

DOI:10.3969/j.issn.1001-4551.2015.03.011

PNN 与 BP 神经网络在钢板表面 缺陷分类中的应用研究*

郭联金¹, 罗炳军²

(1. 东莞职业技术学院 机电工程系, 广东 东莞 523808; 2. 广州炬森自动化设备有限公司, 广东 广州 510660)

摘要:针对钢板表面缺陷图像信噪比低、特征复杂多变而导致现有的钢板表面缺陷模式识别与分类方法存在的实时性差、精度低、适应性差等问题,研究了基于人工神经网络的分类器,以实现钢板表面缺陷进行实时有效的分类识别。根据钢板表面划痕、麻点、夹杂、锈蚀、辊印 5 类缺陷的特点,从缺陷图像信号中提取了几何特征、灰度特征和 Hu 矩特征,选取了能够比较全面表征缺陷特征信息的 13 维特征向量作为神经网络的输入数据,为缺陷识别和分类提供了依据。分别构造了概率神经网络 PNN 和 BP 神经网络分类器,对钢板的表面缺陷进行了分类测试,并对测试结果进行了对比分析。实验结果表明,PNN 和 BP 神经网络的识别率分别为 87% 和 81%。PNN 在识别准确率、训练速度、追加样本的能力等几方面的综合性能优于 BP 神经网络。

关键词: PNN; BP 神经网络; 钢板表面; 缺陷分类

中图分类号: TB553; TH878

文献标志码: A

文章编号: 1001-4551(2015)03-0352-06

Application of probabilistic neural network and BP networks for steel plate surface defects classification

GUO Lian-jin¹, LUO Bing-jun²

(1. Department of Electrical and Mechanical Engineering, Dongguan Polytechnic, Dongguan 523808, China;
2. GreatSense Automatic Instrument Co., Ltd., Guangzhou 510660, China)

Abstract: Aiming at the low SNR and feature complex of the steel surface defect images, which leading to the existing steel surface defect pattern recognition and classification method has poor real-time, low precision, and poor adaptability, classifier based on artificial neural network was studied, to achieve the classification of the steel surface defect. According to the characteristics of surface scratch, corrosion, pitting, inclusions and roller printing, the five typical defects on steel plate surface, geometric features, grayscale characteristics and Hu moment feature were extracted from defect image signal. Comprehensive characterizations of defect feature information of the 13 d feature vector were selected as input of neural network, the basis for defects recognition and classification was provided. To classify the surface defects of steel plate, probabilistic neural network PNN and BP neural network classifier were constructed respectively, and the test results were compared and analyzed. The resules indicate that PNN and BP neural network recognition rate were 87% and 81% respectively. It shows that PNN is better than that of BP neural network in comprehensive performance of recognition accuracy, training speed and the ability of increasing samples.

Key words: PNN; BP neural network; steel plate surface; defects classification

0 引 言

钢板在加工制造业中应用广泛。由于受原材料、轧制工艺、加工设备等因素的影响,钢板表面出现裂纹、孔洞、氧化皮、辊印、麻点、色斑等缺陷,对其耐磨

性、抗疲劳性、抗腐蚀性和电磁特性等主要特性都有不同程度的影响^[1]。传统的人工目视检测方法因检测效率低、误检率高,且耗费大量人力,已不能满足当前钢板生产的需要。近年来,随着计算机技术、自动化技术的发展,以及人工智能、神经网络等理论的成熟,以

收稿日期: 2014-10-22

基金项目: 东莞职业技术学院 2014 年科研基金项目(2014c07)

