

基于卷积神经网络的短切毡缺陷分类

卓东, 景军锋*, 张缓缓, 苏泽斌

西安工程大学电子信息学院, 陕西 西安 710048

摘要 基于卷积神经网络,提出了短切毡缺陷分类的方法。通过旋转、平移和翻转对数据集进行扩充,解决了小数据样本在深度卷积神经网络中的过拟合问题;利用迁移学习的思想加速网络收敛,提高了网络的泛化能力;对比了不同网络结构并选择较好的网络进行数据集验证。结果表明,所提方法能够实现短切毡缺陷的有效分类,准确率为 93%。

关键词 图像处理; 卷积神经网络; 缺陷分类; 泛化能力; 短切毡

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/LOP56.101009

Classification of Chopped Strand Mat Defects Based on Convolutional Neural Network

Zhuo Dong, Jing Junfeng*, Zhang Huanhuan, Su Zebin

School of Electronic Information, Xi'an Polytechnic University, Xi'an, Shaanxi 710048, China

Abstract In this study, a classification method of chopped strand mat defects based on convolutional neural network is proposed. In the proposed method, the rotation, translation, and inversion are employed to expand the dataset for solving the overfitting problem caused by the small data samples in the deep convolutional neural networks. Transfer learning is employed to improve the convergence speed and generalization ability of the network. Further, the different network structures are compared, and the most optimal network structure is used to verify the database. The experimental results demonstrate that the proposed method can effectively classify the chopped strand mat defects with an accuracy rate of 93%.

Key words image processing; convolutional neural network; defect classification; generalization ability; chopped strand mat

OCIS codes 100.5010; 100.2000; 150.1135

1 引言

玻璃纤维短切原丝毡简称为短切毡,是将玻璃纤维原丝切成一定长度的短切纤维后,无定向均匀分布,通过黏接剂黏结而成的玻璃纤维无纺毡制品^[1]。短切毡厚薄均匀,硬度适中,柔韧性好,具有良好的机械力学性能和化学性能,可广泛应用于复合材料行业的玻璃纤维制品中^[2],如板材、采光板和浴缸等。在短切毡的生产过程中,不可避免地会出现分散不良、纱结、并条和异物等缺陷。在质量检测过程中,统计短切毡缺陷的数目并分析缺陷形成的

原因,有针对性地进行生产指导,对提高产品质量具有重要意义。

传统人工检测方法具有一定的主观性,劳动成本高、效率低。早期的缺陷分类由于受到数据集和计算机性能的制约,多采用支持向量机(SVM)、多层感知机等分类器。近年来,随着数据集的扩大和网络结构的优化,卷积神经网络被广泛应用于解决图像分类问题^[3-5]。Jing 等^[6]应用卷积神经网络对色织物缺陷进行检测,提高了检测效率。方旭等^[7]结合均值漂移分割与全卷积神经网络对高分辨遥感影像进行分类,与传统方法相比,该方法的精度明显

收稿日期: 2018-10-29; **修回日期:** 2018-12-07; **录用日期:** 2018-12-14

基金项目: 国家自然科学基金(61301276)、陕西省重点研发计划(2017GY-003)、陕西省高校科协青年人才托举计划项目(20180115)、陕西省教育厅科研计划项目(18JK0338)

* **E-mail:** jingjunfeng0718@sina.com

高于传统的机器学习方法。来文豪等^[8]利用激光诱导荧光技术获取白酒的荧光光谱,结合深度学习算法对光谱图像进行分类,能够准确区分白酒的品牌和度数。以上研究表明,卷积神经网络在色织物图像、高分辨遥感影像、荧光光谱图像分类上均有良好的表现效果。

为了提高短切毡缺陷图像的分类效果,避免人为设计提取特征的复杂性和局限性,本文采用卷积神经网络对缺陷图像进行特征提取,通过对数据集进行分类和增广,修改网络结构的全连接层,利用随机梯度下降法和交叉损失函数对网络参数进行迭代更新,训练网络模型,并在多个网络模型上训练数据集,对比模型的性能,选择训练效果较好的网络结构进行数据测试,计算混淆矩阵和网络性能评价指标。

