

基于改进LLE的Elman神经网络电路故障诊断

郭 斌, 齐金鹏

(东华大学 信息学院, 上海 201620)

摘要: 如今的电路越来越复杂,随之而来的就是电路系统的高故障性,所以如何定位故障发生成为一大难题。文中基于提高故障诊断性能的目的,先采用一种改进的局部线性分析算法作为初始数据处理器对输出响应序列进行降维,提取故障特征向量,然后再通过OIF-Elman神经网络搭建故障分类器,对电路进行故障检测。仿真结果表明,将改进过的局部线性分析算法和OIF-Elman神经网络应用到故障诊断中,不仅具有比传统BP神经网络更精确的故障诊断正确率,且整个网络的收敛速度也会有明显提升。

关键词: 定位故障;改进的局部线性分析;降维;OIF-Elman神经网络

中图分类号: TP183

文献标识码: A

文章编号: 1673-629X(2014)03-0194-04

doi: 10.3969/j.issn.1673-629X.2014.03.048

Research on OIF-Elman Neural Network Circuit Fault Diagnosis Based on Improved LLE

GUO Bin, QI Jin-peng

(College of Information and Technique, Donghua University, Shanghai 201620, China)

Abstract: The circuit is more and more complex and followed by a circuit system failure, so how to locate the fault occurs is a major problem. For improving the performance of fault diagnosis, use an improved locally linear embedding analysis method as the initial data (raw data) processor for output response sequence to reduce the dimension and extract fault feature vector, and then through the OIF-Elman neural network to build fault classifier for fault detection circuit. Simulation results show that the fault diagnosis method is made of improved LLE and OIF-Elman neural network is not only to have the better diagnosis rate compared with the BP neural network, but also greatly enhance convergence speed for the whole network.

Key words: fault locating; improved locally linear embedding analysis; dimension reduction; OIF-Elman neural network

0 引言

近年来,随着大规模模拟集成电路的迅速发展,模拟电路的复杂度不断增长,对模拟电路的可靠性要求更为严格^[1]。所以,在模拟电路发生故障后,要求能及时将故障诊断出来,以便检修、调试、替换^[2-3]。而模拟电路诊断由于其自身的属性,如输入输出均是连续量,故障模型难以构造,元器件存在容差,大量的非线性及反馈的存在,使其故障诊断技术的发展依然十分缓慢,尤其是针对模拟电路的参数偏移等问题,软故障诊断尚缺乏有效的解决方法。在众多故障诊断的方法中,神经网络因其具有非线性映射、学习推理等优点,非常适合解决故障诊断这类模式识别与分类问题,在

模拟电路故障诊断中已获得较成功的应用^[4-8]。

电路发生故障时,必然表现出与之对应的故障征兆(症状),如电压、电流信号曲线发生变化,这些征兆是故障信息的重要组成部分,蕴含着大量的故障分类信息。为全面地反映电路真实运行状态,将从不同角度观测到的故障征兆记录下来,构成对应故障模式的故障特征,再将故障样本(作为输入向量)作为神经网络的训练数据,得到输入(故障特征向量)与输出(故障判断)的映射关系。但这存在两个明显的不足:对于没有先验知识的故障诊断过程而言,并不知道需要采集故障样本的数量,样本数据容易造成冗余,影响故障分类的效果;此外就是神经网络自身的不足,比如容

收稿日期: 2013-05-26

修回日期: 2013-08-28

网络出版时间: 2014-01-07

基金项目: 国家自然科学基金资助项目(61104154); 中央高校基本科研业务费专项资金

作者简介: 郭 斌(1987-),男,上海人,硕士研究生,研究方向为故障诊断; 齐金鹏,副教授,硕士研究生导师,研究方向为生物数据挖掘与智能算法、系统生物学与生物信息学。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20140107.1647.026.html>

