

基于动量 BP 神经网络激光陀螺调腔检测方法

马 立¹ 徐次雄¹ 欧阳航空¹ 荣伟彬² 孙立宁²

(¹上海大学机电工程与自动化学院, 上海 200072
²哈尔滨工业大学机器人技术与系统国家重点实验室, 黑龙江 哈尔滨 150080)

摘要 为解决激光陀螺人工调腔质量低、效率不高等缺点,提出一种由 CCD 相机和光电倍增管构成的多传感器信息融合调腔检测方法,该方法同时检测光斑、光阑中心点及陀螺损耗值,并将这些信息送入融合中心,经过融合计算得到陀螺调腔是否合格的综合判断。融合系统采用动量 BP 神经网络对多源信息进行融合,根据调腔过程中的输入、输出情况,设计包含输入层、隐含层及输出层的 3 层网络拓扑结构。实验结果表明,此种方法对激光陀螺调腔质量是否合格判断准确率为 93.81%,比人工采用单一传感器分步检测准确率提高了 6%。

关键词 信号处理;激光陀螺调腔;信息融合;检测;动量 BP 神经网络

中图分类号 TP249; TP274+.5; V241.5+58 **文献标识码** A **doi**: 10.3788/CJL201239.0402007

Detection Method of Laser Gyroscope Cavity Adjustment Based on Momentum BP Neural Network

Ma Li¹ Xu Cixiong¹ Ouyang Hangkong¹ Rong Weibin² Sun Lining²

(¹School of Mechanical and Electronic Engineering and Automation, Shanghai University, Shanghai 200072, China)
²State Key Laboratory of Robotics and System, Harbin Institute of Technology, Harbin, Heilongjiang 150080, China)

Abstract In order to solve the manual detection drawbacks of laser gyroscope cavity adjustment, such as low quality and low efficiency, a multi-sensor information fusion detection method is proposed using a CCD camera and a photomultiplier. The center of the facula and the diaphragm and the loss of laser gyroscope are obtained and then transmitted to the fusion center. After fusion calculation, the integrated judgment is produced. The fusion system utilizes the momentum back-propagation neural network (BPNN) to fuse the multi-source information and output the final decision. And according to the modes of the detected signals and output decision, a three layers topology structure including an input layer, a hidden layer and an output layer is designed. The experimental results indicate that the accuracy of the proposed cavity adjustment detection method is 93.81%, which is higher than the manual step detection method using a single sensor about 6%.

Key words signal processing; cavity adjustment of laser gyroscope; information fusion; detection; momentum BP neural network

OCIS codes 140.3370; 140.1340; 140.3410

1 引 言

激光陀螺是惯性导航系统的重要部件,被广泛用于飞机、舰船、导弹等民用和军事领域^[1,2]。调腔装配是激光陀螺制作过程中的一个关键环节,所谓调腔就是通过调整构成环形回路的球面反射镜的位置,从而改变腔体内光线的反射方向,对腔体和镜片的参数由于加工等因素造成的误差进行补偿,使腔

内运行的闭合光路尽量接近陀螺腔内毛细管中心轴线所构成的几何回路。调腔装配工艺要保证两个重要指标:损耗和光斑-光阑中心距,即在调腔过程中要同时满足损耗和光斑-光阑中心距两个要求。损耗反应的是入射光经过陀螺腔内毛细管出射后能量减少程度;中心距直观上表示光斑坐标原点和光阑坐标原点距离,实质反应的是陀螺腔体内闭合光路

收稿日期: 2011-11-08; **收到修改稿日期**: 2011-12-09

基金项目: 国家自然科学基金(50905105)、机器人技术与系统国家重点实验室开放课题(SKLRs-2010-MS-02)及上海大学创新基金(SHUCX112200)资助课题。

作者简介: 马 立(1977—)女,博士,副教授,主要从事微操作机器人技术方面的研究。E-mail: malian@shu.edu.cn

与陀螺腔体毛细管中心轴线重合度,中心距可由图像信息得到。调腔质量对陀螺精度影响重大,虽然较小的误差可以通过控制外围设备方法得到补偿,但是当陀螺调腔装配误差较大时很难通过控制外围设备方法来解决。因此,调腔过程中必须同时检验图像信息和损耗信息。目前人工调腔把图像信息和损耗信息的获得分为两个独立过程,分步进行。人工调腔时先用人眼观察出射光以判断腔体内激光回路与毛细管中心轴线重合情况,若图像重合度满足要求则固定反射镜;然后,通过示波器得到损耗信息,若损耗值满足要求则调腔完毕,否则要切下反射镜重新调腔。这样不仅效率低,精度难以保证,而且调腔过程时间过长时陀螺腔内还会掉入灰尘,这也会对陀螺带来不利,甚至影响陀螺正常工作。

针对上述人工调腔的缺点,本文提出一种基于动量 BP 神经网络的信息融合调腔检测方法,在陀螺自动调腔过程中同时检测损耗和光斑、光阑中心点坐标信息,并将这些信息送入神经网络融合中心,经融合计算后对调腔质量是否合格做出综合判断。