2 卷积神经网络与迁移学习

2.1 卷积神经网络

LeCun 等^[9]提出卷积神经网络,它是一种带有卷积结构的前馈神经网络,具有权值共享、局部连接和非线性激活等特点。通过多层卷积层进行特征选择与提取,避免了传统方法提取特征的局限性。卷积神经网络主要由输入层、卷积层、激活层、池化层、全连接层和输出层组成。卷积层旨在学习输入数据的特征,由多个卷积核组成,用于计算不同的特征映射。卷积层使用多个卷积核对输入图片进行特征提取,再利用激活函数对特征图谱进行非线性处理,得到新的特征映射并作为下一层的输入。第 l 层卷积的特征图谱中,第 t 张特征图 m_t 在 (i, j) 位置的特征值可表示为

$$z_{i,j}^{(l)} = \sum_{i \in m_t} x_{i,j}^{(l-1)} \times w_{ij}^{(l)} + b_j^{(l)}, \quad (1)$$




图1 卷积神经网络模型结构

Fig. 1 Architecture of convolutional neural network model

2.2 迁移学习

在深度学习中,为了使训练得到的网络模型满足准确性和可靠性的要求,训练过程中要求训练集与测试集满足独立分布;训练样本必须足够大,能够拟合网络参数。当直接将小样本数据集输入到卷积

式中: l 为卷积层数; m_t 为第 t 张特征图谱; $w_{ij}^{(l)}$ 和 $b_j^{(l)}$ 为 l 层卷积核的权值和偏置值, $x_{i,j}^{(l-1)}$ 为 $l-1$ 层输入区域 (i, j) 的中心像素位置。激活函数使得卷积神经网络具有拟合非线性的能力,用 $f(\cdot)$ 表示激活函数。典型的激活函数包括 sigmoid, tanh 和 ReLU。卷积特征 $z_{i,j}^{(l)}$ 的激活值可表示为

$$a_{i,j}^{(l)} = f(z_{i,j}^{(l)}). \quad (2)$$

池化过程又称为下采样过程或二次采样过程,利用局部连接的相关性原理,减少后续网络层的计算量,并防止过拟合。将图像某一区域用最大值代替,称为最大池化;如果采用平均值,则为平均池化^[10]。池化层具有移位、旋转不变性,通常位于两个卷积层之间,促使网络快速收敛。输入特征图谱尺寸为 (H_{in}, W_{in}) ,经过卷积和池化后的输出尺寸为 (H_{out}, W_{out}) ,两者的关系为

$$H_{out} = \frac{H_{in} + 2 \times p - k}{s} + 1, \quad (3)$$

$$W_{out} = \frac{W_{in} + 2 \times p - k}{s} + 1, \quad (4)$$

式中: p 为特征图的边缘填充; s 为滑动窗口的步长; k 为卷积核尺寸。

在多个卷积和池化层之后通常用一个全连接层将前一层的特征图谱连接成单列特征图,构成全局语义信息^[11],将二维特征用一维特征向量表示,输入到 Softmax 分类器^[12]或者 SVM^[13]进行不同类别分类。最后一层的全连接层与输出层连接。基于卷积神经网络的短切毡缺陷分类网络模型结构如图1所示,由2个卷积层、2个池化层和3个全连接层组成,利用 Softmax 对最后一层全连接层的输出数据进行处理,得到输入数据对应每种缺陷的概率,确定缺陷种类。

神经网络模型中进行训练时,由于受到数据集的限制,会产生欠拟合现象,训练集精度高,但测试集的精度较低。为提高网络的泛化能力,采用迁移学习的策略在图像分类领域已取得巨大成功^[14-15]。将深度卷积神经网络从大规模数据集中训练学习到的图

像分类共性的知识,迁移到短切毡缺陷分类中,有助于加快小规模数据模型的收敛速度。

图像底层特征由边缘、纹理和颜色等细节组成,因此,对于图像分类问题,卷积神经网络模型的特征抽象能力是可以共用的。在短切毡的缺陷分类任务中,使用参数迁移的方法将原网络结构对特征提取的能力作为先验知识应用于短切毡数据集,对原网络结构的全连接层进行调整,使模型满足短切毡缺陷的分类要求。

