

# 基于 GRNN-PNN 神经网络的印铁缺陷分类方法

张志晟，张雷洪，王新月，李正礼，孙琳源，徐邦联  
(上海理工大学，上海 200093)

**摘要：**目的 针对在印铁过程中缺陷检测系统存在不同缺陷类型检测精度不高，对于产品整体质量无法实现智能判断的问题，基于 GRNN-PNN 神经网络，提出一种适用于印铁在线检测的分类算法。方法 对平面印刷铁片进行小波变换提取低频信息，在低频信息中进行缺陷定位并对缺陷区域进行标记和分割。通过缺陷面积、周长等评价指数和缺陷形状构建 GRNN 神经网络，对缺陷进行分类。通过构建 PNN 神经网络智能化判别整体产品是否属于合格产品。结果 GRNN-PNN 平均耗时 0.69 s，达到了厂方对于缺陷在线检测的响应时间要求。GRNN-PNN 多分类的准确率为 86%，能够对印铁过程中产生的主要缺陷进行分类。二分类的灵敏度为 96%，可以准确地判断产品整体的合格性。在 5% 的椒盐噪声干扰下，准确率为 63%，具有良好的鲁棒性。结论 该设计能够对印铁缺陷进行精确的分类和智能的判断，GRNN-PNN 神经网络可以在印铁过程中进一步提高检测精度，GRNN-PNN 神经网络可帮助质检员及时判断生产质量。

**关键词：**缺陷检测；图像评估；神经网络；印铁技术；图像处理

**中图分类号：**TS807   **文献标识码：**A   **文章编号：**1001-3563(2020)15-0260-07

**DOI：**10.19554/j.cnki.1001-3563.2020.15.039

## Classification Method of Printed Iron Defects Based on GRNN-PNN Neural Network

ZHANG Zhi-sheng, ZHANG Lei-hong, WANG Xin-yue, LI Zheng-li, SUN Lin-yuan, XU Bang-lian

(University of Shanghai for Science and Technology, Shanghai 200093, China)

**ABSTRACT:** During the iron printing process, the defect detection system has a problem that the accuracy of defect detection is not high, and intelligent judgment cannot be achieved for the overall product quality. This paper aims to propose a classification algorithm suitable for on-line detection of printed iron based on GRNN-PNN neural network. Wavelet transform was performed on printed iron sheet to extract low-frequency information. The defects in low-frequency information were located, and the defective areas were marked and segmented. A GRNN neural network was constructed based on defect area, perimeter and other evaluation indexes to classify defects. A PNN neural network was constructed to intelligently determine whether the overall product was a qualified product. The average time of GRNN-PNN was 0.69s, which met the factory's requirement on the response time of online defect detection. The accuracy of GRNN-PNN multi-classification was 86%, which can classify the main defects generated during the iron printing process. The sensitivity of the two classifications was 96%, which can accurately judge the overall qualification of the product. Under 5% salt and pepper noise, the accuracy rate was 63%, and GRNN-PNN had good robustness. The design can accurately classify and intelligently judge the defects of printed iron. The GRNN-PNN neural network can further improve the detection accuracy during the iron printing process. The GRNN-PNN neural network can help quality inspectors to judge the production

---

收稿日期：2019-12-02

作者简介：张志晟（1994—），男，上海理工大学硕士生，主攻图像识别和印刷包装技术。

通信作者：张雷洪（1981—），男，博士，上海理工大学副教授，主要研究方向为印刷包装技术和数据模拟仿真。

quality in time.

**KEY WORDS:** defect detection; image evaluation; neural network; iron printing technology; image processing

由于进口在线检测设备价格昂贵等原因, 在国内大多数制罐厂没有专用的印铁在线检测设备。与普通的印刷不同, 金属材料受光线影响更容易产生噪声, 质检员只有在系统产生面积较大缺陷和连续报错的情况下才能发现问题。在这种情况下, 如何使制罐厂在印铁过程中, 快速准确地发现不合格铁片, 减少不必要的损失, 成了制罐企业智能化生产的重大难题。

机器视觉和图像处理技术是提高制罐企业生产效率、实现智能化生产不可缺少的手段之一。周春霞、魏敏等<sup>[1]</sup>在 2007 年提出了基于数学形态学的印刷网点图像分割方法, 在图像增强的基础上采用数学形态学方法去除噪声, 取得了良好效果。刘盛鹏、方勇等<sup>[2]</sup>提出了一种基于数学形态学的 Contourlet 变化域图像降噪方法, 也取得了较好的效果。在图像预处理后, 还需要利用神经网络对印铁缺陷进行分类、对印铁图像进行评估。