作者简介: 郭联金(1981-),女,广东广州人,讲师,主要从事测控技术方面的研究。E-mail: echo-guo@163.com

机器视觉技术为核心的钢板表面缺陷检测技术已成为当前研究的重点和趋势^[2]。目前国外基于机器视觉的金属表面缺陷检测技术已经比较成熟,以美、日、德为主导的金属表面检测系统已获得应用^[3]。这类系统能够在线实时检测带钢表面缺陷并加以分类处理。如德国 Parsytec 公司开发的 HTS-2 冷轧带钢自动表面质量检测系统,可统计和存储缺陷的图像、种类、数量和位置等信息,自动判定钢卷表面质量等级。该系统采用了基于人工神经网络的分类器设计技术,可在轧制速度为 300 m/min 的情况下,检测最小尺寸为 0.5 mm 的带钢表面缺陷^[4]。但其缺陷识别率的高低受限于专家样本组的完善程度及分类器的参数设置^[5]。国内华中科技大学等高校和钢铁企业也都致力于该领域的研究,其检测精度和稳定性方面有待进一步提高。

由于受光源光照均匀性、光色及现场环境的影响,系统采集的钢板表面图像的信噪比很低,而缺陷区域又较小,形状也不规则,各类缺陷间的特征差别不明显,因此钢材表面缺陷识别率难以提高。缺陷分类就是实现从缺陷的特征空间到类别空间的非线性映射^[6]。人工神经网络(ANN)作为描述和刻画非线性系统的一种有效工具,在模式识别与分类中获得了广泛应用。其中,误差反向传播(BP)神经网络因其非线性逼近性能好、易于硬件实现和泛化能力强,成为目前应用最广的一类神经网络^[7-9]。概率神经网络(PNN)的训练过程简单,算法容易设计,常用于模式识别与分类^[10]。

现阶段的研究大多采用 BP 神经网络来实现钢板表面缺陷的分类,而采用 PNN 作为钢板表面缺陷分类器的研究还比较少。为了提高钢板表面缺陷检测的效率,笔者选择和设计有效提高钢板表面缺陷识别率的分类器,根据钢板表面缺陷图像的特征,用 BP 神经网络和 PNN 对钢板表面的 5 种缺陷分别进行分类识别。其实现过程为:将采集的缺陷图像进行预处理,得到含目标缺陷的二值图像,再对目标图像进行特征提取和选择。根据缺陷特征向量,分别以 BP 神经网络和概率神经网络 PNN 为分类器,对缺陷图像训练集进行分类模型训练,利用测试集对训练好的分类识别模型预测分类结果。

1 缺陷特征提取和选择

特征提取和特征选择是为了选出一组对识别最有效、数量最少的特征。这种理想的特征应该具有可区分性、可靠性和独立性^[11]。这里主要以几何特征、灰度特征和 Hu 矩特征来表征目标图像的缺陷信息。本研究根据钢板制品常见的划痕、麻点、夹杂、锈蚀、辊印 5 种表面缺陷的图像特征进行提取。经过实验,笔者在众多特征中选取能够比较全面地反映缺陷信息的圆形度、矩形度、细长度 3 个特征参数;均值、方差、歪度、峭度、能量和熵直方图 6 个灰度特征;以及 Hu 不变矩的 4 组特征参数,组成 13 维的特征向量作为神经网络的输入数据,为缺陷识别提供依据。所提取缺陷样本的特征数据如表 1 所示。

