

# 一类反馈过程神经元网络模型 及其学习算法<sup>1)</sup>

何新贵 许少华

(北京大学信息科学技术学院 北京 100871)  
(E-mail hexingui@pku.edu.cn)

**摘要** 提出了一种基于权函数基展开的反馈过程神经元网络模型。该模型为三层结构，由输入层、过程神经元隐层和过程神经元输出层组成。输入层完成系统时变过程信号的输入及隐层过程神经元输出信号向系统的反馈；过程神经元隐层用于完成输入信号的空间加权聚合和激励运算，同时将输出信号传输到输出层并加权反馈到输入层；输出层完成隐层输出信号的空间加权聚集和对时间的聚合运算以及系统输出。文中给出了学习算法，并以旋转机械故障自动诊断问题为例验证了模型和算法的有效性。

**关键词** 过程神经元，反馈过程神经网络，聚合运算，基函数展开，学习算法  
**中图分类号** TP183

## A Feedback Process Neuron Network Model and Its Learning Algorithm

HE Xin-Gui XU Shao-Hua

(School of Electronics Engineering and Computer Science, Peking University, Beijing 100871)  
(E-mail: hexingui@pku.edu.cn)

**Abstract** A feedback process neural network model based on weight function base expansion is put forward. Structurally, this model has three layers, namely the input layer, process neuron hidden layer and process neuron output layer. The input layer completes input of the time-varying process signal and feedback of output from the hidden layer to the system, the process neuron hidden layer is used to complete the space weight aggregation and incitation operation, at the same time the output signal is transferred to the output layer and fed back to the input layer after being weighted. The output layer completes space weight aggregation and time aggregation of output signal from the hidden layer and the system output. The learning algorithm is given in this paper. The effectiveness of the model and algorithm is proved by automatic diagnoses of a rotating machine.

**Key words** Process neuron, feedback process neural network, aggregation operation, base function expansion, learning algorithm

1) 国家自然科学基金(60373102)资助

Supported by National Natural Science Foundation of P.R. China (60373102)

收稿日期 2003-7-16 收修改稿日期 2003-12-09

Received July 16, 2003; in revised form December 9, 2003

## 1 引言

针对实际应用领域中许多系统的输入是依赖于时间变化的连续函数(或称过程),其输出既依赖于对输入过程信号的空间聚合作用,又与输入过程信号的时间累积效应密切相关的问题,作者在文[1,2]中提出了过程神经元的概念和过程神经元网络模型。过程神经元的结构与传统神经元<sup>[3]</sup>不同之处在于过程神经元的输入和连接权都可以是时变函数,过程神经元既有对输入信号的空间聚合,亦有对时间效应的累积。过程神经网络可以直接把时变过程信号作为系统输入,这是传统人工神经网络在时间域上的一种扩展。

生物学研究表明,生物神经组织在进行信息处理时,实际上是带有信息反馈的。本文在文[1,2]的基础上,提出了一种反馈过程神经元网络模型。模型为三层结构,由输入层、过程神经元隐层和过程神经元输出层组成。输入层完成对系统时变过程信号的输入及隐层过程神经元输出信号向系统的反馈;过程神经元隐层完成对系统输入信号的空间加权聚合和激励运算,并将各神经元的输出信号输出到输出层,同时反馈到输入层;输出层完成对隐层输出信号的空间加权聚集和对时间的聚合运算以及系统输出。考虑网络连接权函数形式的任意性,在输入空间中选择一组适当的基函数,将权函数表示为该组基函数的有限项展开形式,从而将网络权函数的训练问题转化为权函数基展开系数的学习问题。文中给出了学习算法,并以旋转机械故障诊断问题为例证明了模型和算法的有效性。

## 2 网络拓扑结构

作者构造的反馈过程神经元网络模型为三层结构:输入层有  $n$  个节点,隐层有  $m$  个过程神经元节点,输出层由过程神经元构成。一个多输入单输出系统(不难推广到多输入多输出情况)的网络拓扑结构和信息流程如图 1 所示。