神经网络在工业上得到了广泛的应用, Chen FL 和 Liu SF<sup>[3]</sup>在半导体制造领域利用神经网络识别晶片缺陷, 通过实验对比发现神经网络识别缺陷更加准确。Carvalho<sup>[4]</sup>利用信号分析技术提高了神经网络在缺陷识别上的准确率。阮重德等<sup>[5]</sup>利用 RBF 神经网络提高了焊接质量。Adly Fatima<sup>[6]</sup>通过将神经网络与随机技术结合, 实现了对晶圆缺陷有效的分类。Cha Y.J.<sup>[7]</sup>利用深度学习识别了混泥土裂缝。

虽然深度学习极大程度提高了神经网络识别能力, 但是由于需要大量样本和运行速度缓慢等原因, 在工程应用上受到了一定限制。广义回归神经网络 (GRNN) 由 Specht 提出被广泛应用于各类故障的评估和预测中<sup>[8—14]</sup>。王玉梅等<sup>[15]</sup>利用 GRNN 实现了对海洋平台结构损伤位置的识别。崔建国等<sup>[16]</sup>提出了 GRNN 和极限学习机结合的方式用于识别复合材料的损伤。Chenshuang Zhang, Guijin Wang 等<sup>[17]</sup>提出了基于 RNN 的心电图心跳分类系统, 在实际应用中更新了全球心跳分类系统。概率神经网络 (PNN) 更多应用于识别中<sup>[18—22]</sup>。李朝锋等<sup>[23]</sup>通过对比发现, 对于遥感图像 PNN 比 BP 分类精度更高。李延鹏等<sup>[24]</sup>利用 GRNN 和 PNN 分析了复杂的电磁环境, 有效地验证了该方法的优势。

尽管有很多不同领域的学者和企业使用了 GRNN 或 PNN 神经网络提高分类性能, 但目前大多制罐企业仍需要依靠质检员进行产品合格判断, 因此, 文中提出一种新的解决方法——基于 GRNN-PNN 神经网络的印铁缺陷分类算法。文中利用小波变换和形态学对图像进行预处理, 再通过评价指标与缺陷形状构建 GRNN 神经网络对缺陷特征进行分类, 同时

通过 PNN 神经网络判断整体是否合格。文中通过结合 GRNN 和 PNN, 拓宽神经网络在印铁过程中的应用, 进一步提高印铁过程中缺陷识别的精准度。

## 1 技术原理研究

为实现印铁缺陷分类和智能化判断, 主要技术包括图像预处理、缺陷特征提取和基于 GRNN-PNN 的分类, 其中通过印铁缺陷的特征构建 GRNN-PNN 是整个设计的核心。

### 1.1 图像预处理技术

平面印刷铁片图像是二维矩阵, 矩阵大小为  $N \times N$ , 且  $N=2^n$  ( $n$  为非负整数), 经过小波变换后, 印刷铁片图像分解为 4 个子区域。通过对铁片图像水平方向和垂直方向低通滤波可以得到  $LL$ ,  $LL$  保存了原始图像的主要内容, 该过程见式 (1)。

$$f_{2^j}^0(m,n) = \langle f_{2^{j-1}}(x,y), \phi(x-2m, y-2n) \rangle \quad (1)$$

式中:  $\langle \cdot \rangle$  为内积运算;  $\phi(x)$  为尺度函数。

通过小波变换可以提取印刷铁片的主要信息, 同时去除噪声和压缩图像。在  $LL$  上进行边缘检测, 利用边缘信息计算梯度图像, 结果见图 1。观察图 1 可发现, 平面印刷铁片的核心部位为商标区域、品牌名称区域、二维码、配料表区域。在标准印刷铁片图像上框选这些核心部位, 标记并计算核心部位的坐标范围。



图 1 核心区域  
Fig.1 Core area

### 1.2 缺陷特征提取技术

由于印铁设备和印铁工艺的原因在印铁过程中会产生 2 大类缺陷: 主区缺陷、背景缺陷。其中主区缺陷包含大面积缺陷、散点缺陷、划痕缺陷; 大面积缺陷主要表现为套印不准、重影、糊版等, 因套印不准而产生的大面积缺陷见图 2a。散点缺陷主要表现



图 2 印铁缺陷  
Fig.2 Defect of printed iron

为漏印、污点,“乳”字笔画漏印见图 2b,此类缺陷存在的区域较为离散,当处于核心部位或面积较大时,需要及时发现解决。划痕缺陷:图 2c 为刮痕,较长的刮痕分布较广,影响整体外观。背景缺陷主要为图像采集过程中产生的噪声和在非核心区域中面积较小的污点和刮痕。

