

文章编号 1004-924X(2007)07-1104-08

# 数据融合技术在声全息测量中的应用

高印寒<sup>1</sup>, 周晓华<sup>2</sup>, 梁 杰<sup>1</sup>, 常 鑫<sup>2</sup>

- (1. 吉林大学 测试科学实验中心, 吉林 长春 130022;
2. 吉林大学 仪器科学与电气工程学院, 吉林 长春 130022)

**摘要:**提出了基于神经网络和证据理论的数据融合技术。首先,根据声全息的测量原理,建立了由传感器子网和融合子网组成的数据融合模型。接着,给出了基于神经网络的传感器子网结构,实现了从目标特征参数到目标类型的映射,得到初步的输出结果。然后,采用证据理论将目标信息融合起来,达到对目标的有效识别得到最后的识别结果。最后,给出了数据融合技术应用于声全息法识别声源的实例计算。实验结果表明:数据融合后的声源识别率为94.2%,比融合前提高了11.7%。该技术减小了由于信息量不足或存在较大偶然误差而带来的不利影响,使声源的识别结果更可靠。

**关键词:**声全息;声源识别;神经网络;证据理论

**中图分类号:**O438.1 **文献标识码:**A

## Application of data fusion to acoustic holography

GAO Yin-han<sup>1</sup>, ZHOU Xiao-hua<sup>2</sup>, LIANG Jie<sup>1</sup>, CHANG Xin<sup>2</sup>

(1. *Centre of Test Science, Jilin University, Changchun 130022, China*; 2. *College of Instrumentation & Electrical Engineering, Jilin University, Changchun 130022, China*)

**Abstract:** A data fusion technology was proposed based on neural network and evidence theory, and a data fusion model consisting of the sensor subnet and the fusion subnet was established based on the measurement principle of acoustic holography. The sensor subnet on neural network was given to realize the map from the target characteristic parameters to the target type, so that the preliminary output was obtained. Then, the evidence theory and target information were synthesized to obtain the final identification result. Finally, an example was provided to illustrate the application of data fusion technology to the sound source identification of acoustic holography. Experimental results indicate that the identification rate of sound source is 94.2% after data fusion, It is increased by 11.7%. The application of data fusion technology can reduce the adverse effects caused by insufficient information or accidental errors and make the identification results of sound source more reliable.

**Key words:** acoustic holography; sound source identification; neural network; evidence theory

收稿日期:2006-12-11;修订日期:2007-03-21.

基金项目:高等学校博士学科点专项科研基金资助项目(No. 20050183019)

## 1 引言

声全息是利用声波干涉获得被观察物体声场全部信息的声成像技术。声全息在原理上与光全息<sup>[1]</sup>完全相同,是把光学上的干涉和衍射综合起来用于记录和显示图像的一种技术。声全息能够显示对可见光或 X 射线不透明的物质内部结构特性,可以弥补光学全息和 X 射线成像的不足。全息技术目前已经得到了广泛应用<sup>[2-3]</sup>在地质科学中用于资源勘探和地震观测,在工业上用于无损检测和水下探测,在临床医学中广泛用于人体内部疾病的医疗诊断等。

声全息技术一般包括获得物体的声全息图和由声全息图重建声场两个步骤。利用采样得到的全息数据重建声源平面,重建算法将直接影响声源的识别效果。目前,在国外声全息的研究中,利用较多的是菲涅尔变换推导的声全息重建公式<sup>[4]</sup>,以及利用波的反向传播原理推导的重建公式。在实际实验中,积分不可能在无穷大平面上进行,只能在有限大小的全息面上进行,将无限连续的重构公式转化为有限、离散并适合进行离散傅氏变换的表达形式。因此,全息数据的测量只是在全息面的有限离散测点上进行,如果将离散值进行简单求和,相当于将单个传感器的接收信号进行简单叠加。由于传感器的布置位置、性能不同等因素而使得提供的信息不完整、不精确甚至是矛盾的,即包含着大量的不确定性。由此获得的声场信息存在局限性,声源识别效果也将受到影响。为此,本文提出了数据融合技术,充分利用传感器在全息面上离散点的测量资源,通过对传感器及其观测信息的合理支配和使用,把传感器在空间或时间上的冗余或互补信息进行组合,以获得对被测对象的一致性解释或描述,使该信息系统比它的各组成部分的子集所构成的系统具有更优越的性能。该方法分为基于神经网络的传感器子网和基于证据理论的融合子网两部分进行处理,将智能化方法用于对目标的初步判决,然后用融合算法融合,使声场重建结果更可靠,声源识别率更高。文中在阐述声全息测量原理和多数数据融合理论的基础上,将数据融合技术应用到声全息法识别声源的具体实例中,通过模拟、计算和分析,证明了该方法的有效性。