表 1 缺陷样本的特征提取数据

样本	几何特征			灰度特征						不变矩特征			
	圆度	矩形度	细长度	均值	方差	歪度	峭度	熵	能量	$\varphi_1 \times E-3$	$\varphi_2 \times E-7$	$\varphi_3 \times E-13$	$\varphi_4 \times E-13$
划痕	1.882	0.184	12.64	138.5	680.2	1.932	2.214	-0.214	0.681 6	1.264	1.395	0.764	0.694
辊印	1.384	0.679	3.814	105.7	225.4	2.103	16.44	7.746	0.022 7	1.305	3.844	3.570	3.163
划痕	3.102	0.197	10.19	140.7	706.8	2.141	2.176	-0.195	0.624 5	1.376	1.400	0.790	0.731
麻点	0.963	0.796	1.869	132.1	826.1	0.462	3.384	6.821	0.010 7	1.617	7.669	5.433	6.757
夹杂	1.464	0.436	3.277	167.6	2214	-0.142	-1.223	0.342	0.184 1	1.549	3.194	0.387	0.447
锈蚀	1.467	0.873	3.673	146.3	837.5	0.822	3.577	5.816	0.016 0	1.721	8.174	0.973	1.684
麻点	1.107	0.891	1.963	146.4	789.4	0.648	2.861	5.898	0.014 7	1.724	7.972	4.375	6.623
夹杂	1.632	0.541	2.865	154.0	2 036	-0.126	-1.064	0.502	0.204 2	1.604	3.160	0.406	0.459
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
夹杂	1.584	0.579	3.567	170.1	2 257	-0.147	-1.168	0.635	0.213 1	1.581	3.207	0.395	0.442
锈蚀	1.358	0.701	3.043	152.3	1 003	1.026	4.014	5.794	0.012 4	1.863	6.695	0.887	1.368
划痕	1.965	0.251	6.852	138.4	732.4	1.865	2.742	-0.306	0.734 4	1.305	1.517	0.783	0.738
麻点	1.026	0.906	2.544	135.6	951.3	0.839	2.813	7.650	0.009 3	1.586	8.074	4.404	5.629
辊印	1.374	0.693	3.624	127.4	1 374	2.345	24.10	7.059	0.008 3	1.254	3.373	2.986	3.631
锈蚀	1.475	0.843	3.254	156.6	938.0	0.956	3.703	6.083	0.010 3	1.815	5.882	1.474	1.486
辊印	1.265	0.618	3.416	119.8	1 502	2.394	24.43	5.647	0.007 6	1.356	3.226	3.627	3.818

从表 1 可见,不同种类的缺陷,其各特征参数也在不同的值域内。如麻点较为接近圆形,其圆形度在 1 左右,主要集中在 0.6~1.2,矩形度在 0.7~1.0,细长度比其他缺陷小(1.5~2.5)。划痕一般为细长形,其圆形度(1.7~3.2)与细长度(4~15)都比其他缺陷大,而矩形度(0.1~0.4)则明显比其他缺陷小。夹杂的歪度和峭度较多出现负值,且其熵值(0.1~0.9)较小。辊印的峭度最大(10~30),熵值较大(4~8),而能量(0.003~0.04)较小。锈蚀的 Hu 不变矩 Φ_2 (4~10)普遍比其他缺陷大。尽管各类缺陷的特征参数区间存在交集,但是综合利用 13 个特征参数就能够对具体的缺陷类型作出判决。

2 分类识别模型设计

2.1 BP 神经网络

BP 网络是一种按误差逆传播算法训练的多层前馈网络,是现今最广泛应用的神经网络模型之一。应用 BP 神经网络识别钢板表面缺陷的过程如下^[12]:

- (1) 输入训练样本。将输入样本进行归一化处理,使训练样本的输入特征值在 $[-1, 1]$ 之间。
- (2) 初始化网络的权值、阈值。
- (3) 设计网络结构,采用典型的三层结构(输入层、隐含层、输出层),隐含层节点数参考经验公式 $k = \sqrt{n + m} + a$ (k —隐含层节点数, n —输入层节点数, m —输出节点数, a —1~10 之间的调节常数),改变 k 值,用同一样本集训练,从中确定网络误差最小时对应的隐含层节点数。
- (4) 选择激活函数和相关参数。选取神经元作用函数,设定学习系数、期望误差和最大迭代次数等,选择神经网络的学习规则。
- (5) 设定输出期望值。针对不同类型的输入缺陷样本,设定一个输出向量。
- (6) 进行 BP 网络训练,获取最终的权值与阈值矩阵。
- (7) 输入待识别的缺陷样本,进行分类识别。

2.2 概率神经网络(PNN)

