基于混合神经网络模型的磨粒电荷检测方法研究 *

薛 倩，王一虎

（中国民航大学 电子信息与自动化学院，天津 300300）

摘 要：由于传统的滑油磨粒在线监测方法无法获取电荷分布位置信息，难以准确测量荷电颗粒数目及其携带的电荷量。为此，本文提出一种基于静电层析成像（Electrostatic tomography，EST）技术和深度学习算法的荷电颗粒检测方法。对EST传感器测量数据采用BP神经网络算法重建出测量截面上电荷的分布图像，采用卷积神经网络（Convolutional neural networks，CNN）算法分析重建图像以识别荷电颗粒数目，将识别的颗粒数目和传感器测量数据组合成输入向量，通过1个多层前馈网络确定带电颗粒数目、感应电荷值与颗粒电荷量值之间的映射关系，得到准确的各颗粒的电荷量值。实验结果表明：混合神经网络模型对数据样本的测量误差为9%，可满足滑油监测对于准确性的要求。

关键词：滑油检测；荷电磨粒；神经网络；电荷检测；静电层析成像

中图分类号：TP391.9 **文献标识码**：A **文章编号**：1001-4055（2022）06-210002-09

DOI：10.13675/j.cnki. tjjs. 210002

Charge Detection Method of Debris Based on Hybrid Neural Network

XUE Qian，WANG Yi-hu

（College of Electronic Information and Automation，Civil Aviation University of China，Tianjin 300300，China）

Abstract：It is difficult to determine the distribution of charging debris in lubricating oil and accurately measure the number and charge value of charging debris with traditional on-line monitoring methods. To address this problem，a charging debris detection method based on electrostatic tomography（EST）technology and deep learning algorithm is proposed in the study. First，BP neural network algorithm is adopted to reconstruct the image of charge distribution on the measured section. Thereafter，the reconstructed image is analyzed with convolutional neural network（CNN）algorithm to identify the number of charging debris. Finally，the number of charging debris and the measured data obtained by the EST sensor are combined into an input vector and then transferred to a multilayer feed forward network. Therefore，the mapping relationships between the amount of charging debris，the induced charge value and the charge value of each charging debris can be formed. In this way，the accurate charge value of each charging debris can be obtained. The experimental results demonstrated that the measurement error of the mixed neural network model was about 9%，which could meet the requirement of on-line monitoring of lubricating oil.

Key words：Lubricating oil monitoring；Charging debris；Neural network；Charge detection；Electrostatic tomography

* **收稿日期**：2021-01-01；**修订日期**：2021-04-26。

基金项目：国家自然科学基金面上项目（61871379）；中央高校基本科研业务费中国民航大学专项（3122019052）。

通讯作者：薛 倩，博士，教授，研究领域为航空无损检测和电学层析成像。

引用格式：薛 倩，王一虎. 基于混合神经网络模型的磨粒电荷检测方法研究[J]. 推进技术，2022，43(6):210002.（XUE Qian，WANG Yi-hu. Charge Detection Method of Debris Based on Hybrid Neural Network[J]. *Journal of Propulsion Technology*，2022，43(6):210002.）

1　引　言

航空发动机由于长时间工作在高温、高压的环境中，其主要零部件出现异常磨损的概率相对较高，磨损过程中产生的荷电磨粒随油液进入润滑系统，并受油液的绝缘保护而保持荷电特性。一般认为严重磨损故障产生的磨粒会携带有更多的电荷量，所以对滑油中的磨粒电荷量进行监测可为航空发动机的健康状态提供参考，对保障飞机安全可靠运行具有重要意义。基于静电感应原理的静电监测技术[1-3]是一种有效的在线油液磨粒监测技术，广泛应用于航空航天等领域[4-6]。而静电层析成像技术(EST)是在传统静电传感器的基础上，采用阵列式电极，通过电极上的感应电荷的测量值反演得到电荷分布图像，从而改进传统传感器只能测得区域内磨粒电荷的静电场叠加值，无法获取磨粒的数量、位置信息和携带的电荷量的问题。

