

DOI:10.19322/j.cnki.issn.1006-4710.2020.04.018

基于图文信息的柔版印刷压力预测方法研究

廖开阳, 豆佳欣, 武吉梅

(西安理工大学 印刷包装与数字媒体学院, 陕西 西安 710048)

摘要: 印刷压力是印刷质量的根本保证, 为了减少目前印刷压力预测系统依赖性高和价格高的问题, 提出了一种基于图文信息的柔版印刷压力预测方法。该方法通过对印刷原稿的分析, 提取了原稿的图文面积、图文分布和最大梯度值三种图文特征信息, 建立基于图文特征信息和最佳印刷压力预测模型。实验结果表明该方法能够实现最佳印刷压力的有效预测, 减少了印刷压力预测系统依赖性高和价格度高的问题, 对柔版印刷机的智能化发展有重要意义。

关键词: 印刷压力; 印刷原稿; 卷积神经网络; 柔性版印刷

中图分类号: TS803.6 **文献标志码:** A **文章编号:** 1006-4710(2020)04-0562-07

Flexographic printing pressure prediction method based on graphic feature information

LIAO Kaiyang, DOU Jiaxin, WU Jimei

(School of Printing, Packaging Engineering and Digital Media Technology, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Printing pressure is the fundamental guarantee of printing quality. In order to reduce the high dependence and high price of printing pressure prediction system, a flexographic printing pressure prediction method based on graphic information is proposed. By analyzing the printed originals, the using method extracts the three kinds of graphic feature information: the original graphic area, the graphic distribution and the maximum gradient value, thus establishing the image based on the graphic feature information and the optimal printing pressure prediction model. The experimental results show that the method can effectively predict the optimal printing pressure and reduce the dependence of printing pressure prediction system and high price, and it is of great significance to the intelligent development of flexographic printing machine.

Key words: printing pressure; printed original; convolutional neural network; flexographic printing

近年来,随着材料技术、工艺技术和印前技术的持续改善,柔印步入高印刷品质行列,再加上其自身更加高效、环保、安全和卫生的特性,市场认知度和接受度也在不断提高,柔印产业日趋完善,中国柔印迎来了绿色环保国策下最好发展条件的时代^[1-2]。柔性版印刷是一种轻压力印刷,印刷压力远远小于胶印、凹版的印刷压力,其压力大小通常为 $1\sim 3\text{ kg/cm}^2$,压力的轻微变化都会对印品质量产生显著的影响。如果印刷压力过小,则油墨转移量不足,导致印品发虚,细小网点和线条丢失,甚至图文出现空白;如果印刷压力过大,则印品网点扩大严重,且网

点呈现中心颜色浅,四周颜色较深的现象,导致亮调图文丢失,暗调图文阶调合并,出现糊版等。因此印刷压力的精确确定对保证印品质量有十分重要的意义^[3-6]。

关于最佳印刷压力的确定方式有以下三种。一是应用最为广泛的开机预印的方式,其流程为:先根据经验设置初始印刷压力开机印刷,人工检验印品质量,再根据印品质量调节印刷压力的大小,直至印出满足生产要求的印品。这种方式虽然可以满足工业生产要求,但是造成了大量的人力、物力资源的浪费。二是BOBST公司研发了一套柔印压力自动预测系统,

收稿日期: 2019-11-04; 网络出版日期: 2020-07-17

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1294.N.20200716.1722.002.html>

基金项目: 陕西省自然科学基金资助项目(2018JM5023)

第一作者: 廖开阳,男,博士,讲师,研究方向为机器视觉、人工智能。E-mail: liaokaiyang@xaut.edu.cn

通信作者: 武吉梅,女,博士,教授,博导,研究方向为机械设备智能故障诊断理论与方法。E-mail: wujimei@xaut.edu.cn

通过在贴版环节采集版面信息,经过计算机处理,即可直接获得合适的印刷压力。这种印刷压力预测系统,数据来源依赖于专用贴版机,为保持优良的数据采集精度,就使得这种贴版机的价格较高。三是张含笑^[7]提出了一种基于卷积神经网络的柔印压力预测系统,使用感压胶片测量压力,以印版在初始合压位置的表面压力为输入,正常印刷状态下印版承压条上的压力为输出,建立了基于卷积神经网络的柔印压力预测模型。这种印刷压力预测系统,数据来源依赖于感压胶片和 Related 设备,数据测量过程复杂度较高。