2.2.1 PNN 的模型结构

PNN 是由径向基函数网络发展而来的一种前馈型神经网络。它基于概率统计思想,由 Bayes 分类规则构成,是一种有监督的网络分类器。在进行分类模式识别时,笔者采用 Parzen 窗函数密度估计方法估算条件概率,由 Parzen 方法得到的概率密度函数估计式如下:

$$f_A(\mathbf{X}) = \frac{1}{(2\pi)^{P/2} \delta^P} \frac{1}{m} \quad (1)$$

$$\sum \exp - \frac{(\mathbf{X} - \mathbf{X}_{ai})^T (\mathbf{X} - \mathbf{X}_{ai})}{2\delta^2} \quad (2)$$

式中: \mathbf{X}_{ai} —缺陷模式的第 i 个训练向量, m —缺陷模式的训练样本数, δ —平滑参数。

对应以样本点为中心的钟状曲线的宽度,对分类结果有着重要影响。PNN 的模型结构由输入层、模式层、累加层、决策层组成,如图 1 所示。其工作过程为:待识别样本 X 由输入层直接送到模式层各类别单元,进行向量输入向量 X 与连接权值 W 的点积计算,再送入累加层。在累加层中,各单元只与相应类别的模式单元相连,并依据 Parzen 方法求和估计各类别的概率;在决策层中,根据对输入向量的概率估计,按 Bayes 分类规则将输入向量分到最大后验概率值的类别^[13]。

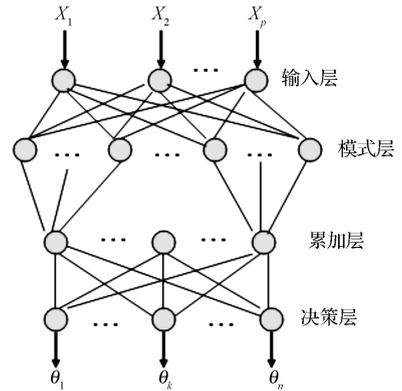


图 1 PNN 的结构

基于 PNN 的缺陷识别是利用其强大的非线性处理能力,将缺陷样本的特征空间映射到缺陷类型空间中,而形成一个具有较强容错能力和结构自适应能力的识别网络系统^[14],以此提高识别率。

2.2.2 概率神经网络的构建过程

- (1) 采集缺陷特征数据。选取剪性强、包括足够的反映缺陷特征的数据作为训练和测试数据。
- (2) 根据已有的缺陷数据训练网络。将已有的缺陷特征数据作为训练样本的输入,以缺陷类别作为期望输出。通过训练网络从而得缺陷分类识别的 PNN 网络模型。
- (3) 进行网络性能测试。将各层神经元间的连接权值代回网络中,对训练样本进行回归模拟,当训练样本的期望值输出与 PNN 网络的仿真输出一致时,说明网络已训练成功,可用来预测未知样本的类别。
- (4) 利用已训练好的网络进行预测。利用已构建的 PNN 网络来对未知的缺陷样本数据进行分类。

3 缺陷识别实验

本研究选择现场采集的钢板表面缺陷样本 300 个,将其分成两组,一组为训练集,每类缺陷 40 个,共 200 个样本;另一组为验证集,每类缺陷 20 个,共 100 个样本。

3.1 网络输入数据的归一化

由表 1 可见,钢板缺陷图像的特征提取值大小不一,有的特征值达到负的几十次方数量级,有的达到正的几次方数量级。为了避免不同种类的特征数据以及同一种类不同特征之间的数量级差距对分类准确率的影响,消除参数量纲的不统一,将参数化为同一范围内的数值,并加快网络的训练速度,本研究将每个特征值归一化为 $[-1, 1]$ 之间的数值。

