

DOI: 10.13382/j.jemi.2017.08.022

基于改进 SAE 网络的织物疵点检测算法*

景军锋 党永强 苏泽斌 李鹏飞 张宏伟
(西安工程大学 电子信息学院 西安 710048)

摘 要:针对传统织物缺陷检测手工提取特征困难,疵点样本有限的问题,结合卷积自编码器(CAE),提出一种基于 Fisher 准则的栈式去噪自编码器算法(FSDAE)。首先从原始图像中截取若干小块图像,采用稀疏自编码器(SAE)训练,得到小块图像的稀疏性特征;其次利用该特征,初始化 CAE 网络参数,提取原始图像的低维特征;最后将该特征数据送入 FSDAE 网络进行疵点检测分类。分别对 3 类织物进行测试,实验结果表明,算法能够有效地提取织物图像的分类特征,且通过加入 Fisher 准则,提高了织物疵点的检测率。

关键词: 深度学习;卷积自编码器;Fisher 准则;缺陷检测

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Fabric defect detection algorithm based on improved SAE neural network

Jing Junfeng Dang Yongqiang Su Zebin Li Pengfei Zhang Hongwei
(School of Electronic and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: In this paper, with the combination of convolutional autoencoders (CAE), an algorithm named stacked denoising autoencoders based on Fisher criterion (FSDAE) is proposed to solve the problem of the difficulty of manual features extraction and the limitation of defect samples on traditional fabric defect detection. Firstly, the sparse autoencoder (SAE) is used to obtain the sparse characteristics of the small patches cut out from the original images. Secondly, the CAE network parameters are initialized by using the sparse characteristics and the low-dimensional features of the original image are extracted. Finally, the features data are sent to the FSDAE network for defect detection and classification. The experimental results show that the algorithm can effectively extract the classification characteristics of the fabric image, and the detection rate of the fabric defect is improved by adding the Fisher criterion.

Keywords: deep learning; CAE; Fisher criterion; defect detection

0 引 言

在纺织领域中,织物疵点检测是保障产品质量的关键环节。目前,多数企业仍然采用传统的人工视觉进行织物疵点检测,人工检测受工作环境和劳动强度的影响,检测效率低下。近年来,图像处理和计算机视觉技术迅猛发展^[1-2],利用该技术实现织物疵点自动检测^[3],已成为纺织工业生产的必然趋势。

现阶段,基于图像处理的疵点检测算法主要分为 6

类:统计法、频谱法、模型法、结构法、自学习法和基本图案法^[4-5]。频谱法是这一领域的研究热点。频谱法主要包括傅里叶变换、小波变换和 Gabor 变换等。傅里叶变换作为织物分析的经典方法,经常与其他算法结合使用进行织物疵点检测^[5-8]。Schneider 等人^[5]结合傅里叶变换、模板匹配和模糊聚类提出一种自动检测算法用于检测平纹和斜纹织物。文献[6]结合傅里叶分析和小波收缩提出一种无监督方法来检测具有周期性图案的织物,其优点是不需要参照图像。小波变换因其良好的局部时频特性在织物检测领域受到广泛关注^[9-12]。在检测具有

良好边缘的织物缺陷时效果较好,当缺陷与背景织物的灰度阶差异较小时,性能不佳。Gabor 滤波器具有优良的滤波性能以及与生物视觉系统相近的特点,也常用于织物疵点检测^[13-16]。但鉴于 Gabor 过滤器需在多尺度和多方向上进行图像滤波,计算量与计算复杂度较大,难以满足实时性要求。为降低计算复杂度,文献[14,16]利用遗传算法设计了最优 Gabor 滤波器,但其滤波器仅能在单一尺度和单一方向上执行滤波操作,致使算法整体性能下降。

织物缺陷分类的传统方法分为两个阶段:特征提取和特征识别。其中最关键的问题是设计可区分的疵点特征。空域中,常提取的图像特征主要包含 LBP 算子、HOG 算子、协方差矩阵和灰度共生矩阵等;频域中,傅里叶变换、小波变换以及 Gabor 变换等,这些变换系数通常作为图像的特征参数用于疵点分类。近年,神经网络也被用于织物缺陷检测与分类^[17-18]。文献[19]手工提取织物疵点的形状和灰度特征,利用 BP 神经网络进行本色布疵点分类。文献[20]提取织物的 LBP 特征,进而采用 SVM 进行织物疵点分类识别。