因此,针对上述三种方法存在在的不足,本文提出了一种基于图文信息的柔版印刷压力预测方法。该方法通过对印刷原稿的分析,提取了图像的图文面积、图文分布和最大梯度值三种特征信息,建立了图文特征信息和最佳印刷压力预测模型,最后通过实验验证了该模型的有效性。

1 研究方法

1.1 图文信息特征

提取的印刷原稿图文信息特征包括:图文面积、图文分布和最大梯度值。印刷压力与图文面积和图文分布息息相关,在相同压缩量下,图文面积大的印版,印刷压力小;图文面积小的印版,印刷压力大;且每个图文的印刷压力受周围图文的影响^[7-8],因此我们选择提取面积特征和图文分布特征。此外,为了增强图像的特征表达,还加入了图像的边缘信息,一方面图文的边缘承载更大的压力,另一方面边缘信息增强了文字特征的表达,当图像中存在边缘时,一

定有较大的梯度值。相反,当图像中有比较平滑的部分时,灰度值的变化较小,则相应的梯度也较小,因此我们选择了图像的最大梯度特征来反映图像的边缘信息^[9]。

在特征提取之前需要对不同大小的分色原稿进行标准化处理,由于原稿设计时的分辨率通常为 300dpi,且通过陕西北人 FIL220 机组式印刷机参数可以得出常用的印刷的最大幅宽为 1 350 mm,最大长度为 800 mm,因此通过计算可以得到常用分色原稿的最大像素大小约为 16 000×10 000 dpi。将常用的分色原稿最大像素作为标准的分色原稿像素,对于尺寸较小的分色原稿通过在其右方和下方填补灰度值 255,从而得到大小相同的分色原稿。

图文分布体现为图像网格化,即图像划分为一个个规则的网格以区分不同的区域。网格划分的数量对实验结果有重要影响,网格划分数量多,则预测模型的计算难度将大大提升,网格划分数量少,则预测模型的精确性将会大大降低,因此我们将网格划分为 28×28。

图文面积的计算首先是对图像取反,然后进行二值化和图像取反处理,然后将得到的二值图像进行网格划分,对单个网格内的图像分别进行区域标记、区域统计和区域计算,最终得到面积矩阵。最大梯度值的计算通过常用的 Sobel 梯度算子来计算,经过横向梯度、纵向梯度和梯度模的计算得到梯度图像,然后将得到的梯度图像进行网格划分,计算区域的最大值,最终得到梯度矩阵。

