

故障诊断的多层神经网络研究^{*}

王志鹏 孙惠国 时 斌
(郑州工业大学机械系)

摘 要 针对大型旋转机械多测点、多故障、同时性诊断问题,基于人工神经网络及贝叶斯分类规则,构造了一种由多个子网络组成的模块化、分层诊断网络,提高了子网络的分类能力,从而使整个网络有高精度、多故障同时性实时诊断的能力。

关键词 人工神经网络;故障诊断;贝叶斯分类规则;灰关联度;时间序列

中图分类号 TP806.3 TH165.3

0 前言

人工神经网络技术作为一种模式识别方法,其分类精度在很大程度上取决于子网络结构的复杂度、训练样本的精度与数量。对于多测点、多故障源的大型复杂旋转机械而言,设计单一网络来进行诊断必然引起网络结构庞大,训练样本增多,使网络训练难以顺利进行,同时网络强壮性不好,对样本误差较敏感,造成分类精度低,诊断结论不可靠^[1]。为此,现构造一种分层模块神经网络^[2],将大规模的分类模式空间划分为多个子空间,子网络在各自子空间中训练和学习,由上层网络将子网络连接起来进行综合评判,从而提高整个诊断网络的学习效率和分类精度。

1 故障诊断的多层神经网络的整体结构

故障诊断的多层神经网络的整体结构如图 1 所示,低层(Low Level)为预测模块层,顶层(Upper Level)为综合评判决策层。

1.1 预测模块层

为使该故障诊断网络能够实现多测点、多故障、同时性实时诊断,我们建立“测点—故障”对(一个测点与该测点可能发生的众多故障中的一种组成)。该网络的输入为本测点所测取的当前及以前时刻的值,经预测子模块输出,再由贝叶斯决策规则反复递归得出低层输出值。

1.2 综合评判层

该层根据各测点所对应的零部件及故障间的相关性建立起来的,以低层模块的输出作为该层的输入,经网络计算,其输出即为最终诊断结论。

^{*} 河南省计委科技攻关项目(1995.556)

收稿日期:1997—12—31

第一作者 男 1973 年 6 月生 硕士研究生

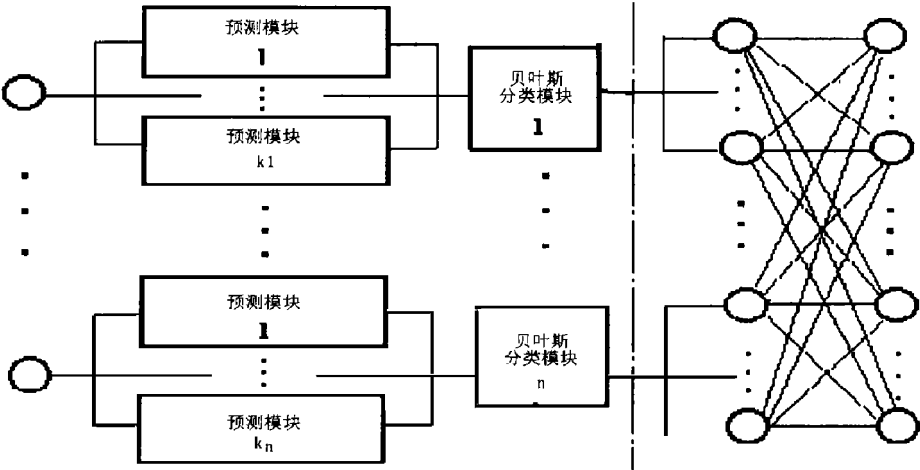


图 1 总体结构

2 底层(Low Level)——预测模块层

2.1 学习算法

预测模块采用 BP 网络,BP 学习算法即误差反向传播算法,特别适合于这类网络的训练,故选用 BP 算法为子模块网络训练学习算法。

2.2 训练样本的建立

训练样本为一时间序列。每个模块都对应一个“测点—故障”对,可以通过实验或由该领域专家给出时间序列数据样本,由此数据样本组成如表 1 所示学习样本(设输入层有 N 个节点)(表中 N 是网络输入层节点数;S 是训练样本数)。

表 1 训练样本集

输出	输入
$x(N+1)$	$x(1), x(2), \dots, x(N)$
$x(N+2)$	$x(2), x(3), \dots, x(N+1)$
\dots	$\dots, \dots, \dots, \dots$
$x(N+S)$	$x(S), x(S+1), \dots, x(N+S+1)$