然而，EST是被动感应式的成像，测量值数等于电极数，欠定性相对于电阻抗层析成像(EIT)更加严重，成像效果不佳，并且测定滑油磨粒携带的电荷量大小首先需要确定磨粒的准确个数和位置。近年来，为了提高成像质量以得到准确的电荷分布情况，研究人员从静电传感器结构、信号处理、图像重建等方面提出了改进：2010年，李绍成等[7]优化设计了油液磨粒监测静电传感器尺寸，并成功监测到了静电信号。2016年，冒慧杰等[8]对传感器输出信号与磨粒的位置关系进行仿真，研究了输出信号与磨粒位置的对应关系，为测量油滴的电荷量提供了新思路。2018年，陈进[9]完成了电荷颗粒注入试验，搭建了静电在线监测试验平台，验证了滑油系统磨粒在线监测的可行性。唐欣[10]研究了半球式静电传感器阵列在燃气轮机尾气颗粒监测中的应用，与压缩感知理论相结合进行异常颗粒重构，但对多颗粒重构时出错概率较大。付宇等[11]得出了静电传感器感应信号的输出表达式，为电荷量的测量提供了理论参考。2019年，陈志雄等[12]改进了静电传感器模型，分析了感应电荷量与磨粒位置的关系，但未得到准确的电荷量。李晓青等[13]研究了单个油滴带电量和电压、油滴大小之间的关系，且得到了湿度越高电荷量消散速度越快的结论。薛倩等[14]基于压缩感知理论对EST进行图像重建，明显改进了成像质量，对不同位置的1~3个电荷分布可较准确地重建。2020年，郭家琛等[15]研究了颗粒带电量和传感器脉冲之间的关系，有待得到实验验证。钟志荣等[16]采用平面阵列棒状传感器，提出了基于Tikhonov正则化方法的重建颗粒电荷分布的算法，对单个电荷量的测量有较好的测试结果。随着机器学习、深度学习的广泛应用，已有研究人员将深度学习算法引入ET的图像重建，以期改善逆问题的欠定性对成像质量的影响。马敏等[17]将改进的卷积神经网络应用于ECT图像重建中，提出了MSCNN-LSTM-BP网络模型，提高了数据样本的分类准确率。2019年，李峰等[18]提出了一种6层全连接深度网络的图像重建算法，图像重建结果具有较高的重建精度，但其抗噪性和适用性仍需进一步提高。

在参考前人已有电荷量监测方法及工作的基础上，结合深度学习的强大优势，利用传感器感应电荷值，依次得到电荷分布图像、准确的电荷数目、各个颗粒的电荷量。研究了基于混合神经网络模型的新型静电电荷检测方法：将阵列式传感器测量值作为输入，通过BP反演成像得到较高质量的重建图像，再将图像输入到CNN中识别出准确的电荷数目，然后参考循环神经网络的思想[19]，通过增加一个隐层将电荷数目传递到BP神经网络，综合电荷数目与感应电荷值判断测量截面上各颗粒的电荷值，以克服多个带电颗粒同时存在时无法准确检测电荷量的问题。

2　EST系统原理

静电层析成像技术是基于静电感应原理，利用阵列式静电传感器测量被测物体内部的电荷分布，其原理如图1所示。当带有电荷的滑油磨粒经过阵列传感器截面时，各个测量电极上会产生相应的感应电荷，感应电荷信号经信号调理电路处理后发送到上位机，通过对信号进一步处理得到电荷量值，并利用图像重建算法获得电荷分布图像。

EST技术包括正问题和逆问题，正问题是由电荷分布获得敏感场边界处的感应电荷值，并建立管道内电荷颗粒分布和静电传感器阵列12极片上感应电荷的对应关系

$$\boldsymbol{Q} = \boldsymbol{SG} \tag{1}$$

式中$\boldsymbol{Q}$为测量得到的12×1维的感应电荷矩阵；$\boldsymbol{G}$为场内317×1维的电荷分布向量；$\boldsymbol{S}$表示12×317维的灵敏度矩阵。

灵敏度矩阵的定义为

$$S(x,y,z) = \left| \frac{Q}{q(x,y,z)} \right| \tag{2}$$

式中q表示点电荷的电量；Q表示感应电极上的

感应电荷量。

阵列式静电传感器模型如图2所示，本文采用了12电极设计，利用有限元仿真软件对电极尺寸进行优化，阵列电极均匀放置在管道外壁上，电极片轴向长度为33mm，占空比为0.9。实验所使用的传感器管道直径为10cm，将10cm×10cm的正方形截面以0.5cm为间隔剖分成20×20的网格，其中位于管道内部的点有317个。网格剖分示意图如图2(c)所示。通过仿真或实验可获得单位电荷分别放置于317个像素点时，传感器的12个电极上的感应电荷值，建立起感应电荷向量与各点像素值之间的映射关系(灵敏度矩阵$\boldsymbol{S}$)。

EST系统逆问题即图像重建，由上位机利用图像重建算法对公式(1)中图像灰度向量$\boldsymbol{G}$进行求解。其中，$\boldsymbol{Q}$为已知量，是阵列传感器感应电极上的测量值。

3　电荷检测方法

本文针对EST滑油监测的特点，提出了基于EST技术和深度学习算法的混合神经网络荷电颗粒电荷量检测方法，电荷检测模型基本结构如图3所示，利用设计的12电极EST传感器和数据采集系统获得12×1维的感应电荷信号，输入到预先训练的BP神经网络，进行图像重建，得到测量截面上的电荷分布图像，为减少图像中的伪影或计算误差对识别精度的影响，采用卷积神经网络(CNN)对重建图像进行处理以输出准确的带电颗粒数目，最后将识别的颗粒数目n与测量的感应电荷值Q构成13×1维的向量输入，通过1个多层前馈网络确定带电颗粒数目、感应电荷值与颗粒电荷量值之间映射关系，最终得到准确的各颗粒的电荷量值。混合神经网络的电荷量检测由三个阶段组成：BP图像重建阶段、CNN特征分类阶段、电荷量检测阶段。混合神经网络示意图如图4所示。