特征提取过程见图 1。

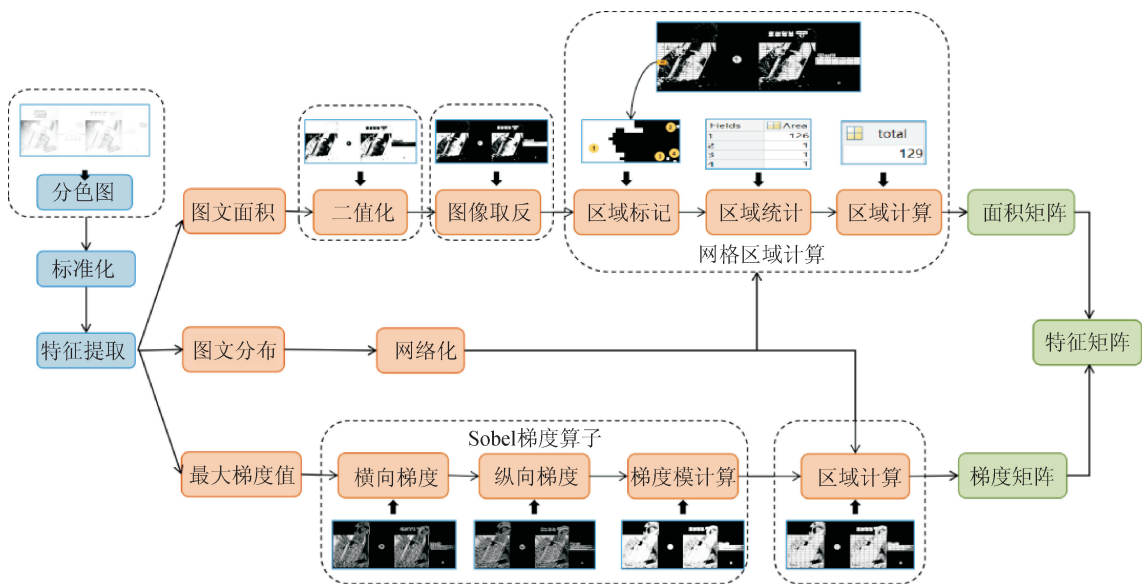


图 1 特征提取过程

Fig. 1 Graphic feature information extraction process

1.2 数据预处理

提取的特征数据在模型训练之前,需将数据归一化至 $[0,1]$ 之间,其目的是为了更加快速便捷的处理数据。本文采用线性函数归一化的方法,将数据转换至 $[0,1]$ 范围之间,公式为:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

式中: X 和 X' 分别表示为原始数据和归一化后数据, X_{\min} 和 X_{\max} 分别表示原始数据的最小值和最大值。

1.3 卷积神经网络

为了建立图文特征信息和最佳印刷压力的预测模型,以图文特征信息为输入数据,相应的最佳印刷

压力为输出数据,使用卷积神经网络(Convolution Neural Network, CNN)进行预测。

CNN是一种特殊的多层感知器或前馈神经网络,具有局部连接、权值共享的特点,其中大量的神经元按照一定方式组织起来对视野中的交叠区域产生反应,在手写字符识别、目标定位与检测、图像分类、人脸验证等诸多方面获得了广泛的成功应用。

标准的CNN一般由输入层、交替的卷积层和池化层、全连接层和输出层构成,见图2,每个平面表示一个特征图,其中所有神经元权值共享,但偏置可能不同^[10]。




图2 标准卷积神经网络

Fig. 2 Standard convolution neural network structure

卷积层是对输入层或者上一层的特征图进行卷积操作,用来学习更深层次的特征。若 x 表示输入样本, y 表示输入样本, \mathbf{W} 表示相应卷积层的权值矩阵, β 表示相应池化层的权值, b 表示相应层的阈值,则 n 卷积层神经元 i 的输出为:

$$x_i^n = f(w_{ij}^n \otimes x_j^{n-1} + b_i^n) \quad (2)$$

式中: x_i^n 代表 n 卷积层神经元 i 的输出, w_{ij}^n 代表 n 卷积层神经元 i 和 n 卷积层神经元 j 之间的权值, b_i^n 代表 n 卷积层神经元 i 的阈值, f 代表激励函数。

池化层是对卷积层获得的特征图进行降采样处理,利用局部相关性减少后续数据处理量,同时又保留有用信息。 $n+1$ 池化层神经元 i 的输出为:

$$x_i^{n+1} = f(\beta_i^{n+1} \text{down}(x_i^n) + b_i^{n+1}) \quad (3)$$

式中: x_i^{n+1} 代表 $n+1$ 池化层神经元 i 的输出,down代表降采样函数, β_i^{n+1} 代表 $n+1$ 池化层神经元 i 的权值, b_i^{n+1} 代表 $n+1$ 池化层神经元 i 的阈值。

