DOI: 10.3901/JME.2021.01.157

针对不连续时变样本空间的连续学习故障诊断方法*

李 栋¹ 刘树林² 孙 欣²

(1. 常州大学石油工程学院 常州 213164;
2. 上海大学机电工程与自动化学院 上海 200072)

摘要: 智能故障诊断方法是保障机械设备安全可靠运行的重要手段,然而,现有智能故障诊断方法多属于批量学习模式,缺乏连续学习能力,无法高效地处理不连续时变样本空间的故障诊断问题。在生物免疫系统利用记忆细胞快速识别二次入侵抗原,以及记忆细胞随入侵抗原进化而进化等智能机理的启发下,提出一种针对不连续时变样本空间的具有连续学习能力的故障诊断方法,当样本空间与时间无关时,其退化为一般的监督学习故障诊断方法。在诊断过程中通过对样本的不断学习,持续更新记忆细胞,利用亲和力阈值识别未参与训练以及发生间断后再次出现的故障样本。通过 20 个标准数据集的仿真分析了当其退化为一般的监督学习故障诊断方法时的性能;利用西安交通大学的 XJTU-SY 滚动轴承加速寿命试验数据集分析了其处理不连续时变样本空间故障诊断问题时的性能。试验结果表明与经典故障诊断方法相比,此故障诊断方法对时不变样本空间的故障诊断问题具有良好的故障诊断性能,对于不连续时变样本空间的故障诊断问题具有更好的故障诊断性能。

关键词: 时变样本; 连续学习; 故障诊断; 生物免疫机理; 人工免疫算法; 滚动轴承

中图分类号: TP306

A Continual Learning Fault Diagnosis Method for Discontinuous Time-varying Sample Space

LI Dong¹ LIU Shulin² SUN Xin²

(1. School of Petroleum Engineering, Changzhou University, Changzhou 213164;
2. School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200072)

Abstract: Intelligent fault diagnosis methods play an important role in ensuring the equipment safely and reliably operating. However, they cannot effectively classify the discontinuous time-varying sample space, for most of them belong to batch learning and lack continual learning ability. A continual learning fault diagnosis method for discontinuous time-varying sample space based on the artificial immune system, CLFDMDTVS, is proposed. It is inspired by the intelligent mechanism that memory cells of the biological immune system can recognize previous invaders when they attack again very fast and more efficiently, and these memory cells can evolve with the evolution of previous invaders. CLFDMDTVS will degenerate into a common supervised learning fault diagnosis method when all data independent of time. Memory cells were continuously updated by learning testing data during the fault diagnosis stage, the samples which are not used to train and the reappeared samples which are discontinuous can be diagnosed by affinity threshold. To assess the performance and possible advantages of CLFDMDTVS, the experiments on 20 well-known datasets from the UCI repository and XJTU-SY rolling element bearing accelerated life test datasets were performed. Results show that CLFDMDTVS has better fault diagnosis performance for time-invariant data, and outperforms the other methods for the problems with discontinuous time-varying sample space.

Key words: time-varying sample; continual learning; fault diagnosis; biological immune mechanism; artificial immune algorithm; rolling element bearing

0 前言

随着现代化机械设备大型化、高速化、复杂化

及自动化的发展,智能故障诊断方法成为保障机械设备安全可靠运行的重要手段^[1-2]。神经网络^[3-4]、支持向量机^[5-6]、 K 近邻^[7-8]以及深度学习^[9]等方法在机械设备故障诊断领域得到了广泛的应用,取得了丰硕的研究成果。然而,这些方法多属于批量学习模式,即假设在训练之前所有类型的数据都已经得

* 国家自然科学基金资助项目(51575331)。20191128 收到初稿,20200731 收到修改稿

到,学习结束之后则不再学习新的知识,除非重新训练。然而,在实际生产中,由于故障数据可遇不可求,如往复压缩机的活塞杆断裂与曲轴断裂故障,导致无法一次性得到所有类型的故障数据,从而使这些方法难以识别未参与训练的故障类型。此外,对于滚动轴承的磨损渐变类故障,故障数据或故障特征随时间变化;由某一时间段采集的数据训练得到的故障诊断模型,经过一段时间后,故障诊断性能退化,很难有效识别出此类故障,定期重新训练是解决此类问题的常用方法。