3.2 BP 网络设计

用 BP 神经网络设计缺陷分类器时,本研究根据提取到的 13 维特征向量设定输入层神经元数为 13,需要识别的缺陷数为 5,输出层神经元数为 5,学习速

率取 0.1,精度要求取 0.001,最大训练次数为 1000。为避免学习算法不收敛,提高学习速度,设期望输出为相应小数,即期望输出的 0 和 1 分别用 0.001 和 0.999 代替。期望输出矩阵 T 如下:

$$T = \begin{matrix} y_1 & 0.999 & 0.001 & 0.001 & 0.001 & 0.001 \\ y_2 & 0.001 & 0.999 & 0.001 & 0.001 & 0.001 \\ y_3 & 0.001 & 0.001 & 0.999 & 0.001 & 0.001 \\ y_4 & 0.001 & 0.001 & 0.001 & 0.999 & 0.001 \\ y_5 & 0.001 & 0.001 & 0.001 & 0.001 & 0.999 \end{matrix}$$

式中: $[y_1 \ y_2 \ y_3 \ y_4 \ y_5]$ —划痕、麻点、夹杂、锈蚀、辊印 5 种缺陷形式的期望输出矢量矩阵 T 。

隐含层神经元个数分别取 $n = \{6, 7, \dots, 16\}$,通过对各种算法进行比较实验,采用仿真速度快、训练精度高的 Levenberg-Marquardt 算法进行训练。网络训练结果如表 2 所示,综合考虑网络性能和训练速度,隐含层节点数为 12 的 BP 神经网络的训练误差最小、训练时间和次数较少,逼近效果最好,所以将网络隐含层的节点数确定为 12。

表 2 不同隐含层节点数的网络训练结果

节点数	6	7	8	9	10	11	12	13	14	15	16
训练次数	1 000	1 000	1 000	168	142	113	84	154	268	1000	1000
网络误差	0.037 2	0.024 5	0.017 6	0.000 99	0.000 89	0.000 98	0.000 89	0.000 94	0.000 98	0.015 2	0.031 7

在隐含层节点数为 12 时,笔者分别采用梯度下降 BP 算法、自适应学习率算法、Levenberg-Marquardt 3 种常用的 BP 网络改进模型进行比较实验,训练效果如图 2 所示。3 种算法的训练时间分别为 14 s、3 s、2 s,

迭代次数分别为 1 000、168、84,后两种算法均能达到期望误差,而第一种算法经过 1 000 次训练仍未达期望误差。综合比较,本研究选择训练效果最好的 Levenberg-Marquardt 算法作为 BP 网络的训练函数。

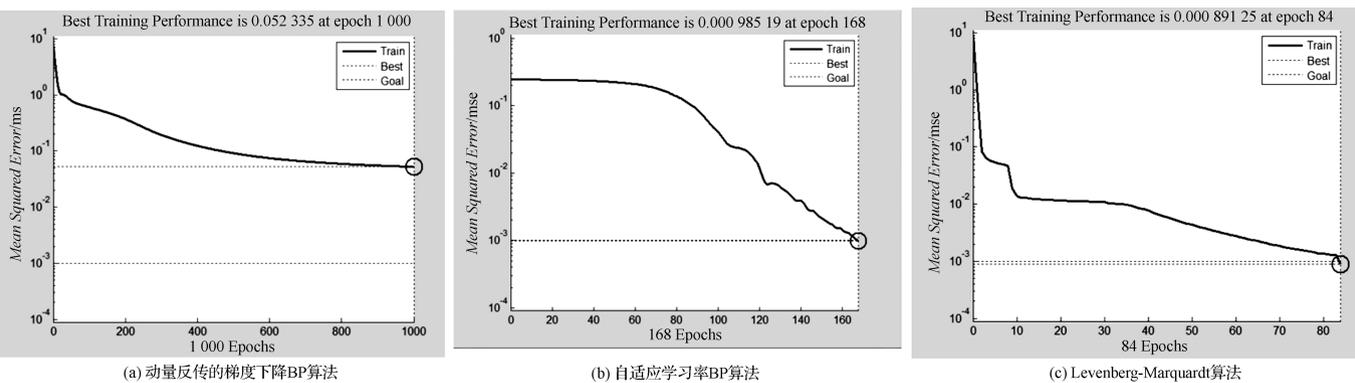


图 2 3 种算法的训练效果

3.3 BP 网络的缺陷识别实验结果与分析

训练完成后,本研究对训练好的网络进行测试,抽取每类缺陷 20 个样本,共 100 个未训练的新数据,作为网络测试的输入数据,BP 神经网络的分类识别结果如表 3 所示。由表 3 可见,共 100 个检测样本,均未出现拒识,各类缺陷误判的个数合计为 19,