易陷入局部最优、训练时间长等^[9]。

针对这两个问题,文中从减少大数据冗余度和改善神经网络性能入手,采用一种改进的 LLE 和 OIF-Elman 神经网络相结合的方式故障诊断。LLE 算法对比现在比较常用的线性降维方法(如主元分析法等)而言更有优势,它不仅能够解决非线性特征提取问题,还能比常用的 PCA 提供更多的特征数目和特征向量,能最大限度地抽取指标信息;而 Elman 神经网络是一种反馈型神经网络,它比常用的前向神经网络有更好的全局稳定性。该模型在前馈网络的隐含层中增加一个承接层,从而使系统具有适应时变特性的能力,能直接反映动态过程系统的特性^[10]。

1 LLE 算法

局部线性嵌入(Linear Local Embed, LLE)算法是 Roweis 和 Lawrance 提出的一种非线性降维方法,该算法的核心思想是在样本点与其被选定的一些邻域点之间重构一个权向量,并在映射空间中保持映射点(map unit)之间的权值不变。即假设嵌入映射在局部是线性的条件下,使得重构误差最小化。LLE 的降维方法不仅仅提供了减少数据冗余的功能,在某种意义上也是一种新的特征提取方式。该算法既有处理非线性数据的优点,又有线性降维方法计算性能的优越性。

LLE 方法采用由 N 个 D 维向量组成的矩阵 $M_{D \times N}$ 作为输入,输出则是一个由 N 个 d 维向量($d \ll N$)组成的矩阵 $Y_{d \times N}$ 。矩阵 Y 的第 k 列对应的是矩阵 X 中的第 k 列。算法步骤可总结如下:

1) 对于数据输入空间中的每个样本点 X_i ($i = 1, 2, \dots, N$), 计算它和其他 $N - 1$ 个样本点之间的距离, 根据欧氏距离的大小, 找到与 X_i 最近的 K 个点作为其近邻点, 即:

$$d_{ij} = \|X_i - X_j\| \quad (1)$$

2) 计算每个点 X_i ($i = 1, 2, \dots, N$) 与它的近邻点之间的权重 w_{ij} , 即最小化:

$$\varepsilon(W) = \sum_{i=1}^N \|X_i - \sum_{j=1}^N w_{ij} X_j\|^2 \quad (2)$$

其中, $w_{ij} = 0$, 如果 X_j 不是 X_i 的近邻; 且 $\sum_{j=1}^N w_{ij} = 1$ (为了保持平移不变性)。

3) 根据高维输入空间中的样本 X_i 和它的近邻 X_j 之间的权重 w_{ij} 来计算低维嵌入空间中的值。由于目标是在低维映射空间中尽量保持高维输入空间中的局部线性结构, 因此将权重 w_{ij} 固定, 而使下面的损失函数最小化:

$$\varphi(Y) = \sum_{i=1}^N \|Y_i - \sum_{j=1}^N w_{ij} Y_j\|^2 \text{tr}(Y^T M Y) \quad (3)$$

其中, $\sum_{i=1}^N Y_i = 0$, 且 $\frac{1}{N} \sum_{i=1}^N Y_i Y_i^T = I; M = (I - W)^T(I - W)$ 。使(2)式最小化的解为由矩阵 M 的最小的几个特征值所对应的特征向量构成的矩阵。取 M 的最小的 $d + 1$ 个特征值对应的特征向量(去除 0 特征值对应的向量)组成的矩阵即为得到的低维映射空间中的样本。

2 改进的 LLE 算法

在使用 LLE 算法进行数据特征提取过程中发现近邻个数 K 的值对最后结果影响较大^[11], 并且 LLE 算法假设原始样本在流行上的分布比较均匀和连续。但对于多维样本的大数据集, 在很多情况下, 数据并不呈现出连续分布的规律。即对于一个随机采样的样本群, 根据样本分布的区域进行划分, 总能划分出样本密集区和稀疏区。因此, 根据式(1)可以看出, 稀疏区 K 个样本点构成的局部邻域显然比密集区 K 个样本点构成的局部邻域要大得多。所以, 对于分布不均匀的样本集而言, 近邻点数 K 的取值对 LLE 算法结果(数据降维)的影响就更为明显了。因此, 文中对 LLE 做了一点改进, 使得整个算法对 K 不是非常敏感。

