的部分, 残差部分相对于原始的学习特征而言更加容易学习, 而当残差部分为 0 时, 此时的残差块只完成了直接映射, 保证了网络的性能不会退化^[25]。

$$x_{t+1} = x_t + F(x_t, W_t) \quad (3)$$

最基本的深度残差网络则是由多个原始的残差单元学习块组合而成, 其原始残差单元学习块如图 8 所示。而本文构建一个层数相对深的网络 (50 层), 因此为了避免过多原始残差单元块累计的参数量, 去除了第 1 个 ReLU, 并在最后增加一个 BN 层, 具体网络结构如图 9 所示。

3) 残差网络的参数设计

残差网络重要的参数以及类型选择如表 2 所示。

残差网络的优化器的原理选择以及学习率等重要参数的选择均为兼顾识别精度、训练时间、模型分类能力等多方面的选择结果。选取的方式与迁移学习的 GoogleNet 网络相同, 这里不再赘述。

2 实验结果与分析

2.1 网络训练实验结果分析与对比

在纹理特性训练集完成训练后, 将剩余的 7 种共 309 张图片输入至 GoogleNet 以及残差网络模型中, 对模型的精度进行评价, 其验证的频率为 50 次迭代, 实验结果如图 10~11 所示。

GoogleNet 网络由于是基于迁移学习的模型, 因此网络的收敛速度十分的快。在模型迭代次数为 50 次时, 预测的精确度已经达到了 96% 以上, 而 100 次迭代过后, 预测精度已经稳定在 100%。而非迁移学习的残差网络模型,

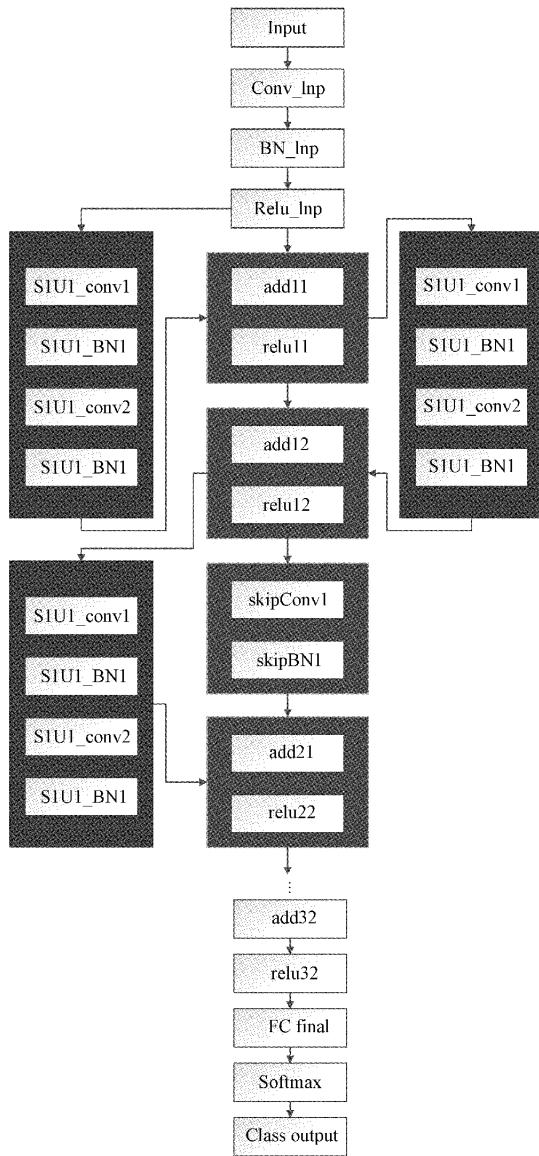


图 8 原始残差单元学习块

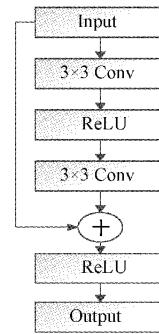


图 9 残差网络结构

表 2 残差网络参数详情

类目	选择参数/类型
优化器	Mini-Batch(梯度下降算法)
激活函数	ReLU
学习率	1×10^{-3}
训练批量	64
迭代次数	30

大约 200 次迭代的时候开始逐渐收敛, 精度与 GoogleNet 网络没有差异, 但是迁移学习的收敛速度为残差网络的 4 倍, 而且从趋势线波动上迁移学习的泛化性能更好, 因此在小样本的测试中迁移学习的性能优于非迁移学习的残差网络性能。

