

自组织映射法在机械故障诊断中的应用

黄士涛 孙惠国
(郑州工业大学机械系)

摘 要 自组织映射法是由 T. Kohonen 提出的一种人工神经网络模式,它能把高维的信息数据以有序方式映射到低维的网络上,形成一种拓扑意义上的有序图。由于其有序性,使得信号空间图成为许多输入信息及其关系的群落图。每个图可用灰度深浅不等的方块阴影图表示出来,这种可视的图形表示了机械运行的状态。人们可以非常直观地从图上判断机械运行状态,从而使得机械运行状态的监测和故障诊断更为简便。

关键词 人工神经网络;自组织映射法;故障诊断

中图分类号 TP806.3 TH165.3

0 序言

人们一直在研究各种新的故障诊断技术和方法,来提高故障诊断的正确率,从而防患于未然。自组织映射法是近年来发展起来的一个最新的、十分有效的方法。它把机械的运行状态用一种方块阴影图形式显示出来。从而使得故障诊断变得非常直观。在机械运行状态发生变化时,人们能从运行状态图的变化中,分析出机械运行状态所发生的变化。因此,这是一种非常好的故障诊断方法。

自组织映射法是由 T. Kohonen 提出的一种人工神经网络模式,它能把高维的信息数据以有序方式映射到低维的网络上,形成一种拓扑意义上的有序图。由于其有序性,从而揭示了输入信息中的群落图及其在映射图中的关系,为人们从另一个角度去认识机械运行状态的内在联系提供了方法。自组织映射法可以认为是一个非线性的、有序的、光滑的映射算法,它如同一个有序的译码阵,把输入数据的某一个区域,通过唯一的一个译码器映射到输出层中。在机械运行状态发生变化时,映射的反应是非常灵敏的。因此,它是机械运行状态监测和分析、机械故障诊断的非常好的、有力的工具。

本文首先介绍了自组织映射模型,然后介绍了其计算方法,举例说明了该方法在机械运行状态监测和故障诊断中的应用。最后,指出了该方法在应用故障分析时存在的问题。

1 自组织映射模型

Kohonen 提出的自组织映射模型的网络结构如图 1。该网络由输入层和映射层组成,输

收稿日期 1997-10-14

第一作者 1946 年 5 月生 硕士学位 副教授

入层由 N 个输入神经元组成, 输出层或映射层由 M 个神经元组成, 且形成一个二维平面阵列。输入层各神经元与映射层各神经元之间实现全互连接。有时, 映射层各神经元之间也实现侧抑制连接。这种网络将输入样本映射到输出层上, 形成特征图。它们之间的连接权值是通过无导师竞争学习来实现的, 所以称为自组织特征映射。

在足够的样本数据情况下, 网络通过调整连接权值, 最后使得输出层特征图能够反映样本数据的分布特性。由于映射层的神经元是有序排列的, 因此它可以反映输入信息域中的拓扑关系。

映射层中所显示出的输入信息的族群及其关系, 也正好是反映了输入信息的特征。由于在机械故障诊断时需要特征提取, 所以该方法非常适合于机械的故障诊断。

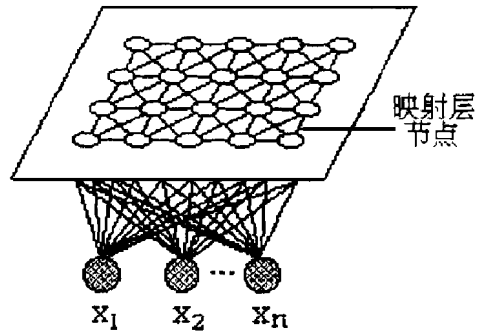


图 1 Kohonen 自组织特征映射网络

2 自组织映射法计算方法

假设有一实数向量集 $x = [\xi_1, \xi_2, \dots, \xi_N]^T \in R^N$, 其中 $\{\xi_i\}$ 为输入变量, 另设一实数向量集 $m_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{iN}]^T \in R^N$, 其元素为输入阵各元素和映射阵各元素间的连接权值, m_i 即为权向量集。定义 x 和 m_i 之间的广义测距为 $d(x, m_i)$, 记

$$c = \arg \min_i \{d(x, m_i)\}$$

则输入向量集 x 在自组织映射阵中的映象可定义为具有阵标记为 c 的映象。现任务是: 确定 m_i , 使得映射是有序的并能描述 x 的分布。

引入平均期望量化误差函数

$$E = \int \sum_i h_{ci} f[d(x, m_i)] p(x) dx$$

其中 $p(x)$ 为 x 的概率密度函数, f 为广义测距 d 的某个单调递增函数。 h_{ci} 为平滑核, 它是阵中节点 c 和 i 之间测距的特殊函数。确定 m_i 有序的值, 使得函数 E 为局部最小。该式的求解是十分困难的, 因此必须进行统计近似, 同时进行离散化, 则误差函数成为

$$E = \sum_i h_{ci} f[d(x(t), m_i(t))]$$

其优化的近似算法为

$$m_i(t+1) = m_i(t) - \frac{1}{2} \lambda(t) \frac{\partial E}{\partial m_i(t)}$$

