

# RBF 神经网络在变速箱齿轮故障诊断中的应用

褚衍贺<sup>1</sup>, 陈洪建<sup>2</sup>, 商艳兰<sup>3</sup>

(1. 青岛科技大学, 山东 青岛 266042;

2. 中国联通泗水分公司, 山东 济宁 273200;

3. 滨州市无棣县农业局, 山东 滨州 251900)

**摘要:** 提出了径向基函数神经网络应用于变速箱齿轮故障诊断的基本方法。利用 Matlab 神经网络工具箱对变速箱齿轮进行故障诊断仿真, 并创建 RBF 神经网络与 BP 神经网络来进行故障诊断。通过对比诊断结果, 证明 RBF 网络在诊断精度、诊断速度上均优于 BP 网络, 说明 RBF 网络应用于齿轮的故障诊断准确、可靠, 在机械故障诊断方面具有广泛的应用前景。

**关键词:** 故障诊断; 神经网络; RBF 网络; 变速箱齿轮

中图分类号: TP306

文献标识码: A

文章编号: 1674-7720(2010)17-0094-04

## Application of RBF neural network to fault diagnosis in transmission gear

CHU Yan He<sup>1</sup>, CHEN Hong Jian<sup>2</sup>, SHANG Yan Lan<sup>3</sup>

(1. Qingdao University of Science and Technology, Qingdao 266042, China;

2. Sishui Branch of China Unicom, Jining 273200, China;

3. Agriculture Bureau of Wudi Country, Binzhou 251900, China)

**Abstract:** A new method for transmission gearbox fault diagnosis is put forward in this paper by using radial basis function neural network (RBF network). RBF neural network is created to simulate the gearbox fault diagnosis using Matlab neural network toolbox. Compared with BP neural network, RBF network is superior to the former in the accuracy and speed according to the simulate results. This new method is accurate and credible in gear fault diagnosis, and it has a broad application prospects in mechanical fault diagnosis.

**Key words:** fault diagnosis; neural network; RBF network; transmission gear

由于汽车的特殊运行条件和环境, 以及汽车行驶过程中经常性换挡, 使得变速箱中齿轮、轴、轴承等常发生故障。据统计, 由齿轮失效引起的汽车变速箱故障占全部原因的 60%。在这里, 齿轮失效的主要形式有齿根裂痕和弯曲疲劳引起的断齿等。因而随着汽车技术的发展, 对变速箱实施故障诊断、特别是对齿轮的诊断变得尤为重要。目前, 故障诊断技术已进入到智能化阶段。对汽车变速器齿轮故障诊断的实施方法有很多种, 如磨损残余物分析诊断法、振动监测技术诊断法、声发射技术诊断法、光纤传感技术诊断法、人工神经网络技术诊断法等<sup>[1]</sup>。

神经网络技术的出现, 为故障诊断问题提供了一种新的解决途径。近几年, RBF 神经网络大量应用于机械故障诊断, 如汽车发动机、压缩机、水轮机、内燃机等。在故障诊断的应用中, RBF 神经网络的应用能准确、快速地判断故障类型和原因, 对及早发现和排除故障发挥了很好的作用。在实际运行中, 引起故障的原因很多, 不同故障表现出的征兆有时具有相似性。针对故障原因与故障征兆之间的非线性关系, 应用 RBF 神经网络进行故障诊断能准确、快速判断故障类型和原因, 对于提高安全性具有重要的意义。

本文提出了 RBF 网络应用于变速箱齿轮故障诊断

的基本方法,利用 Matlab 神经网络工具箱对变速箱齿轮进行故障诊断仿真,并创建 RBF 神经网络与 BP 神经网络来进行故障诊断。

### 1 神经网络故障诊断原理<sup>[2]</sup>

神经网络是由多个神经元按一定的拓扑结构相互连接而成。神经元之间的连接强度体现了信息的存储和相互关联程度,且连接强度可通过学习加以调节。神经元模型结构如图 1 所示。