## 2 声全息测量原理

声全息进行声场重建时,在离被测声源的外表面一定距离的平面上记录下声源信号的幅值和相位信息的全息数据,经过一定的处理作为全息函数。然后把全息函数代入重建公式,根据重建面与全息面的距离,推算出重建平面上的声源分布。测量原理如图 1 所示:




图 1 声全息原理图

Fig. 1 Principle map of acoustic holography

图中  $H$  为全息面,  $S$  为重建面,也称声源面。全息面与重建面相互平行,且间距为  $z_0$ 。通过测量全息面  $H$  上的复声压分布  $U(x_H, y_H)$ , 利用重建公式计算得到重建面  $S$  上的声场分布  $U_s(x, y)$ , 从而可识别出声源面上的噪声源。根据基尔霍夫边界条件,重建公式表示为<sup>[5]</sup>:

$$U_s(x, y) = \frac{1}{j2\lambda} \iint_H U(x_H, y_H) \left[ 1 + \left( 1 - \frac{1}{jk_0 r_1} \right) \frac{z_0}{r_1} \right] \frac{e^{jk_0 r_1}}{r_1} dx_H dy_H, \quad (1)$$

可以整理成:

$$U_s(x, y) = \iint_H U(x_H, y_H) W(x - x_H, y - y_H) dx_H dy_H, \quad (2)$$

其中:  $W(x, y) = \frac{\beta}{r_0^3} [z_0 - jk_0(r_0^2 + r_0 z_0)] e^{jk_0 r_1}$

$$r_1 = \sqrt{(x - x_H)^2 + (y - y_H)^2 + z_0^2}$$

$$r_0 = \sqrt{x^2 + y^2 + z_0^2}$$

式中:  $U_s(x, y)$  为重建面  $S$  上任意一点  $Q(x, y)$  的声场值,  $U(x_H, y_H)$  为全息面  $H$  上任一点  $P(x, y)$  的复声压,  $r_1$  为点  $P(x, y)$  与点  $Q(x, y)$  间的距离,  $r_0$  是重建面上任一点到全息面的距离,  $k_0$  为所感兴趣频率的波数。

在实际的测量中,不可能获取连续的无限大全息面  $H$  上的全息函数  $U(x_H, y_H)$ , 因此假设在无穷大的全息面上, 全息函数的测量只是在尺度为  $L_x \times L_y$  的全息面  $H$  上的离散点进行, 如图 2 所示:




图 2 全息面离散化示意图

Fig. 2 Sketch map of discrete holographic surface

将全息面离散成  $M \times N$  个大小相同的网格。即:

$$\Delta x = L_x / M, \quad \Delta y = L_y / N, \quad (3)$$

则式(2)的连续积分可以化为下式的离散求和:

$$\tilde{U}_s(m, n) = \Delta s \sum_{p=0}^{M-1} \sum_{q=0}^{N-1} U_H(p, q) \times W(m-p, n-q).$$

$$(m=0, 1, 2, \dots, M-1; n=0, 1, 2, \dots, N-1), \quad (4)$$

其中:  $\Delta s$  为图 2 中一个坐标方格的面积, 等式左侧的  $\tilde{U}_s(m, n)$  表示  $U_s(m, n)$  的一个估计。实验证明, 只要适当地选取离散网格的大小<sup>[6]</sup>, 就能使用  $\tilde{U}_s(m, n)$  代替  $U_s(x, y)$  有效地对声源进行识别。

全息函数在全息面离散点上的测量成为数据融合技术应用的前提。数据融合技术将不同网格上获得的同一声源的信息进行融合处理后, 获得整个声场的信息, 可以增强系统内部各离散值和目标的协调性, 提高目标检测概率和声源识别的准确率和位置, 以至提高系统输出结果的可信度和系统的性能。

### 3 数据融合结构

假设全息面上每个(或几个)离散值对应一个传感器, 则离散全息面上有多个传感器对同一声源进行测量, 为获得对该声源的综合识别结论, 采用神经网络与证据理论相结合的方式作为多传感器数据融合技术的模型。这是因为神经网络的

