



基于卷积神经网络的纺织面料主成分分类

张 玮, 张华熊

(浙江理工大学信息学院, 杭州 310018)

摘 要: 为自动检测纺织面料的主成分, 以 100~200 倍放大后拍摄的纯纺面料或主成分含量在 50% 以上的混纺面料图像为研究对象, 提出了一种基于深度卷积神经网络的纺织面料主成分分类方法。首先对纺织图像进行裁剪及颜色空间转换; 然后将图像输入卷积神经网络进行织物面料主成分分类训练; 最后将待分类的纺织面料图像输入训练后的卷积神经网络中, 得出纺织面料主成分分类结果。对棉、涤纶、腈纶、羊毛、天丝 5 类共 4497 张图像进行实验, 实验结果显示: 该方法对 5 类织物面料主成分分类准确率为 96.53%; 与其他卷积神经网络模型相比大幅降低了训练时间, 减小了网络规模, 提高了分类准确率。

关键词: 纺织面料成分分类; 卷积神经网络; 空洞卷积; 深度可分离卷积

中图分类号: TP181; TS107

文献标志码: A

文章编号: 1673-3851 (2019) 01-0001-08

Classification of main components of textile fabrics based on convolutional neural network

ZHANG Wei, ZHANG Huaxiong

(School of Information Science and Technology, Zhejiang Sci-Tech
University, Hangzhou 310018, China)

Abstract: To automatically test main components of textile fabrics, the pictures of pure textile fabric shot after amplification of 100—200 times or blended textile fabric with main component content more than 50% were used as the objects of study to propose a main component classification method for textile fabrics based on deep convolutional neural network. Firstly, cropping and color space conversion were conducted for the pictures. Secondly, the pictures were input into the convolutional neural network to train main component classification for textile fabrics. Finally, the pictures of the textile fabric to be classified were input into the trained convolutional neural network, and the main component classification results of textile fabrics were obtained. 4497 pictures of cotton, polyester, acrylic, wool and Tinsel were chosen for the experiment. The experiment results showed that the accuracy of the main component classification method for the 5 classes of fabrics is 96.53%. Compared with other convolutional neural network models, the proposed method reduces training time, decreases network size and improves the classification accuracy.

Key words: classification of main components of textile fabrics; convolutional neural network; dilated convolution; depthwise separable convolution

0 引言

纺织面料成分是衡量纺织品质量的重要指标之一,随着纺织业的发展,纺织面料的种类日渐增多,其检测难度随之增加。一些不法商家在面料成分标注中弄虚作假、以次充好,而消费者一般不具备相应的鉴别技术,导致消费者的合法权益受到损害。因此,找到一种快速、方便、低门槛的面料成分检测分类方法非常重要。

传统的面料成分检测方法有手感目测法、显微镜观测法、光谱分析法、化学方法及物理方法。这些方法要求检测者具备一定的专业知识,在检测过程中需要对织物进行拆解。手感目测法中主观因素对检测结果的影响较大,显微镜观测法及物理方法对专业仪器设备的要求较高;近红外光谱分析技术利用已知成分纺织品及其近红外光谱信息建立模型,通过该模型快速检测未知纺织品成分,但该方法对近红外光谱仪的设备参数有较高要求,且织物组织结构与均匀性也会影响该方法的使用^[1];化学方法中使用的化学试剂不仅污染环境也会损害检测者的健康。在基于图像识别技术的纤维检测方法中,胡觉亮^[2]利用贝叶斯决策理论通过提取织物图像的形态结构参数进行分类,棉、麻、丝的分类准确率分别为93.2%、91.5%和90.2%;应乐斌等^[3]利用单纤维纵向纤维图像,通过最小二乘支持向量机分类器对棉/亚麻纤维进行分类,分类准确率为93.3%。这些方法首先需对面料进行拆解,然后对单根纤维的图像进行分类处理,对图像的放大倍数要求较高,且仅针对特定的几种面料成分分类效果较好,模型通用性较差,应用场景受限。