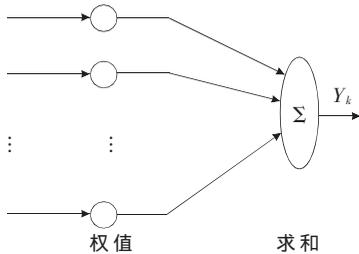


图 1 神经元模型结构

神经网络输入层从监控对象接收各种故障信息及现象,并经归一化处理,计算故障特征值为: $X=[x_1, x_2, \dots, x_n]$ ;中间层从输入得到的信息经内部学习和处理,转化为有针对性地解决办法,该层含有隐节点,一般可以完成输入模式到输出模式的非线性映射;输出层通过神经元输出与阈值的比较得出诊断结果。输出层节点数为故障模式的总数。若第  $j$  个模式的输出为: $Y_j=(0, 0, \dots, 0, 1, 0, \dots, 0, 0)$ ,即第  $j$  个节点的输出为 1,其余输出均为 0,它表示第  $j$  个故障存在(输出 0 表示无故障)。

利用神经网络进行故障诊断的基本思想是:以故障特征作为神经网络输入,诊断结果作为神经网络输出。首先利用已有的故障诊断征兆和诊断结果对神经网络进行离线训练,使神经网络通过权值记忆故障征兆与诊断结果之间存在的对应关系;然后将得到的故障征兆加到神经网络的输入端,就可以利用训练后的神经网络进行故障诊断,并得到相应的诊断结果。

可以看出,神经网络进行故障诊断是利用它的相似性、联想能力和通过学习不断调整权值来实现。给神经网络存入大量样本,神经网络就对这些样本进行学习。当  $n$  个类似样本被学习后,根据样本的相似性,把它们归一为同一类的权值分布。当第  $n+1$  个相似样本输入时,神经网络会通过学习来识别它的相似性,并经权值调整把这  $n+1$  个样本归入一类。神经网络的归类标准表现在权值的分布上。当部分信息丢失时,如  $n$  个样本中丢失了  $n_1(n_1 < n)$  个,则神经网络还可通过另外  $n-n_1$  个样本去学习,而不影响全局。

设对神经网络输入具有对应关系的两组样本为  $X(p) \rightarrow Y(p)$ ,  $X(p)$  代表输入的故障信息,  $Y(p)$  代表输出的解决策略。在这里,输入的样本越多,它的功能就越强。当有另一故障输入时,如  $X=X(r)+V$ ,式中,  $X(r)$  是样本之一,  $V$  为偏差项。神经网络经过学习不断调整权值,就可以

输出  $Y=Y(r)$ ,这样,当输入一个新的故障现象,神经网络经过学习总可以找到一个解决策略。

### 2 RBF 神经网络

径向基函数(Radial Basis Function)神经网络是由 J. Moody 和 C. Darken 在 20 世纪 80 年代末提出的一种神经网络,它是具有单隐层的三层前馈网络。RBF 网络模拟了人脑中局部调整、相互覆盖接受域(或称感受域, Receptive Field)的神经网络结构,已证明 RBF 网络能任意精度逼近任意连续函数。RBF 网络的学习过程与 BP 网络的学习过程类似,两者的主要区别在于各使用不同的作用函数。BP 网络中隐含层使用的是 Sigmoid 函数,其值在输入空间中无限大的范围内为非零值,因而是一种全局逼近的神经网络;而 RBF 网络中的作用函数是高斯基函数,其值在输入空间中有限范围内为非零值,因而 RBF 网络是局部逼近的神经网络。RBF 网络是一种三层前向网络,由输入到输出的映射是非线性的,而隐含层空间到输出空间的映射是线性的,前者是一个非线性优化的问题,求解方法较复杂,目前可选用的学习方式较多,主要有随机选取 RBF 中心(直接计算法)、无监督学习选取 RBF 中心(K-均值聚类法)、有监督学习选取中心(梯度下降法)和正交最小二乘法(OLS)等<sup>[3-5]</sup>。本文主要采用第一种方法。RBF 网络结构如图 2 所示。