2 自动调腔系统构成

采用基于参考光的调腔方法,调腔光路系统结构如图 1 所示。光源腔体是用调好的陀螺腔体充满氦氖气体制成的,腔体在氦氖激光电源及锯齿波发生器的作用下输出的激光与陀螺实际运行相似,可作为调腔的参考光源。图 1 中偏振片用于选择透射的横波或纵波,垂直和水平调整镜片用于上下或左右微调光线位置,反射镜片用于改变入射光线在水平和竖直两个面内的角度,通过这几个镜片的调节使得参考光从待调整的腔体光路孔的中心入射。背景灯用于得到光阑孔图像,光线为绿色的,所以观察到的光阑图像也是绿色的。CCD 相机和光电倍增




图 1 调腔光路示意图

Fig. 1 Optical path schematic of cavity adjustment

管用于检测出射光,分别得到光斑光阑图像和激光频谱曲线。

为解决激光陀螺人工调腔质量低、效率不高等缺点,根据调腔工艺特点,建立自动调腔系统如图 2 所示。调腔时,机械手移动待装配球面镜调整腔体内闭合光路的路径,使其尽可能与腔体毛细管中心轴线重合。从陀螺射出的光经过半反半透镜后分为两路,分别被光电倍增管和 CCD 相机检测到,检测到的信号送入计算机后,通过计算可以得出陀螺腔体损耗及光斑和光阑的中心点坐标信息。




图 2 激光陀螺调腔系统

Fig. 2 Cavity adjustment system of laser gyroscope

3 动量 BP 神经网络检测方法

3.1 检测系统组成

调腔装配质量要满足损耗和光斑-光阑中心距两个指标。建立如图 3 所示基于动量 BP 神经网络信息融合系统,系统所用传感器包括 CCD 相机和光电倍增管(见图 2),所检测到的信息包括光斑中心点坐标 x_1 、 x_2 ,光阑中心点坐标 x_3 、 x_4 及损耗值 x_5 。




图 3 信息融合系统结构

Fig. 3 Schematic diagram of the information fusion system

整个检测系统结构框图如图 3 所示,光电倍增管接收从陀螺腔体射出并经半反半透镜分光后的一路光,并将光信号转换为电信号,该信号经模拟数字(A/D)转换后,经过分析计算得到损耗值,该损耗值作为融合中心的输入之一;半反半透镜分光后的另一路光被 CCD 接收,经图像采集卡传入计算机,通过图像处理可以提取出光斑和光阑中心点坐标,这些值也作为融合中心的输入送入融合中心,接着融

合中心对来自光电倍增管和 CCD 的信息进行融合计算,最终给出调控质量是否合格的综合判断。

3.2 光斑、光阑中心提取及损耗检测

CCD 相机采集到的光斑光阑图像如图 4 所示。为便于分析,建立以视频窗口的左上角为坐标原点坐标系。像素分辨率约为 $10\ \mu\text{m}$ 。




图 4 光阑-光斑图像

Fig. 4 Image of facula and diaphragm

光斑图像强度随时间做周期性变化,图像闪烁不定,针对这一特点,采用序列图像方差分析方法对光斑图像进行处理,得出光斑所在区域为 $x \in (X_L, X_H), y \in (Y_L, Y_H)$,其中 $X_L, X_H (Y_L, Y_H)$ 分别表示光斑区域 x 向(y 向)的最低点和最高点。然后利用重心法计算出光斑中心点坐标 x_1, x_2 , 公式为

$$x_1 = \bar{X} = \frac{\sum_{i=X_L}^{X_H} \sum_{j=Y_L}^{Y_H} iI(i, j)}{\sum_{i=X_L}^{X_H} \sum_{j=Y_L}^{Y_H} I(i, j)}, \quad (1)$$

$$x_2 = \bar{Y} = \frac{\sum_{i=X_L}^{X_H} \sum_{j=Y_L}^{Y_H} jI(i, j)}{\sum_{i=X_L}^{X_H} \sum_{j=Y_L}^{Y_H} I(i, j)}. \quad (2)$$

由于光阑图像亮度均匀,形状规则,对称性好,采用最大类间方差法对光阑图像进行分割,同样采用光斑中心点提取的重心法对光阑图像中心进行计算,可得光阑中心点坐标 x_3, x_4 。

损耗是评价激光器谐振腔质量的一个重要指标,在激光陀螺的生产装配和质量检测过程中,都需要对谐振腔的损耗进行测量。其损耗定义为

$$s = 2\pi \frac{\omega'}{T}, \quad (3)$$

式中 ω' 为谱线的半峰全宽, T 为频谱曲线的间隔。

损耗信息由光电倍增管提供,光电倍增管检测到光信号后将其转换为电信号,该信号经过 A/D 转换后送入上位机,得到信号频谱分布曲线。根据频谱分布曲线的特点,提出一种基于谱线的快速自相