3.1　BP图像重建阶段

BP神经网络指用误差反向传播(Error back propagtion，BP)算法训练的多层前馈神经网络，由输入层、隐含层、输出层组成。

当有i个输入，j个隐含层神经元和k个输出时，隐含层的输出为

$$y_j = f_1\left(\sum_i w_{ij}x_i - b_j\right) \tag{3}$$

式中w_{ij}为输入层与隐含层的连接权值，x_i为输入，b_j为隐含层阈值，f_1为激活函数。

输出层的输出为

$$O_k = f_2\left(\sum_j w_{jk}y_j - b_k\right) \tag{4}$$

式中w_{jk}为隐含层与输出层的连接权值，b_k为输

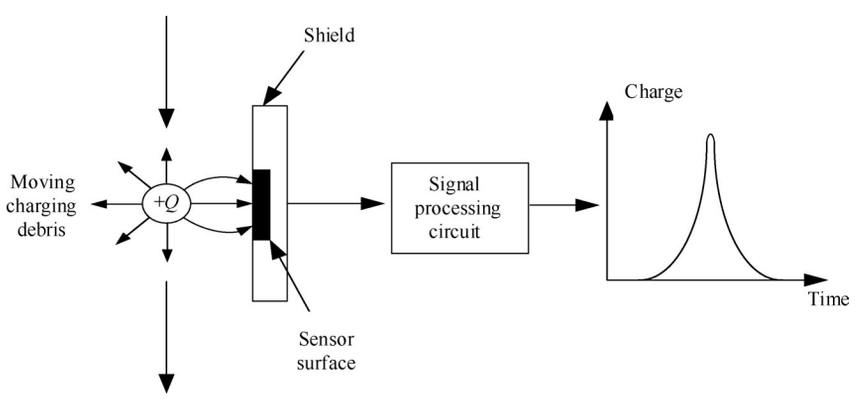
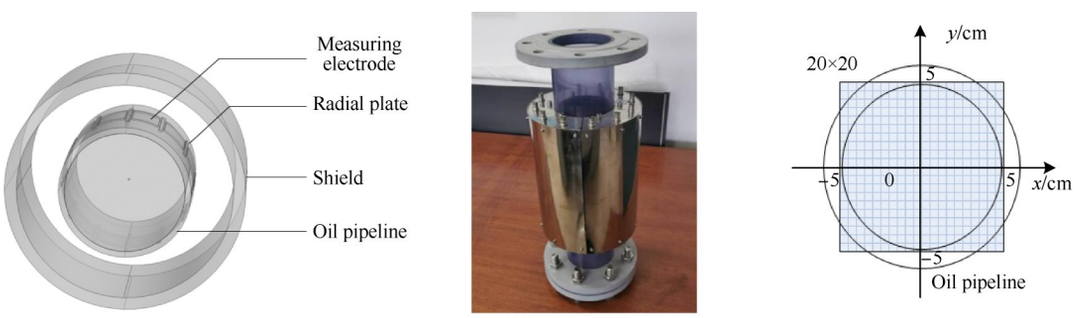