3 贝叶斯时间序列分类规则及递归算法

故障源 $S(\theta_k)$ 产生一时间序列 $y_t, t=1, 2, \dots$,其中 $\theta_k \in \Theta=\{\theta_1, \theta_2, \dots, \theta_k\}$ 。时间序列分类即找出最佳 θ_k 值。引入变量 $Z \in \Theta, S(Z)$ 表示某故障源。

对机组的诊断在缺少先验知识的情况下,可以对每个模块均取为

$$P_k^0 = \frac{1}{K}, \quad k = 1, 2, \dots, K \tag{1}$$

(C)1994-2023 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

P_t^k 给出了时间序列 y_1, y_2, \dots, y_t 由故障源 $S(\theta_k)$ 产生的置信度。显然应该选取 t 时刻具有最大后验概率的故障源。因此, 分类问题可简化为计算 $P_t^k, k=1, 2, \dots, K; t=1, 2, \dots$ 。该计算由递归过程完成:

$$P_t^k = \frac{\text{Prob}(y_t | y_{t-1}, \dots, y_1, Z = \theta_k) \cdot P_{t-1}^k}{\sum_{j=1}^K \text{Prob}(y_t | y_{t-1}, \dots, y_1, Z = \theta_j) \cdot P_{t-1}^j} \quad k = 1, 2, \dots, K; t = 1, 2, \dots \quad (2)$$

用由故障源 $S(\theta_k)$ 产生的时间序列 y_t 对 ANN 预测模块进行训练, 由前所述可知, ANN 预测器仅仅用有限步的过去值 y_{t-1}, \dots, y_{t-N} 来预测 \hat{y}_t , 因此对于 $k=1, 2, \dots, K; t=1, 2, \dots$, 预测器误差值定义为:

$$e_t^k = y_t^k - \hat{y}_t^k \quad (3)$$

其中: \hat{y}_t^k 为预测值, y_t^k 为实测值。

假定 e_t^k 具有 Gaussian 条件概率分布形式, 则有:

$$\begin{aligned} \text{Prob}(e_t^k | y_1, y_2, \dots, y_{t-1}, Z = \theta_k) &= C(\sigma_k) \exp\left(-\left|\frac{e_t^k}{\sqrt{2\pi\sigma_k}}\right|^2\right) \\ &= \text{Prob}(y_t^k | y_1, y_2, \dots, y_{t-1}, Z = \theta_k) \end{aligned} \quad (4)$$

其中: σ_k 为方差。在 ANN 预测模块中, 可取为在训练阶段计算出的 RMS 误差值。 $C(\sigma_k)$ 是归一化概率值的常数。在本文中取

$$C(\sigma_k) = \frac{1}{\sqrt{2\pi\sigma_k}} \quad (5)$$

式中的假设条件是人为规定的, 但在实际应用中效果很好。

由以上等式可计算出各个时刻每个故障源的后验概率 $P_t^k, k=1, 2, \dots, K; t=1, 2, \dots$ 。选出其中最大值, 即对应的真正的故障源

$$Z_t = \max_j P_t^j, \theta \in \Theta \quad (6)$$

由以上公式来实现贝叶斯递归分类算法^[3]。

4 顶层(Top Level)——综合评判层

4.1 网络权值的设定

综合评判网络结构如图 1 所示。设权值矩阵为 $W=[W_{ij}]$, W_{ij} 表明底层中第 i 个模块所对应的测点处发生相应故障时对第 j 个模块所对应的测点发生相应故障的影响程度的大小(包括同一测点不同故障的情况)。

本文采用灰色理论中的灰关联分析来确定权值矩阵 $W^{[4,5]}$ 。假定待检时间序列 $Y=\{y_1, y_2, \dots, y_K\}$, 标准时间序列 $X=\{x_1, x_2, \dots, x_K\}$, 关联系数定义为:

$$\xi_k = \frac{\min \min |x_k - y_k| + 0.5 \times \max \max |x_k - y_k|}{|x_k - y_k| + 0.5 \times \max \max |x_k - y_k|} \quad (7)$$

关联系数包含的信息过于分散, 对其做进一步处理, 求两序列的关联度。定义如下:

$$r_{xy} = \frac{1}{K} \sum_{k=1}^K \xi_k \quad (8)$$

$r_{xy} \in [0, 1]$, 表明时间序列之间的关联程度。

在实际中,测取训练样本时间序列 x_t^m 的同时,记录下个测点的时间序列 y_t^{mn} ,即在 x_t^m 所代表的故障发生的同时,其它各测点所记录的数据,其中: $m=1,2,\dots,M$ (M 为底层模块个数), $n=1,2,\dots,N$ (N 为测点个数)。由(7)、(8)式分别计算各模块的样本序列 x_t^m 与所在测点所记录的所有序列 y_t^{js} ($j=1,2,\dots,M$; s 为 x_t^m 所在测点)间的关联度 r_{xy}^{mj} ,本文取

$$W_{mj} = \begin{cases} -r_{xy}^{mj} / \sum_{m=1, m \neq j}^M r_{xy}^{mj}, & m \neq j \\ 1, & m = j \end{cases} \quad (9)$$