全连接层是将上一层获得的局部特征按照顺序排列,得到输入的全局特征,起到将学习到的特征映射到样本的标记空间的作用。通过计算网络损失函数极小化问题来估计网络参数,并利用反向传播算法更新网络参数使网络得到训练^[11]。其中,对于实际输出值为 y_i 和预测输出值为 \hat{y}_i 的模型损失函数的计算为:

$$L = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

1.4 模型评价

采用的模型评价参数为:均方根误差RMSE、线性回归相关系数 R 和累积预测精度函数 $CS(\theta)$ 。其中,RMSE是预测值与实际值之差平方的期望值,反映了模型预测值相对于实际值的整体偏差程度,RMSE的值越小,说明预测模型描述实验数据具有更好的精度,其函数表达式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (5)$$

式中: y_i 为实际输出值, \hat{y}_i 为预测输出值, N 为预测样本数量。

回归系数 R 反映预测值与实际值的关联程度, R 值越接近1,说明预测模型描述实验数据与实际值具有更好的相关性。

$CS(\theta)$ 是预测值与实际值的绝对值误差小于 θ 的样本数占总样本数的百分比,其函数表达式为:

$$CS(\theta) = \frac{N_{e \leq \theta}}{N} \times 100\% \quad (6)$$

式中: $N_{e \leq \theta}$ 为预测误差小于 θ 的数据数量, N 为预测样本数量。

1.5 预测模型

以提取的特征矩阵作为 CNN 的输入数据,相应的最佳印刷压力作为 CNN 的输出数据,建立 CNN 预测模型。

图 3 所示为 CNN 模型的流程图。首先将输入数据和输出数据组成的数据集划分为训练集和测试

集,然后对训练集的数据输入到 CNN 结构中处理,经过归一化、交替的卷积层和池化、全连接层和输出层处理,建立特征矩阵和最佳印刷压力值之间的非线性映射关系。最后将测试集的数据输入到训练好的 CNN 模型中,经过 CNN 模型计算便可以预测出最佳印刷压力值。

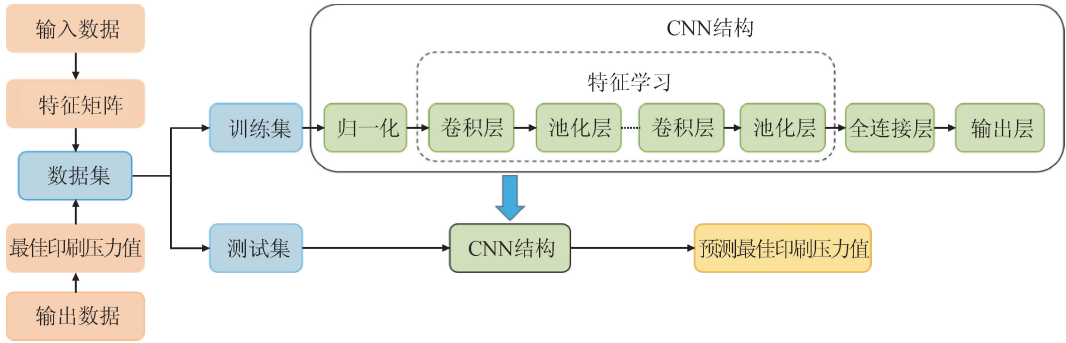


图 3 CNN 模型流程图
Fig. 3 Flow chart for CNN model

模型预测的结果与模型参数的选择有密切的关系,影响 CNN 结构的主要参数有卷积层和池化层的个数,卷积核的大小,特征图的数量和学习率的大小。

图 4 和表 1 表示了不同卷积层和池化层个数对模型结果的影响,可以看出,卷积层和池化层的个数为 2 时,模型的结果最好,因此,确定卷积层和池化层的个数为 2。

图 5 和表 2 表示了不同卷积核大小对模型结果的影响,可以看出,当卷积核的大小分别为 5 和 5 时,模型的结果最好,因此,确定卷积核的大小分别为 5 和 5。




图 4 不同卷积层和池化层个数的 $CS(\theta)$ 曲线
Fig. 4 $CS(\theta)$ curves with different numbers of convolution layers and pooling layers

表 1 不同卷积层和池化层个数的均方根误差和相关系数
Tab. 1 RMSE and R with different numbers of convolution layers and pooling layers

