

因子模糊化 BP 神经网络在磨粒识别中的应用

吴振锋¹, 左洪福¹, 刘红星¹, 杨 忠²

(1. 南京航空航天大学 民航学院, 江苏 南京 210016;

2. 南京电力高等专科学校, 江苏 南京 210016)

摘要: 在引入磨粒形态学描述子提取磨损颗粒显微形态特征的基础上, 用人工神经网络技术, 编制了用于磨损颗粒自动识别的 BP 网络计算机模拟程序. 应用所引入的因子模糊化训练法可使训练速度加快. 以异或问题为例, 速度可提高 5~10 倍. 用此网络对磨粒测试库进行识别实验发现, 识别速度快且正确率在 90% 以上, 优于传统的磨粒识别方法.

关键词: BP 神经网络; 因子模糊化; 磨粒识别; 油液监测

中图分类号: TH117.3; Q811

文章标识码: A

文章编号: 1004-0595(2000)02-0143-04

应用铁谱技术对现代大型机械进行状态监测和故障诊断时, 如何准确地对磨损颗粒进行分类识别是解决问题的关键. 传统的铁谱分析技术依靠专家经验来识别磨粒^[1,2], 对操作者要求较高, 效率低且有较大的人为误差. 随着计算机视觉和图像处理技术的发展, 可以应用计算机对磨粒进行图像处理, 根据磨粒的特征参数进行统计分析. 然而统计分析方法也存在缺点, 例如分类精度低, 缺乏自学习性, 应用于不同的机械时需要进行大量的实验以确定不同的统计容许限^[3]. 这些都不利于磨损故障诊断技术的应用与推广. 近年来, 人工神经网络的应用范围越来越广, 解决了很多疑难问题. 我们将其引入铁谱分析领域, 以便更好地解决磨损颗粒的分析与识别这一关键问题.

1 磨损颗粒的形态学描述简介

磨损颗粒是进行磨损故障诊断的主要信息源. 为了对磨粒的各种形态特征进行定量分析, 本文在计算机视觉和图像处理的基础上, 运用形态学分析方法, 综合建立了磨粒的形态学特征参数描述体系, 用于提取磨粒的各种分类特征. 表 1^[3,4] 给出了部分参数的定义及说明. 根据机械零件之间不同的磨损模式可以将磨损颗粒分为正常滑动磨粒、严重滑动磨粒、切削磨粒、疲劳剥块、层状磨粒、球状磨粒及氧化物磨粒等 7 类. 各种磨损模式都有其对应的一些磨损颗粒, 根据各类磨粒数量的多少, 即可判断机械所处的运行状态. 表 1 所列的形态学描述子提取了不同种类磨粒的

形态特征, 可作为诊断依据.

2 BP 神经网络的因子模糊化训练方法

人工神经网络(ANN)模型是在现代神经生理学和心理学研究基础上, 模仿人的大脑结构特征而建立的一种非线性动力学网络系统, 它由大量的简单非线性处理单元(类似于人脑的神经元)高度并联和互联而成, 能够简单地模拟人脑的某些基本功能. 作为 ANN 的一种典型结构形式, 前馈神经网络因其具有良好的分类及联想功能, 已经广泛地应用于工程技术之中. 前馈神经网络具有非常强的学习(训练)功能, 通常采用误差反传训练算法(简称 BP 算法)进行网络训练, 因此又称这种网络为 BP 神经网络. BP 算法的学习过程由正向计算和误差反向传播两部分组成.

取神经元传递函数为 Sigmoid 函数:

$$F_s(x) = 1/[1 + \exp(-x)] \quad (1)$$

定义误差函数:
$$e = \frac{1}{2} \sum_j (t_j - o_j)^2 \quad (2)$$

其中: o_j 为实际输出, t_j 为期望输出. 网络按梯度下降法来修改权重(W_{ji})和阈值(θ):

$$W_{ji} = - \frac{\eta \delta_j}{\partial V_{ji}} \quad (3)$$

设某一层中第 j 个节点在第 p 个样本点时的总输入为 net_j^p , 则:

$$net_j^p = net_j = \sum_i o_i W_{ji} \quad (4)$$

其中: $o_i = F_s(net_i) = 1/[1 + \exp(-net_i)]$

定义误差信号为: $\delta_j = - \frac{\partial e}{\partial net_j}$

经推导得:

$$\delta_j = o_j(1 - o_j)(t_j - o_j) \quad (j \text{ 为输出节点}); \quad (5)$$

$$\delta_j = - F'_s(net_j) \sum_k \delta W_{jk} \quad (j \text{ 为隐层节点}). \quad (6)$$