实际环境下,织物图像受光照强度、拍摄角度和机械结构等因素的影响,容易出现灰度不均匀和纹理扭曲等现象,且织物疵点种类繁多。因此,设计并提取鲁棒性较好且区别度较高的织物疵点特征较为困难。随着生物神经学和人类心理认知学逐渐被应用到图像高层语义特征的研究中来,深度学习得到进一步发展,并在图像检测和分类领域取得较好的效果^[21]。本文提出一种不同于传统的织物检测方法,利用深度学习网络模型自动提取织物图像特征,并进行织物疵点检测与分类。实验结果表明,此算法不仅能提高分类的准确性,且具有一定的普适性。

1 算法相关理论

传统的神经网络由输入层、输出层和一个单一的隐藏层组成,这称为浅层结构(即浅层网络)。在浅层结构中,神经网络逼近复杂函数的能力有限。与之相对的则被称为深层结构(即深层网络),其含有多个隐藏层。实践证明学习训练具有多个隐藏层的神经网络非常困难。Hinton 等人^[22]提出了逐层贪婪算法来初始化深层结构的权重,再利用传统 BP 算法训练神经网络,此情况才得以改善。

1.1 自动编码器

自动编码器(auto encoder, AE),由两个主要部分组成:编码器网络和解码器网络,结构如图1所示。编码器网络的目的是寻找一个给定输入的压缩表示,即数据的隐含特征,这种特征往往能更好的替代原始数据;解码器

网络则是利用压缩表示的数据还原和重构原始数据,使输出数据近似等于原始输入。由于输入数据通常使用无标签数据,因此自动编码器属于无监督学习方式。网络训练采用传统的反向传播算法。




图1 自编码器

Fig.1 Auto encoder

假设 $x \in [0,1]^d$ 为输入向量, $y \in [0,1]^d$ 为 x 的近似表示,则传统的自编码器模型定义如下:

$$z = f_{\theta}(x) = s(Wx + b) \quad (1)$$

$$y = g_{\theta'}(z) = s(W'z + b') \quad (2)$$

式中: $z \in [0,1]^d$ 代表隐藏层的输出, W 代表一个 $d \times d'$ 的权值矩阵, b 表示偏置项, $S(\cdot)$ 表示 sigmoid 函数。要获得 x 最有效的近似,通常要求损失函数的函数值最小,损失函数定义如下:

$$L(x, y) = \|x - y\|^2 \quad (3)$$

1.2 稀疏自编码

在自编码器的基础上,对编码数据加入一定的稀疏性限制,构成稀疏自编码器(spare autoencoder, SAE),如图1所示。稀疏性限制要求每次得到的编码数据尽量稀疏,即约束编码数据中大部分数据为0,少数数据为非0,这称为数据的稀疏性表示。稀疏性表示的数据通常更为有效,研究表明人脑神经元在接受某一刺激后,其中只有少数神经元处于兴奋状态,多数神经元受到抑制。

1.3 降噪自编码

降噪自编码器(denoising auto encoder, DAE),是在自编码器的基础上,对输入数据随机加入噪声,再对加噪后的数据进行编码与解码,要求解码后得到的输出数据尽可能保有原始输入数据的所有信息。显然,对于加噪后的输入,输出能够较好地重构出原始输入,表明网络具有更强的健壮性和鲁棒性。降噪自编码器原理如图2所示。

加入噪声的两种常用方式:1)加入高斯噪声, $\tilde{x} = x + \varepsilon$, $\varepsilon \in N(0, \sigma^2 I)$ 。2)加入二值掩模噪声,即按照一定比例,将 x 中的部分数据随机赋值为0。

DAE 是传统 AE 的改进模型,其定义如下:

$$z = f_{\theta}(\tilde{x}) = s(W\tilde{x} + b) \quad (4)$$




图2 降噪自编码器

Fig.2 Denoising AutoEncoder

$$y = g_{\theta'}(z) = s(W'z + b') \quad (5)$$

式中： x 表示原始输入数据， $\tilde{x}$ 表示加入噪声后的数据， z 是 $\tilde{x}$ 由式(4)得到的激活值， y 是 z 通过式(5)对原始输入的重构。损失函数同式(3)。

