

DOI:10.19651/j.cnki.emt.1802258

干扰条件下基于改进 SOM 故障诊断研究

孙 扩¹ 刘 兴²

(1.海军航空大学研究生管理大队 烟台 264001; 2.91306 部队 上海 200436)

摘要: 针对机载电子设备在噪声干扰条件下故障诊断效果不佳的问题,基于自组织特征映射网络(SOM),提出了改进的 SOM 的网络算法,该算法在标准 SOM 网络的基础上引入了滤波算法进行初级降噪处理,然后进行阈值学习,重新定义了邻域函数和学习率,最后以故障评价指标为基准进行故障的隔离定位。在高斯白噪声条件下以某型飞机前端接收机的故障数据为例建立诊断模型。通过聚类和网络训练等仿真测试实验得到了故障模式的分类和隔离。同时通过与其他方法的性能比较验证了 SOM 神经网络在高斯白噪声干扰条件下故障诊断中的有效性、准确性和鲁棒性。

关键词: SOM; 故障诊断; 噪声干扰; 推理机

中图分类号: TN98 文献标识码: A 国家标准学科分类代码: 510.99

Research on fault diagnosis based on improved SOM under interference conditions

Sun Kuo¹ Liu Xing²

(1. Graduate Student Bridge, Naval Aeronautical University, Yantai 264001, China;

2. Unit 91306 of PLA, Shanghai 200436, China)

Abstract: Aiming at the problem of poor fault diagnosis of airborne electronic equipment under noise interference conditions, an improved self-organizing feature mapping (SOM) network algorithm is proposed based on SOM network. Based on the standard SOM network, the algorithm introduces the filtering algorithm for primary noise reduction, then performs threshold learning, redefines the neighborhood function and learning rate, and finally uses the fault evaluation index as the benchmark to isolate the fault. Under the condition of Gaussian white noise, the fault data of the front-end receiver of a certain aircraft is taken as an example to establish a diagnostic model. The classification and isolation of fault modes are obtained through simulation tests such as clustering and network training. At the same time, the effectiveness, accuracy and robustness of SOM neural network in fault diagnosis under Gaussian white noise interference conditions are verified by comparison with other methods.

Keywords: SOM; fault diagnosis; noise interference; inference engine

0 引言

机载电子设备通常是指装备在飞机上,用于测量、处理、传递、显示和控制各种信息、指令和操纵的电子设备。对于军用飞机而言,机载电子设备主要包括雷达、通信导航、显控、电子战、仪表、电气和飞行控制等专业系统^[1]。机载电子设备故障诊断技术是通过对测取的机载电子设备在运行中或相对静止条件下的状态信息进行分析和处理,并结合诊断对象的历史状况,来定量识别机械设备及其零部件的实时技术状态,并预测异常故障的未来技术状态,从而确定必要对策的一种技术^[2]。目前,广泛用于故障诊断的

包括前馈神经网络、随机神经网络、反馈神经网络和自组织神经网络等模型。

自组织特征映射网络(self-organizing map, SOM)也称 Kohonen 网络,它是由荷兰学者 Kohonen 于 1981 年提出的,基本上为输入层和映射层的双层结构,输入层用于接收输入模式,映射层用于输出结果,映射层的神经元互相连接,每个输出神经元连接至所有输入神经元^[3]。神经网络用于故障诊断是通过故障实例的训练和学习,用分布在神经网路中的连接权值来表达所学习的故障诊断知识,具有对故障的联想记忆、模式匹配和相似归纳的能力,可以实现故障和征兆间的复杂非线性映射关系。机载设备的故障诊

断有很多传统的方法,文献[4]提出用遗传反向传播网络对机载雷达进行故障诊断;文献[5]提出径向基函数神经网络在汽轮机的故障诊断应用;文献[6]提出前向反馈传播人工神经网络对电力电子电路进行参数性故障诊断。上述方法仅在一般条件下的故障诊断研究,而在部队装备实际使用中面对着各种复杂的环境,尤其是各类噪声信号的干扰,而且经常会出现故障诊断的模式未知的情况。所以本文提出一种在噪声干扰下的改进 SOM 模型,以某型飞机前端接收机为研究对象,以提高故障诊断方法鲁棒性为预期要求,保证在干扰状态下的改进 SOM 模型,同时保证在干扰状态下有较高的故障检测率和准确率。