因此 BP 网络对各类缺陷的识别正确率平均为 81%,分类基本准确,用时 2.43 s。对划痕、锈蚀两种缺陷的识别率较高,达到 85%,而对夹杂的识别率最低,仅为 75%。可见,采用 BP 神经网络法对训练样本特征值进行多次训练后再进行分类识别时,识别结果具有较高的稳定性和容错性。但在新增训练样本或

除去某些旧的训练样本时,需要对修改过的训练样本重新进行训练。

表 3 BP 神经网络的分类识别结果

缺陷类型	划痕(20)	麻点(20)	夹杂(20)	锈蚀(20)	辊印(20)
划痕	17	0	1	1	0
麻点	0	16	1	0	2
夹杂	1	1	15	1	1
锈蚀	2	1	2	17	1
辊印	0	2	1	1	16
识别率	85%	80%	75%	85%	80%
总识别率	81.0%				

3.4 PNN 的缺陷识别实验结果与分析

首先确定 PNN 网络的结构,根据径向基函数的特点,其输入层神经元个数与输入样本向量个数相同,输出层神经元个数等于训练样本数据的种类个数,网络的输出层是竞争层,每个神经元分别对应于一个数据类别。则本研究设计的 PNN 网络的结构为:输入层有 13 个神经元,输出层有 5 个神经元。中间层神经元的传递函数为高斯函数,输出层的传递函数为线性函数。

笔者首先用提取的 200 组特征数据作为训练输入样本 P 和目标样本 T,检验网络对训练数据的分类;用另外的 100 组作为检验样本数据以检验网络的泛化性能。在 Matlab 中创建 PNN 网络,创建函数为 net = newpnn(P,T,SPREAD)^[12]。为分析 SPREAD 对网络性能的影响,仿真过程中将 SPREAD 分别取 20、10、1.5、1、0.5、0.1、0.005、0.001 进行训练和分类、总测试精度分别对应为 31%、52%、73%、82%、87%、85%、76%、59%。可见,对于概率神经网络方法,传播率过大或过小,网络模型可分性都比较差,宜取 0.1~1 之间的数据,尤以 0.5 左右较佳。故本研究将 SPREAD

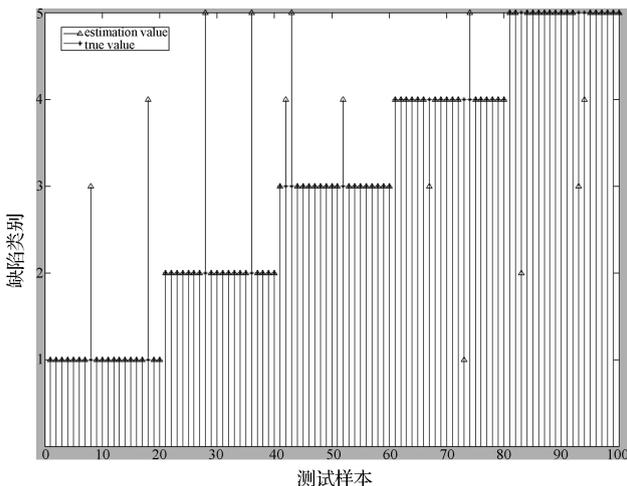


图 3 PNN 的分类结果

“*”——真实缺陷,“△”——PNN 的分类结果

值取为 0.5,把 100 个检验样本输入已经训练好的 PNN 网络中,此时 PNN 网络的分类结果如图 3 所示,其统计数据如表 4 所示。由表 4 可见,以 PNN 作为缺陷分类器,共 100 个检验样本,均未出现拒识,其中出现误判的样本个数为 13,故总识别率为 87.0%,识别时间为 0.461 s。其中划痕、麻点类缺陷识别率相对较高。某些仿真样本出现误判,可能因钢板表面各种缺陷形状相似,以及缺陷图像处理、特征提取,或是训练样本不足,未能全面涵盖缺陷特征信息而造成的缺陷特征信息缺失,从而影响了识别率,这有待于以后对算法进行优化。