图像特征的提取和分类是机器视觉领域的核心问题。近年来,卷积神经网络在该领域取得了突破性的研究成果,受到了广泛关注。卷积神经网络采用一种端到端的学习模型,通过梯度下降法训练确定模型参数,能够获得图像特征,并实现图像归类^[4]。卷积神经网络在纺织领域的应用日渐增多。景军锋等^[5]提出了一种基于深度卷积神经网络的色织物缺陷检测算法,提高了色织物缺陷图像的检测效率和准确性。张宏伟等^[6]提出了一种基于深度卷积神经网络的条状、格子 and 波点纹理织物的识别分类方法,可对织物花型进行有效分类。冀中等^[7]通过实验发现,卷积神经网络模型在大多纹理数据集上均能取得很好的性能,是一种优秀的纹理特征表示模型。卷积神经网络在纺织领域主要应用于织物缺陷检测和花型分

类,面料成分分类领域应用较少,一个很重要的原因是训练用的数据样本库建立非常费时费力。

鉴于现有检测方法的不足和卷积神经网络的特点,本文以放大100~200倍的纯纺面料或主成分含量在50%以上的混纺面料图像为研究对象,构建了一种基于卷积神经网络的多分类模型,以避免对待检测面料进行拆解并减少面料成分定性检测对专业人员的依赖。首先,为更好地学习到织物图像特征,对图像进行预处理;其次,使用空洞卷积和深度可分离卷积构建卷积神经网络;然后,将图像库输入网络进行训练,得到面料图像与分类结果间的映射;最后,将面料图像输入训练好的卷积神经网络,完成面料主成分分类。

1 算法流程

本文提出的基于卷积神经网络的面料分类算法流程如图1所示,主要分为3个阶段:

a) 图像预处理。首先转换图像的颜色空间,便于网络更好地学习到图像特征;其次对图像进行数据增强操作,提高网络的泛化能力。

b) 建立并训练网络模型。根据本文提出的卷积神经网络结构搭建网络,并使用图像预处理后的图像库训练该网络,得到训练好的网络模型。

c) 将待分类面料图像进行图像预处理,然后输入训练好的卷积神经网络,得到分类结果。




图1 算法流程

2 图像库构建及图像预处理

2.1 图像库构建

使用放大100~200倍的相机对已知成分的纯纺或主成分含量在50%以上的混纺面料进行图像采集,每个面料样本采集一张成像清晰的图像,并以主成分名称为图像标注类别信息。

2.2 颜色空间转换

HSV颜色空间能够分离颜色、亮度及饱和度信

息,能较好反映人对色彩图像的理解和鉴别过程,适合于色彩图像处理^[8]。由于面料图像的纹理特征较为丰富,HSV 颜色空间比 RBG 颜色空间更有利于卷积神经网络处理图像特征,因此本文将图像转换为 HSV 颜色空间。

2.3 数据增强

为了使卷积神经网络进行充分地训练,本文采用数据增强技术对图像库进行扩充。由于面料成分图像各部分具有相似的特征,本文采用以下方式进行数据增强:a) 将图像统一压缩到 700×700 个像素点;b) 分别在缩放后图像的左上、左下、右上、右下和中心位置截取一张 384×384 个像素点的图像。这样可在增加图像库样本的同时,尽可能减少因缩放造成图像信息损失,充分利用图像信息。

3 卷积神经网络构建

本文参考 MobileNet 网络模型^[9]搭建了卷积神经网络结构,网络参数见表 1。该网络由 20 个不同类型的卷积层、1 个均值池化层(Average pooling layer)、1 个全连接层和 1 个 Softmax 层简单线性堆叠而成。其中,每一个卷积操作后,都先进行批标准化(Batch normalization)操作,然后通过激励函数进行非线性变换。本文网络中使用的激活函数为 ReLu 函数,空洞卷积中卷积核的膨胀率为 2。