1 噪声干扰条件

在真实军事作战的环境中,机载电子设备面对着各种各样的干扰,最常见的就是噪声干扰。设备带宽范围内和远小于系统带宽的信号干扰就可被视为是窄带干扰。最基本的窄带噪声干扰是高斯白噪声干扰。

高斯白噪声,这里的“高斯”是指概率分布为正态分布,“白噪声”指的是其二阶不相关,一阶矩为常数,即先后信号在时间上的相关性^[7]。它是考察信号各个方面的问题。高斯白噪声仿真波形如图 1、2 所示。

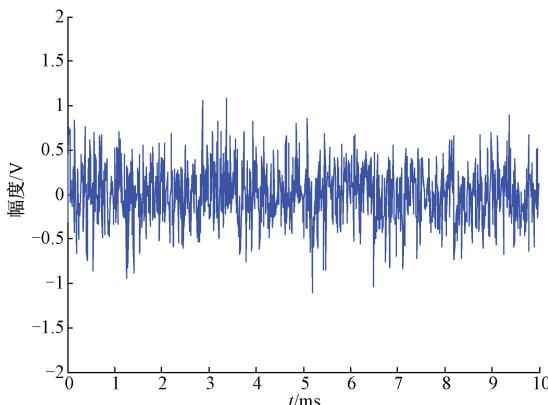


图 1 高斯白噪声干扰时域波形仿真

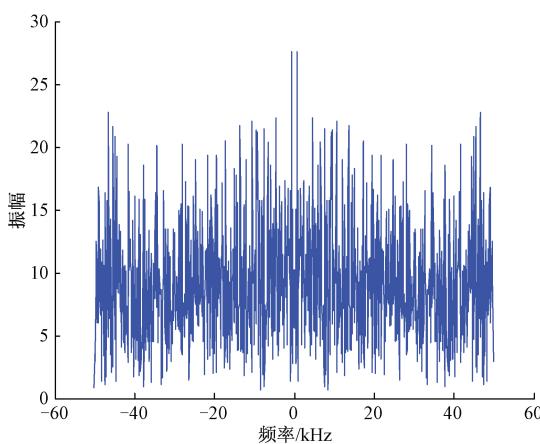


图 2 高斯白噪声干扰频域波形仿真

高斯白噪声的幅度和功率谱分别符合高斯分布以及均匀分布,热噪声和散粒噪声都是高斯白噪声。

2 算法改进

SOM 是典型的自组织神经网络^[8],能够在无需人工操作的情况下完成输入模式的聚类,其在自组织、自适应方面表现十分突出^[9]。文献[10]通过 SOM 来识别汽轮机的故障;文献[11]指出,自组织神经网络能够被用来诊断汽轮发电机组的不同故障,然而,设备发生多种故障,并不代表所有故障均为相似的,而且如果其中含有标准故障,该方法并不适用,尤其是充满噪声干扰的军事环境下。为此提出改进的 SOM 算法用于高斯白噪声干扰条件下的故障诊断,首先采用 SOM 网络进行聚类,对网络进行粗调学习,然后根据聚类后得到的网络权值确定各故障模式对应属性的经典域,通过邻域值更新神经元的方法进行细调学习。

2.1 标准 SOM 网络

SOM 网络由输入层、输出层构成,输出层包括了网络拓扑结构。输出层采用二维拓扑结构的 SOM 网络,如图 3 所示。

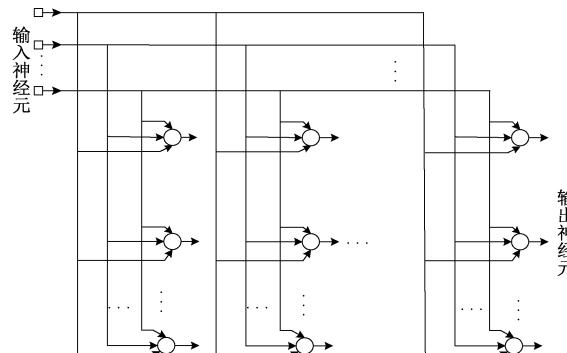


图 3 SOM 网络结构

SOM 网络的工作过程包括两个环节。训练环节,网络随机的接收训练集里面的样本,在具体的输入模式下,输出层中有一个节点会形成最大响应并因此而获胜,但在训练的起初,输出层哪个位置的节点会对具体的输入模式出现最大响应,这一点是未知的。如果调整输入模式,平面中的获胜节点一并变化。获胜节点附近的节点,会因此而受到影响,所以这些节点的权向量都会朝着输入方向发生改变,改变力度和附近节点成为对特定模式类具有敏感性的神经元,对应的内星权向量就会变成输入模式的中心向量。在两个模式类的特征比较相似的情况下,两类节点的距离更近。如此一来,输出层就会产生可以揭示出样本模式分布情况的有序特征图^[12-13]。