在缺陷识别之前,需要对测试印刷铁片的缺陷进行分割和特征提取。文中将预处理后的标准印刷铁片与每张测试印刷铁片进行差分,通过差分图像反映缺陷的特征信息。通过连通域分析,计算缺陷的面积和周长。通过式(2)计算缺陷区域的质心,利用集合运算判断质心是否在核心区域内。再对差分图像进行形态学处理,提取缺陷区域的形状特征并将图像二值化。缺陷区域的质心的计算公式为:

$$\bar{x} = \frac{\sum j * x_{i,j}}{\sum x_{i,j}} \quad \bar{y} = \frac{\sum i * y_{i,j}}{\sum y_{i,j}} \quad (2)$$

式中:  $i, j$  为缺陷区域的像素在图像矩阵中的下标。

### 1.3 基于 GRNN-PNN 的分类技术

GRNN 神经网络是由 RBF 网络发展而来的一种前馈型神经网络,具有很强的非线性映射能力,很强的容错性和鲁棒性,GRNN 的网络结构见图 3,它主要由输入层、模式层、求和层以及输出层组成。模式层神经元传递函数为:

$$p_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad i = 1, 2 \dots n \quad (3)$$

式中:  $X$  为网络输入变量;  $X_i$  为第  $i$  个神经元对应的学习样本;  $\sigma$  为权值。

求和层对所有模式层神经元的输出进行算术求和,计算公式为:

$$\sum_{i=1}^n \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad (4)$$

连接函数为 1,传递函数为:

$$S_D = \sum_{i=1}^n P_i \quad (5)$$

各神经元将求和层的输出相除,神经元  $j$  的输出

对应估计结果  $\hat{Y}(X)$  的第  $j$  个元素,即:

$$y_j = \frac{S_{Nj}}{S_D} \quad j = 1, 2 \dots k \quad (6)$$

文中使用 GRNN 对印铁缺陷实现缺陷种类分类,然后使用 PNN 对整体图像进行二分类,实现了对产品是否合格进行判断。

PNN 与 GRNN 结构大致相同,不同的是 PNN 模式层每个模式单元的输出为:

$$f(X, W_i) = \exp\left[-\frac{(X - W_i)^T(X - W_i)}{2\delta^2}\right] \quad (7)$$

式中:  $W_i$  为输入层到模式层连接的权值;  $\delta$  为权值。

PNN 的输出层为竞争神经元,将最大的输出设为 1,其余为 0。文中利用 PNN 将不合格印刷铁片图像标记为 1,合格印刷铁片图像标记为 0。

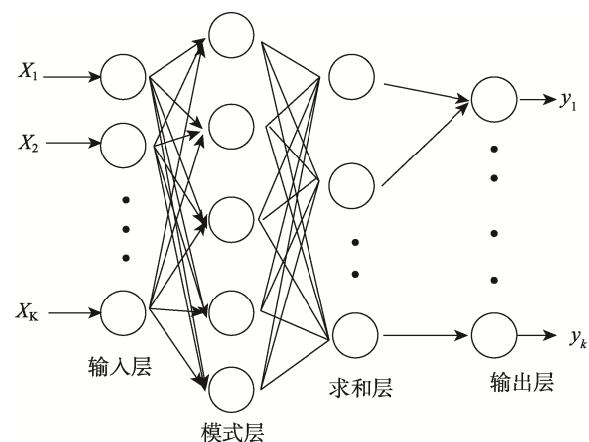


图 3 GRNN 神经网络结构  
Fig.3 Structure of GRNN neural network

## 2 方案设计

设计方法见图 4,主要包含 3 个模块:印铁图像预处理、提取印铁缺陷特征和构建神经网络。具体内容:首先对 ccd 采集到的印刷铁片图像进行小波变换,提取低频图像,完成图像去噪。将标准印铁图像的低频图像与每张测试印铁图像的低频图像进行差分。在