1.4 卷积自编码

卷积自编码(convolutional auto encoders, CAE), 与传统 AE 不同, 其最大的优势在于局部感知和权重共享。局部感知可以保留图像的空间位置信息; 权值共享则能极大地降低训练参数。其结构如图3所示。




图3 CAE 卷积与池化过程

Fig.3 Convolution and pooling process of CAE

1.5 栈式降噪自编码

栈式降噪自编码(stacked denoising auto encoder, SDAE), 即将多个 DAE 堆叠起来, 组成一种深度模型结构, 通常将多个训练好的 DAE 的权值参数用于 SDAE 参数的初始化, 其结构如图4所示。采用深度模型的原因: 深度模型具有强大的表达复杂函数的能力, 在提取有效特征方面明显优于浅层模型, 且多层提取的特征比浅层提取的特征更形象、更具有代表意义^[24]。




图4 栈式自编码器

Fig.4 Stacked AutoEncoder

假设有一组 n 个样本的训练数据集 $\{(x^{(1)}, y^{(1)}), \dots, (x^{(n)}, y^{(n)})\}$, 整个网络通过标准 BP 算法进行训练求解损失函数的最小值, 损失函数定义如下:

$$J_{(w,b)} = \frac{1}{n} \sum_{i=1}^n \left(\frac{1}{2} \|h_{w,b}(x^{(i)} - y^{(i)})\|^2 \right) \quad (6)$$

1.6 基于 Fisher 准则的 SDAE

当样本有限时, 深度学习的效果不佳, 基于此事实, 提出基于 Fisher 准则的 SDAE (FSDAE), 结构如图4所示, 但其损失函数与 SDAE 不同, 定义如下:

$$J_{(w,b)} = \frac{1}{n} \sum_{i=1}^n \left(\frac{1}{2} \|h_{w,b}(x^{(i)} - y^{(i)})\|^2 \right) + \lambda \frac{J_{\text{intra}}}{J_{\text{inter}}} \quad (7)$$

式中: λ 是比例系数, $\frac{J_{\text{intra}}}{J_{\text{inter}}}$ 表示特征空间中的 Fisher 准则。假设样本有 L 个类别, 每类有 m_i 个样本, $i = 1, 2, \dots, L$ 。类间距 J_{intra} , 类内距 J_{inter} 分别定义如下:

$$J_{\text{intra}} = \frac{1}{2} \sum_{i=1}^L \sum_{k=1}^{m_i} \|h_{w,b}(x) - M^{(i)}\|^2 = \frac{1}{2} \sum_{i=1}^L \sum_{k=1}^{m_i} \sum_{j=1}^s (a_j^{(k,n_i)} - M_j^{(i)})^2 \quad (8)$$

$$J_{\text{inter}} = \frac{1}{2} \sum_{i=1}^L \sum_{j=i+1}^L \|M^{(i)} - M^{(j)}\|^2 \quad (9)$$

式中: $h_{w,b}(x)$ 表示网络的输出值, $a_j^{(k,n_i)} = f(z_j^{(k,n_i)})$ 表示第 n_i 层第 j 个神经元的激活值。 $M^{(i)}$ 表示第 i 类样本的平均值, 定义如下:

$$M^{(i)} = \frac{\sum_{k=1}^{m_i} a_j^{(k,n_i)}}{m_i} \quad i = 1, 2, \dots, L \quad (10)$$

最小化式(7)中的 Fisher 准则项, 可以减小类内距, 增加类间距。最后通过批量梯度下降算法求解整个网络的最优化参数。

2 基于 FSDAE 的织物疵点检测

FSDAE 算法流程如图5所示。




图5 算法流程

Fig.5 Flow chart of algorithm

疵点检测主要分为3个步骤: 1) 从原始图像中截取若干小块图像, 采用 SAE 训练, 得到小块图像的稀疏性

特征;2)利用该特征,初始化 CAE 网络参数,提取原始图像的低维特征;3)将该特征数据送入 FSDAE 网络进行斑点检测与分类。

2.1 数据集获取

实验数据来源:1)TILDA 数据库织物,如图 6 所示;2)工业现场采集的玻璃纤维织物(玻纤),如图 7 所示;3)手工采集的无纺布口罩图像,如图 8 所示。




图 6 TILDA 数据库
Fig. 6 Data base of TILDA




图 7 玻纤织物
Fig. 7 Data of fiberglass




图 8 无纺布口罩
Fig. 8 Data of non-woven mask

2.2 训练 SAE

SAE 包含一个输入数据层,一个编码数据层(隐含层)和一个输出数据层,如图 1 所示。具体训练步骤如下:

1)构建训练集,训练集是由原始图像随机截取的小块图像(通常取 8×8)构成,如图 9 所示;




图 9 截取的小块图像
Fig. 9 The cut patches images

2)对小块图像进行 ZCA 白化处理,降低数据的内部相关性减少冗余;

3)随机初始化网络参数,然后将白化后的数据送入 SAE 网络的输入数据层;

4)输入层的数据通过式(1),得到隐含层的值;

5)隐含层的数据通过式(2),得到输出层的值;

6)利用反向传播算法进行训练微调,求解式(3)的最小值,训练过程如图 10 所示。




图 10 TILDA 训练过程
Fig. 10 The training process of TILDA

通过图 1 所示的网络结构,可训练出所有的权值和偏差参数。网络学习到的特征如图 11 所示。




图 11 小图特征可视化
Fig. 11 Feature visualization of patches

图 10 可看出,随着迭代次数增加,网络的损失函数值逐渐减小,前期下降较快,后期则趋于平缓。原因在于:前期网络误差较大,算法调节速度较快;后期误差减小,算法调节力度变小。

图 11 可看出,针对 TILDA 织物图像和口罩图像,网络主要学习到图像的角点、边缘等特征。有研究表明:该特征提取过程符合人类大脑的学习过程。

2.3 训练 CAE

CAE 包含一个输入层、一个卷积层和一个池化层,如图 3 所示。具体训练步骤如下:

1)输入源样本图像;

- 2) 利用上述提取的局部特征(图 11),对整幅图像进行卷积操作,卷积核的大小与小块图像的大小一致;
- 3) 对卷积后的图像进行平均池化处理,得到每幅原图的特征描述,如图 12 所示。




图 12 原图特征可视化

Fig. 12 Feature visualization of original images

原图特征构成的向量数据集及图像类别标签用于训练 FSDAE 与 softmax 分类器。

2.4 训练 FSDAE

FSDAE 包含 1 个输入层、3 个隐含层和 1 个 softmax 分类器,如图 4 所示,结构大小为 $[A\ 400\ 200\ 100\ C]$,其中, A 为 CAE 提取的特征数据集的维数, C 为分类个数。训练分为两阶段进行:预训练和微调。

- 1) 预训练:特征数据集送入网络输入层,每个自编码器利用反向传播算法以无监督的方式进行训练;
- 2) 微调:训练得到的权值与偏差参数初始化 FSDAE 网络,FSDAE 通过带标记的数据集以监督学习的方式进行训练微调,最后输出分类结果。算法训练过程如图 13 所示。




图 13 FSDAE 训练过程

Fig. 13 The training process of FSDAE algorithm

3 实验结果与分析

实验运行环境:CPU Intel(R) Core(TM) i5-4460 @

3.2 GHz;内存为 8 GB;程序代码使用 MATLAB-2014a 编写运行。

实验采取先检测后分类的原则,即:正常样本与疵点样本各为一类,先使用算法进行 2 分类来判断图像有无疵点;再针对检测出来的疵点图像进行疵点分类,从而减少正常样本的干扰,提高分类准确率。

3.1 TILDA 数据库织物

数据库中包含正常样本与疵点样本共 6 类,每类样本为 50 个,实验随机选取 80% 作为训练集,剩余 20% 作为测试集。为满足深度学习模型基本数据量的要求,分别对训练集和测试集图像进行镜像翻转等操作将样本数量扩充至原来的 8 倍^[25],并归一化图像大小为 128×128 。

为了全面评估算法的有效性,本文使用其他 2 种手工特征和普通 SDAE 进行织物疵点分类实验。选取的特征包括 LBP 特征和灰度共生矩阵(GLCM)。LBP 能提取纹理的局部信息,且具有旋转不变性,对光照不敏感的优势,常用于织物疵点分类。灰度共生矩阵通过统计图像的所有像素,来呈现其图像灰度的分布,也常用于提取织物图像的纹理特征。表 1 与 2 所示分别为检测与分类的结果。