文中引入了另外一种非线性降维方法中定义距离的方法^[12], 即: 将式(1)中的距离 d_{ij} 重新定义为:

$$d_{ij} = \frac{\|X_i - X_j\|}{\sqrt{M(i)M(j)}} \quad (4)$$

其中, $M(i)M(j)$ 分别表示 X_i 到 K 个近邻间距离的平均值和 X_j 到 K 个近邻间距离的平均值。该距离使得处于密集区的样本间的局部邻域增大, 而使得处于稀疏区的样本间的局部邻域缩小, 相当于归一化处理过程, 从而降低 K 的取值对数据降维效果的影响。

3 OIF-Elman 神经网络

Elman 神经网络属于经典的局部递归内时延反馈型网络, 该网络以 BP 神经网络为基础, 并通过引入反馈信号来存储内部状态, 使得 Elman 神经网络具有映射系统动态变化的能力^[10]。对于一般 Elman 神经网络而言, 只包含隐层节点的反馈, 并没有考虑输出层节点的反馈。由于各层神经元的反馈信息都会影响网络的信号处理能力, OIF-Elman 网络增加了输出层节点的反馈, 使其具有了输出-输入反馈机制。

文中引入 OIF-Elman 神经网络^[13] 作为故障分类器, 用于改进 Elman 神经网络学习稳定性差、精度不高的缺点, 其网络结构如图 1。

OIF-Elman 神经网络增加了输出节点的反馈, 称之为 context2 nodes(联系单元 2), 并将其置于第 1 层, 与输入单元和联系单元 1 一起作为隐层节点的输入。

其中 $\gamma(0 \leq \gamma \leq 1)$ 为网络的自连接反馈增益因子, 权值为 $w^{(4)}$, OIF-Elman 神经网络的数学模型为:




图 1 OIF-Elman 神经网络模型

$$x(k) = f(w^{(1)}x_c(k) + w^{(2)}u(k-1) + w^{(4)}y_c(k)) \quad (5)$$

$$x(k) = f(w^{(1)}x_c(k) + w^{(2)}u(k-1) + w^{(4)}y_c(k)) \quad (6)$$

$$x_c(k) = ax_c(k-1) + x(k-1) \quad (7)$$

$$y_c(k) = y(k-1) + \gamma y_c(k-1) \quad (8)$$

$$y(k) = g(w^{(3)}x(k)) \quad (9)$$

其中, $w^{(1)}$ 为联系单元与隐层单元之间的权值矩阵; $w^{(2)}$ 为输入单元与隐层单元之间的权值矩阵; $w^{(3)}$ 为隐层单元与输出单元之间的权值矩阵; $w^{(4)}$ 为联系单元 2 与隐层单元之间的权值矩阵; $x_c(k)$ 、 $x(k)$ 分别表示联系单元 1 和隐层单元的输出; $y_c(k)$ 、 $y(k)$ 分别表示联系单元 2 和输出单元的输出; f 为 sigmod 函数。OIF-Elman 网络的训练算法和 Elman 网络的训练算法^[10]基本一致, 采用梯度下降法。下面给出权值 $w^{(4)}$ 的误差和迭代式:

$$\Delta w_{js}^{(4)} = \eta_4 \sum_{i=1}^m (\delta_i^0 w_{ij}^{(3)} \frac{\partial x_j(k-1)}{\partial w_{js}^{(4)}}), j=1, 2, \dots, n; \quad s=1, 2, \dots, m \quad (10)$$

$$\frac{\partial x_j(k)}{\partial w_{js}^{(4)}} = f_j(\cdot) y_s(k-1) + \gamma \frac{\partial x_j(k-1)}{\partial w_{js}^{(4)}}, j=1, 2, \dots, n; s=1, 2, \dots, m \quad (11)$$

4 电路故障诊断实例

4.1 诊断流程

整个故障诊断的步骤可总结如下:

1) 采样仿真电路图 2 的输出节点 (V_o) 的电压矢量, 作为原始故障数据, 并设立电路的故障模式, 将这些模式进行编码, 作为神经网络的输出。

2) 运用 LLE 算法, 从原始的故障序列中提取出特

征矢量, 作为神经网络的输入向量。

3) 训练神经网络。

4) 用测试样本验证网络效果。

4.2 故障编码和原始故障数据获取




图 2 二阶滤波待测电路

文中选用如图 2 所示的二阶滤波电路作为待测电路, 电路元件和标称参数如图 2, 电阻和电容的容差范围分别取 5% 和 10%, 故障矢量获得方法选择多频测试法。多频测试是用不同频率 (测试频率点集) 的正弦信号激励待测电路, 在某一元件故障下, 获得电路输出 (V_o) 一系列电压序列, 根据故障电路与正常电路之间的输出电压序列差异, 实现模拟电路的故障诊断。

一般交流频率的选择是通过反复实验得到, 这就很容易造成数据的冗余。文中选择 7 个频率作为激励源, 分别是 100、3k、10k、20k、30k、100k、300k。故障为原件偏离标准值 50%, 分别为正常状态、C1 偏大 50%、C1 偏小 50%、C2 偏大 50%、C2 偏小 50%、R1 偏大 50%、R1 偏小 50%、R2 偏大 50%、R2 偏小 50%、R3 偏大 50%、R3 偏小 50%、R4 偏大 50%、R4 偏小 50%、R5 偏大 50%、R5 偏小 50%、R6 偏大 50%、R6 偏小 50%、R7 偏大 50%、R7 偏小 50%, 共 19 种 (包括正常) 故障。将这 19 种故障进行编码, 作为后面神经网络的输出值, 这样最终就能实现输入 (故障电压矢量) 和输出 (故障编码) 的映射, 实现故障诊断的目的。故障编码见表 1。

对每个故障分别进行 25 次蒙特卡洛分析, 得到 $25 \times 19 = 475$ 个 7 维样本, 其中 285 个样本作为神经网络的训练样本, 剩余 190 个作为测试样本。其中一组训练样本部分数据见表 2。

4.3 故障诊断

文中采用上述经改良的 LLE 算法对原始数据样本进行数据降维, 提取待测电路的故障特征向量。其

表1 故障编码表

故障	故障编码(神经网络输出)
正常 50%	100000000000000000
C1 偏大 50%	010000000000000000
C1 偏小 50%	001000000000000000
C2 偏小 50%	000100000000000000
C2 偏大 50%	000010000000000000
R1 偏大 50%	000001000000000000
R1 偏小 50%	000000100000000000
R2 偏大 50%	000000010000000000
R2 偏小 50%	000000001000000000
R3 偏大 50%	000000000100000000
R3 偏小 50%	000000000010000000
R4 偏大 50%	000000000001000000
R4 偏小 50%	000000000000100000
R5 偏大 50%	000000000000010000
R5 偏小 50%	000000000000001000
R6 偏大 50%	000000000000000100
R6 偏小 50%	000000000000000010
R7 偏大 50%	000000000000000010
R7 偏小 50%	000000000000000001

表2 训练样本集

故障	3 kHz	10 kHz	20 kHz	30 kHz	100 kHz	300 kHz
	输出电 压/V	输出电 压/V	输出电 压/V	输出电 压/V	输出电 压/V	输出电 压/V
正常	3.52	2.398 2	1.778	1.033 2	0.335 6	0.132 4
R1 大	2.62	1.690 3	1.239	0.560	0.190 3	0.087 1
R1 小	3.93	3.194 4	2.195	1.590 6	0.535 2	0.233 3
R2 大	3.58	2.229 6	1.325	0.985 2	0.284 9	0.125 6
R2 小	2.80	2.007 9	1.432	0.907 9	0.281 3	0.116 6
R3 大	2.85	1.990 3	1.302	0.808 2	0.258 8	0.108 4
R3 小	3.27	2.164 3	1.772	0.875 2	0.302 5	0.121 3
R4 大	3.15	2.166 5	1.467	0.862 6	0.269 8	0.111 3
R4 小	2.99	1.946 5	1.564	0.758 8	0.259 9	0.113 4
R5 大	2.75	1.832 2	1.289	0.768 9	0.256 6	0.101
R5 小	3.35	2.058 9	1.335	0.893 9	0.285 0	0.135 5
R6 大	2.89	1.755 5	1.265	0.751 5	0.235 2	0.084 4
R6 小	3.18	2.160 5	1.442	0.846 3	0.110 1	0.078 4
R7 大	2.99	1.857 7	1.854	0.813 2	0.25	0.132 2
R7 小	2.66	1.852 3	1.538	0.805 5	0.260 2	0.106 1
C1 大	2.93	1.538 5	0.838	0.573 0	0.183 1	0.082 5
C1 小	3.34	2.855 0	2.080	1.525 7	0.525 3	0.233 3
C2 大	3.17	2.061 9	1.222	0.845 9	0.269 8	0.112 2
C2 小	3.14	2.061 9	1.216	0.843	0.269 9	0.120 3