关算法对 T 进行估计,算法为

$$r(m) = \begin{cases} \frac{1}{M_0} \sum_{n=0}^{M_0-1-m} x(n)x(n+m), & \forall n \in F_{k_1}, n+m \in F_{k_2} \\ 0, & \text{others} \end{cases} \quad (4)$$

式中 M_0 为信号的长度, F_{k_1} 为第 k_1 条谱线, F_{k_2} 为第 k_2 条谱线。 $r(m)$ 分别在 $T, 2T, \dots, kT$ 处存在极大值,因此,通过快速自相关算法即可估计出 T 。对每条基模谱线,求取其极大值 V_{\max} ,进而得到 $V_{\max}/2$ 处的谱线宽度 ω' ,即可按(3)式得到谐振腔的损耗值 x_5 。

3.3 调控质量评价方法

调控的目的是使光斑和光阑中心尽量重合且损耗值 x_5 小于 0.08% ,具体来说就是要求调控结果满足条件:

$$\Delta d \leq 35 \text{ 且 } x < 0.08\%, \quad (5)$$

式中 Δd 为光斑和光阑的中心距。由于调控过程中光斑、光阑中心点 x 轴坐标和 y 轴坐标的变化对调控结果的影响各不相同,因此将光斑、光阑中心点坐标作为神经网络的独立输入来建立神经网络模型。

3.4 动量 BP 神经网络信息融合算法模型

BP 神经网络是由若干神经元组成的复杂系统,在输入输出映射关系未知情况下通过网络训练可以建立输入输出关系^[3-5],具有很好的容错性和自适应性,被广泛应用于模式识别、态势估计等领域。应用 BP 神经网络这一特点,可以建立多传感器信息和调控结果的映射关系,从而可以根据多传感器信息对调控质量进行判断。然而,实际应用中 BP 算法存在的一个重要问题就是收敛速度慢,网络训练时间长。由于调控检测实时性要求较高,因此需要在 BP 算法基础上加入动量项以提高算法的收敛速度。

通过分析调控质量要求和传感器检测功能可知,在陀螺调控过程中各个传感器所检测的信号只能反映调控质量的部分指标,不能对调控质量是否合格做出完整判断。反映调控质量的传感器信号包括光斑中心点坐标 x_1, x_2 , 光阑中心点坐标 x_3, x_4 及陀螺损耗值 x_5 , 应用动量 BP 神经网络信息融合算法融合这些传感器信息,获得对陀螺调控质量是否合格的判断。

为量化分析调控质量合格与不合格的程度,定义 $\mathbf{D}=(d_1, d_2)$,其中 $d_1, d_2 \in [0, 1]$,式中 d_1 表示对调控质量合格的支持程度, d_2 表示对调控质量不合格的支持程度。仅当 $d_1 > d_2$ 时,表示检测结果支

持合格的程度更大,此时判定调控质量合格;仅当 $d_1 < d_2$ 时,表示检测结果支持不合格的程度更大,此时判定调控质量不合格;当 $d_1 = d_2$ 时表示对合格与不合格的支持程度相等,此时表示不能判定调控质量是否合格,但是联系到调控实际,这种不确定情况也应当做不合格处理,即当 $d_1 = d_2$ 时也表示调控质量是不合格的。

根据上述分析,可选择常用的三层网络形式,神经网络输入层有 5 个神经元,分别对应光斑中心坐标 x_1, x_2 , 光阑中心坐标 x_3, x_4 及损耗值 x_5 , 网络的输出就是对调控质量是否合格的判断,分两种形式:

- 1) 合格: ($d_1 > d_2$);
- 2) 不合格: ($d_1 \leq d_2$)。

则网络的输出层含 2 个神经元,中间层神经元个数可先根据近似关系

$$N = 2N_1 + 1 \quad (6)$$

计算^[6], 然后根据网络训练结果对其进行适当调整。(6)式中 N 为隐含层神经元个数, N_1 为输入层神经元个数。网络输入层神经元个数为 5, 则隐含层神经元个数近似为 11。图 5 所示为所建立的 BP 网络模型结构。




图 5 动量 BP 神经网络模型结构

Fig. 5 Model of the momentum BP neural network

图中各变量意义如下:

x_1 : 光斑横坐标; x_2 : 光斑纵坐标; x_3 : 光阑横坐标; x_4 : 光阑纵坐标; x_5 : 损耗值。

3.5 动量 BP 融合算法

BP 融合算法发展至今已经有大量理论和实际研究成果^[7~9], 这里结合调控研究实例介绍动量 BP 融合算法。如图 5 所示, 输入层用大写 I 表示, i 为其中任一神经元; 隐含层用 J 表示, j 表示其中任一神经元; 输出层用 K 表示, k 表示其中任一神经元。输入层与隐含层神经元间连接权值用 w_{ij} 表示, 隐含层与输出层神经元间连接权值用 w_{jk} 表示。 b_j^I, b_k^K 分别表示隐含层和输入层某神经元的阈值。这里假

