

文章编号: 0258-7025(2009)05-1145-05

# 径向基函数神经网络在光纤法布里-珀罗传感器解调中的应用

吴 婧 王 鸣\*

(南京师范大学物理科学与技术学院, 江苏 南京 210097)

**摘要** 提出了一种基于径向基函数(RBF)神经网络的光纤法布里-珀罗传感器解调方法,从理论上分析了该方法的解调原理。从干涉谱中提取特征值,利用干涉谱的特征值和腔长作为训练集,对 RBF 网络进行训练,训练好的网络就可以实现预测腔长的功能。在测量范围为 0~2 MPa 的法布里-珀罗(F-P)腔 MEMS 压力传感器进行的解调实验中,该算法可以辨别 0.1 MPa 的压力,腔长与压力数据的拟合度为 0.98858。仿真计算得出,该方法解调出的腔长的相对误差达到 0.02%,腔长的最大绝对误差小于 0.1  $\mu\text{m}$ 。实验结果表明,神经网络方法可以达到较高的精度,满足实际需求。

**关键词** 光纤光学; 光纤 F-P 传感器解调; 径向基函数神经网络; 压力传感器

中图分类号 TN253 文献标识码 A doi: 10.3788/CJL20093605.1145

## Application of Radial Basis Function Network in Demodulation of Fabry-Pérot Pressure Sensor

Wu Jing Wang Ming

(School of Physical Science and Technology, Nanjing Normal University, Nanjing, Jiangsu 210097, China)

**Abstract** Radial basis function network method is presented for demodulation of Fabry-Pérot pressure sensors, and its principle and error are analyzed theoretically. At first eigenvalue is extracted from interference spectrum, and with the eigenvalue of the spectrum and the length of the cavity the radial basis function network is trained. The trained network can forecast cavity length. In the experiment of demodulating MEMS Fabry-Pérot pressure sensor with metrical range from 0 to 2 MPa, its resolution reaches 0.1 MPa, and the linearity between the length of the cavity and pressure achieves 0.98858. In the simulation, the relative error of this new method is just 0.02% and the maximum absolute error of the length of the sensor cavity is less than 0.1  $\mu\text{m}$ . The experiments show that this new method meets the practical demand with its high resolution.

**Key words** fiber optics; demodulation of fiber Fabry-Pérot sensors; radial basis function (RBF) neural network; pressure sensor

### 1 引 言

光纤微机电系统(MEMS)压力传感器具有的微型、响应频带宽、灵敏度高、成本低、抗干扰能力强、适应恶劣环境等特点使其成为光纤传感中的热点<sup>[1~10]</sup>。在光纤法布里-珀罗传感器测量系统中,解调技术是系统实现的关键,信号解调主要有强度解调和波长解调两大类,波长解调方法也有很多种,

如谱峰追踪、频率傅里叶变换等等。

谱峰追踪解调是通过跟踪归一化干涉谱中一个或数个特定干涉级次的谱峰来实现腔长解调的。已提出的谱峰追踪解调技术有单峰测量方式和双峰测量方式。单峰测量方式分辨率高,但为了避免谱峰级次模糊,动态范围有限;双峰测量方式的动态范围较大,能够实现腔长值的绝对测量,但测量分辨率却

收稿日期: 2008-09-28; 收到修改稿日期: 2008-10-15

基金项目: 江苏省科技支撑计划(BE2008138)资助课题。

作者简介: 吴 婧(1984—),女,硕士研究生,主要从事光纤传感方面的研究。E-mail: gwenwu723@163.com

导师简介: 王 鸣(1950—),男,教授,博士生导师,主要从事光电技术和微纳技术等方面的研究。

E-mail: wangming@njnu.edu.cn(通信联系人)