中 LLE 中 $K=10$, $D=4$, 将 7 维的故障电压矢量降低到 4 维作为 OIF-Elman 神经网络的输入向量, 故障编码值作为神经网络的输出值。BP 神经网络和 OIF-Elman 神经网络的训练曲线如图 3 和图 4。

通过对图 3 和图 4 的对比, 可得到如下的结果:

(1)降低输入向量的维数(电压矢量)使得神经网络

的收敛速度更快, BP 神经网络在训练 500 步时, 均方误差为 0.06 左右, 而 OIF-Elman 神经网络在 20 步时就能达到 0.1 左右的误差, 可见减少冗余数据, 神经网络的收敛速度将大大提高, LLE 的效果非常明显。

(2)OIF-Elman 神经网络直接引入了输出反馈连接, 使得稳定性比传统 BP 神经网络更好, 图中 Elman 神经网络在训练至 140 步时的均方误差为 0.004, 而 BP 神经网络训练至 500 步时的均方误差为 0.06。可见, 这种带输出反馈的 Elman 神经网络性能大大优于 BP 神经网络。

最后将剩余的 190 个测试样本作为数据输入, 利用 OIF-Elman 神经网络进行故障分类, 分类准确率除 C1 过小和 C2 过大这两种故障外都在 90% 以上, C1 过小的故障诊断率为 60%, C2 过大的准确率为 50%。

测试结果表明, C1 小和 C2 大的故障诊断效果不是很理想, 平均诊断正确率只有 55%。此外, 通过对电路的仔细分析, 发现 C1 偏小 50% 和 C2 偏大 50% 的故障特征比较接近。为了能够对这两种故障进行有效识别, 文中将 C2 容值改为 0.1 μF 的方法对其重新进行故障诊断, 最后误判消除。




图3 BP神经网络误差曲线图




图4 OIF-Elman神经网络误差曲线图

(下转第 201 页)

4 结束语

在无线传感网络中采用微型电池供电所以能量是有限的。这一限制在很大程度上缩短了传感器的使用寿命进而使得无线传感网络的稳定性受到了很大的影响。在实际的环境中,噪声是无处不在的,贝叶斯模型就是一种典型解决有噪情况下的框架模型。这就是文中把压缩感知技术和贝叶斯模型结合起来的最原始的出发点。通过大量的仿真求证反馈系数是为了自动地控制网络系统,以满足在允许误差范围内利用最少的测量数据获取精确的重构信号,降低数据的采集传输成本,延长传感器的使用寿命,保证无线传感网络的稳定性,为未来无线传感网络性能的优化提供一种有效的方法。

参考文献:

[1] Donoho D. Compressed sensing[J]. IEEE trans on information theory,2006,52(4):4036-4048.

[2] Tropp J A, Gilbert A C. Signal recovery from random measurements via orthogonal matching pursuit[J]. IEEE trans on information theory,2007,53(12):4655-4666.

[3] 邓乃扬,田英杰. 数据挖掘中的新方法-支持向量机[M]. 北京:科学出版社,2004.

(上接第197页)

5 结束语

文中将LLE算法和OIF-Elman神经网络结合起来,提出了一种新的滤波电路故障诊断模型,并对该模型的具体实现给出了详细的说明与论证,最后利用所提出的故障诊断模型对二阶滤波电路进行分类。对仿真结果进行标记与分析,表明了文中所提出的故障诊断模型具有理想的电路故障诊断准确率,其收敛速度和稳定性对于传统的BP神经网络具有明显的优势。

参考文献:

[1] 刘新东. 基于LLE和SVM的模拟电路软故障诊断[C]//系统仿真技术及其应用学术会议论文集. 出版地不详:出版者不详,2010.