表 4 PNN 网络的缺陷分类统计

缺陷类型	划痕(20)	麻点(20)	夹杂(20)	锈蚀(20)	辊印(20)
1 划痕	18	0	0	1	0
2 麻点	0	18	0	0	1
3 夹杂	1	0	17	1	1
4 锈蚀	1	0	2	17	1
5 辊印	0	2	1	1	17
识别率	90%	90%	85%	85%	85%
总识别率	87.0%				

结果分析:①由于 PNN 对缺陷样本噪声具有较强的鲁棒性,将 PNN 与 BP 神经网络应用于钢板表面缺陷的识别分类中,PNN 比 BP 神经网络准确率高,用时少。②PNN 的隐层节点个数相对确定,训练速度快,工程应用中易于实现。③BP 神经网络初始权值随机分配,隐层节点个数不易确定,难以选择合适的学习速率和改进算法,故其分类结果的重复性和可靠性差,需要进行反复测试才能取得优化参数和最佳分类性能。④新增训练样本易于加进已训练好的 PNN 分类器中,随着训练样本的增加,缺陷识别率可进一步提高。

4 结束语

基于机器视觉的钢板表面缺陷的计算机自动分类识别是当前的研究热点。钢板表面各类缺陷的图像特征没有明确的界限,即使同一类缺陷,其图像特征也存在较大差异。根据钢板表面 5 类缺陷的特点,本研究从缺陷图像信号中提取特征信息,并选择了 13 组能比较有效区分不同缺陷的特征参数,分析了 BP 神经网络与 PNN 两种算法模型的结构及其实现过程。笔者通过优化模型参数,分别设计了基于 BP 及 PNN 的人工神经网络分类器,对两种分类器进行训练和分类测试实验。PNN 和 BP 神经网络的识别率分别为 87% 和 81%。实验结果表明,BP 神经网络分类器的参数设置复杂,训练结果不稳定。PNN 在识别准确率、训练速度、追加样本的能力等几方面的综合性能优于 BP 神

神经网络。由于实验研究样本量有限,对于大容量样本下两种分类器的识别精度、泛化能力等性能还待于进一步研究。

参考文献(References):

- [1] 程万胜. 钢板表面缺陷检测技术的研究[D]. 哈尔滨: 哈尔滨工业大学机电工程学院, 2008.
- [2] 周超. 基于图像处理的钢板表面缺陷检测系统的研究[D]. 锦州: 辽宁工业大学电气工程学院, 2013.
- [3] 陈文达. 金属工件表面瑕疵检测技术的研究与开发[D]. 无锡: 江南大学通信与控制工程学院, 2013.
- [4] 刘海博. 基于机器视觉的钢板表面缺陷检测系统研究[D]. 长春: 吉林大学计算机科学与技术学院, 2008.
- [5] 戴卫东, 安百光. Parsytec 自动表面缺陷检查系统在冷轧连续退火线上的应用[J]. 冶金自动化, 2009(2): 47-51.
- [6] 张洪涛, 计时鸣. 基于改进的BP神经网络钢板表面缺陷分类算法研究[J]. 浙江工业大学学报, 2010(4): 388-390.
- [7] LIPPMANN R P. Patten classification using neural networks

trained by gradient descenty [J]. **IEEE Transactions on Neural**, 2007, 18(7): 1527-1554.