输入数据来自各个传感器的检测报告, 各传感器提供的信息包含着大量的不确定性, 而且多传感器信息融合问题本身具有复杂性, 单单利用神经网络来解决目标识别存在一些缺点。证据理论能将传感器多次报告提供的关于该目标的信息不断融合起来, 以达到对该目标的有效识别, 从而能够减小由于信息量不足或存在较大偶然误差而带来的不利影响, 提高系统的识别率。所以首先用神经网络训练学习样本, 得到初步的输出结果, 然后把神经网络的每次输出作为一条证据, 用证据理论方法把由此得到的证据不断地结合起来, 形成最后的识别结果。主要过程为: 传感器-神经网络-证据理论-识别结果。模型结构如图 3 所示:




图 3 网络结构

Fig. 3 Network structure

网络由传感器子网和融合子网两级组成, 传感器子网单独训练, 各子网的输出进入融合子网进行融合。其中, 传感器子网采用神经网络技术进行训练, 融合子网将来自多个传感器的目标识别结果作为多个证据, 采用证据理论的方法融合神经网络对每个传感器的判决输出, 从而提高声源识别的准确性。

#### 3.1 基于神经网络的传感器子网

神经网络具有良好的分类功能, 因此很多学者把目标特征参数作为神经网络的输入, 各种目标类型作为输出, 进行目标类型识别<sup>[7]</sup>。声全息识别声源中, 为了避免输入变量过多时神经网络规模过大的问题, 把采样平面上的离散测值进行分组, 每组中测值的离散求和结果作为每个传感器的测量值, 并作为神经网络的输入, 由模糊理论构造神经网络, 通过大量样本对网络进行训练, 实现从目标特征参数到目标类型的映射。

##### 3.1.1 网络选择

首先讨论单传感器目标识别过程。设传感器  $S$  可以提取  $n$  类信号特征, 并能识别  $m$  种目标,

传感器对每种目标的识别概率  $P_j(T_i)$  不同,  $P_j(T_i)$  表示第  $j$  个传感器对第  $i$  类目标的识别概率。网络构造如图 4 所示:




图 4 神经网络结构示意图

Fig. 4 Sketch map of neural network

定理证明:任意连续函数  $f$  可以精确地用一个三层网络实现<sup>[8]</sup>。该网络的第一层即输入层有  $n$  个神经元,中间层即规则层有  $2n+1$  个神经元,输出层有  $m$  个神经元。输入层接收传感器信号,每个输入层神经元接受一种特征信号,如声压幅值或相位等;规则层可以采用多种推理模型,如广义概率和、积模型、混合连接模型等。在本文中,规则层神经元采用广义概率积模型,输出层采用广义概率和模型,其表达式分别如下:

广义概率和:

$$y_i = 1 - \left[ \prod_{k=1}^n (1 - x_j)^{\omega_{ik}} \right]^{q_i}, \quad (5)$$

广义概率积:

$$y_i = \left[ \prod_{k=1}^n (x_j)^{\omega_{ik}} \right]^{p_i}, \quad (6)$$

其中  $\sum_{j=1}^n \omega_{jk} = 1, \omega_{jk} \geq 0, q_i \in [0, 1], p_i \in [0, 1]$ 。

输出层输出目标的识别结果,只是给出各个目标的可能概率,这是模糊理论的特点<sup>[9]</sup>。

### 3.1.2 学习算法

学习算法采用 BP(误差反向传播)算法<sup>[10]</sup>。分别用  $\zeta_k^5$  和  $\sigma_k^5$  表示输出层的第  $k$  个期望输出和实际输出,则单个样本的输出误差(均方误差)为:

$$e = \epsilon_p = \frac{1}{2} \sum_{k=1}^n (\zeta_k^5 - \sigma_k^5)^2, \quad (7)$$

假设有  $b$  个训练样本,则网络总误差为:

$$E = \sum e = \sum_{p=1}^b \epsilon_p, \quad (8)$$

网络训练的目标就是使网络总误差  $E$  小于一个

预先设定的误差限  $\epsilon$ 。

(1) 输入层至规则层的连接权值调整:

$$\omega_{ik}(t+1) = \omega_{ik}(t) - \eta \frac{\partial E}{\partial \omega_{ik}},$$