SOM 网络的学习流程如下:

1) 初始化:对输出层各权向量赋小随机数然后予以归一化处理,获取 W_j ($j = 1, 2, \dots, m$), 据此创建初始优胜邻

域 $N_j(t)$ 和学习率 η 初值。 m 代表输出层神经元数目。

2) 寻找获胜节点:通过随机的方式,从训练集里面选择输入模式,予以归一化处理,获取的结果为 $(p = 1, 2, \dots, n)$, n 代表输入层神经元的多少。通过计算得到 X^p 与 W_j 的点积,按照点积从大到小的顺序排序,排名第一位的对应的即为获胜节点 j 。

3) 定义优胜邻域 $N_j(t)$: 以 j 为中心确定 t 时刻的权值调整域,通常情况下初始邻域 $N_j(0)$ 较大,随着时间的推移, $N_j(t)$ 不断的收缩。优化优胜域 $N_j(t)$ 中全部节点的权值。

4) 结束判定:一旦学习率 $\eta(t) \leq \eta_{\min}$, 训练完成;若不符合要求,重新从步骤 2)开始。

2.2 SM 学习算法改进

在 SOM 网络中,输入层的神经元利用权向量和任意输出神经元之间侧抑制。在标准 SOM 基础上对算法进行了改进:1)在步骤 2)中加入滤波算法,得到降噪处理后的输出;2)在步骤 3)引入阈值学习机制,对输出神经元的阈值进行变换;3)步骤 4)中采用更新的权值公式,重新定义了 η 的含义。设定了不同距离条件下邻域函数和学习速率的选取。SOM 网络聚类的具体执行流程是:

1) 初始化

设训练样本集为 $\{S_1, S_2, \dots, S_{N_s}\}$, 其所包含的 S_k 拥有 n 个属性 c_1, c_2, \dots, c_n 和输入神经元存在对应关系, 样本 S_k 的属性值向量为 $[v_{1k}, v_{2k}, \dots, v_{nk}]$ 。样本属性值的标准化公式为:

$$v'_{ik} = \frac{v_{ik} - \min_{k=1,2,\dots,N_s} v_{ik}}{\max_{k=1,2,\dots,N_s} v_{ik} - \min_{k=1,2,\dots,N_s} v_{ik}} \quad (1)$$

其中, v_{ik} 和 v'_{ik} 分别表示样本 S_k 属性 c_i 标准化前后的取值, $k = 1, 2, \dots, N_s$, $i = 1, 2, \dots, n$ 。通过随机值对 SOM 网络的权值矩阵进行初始化处理 $W = (w_{it})_{n \times m}$, w_{ij} 代表输入神经元 in_i 和输出神经元 out_t 的权值。

2) 确定获胜神经元

样本 S_k 对应输出层任意神经元 out_t , $t = 1, 2, \dots, m$ 的输出 $y_{tk} = \sum_{i=1}^n w_{it} v_{ik}$, 然后应用一阶滤波原理, 得到输出 $y'_{tk} = a v_{ik} + (1 - a) y_{tk}$, 考虑滤波平稳性与灵敏度的平衡, 取 $a = 0.01$ 。根据输出最大化的最优匹配准则, 样本 S_k 对应的获胜神经元为 out_p , 且 $y_{pk} = \max_{t=1,2,\dots,m} y'_{tk}$ 。

3) 阈值学习

随机初始化权值会导致神经元“饿死”,要防止这一现象的发生,引入了阈值学习机制,获胜概率较高的神经元,只有在得到更高输出的情况下,才能够获胜。而当输出较小时,“饿死”的神经元有更高的概率获胜。通过计算确定神经元获胜次数以及训练样本数量的比,据此分析神经元获胜的可能性,此即为输出神经元 out_t 的阈值 $\gamma_t = f\left(\frac{N_t}{N_k}\right)$, 这里面 N_t 代表输出神经元 out_t 的获胜次数, N_k