设所有神经元的传递函数都为 Sigmoid 函数^[10,11], 该函数定义为

$$f(x) = \frac{1}{1 + \exp(-x)}. \quad (7)$$

设某时刻传感器提供的输入样本为: $\mathbf{X} = \{x_1, x_2, \dots, x_5\}$, 其对应目标输出为: $\mathbf{T} = \{t_1, t_2\}$, 首先传感器信号前向传播, 第 J 层第 j 个神经元的输入为

$$u_j^J = \sum_{i=1}^M \tau w_{ij} x_i. \quad (8)$$

输出为

$$y_j^J = f(u_j^J + b_j^J) = f\left(\sum_{i=1}^M \tau w_{ij} x_i + b_j^J\right), \quad (9)$$

式中 M 为输入信号个数, 传感器信号有 5 种, 因此 M 为 5。同理, 第 K 层输出, 即网络输出层第 k 个神经元输入为

$$u_k^K = \sum_{j=1}^N \tau w_{jk} y_j^J. \quad (10)$$

输出为

$$y_k^K = f(u_k^K + b_k^K) = f\left(\sum_{j=1}^N \tau w_{jk} y_j^J + b_k^K\right), \quad (11)$$

式中 $k = 1, 2$, 由(6)式知 N 为 11。网络输出层所有神经元总误差为

$$E = \frac{1}{2} \sum_{k=1}^P (t_k - y_k^K)^2, \quad (12)$$

式中 P 为输出层神经元个数, 根据输出形式可知 $P = 2$, t_k 为输出层中第 k 个神经元的期望输出。

第 J, K 层第 $n + 1$ 次训练时的权值 $w_{jk}(n + 1)$ 表示为

$$w_{jk}(n + 1) = w_{jk}(n) + \Delta w_{jk}(n), \quad (13)$$

式中 $\Delta w_{jk}(n)$ 为权值修正量, n 代表迭代次数。

根据梯度下降动量法规则^[12~15], 隐含层 J 和输出层 K 间的权值修正量可表示为

$$\Delta w_{jk}(n) = -\eta \sum_{t=0}^n \alpha^{n-t} \frac{\partial E(t)}{\partial u_k^K} \frac{\partial u_k^K}{\partial w_{jk}(t)}, 0 \leq |\alpha| < 1 \quad (14)$$

式中 α 为动量项, 通常是常数, 这里 α 取 0.5。 η 为学习速率, η 取值越大网络收敛越快, 但是波动较大, η 取值太小收敛速度又很慢, 所以要选择合理的 η 值。

同理, 可以计算输入层 I 和隐含层 J 间第 $n + 1$ 次训练时的权值

$$w_{ij}(n + 1) = w_{ij}(n) + \Delta w_{ij}(n), \quad (15)$$

式中

$$\Delta w_{ij}(n) = -\eta \sum_{t=0}^n \alpha^{n-t} \frac{\partial E(t)}{\partial u_j^J} \frac{\partial u_j^J}{\partial w_{ij}(t)}, 0 \leq |\alpha| < 1 \quad (16)$$

当误差 E 达到要求范围时,网络训练停止,此时建立起的输入输出的非线性映射关系有很好的容错性,不会因为某个传感器信号误差较大或失效而对结果产生过大影响。

4 实验、结果与讨论

4.1 动量BP网络训练

调控系统如图2所示,机械手在陀螺装配面上

移动球面反射镜寻找合适的装配位置,在此过程中上位机不断收集光斑和光阑坐标及损耗信息,并做记录。选取其中60组样本数据对以上建立的神经网络进行训练,其中合格与不合格数据各30组,由于人工判断只知道合格与不合格很难准确判断合格与不合格的程度,因此表1中人工判断的结果用(1,0)表示合格,(0,1)表示不合格。表1为所选取的训练样本数据及训练结果。