Fig. 1　Electrostatic induction schematic



(a) Simulation model　　(b) Physical model　　(c) Diagram of grid division

Fig. 2　Electrostatic sensor model and grid division

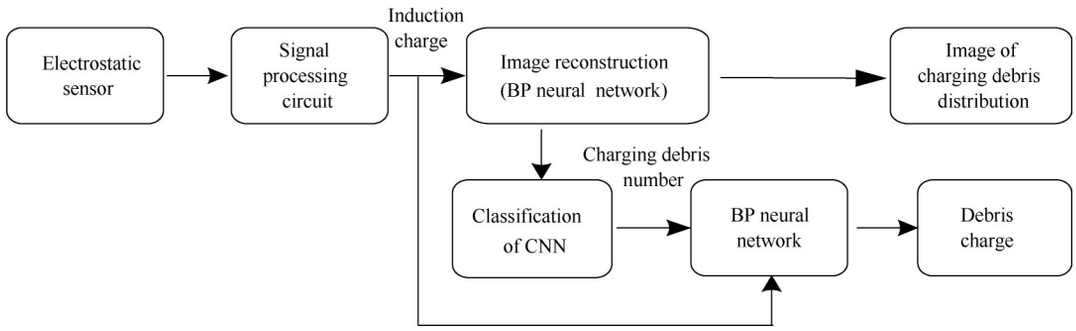


Fig. 3　Basic structure diagram of charge detection model

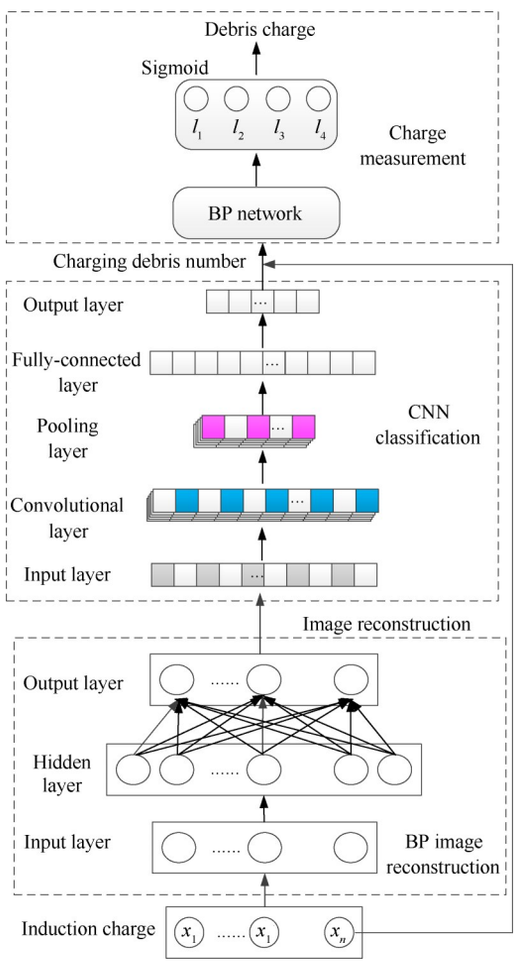


Fig. 4　Hybrid neural network model

出层阈值，f_2为输出层传递函数。

输入层接收 12 个阵列电极的感应电荷值，隐层和输出层对信号进行加工，根据网络输出与期望输出的误差修改隐含层的权值和阈值，从而建立感应电荷向量与电荷分布向量之间的非线性映射，最终输出为管道截面上的电荷分布图像。

3.2　CNN 特征分类阶段

由于 BP 神经网络输出的电荷分布图像不可避免地存在伪影，一般的图像处理步骤难以保证荷电颗粒数目判断的准确率，采用 CNN 对图像做进一步特征提取以得到准确的荷电颗粒数目。将 BP 重建出的图像作为输入，荷电颗粒数目作为输出。将得到的图像数据（可看作二维的像素网络）作为输入，与卷积核进行卷积之后提取到局部特征，经过池化层和全连接层后得到分类输出（电荷个数），计算与理想输出的误差，通过采用梯度下降法最小化损失函数对网络中的权重参数逐层反向调节，通过频繁的迭代来提高网络的精度。

本文的 CNN 网络结构包括两个卷积层和两个池化层，卷积核大小均为 5×5，特征图数量为 6，采用 RELU 函数对输出进行非线性化处理；池化窗口大小均为 2×2，特征图数量为 6，使用 Max-pooling 操作；全连接层有 192 个神经元，用于提取输出特征图的特征向量，将其输出送入逻辑回归多分类器中用于样本分类。本文选取不同电荷颗粒数目、不同位置的 BP 神经网络的重建图像作为训练数据集。

3.3　电荷量检测阶段

电荷量测量示意图如图 5 所示，将传感器电极产生的感应电荷值与 CNN 输出的电荷颗粒个数作为 BP 神经网络的输入，磨粒电荷量值作为输出，通过大量的数据集训练，可得到准确的电荷颗粒的电荷量大小。

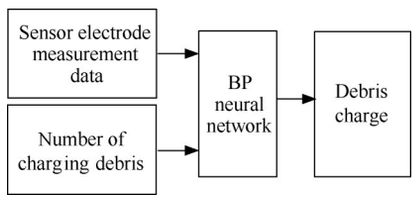


Fig. 5　Schematic diagram of charge measurement

4　实验验证与分析

4.1　数据集构造及实验装置

本文的 EST 传感器采用了 12 电极设计，传感器管道直径为 10cm，金属小球直径为管道直径的 1/10。

通过预先设计小球在管道内分别处于不同位置、不同数量(根据油液监测实际情况,设置数目为 1~2 个)、不同电荷量等多种情况,得到大量的仿真数据集和实测数据集。

在实验时,通过摩擦使小球带电,记录下每次放置的金属球的个数、位置和电荷量大小,由静电层析成像系统实际采集得到的数据构成实测数据集。仿真数据集是利用有限元仿真软件对静电传感器 1∶1 比例建模,在仿真软件中放置与实测数据相同的小球的位置、个数、电荷量,再由仿真软件计算得出感应电荷值。