表 1 检测准确率

Table 1 Detection accuracy		(%)		
	LBP + Softmax	GLCM + Softmax	SDAE	FSDAE
疵点	67.5	70.6	91.2	95.0

表 2 分类准确率

Table 2 Classification accuracy		(%)		
	LBP + Softmax	GLCM + Softmax	SDAE	FSDAE
破洞	40.2	51.0	80.1	83.2
油污	43.3	46.3	82.6	87.0
毛团	52.2	48.8	82.2	87.5
线条	43.6	53.4	83.2	86.3
褶皱	38.3	45.6	84.3	91.8
平均	43.52	49.02	82.48	87.16

表 1、2 纵向可看出,基于 SAE 的分类算法较传统手工提取特征的分类算法,其疵点检测准确率与分类准确率均有大幅度提升。传统算法与基于 SAE 的算法均采用 Softmax 作为分类器,可见由 SAE 自动提取的特征优于手工选取的特征,如图 11 所示。LBP 算子与 GLCM 均提取图像的灰度信息来构建图像特征,但由于 TILDA 织物灰度分度不均匀,纹理背景复杂,两种算子无法提取有效的分类特征。SAE 可以学习到输入到输出复杂的非线性映射,所提取的深度特征具有很强的鉴别能力,再加上对其进行了 3 级优化训练,使得识别准确率得到了进

一步提高。FSDAE 准确率高 于普通 SDAE,表明在损失函数中加入 Fisher 准则对算法准确率的提升有促进作用,原因在于 Fisher 准则可以增加类见距,减少类内距;横向可看出,四种算法疵点的检测准确率均高于其分类准确率的平均值。即算法更易判断疵点的有无,对于已检测出的疵点图像,其分类能力均有所下降。

3.2 玻璃纤维织物

收集工业现场采集样本 2 300 个,手工将其分为 6 类,其中正常样本 800 个,其余 5 类疵点样本均为 300 个。每类样本随机选取 75% 作为训练集,25% 为测试集。检测与分类结果如表 3、4 所示。

表 3 检测准确率

Table 3 Detection accuracy (%)

	SDAE	FSDAE
疵点	95.6	98.0

表 4 分类准确率

Table 4 Classification accuracy (%)

	SDAE	FSDAE
破洞	90.1	97.5
线条	86.6	93.0
油污	88.2	98.2
断经	85.2	93.5
缺纬	86.3	94.1
平均	87.28	95.26

表 3、4 可看出改进的算法,检测率与分类率均高于前述的 TILDA 数据库织物。经观测两种织物的差异,发现玻纤织物的背景纹理较为简单、统一,疵点信息更为突出。图 14 所示为两种不同类型织物的同类疵点图像,图像尺寸为 200 × 200。




图 14 两种不同类型织物的同类疵点图像
Fig. 14 Two different types of similar fabric defect images

本文采用灰度统计法来比较两种织物的纹理背景复杂度。列向灰度均值如图 15 所示,横向灰度均值如图 16 所示。

图 15、16 均表明,玻纤织物的灰度分布均呈现集中、




图 15 列向灰度均值
Fig. 15 The column gray mean




图 16 横向灰度均值
Fig. 16 The row gray mean

均匀的特点;TILDA 织物表现为分散、不规整。且玻纤织物油污的信息较 TILDA 织物更为突出。因此,FSDAE 对背景纹理简单、均匀,疵点信息较为明显的织物图像的检测与分类更有效。

3.3 无纺布口罩

实验室环境下,使用工业相机采集样本,并将样本数量扩充至 1 635 个,手工将其分为 4 类,如表 5 所示。

表 5 口罩样本划分

Table 5 Mask samples partition

	训练样本	测试样本	总数
正常	372	100	472
耳绳脱落	434	120	554
耳绳缺失	160	80	240
表面缺陷	289	80	369
总数	1 255	380	1635

依然采用训练集约 75%,测试集约 25% 的原则,实验直接进行分类,结果如表 6 所示。

表 6 FSDAE 分类混淆矩阵

Table 6 Classification confusion matrix of FSDAE

%	正常	耳绳脱落	耳绳缺失	表面缺陷
正常	75.6	1.3	0	23.1
耳绳脱落	1.2	94.1	2.5	2.2
耳绳缺失	0	2	98.0	0
表面缺陷	19.1	1.2	0.5	79.2