层数	均方根误差	相关系数 R
1	0.009	0.933 5
2	0.005	0.957 9
3	0.007	0.943 5




图 5 不同卷积核大小的 $CS(\theta)$ 曲线
Fig. 5 $CS(\theta)$ Curves with different convolution kernel sizes

表 2 不同卷积核大小的均方根误差和相关系数
Tab. 2 RMSE and R with different convolution kernel sizes

卷积核	均方根误差	相关系数 R
5,3	0.005	0.945 6
5,5	0.005	0.957 9
9,5	0.005	0.946 5
9,7	0.006	0.942 1

图 6 和表 3 表示了不同特征图对模型结果的影响,可以看出,当特征图数量分别为 6 和 12 时,模型的结果最好,因此,确定特征图数量分别为 6 和 12。

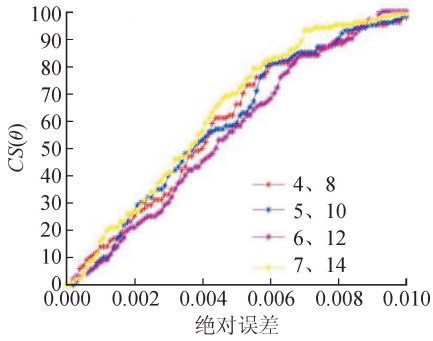
图6 不同特征图的 $CS(\theta)$ 曲线Fig. 6 $CS(\theta)$ curves for different feature maps

表3 不同特征图的均方根误差和相关系数

Tab. 3 $RMSE$ and R with different feature maps

特征图	均方根误差	相关系数 R
4、8	0.005	0.947 6
5、10	0.005	0.938 3
6、12	0.005	0.957 9
7、14	0.005	0.954 4

图7和表4表示了不同学习率对模型结果的影响,可以看出,学习率的大小为0.5时,模型的结果最好,因此,确定学习率的大小为0.5。


图7 不同学习率的 $CS(\theta)$ 曲线Fig. 7 $CS(\theta)$ curves at different learning rates

表4 不同学习率的均方根误差和相关系数

Tab. 4 $RMSE$ and R at different learning rates

学习率	均方根误差	相关系数 R
0.5	0.004	0.971 7
0.1	0.005	0.957 9
0.05	0.006	0.950 3
0.01	0.008	0.9433

经过参数的优化,最终确定CNN的预测模型,该模型包含两个交替的卷积层和池化层及一个全连接层。卷积层C1卷积核的大小是 5×5 ,包含6个特征图,激活函数为ReLU;池化层S2采用平均池

化的方法,池化幅值为2;卷积层C3是第2个卷积层,卷积核的大小是 5×5 ,包含12个特征图,激活函数为ReLU;池化层S4是第2个池化层,采用平均池化的方法,池化幅值为2。

模型参数在训练集和测试集上评价见图8和表5。图8为模型参数在训练集和测试集的 $CS(\theta)$ 曲线,由图8可知,当前模型参数在训练集上的最大累积误差精度为0.0092,在测试集上的最大累积误差精度为0.0092。表5为当前模型参数在训练集和测试集的均方误差和相关系数,由表5可知,当前模型参数在训练集上的 $RMSE$ 为0.004, R 为0.9717,在测试集上的 $RMSE$ 为0.009, R 为0.9348。