从两种网络的测试结果来看, 均达到了预期分类准确率 98% 以上的要求, 不仅完成了对 7 种合计 1 543 张图片的正确分类, 同时也初步验证了, 织物图像中含有的少量瑕疵特征并不会影响分类的准确性。虽然以目前的效果来说, 基于迁移学习的分类稳定性更高, 但是随着类型、类型图片总数以及网络层数的逐渐加深残差网络的优势将会体现出来, 这也是后续研究的方向之一。

为了更进一步的表明实验结果, 引入混淆矩阵即误差

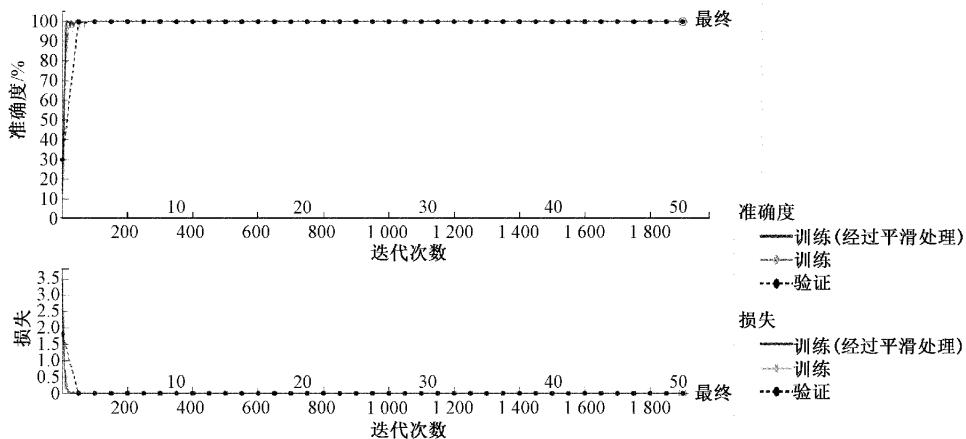


图 10 基于迁移学习的 GoogleNet 网络实验结果

矩阵说明, 如图 12 所示。以第 1 行 BDKHW 为例, 一共有 50 张图片被作为测试集进行测试, 全部被正确的识别为

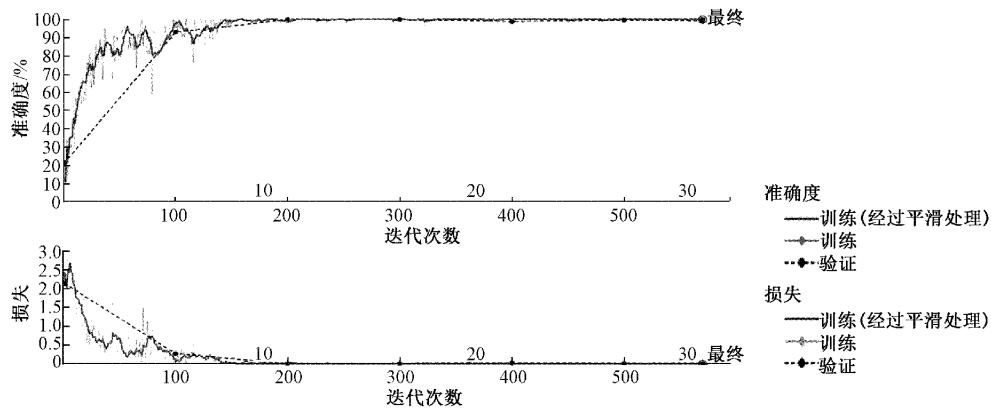


图 11 基于残差网络实验结果

BDKHW, 第 1 行除第 1 列以外, 其余均为空框, 表示数字为 0, 即没有出现识别误差, 将 BDKHW 识别成其他类别。其余的 6 种纹理特性, 也均未出现识别错误的情况。

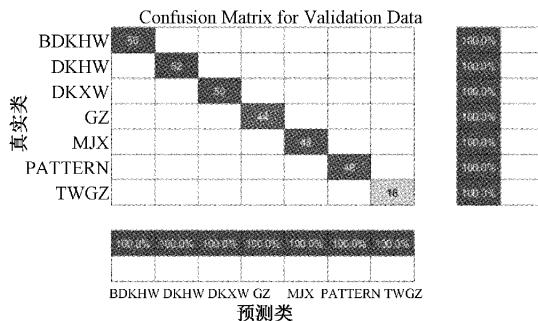


图 12 混淆矩阵

2.2 织物纹理特性分类系统

网络训练的结果表明, 本文搭建的两种卷积神经网络均能完成对织物纹理的高准确率分类, 足以作为系统的算法基础。根据上述两种卷积神经网络的结果对比, 最终选择了基于迁移学习的 GoogleNet 网络作为系统的分类算法。系统的测试对象包括数据集所有的 1 543 张图片, 以及数据集以外的 300 张图片(特征上具有相似性), 另外为