4.2 诊断结论判定

设底层模块输出为 O_i^L , $i=1,2,\dots,M$; 顶层模块输出为 O_j^U , $j=1,2,\dots,M$ 。

$$O_j^U = \sum_{i=1}^M O_i^L \cdot W_{ij} \quad (10)$$

由(10)式计算出输出层各节点的输出值 O_j^U ($j=1,2,\dots,M$), 设定一门限值 $p > 0.5$, 当 $O_j^U > p$ 时, 即认为所有 O_j^U 对应底层模块 j 所代表的测点发生了相应类型的故障, 即实现了以故障部位及故障类型为诊断出发点、多故障同时性实时诊断的目标。

5 结论

故障诊断的多层神经网络方法较之传统的单一网络诊断方法有很多优点:

- (1) 模块化把分类空间划分为多个子空间, 在提高分类精度的同时, 大大简化了网络的结构, 使网络训练时间大幅度的减少, 训练精度提高。
- (2) 各模块独立训练, 一经训练成功后, 根据机组不同结构可以任意组合, 不需再训练, 仅改变顶层结构即可, 需要的话, 可以建立一个模块库, 故模块通用性强, 复用率高, 诊断系统设计周期短, 成本低。
- (3) 模块化本身就具有并行计算的特性, 特别适合于实时诊断。
- (4) 该诊断方法以故障发生部位及故障类型同时为诊断出发点, 可同时诊断出多种故障。
- (5) 采用了贝叶斯递归分类规则, 对预测模块的误差及数据中的噪声有很好的强壮性。

参考文献

- 1 何永勇, 钟秉林, 黄仁. 基于人工神经网络的旋转机械多故障同时性诊断策略. 东南大学学报. 1996, 26(5): 39~43
- 2 Vassilios Petridis, Athanasios Kehagias, Modular Neural Networks for MAP Classification of Time Series and Partition Algorithm, IEEE TRANS ON NEURAL NETWORKS, 1996, 7(1): 73~85
- 3 ATH. KEHCTIAS, VAS. PETRIDIS, Predictive Modular Neural Networks for Time Series Classification, Neural Networks, 1996, 10(1): 31~49
- 4 孙惠国, 张瑞林. 设备状态检测与故障诊断. 郑州: 河南科学技术出版社, 1993. 5, 241~246
- 5 孙惠国. 灰色与模糊故障诊断原理及其应用. 郑州: 河南科学技术出版社, 1997, 6, 82~96
(下转 29 页)

A Unified Analysis of Shearing Capacity of RC Beams Without Web Reinforcement

Li Guanghui Chen Jie^{*} Liu Lixi

(Zhengzhou University of Technology)

^{*} (Financial and Economical Institute of Henan)

Abstract This paper substitutes nonlinear analysis method of reinforced concrete finite element for traditional experimental method. Mechanical behaviors and failure properties of reinforced concrete beams are analyzed with different reinforcement ratios, span to height ratios, shear span to height ratios and loading forms. Based on this three mechanical models, corresponding failure models, and calculation methods of reinforced concrete beams are proposed. Moreover, by introducing the concept of "equivalent shear span to height ratio", a unified analysis method of shearing capacity of R·C· deep, short and shallow beams under concentrated and evenly distributed loads is proposed. It is compatible with experimental results of short beams, and is in line with the current Chinese design code of concrete structure(GBJ10—89).

Keywords reinforced concrete beams; shearing capacity; nonlinear FEM

(上接 23 页)

Research on Fault—Diagnosing System Based on Multiple—Layer Artificial Neural Networks

Wang Zhipeng Sun Huiguo Shi Bin

(Zhengzhou University of Technology)

Abstract Based on artificial neural networks and Bayesian decision rules, a hierarchical modular diagnosis network is proposed with respect to multiple—detectors multiple—faults simultaneous on—line diagnosis for the large—scale complicated rotary system. The subnetworks have good capability of classification, and the whole network is capable of multiple—faults simultaneous perfect diagnosing.

Keywords artificial neural networks; fault diagnosis; bayesian decision rules; grey correlation; time series