表示样本个数。

4) 权值更新输出神经元

按照如下公式,更新获胜神经元领域中的所有输出神经元的权值:

$$w'_{it} = w_{it} + \eta(v_{ik} - w_{it}) \quad (2)$$

其中, $\eta = a \cdot b$, a 代表 SOM 网络的学习速率, b 代表获胜神经元的邻域函数,且:

$$b = \begin{cases} 1, & t = p \\ 0.5, & t \neq p \text{ 且 } t \in N_p(d) \\ 0, & t \notin N_p(d) \end{cases} \quad (3)$$

式中: $t = 1, 2, \dots, m$; $N_p(d)$ 代表从所有距离获胜神经元小于 d 的输出神经元构成的邻域。

权值的更新包括了两个步骤:(1)排序环节,学习率从 a_1 降低到 a_2 , 领域的大小从 $N_p(d)$ 降低到 $N_p(1)$, 持续优化权向量,令输出层能够揭示出输入样本的分布情况;(2)收敛环节,学习率从 a_2 开始进一步变小,领域则是恒定的,通过这种方式优化网络结构,提高分布的均匀性。

5) 终止条件

反复进行步骤 2)~4), 直到迭代次数达到 $item = N_{item}$, 算法停止。

由 SOM 的聚类步骤可知,对样本的聚类过程是对输入与输出神经元之间权值矩阵 W 调整过程,得到的某一输出神经元 out_t 对应所有输入神经元 in_1, in_2, \dots, in_n 的权值向量为 $[w_{1t}, w_{2t}, \dots, w_{nt}]$, 其实质是所有输出为该神经元的样本聚类中心。所以当聚类结束后,每个输出神经元所代表的样本集的聚类中心被确定,进而每种故障模式的聚类中心也可以被确定。当故障 F_j 对应唯一的输出神经元 out_t 时,故障模式 F_j 的聚类中心 $Z_j = [u_{1j}, u_{2j}, \dots, u_{nj}]$ 即为该输出神经元与输入神经元之间的权值,即 $u_{ij} = w_{it}$, $i = 1, 2, \dots, n$; 当故障模式 F_j 对应多个输出神经元时,则故障模式 F_j 的聚类中心 $Z_j = [u_{1j}, u_{2j}, \dots, u_{nj}]$ 即为这些输出神经元和输入神经元之间权值的平均值,即 $u_{ij} = \sum_{out_i \in O_j} \frac{w_{it}}{|O_j|}$, $i = 1, 2, \dots, n$, 其中 $|O_j|$ 表示故障模式 F_j 对应的输出神经元的个数。

对于任意待诊断样本 S_k , 其属性值向量为 $[x_1, x_2, \dots, x_{nk}]$, 那么它关于故障模式 F_j 的评价指标是

$$K_j(S_k) = \sum_{i=1}^n \lambda_i k_{ij}(S_k) \quad (4)$$

式中: λ_i 代表属性 c_i 的权重,如果不存在先验知识,则有 $\lambda_i = \frac{1}{n}$, $k_{ij}(S_k)$ 代表待诊断样本 S_k 属性 c_i 关于故障模式 F_j 的关联函数。

在存在评价指标 $k_{ij}(S_k) \geq 0$, $j = 1, 2, \dots, m_2$ 的情况下,表示待诊断样本 S_k 的故障模式是 F_j 。针对任何故障模式 F_j , $j = 1, 2, \dots, m_2$ 都有 $k_{ij}(S_k) \leq 0$, 此时无法判断样本 S_k 的故障模式,原因是训练样本没有展示出全部的故

障模式,在这种情况下,诊断结果即为评价指标较大的故障模式。也就是有:

$$\max_{j=1,2,\dots,m} K_j(S_k) - K_j(S_k) < \delta \quad (5)$$

则待诊断样本 S_k 的故障模式为 F_j ,一般取 $\delta = 0.01$ 。

3 应用案例

某型前端接收机是某型飞机电子对抗系统的外场可更

换单元(LRU),组成如图 4 所示。其主要任务是对工作频段范围内的信号进行放大和过滤,并检波成含有威胁信息的视频信号,提供给信息处理器进行信息处理,同时为中央接收机和低功率射频单元提供射频信号,以及对威胁雷达信号提供频段信息。根据功能将前端接收机的故障模式划分为 3 种, F_1 对应放大单元故障, F_2 对应微波单元 1 故障, F_3 对应微波单元 2 故障。