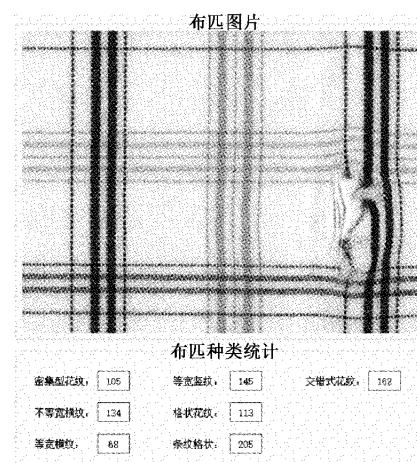


图 14 织物纹理分析与分类系统实验结果

了进一步验证瑕疵是否会对识别结果造成影响, 添加了 50 张有瑕疵的样本, 新增的样本图片如图 13 所示。

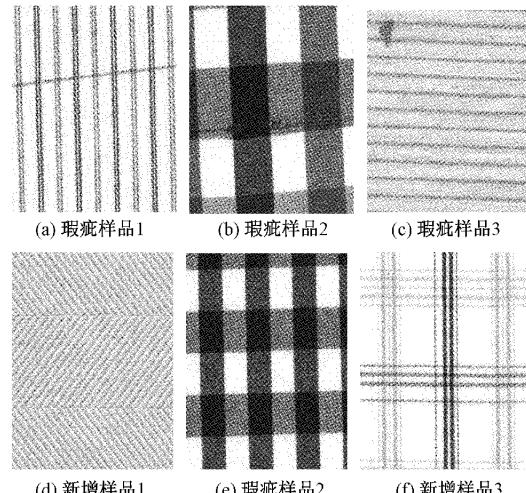
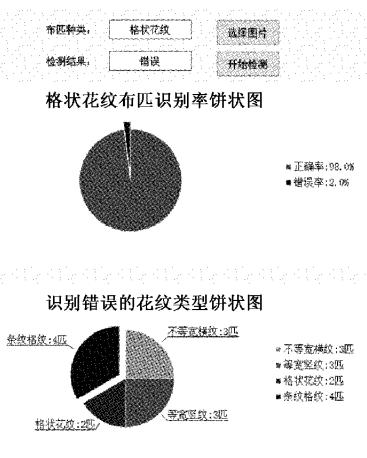


图 13 新增样品图片

系统测试界面如图 14 所示, 主要包括了当前检测的图像、各种类累计检测数量、当前种类检测的正确率以及错检样品的数据统计。最终的测试结果显示: 原样品的识



别中,每一种纹理特性均保持了 100% 的识别准确率,新增样品的识别准确率如表 3 所示。主要的识别误差发生在格状与条纹格状之间,新增样品的准确率均为 97%,主要原因应为较宽的条纹与小的格状特征产生了混淆。系统总体识别准确率为 98%,达到了预设的系统要求。

表 3 新增样品各种类识别结果

织物纹理特性	识别准确率/%
不等宽横纹	99
等宽横纹	99
等宽竖纹	100
格状花纹	97
密集型花纹	100
交错式花纹	100
条纹格状花纹	97

3 结 论

本文采用了基于迁移学习的 GoogleNet 网络与非迁移学习的残差网络对新构建的纹理特征数据集进行测试分析。两者达到的高准确度分类,为后续进行针对性的纹理滤除,以达到更准确自动识别织物开幅引导线奠定基础,并且以此为基础的织物纹理分析系统,在增加数据集以外的图像之后,也展示了高准确率的分类结果,说明了网络学习具有较强的泛化能力以及系统的可靠性。该系统在日后应用于实际生产,需要增加更多不同种类的纹理特性(尤其是特殊纹理),最好系统能具有自学习功能,将新出现的纹理特征进行标注和保存。另外,本文针对瑕疵样品的选择均为范围较小的瑕疵,对织物大范围的瑕疵对纹理分析的影响应做出更加深入的实验研究。