简单的参数迁移方式通过修改分类层的输出类别,保留源模型的提取能力,当目标与样本不被包含在源数据集时,通常会出现网络拟合不够、准确率低等问题。神经网络微调是将预训练参数用于网络参数的初始化,迁移网络原有的学习能力,包括矩阵权重、偏置项等参数,对网络全连接层进行修改,满足不同的分类场景,通常能够在较少的迭代步骤中更新到最优值,提高模型的全局概括能力和训练时间。

2.3 训练卷积神经网络

训练卷积神经网络的目的在于确定网络权重参数,使网络输出值尽可能接近目标值。通过比较网络的输出值和目标值之间的误差,采用梯度下降法^[16]不断地迭代更新网络结构参数,降低输出值与目标值之间的差异。网络的训练过程如图 2 所示,包含前向传播(FP)和反向传播(BP)两个过程。

1) FP 阶段。从训练样本数据集中随机选取一

个样本数据输入到网络结构中,通过卷积层和池化层进行特征选择与提取,结合非线性激活函数得到新的特征映射,信息经过逐层的变换传送到输出层,计算得到网络结构的输出。

2) BP 阶段。反向传播是一种常用于调整网络权重、最小化神经网络损失值的方法。利用损失函数计算网络模型的输出值与目标值之间的差异即损失值,结合随机梯度下降法和反向传播,按照极小化损失值的方法,对网络权值进行调整,实现网络参数的更新。

在卷积神经网络训练过程中,常用交叉熵损失评估网络的实际输出与目标值之间的接近程度,交叉熵损失函数为

$$C = -\frac{1}{N} \sum_x [y_i \ln y_o + (1 - y_i) \ln (1 - y_o)], \tag{5}$$

式中: x 为样本; N 为样本总数; y_i 为目标输出; y_o 为网络实际输出。当网络输出值与目标值接近时,交叉熵损失值接近于 0。

BP 算法是采用梯度下降法更新参数的标准训练方法,随机梯度下降算法是机器学习中应用最多的优化算法,针对小批量数据更新参数,有助于减少参数更新的差异,使网络具有更稳定的收敛性。收敛速度由学习率控制。常采用恒定的学习速率,在初始阶段给出稳定的收敛,在收敛速度减慢时降低学习率。

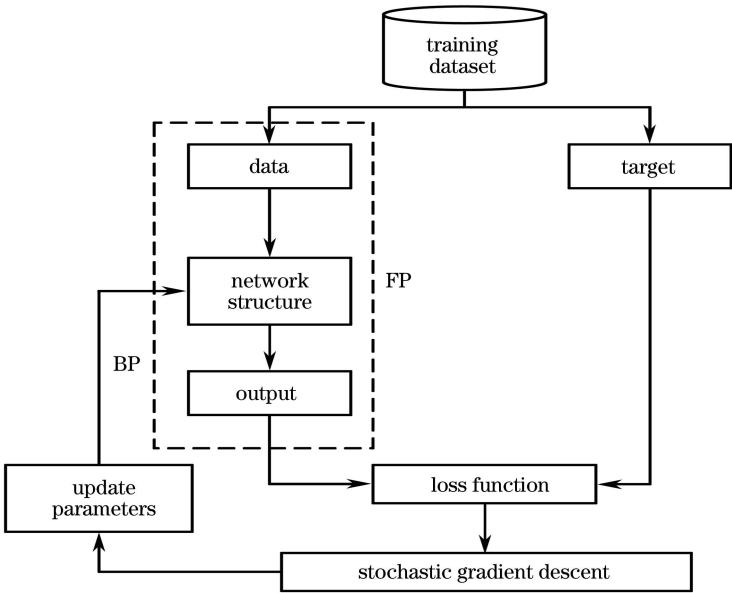


图 2 卷积神经网络训练过程

Fig. 2 Training process of convolutional neural network

3 实验平台与数据集

3.1 实验平台

实验环境采用 Ubuntu 操作系统, 处理器

Intel®CoreTMi7-6800K CPU@ 3.40 GHz×12, 内存 125.8 GiB, 显卡 GTX1080 Ti, 结合 Pytorch 深度学习框架完成实验。实验流程如图 3 所示。