[2] 李云红,孟凡斌,谭阳红,等. 基于量子神经网络的容差模拟电路的软故障诊断[J]. 计算机测量与控制,2009,17(8):1463-1467.

[3] 孙永奎,陈光[祺],李辉. 模糊聚类与SVM诊断模拟电路单软故障的方法[J]. 计算机辅助设计与图形学学报,2008,20(5):612-617.

[4] 刘安,刘春生. 基于RBF神经网络的非线性系统故障诊断[J]. 计算机仿真,2007(2):141-144.

[4] Vapnik V N. 统计学习理论[M]. 许建华,张学工,译. 北京:电子工业出版社,2004.

[5] Vapink V N. 统计学习理论的本质[M]. 张学工,译. 北京:清华大学出版社,2000.

[6] 薛建儒,郑南宁,郑朝晖,等. 基于自适应高斯混合体模型的相控阵雷达TWS跟踪技术[J]. 电子学报,2003,31(3):433-436.

[7] Babacan S D, Molina R, Katsaggelos A K. Bayesian compressive sensing using Laplace priors[J]. IEEE trans on image processing,2010,19(1):53-63.

[8] Tipping M. Sparse Bayesian learning and the relevance vector machine[J]. Journal of machine learning research,2001,1(1):211-244.

[9] Figueiredo M, Nowak R, Wrih S J. Gradient projection for sparse reconstruction: Application to compressed sensing and other inverse problems[J]. IEEE transaction on selected topics in signal processing,2007,1(4):586-597.

[10] 王平波,蔡志明,刘旺锁. 混合高斯概率密度模型参数的期望最大化估计[J]. 声学技术,2007,26(3):498-502.

[11] 岳佳,王士同. 高斯混合模型聚类中EM算法及初始化的研究[J]. 微计算机信息,2006,22(11-3):244-246.

[12] Seeger M W, Nickisch H. Compressed sensing and Bayesian experimental design[C]//Proc of ICML. [s.l.]:[s.n.],2008:912-919.

[5] 张义忠,冯振声. 基于神经网络的复杂电子装备故障诊断系统的仿真研究[J]. 计算机仿真,2000,17(4):39-42.

[6] 祝世虎,董朝阳,张金鹏,等. 基于神经网络与专家系统的智能决策支持系统[J]. 光电与控制,2006,13(1):8-11.

[7] 吴进华,沈剑,段育红,等. 数模混合电路故障诊断的方法研究[J]. 海军航空工程学院学报,2008,23(3):297-301.

[8] 祝文姬,何怡刚. 容差模拟电路软故障诊断的神经网络方法[J]. 电工技术学报,2009,24(11):184-191.

[9] 高洪深,陶有德. BP神经网络模型的改进[J]. 系统工程理论与实践,1996(1):67-71.

[10] 陈龙,张可,罗配明. 改进的Elman神经网络在WSNs距离预测中的应用[J]. 传感器与微系统,2013,32(1):149-152.

[11] 郑杰. 一种改进的LLE方法[J]. 湖南理工学院学报(自然科学版),2007,20(3):30-32.

[12] Vin de Silva, Joshua B. Global versus local methods in nonlinear dimensionality reduction[C]//Proc of NIPS. [s.l.]:[s.n.],2002:705-712.

[13] Shi X H, Liang Y C, Lee H P, et al. Improved Elman networks and applications for controlling ultrasonic motors[J]. Applied artificial intelligence,2004,18:603-609.

基于改进LLE的Elman神经网络电路故障诊断

作者：[郭斌](#)，[齐金鹏](#)，[GUO Bin](#)，[QI Jin-peng](#)
作者单位：[东华大学 信息学院, 上海, 201620](#)
刊名：[计算机技术与发展](#)

ISTIC

英文刊名：[Computer Technology and Development](#)

年，卷(期)：2014(3)

本文链接：http://d.g.wanfangdata.com.cn/Periodical_wjfz201403048.aspx