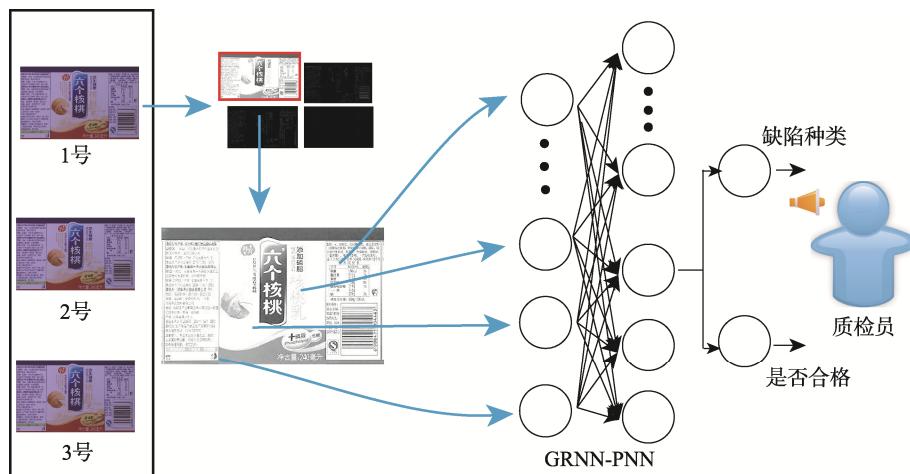


图 4 印铁缺陷检测流程  
Fig.4 Flow chart of printed iron defect detection

差分图像上,通过连通域分析来获取缺陷的面积和周长,通过缺陷的质心坐标,对缺陷进行定位,判断缺陷的位置。将面积、周长和缺陷位置作为评价指标。通过数字形态学提取缺陷区域形状特征。将评价指标和缺陷形状用于构建 GRNN 神经网络对缺陷特征进行分类,同时通过评价指标构建 PNN 神经网络判断整体是否合格,从而提高在印铁中缺陷识别的精准度和智能化。

### 3 实验仿真及模型分析

将工厂提供的印刷缺陷图像按上述方法进行预处理,将完成预处理的印刷铁片图像采用形态学处理和连通域分析方法对图像上每个缺陷进行提取。该次仿真使用的印刷铁片图像共 750 张,其中 600 张为不合格的缺陷图像,150 张为合格图像。编号 1~150 为污点,编号 151~300 为刮痕,编号 301~450 为套印不准,编号 451~600 为漏印,编号 601~750 为合格产品图像,其中 75 张为无缺陷,75 张为有缺陷但符合标

准。其中污点标记为类 1,刮痕标记为类 2,套印不准标记为类 3,漏印标记为类 4,无缺陷图像标记为 5。文中将面积大于 2 mm 或累计周长大于 250 mm 或质心处于核心区域的缺陷判为不合格,标记 1—4 的缺陷图像均为不合格产品。随机取其中 600 张图像作为训练集,其余 150 张为测试集。文中通过准确率、灵敏度和抗噪性,进一步分析该方法。

#### 3.1 准确率

在线检测设备 PC 机的一般配置为 i7 CPU,Win7,16 G 内存,在相同配置下,GRNN-PNN 算法平均耗时为 0.69 s,达到了制罐厂商对于印铁在线检测设备的响应时间要求。准确率的计算见式(8),是分类正确的测试数量与所有的测试数之比。对于测试集,GRNN 神经网络分类的结果见图 5。