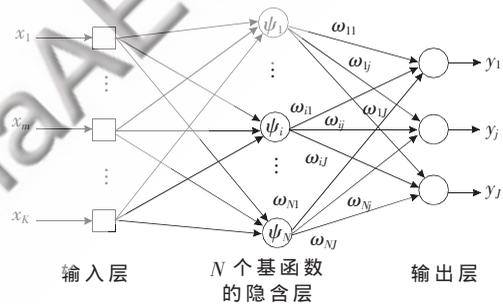


图 2 RBF 网络结构

当网络输入训练样本  $X_k$  时,网络第  $j$  个输出神经元的实际输出为:

$$y_{kj}(X_k) = \sum_{i=1}^N w_{ij} \varphi(X_k, X_i) \quad (1)$$

一般“基函数”选为格林函数,当格林函数为高斯函数时:

$$\varphi(X_k, X) = G(X_k, X_i) = G(\|X_k - X_i\|) = \exp\left\{-\frac{1}{2\sigma_i^2} \sum_{m=1}^M (X_{km} - X_{im})^2\right\} \quad (2)$$

RBF 网络训练过程为:由实验样本确定训练隐含层与输出层间的权值  $w$ ,最终权值为:

$$\omega = \varphi^{-1}y \quad (3)$$

在 RBF 网络训练中,隐含层神经元数量的确定是关键,一般选取与输入向量的元素相等。然而,在输入矢量很多时,过多的隐含层单元数使网络结构复杂化,影响

训练时间。为此提出了改进方法: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  $w$ ,产生一个新的隐含层神经元,然后检查新网络的误差,重复此过程直至达到误差要求或最大隐含神经元数为止。

### 3 实验分析

#### 3.1 RBF 神经网络与 BP 神经网络训练过程

表 1 为某汽车变速箱的齿轮啮合频率样本数据。这些数据都是经过归一化处理后的样本数据,共有 9 个实际样本,3 种故障模式,每个样本有 15 个特征参数<sup>[6]</sup>。应用 Matlab 提供的神经网络工具箱构建 RBF 网络与 BP 网络,并用表 1 学习样本进行训练。因此,可按照如下的方式设计网络,网络的输入层神经元个数为 15,输出层的个数为 3 个。由于齿轮包括 3 种故障模式,因此可以用如下形式表示输出:无故障 (1,0,0);齿根裂纹 (0,1,0);断齿(0,0,1)。

利用函数 `newrb` 创建一个精确的 RBF 神经网络,该函数在创建 RBF 神经网络时,自动选择隐含层的节点数目,使得误差为 0.001。代码为:

```
net=newrb(x,y,0.001,0.9,15,1);
```

其中, $x$  为输入向量, $y$  为目标向量,它们可以从表 1 中得到。径向基函数的扩展速度 `SPREAD`,经不同值的试验确定为 0.9,神经元的最大数目为 15,两次显示之间所添加的神经元数目为 1。由于网络的建立过程就是训练过程,因此得到的网络已经是训练好了的。

根据经验公式估计 BP 网络有 10 个隐层节点,其中隐含层神经元的传递函数为 `tansig`,输出层神经元的传递函数为 `purelin`,选用一种学习效果较好的动量及自适应学习率算法 `traingdm`。两种网络的目标误差设为 0.001,对应各自网络的误差平方和与训练步数的变化曲线如图 3 和图 4 所示。

由图 3、图 4 可知,在达到规定的期望误差平方和的前提下,BP 网络所需的训练步数约 1 847 步,RBF 网络只需 8 步。RBF 网络训练速度快,可以在很短的时间内诊断出故障,完全能够达到实时诊断的要求。