测量系统示意图及实验装置如图 6,7 所示,为减小噪声干扰,数据采集系统用定制屏蔽机箱封装。实验时在管道口放置定制网格,使用热熔胶将挂钩固定在小球表面,实验时在网格内的不同位置用绝缘悬线(系在铁架台下)钓下金属小球到传感器阵列截面,以悬线位置表示小球位置,模拟带电颗粒在滑油管道内的分布,然后用本课题组设计制作的数据采集系统进行电荷信号的调理、采集并传送到上位机得到实验数据,最后将小球从管道内拉出并迅速放置到法拉第筒中,通过读取静电计示数得到小球的电荷量值。本文共提取了 25684 组样本,将其中的 23050 组数据(包括仿真数据和实测数据)用于训练混合神经网络,2634 组用于网络的测试。

4.2　BP 图像重建

利用 BP 神经网络进行 EST 图像重建时,先将传感器数据归一化处理,消除各维数据间数量级的差别,再把测量数据按照比例分为训练集数据与测试集数据,使用训练集数据进行 BP 神经网络的训练,利用测试集数据验证 BP 神经网络图像重建的准确性。

本文采用的 BP 神经网络输入层为 12×1 维的电荷量矩阵,隐含层神经元个数为 25,输出为 317×1 维的电荷分布矩阵,初始训练步数为 20000,网络期望误差为 10^{-4},激活函数选取 Sigmoid 函数,将 BP 重建图像与真实分布图像两者之间的图像相关系数作为评价指标,计算公式为

$$c=\frac{\sum_{i=1}^{M}(\hat{\boldsymbol{g}}_i-\bar{\hat{g}})(\boldsymbol{g}_i-\bar{g})}{\sqrt{\sum_{i=1}^{M}(\hat{\boldsymbol{g}}_i-\bar{\hat{g}})^2\sum_{i=1}^{M}(\boldsymbol{g}_i-\bar{g})^2}} \tag{5}$$

式中 $\boldsymbol{g}$ 表示理想电荷分布矩阵;$\bar{g}$ 表示 $\boldsymbol{g}$ 的平均值;$\hat{\boldsymbol{g}}$ 表示基于 BP 算法的重建图像的灰度值矩阵,$\bar{\hat{g}}$ 表示 $\hat{\boldsymbol{g}}$ 的平均值。

将 4.1 节提取的训练集用于训练 BP 神经网络,部分测试样本的图像重建和相关系数如表 1,2 所示。

从表 1 可以看出:(1)Landweber 算法和 BP 重建出的图像可以大致分辨出电荷的位置情况,但是重建出的图像存在严重的伪影。(2)使用相同的成像算法时,仿真数据的重建图像与实际测量数据重建出

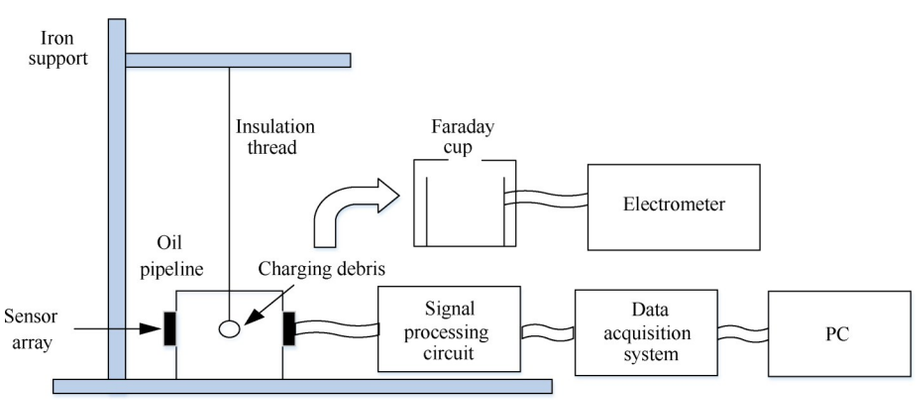


Fig. 6　Experimental setup for charge measurement using EST

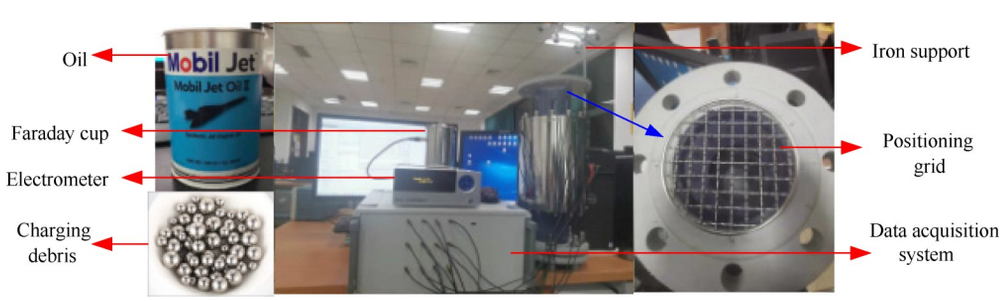


Fig. 7　Experimental facility of EST system

Table 1　Results of BP image reconstruction algorithm for charging debris

Debris coordinate/cm	Real distribution	Simulation data		Measured data	
		Landweber	BP	Landweber	BP
(−4.5,1)					
(2.5,−0.5)					
(2.5,−3.5) (−2.5,3.5)					
(3,3.5) (0,0.5)					
(3,0)(−4.5,0) (−1.5,−0.5)					