$$A_{cc} = \frac{T_Y + T_N}{T} \quad (8)$$

式中:  $A_{cc}$  为准确率;  $T_Y$  为实际正确结果;  $T_N$  为实际错误结果;  $T$  测试集总数。

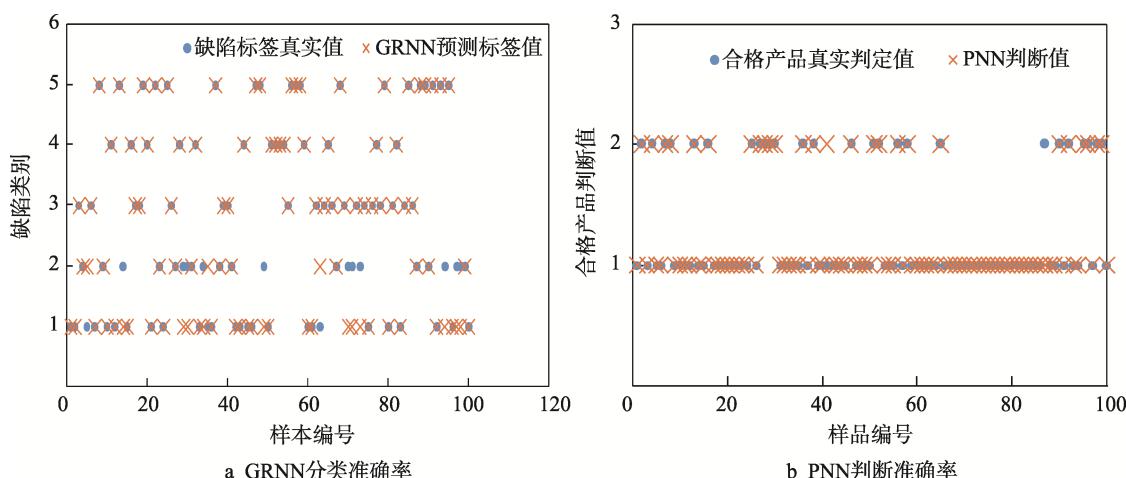


图 5 GRNN-PNN 分类及判断的结果  
Fig.5 Results of GRNN-PNN classification and judgment

观察图5可以发现，整体而言，GRNN-PNN神经网络对平面印刷铁片中缺陷区域可以准确地识别分类，分类准确率达到86%，满足制罐厂对印铁缺陷的识别分类要求。图5a中●代表缺陷标签真实值，×表GRNN-PNN预测的分类标签值，两者重合时表示神经网络识别符合实际。GRNN神经网络对于污点缺陷和刮痕缺陷的分类有些许误差，但两者都属于主区缺陷，因此少许误差可以接受。通过观察可以发现，GRNN-PNN神经网络可以准确地识别套印不准等大面积缺陷和漏印缺陷。

通过图5b可知，GRNN-PNN神经网络可以准确地判断印铁产品是否合格。GRNN-PNN可以判断合格产品图像和大污点、刮痕、套印不准等有缺陷图像。现在大多数印刷在线检测设备都是依靠灰度阈值提取缺陷<sup>[25]</sup>。由于马口铁等金属材料更容易产生噪声，当质检员降低灰度阈值时会使错检率升高，当质检员提高阈值时与标准印刷铁片灰度相近的缺陷则会漏检。漏印缺陷是主要缺陷之一，但由于图像采集设备存在噪声、检测设备阈值过高，漏印缺陷经常会被忽视，从而造成大量损耗，通过图5b可知，与传统设备中的阈值提取算法相比，GRNN-PNN网络二分类性能更优。GRNN-PNN网络可以通过训练和缺陷质心坐标，有效地判断噪声和缺陷位置，进一步使GRNN-PNN神经网络区分漏印缺陷和合格铁片，从而帮助质检员及时的发现漏印缺陷，避免损失。

文中使用BP和RBF神经网络与GRNN-PNN进行多类的性能对比分析。使用BP神经网络和RBF神经网络对750张污点（类1）、刮痕（类2）、套印不准（类3）、漏印（类4）、合格产品图像（类5）进行分类训练和测试，结果见图6和图7。

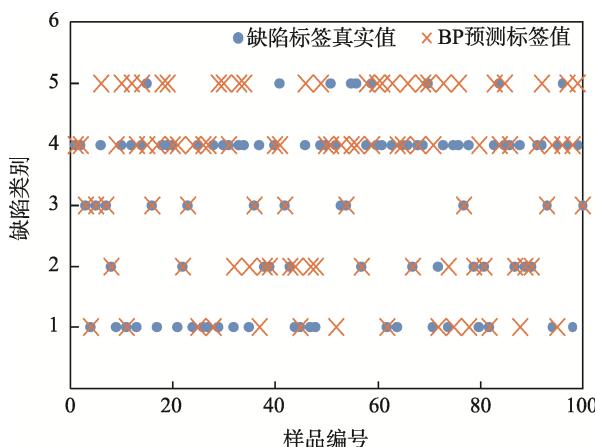


图6 BP神经网络分类  
Fig.6 Classification of BP neural network

印铁缺陷在整个印铁产品中占小部分，同时由于在线检测设备的原因无法保存大量信息，通过图6可以发现，与文中的GRNN-PNN神经网络相比，BP神经网络对于此类小样本的分类，精度不高，无法满足