表1 神经网络训练数据及判断结果

Table 1 Train data and judgment result of the network

| Serial number | Facula center coordinate /pixel | | Diaphragm center coordinate /pixel | | Loss value $x_5/\%$ | Artificial actual judgment result | | Network judgment result | |
|---------------|---------------------------------|----------------|------------------------------------|----------------|---------------------|-----------------------------------|---|-------------------------|-------|
| | Abscissa x_1 | Ordinate x_2 | Abscissa x_3 | Ordinate x_4 | | | | | |
| 1 | 245.3 | 261.3 | 249.5 | 281.4 | 0.0383 | 1 | 0 | 1.000 | 0.000 |
| 2 | 245.1 | 261.8 | 229.5 | 241.6 | 0.0621 | 1 | 0 | 0.997 | 0.003 |
| 3 | 244.7 | 261.8 | 235.3 | 241.8 | 0.0628 | 1 | 0 | 0.997 | 0.003 |
| 4 | 246.1 | 261.0 | 227.4 | 250.6 | 0.0678 | 1 | 0 | 0.999 | 0.001 |
| 5 | 246.3 | 261.0 | 218.6 | 268.2 | 0.0742 | 1 | 0 | 0.999 | 0.001 |
| 6 | 245.1 | 261.8 | 229.5 | 241.6 | 0.0621 | 1 | 0 | 0.997 | 0.003 |
| 7 | 245.2 | 260.3 | 226.7 | 250.9 | 0.0612 | 1 | 0 | 1.000 | 0.000 |
| 8 | 244.0 | 261.0 | 230.0 | 232.2 | 0.0625 | 1 | 0 | 0.993 | 0.012 |
| 9 | 243.3 | 261.3 | 238.4 | 249.9 | 0.0626 | 1 | 0 | 0.997 | 0.003 |
| 10 | 246.0 | 261.4 | 220.8 | 258.8 | 0.0656 | 1 | 0 | 0.999 | 0.001 |
| 11 | 245.7 | 261.0 | 239.2 | 251.8 | 0.0669 | 1 | 0 | 0.997 | 0.003 |
| 12 | 244.1 | 260.5 | 231.8 | 238.9 | 0.0657 | 1 | 0 | 0.997 | 0.003 |
| 13 | 244.3 | 260.5 | 232.3 | 258.4 | 0.0656 | 1 | 0 | 1.000 | 0.000 |
| 14 | 244.0 | 261.0 | 233.7 | 244.3 | 0.0716 | 1 | 0 | 0.997 | 0.003 |
| 15 | 243.9 | 260.5 | 246.0 | 243.0 | 0.0742 | 1 | 0 | 0.994 | 0.005 |
| 16 | 243.5 | 261.7 | 226.7 | 263.2 | 0.0702 | 1 | 0 | 1.000 | 0.000 |
| 17 | 244.1 | 261.5 | 248.5 | 270.4 | 0.0722 | 1 | 0 | 1.000 | 0.000 |
| 18 | 244.5 | 260.5 | 242.5 | 271.3 | 0.0760 | 1 | 0 | 1.000 | 0.000 |
| 19 | 244.1 | 260.8 | 257.1 | 272.6 | 0.0790 | 1 | 0 | 0.996 | 0.004 |
| 20 | 244.4 | 260.4 | 252.1 | 241.1 | 0.0761 | 1 | 0 | 0.991 | 0.015 |
| 21 | 244.1 | 263.1 | 255.4 | 271.9 | 0.0791 | 1 | 0 | 0.997 | 0.003 |
| 22 | 244.6 | 264.5 | 244.1 | 278.0 | 0.0511 | 1 | 0 | 1.000 | 0.000 |
| 23 | 244.4 | 260.9 | 241.0 | 234.5 | 0.0618 | 1 | 0 | 0.991 | 0.014 |
| 24 | 244.5 | 260.7 | 239.9 | 242.3 | 0.0624 | 1 | 0 | 0.997 | 0.004 |
| 25 | 245.1 | 260.0 | 224.1 | 268.9 | 0.0631 | 1 | 0 | 1.000 | 0.000 |
| 26 | 244.9 | 260.0 | 229.4 | 277.1 | 0.0633 | 1 | 0 | 1.000 | 0.000 |
| 27 | 244.8 | 260.4 | 227.6 | 268.3 | 0.0657 | 1 | 0 | 1.000 | 0.000 |
| 28 | 244.4 | 260.7 | 234.9 | 233.7 | 0.0657 | 1 | 0 | 0.991 | 0.014 |
| 29 | 244.9 | 260.4 | 219.1 | 259.8 | 0.0719 | 1 | 0 | 0.999 | 0.001 |
| 30 | 244.1 | 260.8 | 257.1 | 272.6 | 0.0790 | 1 | 0 | 0.996 | 0.004 |
| 31 | 244.9 | 261.9 | 267.8 | 247.2 | 0.0892 | 0 | 1 | 0.003 | 0.999 |
| 32 | 244.2 | 261.0 | 258.0 | 263.8 | 0.0874 | 0 | 1 | 0.009 | 0.993 |
| 33 | 243.6 | 261.0 | 220.2 | 228.8 | 0.0888 | 0 | 1 | 0.001 | 0.998 |
| 34 | 244.5 | 260.5 | 223.2 | 231.1 | 0.0868 | 0 | 1 | 0.001 | 0.998 |
| 35 | 244.0 | 260.5 | 264.3 | 254.5 | 0.0902 | 0 | 1 | 0.004 | 0.997 |
| 36 | 243.7 | 260.5 | 266.8 | 245.3 | 0.0946 | 0 | 1 | 0.003 | 0.999 |