其中 $\lambda(t)$ 为小的、正的、尺度因子, 它决定了 t 时刻的梯度步长, 其选择应使 $m_i(t)$ 集中于 $\{m_i^*\}$ 值。如果令广义测距为欧几里德距离, 即 $d(x, m_i) = \|x - m_i\|$, 并令 $f(d) = d^2$ 则有

$$m_i(t+1) = m_i(t) + h_{ci}(t)[x(t) - m_i(t)]$$

在此 $h_{ci}(t)$ 已把 $\lambda(t)$ 结合在内。可简单而有效地定义 $h_{ci}(t) = \alpha(t)$, 且令其当节点 i 在指定的某个小邻域 $N_c(t)$ 内为小的正值, 否则为零。 $N_c(t)$ 为阵中以节点 c 为中心的某半径小

邻域。

因此,自组织映射法计算方程为

$$\begin{aligned} m_i(t+1) &= m_i(t) + \alpha(t)[x(t) - m_i(t)] && \text{如果 } i \in N_c(t) \\ m_i(t+1) &= m_i(t) && \text{如果 } i \notin N_c(t) \end{aligned}$$

其学习时的计算步骤如下:

- (1) 设置所有权向量集 $m_i(t)$ 的初始值,它可以是小的随机数。
- (2) 选择 $\alpha(t)$ 和 $N_c(t)$ 随时间变化的形式,设置 $\alpha(t)$ 和 $N_c(t)$ 的初始值。
- (3) 计算输入 x 与所有权向量集 m_i 之间的距离。

$$d_j = [\sum_i (x_i - m_i)^2]^{1/2} \quad j = 1, 2, \dots, n$$

- (4) 选择最小距离的节点 i^* 作为获胜节点:

$$d^* = \min_j \{d_j\}$$

- (5) 根据上述计算方程,计算节点 i^* 及其邻域 $N_c(t)$ 内的所有 $m_i(t)$ 的值,调整权向量集。

- (6) 重复从(3)的步骤,直至输入数据结束。

- (7) 更新 $\alpha(t)$ 和 $N_c(t)$ 的值,重复从(3)的步骤,直至规定的次数,或邻域 $N_c(t)$ 已收缩至一点并获胜节点不再变更。

权向量集 $m_i(t)$ 的初始值设置时,一般选择其分量 $\{ \mu_{ij} \}$ 有相同的初始值,以减少输入 x 在初始时刻对权向量集 $m_i(t)$ 依赖,加快 $m_i(t)$ 与 x 间方向的修正。

$\alpha(t)$ 和 $N_c(t)$ 是随时间递减的函数,具体应用时应精心选择。其应满足 $0 < \alpha(t) < 1.0$ 及 $N_c(t)$ 为正整数。设置 $\alpha(t)$ 和 $N_c(t)$ 的初始值,一般取 $\alpha(t) > 0.5$ 及 $N_c(0)$ 为小于 10 的正整数。邻域 $N_c(t)$ 可以按正方形进行收缩。如设获胜的节点为 i^* ,先求出其在自组织映射阵中相应坐标位置 X_i ,则其正方形邻域 $N_c(t) = (X_i - N_0, X_i + N_0)$, N_0 为某确定的区域值,该值的大小随时间递减的,如图 2 所示。

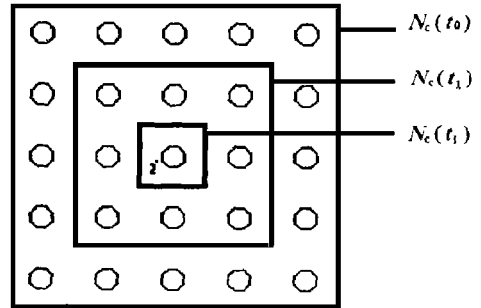


图2 按正方形收缩的 $N_c(t)$

进行上述方法计算时,对于输入向量集 x 必须进行标准化,即使得输入变量的每个 $\{ \xi_i \}$ 有零均值和有相等的方差。由于两个向量之间的距离主要取决于两个向量的方向,而与它们的模数大小无关。因此,计算时将权向量集 m_i 作规一化处理,以后的权值大小的比较也是以规范值进行。规一化的方法为:

$$m_i = \frac{m_i}{\|m_i\|} \quad j = 1, 2, \dots, n$$

3 实例

为更好、更集中地反映机械运行状态,首先对机械振动信号的采样数据进行 FFT 分

析,得到各频率的谱值。选用该频谱值中的若干个低频振幅和若干个高频振幅,作为输入向量集 x 的元素。显然,这些量完全可以反映机械运行状态,并在机械运行状态发生变化后,会发生不同程度的变化。