图 3 实验流程

Fig. 3 Flow chart of experiment

3.2 数据集

实验数据来源于工厂实际生产, 使用工业相机采集短切毡样本图像, 得到短切毡样本数据库。目前, 工业上的短切毡缺陷主要有分散不良、并条、异物和纱结 4 种类型。利用 OpenCV 计算机视觉库, 通过旋转、平移和翻转等方法对获取的数据集进行扩充形成短切毡数据库, 共 5777 张, 各缺陷样本数量如图 4 所示, 图片尺寸为 224 pixel×224 pixel。部分样本如图 5 所示, 图 5(a)~(d)为并条样本, 图 5(e)~(h)为分散不良样本, 图 5(i)~(l)为纱结样本, 图 5(m)~(p)为异物样本。将数据集数量按 6 : 2 : 2 的比例分为训练集、验证集和测试集 3 部分, 训练集和验

证集用于网络训练, 测试集用于对训练好的网络进行性能评估。

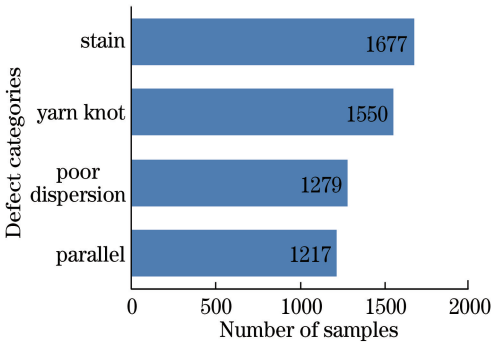


图 4 缺陷样本数量

Fig. 4 Number of defect samples




图 5 数据集样本。(a)~(d)并条;(e)~(h)分散不良;(i)~(l)纱结;(m)~(p)污渍

Fig. 5 Dataset samples. (a)-(d) Parallel; (e)-(h) poor dispersion; (i)-(l) yarn knot; (m)-(p) stain

4 实验结果及分析

4.1 参数设置

卷积神经网络的训练过程计算量大、耗费时间长, 为了提高深度学习模型的建模速度, 训练过程和测试均通过图形处理器(GPU)加速。网络采用交叉熵损失函数计算预测值和真实值之间的误差, 使

用随机梯度下降法对网络参数进行迭代更新。使用迁移学习的方法将短切毡数据集在多个网络结构上进行训练和验证, 网络全连接层替换为 4 分类的分类器, 卷积层和池化层保持卷积核大小、步长等参数不变, 即保留预训练模型的学习和提取特征的泛化能力。

从网络模型的训练过程中训练精度与迭代次数

曲线可知,当迭代步长接近 50 时,精度趋于稳定,将总迭代次数设置为 50;在模型训练过程中,通常在网络刚开始训练时,设置较大的学习率,随着迭代次数的增加,降低学习率,通过实验对比不同初始学习率和衰减策略对精度和损失值的影响,设置初始学习率为 0.01,步长为 10,衰减因子 γ 为 0.1,即每迭代 10 次学习率降低为上一次的 10%;在合理范围内,越大的批量数据会使下降方向越准确,但对电脑配置要求越高,对比不同批量数据对实验结果的影响,将 Batch_size 设置为 20。

4.2 对比参数初始化方法

在保留网络结构参数的基础上,网络模型的参数初始化通常有 2 种方式:1) 随机初始化网络参数,输入训练集和验证集进行网络训练;2) 对迁移网络结构在源数据集上的训练参数进行模型初始化。在 VGG19 网络模型上对比 2 种初始化方法在训练过程中训练精度、验证精度、训练损失值和验证损失值的变化,如图 6 所示,实线表示随机初始化网

络参数的训练过程,虚线表示微调网络参数的训练过程,实验结果如表 1 所示。每完成一次迭代,将验证集样本输入到网络结构中,记录验证集的准确率并将其作为评估该模型性能的依据。实验结果表明,第 1 种网络初始化方式,当迭代步数为 20 时,训练精度和验证精度趋于稳定,验证精度为 75%;第 2 种方式,当迭代次数为 10 时,网络的训练精度和验证精度基本达到最大值 86.5%,训练损失值和验证损失值达到最小。对迁移源数据集的训练参数进行网络训练能够更快拟合数据集且精度高。

表 1 参数初始化方法对比

Table 1 Comparison of initialization parameters				
Method	Training accuracy / %	Training loss	Verification accuracy / %	Verification loss
Randomly initialized	80.0	0.0270	75.0	0.032
Migration initialized	99.6	0.0016	86.5	0.023