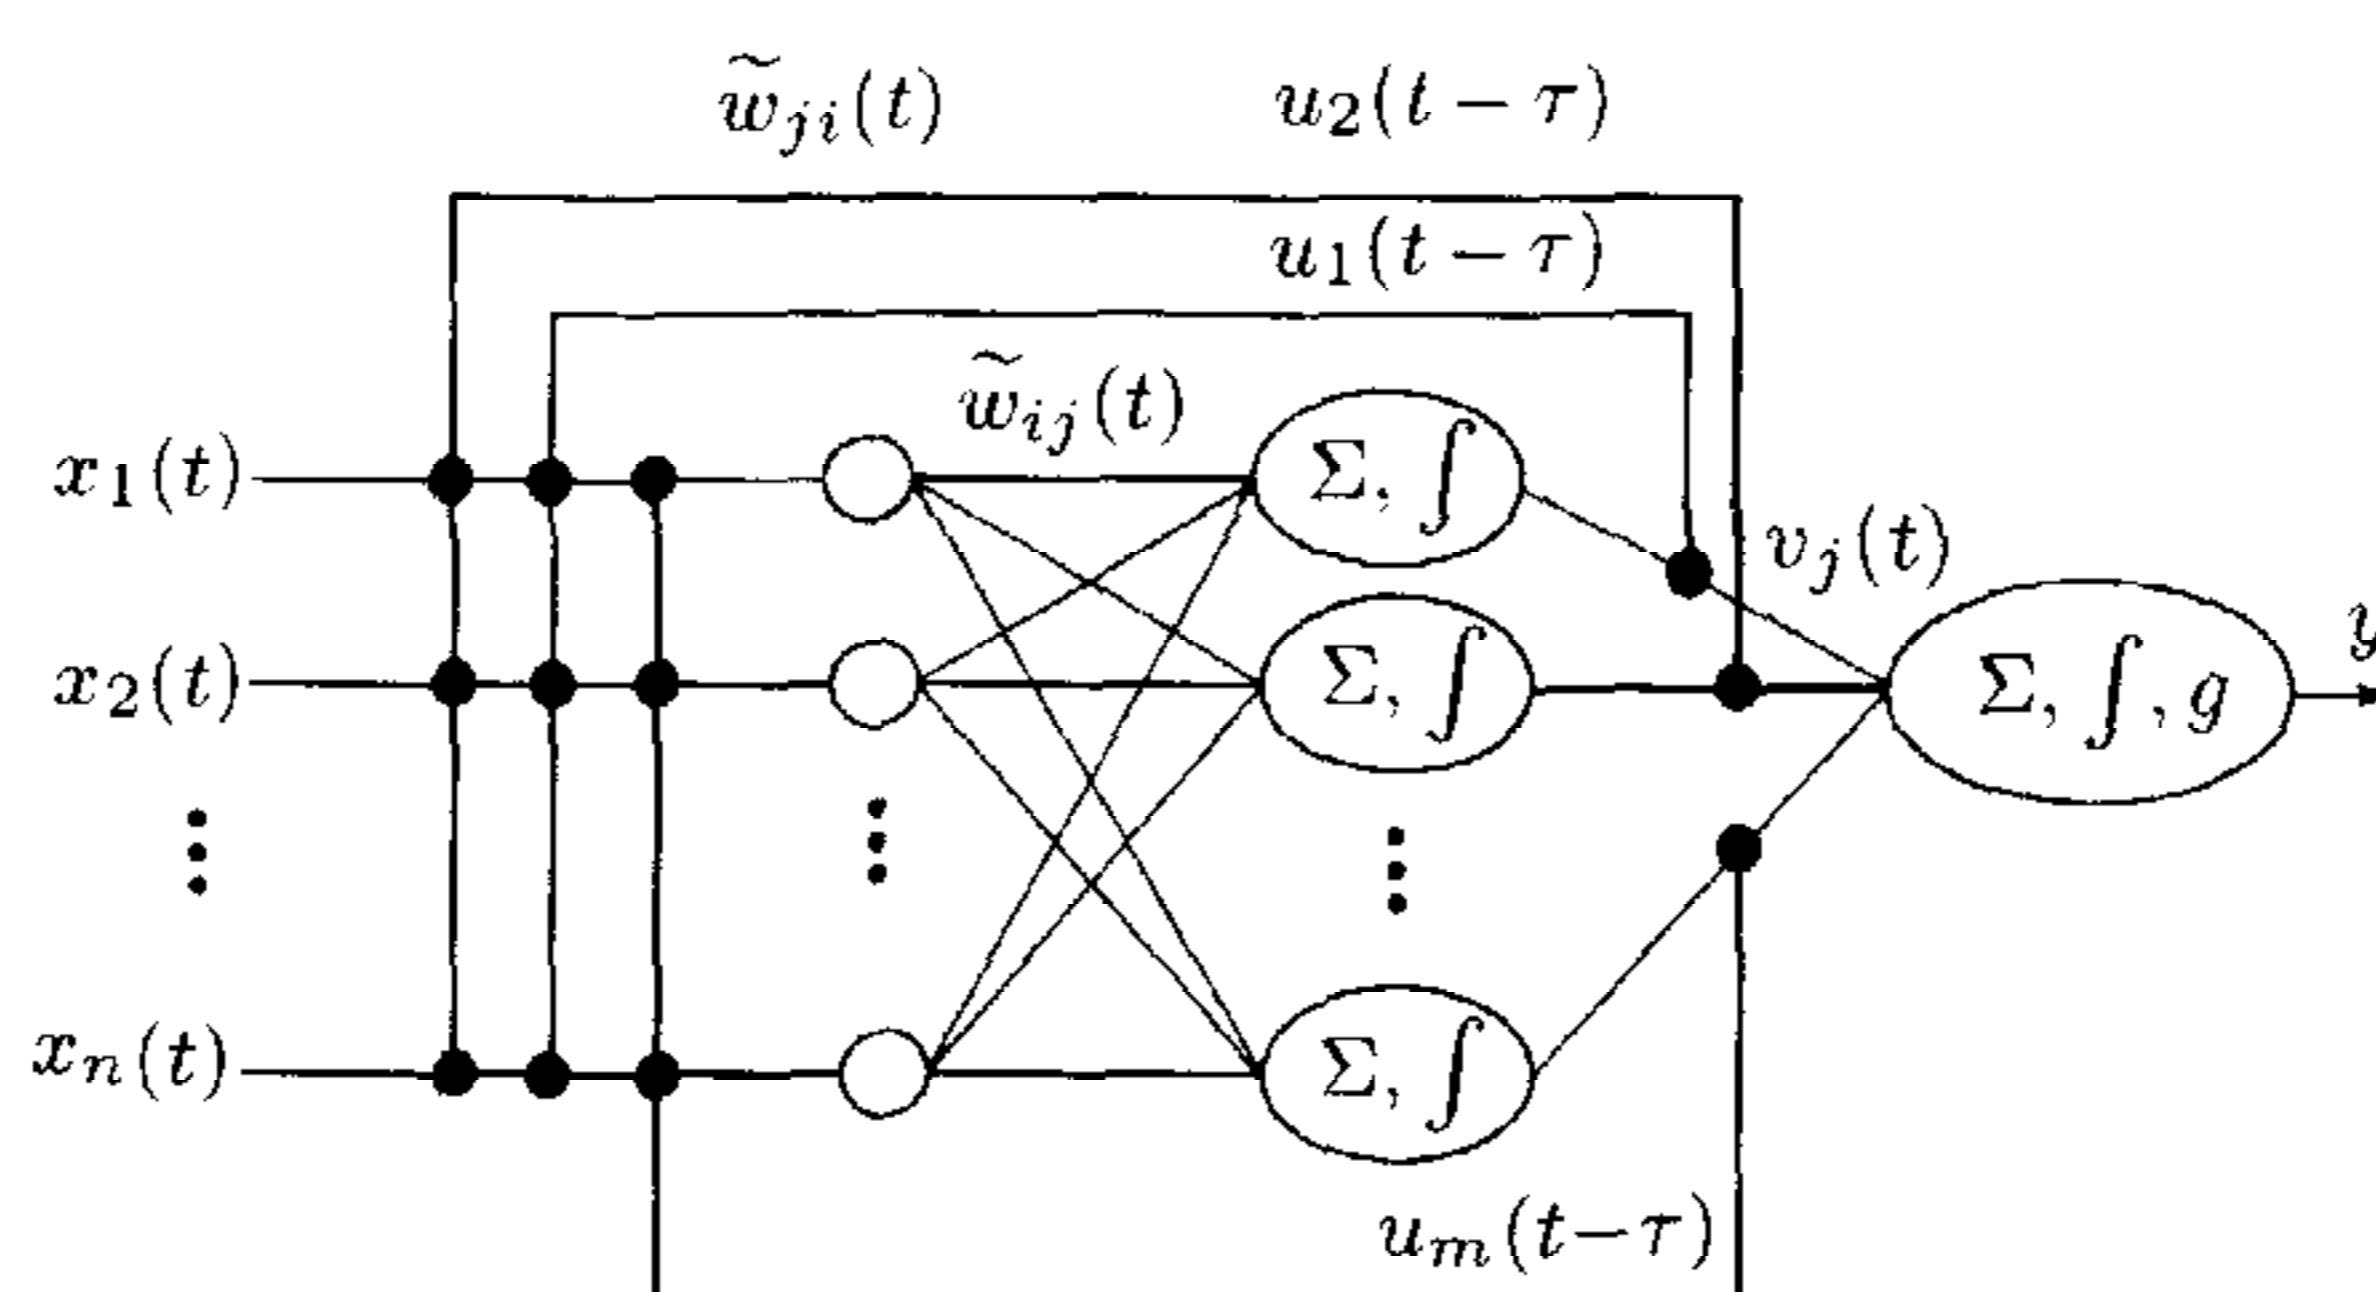


图 1 反馈过程神经元网络模型

Fig. 1 Feedback process neural network model

图 1 中网络各层输入输出之间的关系如下:

- 1) 系统输入  $x_1(t), x_2(t), \dots, x_n(t), t \in [0, T]$ ;  $[0, T]$  为系统输入过程区间;
- 2) 隐层过程神经元节点输出

$$u_j(t) = f\left(\sum_{i=1}^n (w_{ij}(t)(x_i(t) + \sum_{j=1}^m \tilde{w}_{ji}(t)u_j(t-\tau)))\right), \quad j = 1, 2, \dots, m \quad (1)$$

式中  $w_{ij}(t)$  为输入层第  $i$  个节点与隐层第  $j$  个节点的连接权函数,  $\tilde{w}_{ji}(t)$  为隐层第  $j$  个节点与输入层第  $i$  个节点的反馈连接权函数,  $u_j(t)$  为隐层第  $j$  个节点在时刻  $t$  的输出,  $\tau$  为时间延迟,  $f$  为隐层过程神经元激励函数;

### 3) 反馈过程神经网络的系统输出

$$y = g\left(\int_0^T \left(\sum_{j=1}^m v_j(t) u_j(t)\right) dt - \theta\right) \quad (2)$$

其中  $v_j(t)$  为隐层第  $j$  个节点与输出节点的连接权函数,  $\theta$  为输出层过程神经元的激励阈值,  $g$  为输出节点的激励函数,  $y$  为系统输出.