实际的机械运行状态的监测是这样进行的:利用足够长的采样数据,采用上述的计算方法,算出权向量集 $m_i = [\mu_{i1}, \mu_{i2}, \dots, \mu_{in}]^T$ 。根据权值的大小,画出灰度深浅不等的方块阴影图。将采样数据中每次获胜节点的小方块特别给予标出,从而形成一个轨迹图。在以后的监测过程中,如果机械运行状态基本保持不变的话,那么以后画出的轨迹图与其十分相似,反之,如果机械运行状态发生了变化了,或者发生了故障,则画出的轨迹图将会发生变化,它将超出原有的范围。从而可以非常直观地从图上判断机械运行状态,即所谓的状态的可视性,使诊断更为简便。图 3 用方块阴影图显示了某机器量测值的自组织映射算法的权值,白线表示了获胜点的轨迹。

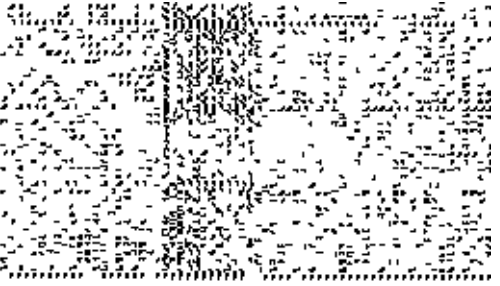


图 3 方块阴影图

4 故障的分析与自组织映射法存在的问题

自组织映射法反映了输入信息中各个成分间复杂的分布关系,并且能灵敏地反映分布关系的变化。利用方块阴影图又可使机械运行状态具有可视性,使得诊断更为简便。但是,如何从这些可视阴影图中分析出机械运行状态是否正常,以及如果状态异常,如何分析出故障的性质和类型将十分困难。这需要在监测机械运行状态时,首先确保机械是在正常状态下运行,从而得到正常状态下的权值、量化误差值及方块阴影图。在而后的运行中,如果机械运行异常,则由于其量化误差值、权值增大,使得方块阴影图中表示获胜点的白色轨迹向外扩张。因此可以从量化误差值的增大并超过预定的阀门值,和方块阴影图的向外扩张来判断机械运行状态是否正常。

要分析出故障的性质和类型,则只能先作出很多反映该故障的方块阴影图,即很多详细的故障图集,然后再把得到的异常的方块阴影图与这些所谓的标准故障图相比较,从而得到故障的性质和类型。如果能通过计算机模拟得到这些标准故障图,当然是最为理想的。

这些也正是自组织映射法用于机械故障的分析和诊断时存在的问题。但是,自组织映射法能较为灵敏地反映机械的故障,并以可视的方式出现,使得故障的分析和诊断十分直观。同时,该方法不需要建立复杂过程模型,就能揭示输入信息中各个成分间复杂的分布关系。它是一种统计方法,它还说明了存在于输入信息各个变量之间的、其它方法难以认识的非线性逻辑关系特性。因此,自组织映射法在机械故障的分析和诊断方面有着其独特的优越性。

参 考 文 献

- 1 T. Kohonen, E. Oja. Engineering Applications of the Self-Organizing Map. Proceeding of the IEEE, Vol. 84, No. 10, 1996, 1358~1379
- 2 王伟. 人工神经网络原理. 北京: 航空航天大学出版社, 1995, 77~110
- 3 黄德双. 神经网络模式识别系统理论. 北京: 电子工业出版社, 1996, 234~253

Application of the Self-Organizing Map to Fault Diagnosis of Machinery

Huang Shitao Sun Huiguo

(Zhengzhou University of Technology)

Abstract The self-organizing map is an artificial neural networks model and algorithm that implements a characteristic nonlinear projection from the high-dimensional space of signal data into a low-dimensional array of neurons in an orderly fashion, which is made by T. Kohonen. The mapping tends to preserve the topological relationships of signal domains. Owing to the order, the image of the signal space tends to manifest clusters of input information and their relationship on the map. The map can be shown by square shades of gray, so it makes machinery operating conditions be visualized. The map will vary with changes of machinery operating conditions, which helps us to detect and identify the faults.

Keywords artificial neural networks; self-organizing map; fault diagnosis