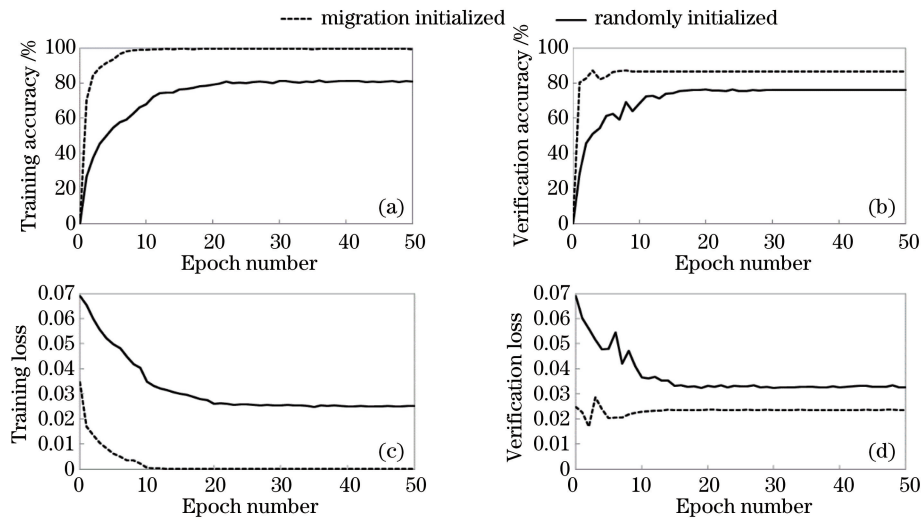


图 6 参数初始化方法对比。(a)训练精度;(b)验证精度;(c)训练损失值;(d)验证损失值
Fig. 6 Comparison of initialization parameters. (a) Training accuracy; (b) verification accuracy;
(c) training loss values; (d) verification loss values

4.3 微调网络参数

为了提高网络对数据集特征的提取能力,加速网络拟合过程,基于 4.2 节对网络 2 种初始化参数方式的对比,将网络在大样本数据集下的训练参数作为权值和偏置值,并进行初始化,对比 ResNet (residual neural network) 和 VGG (visual geometry group) 系列网络包括 ResNet18、ResNet50、ResNet101、VGG11、VGG16 和 VGG19 对短切毡缺陷数据的表现,进行 50 次迭代,记录每次迭代网络的训练精度、验证精度、训练损失值和验

证损失值,并统计网络的建模时间,实验结果如表 2 所示。

由表 2 可知,ResNet 网络中,与 ResNet18 和 ResNet101 网络相比,ResNet50 对短切毡的拟合能力较强;VGG 网络中,VGG19 的拟合能力强于 VGG11 和 VGG16。随着网络深度的增加,网络建模时间也随之增加;由于 ResNet 网络结构中存在残差模块,在建模时间上相比于 VGG 网络的建模时间相对较短。对比 ResNet50 和 VGG19 网络的训练结果过程,网络的训练误差、验证误差、训练

表 2 网络模型性能
Table 2 Model performances

Network structure	Training accuracy / %	Training loss	Verification accuracy / %	Verification loss	Modeling time / s
Resnet18	99.7	0.0019	84.6	0.026	350
Resnet50	99.9	0.0010	93.0	0.015	949
Resnet101	99.8	0.0058	85.6	0.022	1518
VGG11	99.2	0.0017	80.0	0.035	940
VGG16	99.4	0.0013	86.2	0.027	1629
VGG19	99.6	0.0016	86.5	0.023	1952

损失值和验证损失值变化过程如图 7 所示。ResNet50 在迭代 5 次之后开始趋于收敛且验证精度高于 VGG19,结果表明,ResNet50 能够更快更好地提取短切毡缺陷特征,验证精度达到 93%。