为了在实际训练过程中加快网络收敛速度,我们

表 1 磨粒形态学参数描述子

Table 1 Morphology Descriptor of Debris

Items	Parameters	Definition
Size	Area A	$A = \iint dx \cdot dy$ or $A = H(0)$.
	Equivalent diameter D	$D = \sqrt{4 \cdot A / \pi}$
	Long axial length a	$a = \left(\frac{4}{\pi} \right)^{1/4} \cdot \frac{I_x^{3/8}}{I_y^{1/8}}$
	Long axial length b	$b = \left(\frac{4}{\pi} \right)^{1/4} \cdot \frac{I_y^{3/8}}{I_x^{1/8}}$
		I_x, I_y are second order momentum.
Shape	Roundness R _d	$R_d = P_\epsilon^2 / 4\pi A$.
	Aspect ratio R _t	$R_t = a/b$
	Concavity C _v	$C_v = L/Z$. Z is the minimum parameter of particle area
Structure	Hole ratio E''	$E'' = n(0)/n(1)$, n(0) is the number of white spots; n(1) is the number of black spots
Gray	Mean G _m , variance G _v	In particle area, calculating in terms of statistic frequency.
Edge	Structure round function expanded at zero H(r)	$H(r) = S(A - B) = H'(0)r + H''(0) \frac{r^2}{2} + \dots$
	Parameter P _ε	$P_\epsilon = H'(0)$.
	Edge turn degree A _n	$A_n = H'' = 2 \sum_{k=1}^n \text{tg} \alpha_k$, $-\frac{\pi}{2} < \alpha_k < \frac{\pi}{2}$.
Fractal	Gray texture F _{gt}	$F_{gt} = 1 - D_{g1}$, D _{g1} is the line of best fit from the plot of log normalised parameter vs log large step length,
	Gray structure F _{gs}	$F_{gs} = 1 - D_{g2}$, log normalised parameter vs log large step length,
	Edge details F _{pt}	$F_{pt} = 1 - D_{p1}$, similar to above,
	Edge structure F _{ps}	$F_{ps} = 1 - D_{p2}$, similar to above

在式(3)中加入动量项^[5,6],可得网络连接权重(W_{ji})的修正式,阈值(θ)的修正式类似

$$W_{ji}(t+1) = W_{ji}(t) + \eta \delta_i + \alpha W_{ji}(t). \quad (7)$$

其中: η为学习因子, α为动量因子.

从以上公式推导可以看到,BP网络实际上是把

一组样本的输入和输出问题转化为一个非线性优化问题,使用了优化中的梯度下降法,这不可避免地导致算法的不完备性,即存在局部极小值.因此,为了加快收敛速度和尽量避免局部极小值的出现,我们引入因子模糊化方法:如果在网络训练的初期利用较大的学习因子,而训练到一定程度时采用较小的学习因子,将有利于加快学习速度;同时,根据训练误差变化速度CE和加速度CCE来改变动量因子和学习因子的大小,使网络在误差较小时进行“晃动”,则有利于逃出局部极小点.其基本原则是:如果CE和CCE均远大于0,说明误差呈增大的趋势,应该减小权值的调整步幅,即减小α和η的值,以防止振荡;如果CE远大于0而CCE远小于0,说明误差的变化趋势趋于平缓,为加快收敛,应该减小惯性项的调节作用,即令α不变而使η变小;如果CE和CCE都稍大于0,说明误差值很小而且变化趋势平缓,为加快收敛,应该增大学习因子,但为了防止振荡,应相应地增大惯性项,即同时增大α和η.

设 $\eta = \eta_0 + \eta_1 \alpha + \alpha_0$, $\alpha = \alpha_0 + \alpha_1 \eta$ 和 α_0 为基准值, η和α变化的实例见表2.

采用上述因子模糊化方法,我们对异或问题进行了网络训练,证明该算法速度提高了5~10倍.

3 BP神经网络在磨粒识别中的应用

实际的磨损颗粒中,某些类别的磨粒特征较为明显,只需要较少参数即可识别出来,而某些类别的磨粒,则需要较多的特征参数作为输入参数才能达到较高的识别率.为此,我们采用双BP识别网络.