表6出现分化现象,即耳绳缺失和耳绳脱落两类疵点图像识别率较高,而其余两类疵点识别率较低。实验中发现:表面缺陷此类图像经归一化过程(包括灰度归一化,尺寸变化等),疵点信息减少,与正常图像相似度增高,导致这两类图像错分率增加,其余两类图像则影响较小,这表明算法对于疵点信息较少的样本难以有效分类。实验中,为最大保留疵点信息,图像尺寸不缩减(200×200),但这样导致训练参数极具增大,算法无法有效运行,因此需要探索更为有效的方法。

深度学习算法通常对数据量有较为苛刻的要求,一般认为训练数据越多分类精度越高,但在实际生产过程中,负面样本数据的收集比较困难,因此有必要探讨口罩样本数目对分类准确率的影响。

实验合理选取不同的样本数目对一般 SDAE 和 FSDAE 算法进行验证。分类结果如图17所示。




图17 口罩分类柱状图

Fig. 17 The histogram of mask classification

图17可看出当样本数目较少时,算法的识别率很低。深度学习算法是一般神经网络的深度结构,其本质依然是通过一定的网络模型学习图像的分类界面。当训练样本过少,学习参数过多时,网络无法充分学习图像的分类规则,准确率很低,参考意义不大;当增加样本数目时,网络学习图像分类的充分性和有效性增加,准确率也随之提升;当网络训练到一定阶段时,增加样本数目,网络参数的调节力度减小,准确率的提升也有所减小。图17也可看出在使用同等样本数目的图像进行网络学习时,加入Fisher准则的SDAE算法的准确率高于一般的SDAE,表明在一定样本数目下,Fisher准则对算法的分类性能有所提升。

4 结论

本文提出的基于Fisher准则的栈式去噪自编码器算法,目的是自动提取织物缺陷的特征,解决人工选取特征的困难。并且在缺陷样本有限的情况下,能有效地检测

和分类疵点。实验结果表明,FSDAE算法能有效地提高织物的检测率,且可以通过调整少量参数,检测分类不同类型的织物图像,具有一定的普适性。

此外,FSDAE的缺点也较为明显,即针对纹理背景复杂,疵点信息较少的织物图像检测效果不理想。今后将改进算法以解决上述问题,并探讨如何将此方法整合到自动缺陷检查系统中。

参考文献

- [1] 王爽, 潘静. 一种基于颜色与纹理特征的图像模糊检索算法[J]. 电子测量技术, 2014, 37(2): 54-57.
WANG SH, PAN J. An fuzzy image retrieval method based on color and texture feature [J]. Electronic Measurement Technology, 2014, 37(2): 54-57.
- [2] 刘斌, 乔双梁, 魏艳萍. 基于采样三通道不可分小波的多光谱图融合[J]. 仪器仪表学报, 2015, 36(3): 645-653.
LIU B, QIAO SH L, WEI Y P. Multi-spectral image fusion method based on subsampled three channel nonseparable wavelets [J]. Chinese Journal of Scientific Instrument, 2015, 36(3): 645-653.
- [3] 景军锋, 赵娟. 基于Mean Shift滤波的织物疵点检测方法[J]. 电子测量与仪器学报, 2016, 30(5): 739-746.
JING J F, ZHAO J. Fabric defect detection based on Mean Shift filtering [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(5): 739-746.
- [4] NGAN H Y T, PANG G K H, YUNG N H C. Automated fabric defect detection: A review [J]. Image and Vision Computing, 2011, 29(7): 442-458.
- [5] SCHNEIDER D, MERHOF D. Blind weave detection for woven fabrics [J]. Pattern Analysis and Applications, 2015, 18(3): 725-737.
- [6] HU G H, ZHANG Q H, ZHANG G H. Unsupervised defect detection in textiles based on Fourier analysis and wavelet shrinkage [J]. Applied Optics, 2015, 54(10): 2963-2980.
- [7] ELDESSOUKI M, HASSAN M, QASHQARY K, et al. Application of principal component analysis to boost the performance of an automated fabric fault detector and classifier [J]. Fibres and Textiles in Eastern Europe, 2014, 22(22): 51-57.
- [8] MALEK A S, DREAN J Y, BIGUE L, et al. Optimization of automated online fabric inspection by fast Fourier transform (FFT) and crosscorrelation [J]. Textile Research Journal, 2013, 83(3): 256-268.
- [9] ZHU B, PAN R, GAO W, et al. Seam detection of inhomogeneously textured fabrics based on wavelet