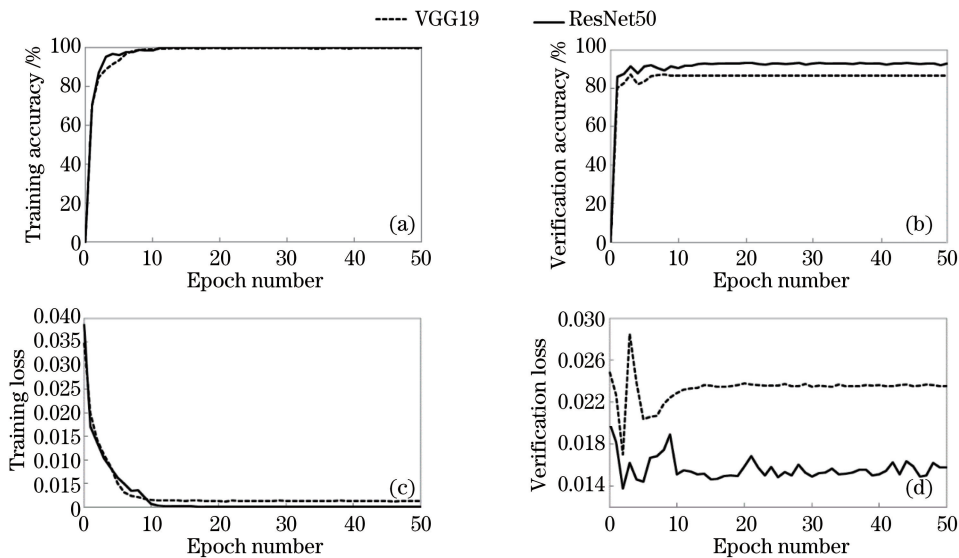


图 7 网络微调训练过程。(a)训练精度;(b)验证精度;(c)训练损失值;(d)验证损失值

Fig. 7 Training process of fine-tuning. (a) Training accuracy; (b) verification accuracy; (c) training loss values; (d) verification loss values

4.4 模型测试

为了评价卷积神经网络在短切毡图像分类方法的性能,基于对图 7 的分析,采用 ResNet50 训练网络模型进行测试数据集的验证。1)计算混淆矩阵,结果如表 3 所示,横坐标表示被预测短切毡数据的真实值,纵坐标表示数据的预测值。针对短切毡的 4 种缺陷,每类选取 260 张进行预测,每张的测试时间为 100 ms。2)计算该算法的分类精确率 P 、召回率 R 及 F_1 。 F_1 综合了 P 和 R 的判断指标, F_1 的取值范围为 0 到 1,1 表示效果最好,0 表示效果最差,对应计算公式为

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}, \tag{6}$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \tag{7}$$

$$F_1 = \frac{2 \times P \times R}{P + R}, \tag{8}$$

式中: N_{TP} 为被模型预测正确的正样本的数目; N_{FN} 为被模型预测错误的负样本的数目; N_{FP} 为被模型预测错误的正样本的数目; N_{TN} 为被模型预测正确的负样本的数目。

表 3 测试样本混淆矩阵

Table 3 Confusion matrix of test sample

Matrix		Predicted value			
		Parallel	Poor dispersion	Yarn knot	Stain
True value	Parallel	260	2	0	0
	Poor dispersion	0	257	15	0
	Yarn knot	0	1	243	0
	Stain	0	0	2	260

根据混淆矩阵中各缺陷类别的实际值与与预测值数据,应用(6)~(8)式计算各类缺陷的精确率、召回率及 F_1 ,计算结果如表 4 所示。

表4 网络性能评价指标
Table 4 Evaluation of network performances

Defect category	P	R	F_1
Parallel	1.00	0.99	1.00
Poor dispersion	0.99	0.94	0.97
Yarn knot	0.93	1.00	0.96
Stain	1.00	0.99	1.00

由表4可知,ResNet50网络使用微调的方式对短切毡数据集进行训练得到的网络参数,在并条和异物两种缺陷分类上表现最好, F_1 的值达到了1;在分散不良上表现较好,部分缺陷被误分类到并条和纱结类别上;针对纱结缺陷,表现效果较差,由于纱结部分表现不明显,易被误判为分散不良。

5 结 论

采用基于卷积神经网络的短切毡缺陷分类算法对缺陷图片进行分类。通过卷积神经网络自动提取织物缺陷特征,解决了人工提取特征不全面的问题;使用迁移学习和反向传播算法对数据集在多个网络结构上进行模型训练和特征提取,获取网络参数,选择拟合能力较好的网络进行测试,评估网络性能。实验结果表明,ResNet50能够更快更好地提取短切毡缺陷特征,并且验证精度可达到93%,能够实现数据集的有效分类。

参 考 文 献

[1] Deng H P, Bo S Q. Correlation offiberglass chopped strand mat strength with its binder[J]. Fiber Glass, 2015(2): 18-21.
邓和平, 薄圣泉. 玻璃纤维短切原丝毡中粘结剂和毡的强度关系[J]. 玻璃纤维, 2015(2): 18-21.