双BP网络是构造A和B的BP网络,网络A用于识别特征明显的磨粒,而网络B输入节点较多,可以识别特征不太明显的磨粒.网络A和B之间可以串联或并联.前者将网络B串联于网络A之后,如果网络A可以识别磨粒则直接输出识别结果,否则增加一些参数之后送入网络B继续识别;后者将网络A和B并联,取两网络输入节点的并集为输入参数,将所选参数全部输入网络进行识别.2种连接形式识别率基本相同,只是串联情况下识别速度较快.

应用双BP神经网络进行磨粒分类与识别的具体操作步骤如下:

(1) 首先把磨粒图谱库划分为1个标准库和2个测试库^[5],并对磨粒图像进行图像校正、平滑去噪等预处理工作.

(2) 构造2个BP网络A和B.网络A用于识别特征显著的正常滑动磨粒、切削磨粒、层状磨粒和

表 2 η (左)和 α (右)的模糊取值表

Table 2 Fuzzy value of η (left) and α (right)

CE,CCE	$\gg 0$	> 0	$= 0$	< 0	$\ll 0$	CE,CCE	$\gg 0$	> 0	$= 0$	< 0	$\ll 0$
$\gg 0$	- 0.15	- 0.15	- 0.10	- 0.10	- 0.10	$\gg 0.00$	- 0.20	- 0.10	0.00	0.00	0.00
> 0	- 0.15	- 0.05	0.00	0.00	- 0.10	> 0.00	- 0.10	0.00	0.10	0.00	0.00
$= 0$	- 0.05	0.10	0.15	0.10	- 0.05	$= 0.00$	0.00	0.10	0.20	0.10	0.00
< 0	- 0.15	0	- 0.10	- 0.05	- 0.15	< 0.00	0.00	0.00	0.10	0.00	- 0.10
$\ll 0$	- 0.10	- 0.10	- 0.05	- 0.15	- 0.15	$\ll 0.00$	0.00	0.00	0.00	- 0.10	- 0.20

球状磨粒, 网络 B 负责识别严重滑动磨损产生的磨粒和疲劳剥块

(3) 训练网络 A. 选择网络结构为 17-24-4 其中, 输入节点(神经元)有 17 个, 对应 17 个磨粒特征(如等效椭圆直径、圆形体、细长度、散射度、凹度、形心偏心度、长短轴比、体态比、转折度、孔隙率及 4 个纹理相关系数等); 4 个输出节点对应网络 A 所识别磨粒 然后以标准库中 6 类磨粒(共 295 颗)为学习样本训练网络, 其中, 属于网络 A 所识别磨粒(共 210 颗)对应的期望输出取 0.99; 属于网络 B 所识别的磨粒(共 85 颗)所对应的期望输出取 0.01. 在奔腾 100MHz, 16M 内存微机上用约 4 h, 收敛误差至 0.02

(4) 训练网络 B. 选择网络结构为 28-33-2 其中, 输入节点有 28 个, 对应的磨粒特征有一部分与网络 A 的重合, 另一部分则包括 4 个中心矩、4 个不变矩、2 个分形维数以及与纹理有关的灰度和梯度方面约 20 个参数; 2 个输出节点分别对应网络 B 所识别的磨粒 加入其它纹理参数的目的, 是要将严重滑动磨粒表面常有的划痕同疲劳剥块的腐蚀状麻点分离开来 步骤与(3)类似, 以标准库中 6 类共 295 颗磨粒为学习样本训练网络, 其中属于网络 B 所识别的磨

粒所对应的期望输出取 0.99, 其它类型磨粒的期望输出取 0.01. 经过 5 h, 收敛误差至 0.13

(5) 网络回忆的识别过程 设有 1 个待识别磨粒, 将其送入 A 网络或 B 网络, 所得的输出值必然 < 1.0 , 因此可以将该值视为该磨粒属于对应输出节点所代表的磨粒类别的信度或可能性

对于网络 A 与 B 串联, 首先送入网络 A 识别, 得到 4 个输出值 o_1, \dots, o_4 , 选择阈值 TH (如 0.7), 若 $o_m = \max\{o_1, \dots, o_4\} \geq TH, m \in [1, 4]$, 则磨粒归入第 m 类, 分类结束; 若 $o_m < TH$, 则磨粒可能不属于网络 A 的 4 类而属于网络 B 的 2 类, 因此将该磨粒送入网络 B, 依网络 A 方法, 若 $o_n \geq TH, n \in [1, 2]$, 则磨粒归入第 n 类, 分类结束; 若 $o_n < TH$, 则表明磨粒不可分, 可将 $\max\{o_m, o_n\}$ 返回