其中:  $i=1-n, k=1-m, \eta > 0$

(2) 规则层模糊推理算子参数的调整:

$$P_k(t+1) = P_k(t) - \eta \frac{\partial E}{\partial P_k},$$

其中:  $k=1-M, \eta > 0$

(3) 规则层至输出层的连接权值调整:

$$C_{kj}(t+1) = C_{kj}(t) - \eta \frac{\partial E}{\partial C_{kj}},$$

(4) 输出层模糊推理算子参数的调整:

$$q_j(t+1) = q_j(t) - \eta \frac{\partial E}{\partial q_j}.$$

以上式中,  $\eta$  为学习速度,  $E$  为输出总误差。

## 3.2 基于证据理论的融合子网

由于神经网络经过了大量样本的学习,所以输出结果不亚于领域专家的判断,采用证据理论将传感器多次报告提供的关于该目标的信息不断融合起来,达到对该目标的有效识别。在应用证据理论时,首先定义识别框架,其次计算基本概率分配函数,然后根据证据理论的组合规则对基本概率分配函数进行组合,再采用基于基本概率赋值的判定原则判定目标类型,形成最后的识别结果。

### 3.2.1 证据理论概述

证据理论中最基本的概念是识别框架<sup>[11]</sup>,记为  $\theta, \theta$  为变量的所有可能值的穷举集合,且框架中的各元素相互排斥。 $\theta$  的幂集( $2^\theta$ )构成了命题的集合。在  $2^\theta$  上定义基本概率分配函数  $m: 2^\theta \rightarrow [0, 1]$ ,且满足:

(1) 不可能事件的基本概率函数为 0:

$$m(\Phi) = 0$$

(2)  $2^\theta$  中全部元素的基本概率之和为 1:

$$\sum_{A \subseteq \theta} m(A) = 1$$

命题的信任函数 bel 和似然函数 pls 的定义为:

$$\text{bel}(A) = \sum_{B \subseteq A} m(B) \quad \forall A \subseteq \theta$$

$$\text{pls}(A) = 1 - \text{bel}(\bar{A}) \quad \forall A \subseteq \theta$$

bel(A) 表示对 A 的总的信任,pls(A) 表示不否定 A 的信任程度( $\bar{A} = \theta - A$ ),即为潜在支持 A 的信任度。 $[\text{bel}(A), \text{pls}(A)]$  构成命题 A 的不确定区间。

### 3.2.2 融合规则

对于多传感器系统,如果各传感器探测的主体相同(即识别框架相同),那么,多传感器数据融合实质上就成为在同一识别框架下,将不同的证据体合并成一个新的证据体的过程。应用证据理论解决多传感器多测量周期数据融合问题时,可以利用 Dempster 组合规则<sup>[12]</sup>。Dempster 组合规则是反映证据的联合作用的一个法则,它提供了组合两个证据的规则,可概括如下:

设  $bel_1$  和  $bel_2$  是同一识别框架  $\theta$  上的两个信任函数,  $m_1$  和  $m_2$  分别是其对应的基本概率赋值,焦化元分别为  $A_1 \cdots A_i$  和  $B_1 \cdots B_j$ , 又设:

$$K = \sum_{\substack{i,j \\ A_i \cap B_j}} m_1(A_i) m_2(B_j) < 1$$

$$\text{则: } m(C) = \begin{cases} \sum_{\substack{i,j \\ A_i \cap B_j}} m_1(A_i) m_2(B_j), & \forall C \subset \theta \\ 1 - K, & C \neq \phi \\ 0, & C = \phi, \end{cases} \quad (9)$$

式中,若  $K \neq 1$ ,则  $m$  确定一个基本概率赋值;若  $K = 1$ ,则认为  $m_1, m_2$  矛盾,不能对基本概率赋值进行组合。对于多个证据的组合,与次序无关,可采用 Dempster 组合规则对证据两两综合。

由证据理论方法得到合并后的基本概率的分配后,如何得到最后的决策结果没有一般性的统一方法,必须根据具体问题具体分析。在声全息法识别声源问题中,采用基于目标基本概率赋值(BPAF)的决策<sup>[13]</sup>。主要规则为:

规则 1:判定的目标类型具有最大的可信度;

规则 2:判定的目标类型的可信度与其他类型的可信度值的差必须大于某一阈值  $\epsilon_1$ ;

规则 3:不确定性区间长度必须小于某一阈值  $\epsilon_2$ ;