[2] Zhang J Y, Jing J F. Defect classification of chopped strand mats based on deep learning and piecewise linear interpolation[J]. Journal of Xi'an Polytechnic University, 2018, 32(5): 553-559.
张君扬, 景军锋. 基于深度学习和分段线性插值的短切毡缺陷分类[J]. 西安工程大学学报, 2018, 32(5): 553-559.

[3] Szegedy C, Liu W, Jia Y Q, *et al.* Going deeper with convolutions [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 7-12 June 2015, Boston, MA, USA. New York: IEEE, 15523970.

[4] Du J, Hu B L, Zhang Z F. Gastriccarcinoma classification based on convolutional neural network and micro-hyperspectral imaging [J]. Acta Optica

Sinica, 2018, 38(6): 0617001.

杜剑, 胡炳樑, 张周锋. 基于卷积神经网络与显微高光谱的胃癌组织分类方法研究[J]. 光学学报, 2018, 38(6): 0617001.

[5] Chu J H, Wu Z R, Lü W, *et al.* Breast cancer diagnosis system based on transfer learning and deep convolutional neural networks [J]. Laser & Optoelectronics Progress, 2018, 55(8): 081001.
褚晶辉, 吴泽蕤, 吕卫, 等. 基于迁移学习和深度卷积神经网络的乳腺肿瘤诊断系统[J]. 激光与光电子学进展, 2018, 55(8): 081001.

[6] Jing J F, Fan X T, Li P F. Patterned fabric defect detection via convolutional matching pursuit dual-dictionary[J]. Optical Engineering, 2016, 55(5): 053109.

[7] Fang X, Wang G H, Yang H C, *et al.* High resolution remote sensing image classification combining with mean-shift segmentation and fully convolution neural network [J]. Laser & Optoelectronics Progress, 2018, 55(2): 022802.
方旭, 王光辉, 杨化超, 等. 结合均值漂移分割与全卷积神经网络的高分辨遥感影像分类[J]. 激光与光电子学进展, 2018, 55(2): 022802.

[8] Lai W H, Zhou M R, Wang Y, *et al.* Application of counterfeit liquor recognition based on deep learning and laser induced fluorescence [J]. Laser & Optoelectronics Progress, 2018, 55(4): 043001.
来文豪, 周孟然, 王亚, 等. 深度学习与激光诱导荧光在假酒识别中的应用[J]. 激光与光电子学进展, 2018, 55(4): 043001.

[9] LeCun Y, Boser B, Denker J S, *et al.* Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.

[10] Yang W, Wanli O Y, Li H S, *et al.* End-to-end learning of deformable mixture of parts and deep convolutional neural networks for human pose estimation[C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 27-30 June 2016, Las Vegas, NV, USA. New York: IEEE, 16541427.

[11] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks[M] // Zeiler M D, Fergus R. eds. Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 818-833.

[12] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C] // International Conference on Neural Information

- Processing Systems. Dickinson: Curran Associates Inc. 2012: 1097-1105.
- [13] Hearst M A, Dumais S T, Osuna E, *et al.* Support vector machines [J]. IEEE Intelligent Systems and their Applications, 1998, 13(4): 18-28.
- [14] Oquab M, Bottou L, Laptev I, *et al.* Learning and transferring mid-level image representations using convolutional neural networks [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition, 23-28 June 2014, Columbus, OH, USA. New York: IEEE, 14632209.
- [15] Donahue J, Hendricks L A, Rohrbach M, *et al.* Long-term recurrent convolutional networks for visual recognition and description [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 677-691.
- [16] Wang Z, Crammer K, Vucetic S. Breaking the curse of kernelization: budgeted stochastic gradient descent for large-scale SVM training[J]. Journal of Machine Learning Research, 2012, 13(1): 3103-3131.