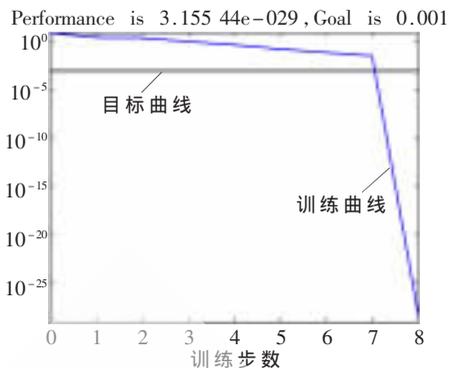


图 3 RBF 网络变化曲线



图 4 BP 网络变化曲线

RBF 网络的误差为:

```
NEWRB,neurons=0,sse=3.617 45
NEWRB,neurons=2,sse=2.755 72
NEWRB,neurons=3,sse=1.223 87
NEWRB,neurons=4,sse=0.537 735
NEWRB,neurons=5,sse=0.179 913
NEWRB,neurons=6,sse=0.092 184 5
NEWRB,neurons=7,sse=0.035 904 2
NEWRB,neurons=8,sse=3.155 44e-029
```

BP 网络的误差为:

```
MSE=9.994 4e-004
```

由误差结果可知:RBF 训练过程中,隐含层的节点个数(neurons)是从 0 开始,中间通过检查输出误差(sse)与目标误差(goal)的偏差值,使建立的网络自动增加神

表 1 齿轮箱样本数据

序号	各种特征样本	齿轮状态
1	0.2286,0.1292,0.0720,0.1592,0.1335,0.0733,0.1159,0.0940,0.0522,0.1345,0.0090,0.1260,0.3619,0.0690,0.1828	无故障
2	0.2090,0.0947,0.1393,0.1387,0.2558,0.0900,0.0771,0.0882,0.0393,0.1430,0.0126,0.1670,0.2450,0.0508,0.1328	无故障
3	0.0442,0.0880,0.1147,0.0563,0.3347,0.1150,0.1453,0.0429,0.1818,0.0378,0.0092,0.2251,0.1516,0.0858,0.0670	无故障
4	0.2603,0.1715,0.0702,0.2711,0.1491,0.1330,0.0968,0.1911,0.2545,0.0871,0.0060,0.1793,0.1002,0.0789,0.0909	齿根裂纹
5	0.3690,0.2222,0.0562,0.5157,0.1872,0.1614,0.1425,0.1506,0.1310,0.0500,0.0078,0.0348,0.0451,0.0707,0.0880	齿根裂纹
6	0.0359,0.1149,0.1230,0.5460,0.1977,0.1248,0.0624,0.0832,0.1640,0.1002,0.0059,0.1503,0.1837,0.1295,0.0700	齿根裂纹
7	0.1759,0.2347,0.1829,0.1811,0.2922,0.0655,0.0774,0.2273,0.2056,0.0925,0.0078,0.1852,0.3501,0.1680,0.2668	断齿
8	0.0724,0.1909,0.1340,0.2409,0.2842,0.0450,0.0824,0.1064,0.1909,0.1586,0.0116,0.1698,0.3644,0.2718,0.2494	断齿
9	0.2634,0.2258,0.1165,0.1154,0.1074,0.0657,0.0610,0.2623,0.2588,0.1155,0.0050,0.0978,0.1511,0.2273,0.3220	断齿

表 2 齿轮箱测试数据

序号	各种特征样本	齿轮状态
1	0.2101, 0.0950, 0.1298, 0.1359, 0.2601, 0.1001, 0.0753, 0.0890, 0.0389, 0.1451, 0.0128, 0.1590, 0.2452, 0.0512, 0.1319	无故障
2	0.2593, 0.1800, 0.0711, 0.2801, 0.1501, 0.1298, 0.1001, 0.1891, 0.2531, 0.0875, 0.0058, 0.1803, 0.0992, 0.0802, 0.1002	齿根裂纹
3	0.2599, 0.2235, 0.1201, 0.1171, 0.1102, 0.0683, 0.0621, 0.2597, 0.2602, 0.1167, 0.0048, 0.1002, 0.1521, 0.2281, 0.3205	断齿

经元个数(建立网络时设定每次只增加 1 个神经元),直到均方误差满足要求为止( $sse=3.155\ 44e-029 < goal=0.001$ )。可见 RBF 网络的建立过程即为网络的训练过程,且网络收敛幅度大,速度快。相比 BP 网络,精度更高。