Table 2　Correlation coefficients obtained with two image reconstruction algorithms

Debris coordinate/cm	Simulation data		Measured data	
	Landweber	BP	Landweber	BP
(−4.5,1)	0.3370	1.0000	0.3301	0.9984
(2.5,−0.5)	0.1101	1.0000	0.11	0.9902
(2.5,−3.5) (−2.5,3.5)	0.4277	1.0000	0.2322	1.0000
(3,3.5) (0,0.5)	0.2446	1.0000	0.2373	0.9997
(3,0)(−4.5,0) (−1.5,−0.5)	0.2070	0.9953	0.1579	0.8627

的图像差异不大，能基本反映出管道内电荷的分布情况。(3)在相同位置时，BP的成像效果优于Landweber算法，尤其当只存在单个电荷颗粒时，可准确反映出电荷的个数和位置分布。

从表2可以看出，BP重建图像的相关系数比Landweber算法的相关系数大，测试集BP重建图像的相关系数均值达97.02%，识别度更高。实测数据的重建图像相关系数略低于仿真数据的重建图像的相关系数，与实际情况相符。

在存在两个甚至多个电荷的情况下，无论是BP算法或是Landweber算法重建出的图像都有严重的伪影，通过调节神经网络的参数也不能100%判断出准确的电荷个数，所以需要对重建出的图像做进一步的特征提取以准确识别出电荷的个数。

4.3　CNN数目分类

选取BP神经网络的重建图像作为CNN的输入，电荷颗粒的个数作为输出，对电荷个数分类的准确率作为评价指标，即正确分类的测试样本数与总测试样本数之比。训练数据集包括18050组仿真样本图像和实测样本图像，测试集包括2634组仿真样本和实测样本图像，某次训练的均方误差曲线如图8所示。测试样本的部分分类结果如表3所示。

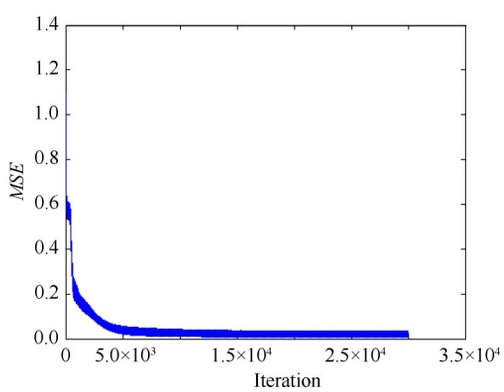


Fig. 8　Mean square error curve of CNN

由表3可以看出，管道内存在单个电荷颗粒时，因为BP神经网络的重建图像效果较好，所以CNN对测试集中的各个位置的电荷颗粒数目的分类准确率可达到100%；当存在两个携带有不同电荷量的电荷颗粒时，BP重建的图像在个别位置有伪影或误差较

大的情况，经过 CNN 特征提取分类后准确率为 91.01%；当存在两个携带有相同电荷量的电荷颗粒时，由于此种情况训练集和测试集样本相对较多，CNN 图像分类的分类准确率达 93.26%。测试集平均分类准确率为 94.76%，取得了较好的分类效果。

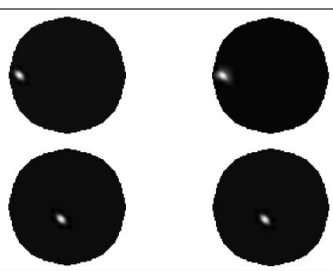
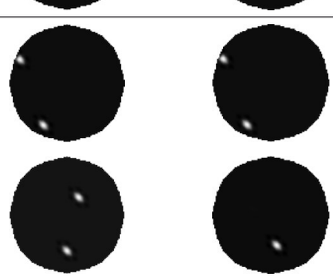
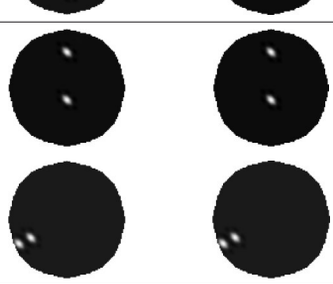
4.4　磨粒电荷量计算