表 1 面料成分分类卷积神经网络结构

序号	卷积类型/ 步长	卷积核大小/ 像素	输入尺寸/ 像素
1	Dilated_conv/S1	3×3×3×32	384×384×3
2	Depthwise_conv/S3	3×3×32	384×384×32
3	Depthwise_conv/S1	3×3×32	128×128×32
4	Pointwise_conv/S1	32×1×1×64	128×128×32
5	Depthwise_conv/S2	3×3×64	128×128×64
6	Pointwise_conv/S1	64×1×1×128	64×64×64
7	Depthwise_conv/S1	3×3×128	64×64×128
8	Pointwise_conv/S1	128×1×1×128	64×64×128
9	Depthwise_conv/S2	3×3×128	64×64×128
10	Pointwise_conv/S1	128×1×1×256	32×32×256
11	Depthwise_conv/S1	3×3×256	32×32×256
12	Pointwise_conv/S1	256×1×1×256	32×32×256
13	Depthwise_conv/S2	3×3×256	32×32×256
14	Pointwise_conv/S1	256×1×1×512	16×16×512
15	Depthwise_conv/S1	3×3×512	16×16×512

表 1 续

序号	卷积类型/ 步长	卷积核大小/ 像素	输入尺寸/ 像素
16	Pointwise_conv/S1	512×1×1×512	16×16×512
17	Depthwise_conv/S2	3×3×512	16×16×512
18	Pointwise_conv/S1	512×1×1×1024	8×8×1024
19	Depthwise_conv/S1	3×3×1024	8×8×1024
20	Pointwise_conv/S1	1024×1×1×1024	8×8×1024
21	Average pooling/S1	8×8	8×8×1024
22	Fully connected/S1	1024×5	1×1×1024
23	Softmax	—	1×1×5

注:Dilated_conv 表示空洞卷积,Depthwise_conv 表示深度卷积,Pointwise_conv 表示逐点卷积,Depthwise_conv 和 Pointwise_conv 组成一个深度可分离卷积;S1 表示步长为 1 像素,以此类推。

网络第 2 层使用深度卷积,以达到压缩特征图的目的,与传统的池化操作相比,增加网络深度的同时充分利用了特征图数据。第 3 层到第 20 层共使用 9 个深度可分离卷积,按照前一层卷积进行同等维度的特征学习,后一层卷积在对特征图进行学习的同时对特征图进行压缩和升维操作的方式交替排列。通过均值池化输入到全连接层,通过 Softmax 函数得到最终的分类结果。

网络首先使用空洞卷积技术进行原始图像特征提取。与普通卷积相比,空洞卷积可以在不增加网络计算量的情况下增大网络感受野^[10]。卷积和下采样池化与空洞卷积的比较如图 2 所示。图像 a 表示一张 6×6 像素的图像;图像 b 表示图像 a 使用 3×3 的卷积核进行步长为 1 的卷积操作后得到的结果;图像 c 表示图像 b 使用 2×2 的核进行步长为 2 的池化操作后得到的结果。图像 d 表示图像 a 使用 3×3 大小膨胀率为 2 的卷积核进行空洞卷积后得到的结果。与图像 c 相比,图像 d 保留了更多的原图信息,且需要的计算量更少。同时本文涉及的面料成分图像特征是非像素级别的,每个像素和其邻域内的像素值相近,使用空洞卷积较传统卷积操作更能高效地提取面料成分图像特征。




图 2 卷积和下采样池化与空洞卷积的对比
从网络的第 2 层到第 20 层,使用深度可分离卷

积(Depthwise separable convolution)来搭建网络。深度可分离卷积即将一个普通卷积拆分为一个深度卷积(Depthwise convolution)和一个逐点卷积(Pointwise convolution),普通卷积与深度可分离卷积的对比如图3所示。深度可分离卷积首先对输入数据 \mathbf{G} 进行深度卷积,其是一种分组卷积操作,即卷积核中每个通道分别与输入数据 \mathbf{G} 的对应通道进行卷积得到结果 \mathbf{F}_1 ,再通过逐点卷积,即卷积核为 1×1 的卷积得到结果 \mathbf{F}_2 。 K 代表卷积核大小,