### 3.2 故障诊断推理

首先验证 RBF 网络的预测性能。代码为:

$$ty = \text{sim}(\text{net}, tx)$$

其中  $tx$  为网络的测试样本。

三层 RBF 神经网络进行故障诊断,采用数据驱动的正向推理策略,从初始状态出发,向前推理,到达目标状态为止。其故障诊断结果如表 2 所示。

抽取表 2 所示的 3 组新数据作为输入数据,对已经训练好的网络进行测试。其测试结果为:

$$ty = \begin{bmatrix} 1.007\ 3 & -0.032\ 4 & -0.008\ 9 \\ -0.004\ 7 & 0.993\ 8 & 0.004\ 7 \\ -0.002\ 6 & 0.038\ 6 & 1.004\ 2 \end{bmatrix}$$

也就是说,将第一组测试数据(无故障)输入网络时,网络输出有  $ty_1=(1.007\ 3, -0.004\ 7, -0.002\ 6)$ ,所以网络诊断的结果为无故障;将第二组测试数据(齿根裂纹)输入网络时,网络的输出有  $ty_2=(-0.032\ 4, 0.993\ 8, 0.038\ 6)$ ,所以网络诊断的结果为齿根裂纹;同样,将第三组测试数据(断齿)输入网络时网络的输出有  $ty_3=(-0.008\ 9, 0.004\ 7, 1.004\ 2)$ ,所以网络诊断的结果为断齿。

BP 网络的测试结果为:

$$ty = \begin{bmatrix} 1.025\ 7 & 0.000\ 3 & 0.115\ 1 \\ -0.041\ 7 & 0.926\ 3 & -0.032\ 4 \\ -0.026\ 7 & -0.097\ 7 & 0.953\ 5 \end{bmatrix}$$

从结果来看,应用 RBF 神经网络对变速箱的齿轮故障进行诊断明显优于应用 BP 神经网络,达到了应用 RBF 神经网络进行故障诊断研究的目的。

仿真试验表明,RBF 神经网络是一种性能良好的非

线性逼近网络,对故障类型的识别十分准确。网络训练过程中,在采用相同的输入节点、输出节点,且在相同期望误差平方和的条件下,RBF 网络的收敛速度明显高于优化的 BP 网络,不仅减少了样本的学习时间和复杂度,而且不容易出现局部极小值。通过对比可知,采用 RBF 网络对变速箱的齿轮进行故障诊断是可行的,并且 RBF 网络比 BP 网络诊断速度快且准确,更适用于进行故障诊断。这种故障诊断方法不仅可用于变速箱齿轮故障诊断,也完全可用于柴油机、大型旋转机组等的故障诊断,因而具有广泛的应用前景。

### 参考文献

- [1] 金鑫,任献彬,周亮.智能故障诊断技术研究综述[J].国外电子测量技术,2009(7):30-32.
- [2] 马杏斋,冯志杰.热工动态过程故障的模糊神经网络诊断方法研究[J].电子测试,2007(5):59-62.
- [3] 宋宏儒,丁常富,冯玉朝.RBF 神经网络在高加故障诊断中的应用[J].东北电力技术,2008(11):15-18.
- [4] HAGAN M T, DEMUTH H B, BEALE M. Neural network design[M]. PWS Publishing Company, 2002.
- [5] 蒋良孝,李超群.基于 BP 神经网络的函数逼近方法及其 MATLAB 实现[J].微型机与应用,2004(1):52-54.
- [6] 袁科新,刘枚.神经网络在故障诊断中的应用[J].山东商业职业技术学院学报,2006(8):97-99.

(收稿日期:2010-03-05)

### 作者简介:

褚衍贺,男,1983 年生,硕士研究生,主要研究方向:新型电力拖动系统及智能控制。

陈洪建,男,1981 年生,硕士研究生,主要研究方向:网络通讯。

商艳兰,女,1983 年生,本科,主要研究方向:自动化技术。