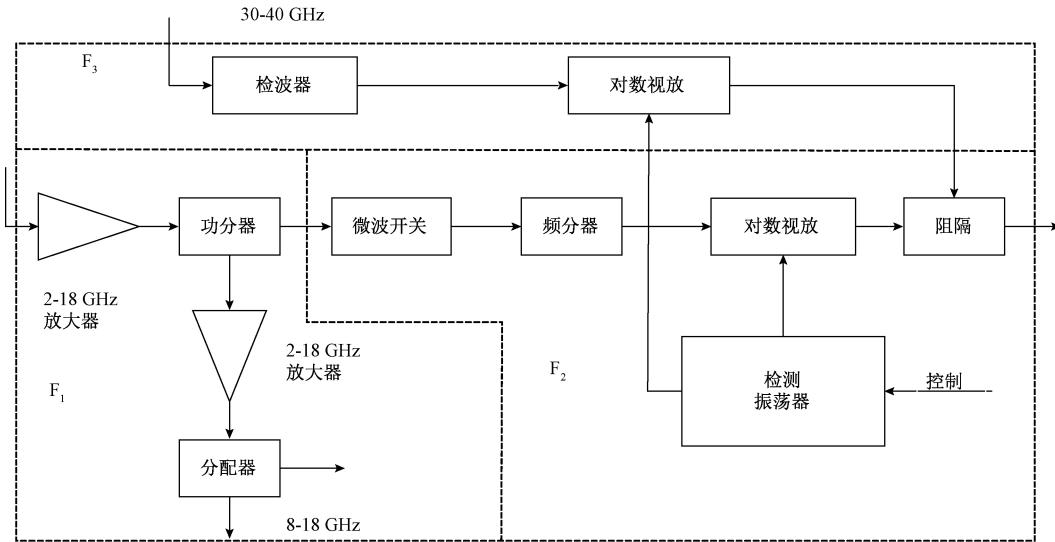


图 4 前端接收机组成

给接收机模块引入高斯白噪声干扰信号,采用改进算法进行 LRU 级故障诊断,自动测试系统对前端接收机进行测试时主要有 7 个性能指标,包括 3 个频点的灵敏度、动态范围,以及 1 项射频增益。其中 C_1, C_2, C_3 表示 3 个频点的灵敏度, C_4, C_5, C_6 代表这 3 个频点的动态范围, C_7 代表射频增益。整

个测试过程中共选取 15 组故障数据,序号 1~9 共 9 组故障数据用于网络训练,分别对应 3 种故障模式,其中 1~3 组对应故障 F_1 ;4~6 组对应故障 F_2 ;7~9 组对应故障 F_3 ;另外序号 10~15 共 6 组用于故障诊断测试,其中每种故障模式对应的 2 组测试样本。前端接收机测试数据如表 1 所示。

表 1 某型前端接收机部分测试数据

分组	C_1	C_2	C_3	C_4	C_5	C_6	C_7	故障
1	0.108	0.280	0.106	0.698	0.641	0.627	0.357	F_1
2	0.073	0.344	0.104	0.899	0.544	0.050	0.238	F_1
3	0.315	0.008	0.303	0.936	0.363	0.803	0.253	F_1
4	0.893	0.077	0.224	0.694	0.788	0.173	0.827	F_2
5	0.798	0.279	0.560	0.871	0.546	0.283	0.704	F_2
6	0.875	0.603	0.158	0.821	0.349	0.953	0.687	F_2
7	0.515	0.505	0.854	0.303	0.221	0.445	0.439	F_3
8	0.671	0.029	0.557	0.328	0.744	0.664	0.403	F_3
9	0.045	0.227	0.719	0.243	0.484	0.198	0.847	F_3
10	0.350	0.076	0.102	0.199	0.195	0.157	0.344	F_1
11	0.192	0.160	0.835	0.750	0.498	0.119	0.084	F_1
12	0.507	0.537	0.613	0.906	0.951	0.730	0.438	F_2
13	0.615	0.453	0.285	0.948	0.752	0.211	0.883	F_2
14	0.847	0.241	0.729	0.041	0.235	0.101	0.285	F_3
15	0.556	0.093	0.965	0.424	0.165	0.053	0.027	F_3