较低。本文提出了一种基于径向基函数(RBF)神经网络的谱峰追踪解调方法,避免了谱峰级次辨识,进行多个谱峰的连续跟踪,实现了大动态范围的测量。

## 2 RBF 神经网络原理

径向基网络也能够以任意精度逼近任意连续函数。如果要实现同一个功能,径向基网络的神经元个数可能要比前向反向传播算法(BP)网络的神经元个数要多,但是,径向基网络所需的训练时间却比前向 BP 网络的要少。

径向基函数网络是由输入层、隐含层和输出层构成的三层前向网络(以单个输出神经元为例),隐含层采用径向基函数作为激励函数。该径向基函数一般为高斯函数,如图 1 所示。隐层每个神经元与输入层相连的权值向量  $\omega_{1j}$  和输入矢量  $x^q$ (表示第  $q$  个输入向量),之间的距离乘上阈值  $b_{1i}$  作为本身的输入,如图 2 所示。




图 1 RBF 网络结构

Fig. 1 Structure of RBF network




图 2 RBF 网络隐含层神经元的输入与输出

Fig. 2 Input and output of hidden layer neuron of

RBF network

由此可得隐含层的第  $i$  个神经元的输入为

$$k_i^q = \sqrt{\sum_j (\omega_{1ji} - x_j^q)^2} \times b_{1i}, \quad (1)$$

输出为

$$r_i^q = \exp[-(k_i^q)^2] = \exp\left[-\sqrt{\sum_j (\omega_{1ji} - x_j^q)^2} \times b_{1i}\right] = \exp\left[-(\|\omega_{1i} - X^q\| \times b_{1i})^2\right]. \quad (2)$$

径向基函数的阈值  $b_{1i}$  可以调节函数的灵敏度。但实际工作中更常用另一参数  $C$ (称为扩展常数)。 $b_{1i}$  和  $C$  的关系有多种确定方法,在 Matlab 神经网络工具箱中, $b_{1i}$  和  $C$  的关系为  $b_{1i} = 0.8326/C_i$ ,此时隐含层神经元的输出变为

$$g_i^q = \exp\left[\frac{\sqrt{\sum_j (\omega_{1ji} - x_j^q)^2} \times 0.8326}{C_i}\right] = \exp\left[-0.8326^2 \times \left(\frac{\|\omega_{1i} - X^q\|}{C_i}\right)^2\right], \quad (3)$$

由此可见, $C$  值的大小实际上反映了输出对输入的响应宽度。 $C$  值越大,隐含层神经元对输入矢量的响应范围将越大,且神经元间的平滑度也较好。

输出层的输入为各隐含层神经元输出的加权求和。由于激励函数为纯线性函数,因此输出为

$$y^q = \sum_{i=1}^n r_i \times \omega_{2i}. \quad (4)$$

RBF 网络的训练过程分为两步:第一步为无教师式学习,确定训练输入层与隐含层间的权值  $\omega_1$ ; 第二步为有教师式学习,确定训练隐含层与输出层间的权值  $\omega_2$ 。在训练以前,需要提供输入矢量  $X$ 、对应的目标矢量  $T$  与径向基函数的扩展常数  $C$ 。训练的目的在于求取两层的最终权值  $\omega_1$ 、 $\omega_2$  和阈值  $b_1$ 、 $b_2$ (当隐含层单元数等于输入矢量数时,取  $b_2 = 0$ )。

在 RBF 网络训练中,隐含层神经元数量的确定是一个关键问题,传统的做法是使其与输入向量的元素相等。显然,在输入矢量很多时,过多的隐含层单元数是难以让人接受的。提出了改进方法,基本原理是从 0 个神经元开始训练,通过检查输出误差使网络自动增加神经元。每次循环使用,使网络产生的最大误差所对应的输入向量作为权值向量  $\omega_{1i}$ ,产生一个新的隐含层神经元,然后检查新网络的误差,重复此过程直到达到误差要求或最大隐含层神经元数为止。由此可见,径向基函数网络具有结构自适应确定、输出与初始权值无关等特点。