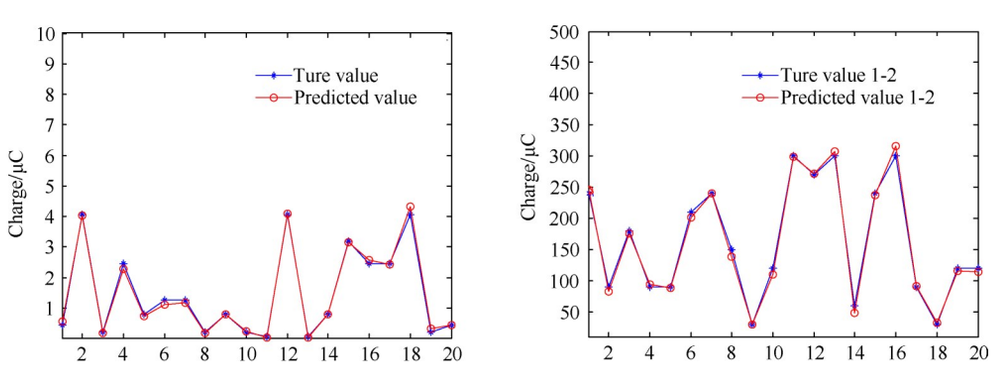
BP 神经网络的隐含层神经元个数为 4，网络期望误差 0.001，激活函数选取 Sigmoid 函数，初始训练步数为 30000。

使用 BP 神经网络对单个磨粒、两个带电量磨粒的情况分别测试，将 BP 神经网络的预测值与真实值的误差作为评价指标，其中训练数据集有 23050 组仿真数据和实测数据，测试集有 2634 组仿真数据和实测数据，使用训练集数据训练 BP 神经网络，利用测试集数据验证网络测量的准确性。仿真数据和实测结果分别如图 9，10 所示，测量误差如表 4 所示。

由图 9，10 可以看出，当使用仿真数据测量磨粒的电荷量时，单个电荷磨粒的 BP 神经网络的预测值与仿真真实值基本相同，误差为 1.01%，两个电荷磨粒的预测值曲线紧紧跟随仿真真实值曲线，误差为

Table 3　Classification results of CNN

Number of charging debris	Coordinate/cm	Real distribution	BP	Training set/ testing set	Classification accuracy/%
1	(−4,0) (−0.5,−1)			9600/287	100
2 (Different charge)	(−4,2) (−2,−3.5) (0,−3)(1,2)			3750/610	91.01
2 (Same charge)	(0,3) (0,−1) (−4,−2) (−3,−1.5)			10500/1737	93.26



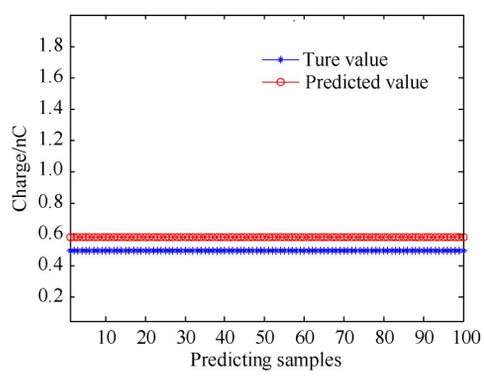
(a) Charge of single charging debris　　(b) Charge of two charging debris

Fig. 9　Results of charge estimation using simulation data

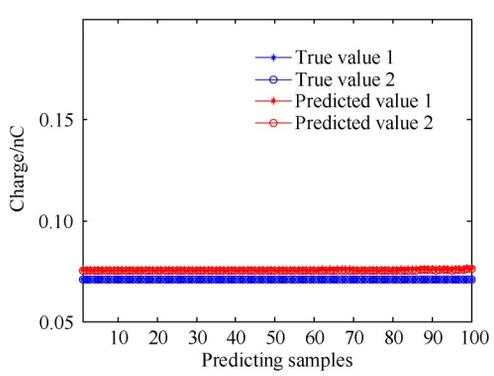
2.96%，模型的有效性得到了仿真验证。

从图 10(a)可以看出，实测数据的单个电荷磨粒的 BP 神经网络的误差为 20.3%，预测值与实测真实值偏差较大，这是因为在实验过程中，当使用法拉第筒标定好带点小球的电荷量后，转移到传感器桶内时有部分电荷损失，导致电荷量读数略高于真实值，且在做不同位置的实验时，带电小球的空间移动也会造成一部分电荷逸散，出现一定的电荷损失，导致预测值与实测值偏差较大。

当存在两个电荷磨粒时，实验时是先将两个带电小球一起放入传感器管道中，使两个小球相互接触来达到带有相同电荷量的目的，再移动至各个位置进行测量，待实验结束后将两小球分别放入法拉第筒内，取两球的测量最大值作为真实值，所以两个相同电荷量的磨粒电荷量测量值比较接近真实值，从图 10(b)可以看出 BP 神经网络的预测值与实测真实值相差不大，误差为 11.75%，测试集平均误差为 9%，能够比较准确地测量磨粒的电荷量大小。



(a) Charge of single charging debris



(b) Charge of two charging debris

Fig. 10　Results of charge measurement

Table 4　Errors of charge measurement　(%)

Number of charging debris	Simulation data	Measured data
Single charging debris	1.01	20.3
Two charging debris	2.96	11.75