## 3 学习算法

给定  $P$  个样本函数  $(x_{p1}(t), x_{p2}(t), \dots, x_{pn}(t), d_p)$ ,  $p = 1, 2, \dots, P$ , 这里  $x_{pi}(t)$  的第 1 下标表示学习样本序号, 第 2 下标表示输入函数向量分量序号;  $d_p$  为对应于输入  $(x_{p1}(t), x_{p2}(t), \dots, x_{pn}(t))$  网络的期望输出. 设  $y_p$  为对应于输入  $x_{p1}(t), x_{p2}(t), \dots, x_{pn}(t)$  反馈过程神经网络的实际输出, 则网络误差函数可定义为

$$\begin{aligned} E &= \sum_{p=1}^P (y_p - d_p)^2 = \sum_{p=1}^P \left( g\left(\int_0^T \left(\sum_{j=1}^m v_j(t) u_i^p(t)\right) dt - \theta\right) - d_p \right)^2 \\ &= \sum_{p=1}^P \left( g\left(\int_0^T \left(\sum_{j=1}^m v_j(t) \left(f\left(\sum_{i=1}^n (w_{ij}(t)(x_{pi}(t) + \sum_{j=1}^m \tilde{w}_{ji}(t) u_j^p(t-\tau)))\right)\right)\right) dt - \theta\right) - d_p \right)^2 \end{aligned} \quad (3)$$

不失一般性, 设反馈过程神经网络的输入空间为  $(C[0, T])^n$ ;  $b_1(t), b_2(t), \dots, b_l(t), \dots$  为  $C[0, T]$  的一组基函数 (例如三角基函数、Walsh 基函数等). 将网络权函数  $v_j(t), w_{ij}(t), \tilde{w}_{ji}(t)$  表示为该组基函数的有限项展开形式:

$$v_i(t) = \sum_{l=1}^L v_j^{(l)} b_l(t) \quad (4)$$

$$w_{ij}(t) = \sum_{l=1}^L w_{ij}^{(l)} b_l(t) \quad (5)$$

$$\tilde{w}_{ji}(t) = \sum_{l=1}^L \tilde{w}_{ji}^{(l)} b_l(t) \quad (6)$$

其中  $v_j^{(l)}, w_{ij}^{(l)}, \tilde{w}_{ji}^{(l)}$  分别为  $v_j(t), w_{ij}(t), \tilde{w}_{ji}(t)$  关于  $b_l(t)$  的展开式系数.

将输入区间  $[0, T]$  进行适当的  $K$  等分, 设时间分割点为  $t_1, t_2, \dots, t_K$ , 则式 (2) 可改写为

$$y = g\left(\sum_{k=1}^K \sum_{j=1}^m v_j(t_k) u_j(t_k) (t_k - t_{k-1}) - \theta\right) \quad (7)$$

其中  $t_0 = 0, t_K = T$ .

式 (4~6) 的离散形式表示为

$$v_j(t_k) = \sum_{l=1}^L v_j^{(l)} b_l(t_k) \quad (8)$$

$$w_{ij}(t_k) = \sum_{l=1}^L w_{ij}^{(l)} b_l(t_k) \quad (9)$$

$$\tilde{w}_{ji}(t_k) = \sum_{l=1}^L \tilde{w}_{ji}^{(l)} b_l(t_k) \quad (10)$$

则网络误差函数式(3)可改写为

$$E = \sum_{p=1}^P (y_p - d_p)^2 = \sum_{p=1}^P \left( g \left( \sum_{k=1}^K \sum_{j=1}^m \left( \sum_{l=1}^L v_j^{(l)} b_l(t_k) \right) \left( f \left( \sum_{i=1}^n \left( \left( \sum_{l=1}^L w_{ij}^{(l)} b_l(t_k) \right) \left( x_{pi}(t_k) + \sum_{j=1}^m \left( \sum_{l=1}^L \tilde{w}_{ji}^{(l)} b_l(t_k) \right) u_j^p(t_{k-1}) \right) \right) - \theta \right) - d_p \right)^2 \right) \right) \quad (11)$$