为了便于理解,将使用信号处理手段提取的信号特征构建的样本集所形成的数据空间称为样本空间;若样本空间随时间发生变化,则称为时变样本空间,否则称为时不变样本空间。通常情况下认为时变样本空间是连续变化的,然而由于数据缺失会造成时变样本空间不连续,则将此类型样本空间称为不连续时变样本空间。批量学习模式的故障诊断方法通常使用定期重新训练的方式处理时变样本空间的故障诊断问题,这将消耗大量时间和空间。因此,研究能应用于时变样本空间尤其是不连续时变样本空间的故障诊断方法,具有重要的意义。

生物免疫系统是一个非常复杂的且具有连续学习能力的智能系统,受其相关智能机理的启发产生了一系列的智能算法,如反面选择算法、人工免疫网络、克隆选择算法,等等,并在计算机安全和故障诊断等领域得到了广泛的应用^[10-15]。时变数据连续学习分类方法(Continual learning classification method for time-varying data based on artificial immune system, CLCMTVDAIS)^[16]是在生物免疫系统利用记忆细胞快速识别二次入侵抗原,以及免疫记忆细胞随入侵抗原进化而进化等智能机理的启发下,提出的一种针对时变样本空间的具有连续学习能力的监督学习分类方法。CLCMTVDAIS 利用生成的记忆细胞对数据进行分类,在测试阶段不断学习新样本,形成新的记忆细胞,同时淘汰失效的记忆细胞,从而使得状态空间始终保留着最佳的记忆细胞。当样本与时间无关时,CLCMTVDAIS 退化为一般的监督学习分类方法。

CLCMTVDAIS 虽然可以有效处理时变数据,但是与其他监督学习分类方法一样,一方面,无法有效识别出未参与训练的样本;另一方面,当没有新样本刺激记忆细胞,随着时间的发展,记忆细胞会消亡,当时变样本空间发生间断的时间大于记忆细胞的消亡时间时,CLCMTVDAIS 无法识别出发生间断后再次出现的样本。因此,需要在

CLCMTVDAIS 的基础上,进一步研究能处理不连续时变样本空间的连续学习故障诊断方法(Continual learning fault diagnosis method for discontinuous time-varying sample space, CLFDMDTVS)。

1 CLFDMDTVS 基本思想

CLCMTVDAIS 在训练阶段根据样本的在状态空间的分布情况,产生记忆细胞,并利用记忆细胞对测试样本进行分类;在测试阶段通过对测试样本的不断学习,生成新的记忆细胞,同时淘汰失效的记忆细胞,使得记忆细胞不断得到更新,从而保证较好的分类性能。对于类别数量为 m 的细胞集 C ,单个细胞描述为

$$\langle \mathbf{c}, p, q_1, t_1, q_2, t_2, \dots, q_m, t_m | \mathbf{c}, t \in R, p, q \in N \rangle$$

式中, $\mathbf{c}$ 为细胞的中心坐标, p 为细胞的代数, q_i 为细胞中第 i 类样本的核数量, t_i 为细胞中第 i 类样本最近一次被测试样本刺激的时间。

若细胞集 C 中有 k 个细胞, $\mathbf{c}$ 为 t 维,则细胞集 C 是一个 k 行 $2m+t+1$ 列的矩阵。当 $\sum_{i=1}^m q_i = 0$ 时为空细胞,当 $\sum_{i=1}^m q_i > 0$ 时为记忆细胞,当 $\sum_{i=1}^m q_i > 1$, 并且 $\sum_{i=1}^m q_i > q_j (j=1, 2, \dots, m)$ 时为多核记忆细胞,当 $q_i > 0, \sum_{j=1}^m q_j = 0 (j \neq i)$ 并且时为单核记忆细胞。

在测试阶段,利用亲和度 $\mathbf{a}$ 描述测试样本与记忆细胞之间的关系。 $\mathbf{a}$ 是一个 m 维向量,其每个分量的值表示测试样本与记忆细胞中相应类别之间的亲密程度,值越大两者越亲密,使用公式(1)计算。

$$\mathbf{a} = \left(\frac{a_1}{a_{\max}}, \frac{a_2}{a_{\max}}, \dots, \frac{a_m}{a_{\max}} \right) \quad (1)$$

$$a_{\max} = \max(a_1, a_2, \dots, a_m) \quad (2)$$

$$a_i = \frac{q_i}{d} (i=1, 2, \dots, m) \quad (3)$$

式中, d 为测试样本至记忆细胞中心的欧式距离。

对于二维和三维数据,CLCMTVDAIS 产生正方形或者立方体记忆细胞;对于 $n>3$ 的高维数据($d_1, d_2, \dots, d_n$),一个父代细胞会分裂为 2^n 个子代细胞,如一个 20 维的父代细胞会生成 $2^{20}=1\ 048\ 576$ 个子代细胞,这将消耗大量的时间和空间,而且这些子代细胞中只有少量的记忆细胞。为此需要对高维数据进行处理,CLCMTVDAIS 将数据分为 n 段,即($d_1,$