对于网络 A 与 B 并联的形式, 将该磨粒同时送入网络 A 和 B 识别, 得到 6 个输出值 o_1, \dots, o_6 , 选择阈值 TH , 如果 $o_m = \max\{o_1, \dots, o_6\} \geq TH$, 而 $m \in [1, 6]$, 则磨粒归入第 m 类; 若 $o_m < TH$, 则表明磨粒不可分, 将 o_m 返回

表 3 所列采用上述双 BP 网络识别法(串联)对测试库 1 和 2 的磨粒分别进行识别的计算实例 从用于训练网络的标准图谱库中挑选出一部分磨粒组

表 3 网络 A 与 B 串联形式的测试库磨粒识别结果

Table 3 Identifying results of the testing set with networks A and B

Type of particles	Testing set 1				Testing set 2			
	Right	Error out	Error in	Undistinguishable	Right	Error out	Error in	Undistinguishable
Mild rubbing	1.00	0.00	0.00	0.00	0.93	0.07	0.03	0.00
Serious rubbing	0.90	0.10	0.10	0.00	0.80	0.15	0.16	0.05
Cutting	0.95	0.05	0.00	0.00	0.90	0.05	0.00	0.05
Spalling	0.90	0.10	0.10	0.00	0.80	0.13	0.20	0.07
Layer-like	1.00	0.00	0.05	0.00	0.93	0.07	0.07	0.00
Ball-like	1.00	0.00	0.00	0.00	0.93	0.07	0.13	0.00

成测试库 1, 以检测网络的训练效果; 而测试库 2 中的磨粒直接来自磨粒图谱库, 其中的磨粒对于网络来说是完全“陌生”的, 这样可以检验网络的泛化能力 从识别结果来看, 测试库 1 的识别率高而且误差很

小, 测试库 2 的识别率虽然略低于测试库 1, 但也在 90% 左右 这一结果比文献[3]有一定的提高, 证明本识别方法有效且特征参数选择合理 另外, 测试库 1 和测试库 2 中的磨粒的来源非常广泛, 它包括在高温

高压下工作的航空发动机、磨损严重的矿山机械和火车机车以及腐蚀严重的船舶柴油机等,这说明本网络基本上可以胜任各种工况条件下工作的大多数机械的油液监测任务。

上述磨粒分类误差的主要来源在于标准库磨粒自身存在误差,分布在图像采集与校正、边缘提取及专家确认等若干方面,还有所获取磨粒的数目不太多;描述磨粒的特征参数的数量、用于网络训练的特征组合的恰当程度以及同种磨粒形态的差异性等。另外BP算法的局部极小、结构的确定及权重和阈值初始值设定等均会影响训练速度并导致误差不能继续减小,从而影响网络的泛化能力。

4 结论

所编制的BP网络模拟程序,可用于磨损颗粒自动识别;应用本文引入的因子模糊化方法进行网络训

练,可大大加快训练速度;以异或问题为例,速度提高5~10倍;应用此网络对磨粒测试库进行识别实验,识别速度很快,识别正确率在90%以上,大大优于传统的磨粒识别方法。

参考文献:

- [1] Anderson D P 著,金元生,杨其明译.磨粒图谱[M].北京:机械工业出版社,1987.
- [2] 董龙珠.液体润滑滑动轴承的铁谱诊断[C].90'中国铁谱技术会议论文集.合肥:合肥工业大学出版社,1990.
- [3] 左洪福.发动机磨损状态监测与故障诊断技术[M].北京:航空工业出版社,1995.
- [4] 徐建华.图像分析与处理[M].北京:科学出版社,1992.
- [5] 杨忠.发动机磨损故障智能诊断技术研究[D].南京:南京航空航天大学机电工程学院,1998.
- [6] 周继成.神经网络[M].北京:科学普及出版社,1993.

Application of Fuzzified-factor Based BP-network in Wear Debris Identification

WU Zhen-feng¹, ZUO Hong-fu¹, LU Hong-xing¹, YANG Zhong²

(1. Department of Mechanical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Nanjing Institute of Electric Power, Nanjing 210008, China)

Abstract: The program of auto-identification of wear particles has been made by means of artificial neural network (ANN) technique, with which a set of morphology descriptors of wear debris are cited to describe the micro-features of wear particles. During training of the network, the fuzzified-factor based training technique is used, and the training process is accelerated rapidly. Taking the exclusive or problem (XOR problem) as an example, the training speed increases by five to ten times. The network has an identifying accuracy higher than 90% and is effective in identifying various wear particles.

Key words: back-propagation neural network; fuzzified-factor; debris identification; lubricating oil inspection