## 3 基于 RBF 网络的干涉谱处理方法

对于 F-P 压力传感器,在光纤端面反射率较低时可以用双光束干涉进行近似,其反射光强可用下式表示:

$$\frac{I_r}{I_0} = 2R \left[ 1 - \cos\left(\frac{4\pi L}{\lambda}\right) \right], \quad (5)$$

其中  $R$  为端面反射率(假设两端面反射率相同), $I_0$  为入射光强(假设各波长上入射光强相同), $L$  为

F-P腔的腔长。

由(5)式可见,腔长与光强和波长有关,给传感器一定的压力,光谱分析仪可以得到一组波长与光强对应的数据,压力连续变化,就可以得到很多组光谱数据。压力的变化导致腔长的变化,所以腔长的解调就要通过这些光谱数据来实现。

建立一个 RBF 网络,光谱信号特征值  $R_i$  和对应腔长  $g_i$  作为训练集,选取每个峰值位置作为特征值。峰值定位由小波降噪和最小二乘法拟合完成,最后对训练好的网络进行测试。任意取一组光谱特征值,网络可以自行计算出对应的腔长。

波长域的干涉信号并不是一个频率成分有限的限带信号,不适合利用有限冲击响应(FIR)低通滤波器来实现信号的降噪。小波变换是实现非限带信号降噪的有效方法。

对光谱信号进行小波降噪,首先选择一个小波基函数,确定小波分解的层次  $N$ ,对信号进行  $N$  层小波分解。有用干涉信号分布在低频部分,而噪声信号分布在高频部分。对小波分解得到每一层次高频部分的系数,应用一定统计的方法确定一个阈值。选取恰当的规则,对阈值限下的高频部分系数进行清零或适当减小。根据小波分解得到的第  $N$  层低频部分的系数和经过阈值处理的高频部分系数利用重构算法进行重构得到降噪后的信号。

经过小波降噪得到光滑的归一化干涉光谱信号后,首先在有效光谱范围内,通过简单的比较,找到干涉光谱极大值点作为谱峰位置的粗估值。确定谱峰位置的粗估值后,通过对谱峰粗估值附近的数点利用最小二乘法拟合来得到一条二次多项式曲线  $I(\lambda) = a_1 + a_2\lambda + a_3\lambda^2$ ,把拟合多项式曲线的极值点作为谱峰的精确位置。

## 4 实验与结果

### 4.1 实验系统

为了检验算法的可行性,建立起如图 3 所示的实验系统。由 Si720 传感分析仪的输出的宽光源经 2:2 耦合器一端与 F-P 压力传感器相连,另一端悬空,其反射光再经耦合器输入 Si720, Si720 扫描出反射光的光谱经网线传送给计算机,由计算机对光谱数据进行处理。

这里 F-P 压力传感器采用的是南京师范大学光电实验室研制的光纤 MEMS 压力传感器,其结构如图 4 所示。

光从单模光纤进入传感器,在光纤-硼硅玻璃、




图 3 实验系统图

Fig. 3 Experiment system




图 4 光纤 MEMS 压力传感器结构示意图

Fig. 4 Sketch of optical fiber MEMS pressure sensor

硼硅玻璃-空气腔、空气腔-铝介质界面上反射,反射光彼此干涉,最后反射到光纤的是复合腔的干涉信号,复合法布里-珀罗腔由硼硅玻璃层和空气腔构成。当硅敏感膜受到压力时,产生形变,导致法布里-珀罗腔腔长减小。

利用标准活塞式压力计给光纤 MEMS 压力传感器加压,从 0 MPa 开始间隔为 0.1 MPa 加压到 2 MPa。传感分析仪就得到 21 组光谱数据,对每一组光谱进行特征提取。