图8 训练集和测试集的 $CS(\theta)$ 曲线Fig. 8 $CS(\theta)$ on the train set and the test set

表5 训练集和测试集的均方根误差和相关系数

Tab. 5 $RMSE$ and R on the train set and the test set

数据集	均方根误差	相关系数 R
训练集	0.004	0.971 7
测试集	0.009	0.934 8

综上所述,CNN预测模型能够逼近实际的印刷压力值,且具有较强的预测能力。

2 实验

2.1 实验设备

实验设备为陕西北人FIL220机组式柔印机,图9为柔印机设备照片,实验的主要技术参数见表6。



图9 FIL220 柔印机

Fig. 9 FIL220 Flexo printing machine

表6 实验主要参数表

Tab. 6 Main parameters of the experiment


参数	取值
印刷色数	8
印刷物幅宽/mm	1 050
版辊印刷长度/mm	349
印版品牌	杜邦
印版厚度/mm	1.7
承印材料	80g/m ² 铜版纸(厚度为0.072mm)
胶带规格	德莎中性胶带
胶带厚度/mm	0.5
驱动方式	全伺服驱动系统
油墨类型	水性油墨
温度/(°C)	28
湿度	35%RH
速度/(m·min ⁻¹)	12

2.2 最佳印刷压力测量

理想的印刷品质量,应该是印版上的图文能完整的转印到承印物上,同时达到印品墨色饱满、均匀的要求,我们将这种状态下的印刷压力称为最佳印刷压力。FIL220 柔版印刷机伺服电机通过调压带轮带动滚珠丝杠走位,用来调整印版与网纹辊、版辊与压印滚筒之间的压力。首先调节网纹辊对印版滚筒的着墨压力,使印版的图文部分得到所需要的墨层;其次调节印版滚筒和压力滚筒之间的印刷压力,使印版上的图案在承印材料上全部清晰印出^[12-13]。由于印刷压力通常是由压缩量来表示,因此我们记录版辊与承印物从刚好接触到清晰印出过程中版辊位移量作为当前版辊的最佳印刷压力,此时的位移量也是压缩量。FIL220 柔版印刷机版辊移动的最小位移为 0.01 mm。

2.3 模型比较

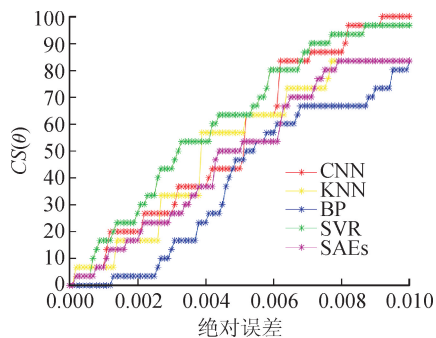
另外选取了 30 个分色原稿,提取其特征矩阵,并将提取的特征矩阵输入到确定好的预测模型中,预测这 30 个分色原稿的最佳印刷压力值。然后实际测量这 30 个分色原稿的实际最佳印刷压力值,并将预测的最佳印刷压力值与实际的最佳印刷压力值进行比较,验证数据的 $CS(\theta)$ 曲线见图 10。根据图 10 可知,这 30 个分色原稿的最大累积误差精度为 0.008 2。经计算,这 30 个分色原稿的预测值与实际值之间的相关系数值为 0.857 6,均方根误差为 0.008。

图 10 验证数据的 $CS(\theta)$ 曲线Fig. 10 $CS(\theta)$ curve for validation data

2.4 模型对比

为了评价 CNN 模型,我们将 CNN 模型与预测研究常用的模型进行对比^[14],包括 KNN (k-Nearest Neighbor)、SVR (Support Vector Regression)、BP (Back Propagation) 和 SAEs (Stacked Autoencoder)。其中, KNN 算法中 $k=8$; SVR 采用 nu-SVR 网络, linear 核函数, 惩罚系数 C 为 0.001; BP 神经网络使用三层结构, 隐层节点数为 48, 训练算法采用 Ploak-Ribiere 共轭梯度法 (traincgp), 节点传输函数使用双极性 S 函数 (tansig); SAEs 采用三个隐含层结构, 隐含层分别为 900, 400, 100。

图 11 为不同预测模型的 $CS(\theta)$ 曲线, 可以看出, CNN 模型的累积误差精度值为 0.009 2, 与其他预测模型相比, 具有较小的累积误差精度。

图 11 不同预测模型 $CS(\theta)$ 曲线Fig. 11 $CS(\theta)$ curves with different models

对各个模型的均方根误差和相关系数的变化情况进行比较, 见表 7。CNN 模型的均方根误差为 0.004, 相关系数值为 0.971 7, 与其他预测模型相比, 具有相对较小的均方根误差和相对较高的拟合度。