由梯度下降算法, 网络权值修正规则为

$$v_j^{(l)} = v_j^{(l)} + \alpha \Delta v_j^{(l)}, \quad j = 1, 2, \dots, m \quad (12)$$

$$w_{ij}^{(l)} = w_{ij}^{(l)} + \beta \Delta w_{ij}^{(l)}, \quad i = 1, 2, \dots, n; j = 1, 2, \dots, m \quad (13)$$

$$\tilde{w}_{ji}^{(l)} = \tilde{w}_{ji}^{(l)} + \gamma \Delta \tilde{w}_{ji}^{(l)}, \quad j = 1, 2, \dots, m; i = 1, 2, \dots, n \quad (14)$$

$$\theta = \theta + \lambda \Delta \theta \quad (15)$$

为表述简便, 记

$$\begin{aligned} & \sum_{k=1}^K \sum_{j=1}^m \left( \sum_{l=1}^L v_j^{(l)} b_l(t_k) \right) \left( f \left( \sum_{i=1}^n \left( \left( \sum_{l=1}^L w_{ij}^{(l)} b_l(t_k) \right) \left( x_{pi}(t_k) + \sum_{j=1}^m \left( \sum_{l=1}^L \tilde{w}_{ji}^{(l)} b_l(t_k) \right) u_j^p(t_{k-1}) \right) \right) - \theta \right) - z_p^{(1)} \right) \\ & \sum_{i=1}^n \left( \left( \sum_{l=1}^L w_{ij}^{(l)} b_l(t_k) \right) \left( x_{pi}(t_k) + \sum_{j=1}^m \left( \sum_{l=1}^L \tilde{w}_{ji}^{(l)} b_l(t_k) \right) u_j^p(t_{k-1}) \right) \right) = o_{pj}^{(1)} \end{aligned}$$

则

$$\Delta v_j^{(l)} = -\frac{\partial E}{\partial v_j^{(l)}} = -2 \sum_{p=1}^P (g(z_p^{(1)}) - d_p) g'(z_p^{(1)}) \sum_{k=1}^K b_l(t_k) f(o_{pj}^{(1)}) (t_k - t_{k-1}) \quad (16)$$

$$\begin{aligned} \Delta w_{ij}^{(l)} = -\frac{\partial E}{\partial w_{ij}^{(l)}} &= -2 \sum_{p=1}^P (g(z_p^{(1)}) - d_p) g'(z_p^{(1)}) \sum_{k=1}^K v_j(t_k) f'(o_{pj}^{(1)}) b_l(t_k) (x_{pi}(t_k) + \\ &\sum_{j=1}^m \tilde{w}_{ji}(t_k) u_j^p(t_{k-1})) (t_k - t_{k-1}) \end{aligned} \quad (17)$$

$$\begin{aligned} \Delta \tilde{w}_{ji}^{(l)} = -\frac{\partial E}{\partial \tilde{w}_{ji}^{(l)}} &= -2 \sum_{p=1}^P (g(z_p^{(1)}) - d_p) g'(z_p^{(1)}) \sum_{k=1}^K v_i(t_k) \times \\ &f'(o_{pj}^{(1)}) w_{ij}(t_k) b_l(t_k) u_j^p(t_{k-1}) (t_k - t_{k-1}) \end{aligned} \quad (18)$$

$$\Delta \theta = -\frac{\partial E}{\partial \theta} = -2 \sum_{p=1}^P (g(z_p^{(1)}) - d_p) g'(z_p^{(1)}) (-1) \quad (19)$$

算法描述:

**第1步.** 给定误差精度  $\varepsilon$ , 学习累计次数  $s = 0$ , 最大学习次数  $M$ , 选取基函数  $b_1(t), b_2(t), \dots, b_L(t)$ , 对区间  $[0, T]$  进行适当等分割, 确定分割点  $t_1, t_2, \dots, t_k$ ;

**第2步.** 初始化网络权值和阈值  $v_j^{(l)}, w_{ij}^{(l)}, \tilde{w}_{ji}^{(l)}, \theta (i = 1, 2, \dots, n; j = 1, 2, \dots, m; l = 1, 2, \dots, L)$ ;

**第3步.** 由式(11)计算误差函数  $E$ , 如果  $E < \varepsilon$  或  $s > M$ , 转第5步;

**第4步.** 按式(12)~(19)修正权值和阈值,  $s + 1 \rightarrow s$ , 转第3步;

**第5步.** 输出学习结果, 结束.

## 4 应用实例

旋转机械是以转子及其它回转部件作为工作主体的机械设备. 对于旋转机械故障的诊断问题, 不同故障类型对应不同的时域波形信号, 因此通过对采样区间内连续波形信号的识别, 实现故障自动诊断. 旋转机械运动呈周期性, 故可把机械的一个旋转周期作为采样区间, 把一个周期内的信号连续变化过程作为一个样本. 旋转机械的典型故障主要分为偏心、不同轴、磨损, 加上正常共4种情况. 典型信号曲线如图2所示. 以本文构造的