| Serial number | Facula center coordinate /pixel | | Diaphragm center coordinate /pixel | | Loss value $x_5 / \%$ | Artificial actual judgment result | | Network judgment result | |
|---------------|---------------------------------|----------------|------------------------------------|----------------|-----------------------|-----------------------------------|---|-------------------------|-------|
| | Abscissa x_1 | Ordinate x_2 | Abscissa x_3 | Ordinate x_4 | | 0 | 1 | result | |
| | | | | | | | | | |
| 37 | 243.8 | 260.1 | 263.2 | 264.5 | 0.0949 | 0 | 1 | 0.008 | 0.994 |
| 38 | 244.3 | 260.8 | 230.3 | 215.7 | 0.0953 | 0 | 1 | 0.000 | 1.000 |
| 39 | 244.9 | 261.2 | 266.7 | 254.4 | 0.0917 | 0 | 1 | 0.004 | 0.997 |
| 40 | 243.8 | 260.8 | 258.6 | 253.7 | 0.0943 | 0 | 1 | 0.005 | 0.996 |
| 41 | 246.1 | 261.3 | 228.3 | 217.3 | 1.0007 | 0 | 1 | 0.000 | 1.000 |
| 42 | 244.5 | 260.5 | 231.2 | 217.0 | 1.0032 | 0 | 1 | 0.000 | 1.000 |
| 43 | 245.1 | 260.8 | 218.4 | 214.5 | 0.0968 | 0 | 1 | 0.000 | 1.000 |
| 44 | 244.6 | 261.0 | 216.2 | 229.7 | 0.0995 | 0 | 1 | 0.001 | 0.998 |
| 45 | 244.7 | 260.8 | 225.9 | 216.5 | 1.0008 | 0 | 1 | 0.000 | 1.000 |
| 46 | 246.0 | 261.8 | 217.4 | 230.9 | 0.0880 | 0 | 1 | 0.002 | 0.996 |
| 47 | 244.1 | 260.2 | 267.7 | 218.9 | 1.0044 | 0 | 1 | 0.000 | 1.000 |
| 48 | 244.5 | 261.0 | 222.0 | 220.3 | 1.0058 | 0 | 1 | 0.001 | 0.998 |
| 49 | 245.4 | 261.5 | 268.0 | 238.2 | 1.0045 | 0 | 1 | 0.000 | 1.000 |
| 50 | 245.5 | 261.8 | 225.4 | 225.0 | 1.0047 | 0 | 1 | 0.001 | 0.998 |
| 51 | 246.5 | 261.7 | 220.2 | 217.7 | 1.0078 | 0 | 1 | 0.000 | 1.000 |
| 52 | 245.8 | 262.5 | 266.2 | 254.9 | 1.0090 | 0 | 1 | 0.004 | 0.996 |
| 53 | 243.6 | 261.0 | 270.0 | 234.0 | 1.0072 | 0 | 1 | 0.000 | 1.000 |
| 54 | 243.8 | 260.3 | 268.6 | 228.1 | 1.0075 | 0 | 1 | 0.000 | 1.000 |
| 55 | 244.8 | 260.5 | 236.7 | 219.3 | 1.0152 | 0 | 1 | 0.000 | 1.000 |
| 56 | 245.3 | 261.0 | 256.9 | 219.1 | 0.0389 | 0 | 1 | 0.006 | 0.994 |
| 57 | 245.2 | 261.3 | 263.5 | 219.8 | 0.0471 | 0 | 1 | 0.006 | 0.994 |
| 58 | 245.5 | 260.9 | 251.5 | 217.8 | 0.0599 | 0 | 1 | 0.006 | 0.994 |
| 59 | 244.4 | 260.5 | 244.7 | 225.1 | 0.0676 | 0 | 1 | 0.006 | 0.994 |
| 60 | 245.1 | 261.7 | 237.1 | 225.0 | 0.0702 | 0 | 1 | 0.006 | 0.994 |

通过多次训练,根据训练结果确定网络训练参数,最终确定网络最大训练次数为 200,训练目标为 0.0001,学习速率为 0.6。图 6 所示为选取的 60 组样本数据对网络的训练效果,网络的输入数据为表 1 的第 2~6 列。

由图 6 可知训练 56 步后,均方误差约为 4.76×10^{-5} ,小于设定训练目标 0.0001,达到训练目标,神经网络停止训练。




图 6 BP 网络训练结果

Fig. 6 Train result of BP neural network

图 7 为动量 BP 网络对样本数据的拟合判断偏差曲线,这里偏差由网络判断结果和实际判断结果的欧氏距离表示,表示神经网络判断结果和实际判断结果的一致程度。由图可知最大判断偏差小于 0.02,判断偏差基本在 0.005 以下。