工程需要。还发现，BP神经网络容易将污点、漏印与合格产品图像混淆，无法正确识别散点类缺陷。

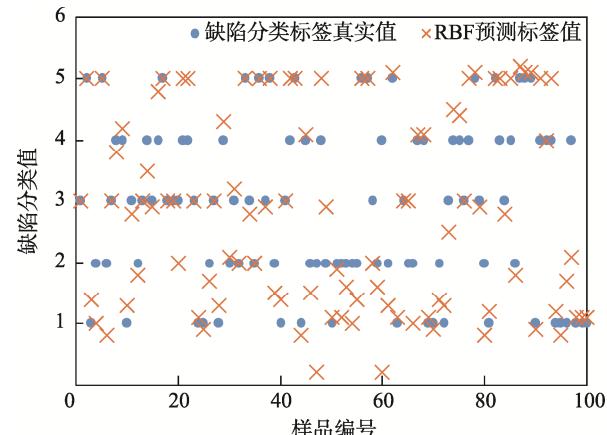


图7 RBF神经网络分类  
Fig.7 Classification of RBF neural network

GRNN和PNN神经网络都是由RBF神经网络改进而来，通过图5和图7对比分析可知，GRNN-PNN神经网络比RBF神经网络对于此类小样本的分类精度更高。通过图7还发现，RBF神经网络判断的标签值更加离散，无法实现精准判断。通过图6和图7分析可以发现BP和RBF神经网络对于小样本分类性能不佳，无法满足印铁生产中实际需求。

### 3.2 灵敏度

灵敏度可以衡量该设计中GRNN-PNN神经网络二类别的判别能力，灵敏度的计算见式(9)。使用印刷铁片图像测试GRNN-PNN二类别的灵敏度，随机取其中600张图像作为训练集，其余150张为测试集。分析GRNN-PNN的判断性能。同样使用BP和RBF作为进行二分类对比，结果见表1，灵敏度的计算公式为：

$$S = \frac{T_Y}{P} \quad (9)$$

式中：S为灵敏度；T<sub>Y</sub>为测试中能正确区分合格的结果；P为测试集中合格图像的总数。

表1 灵敏度分析  
Tab.1 Sensitivity analysis

| 算法类型     | 正确区分的数量(测试集中合格图像的总数) | 灵敏度/% |
|----------|----------------------|-------|
| GRNN-PNN | 25幅(26幅)             | 96    |
| BP       | 30幅(37幅)             | 81    |
| RBF      | 22幅(48幅)             | 45    |

通过观察表1可知，GRNN-PNN二类别的灵敏度达到96%，说明GRNN-PNN对于合格图像的判断能力较高，满足印铁过程中在线检测的要求。同时再

次证明 BP 神经网络和 RBF 神经网络不适用此类问题, 无法满足制罐厂的需求。

### 3.3 抗噪性

由于图像采集设备、制罐厂环境以及铁片本身原因, 印铁图像在线检测受到很大的噪声干扰, 因此文中采用对样品集添加椒盐噪声的方法来测试方法对于噪声的抗干扰能力, 并使用准确率作为客观评价指标, 用于评价 GRNN-PNN 在不同噪声密度下能否判断整体铁片是否合格, 能否从噪声中有效识别污点、漏印等小面积缺陷图像, 结果见图 8。

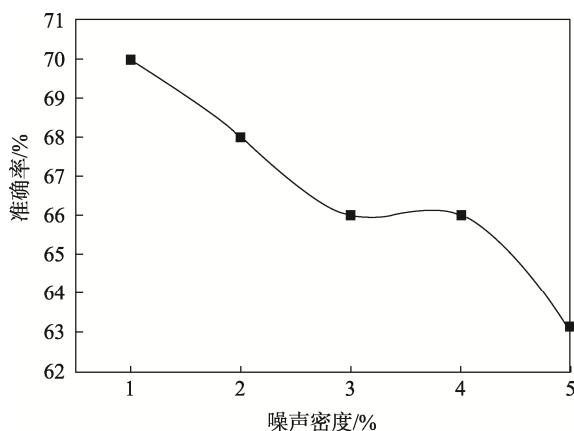


图 8 在噪声 GRNN-PNN 准确率  
Fig.8 GRNN-PNN accuracy under noise

通过观察图 8 可以发现, 随着噪声密度的增加, 准确率保持相对平稳, 说明该算法具有一定的抗噪能力。在 5% 的噪声下, 准确率为 63%, 说明该算法可以适用于工厂环境和普通的图像采集设备。

## 4 结语

文中提出了一种基于 GRNN-PNN 的印铁图像在线检测算法, 并对其分类机理进行了研究, 解决了目前制罐厂在印铁过程中对于缺陷识别不精准、不智能等问题。在分类过程中结合 PNN 算法, 能够智能判断印铁产品情况, 提高信息的识别率, 从而进一步提高了质检员对于印铁缺陷判断的准确性, 实现精准的分类识别, 并且对环境噪声具有较强的免疫效果。该方法对印铁图像可实现智能判断, 具有重要的参考意义。同时有利于质检员及时发现缺陷部位, 拥有广阔前景。