C_i 代表 \mathbf{G} 的通道数, G_h 代表 \mathbf{G} 和 \mathbf{F} 的高度, G_w 代表 \mathbf{G} 和 \mathbf{F} 的宽度, C_o 代表 \mathbf{F} 的通道数,即普通卷积过程中卷积核参数个数为 $S_k = K \cdot K \cdot C_i \cdot C_o$,计算量为 $C_k = S_k \cdot G_h \cdot G_w$;深度可分离卷积过程中卷积核参数个数为 $S_d = K \cdot K \cdot 1 \cdot C_i + 1 \cdot 1 \cdot C_i \cdot C_o$,计算量为 $C_d = S_d \cdot G_h \cdot G_w$,推出 $\frac{S_d}{S_k} = \frac{C_d}{C_k} = \frac{1}{K^2} + \frac{1}{C_o}$ 。这样可在增加网络深度的同时,大量减少卷积操作计算量及卷积核参数量^[10]。




图3 普通卷积与深度可分离卷积对比

4 实验与结果分析

本文实验所用工作站操作系统为 Windows 10, 主要硬件参数为: Nvidia Tesla P100-12G GPU 一块, Intel Xeon E5-2620 V4 CPU 两颗, DDR4 2400MHz 16 G 内存四条。深度学习框架采用 Keras 2.1.5, 其后端使用 TensorFlow 1.7.0, Python 版本为 3.5.5。实验过程中, 训练集数据量为图像库的 80%, 验证集数据量为图像库的 20%, 选取图像的方式为随机抽取。

实验训练过程均采用 Adam 优化器 (Optimizer), β_1 、 β_2 分别为 0.9 和 0.999; 损失函数使用分类交叉熵函数 (Categorical cross entropy); 训练次数 (Epoch) 为 80 次, 训练网络时, 训练集图像随机旋转 $0^\circ \sim 20^\circ$, 水平/垂直方向分别随机偏移 $0 \sim 10\%$ 并进行随机翻转, 以增强网络的泛化能力; 实验分类准确率取验证集最高分类准确率。

4.1 构建图像库

使用放大 100~200 倍的相机对面料样本进行图像采集, 图像大小为 3264×2448 个像素点。在构

建面图图像库时, 考虑到样本平衡问题及图像库中最少类别图像数目, 构建了 5 类共 4497 张图像的图像库, 其中涤纶、棉、天丝、腈纶每类各 900 张, 羊毛 897 张, 示例图像如图 4 所示。

4.2 图像预处理

首先, 裁剪掉图像中与面料主成分分类不相关的阴影部分。然后, 分别对图像库中图片进行转换颜色空间及数据增强操作, 将图像库由原来的 4497 张扩充到 22485 张, 转换效果如图 5 和图 6 所示。

为验证图像预处理的有效性, 将图像库按 3 种不同方式进行预处理, 分别为: 直接将 RGB 颜色空间图像压缩为 384×384 个像素点; 将图像转换为 HSV 颜色空间后压缩为 384×384 个像素点; 使用 RGB 颜色空间, 采用 2.3 节所述数据增强方式。对比结果如表 2 所示, 从表中可以看出: 通过转换为 HSV 颜色空间, 网络分类准确率增加了 8.56%; 数据增强操作为网络分类准确率提高了 22.16%; 同时使用两种方法, 网络分类准确率提升了 31.42%。




图 4 面料示例图像




图 5 将 RGB 颜色空间转换为 HSV 颜色空间




图 6 数据增强操作

表 2 不同图像预处理方法后网络的分类结果

图像预处理方式	准确率/%
RGB 颜色空间,无数据增强	65.11
HSV 颜色空间,无数据增强	73.67
RGB 颜色空间,采用数据增强	87.27
HSV 颜色空间,采用数据增强	96.53

本文改变图像库中图像的尺寸,对网络进行训练并测试,实验中采用 HSV 颜色空间并进行数据增强处理。实验结果如表 3 所示,从表中可以看出,网络在输入图像尺寸为 384×384 个像素点的情况下分类准确率最高。

4.3 可视化分析

使用 Grad-CAM (Gradient-weighted class

表 3 不同尺寸下的网络分类结果

图像尺寸/像素	准确率/%	训练时间/min
256×256	77.47	568
320×320	90.31	1066
384×384	96.53	1423
512×512	92.13	2357

activation mapping)算法^[11]定位类别判断区域,结果如图 7 所示。图中左侧为面料成分图像,右侧为对应热力图,颜色越深表示类别判断时越依赖该区域信息。通过对比发现,网络分类主要依据图像中面料纤维特征较为丰富的区域,而不是面料纹理信息较为丰富的纺线边缘区域,从而表明网络分类的依据并非面料的纹理特征。