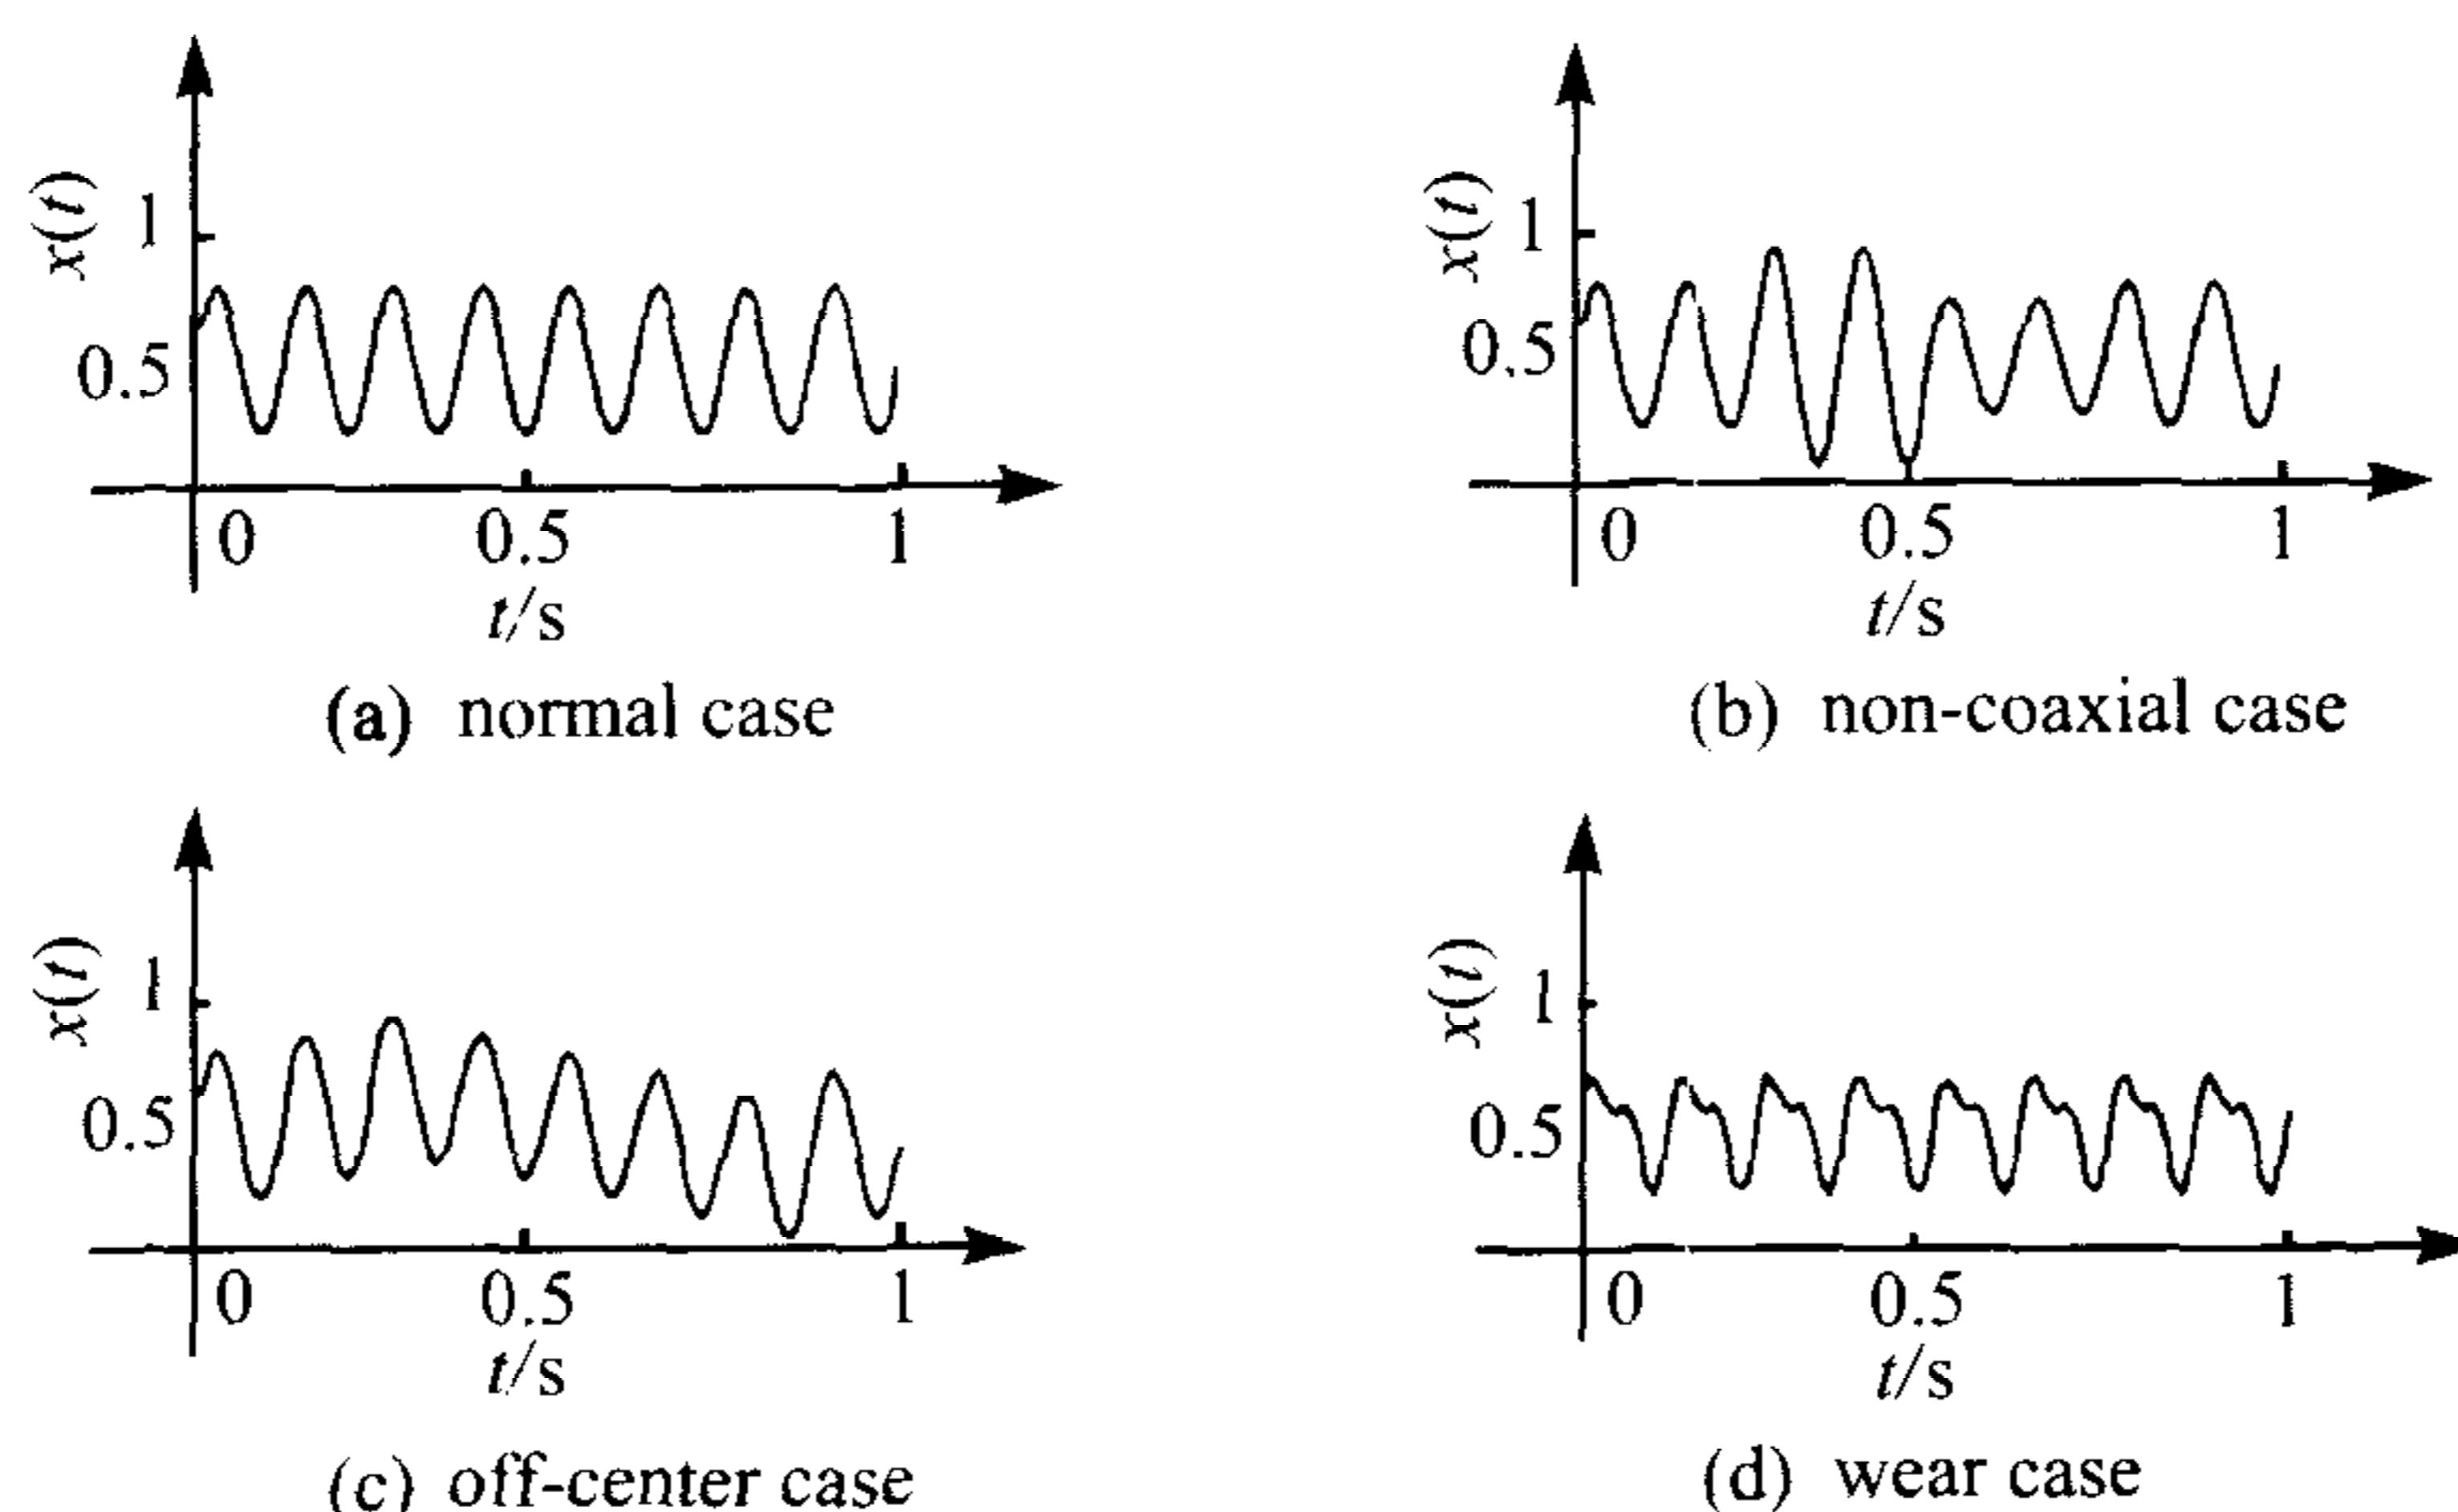


图2 旋转机械运动4种典型曲线

Fig. 2 Four kinds typical curves of rotating machine mechanical motion

反馈过程神经网络作为旋转机械故障自动诊断器, 以一个周期内的连续变化信号为网络输入, 输出为机械工作状态(故障类型). 针对上述4种情况, 在实际测量信号中, 分别选取了5条不同轴、6条偏心、5条磨损和3条正常共19条信号曲线组成学习样本集. 网络结构参数选择如下: 1个输入节点, 7个过程神经元隐层节点, 1个输出节点. 基函数选择完备归一化的 Walsh 正交函数系. 连续 Walsh 变换对为<sup>[4]</sup>

$$f(t) = \sum_{n=0}^L F_n wal(n, t) \quad (20)$$

$$F_n = \int_0^1 f(t) wal(n, t) dt \quad (21)$$

其中  $wal(n, t)$  为连续 Walsh 基函数,  $n$  为列率,  $t$  为时间变量. 将学习样本集中的样本带入反馈过程神经网络进行训练, 类别输出不同轴情况对应 0.25, 偏心情况对应 0.50, 磨损情况对应 0.75, 正常情况对应 1.0. 基函数个数  $L$  为 32, 学习效率  $\alpha = 0.55$ ,  $\beta = 0.50$ ,  $\gamma = 0.60$ ,  $\lambda = 0.55$ , 最大学习次数  $M=10000$ , 学习精度  $\epsilon = 0.05$ . 