### 4.2 模拟分析

取第一组数据,对其进行小波降噪,由于数据量比较大,这里截取其中几个峰值看下滤波效果,如图 5 所示。

可以看到,经过小波降噪后的光谱非常光滑,并且与降噪前光谱相比,没有任何明显失真。

通过简单的比较,找到谱峰粗估值,对附近数点利用最小二乘法拟合,得到一条拟合曲线如图 6 所示,曲线的极值点作为谱峰的精确位置。

这样,一组光谱数据可以求得 30 个谱峰。21 组光谱可以得到一个  $21 \times 30$  的数组。

把谱峰对应的波长作为每个光谱的特征值,一组波长对应一个光谱,即对应一个腔长。利用经验公式得出一组腔长,30 个波长与 1 个腔长是一组输入输出数据,选其中 1~18 组作为训练样本,19~21 组为测试样本。利用 newrbe 函数创建一个精确的神经网络,该函数在创建 RBF 网络时,自动选择隐含层的数目,使得误差为 0。

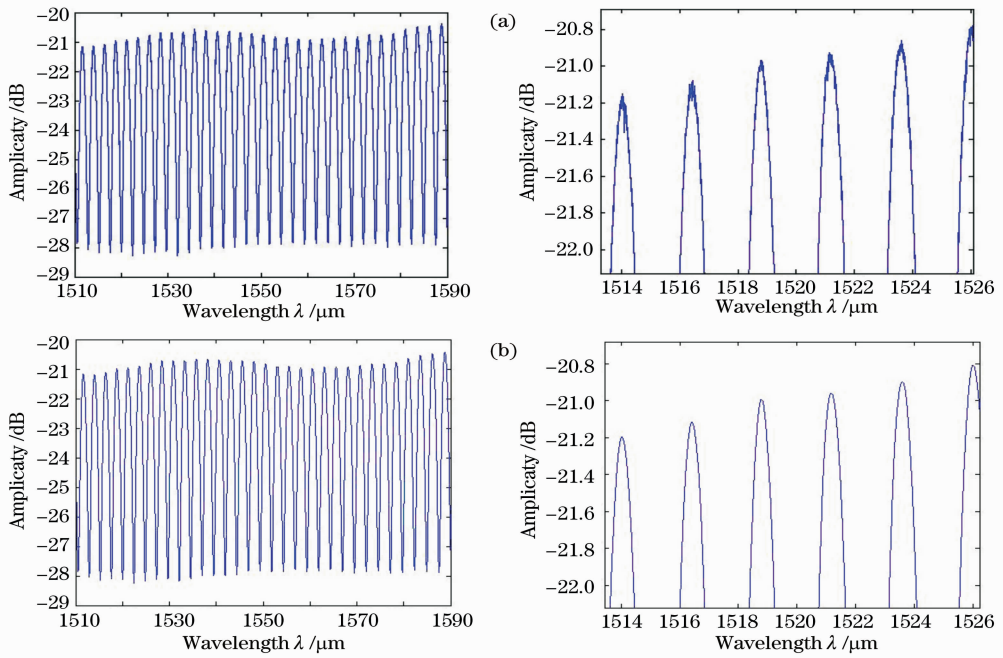


图 5 降噪前(a),降噪后(b)干涉谱信号和局部放大图

Fig. 5 Interference spectrum and magnified part before (a) and after (b) wavelet denoise






图 6 最小二乘法拟合曲线

Fig. 6 Least squares fitting curve

Matlab 里面, RBF 网络有一个径向基函数分布密度  $D_{\text{sprea}}$ , 值的大小影响网络的预测精度。  $D_{\text{sprea}}$  越大, 函数的拟合就越平滑。但是, 过大的  $D_{\text{sprea}}$  意味着需要非常多的神经元以适应函数的快速变化。如果  $D_{\text{sprea}}$  设定过小, 则意味着需要许多神经元来适应函数的缓慢变化。这样一来, 设计的网络性能就不会很好。因此, 在网络设计过程中, 需要不同的  $D_{\text{sprea}}$  值进行尝试, 以确定一个最优值。取  $D_{\text{sprea}} = 0.1, 0.2, 0.3, 0.4, 0.5$  计算网络的预报精度, 发现当  $D_{\text{sprea}} = 0.2$  时, 相对精度最高, 如图 7 所示。