5　结　论

在传统的电荷量检测中，对多个电荷磨粒的电荷量检测的文献较少见到，本文采用混合神经网络方法对滑油磨粒进行了监测，得到以下结论：

(1)针对多磨粒情况下难以准确获得电荷分布和单个电荷量值的问题，混合神经网络方法结合深度学习的强大优势，利用静电传感器感应电荷值，依次得到电荷分布图像、准确的电荷数目、各个颗粒的电荷量值，为电荷量的准确测量提供了一种新的方法和借鉴。

(2)混合神经网络方法对静电传感器测量数据使用 BP 神经网络准确成像，重建图像的相关系数平均达 0.9702，在准确性方面优于传统的图像重建方法。

(3)混合神经网络方法中的 CNN 在单个和两个电荷颗粒的情况下可以有效地识别出颗粒数目，分类准确率达 94.76%；再结合静电传感器测量数据，使用 BP 神经网络中可以准确识别出电荷颗粒的电荷量，通过实验得到 BP 神经网络的电荷量测量平均误差为 9%，验证了混合神经网络方法的有效性。

致　谢：感谢国家自然科学基金面上项目和中央高校基本科研业务费中国民航大学专项资金的资助。

参考文献

[1] Powrie H, Fisher C E. Engine Health Monitoring: Towards Total Prognostics [C]. *Snowmass*: 1999 *IEEE Aerospace Conference Proceedings*, 1999: 11-20.

[2] Powrie H, Novis A. Gas Path Debris Monitoring for F-35 Joint Strike Fighter Propulsion System PHM [C]. *Big Sky*: 2006 *IEEE Aerospace Conference*, 2006: 8-16.

[3] Novis A, Powrie H. PHM Sensor Implementation in the Real World-A Status Report [C]. *Big Sky*: 2006 *IEEE Aerospace Conference*, 2006: 1-9.

[4] Powrie H, Fisher C E. Monitoring of Foreign Objects Ingested into the Intake of a Gas Turbine Aero-Engine [C]. *Swansea*: 1999 *International Conference on Condition Monitoring*, 1999: 175-190.

[5] Fisher C E. Gas Path Debris Monitoring a 21st Century PHM Tool [C]. *Big Sky*: 2000 *IEEE Aerospace Conference Proceedings*, 2000: 441-448.

[6] Fisher C E. Data and Information Fusion for Gas Path Debris Monitoring [C]. *Big Sky*: 2001 *IEEE Aerospace Conference Proceedings*, 2001: 3017- 3022.

[7] 李绍成，左洪福．磨粒在线监测静电传感器设计[J]．压电与声光，2010，32(2)：325-328.

[8] 冒慧杰，左洪福，殷逸冰，等. 静电传感器对滑油系统磨粒电量测量方法研究[J]. 仪器仪表学报，2016，37(1)：40-47.

[9] 陈 进. 滑油系统静电监测试验研究[D]. 南昌：南昌航空大学，2018.

[10] 唐 欣. 基于平面阵列静电传感的燃气轮机尾气异常颗粒监测技术研究[D]. 长沙：国防科技大学，2018.

[11] 付 宇，殷逸冰，左洪福. 航空发动机尾气静电监测及其信号特性分析[J]. 仪器仪表学报，2018，39(2)：160-168.

[12] 陈志雄，王继文，左洪福. 滑油系统静电监测模型研究[J]. 电子测量与仪器学报，2019，33(8)：147-153.

[13] 李晓青，袁亚飞，杨 铭，等. 静电电荷量传感器标定技术研究[J]. 宇航计测技术，2019，39(2)：36-40.

[14] 薛 倩，刘 婧，马 敏，等. 基于原始对偶内点法的EST图像重建[J]. 北京航空航天大学学报，2019，45(10)：1973-1981.

[15] 郭家琛，左洪福，姜 衡，等. 航空发动机棒状静电传感器感应特性数值仿真[J]. 航空计算技术，2020，50(1)：29-32.

[16] 钟志荣，左洪福，郭家琛，等. 基于阵列式静电传感器的颗粒带电量估计方法[J]. 仪器仪表学报，2020，41(7)：80-90.

[17] 马 敏，王 涛，王 力. 基于深度学习的滑油监测方法研究[J]. 推进技术，2020，41(5)：1159-1167.(MA Min，WANG Tao，WANG Li. Research on Monitoring Method of Lubricating Oil Based on Deep Learning[J]. *Journal of Propulsion Technology*，2020，41(5)：1159-1167.)

[18] 李 峰，谭 超，董 峰. 全连接深度网络的电学层析成像算法[J]. 工程热物理学报，2019，40(7)：1526-1531.

[19] 张 冀，郑传哲. 基于多尺度CNN-RNN的单图三维重建网络[J]. 计算机应用研究，2020，37(11)：3487-3491.

(编辑：梅 瑛)