为说明改进 SOM 网络模型在高斯白噪声条件下对机载电子设备故障诊断的作用,以表 1 中某型飞机前端接收机的测试数据为例,前 9 组用于训练改进的 SOM 网络,接着就是聚类环节。后 6 组作为故障诊断的依据。参数分析结果显示,参数分析结果表明,输出神经元数量超过训练样本数量,因此将 12 个输出神经元设定为 3 行 4 列,学习率 $a_1 = 0.9, a_2 = 0.02$, 获胜神经元的初始邻域为 $N_p(2)$, 设置迭代次数为 500, 利用 MATLAB 训练后获取 9 组训练样本在输出层的聚类结果,如图 5 所示。

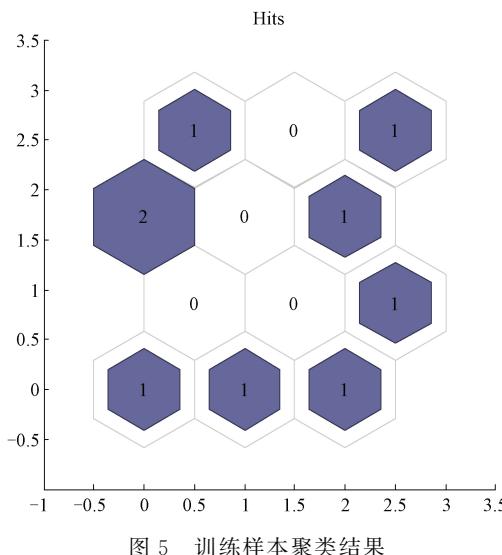


图 5 训练样本聚类结果

图 5 中,以左下角神经元为起点,按从左到右、从下到上依次为 1~12 号输出神经元。标有深色数字的神经元是在聚类过程中产生的获胜神经元,每个获胜神经元上标注的数字代表对应聚类样本的数量,如 1 号输出神经元标注的数字是 1,则表示 1 号神经元是 1 组训练样本的获胜神经元。相同获胜神经元对应的训练样本属于同一种故障模式,权重距离较近的不同获胜神经元也可能属于同一种故障模式。利用 MATLAB 得到输出层相邻神经元之间的权重距离如图 6 所示。

根据图 5 和 6 最终确定 3 个故障模式,每种故障模式包含 3 组故障样本,第 1、2 和 3 号输出神经元表示故障模式 F_1 ; 第 6、9 和 12 号输出神经元表示故障模式 F_2 ; 7 和 10 号输出神经元表示故障模式 F_3 。聚类结果与表 1 中已知情况基本一致,并且 F_1 对应放大单元故障, F_2 对应微波单元 1 故障, F_3 对应微波单元 2 故障, 各类故障模式聚类中心,如表 2 所示。

将表 1 中噪声干扰条件下的测试数据应用到 BP 算法和标准的 SOM 网络中,利用 MATLAB 进行故障诊断仿真计算。仅从结果上看,文献[14]BP 算法、文献[15]标准 SOM 和本文改进的 SOM 算法都能实现对机载电子设备的故障诊断,但由于 3 种算法采用的诊断方式不同,对 3 种诊断算法的比较如表 3 所示。

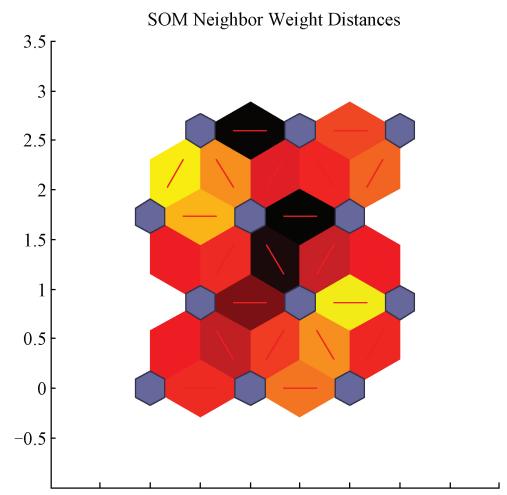


图 6 SOM 相邻权重距离

表 2 各类故障聚类中心

属性	F_1	F_2	F_3
C_1	0.734	0.544	0.122
C_2	0.223	0.261	0.312
C_3	0.499	0.265	0.429
C_4	0.546	0.830	0.553
C_5	0.588	0.479	0.493
C_6	0.459	0.667	0.227
C_7	0.590	0.505	0.506