- transform[J]. Textile Research Journal, 2015, 85(13): 1381-1393.
- [10] LI P, ZHANG H, JING J, et al. Fabric defect detection based on multi-scale wavelet transform and Gaussian mixture model method [J]. Journal of the Textile Institute, 2014, 106(6): 1-6.
- [11] HU G H, ZHANG G H, WANG Q H. Automated defect detection in textured materials using wavelet-domain hidden Markov models[J]. Optical Engineering, 2014, 53(9): 093107.
- [12] WEN Z, CAO J, LIU X, et al. Fabric defects detection using adaptive wavelets [J]. International Journal of Clothing Science and Technology, 2014, 26(3): 202-211.
- [13] CELIK H, TOPALBEKITOGLU M, DÜLGER L. Real-time denim fabric inspection using image analysis[J]. Fibres Textiles in Eastern Europe, 2015, 23(3): 85-90.
- [14] HU G H. Automated defect detection in textured surfaces using optimal elliptical Gabor filters[J]. Optik, 2015, 126(14): 1331-1340.
- [15] BISSI L, BARUFFA G, PLACIDI P, et al. Automated defect detection in uniform and structured fabrics using Gabor filters and PCA [J]. Journal of Visual Communication and Image Representation, 2013, 24(7): 838-845.
- [16] JING J F, YANG P P, LI P F, et al. Supervised defect detection on textile fabrics via optimal Gabor filter[J]. Journal of Industrial Textiles, 2013, 44(1): 40-57.
- [17] CELIK H I, DÜLGER L C, TOPALBEKITOGLU M. Fabric defect detection using linear filtering and morphological operations[J]. Indian Journal of Fibre & Textile Research, 2014, 39(3): 254-259.
- [18] CELIK H I, DÜLGER L C, TOPALBEKITOGLU M. Development of a machine vision system: Real-time fabric defect detection and classification with neural networks [J]. Journal of the Textile Institute, 2014, 105(6): 575-585.
- [19] 汪敏, 王亦红. 神经网络在织物疵点分类识别中的应用[J]. 计算机工程与设计, 2016, 37(1): 221-225.
WANG M, WANG Y H. Application of neural network in classification of fabric defect recognition[J]. Computer Engineering and Design, 2016, 37(1): 221-225.
- [20] 付蓉, 石美红. 基于自适应 LBP 和 SVM 的织物疵点检测算法 [J]. 计算机应用, 2010, 30(6): 1597-1601.
FU R, SHI M H. Fabric defect detection based on adaptive LBP and SVM [J]. Journal of Computer Applications, 2010, 30(6): 1597-1601.
- [21] 曲景影, 孙显, 高鑫. 基于 CNN 模型的高分辨率遥感图像目标识别[J]. 国外电子测量技术, 2016, 35(8): 45-50.
- QU J Y, SUN X, GAO X. Remote sensing image target recognition based on CNN [J]. Foreign Electronic Measurement Technology, 2016, 35(8): 45-50.
- [22] HINTON G E, OSINDERO S, THE Y W. A fast learning algorithm for deep belief nets [J]. Neural Computing, 1989, 18(7): 1527-1554.
- [23] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders [C]. 25th International Conference on Machine Learning, 2008: 1096-1103.
- [24] 邓俊锋, 张晓龙. 基于自动编码器组合的深度学习优化方法[J]. 计算机应用, 2016, 36(3): 697-702.
DENG J F, ZHANG X L. Deep learning algorithm optimization based on combination of auto-encoders[J]. Journal of Computer Applications, 2016, 36(3): 697-702.
- [25] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [C]. International Conference on Neural Information Processing Systems, 2012, 25(2): 1097-1105.