$d_2, d_3)$ 、 (d_2, d_3, d_4) 、 $\cdots$ 、 (d_{n-2}, d_{n-1}, d_n) 、 (d_{n-1}, d_n, d_1) 、 (d_n, d_1, d_2) , 然后分别进行训练生成相应的记忆细胞。这样一个 20 维的父代细胞会生成 $20 \times 2^3 = 160$ 个子代细胞, 所需时间与空间明显减少。在测试阶段, 同样对测试样本进行分段, 利用对应的记忆细胞各段样本进行测试, 然后将每段测试样本返回的亲密度值相加, 利用最大亲密度值决定测试样本的类别, 最后根据测试样本的类别更新每段样本对应的记忆细胞。可以看出, 此分段策略非常简单, 未考虑不同分段策略对故障诊断结果的影响, 因此应根据数据特性优化选择分段策略。

由于 CLCMTVDAIS 是依靠亲密度确定测试样本的类型, 因此, 如果各类样本分布相对集中, 可以认为当某测试样本的亲密度各分量均小于某一定值时, 则此测试样本不属于任何已知类型的记忆细胞, 即为新类型样本, 并由此测试样本生成新类型记忆细胞。基于这一思想, 在 CLCMTVDAIS 的基础上构建 CLFDMDTV S 模型。

在上述分析中可以看出, 要构建 CLFDMDTV S 模型, 需要确定一个亲密度阈值 a_t 。要确定的 a_t 值, 亲密度 a 需要分布在一个固定的区间, 并且不易受过多因素的干扰。CLCMTVDAIS 使用最大值归一化法, 将每次计算的亲密度 a 固定在 $[0, 1]$ 区间, 此值是一个相对量, 可以用来比较大小, 但是无法用此方法确定合理的 a_t 值, 因此需要重新定义亲密度计算公式。由于多核记忆细胞主要出现在各类样本空间的边界处, 其数量远低于单核记忆细胞, 因此将 CLFDMDTV S 的亲密度计算公式修订为

$$a = (f(k_1), f(k_2), \cdots, f(k_3)) \quad (4)$$

$$f(x) = \frac{2}{\pi} \arctan(x) \quad (5)$$

$$k_i = \frac{\delta(q_i)}{d} \quad (6)$$

$$\delta(x) = \begin{cases} 1 & x > 0 \\ 0 & x = 0 \end{cases} \quad (7)$$

对于高维数据, CLFDMDTV S 将每段测试数据对应的亲密度值取平均。

a_t 的取值直接影响到识别出新类型样本的质量, a_t 的取值过大, 容易把已知类型样本识别为新类型样本; a_t 的取值过小, 不易发现新类型样本。

此外, 为了保证新增已知类型记忆细胞的质量, 引入参数 a_n , 当计算得到的测试样本的最大亲密度值大于 a_n 时, 才能将测试样本激活的细胞进化为记忆细胞。

由于 CLFDMDTV S 在测试阶段能识别出新类型样本, 发生间断后重新识别的样本也视为新类型样本, 因此 CLFDMDTV S 描述的细胞类型数量的参数 m 是动态变化的。为此, 有新增类型记忆细胞时, 则在细胞集矩阵末尾增加两列; 同时, 当有某类型记忆细胞消失时, 则将其在细胞集矩阵中对应的 q 和 t 值全部置 0。

2 CLFDMDTV S 基本模型

通过重新定义亲密度 a 的计算公式, 明确细胞集的变化规则, 在 CLCMTVDAIS 的基础上构建 CLFDMDTV S 模型。此外, 所有样本归一化至 $[0, 1]^n$, 初始细胞与状态空间一致, 代数 $p=0$ 。