图 7 网络拟合判断偏差

Fig. 7 Deviation of the network fit judgment

4.2 测试、实验

为验证训练网络的泛化能力,需对神经网络进行测试,利用已训练好的动量 BP 网络对传感器检测的信息进行融合,把神经网络输出和人工根据传

传感器测试值分析得出的结果进行比较,以判断所建立的神经网络是否达到判别精度。表 2 所示为 10 组测试数据及其测试结果。由表中测试结果可以看

出利用训练好的动量 BP 神经网络对陀螺调腔是否合格进行检测判断的偏差为 0.001 左右。

表 2 神经网络测试数据及结果

Table 2 Test data and result of network

| Serial number | Facula center coordinate /pixel | | Diaphragm center coordinate /pixel | | Loss value $x_5/\%$ | Actual judgment | | Network judgment | | Judgment deviation |
|---------------|---------------------------------|----------------|------------------------------------|----------------|---------------------|-----------------|--------|------------------|-------|--------------------|
| | Abscissa x_1 | Ordinate x_2 | Abscissa x_3 | Ordinate x_4 | | result | result | | | |
| 1 | 245.0 | 261.6 | 251.2 | 270.3 | 0.0455 | 1 | 0 | 1.000 | 0.000 | 0.000 |
| 2 | 243.6 | 260.9 | 234.7 | 241.4 | 0.0608 | 1 | 0 | 0.999 | 0.001 | 0.002 |
| 3 | 244.4 | 260.6 | 243.5 | 276.8 | 0.0608 | 1 | 0 | 1.000 | 0.000 | 0.000 |
| 4 | 246.0 | 261.8 | 224.5 | 224.2 | 0.0836 | 0 | 1 | 0.000 | 0.999 | 0.001 |
| 5 | 244.4 | 260.5 | 239.8 | 241.8 | 0.0672 | 1 | 0 | 0.999 | 0.001 | 0.002 |
| 6 | 244.8 | 260.5 | 231.7 | 259.3 | 0.0656 | 1 | 0 | 1.000 | 0.000 | 0.001 |
| 7 | 244.4 | 260.9 | 241.0 | 234.5 | 0.0618 | 1 | 0 | 0.991 | 0.014 | 0.017 |
| 8 | 245.0 | 262.0 | 253.9 | 244.5 | 0.0778 | 1 | 0 | 0.991 | 0.013 | 0.015 |
| 9 | 245.4 | 261.3 | 238.8 | 259.8 | 0.0728 | 1 | 0 | 0.999 | 0.001 | 0.002 |
| 10 | 243.6 | 258.5 | 265.1 | 212.8 | 0.0828 | 0 | 1 | 0.000 | 1.000 | 0.000 |

接着将这个训练好的神经网络应用于调腔过程,动量 BP 网络对采集的 194 组数据进行分析并对调腔是否合格做出判断,结果正确判断 182 组,误判 12 组,图 8 为动量 BP 网络的判断偏差。由图可知,应用动量 BP 神经网络信息融合方法的判断结果与实际判断结果偏差几乎为 0,只有少数误判的才会出现较大偏差。

格; d_1 值小于 0.5 时支持合格的程度较小,表示调腔质量不合格。




图 8 实际应用误差

Fig. 8 Error in application

图 9 为应用动量 BP 神经网络检测判断的效果图。由于实际调腔时, d_1 值越大,相应的 d_2 值会越小,因此图 9 中以 d_1 值表示调腔质量合格程度。图中用上界“1”表示严格合格(1,0),下界“0”表示严格不合格(0,1),越接近上界“1”表示支持合格程度越高。图中符号 Δ 表示误判的点,O 表示人工根据 CCD 和光电倍增管检测的数据给出的判断,以这种判断作为实际判断。* 表示动量 BP 网络对 CCD 和光电倍增管信号融合后做出的判断。图中 d_1 值大于 0.5 时支持合格的程度更大,表示调腔质量合




图 9 实际判断与动量 BP 网络融合判断结果

Fig. 9 BP network fusion judgment result and actual result

同时,针对上述检测到的 194 组数据,分别分析了 CCD、光电倍增管及两者都使用时对调腔是否合格做出判断的准确率,如表 3 所示。

由表 3 检测结果可知用单一 CCD 检测准确率为 87.63%,单一光电倍增管检测准确率是 87.11%,而采用 CCD 和光电倍增管组成的多传感器信息融合检测方法准确率高达 93.81%,比人工采用单一传感器分步检测准确率提高了 6%。

表 3 各种检测方法的检测结果

Table 3 Detection results of different methods

| | CCD camera | Photomultiplier | CCD camera + photomultiplier |
|----------------|------------|-----------------|------------------------------|
| Wrong judgment | 26 | 25 | 12 |
| Accuracy /% | 87.63 | 87.11 | 93.81 |

5 结 论

鉴于传统人工调腔过程中,把对光斑-光阑中心距检测和陀螺损耗检测分步进行,从而导致效率低、质量差等缺点,提出了基于动量 BP 神经网络的多传感器信息融合调腔检测方法,同时检测光斑-光阑中心和陀螺损耗值,并送入融合中心进行融合处理,最终对调腔是否合格做出综合判断。根据调腔检测过程中实际输入、输出情况建立了 3 层动量 BP 神经网络结构,其中输入层、隐含层、输出层神经元个数分别为 5、11、2。并选取 60 组样本数据对网路进行训练,经过多次调整训练参数,最终当训练最大步数为 200,训练目标为 0.0001,学习速率为 0.6 时网络训练达到最佳效果,均方根误差为 4.76×10^{-5} 。