由图 8 可见, 网络预测精度是比较好的。但是由于数据量有限, 预测数目比较小, 如果扩大训练集的个数, 预测数目也会相应增加。

解调出不同压力下反射光谱的峰值并计算出腔

图 7  $D_{\text{sprea}}$  不同取值误差Fig. 7 Error of different  $D_{\text{sprea}}$ 图 8  $D_{\text{sprea}} = 0.2$  误差Fig. 8 Error when  $D_{\text{sprea}} = 0.2$ 

长。对压力和腔长数据进行拟合, 如图 9 所示。得到的拟合方程为:

$$L = 485.2131 - 6.21366 \times P,$$

单位为  $\mu\text{m}$ 。式中  $P$  为压强,单位为 MPa,拟合度达到 0.98858。




图 9 腔长、压力数据拟合图

Fig. 9 Cavity length versus pressure

## 5 结 论

分析了 RBF 神经网络多峰测量的方法的原理,并通过实验结果实现了传感器的腔长解调,并在一定程度上解决了动态范围和分辨率的问题,减少了计算量。

## 参 考 文 献

- 1 Don C. Abeyasinghe, Samhita Dasgupta, Joseph T. Boyd *et al.*. A novel MEMS pressure sensor fabricated on an optical fiber[J]. *IEEE Photon. Technol. Lett.*, 2001, **13**(9): 993~995
- 2 Jie Zhou, Samhita Dasgupta, Hiroshi Kobavashi *et al.*. Optically interrogated MEMS pressure sensors for propulsion applications [J]. *Opt. Eng.*, 2001, **40**(4): 598~604
- 3 Jing Zhenguo, Yu Qingxu, Zhang Guiju *et al.*. A novel wavelength demodulating method for white light optical fiber sensor system[J]. *Acta Optica Sinica*, 2005, **25**(10): 1347~1351  
荆振国,于清旭,张桂菊等.一种新的白光光纤传感系统波长解调方法[J]. *光学学报*, 2005, **25**(10): 1347~1351
- 4 Ge Zhexue, Sun Zhiqian. The Principle of Neural Network and Realize with MATLAB[M]. Beijing: Publishing House of Electronics Industry, 2006. 116~120  
葛哲学,孙志强.神经网络理论与 MATLAB7 实现[M].北京:电子工业出版社,2006. 116~120
- 5 Wang Xiaodong. Application of RBF neural networks in sensor calibration[J]. *Chin. J. Scientific Instrument*, 2003, **24**(2): 96~98  
汪晓东. RBF 神经网络在传感器校正中的应用[J]. *仪器仪表学报*, 2003, **24**(2): 96~98
- 6 Yang Guangxue, Yin Lijing, Kang Shouqiang. Reconstruction of FBG spectrum based on radial basis function network[J]. *Transducer and Microsystem Technologies*, 2007, **26**(10): 12~14  
杨广学,尹丽静,康守强.基于径向基函数网络的 FBG 传感光谱的重构[J]. *传感器与微系统*, 2007, **26**(10): 12~14
- 7 A. Wang, H. Xiao, R. G. May *et al.*. Optical fiber sensors for harsh environments[C]. *SPIE*, 2000, **4077**: 2~6
- 8 B. Qi, G. Pickrell, J. Xu *et al.*. Novel data processing techniques for dispersive white light interferometers[J]. *Opt. Eng.*, 2003, **42**(11): 3165~3171
- 9 Abdeq M. Abdi, Steve E. Watkins. Demodulation of fiber-optic sensors for frequency response measurement[J]. *IEEE Sensors J.*, 2007, **7**(5): 667~676
- 10 Nie Yongjun, Yan Huiming, Du Yanli *et al.*. New data processing method of white light interference spectrum[J]. *J. Zhejiang University*, 2006, **40**(1): 38~40  
聂永军,严惠民,杜艳丽等.一种新的白光干涉谱数据处理方法[J]. *浙江大学学报*, 2006, **40**(1): 38~40