规则 4:判定的目标类型的可信度值必须大于不确定性区间长度。

设  $\exists A_1, A_2 \subset \Omega$ , 满足:

$$M(A_1) = \max\{M(A_i), A_i \subset \Omega\}$$

$$M(A_2) = \max\{M(A_i), A_i \subset \Omega \text{ and } A_i \neq A_1\}$$

若有: a.  $M(A_1) - M(A_2) > \epsilon_1$

$$b. M(U) < \epsilon_2$$

$$c. M(A_1) > M(U)$$

则  $A_1$  为决策结果,其中  $\epsilon_1, \epsilon_2$  为预先设定的阈值。

## 4 实例验证与结果分析

为验证方法的有效性,进行声全息法识别声源的实验。实验在消声室里进行,两个音箱作为声源,声源频率分别为  $f_1 = 500 \text{ Hz}$  和  $f_2 = 400 \text{ Hz}$ 。全息面与重建面距离为  $0.1 \text{ m}$ ,全息面和声源面大小均为  $0.5 \text{ m} \times 0.4 \text{ m}$ ,采样间隔为  $0.1 \text{ m}$ ,全息面离散点数为  $6 \times 5$ 。实验装置还有数据采集系统、传声器、信号发生器等。

### 4.1 数据处理

将两个频率不同的声源作为两类识别目标。假设全息面上有多个传感器对两类声源进行测量,为获得对该声源的综合识别结论,首先对每个传感器进行单独训练,以提供单一传感器的识别报告;然后对多个传感器的识别结果进行融合,以增强决策的信任度,最终利用识别规则做出判决。

主要数据处理如下:

(1) 全息面上采样点数为  $6 \times 5 = 30$ ,将其分成 5 组,每组 6 个采样点数,每 6 个离散值按公式(4)求和后作为神经网络的输入,也就是神经网络的实际输入是 5 维。等效为 5 个传感器,这样,相当于 5 个传感器的数据融合。

(2) 学习算法采用 BP 神经网络。理论上单个隐层就可实现任意函数的逼近,经过大量实验和误差分析,采用 11 个隐层单元。

(3) 输出节点数由识别的类别数确定。待识别声源有两类,则输出节点数为 2。

(4) 对神经网络的初步识别结果构造基本概率指派。由于证据理论要求基本概率指派满足归一化要求,神经网络的输出虽然都在  $[0, 1]$  之间,但节点输出(设为  $y_i = 1 \cdots N, N$  为输出节点数)之和并不满足归一化要求,因此在用证据理论融合之前需要对神经网络的输出作归一化处理。即:

$$m_i = C \cdot y_i / \sum_{i=1}^N y_i, i = 1, \dots, N$$

$$m(\theta) = 1 - C, \quad (10)$$

其中,  $m_i$  是神经网络输出归一化的结果,  $C$  为训练后的神经网络对模型库的识别正确率,  $1 - C$  是神经网络对目标识别的不确定信息,分配给辨识框架  $\theta$ 。

将按上式修正后的输出作为证据理论融合部分的输入,就是所需的基本概率指派。

(5) 采用融合算法融合目标,并依据规则进行判决输出。

### 4.2 网络训练

整个神经网络的结构是 5-11-2。训练的结果如图 5 所示:

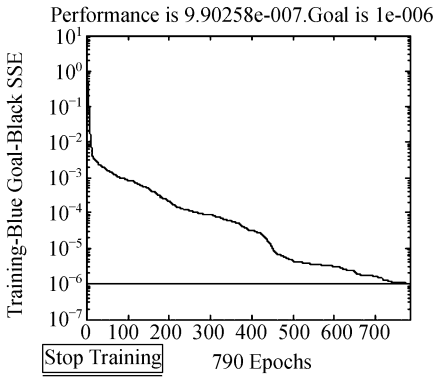


图 5 收敛曲线

Fig. 5 Convergent curve

从图中可以看出,经过 790 次训练,算法收敛,达到预期目标精度  $1e-006$ ,实际误差平方和  $SSE = 9.90258e-007$ 。

### 4.3 信息融合

神经网络训练后对声源的识别正确率为 85%,因此式(10)中的  $C=0.85$ ,判决输出规则取  $\epsilon_1=0.15, \epsilon_2=0.05$ 。用  $A_1, A_2$  表示要识别的两个声源,  $A_3$  表示不明声源,声源识别框架为  $\theta = \{A_1, A_2, A_3\}$ 。传感器子网训练后得到目标初步识别的输出结果,采用公式(10)对输出做归一化处理确定后的基本概率赋值如表 1 所示:

表 1 基本概率赋值

Tab. 1 Basic probability assignment

	$A_1$	$A_2$	$A_3$	$\theta$
$m_1$	0.65	0.20	0.00	0.15
$m_2$	0.48	0.32	0.00	0.20

求出数据融合后目标识别的可信度分配:

$$K = m_1(A_1)m_2(A_2) + m_1(A_2)m_2(A_1) = 0.304$$

$$m(A_1) =$$

$$\frac{m_1(A_1)m_2(A_1) + m_1(A_1)m_2(\theta) + m_1(\theta)m_2(A_1)}{1 - K}$$

$$= (0.312 + 0.130 + 0.072) / 0.696 = 0.739$$

$$m(A_2) =$$

$$\frac{m_1(A_2)m_2(A_2) + m_1(A_2)m_2(\theta) + m_1(\theta)m_2(A_2)}{1 - K}$$

$$= (0.064 + 0.040 + 0.048) / 0.696 = 0.218$$

$$m(\theta) = \frac{m_1(\theta)m_2(\theta)}{1 - K} = 0.030 / 0.696 = 0.043$$

融合结果如表 2 所示:

表 2 基本概率赋值

Tab. 2 Basic probability assignment

$A_1$	$A_2$	$\theta$
$m'(A_1) = 0.739$	$m'(A_2) = 0.218$	$m'(\theta) = 0.043$

对比表 1 和表 2,显然,融合后  $A_1$  的可信度提高了,而  $A_2$  的可信度降低了,融合结果对不确定性的基本概率赋值下降到了 0.043,比初始识别的不确定度低了许多,可见经过融合处理后识别率提高了。

### 4.4 数据融合前后的比较

对两个点声源  $A(0.20, 0.15, 0)$  500 Hz,  $B(0.40, 0.25, 0)$  400 Hz 进行目标识别,以图形方式显示数据融合前后声源识别的结果。

数据融合前的识别结果如图 6:

声源识别位置为:

$$A(0.18, 0.19, 0); B(0.43, 0.21, 0)$$




图 6 声源重建结果等高图

Fig. 6 Contour map of reconstructed results for sound sources (before data fusion)

数据融合后的识别结果如图 7:

声源识别位置为:

$$A(0.19, 0.15, 0); B(0.40, 0.24, 0)$$

从图 6 和图 7 可以看出,数据融合后的声源识别




图 7 声源重建结果等高图

Fig. 7 Contour map of reconstructed results for sound sources(after data fusion)




图 8 融合前后的声源识别结果

Fig. 8 Identification results of the two sound sources before and after data fusion

结果更符合声源的实际位置,而且有很好的降噪作用。

将融合前后的声源识别结果分别进行对比。数据处理中每 6 个采样点离散求和的结果对应 1 个传感器,30 个采样点对应 5 个传感器。融合前、神经网络初步识别及证据理论融合后结果对比如图 8 所示,图中横坐标为传感器对应的序号,纵坐标为基本概率指派值(BPA)。

可以看出,采用神经网络和证据理论结合的数据融合识别方法,由于综合了冗余信息和互补信息,融合后的置信值相比融合前任何一个置信值均有很大幅度的提高,识别结果的鲁棒性增加,识别率显著提高。融合前,声源的识别率为 82.5%,而融合后的识别率为 94.2%。

## 参考文献:

- [1] 潘武,田贻丽. 光学全息的数字实现[J]. 光学精密工程,2005,13(增):15-20.  
PAN W, TIAN Y L. Digital implementation scheme of optical hologram [J]. *Opt. Precision Eng.*, 2005,13 (Supp.):15-20. (in Chinese)
- [2] 楼俊,徐向东,刘颖,等. 全息平面变间距光栅刻线弯曲程度分析[J]. 光学精密工程,2006,14(1):12-15.  
LOU J, XU X D, LIU Y, *et al.*. Study on line-profiles of variable line-space plane gratings with holographic recording. [J]. *Opt. Precision Eng.*, 2006,14(1):12-15. (in Chinese)
- [3] 周文静,彭娇,于瀛洁. 基于数字全息技术的变形测量[J]. 光学精密工程,2005,13(增):46-51.  
ZHOU W J, PENG J, YU Y J. Deformation measurement via digital holography[J]. *Opt. Precision Eng.*, 2005, 13(Supp.):46-51. (in Chinese)
- [4] 杨殿阁,郑四发,李愈康,等. 用于声源识别的声全息重建方法的研究[J]. 声学学报,2001,26(2):156-160.  
YANG D G, ZHENG S F, LI Y K, *et al.*. Research on acoustic holography method for the identification of sound source [J]. *Acta Acustica*, 2001, 26(2):156-160. (in Chinese)
- [5] SCHUHMACHER, HALD J, RASMYSSEN K B, HANSEN P C. Sound source reconstruction using inverse boundary element calculations [J]. *Acoust. Soc. Am.*, 2003,113(1):114-127.