实验结果表明,动量 BP 神经网络信息融合方法对调腔质量是否合格判断准确率高达 93.81%,比人工采用单一传感器分步检测准确率提高了 6%,很好解决了传统人工调腔质量低、效率低等问题。

参 考 文 献

- 1 Zha Feng, Gao Jingdong, Xu Jiangning *et al.*. Overview on strap down inertial system consisted by optical gyros[J]. *Laser & Optoelectronics Progress*, 2011, **48**(7): 072301
查 峰, 高敬东, 许江宁等. 光学陀螺捷联惯性系统的发展与展望[J]. *激光与光电子学进展*, 2011, **48**(7): 072301
- 2 Zhang Mei. Angle random walk of ring laser gyro[J]. *Chinese J. Lasers*, 2011, **38**(2): 0208004
张 梅. 激光陀螺的角度随机游走[J]. *中国激光*, 2011, **38**(2): 0208004
- 3 Tao Wang, Li Liqun, Chen Yanbin *et al.*. Prediction of laser spot weld shape by using artificial neural network[J]. *Chinese J. Mechanical Engineering*, 2009, **45**(11): 300~305
陶 汪, 李俐群, 陈彦宾等. 基于人工神经网络的激光点焊点形态预测[J]. *机械工程学报*, 2009, **45**(11): 300~305
- 4 Yan Zhaojun, Li Xinyang. Neural network prediction algorithm for control voltage of deformable mirror in adaptive optical system [J]. *Acta Optica Sinica*, 2010, **30**(4): 911~916
颜召军, 李新阳. 基于神经网络的自适应光学系统变形镜控制电压预测方法[J]. *光学学报*, 2010, **30**(4): 911~916

- 5 R. Teschl, W. L. Randeu, F. Teschl. Improving weather radar estimates of rainfall using feed-forward neural networks [J]. *Neural Networks*, 2007, **20**(4): 519~527
- 6 Duan Baofu, Zhang Meng, Li Junmeng. A BP neural network model for forecasting of vibration parameters from hole-by-hole detonation [J]. *Explosion and Shock Waves*, 2010, **30**(4): 401~406
段宝福, 张 猛, 李俊猛. 逐孔起爆震动参数预报的 BP 神经网络模型[J]. *爆炸与冲击*, 2010, **30**(4): 401~406
- 7 R. Irani, R. Nasimi. Application of artificial bee colony-based neural network in bottom hole pressure prediction in underbalanced drilling [J]. *J. Petroleum Sci. Engng.*, 2011, **78**(1): 6~12
- 8 W. K. Wong, C. W. M. Yuen, D. D. Fan *et al.*. Stitching defect detection and classification using wavelet transform and BP neural network [J]. *Expert Systems with Applications*, 2009, **36**(2): 3845~3856
- 9 Yang Yang, Cheng Yin, Xu Mingshun *et al.*. Application of neural networks in design of Q-switched laser [J]. *Chinese J. Lasers*, 2010, **37**(3): 646~651
杨 阳, 程 寅, 徐明顺等. 神经网络在调 Q 激光器优化设计上的应用[J]. *中国激光*, 2010, **37**(3): 646~651
- 10 M. Ueda. Improvement of signal-to-noise ratio by stochastic resonance in sigmoid function threshold systems, demonstrated using a CMOS inverter [J]. *Physica A*, 2010, **389**(10): 1978~1985
- 11 Jiang Jianping, Zhang Yangsong, Yan Changhong *et al.*. Application of BP neural network in prediction of compression index of soil [J]. *J. Central South University (Science and Technology)*, 2010, **41**(2): 722~727
蒋建平, 章杨松, 阎长虹等. BP 神经网络在地基土压缩指数预测中的应用[J]. *中南大学学报(自然科学版)*, 2010, **41**(2): 722~727
- 12 Tang Yong, Ma Huiyu, Wang Yiqun. Flat area problem of BP algorithm on soft measurement system of dynamic flow [J]. *Chinese J. Mechanical Engineering*, 2009, **45**(9): 89~92
唐 勇, 马卉宇, 王益群. 动态流量软测量中 BP 算法平坦区问题[J]. *机械工程学报*, 2009, **45**(9): 89~92
- 13 Zhang Naimin. An online gradient method with momentum for two-layer feedforward neural networks [J]. *Applied Mathematics and Computation*, 2009, **212**(2): 488~498
- 14 Wu Wei, Wang Jian, Cheng Mingsong *et al.*. Convergence analysis of online gradient method for BP neural networks [J]. *Neural Networks*, 2011, **24**(1): 91~98
- 15 Shao Hongmei, Zheng Gaofeng. Convergence analysis of a back-propagation algorithm with adaptive momentum [J]. *Neurocomputing*, 2011, **74**(5): 749~752

栏目编辑:何卓铭