- [8] 马立新, 吴兴锋, 费少帅. 基于FFT和神经网络的APF故障诊断方法[J]. 机电工程, 2014, 31(11): 1495-1498.
- [9] 朱文材, 胡海刚, 朱鸣鹤, 等. 遗传神经网络在轴系故障诊断中的应用[J]. 机电工程, 2012, 29(2): 136-141.
- [10] 陈渊. 基于小波包和概率神经网络的焊接缺陷识别[J]. 仪表技术与传感器, 2010(8): 89-92.
- [11] 方小明. 基于机器视觉的带钢表面缺陷识别研究[D]. 西安: 西安理工大学计算机系, 2009.
- [12] 王小川, 史峰, 郁磊, 等. Matlab神经网络43个案例分析[M]. 北京: 北京航空航天大学出版社, 2013.
- [13] 张德丰. Matlab神经网络应用设计[M]. 2版. 北京: 机械工业出版社, 2012.
- [14] 阮晴, 罗飞路, 罗诗途, 等. 基于特征评估和概率神经网络的超声焊缝缺陷识别[J]. 测试技术学报, 2012(2): 125-131.

[编辑: 李辉]

本文引用格式:

郭联金, 罗炳军. PNN与BP神经网络在钢板表面缺陷分类中的应用研究[J]. 机电工程, 2015, 32(3): 352-357.

GUO Lian-jin, LUO Bing-jun. Application of probabilistic neural network and BP networks for steel plate surface defects classification[J]. *Journal of Mechanical & Electrical Engineering*, 2015, 32(3): 352-357.

《机电工程》杂志: <http://www.meem.com.cn>

(上接第347页)

求出系统的全局Pareto最优解集,而且运算速度也相对较快,流量分配的误差比在0.5%左右,符合实验设计的要求。算法的Java实现和控制界面的设计更加直观、有效地反映了整个系统的优化性能,并且可以通过控制界面来远程控制各台计量泵的运行和参数的设置,使得操作更加安全可靠。实验结果表明,该调度方法可以有效地完成特定的投料任务。

参考文献(References):

- [1] 陈雨田, 黄晓斌, 陈展. 计量泵, 磁力泵, 高速泵和增压泵的应用介绍与市场发展[J]. 化工设备与管道, 2006, 43(6): 35-38.
- [2] YANG Zhen-yu, BORSTING H. Optimal Scheduling and Control of a Multi-Pump Boosting System[C]//International Conference On Control Application 2010. Japan: [s. n.], 2010: 2071-2076.
- [3] 魏发远, 李世其. 基于混合遗传算法的多目标动态优化设计[J]. 宇航学报, 2004, 25(6): 610-614.
- [4] 宋文武, 李登松, 符杰. 基于微遗传算法的低比转速泵

叶轮的优化[J]. 流体机械, 2014, 42(4): 42-46.

- [5] 毕书东. 多目标遗传算法的研究[D]. 淮南: 安徽理工大学计算机科学与技术系, 2007.
- [6] ROBIN W, MOHD S. Evaluation of genetic algorithms for optimal reservoir system operation[J]. **Journal of Water Resources Planning and Management**, 1999, 125(1): 25-33.
- [7] 张承慧, 夏东伟, 等. 城市水工业系统泵站优化调度问题建模方法研究[J]. 控制与决策, 2004, 19(5): 582-588.
- [8] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multi-objective genetic algorithm: NSGA-II [J]. **IEEE Transaction on Evolutionary Computation**, 2002, 6(2): 182-197.
- [9] 祁荣宾, 钱锋. 基于精英选择和个体迁移的目标遗传算法[J]. 控制与决策, 2007, 22(2): 164-168.
- [10] 吕校春, 李玲莉. 基于Swing的Java GUI组件开发[J]. 机械工程师, 2008, 1(5): 129-131.
- [11] 杨铁军, 黄琳. MINA网络框架和RMI的对比研究[J]. 计算机应用与软件, 2010, 27(9): 222-239.

[编辑: 李辉]