## 5 结论

通过对声全息测量原理的研究,将数据融合技术应用在声源识别中,采用基于神经网络的传感器子网和基于证据理论的融合子网两部分进行处理。神经网络训练学习样本,得到初步的输出结果,然后把神经网络的每次输出作为一条证据,用证据理论方法把由此得到的证据不断地结合起来,形成最后的识别结果。实验结果表明,融合后的声源识别率提高了 11.7%。该方法充分综合了多源信息提供的冗余信息和互补信息,识别结果更可靠,也适用于多声源的识别,为声全息测量中提高声源识别率提供了新途径。

- [6] WILLIAMS E G, HOUSTON B H, HERDIC P C. Fast fourier transform and singular value decomposition formulations for patch near field acoustical holography [J]. *Acoust. Soc. Am.*, 2003, 114(3):1322-1333.
- [7] 冯志庆,杨英慧,郭景富,等. 基于神经网络的点目标多光谱信息融合识别方法[J]. *光学精密工程*, 2003, 11(4): 412-415.  
FENG ZH Q, YANG Y H, GUO J F, *et al.*. Fusion recognition of dot target multi-spectrum data based on NN [J]. *Opt. Precision Eng.*, 2003, 11(4):412-415. (in Chinese)
- [8] 黄德双. 神经网络模式识别系统理论[M]. 北京:电子工业出版社,1996.  
HUANG D SH. *Theory of NN Recognition System* [M]. Beijing: Publishing House of Electronics Industry, 1996. (in Chinese)
- [9] 郑晓虎,朱荻. 模糊神经网络在UV-LIGA工艺优化中的应用[J]. *光学精密工程*, 2006, 14(1):139-144.  
ZHENG X H, ZHU D. Application of fuzzy neural network to optimizing UV-LIGA process [J]. *Opt. Precision Eng.*, 2006, 14(1):139-144. (in Chinese)
- [10] 陈吉锋,傅丰林,汪洋. BP网络参数对模式识别问题影响的研究[J]. *电子科技*, 2006, 203(8):16-19.  
CHEN J F, FU F L, WANG Y. The study of parameters of BP network for pattern recognition [J]. *Electronics Science and Technology*, 2006, 203(8):16-19. (in Chinese)
- [11] 曹可劲,赵宗贵,江汉. 一种基于证据理论和条件规则的目标识别方法[J]. *系统工程与电子技术*, 2006, 28(8): 1169-1171.  
CAO K J, ZHAO Z G, JIANG H. Target identification based on D-S theory and rule of conditioning[J]. *Systems Engineering and Electronics*, 2006, 28(8):1169-1171. (in Chinese)
- [12] 方士杰. 基于D-S理论的震动信号目标识别研究[J]. *微计算机信息*, 2006, 22(8):226-228.  
FANG SH J. Research in seismic target recognition based on D-S evidence theory [J]. *Micro Computer Information*, 2006, 22(8): 226-228. (in Chinese)
- [13] 曲东才. 基于BPAF判决的决策层目标属性融合研究[J]. *现代防御技术*, 2004, 32(6):6-9.  
QU D C. Research of the target characteristics fusion in the decision layers based on objector BPAF[J]. *Modern Defense Technology*, 2004, 32(6):6-9. (in Chinese)

**作者简介:**高印寒(1951—),男,吉林敦化人,吉林大学测试科学实验中心,教授,博士生导师,主要研究方向为先进制造技术及装备、测控技术及仪器,发表论文60余篇。E-mail: gaoyinhan@sohu.com  
周晓华(1981—),女,内蒙古人,吉林大学仪器科学与电气工程学院,博士研究生,主要研究方向为测试计量技术及仪器、噪声测量技术。E-mail: zhouxiaohua2006@sohu.com