## 参考文献:

- [1] 周春霞, 魏敏, 唐正宁. 基于数学形态学的印刷网点图像分割方法[J]. 包装工程, 2007, 28(6): 28—29.  
ZHOU Chun-xia, WEI Min, TANG Zheng-ning. Image Segmentation Method Based on Mathematical Morphology[J]. Packaging Engineering, 2007, 28(6): 28—29.
- [2] 刘盛鹏, 方勇. 基于 Contourlet 变换和 IPCNN 的融合算法及其在可见光与红外线图像融合中的应用[J]. 红外与毫米波学报, 2007(3): 59—63.  
LIU Sheng-peng, FANG Yong. Fusion Algorithm Based on Contourlet Transform and IPCNN and Its Application in Visible light and Infrared Image Fusion[J]. Journal of Infrared and Millimeter Waves, 2007(3): 59—63.
- [3] CHEN F L, LIU S F. A Neural-network Approach to Recognize Defect Spatial Pattern in Semiconductor Fabrication[J]. IEEE Transactions on Semiconductor Manufacturing, 2000, 13(3): 366—373.
- [4] CARVALHO A A, REBELLO J M A, SAGRILLO L V S, et al. MFL Signals and Artificial Neural Networks Applied to Detection and Classification of Pipe Weld Defects[J]. NDT&E International, 2006, 39(8): 661—667.
- [5] 阮德重, 张登魁, 王国庆, 等. 基于 RBF 神经网络预测 2219 铝合金多层 TIG 焊接头拉伸性能研究[J]. 焊接技术, 2019(6): 22—27.  
RUAN De-zhong, ZHANG Deng-kui, WANG Guo-qing, et al. Prediction of Tensile Properties of 2219 Aluminum Alloy Multilayer TIG Welded Joints Based on RBF Neural Network[J]. Welding Technology, 2019(6): 22—27.
- [6] ADLY F, YOO D, MUHAIDAT S, et al. Randomized General Regression Network for Identification of Defect Patterns in Semiconductor Wafer Maps[J]. IEEE Transactions on Semiconductor Manufacturing, 2015, 28(2): 145—152.
- [7] CHA J, CHOI W. Deep Learning-based Crack Damage Detection Using Convolutional Neural Networks[J]. Computer-aided Civil and Infrastructure Engineering, 2017, 32(5): 361—378.
- [8] SPECHT D F. A General Regression Neural Network[J]. IEEE Transactions on Neural Networks, 2(6): 568—576.
- [9] 张宇航, 兰生. 基于广义神经网络与模糊聚类的变压器故障诊断[J]. 高压电器, 2016, 326(5): 121—125.  
ZHANG Yu-hang, LAN Sheng. Transformer Fault Diagnosis Based on Generalized Neural Network and Fuzzy Clustering[J]. High Voltage Apparatus, 2016, 326(5): 121—125.
- [10] 李善, 谭继文. KPCA-GRNN 网络在数控机床复合故障诊断中的应用 [J]. 煤矿机械, 2016, 37(3): 152—154.  
LI Shan, TAN Ji-wen. Application of KPCA-GRNN Network in Composite Fault Diagnosis of CNC Machine Tools[J]. Coal Mine Machinery, 2016, 37(3): 152—154.
- [11] 廖志伟, 叶青华, 王钢, 等. 基于 GRNN 的多故障自适应电力系统故障诊断[J]. 华南理工大学学报(自然科学版), 2005(9): 9—12.  
LIAO Zhi-wei, YE Qing-hua, WANG Gang, et al. Fault