参考文献

- [1] 国家发展改革委,工业和信息化部.国家发展改革委工业和信息化部关于实施制造业升级改造重大工程包的通知 [N].发展改革委网站,2016-05-18. http://www.gov.cn/xinwen/2016-05/18/content_5074373.htm.
- [2] 杨德亮,魏燕定,周冠雄,等.基于 PSD 的织物引导线跟踪器设计[J].纺织学报,2010,31(6):129-133.
- [3] 武筱婷.德国莱默尔 E+L:智控系统助力行业绿色发展[J].纺织机械,2019(5):66-67.
- [4] 薛乐,李立轻,汪军.应用频谱图的机织物纹理分析[J].纺织学报,2015,36(7):55-60.
- [5] 裴柯棋,陈维国,周华.用光谱成像技术与分光光度法测量织物颜色的比较分析[J].纺织学报,2020,41(11):73-80.
- [6] 王洋,余祖俊,朱志强,等.基于 CNN 的高速铁路侵限异物特征快速提取算法[J].仪器仪表学报,2017,38(5):1267-1275.
- [7] 徐一鸣,张娟,刘成成,等.迁移学习模式下基于 GoogLeNet 网络的风电机组视觉检测[J].计算机科学,2019,46(5):260-265.
- [8] 薛晨兴,张军,邢家源.基于 GoogLeNet Inception V3 的迁移学习研究[J].无线电工程,2020,50(2):118-122.
- [9] 张洁庆,郭敏,肖冰.基于 GoogLeNet 和双层 GRU 的图像描述[J].陕西师范大学学报(自然科学版),2021,49(1):68-73.
- [10] 徐凯,梁志坚,张德议,等.基于 GoogLeNet Inception-V3 模型的电力设备图像识别[J].高压电器,2020,56(9):129-135,143.
- [11] 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.
- [12] 白志鸿.基于稀疏卷积的 GoogLeNet 网络硬件加速设计与实现[D].北京:北京交通大学,2020.
- [13] 李帷韬,韩慧慧,焦点,等.基于深度迁移学习的大雾等级智能认知方法研究[J].电子测量与仪器学报,2020,34(2):88-96.
- [14] 邓向武,马旭,齐龙,等.基于卷积神经网络与迁移学习的稻田苗期杂草识别[J].农机化研究,2021,43(10):167-171.
- [15] 徐慧君,王忠,马丽萍,等.改进 Mini Batch K-Means 时间权重推荐算法[J].计算机工程,2020,46(3):73-78,86.
- [16] PRADHAN S, GUPTA U C. Station distribution of infinite-buffer batch-arrival and batch-service queue with random serving capacity and batch-size-dependent service [J]. International Journal of Operational Research, 2020.
- [17] 赵志成,罗泽,王鹏彦,等.基于深度残差网络图像分类算法研究综述[J].计算机系统应用,2020,29(1):14-21.
- [18] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [J]. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 2016: 770-778.
- [19] 张婷婷,方宇强,韩蕾.基于深度残差网络的自动调制识别方法研究[J].计算机仿真,2021,38(1):178-180,379.
- [20] 郭玥秀,杨伟,刘琦,等.残差网络研究综述[J].计算机应用研究,2020,37(5):1292-1297.
- [21] 徐冰冰,岑科廷,黄俊杰,等.图卷积神经网络综述[J].计算机学报,2020,43(5):755-780.
- [22] 赵玉莹.基于卷积神经网络的航拍目标检测与跟踪方法研究[D].大庆:东北石油大学,2020.
- [23] 张枫,田联房,杜启亮.基于残差网络与中心损失的人

- 人脸识别 [J]. 计算机工程与设计, 2019, 40(6): 1689-1695.
- [24] 林桢哲, 王桂棠, 陈建强, 等. 基于残差网络深度学习的肺部 CT 图像结节良恶性分类模型 [J]. 仪器仪表学报, 2020, 41(3): 248-256.
- [25] 李国强, 陈文华, 高欣. 交叉连接的少层残差卷积神经网络 [J]. 小型微型计算机系统, 2021, 42(3): 510-515.

作者简介

邓宇平, 在读硕士生, 主要研究方向为深度学习、织物图像处理。

E-mail: 849721104@qq.com

王桂棠(通信作者), 教授, 硕士生导师, 主要研究方向为仪器科学与技术、机器视觉。

E-mail: wanggt@gdut.edu.cn