图 7 面料成分图像及其类别判断区域热力图

4.4 网络结构的验证

根据本文提出的卷积神经网络和图像预处理方法,使用空洞卷积与普通卷积来验证其有效性,实验结果见表 4。从表 4 中可以看出,在本文提出的网络结构中,使用空洞卷积比使用普通卷积的准确率

提高了 3.66%。

表 4 使用空洞卷积与普通卷积分类结果

卷积方法	准确率/%
空洞卷积	96.53
普通卷积	92.87

在图像预处理后,输入本文提出的网络和其他网络在网络大小、不同尺寸下的网络训练时间、分类时间、分类准确率、精确率、召回率和 F-Measure 方面进行对比,结果见表 5—表 8。对比结果可以发现:

- a) 在网络规模方面,本文网络的网络参数数量为 5 种网络中最小的 2.1×10^6 个,与其他网络相比缩小 33% 以上,与网络最大的 Net-2 相比缩小近 96%。
- b) 在分类性能方面,当输入图像尺寸为 384×384 个像素点时,本文网络的分类性能优于其他网络,同时训练时间和分类时间小于其他网络;当输入

图像尺寸为 299×299 个像素点时,Net-3 网络的分类性能优于其他网络;二者在分类性能上相当,但在训练时间及分类时间上本文网络(1423 min 、 $14.6\text{ s}/10^3$ 次)明显优于 Net-3(4728 min 、 $28.6\text{ s}/10^3$ 次)。

c) 本文网络在 Net-4 网络基础上进行优化,网络规模进一步减小,在 299×299 个像素点和 384×384 个像素点两种图像尺寸下,分类准确率分别提升 16.85% 和 1.11%,训练时间分别缩短 532 min 和 312 min,每千次分类时间分别缩短 7.9 s 和 6 s,本文网络的各类别 F-Measure(精确率和召回率的调和平均值)均不低于 Net-4。

表 5 本文网络与其他卷积神经网络的比较

网络名称	网络参数/ 10^6 个	图像尺寸 1(299×299 像素)			图像尺寸 2(384×384 像素)		
		训练时间/ min	分类时间/ ($\text{s}\cdot10^{-3}$ 次)	准确率/ %	训练时间/ min	分类时间/ ($\text{s}\cdot10^{-3}$ 次)	准确率/ %
Net-1	21.8	2014	19.4	95.96	3249	30.8	96.27
Net-2	54.4	5282	35.9	96.40	7644	59.2	96.32
Net-3	20.9	4728	28.6	96.04	7020	52.1	96.38
Net-4	3.2	1453	13.5	76.04	1735	20.6	95.42
本文网络	2.1	921	5.6	92.89	1423	14.6	96.53

注:Net-1 为 Inception-V3^[12],Net-2 为 Inception-ResNet-V2^[13],Net-3 为 Xception^[14],Net-4 为 MobileNet^[9],下同。

表 6 本文网络与其他卷积神经网络的 F-Measure 比较

类别	图像尺寸 1(299×299 像素)					图像尺寸 2(384×384 像素)				
	Net-1	Net-2	Net-3	Net-4	本文网络	Net-1	Net-2	Net-3	Net-4	本文网络
腈纶	96.85	97.17	95.45	79.38	93.47	96.80	96.81	97.00	96.69	97.08
棉	95.05	95.51	96.49	75.33	93.68	95.10	96.09	94.71	95.18	96.36
涤纶	93.31	93.91	94.94	67.58	90.34	93.85	93.77	94.19	93.32	93.81
天丝	96.76	97.27	97.38	83.09	95.79	97.02	96.77	97.17	96.04	97.23
羊毛	97.46	97.89	95.85	83.52	93.77	98.20	97.41	98.41	97.40	97.40