作者简介



景军锋, 1978 年出生, 毕业于西安工程大学, 现任西安工程大学副教授。目前主要研究方向为数字图像处理、模式识别等。

E-mail: jingjunfeng0718@sina.com

Jing Junfeng was born in 1978, graduated from Xi'an Polytechnic University.

And he is associate professor in Xi'an Polytechnic University now. His main research interests include digital image processing, and pattern identification and so on.



党永强, 1992 年出生, 毕业于西安工程大学, 现为西安工程大学研究生, 目前主要研究方向为数字图像处理, 深度学习等。

E-mail: 18729984513@163.com

Dang Yonaqiang was born in 1992, graduated from Xi'an Polytechnic University.

And he is M. Sc. candidate in Xi'an Polytechnic University now. His main research interest includes digital image processing, and deep learning and so on.



苏泽斌, 1989 年出生, 毕业于西安工程大学, 现任西安工程大学助理工程师, 目前研究方向为机器学习与模式识别。

E-mail: 247173903@qq.com

Su Zebin was born in 1989, graduated from Xi'an Polytechnic University. And he is

an assistant engineer in Xi'an Polytechnic University now. His main research interest includes machine learning, and pattern identification and so on.



李鹏飞,1962 年出生,分别在 1988 年和 1991 年于西安工程大学获得学士学位和硕士学位,现为西安工程大学教授。目前的研究领域包括数字图像处理,模式识别,电气控制系统,以及印染设备。
E-mail:aiyahooo@sina.com

Li Pengfei was born in 1962, received B. Sc. and M. Sc. from Xi'an Polytechnic University in 1988 and 1991, respectively.

And he is professor in Xi'an Polytechnic University now. His main research interests include digital image processing, and pattern identification and so on.



张宏伟,1983 年出生,博士,现任西安工程大学讲师,目前研究方向为图像处理与机器视觉。
E-mail: zhanghongwei@zju.edu.cn

Zhang Hongwei was born in 1983, Ph. D., and he is lecturer in Xi'an Polytechnic University now. His present research interests include digital image processing, machine vision and so on.

NI 宣布其 MIMO 应用框架新增多天线 UE 支持,进一步助力 5G 研究

NI(美国国家仪器公司,National Instruments,简称 NI)近日宣布其 LabVIEW Communications MIMO 应用程序框架增加了多天线用户设备(UE)支持。这使得 MIMO 应用框架成为全球唯一的商用物理层参考设计,为真正的大规模 MIMO 原型验证提供了强大的助力,超越了单独上位机处理系统,实现了全面的功能性 5G 部署。

无线研究人员可以将 MIMO 应用程序框架与 NI 软件无线电硬件结合使用,对各种 MIMO 研究课题(包括多用户 MIMO、单用户 MIMO 和大规模 MIMO)进行实时无线实验。这一多 FPGA 物理层参考设计提供了详细完整的 LabVIEW Communications 源代码文档,可完全重新编写或修改,最大程度降低您在系统集成或系统设计的工作,并创建完整的多天线设备网络。

研究人员现在不仅可以探索基站端的波束成形技术,而且也可以探索 UE 端的波束形成技术,以进一步提高整体网络吞吐量,扩展小区覆盖范围,减少干扰等。MIMO 应用程序框架支持超过 1.5 Gb/s 的最大网络吞吐量、灵活且可重新配置的基于时分双工的帧结构以及全

双向通信链路,随时可用于进行大规模 MIMO 实验并无缝集成自定义信号处理算法,而且时间相比其他方法要快得多。

作为 NI RF/通信领先用户计划的成员,瑞典隆德大学的无线研究人员已经使用 NI 灵活的原型验证平台来进行 5G 研究,而且最近展示了大规模 MIMO 在步行和驾车等移动环境中的可行性。

“大规模 MIMO 已经成为领先的 5G 技术之一,有望提供前所未有的高频谱效率,这对于支持未来几年预计大幅增加的无线设备至关重要,”IEEE 会士(IEEE Fellow)兼隆德大学无线电系统教授 Fredrik Tufvesson 表示,“NI MIMO 应用框架提供了所需的硬件和软件功能,使用户不仅可以探索大型 MIMO 基站的波束成形技术,而且可以在多天线 UE 环境中进行探索,以进一步提高 5G 网络的整体系统性能。

如需了解更多关于 MIMO 应用程序框架的信息,请访问 www.ni.com/sdr/mimo。