表 3 三种诊断算法的比较

诊断方法	学习	训练	测试	诊断
	类型	时间/s	时间/s	正确率/%
BP 算法	有导师	3.7	1.7	90
标准 SOM	无导师	3.1	1.3	95
改进 SOM	无导师	2.3	1.1	97

由表 3 可知,在干扰噪声条件下对某型飞机前端接收机进行故障诊断,BP 算法、标准 SOM、改进的 SOM 方法的训练时间与测试时间状况分别为高、低、较高低。在相同的迭代次数下,改进的 SOM 方法下的训练耗时是最短的。虽然在高斯白噪声条件下诊断正确率都不同程度受到影响,但总体上改进的 SOM 诊断方法相比较另外两种方法准确率最高,抗干扰能力最强,表现出良好的鲁棒性。

4 结 论

提出改进的 SOM 网络模型,高斯白噪声条件下的机载电子设备进行故障诊断,要求诊断方法能表现出一定的抗干扰诊断特性和稳定性。通过对诊断方法的训练时间、故障诊断正确率等指标的分析,以及与其他两种常见方法

诊断结果的比较表明,改进的 SOM 算法对复杂干扰环境下故障模式的处理能力更强,稳定性更高。采用改进的 SOM 对某型飞机前端接收机进行故障诊断,结果说明该方法适用于训练样本故障模未知的多故障诊断,与其他方法相比在干扰噪声条件下有较好的故障诊断效果。

参考文献

- [1] 朱大齐.航空电子设备故障诊断技术研究[D].南京:南京航空航天大学,2002.
- [2] 秦继容.现代直流伺服控制技术及其系统设计[M].北京:机械工业出版社,2002.
- [3] 张德丰.MATLAB 神经网络应用设计[M].北京:机械工业出版社,2009.
- [4] 翟旭平,孟田,杨兵兵.基于 SOM-SVM 频谱感知算法[J].电子测量技术,2016,39(10):76-80.
- [5] WU L, SUN R P, CHENG J H. Application of RBF neural network in fault diagnosis of FOG SINS[C]. International Conference on Control, Automation and Systems, 2012, 42(18):69-75.
- [6] 吴祎,王友仁,陈好,等.基于 BPNN 的电力电子参数性故障诊断方法[J].电子测量与仪器学报,2012,26(5):458-462.
- [7] 冯小平,李鹏,杨绍全.通信对抗原理[M].西安:西安电子科技大学出版社,2009.
- [8] 唐朝京.现代通信原理[M].北京:电子工业出版社,2010:210-265.
- [9] 徐明远,邵玉斌.MATLAB 仿真在通信与电子工程中的应用[M].西安:西安电子科技大学出版社,2010:50-112.
- [10] KOHONEN T. Essentials of the self-organizing map [J]. Neural Networks, 2013(37):52-65.
- [11] 张彼德.汽轮发电机组振动多故障诊断模型及方法研究[D].重庆:重庆大学,2002:36-38.
- [12] 尤丽静,陈在平.基于自组织神经网络的轴流分机不对中故障诊断研究[J].天津理工大学学报,2010,26(1):99-102.
- [13] WANG J S, LI S X, GAO J. SOM neural network fault diagnosis method of polymerization kettle equipment optimized by improved PSO algorithm[J]. Scientific World Journal, 2014, DOI: 10.1155/2014/937680.
- [14] 肖治平,吴全文,曾洋.遗传 BP 网络在机载雷达故障诊断中的应用研究[J].计算机测量与控制,2011,19(1):14-16.
- [15] 张彼德,欧健,孙才新,等.汽轮发电机多故障诊断的 SOM 神经网络方法[J].重庆大学学报(自然科学版),2005, 28(2): 36-38.

作者简介

孙扩,硕士研究生,主要研究方向为电子装备测试与诊断技术。
E-mail:1419725378@qq.com