表 7 使用 384×384 像素图像本文网络与其他卷积神经网络分类性能的对比

类别	精确率/%					召回率/%				
	Net-1	Net-2	Net-3	Net-4	本文网络	Net-1	Net-2	Net-3	Net-4	本文网络
腈纶	96.96	97.17	96.63	96.96	97.61	96.64	96.44	97.37	96.43	96.56
棉	94.75	96.09	96.21	95.24	96.95	95.45	96.09	93.25	95.12	95.78
涤纶	92.99	91.72	92.18	93.10	92.30	94.73	95.91	96.28	93.53	95.37
天丝	97.17	97.17	97.17	95.29	97.38	96.87	96.37	97.17	96.81	97.08
羊毛	99.04	98.61	99.36	98.07	98.18	97.37	96.24	97.48	96.73	96.63

表 8 使用 299×299 像素图像本文网络与其他卷积神经网络分类性能的对比

类别	精确率/%					召回率/%				
	Net-1	Net-2	Net-3	Net-4	本文网络	Net-1	Net-2	Net-3	Net-4	本文网络
腈纶	96.85	97.28	93.48	74.89	90.98	96.85	97.07	97.51	84.44	96.10
棉	94.99	96.09	95.60	79.24	93.28	95.11	94.93	97.39	71.79	94.09
涤纶	92.18	92.18	93.91	62.30	89.77	94.46	95.70	96.00	73.84	90.92
天丝	96.96	97.17	99.37	85.13	97.70	96.56	97.38	95.47	81.14	93.96
羊毛	98.40	99.04	97.54	88.34	95.72	96.54	96.76	94.21	79.19	91.89

5 结 论

本文提出了基于卷积神经网络的面料主成分分类方法,实现了通过面料图像对其主成分进行分类。该方法避免了对检测面料的拆解,在一定程度上克服了传统方法在面料成分分类上的复杂性,简化面料成分分类工作,降低了检测过程对专业人员的依赖。从实验结果来看,本文提出的卷积神经网络以尽可能小的网络结构更高效地完成了面料成分分类工作,但与传统的机器学习分类器相比训练过程的计算量较大,耗时较长。在后续的工作中,将扩大面料图像库,从而进一步提高网络的泛化能力,并通过特征可视化技术探索卷积神经网络关注的图像特征,在图像预处理中对特征进行强化,进一步提升网络分类效率。

参考文献:

- [1] 杨欣卉. 近红外光谱在纤维成分含量定量分析中的应用研究进展[J].现代纺织技术,2017,25(2):37-42.
- [2] 胡觉亮.基于贝叶斯方法的织物分类研究[J].纺织学报,2004,25(1):48-49.
- [3] 应乐斌,戴连奎,吴俭俭,等.基于纤维纵向显微图像的棉/亚麻单纤维识别[J].纺织学报,2012,33(4):12-18.
- [4] 李彦冬,郝宗波,雷航.卷积神经网络研究综述[J].计算机应用,2016,36(9):2508-2515.
- [5] 景军锋,范晓婷,李鹏飞,等.应用深度卷积神经网络的织物缺陷检测[J].纺织学报,2017,38(2):68-74.
- [6] 张宏伟,张凌婕,李鹏飞.基于深度卷积神经网络的织物花型分类[J].纺织高校基础科学学报,2017,30(2):261-265.
- [7] 冀中,刘青,聂林红,等.基于卷积神经网络的纹理分类方法研究[J].计算机科学与探索,2016,10(3):389-397.
- [8] Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2002,12(7):629-639.
- [9] Howard A G, Zhu M, Chen B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[EB/OL].(2017-4-17)[2018-6-18].<https://arxiv.org/abs/1704.04861>.
- [10] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB/OL].(2016-4-30)[2018-6-18].<https://arxiv.org/abs/1511.07122>.
- [11] Selvaraju R R, Cogswell M, Das A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization [C]//2017 IEEE International Conference on Computer Vision (ICCV), Venice, Italy. IEEE Computer Society,2017:618-626.
- [12] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society,2016:2818-2826.
- [13] Szegedy C, Ioffe S, Vanhoucke V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C/OL]// AAAI Conference on Artificial Intelligence Thirty-First AAAI Conference on Artificial Intelligence,2017:4278-4284.(2016-2-4)[2018-6-18].<https://arxiv.org/pdf/1602.07261.pdf>.
- [14] Chollet F. Xception: Deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society,2017:1800-1807.

(责任编辑:康 锋)