根据实验结果可以看出, CNN 模型能更好的预测最佳印刷压力值。

表7 不同模型的均方根误差和相关系数

Tab.7 RMSE and R with different models

预测模型	均方根误差	相关系数 R
CNN	0.004	0.971 7
KNN	0.006	0.929 1
BP	0.009	0.710 8
SVR	0.005	0.937 7
SAEs	0.007	0.891 3

3 结 论

1) 与其他预测模型相比,CNN 预测模型具有较小的误差,能够有效地预测最佳印刷压力值。

2) 基于原稿的分析,提取了图文分布、图文面积和最大梯度值三个特征作为图像的特征矩阵。

柔印印刷压力在柔版印刷中起着重要的作用,基于目前印刷压力预测系统依赖性高和价格高的问题,本文提出了基于图文信息的柔版印刷压力预测方法。该方法实验结果表明,该方法能够实现柔版最佳印刷压力值的有效预测,对柔版印刷机的智能化发展有重要意义。

参考文献:

- [1] 蔡成基. 环保新形势与柔印发展新机遇[J]. 印刷技术, 2018(10):53-57.
- [2] 郑其红. 中国柔印的现状与未来发展[J]. 印刷杂志, 2017(4):前插 1,1-6.
- [3] 黄颖为. 柔版印刷中网点扩大变形的研究[J]. 包装工程,2005,26(6):233-234.
HUANG Yingwei. Research of dot enlargement deformation in flexography[J]. Packaging Engineering, 2005, 26(6): 233-234.
- [4] 陈文革,蒋文燕,黄学林. 柔印基础知识[M]. 北京:印刷工业出版社,2008.
- [5] 肖志坚. 瓦楞纸板柔印最佳压力调节的研究[J]. 中国印刷与包装研究,2012,4(1):30-34,61.
XIAO Zhijian. Study on the most suitable pressure ad-

justment of flexography on corrugated board[J]. Chinese Printing and Packaging Study, 2012, 4(1): 30-34, 61.

- [6] 李子焘. 印刷压力变化对印刷质量的影响及补偿措施的研究[D]. 广东:华南理工大学,2015.
LI Zitao. Study on the influence of printing pressure change on printing quality and its compensation measures[D]. Guandong: South China University of Technology, 2015.
- [7] 张含笑. 基于卷积神经网络的柔印压力预测系统研究[D]. 西安:西安理工大学,2018.
ZHANG Hanxiao. Research on flexo printing pressure prediction system based on convolution neural network [D]. Xi'an: Xi'an University of Technology, 2018.
- [8] HOLMVALL M, UESAKA T. Nip mechanics of flexo post-printing on corrugated board[J]. Journal of Composite Materials, 2007, 41(17): 2129-2145.
- [9] 孙刘杰. 印刷图像处理[M]. 北京:印刷工业出版社,2013.
- [10] 李玉鑑,张婷,单传辉,等. 深度学习:卷积神经网络从入门到精通[M]. 北京:机械工业出版社,2018.
- [11] 王璨,武新慧,李恋卿,等. 卷积神经网络用于近红外光谱预测土壤含水率[J]. 光谱学与光谱分析,2018, 38(1):36-41.
WANG Can, WU Xinhui, LI Lianqing, et al. Convolutional neural network application in prediction of soil moisture content[J]. Spectroscopy and Spectral Analysis, 2018, 38(1): 36-41.
- [12] 高晶,黎阳辉,唐小君. 柔性版印刷 500 问[M]. 北京:文化发展出版社,2016.
- [13] 周世生. 卫星式柔版印刷机原理与结构[M]. 北京:文化发展出版社,2017.
- [14] LIU Qingchao, WANG Bochen, ZHU Yuquan. Short-term traffic speed forecasting based on attention convolutional neural network for arterials[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33 (11): 999-1016.

(责任编辑 王绪迪)