- Diagnosis of Multi-fault Adaptive Power System Based on GRNN[J]. Journal of South China University of Technology (Natural Science Edition), 2005(9): 9—12.
- [12] 贺湘宇, 何清华. 基于多网络模型的工程机械液压系统故障诊断研究[J]. 中南大学学报(自然科学版), 2010, 41(4): 1385—1390.
- HE Xiang-yu, HE Qing-hua. Research on Fault Diagnosis of Hydraulic System of Engineering Machinery Based on Multi-network Model[J]. Journal of Central South University (Natural Science Edition), 2010, 41(4): 1385—1390.
- [13] 徐春梅, 张浩. 基于改进 D-S 的汽轮机组集成故障诊断研究 [J]. 系统仿真学报, 2011, 23(10): 2190—2194.
- XU Chun-mei, ZHANG Hao. Research on Integrated Fault Diagnosis of Steam Turbine Based on Improved D-S[J]. Journal of System Simulation, 2011, 23(10): 2190—2194.
- [14] 胡鸿志, 岑德炼, 吴汝琴, 等. 基于小波包和 BAGRNN 的模拟电路故障诊断方法[J]. 微电子学与计算机, 2018, 35(4): 42—45.
- HU Hong-zhi, CEN De-lian, WU Ru-qin, et al. Analog Circuit Fault Diagnosis Method Based on Wavelet Packet and BAGRNN[J]. Microelectronics & Computer, 2018, 35(4): 42—45.
- [15] 王玉梅, 刘国栋, 隋宗震. 基于 AR 模型和 GRNN 的结构损伤识别研究[J]. 低温建筑技术, 2019, 41(10): 44—47.
- WANG Yu-mei, LIU Guo-dong, SUI Zong-zhen. Study on Structural Damage Identification Based on AR Model and GRNN[J]. Low Temperature Building Technology, 2019, 41(10): 44—47.
- [16] 崔建国, 张善好, 于明月. 基于 GRNN-ELM 的飞机复合材料结构损伤识别[J]. 南京航空航天大学学报, 2017, 49(4): 468—473.
- CUI Jian-guo, ZHANG Shan-hao, YU Ming-yue. Structural Damage Identification of Aircraft Composites Based on GRNN-ELM[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2017, 49(4): 468—473.
- [17] ZHANG Chen-shuang, WANG Gui-jin, LIU Yong-pan. A global and Updatable ECG Beat Classification System Based on Recurrent Neural Networks and Active Learning[J]. Information Sciences, 2019, 501: 523—542.
- [18] DONALD F, SPECHT D F. Probabilistic Neural Networks[J]. Neural Networks, 1990, 3(1): 109—118.
- [19] 李新德, 杨伟东, 德泽特. 乔. 一种飞机图像目标多特征信息融合识别方法[J]. 自动化学报, 2012, 38(8): 1298—1307.
- LI Xin-de, YANG Wei-dong, DEZERT J. A Multi-feature Information Fusion Recognition Method for Aircraft Image Targets[J]. Acta Automatica Sinica, 2012, 38(8): 1298—1307.
- [20] 孙俊, 路心资, 张晓东. 基于高光谱图像的红豆品种 GA-PNN 神经网络鉴别[J]. 农业机械学报, 2016, 47(6): 215—221.
- SUN Jun, LU Xin-zi, ZHANG Xiao-dong, et al. Identification of Red Bean Variety GA-PNN Neural Network Based on Hyperspectral Image[J]. Transactions of the Chinese Society of Agricultural Machinery, 2016, 47(6): 215—221.
- [21] 孙丽娜, 王佳庆, 黄永红. 基于 PNN 的汽车 ABS 系统中压力调节器和轮速传感器的故障诊断[J]. 计算机测量与控制, 2020, 28(4): 16—21.
- SUN Li-na, WANG Jia-qing, HUANG Yong-hong. Fault Diagnosis of Pressure Regulator and Wheel Speed Sensor in Automobile ABS System Based on PNN[J]. Computer Measurement and Control, 2020, 28(4): 16—21.
- [22] 李鑫, 赵坤鹏, 朱凌寒. 改进的不变矩和 PNN 相结合的多品种产品识别算法[J]. 传感器与微系统, 2019(38): 132—135.
- LI Xin, ZHAO Kun-peng, ZHU Ling-han. A Multi-variety Product Identification Algorithm Based on Improved Invariant Moment and PNN[J]. Sensor and Microsystems, 2019(38): 132—135.
- [23] 李朝峰, 杨茂龙, 许磊. 概率神经网络与 BP 网络模型在遥感图像分类中的对比研究[J]. 国土资源遥感, 2004(4): 11—13.
- LI Chao-feng, YANG Mao-long, XU Lei. Comparative Study of Probabilistic Neural Network and BP Network Model in Remote Sensing Image Classification[J]. Remote Sensing for Land and Resources, 2004(4): 11—13.
- [24] 李廷鹏, 王满喜, 彭丹华. 基于 GRNN 和 PNN 的复杂电磁环境效应机理分析[J]. 现代电子技术, 2018, 41(23): 145—148.
- LI Ting-peng, WANG Man-xi, PENG Dan-hua. Analysis of the Aechanism of Complex Electromagnetic Environment Effects Based on GRNN and PNN[J]. Modern Electronic Technology, 2018, 41(23): 145—148.
- [25] 张瑾, 高军, 付衍文. 一种基于改进动态阈值的缺陷提取算法[J]. 包装工程, 2012, 33(11): 107—111.
- ZHANG Jin, GAO Jun, FU Yan-wen. A Defect Extraction Algorithm Based on Improved Dynamic Threshold[J]. Packaging Engineering, 2012, 33(11): 107—111.