网络训练经过 877 次迭代后收敛. 对 10 个测试样本进行识别, 判对 9 个, 正确率为 90%. 与已有的一些旋转机械故障自动诊断方法比较, 这是一个较好的结果.

## 5 结束语

提出了一种基于权函数基展开的反馈过程神经元网络模型. 模型中的信息传输既有象前馈神经网络一样的前向流, 又有隐层节点到输入层的连续信息反馈. 因此, 反馈过程神经网络既可以作为泛函数逼近器, 同时也可做为联想记忆机. 在基函数的选择中, 考虑连续系统的实际输入既可能是连续的解析函数, 也可能是离散时间采样数据两种情况, 采用三角函数系或 Walsh 函数系作为基函数是值得推荐的.

### References

- 1 He Xingui, Liang Jiuzhen. Process Neural Network. In: Zhongzhi Shi, Boi Faitings, Mark Musen, Proceedings of 16th World Computer Congress on Intelligent Information Processing. Beijing: Publishing House of Electronic Industry, 2000. 143 ~ 146
- 2 He Xingui, Liang Jiuzhen. Some theoretic problems of process neuron network. *Engineering Science*, 2000, 2(12): 40 ~ 44 (in Chinese)
- 3 McCulloch W S, Pitts W H. A logical calculus of the ideas immanent in neuron activity. *Bulletin Mathematical Biophysics*, 1943, 5(1): 115 ~ 133
- 4 Wang Nengchao. Synchronous Parallel Algorithm Design. Beijing: Science Press, 1996. 100 ~ 105 (in Chinese)

**何新贵** 教授, 博士生导师, 中国工程院院士, 研究领域为模糊逻辑, 神经网络, 进化计算, 数据库理论.  
**(HE Xin-Gui** Professor, Ph.D. director, the academician of Chinese Academy of Engineering. His research interests include fuzzy logic, neural network, evolutionary computation, database theory.)

**许少华** 博士后. 研究方向为模式识别, 神经网络.

**(XU Shao-Hua** Postdoctor. His research interests include pattern recognition and neural network.)