2.1 训练过程

由于 n 维样本需要分割为 n 组 3 维样本分别训练, 在此以低维样本为例说明 CLFDMDTV S 的训练过程, 其主要步骤如下。

(1) 初始化

对参数记忆细胞代数 p_m 和记忆细胞寿命 t_l 赋值, 具有 m 类训练样本的 2 维细胞初始化为 $\langle 0.5, 0.5, 0, 0, 0, 0, \cdots, 0, 0 \rangle$ 、3 维细胞初始化为 $\langle 0.5, 0.5, 0.5, 0, 0, 0, 0, \cdots, 0, 0 \rangle$ 。

(2) 培养记忆细胞

此步骤包括细胞激活和细胞分裂两个模块。细胞激活模块的主要功能是判断一个被激活的细胞是否需要分裂, 其流程图如图 1 所示; 细胞分裂模块的主要功能是将一个需要分裂的父代细胞分裂为若干子代细胞, 其流程图如图 2 所示。

图 1 细胞激活模块流程图

图 2 细胞分裂模块流程图

在培养记忆细胞阶段，不仅是细胞激活模块和细胞分裂模块相互调用，而且整个过程是一个递归调用。

2.2 诊断与连续学习过程

由于 CLFDMDTV S 构建的细胞随参数 m 动态变化，因此，在测试过程中构建了一个数据集 S ，根据记忆细胞识别出的样本类别存储识别到的样本。诊断与连续学习过程主要包括亲和度计算模块、更新细胞模块和培养新类型记忆细胞模块。诊断与连续学习过程的流程图如图 3 所示。

图 3 CLFDMDTV S 诊断与连续学习过程流程图

在亲和度计算模块中首先要根据参数 t_l 识别出失活记忆细胞，并将对应的参数 q 和 t 的值重置为 0，然后再计算 a ，其流程图如图 4 所示。如果计算 a 时涉及 t 个记忆细胞，则用式(8)替代式(6)。

$$k_i = \frac{\frac{\delta(q_{1i})}{d_1} + \frac{\delta(q_{2i})}{d_2} + \dots + \frac{\delta(q_{ti})}{d_t}}{t} \quad (8)$$

在更新细胞模块中，根据识别出的样本类型，更新相关记忆细胞的 t 值为测试样本的采样时间，

其流程图如图 5 所示。在培养新类型记忆细胞模块中，首先要确定是否有某类型记忆细胞消失，如果有，则删除细胞集中的相应数据，然后再培养新类型记忆细胞，其流程图如图 6 所示。

图 4 亲和度计算模块流程图

图 5 更新细胞模块流程图

图 6 培养新类型记忆细胞流程图

3 仿真与实例分析

为了验证 CLFDMDTV S 的性能与存在问题，用 UCI 标准数据集、二维人造数据集和西安交通大学

的 XJTU-SY 滚动轴承加速寿命试验数据集, 对 CLFDMDTVS 故障诊断性能进行分析, 并与文献中的常见故障诊断方法进行对比。

3.1 UCI 标准数据集仿真分析

当样本与时间无关时, CLFDMDTVS 退化为一般的监督学习分类方法, 因此 CLFDMDTVS 必须具有良好的分类性能。为了验证 CLFDMDTVS 在分类方面的性能与存在问题, 用 20 个著名的未丢失样本的 UCI 标准数据集^[17]进行验证, 并与常用的分类方法包括: 贝叶斯网络(Naïve Bayesian networks, NB)、决策树 C4.5 算法、 k 近邻算法(k -nearest neighbors, k NN)、RIPPER、BP 神经网络和支持向量机的序列最小最优化方法(Sequential minimal optimization algorithm, SMO)等进行比较。

数据集的简要描述见表 1, 采用 10 倍交叉验证试验, 将数据集均匀分为 10 分, 轮流将其中的 9 份作为训练样本集, 1 份作为测试样本集, 进行验证。每个数据集运行 10 次, 结果取平均值, 各算法的计算结果见表 2, 表 2 中其他算法的计算结果来自文献[16]和文献[18]。

表 1 各数据集简介

数据集名称	样本数量	样本维度	类别数量
天平	625	4	3
糖尿病	768	8	2
哈伯曼生存	306	3	2
心脏病	270	13	2
电离层	351	34	2
鸢尾花卉	150	4	3
国际象棋	3 196	35	2
字母	20 000	16	26
淋巴造影	148	18	4
和尚问题 1	124	6	2
和尚问题 2	169	6	2
和尚问题 3	122	6	2
托儿所	12 960	8	5
图像分割	2 310	19	7
声呐	208	60	2
垃圾邮件	4 601	57	2
车辆	846	18	4
元音	990	13	11
波形	5 000	40	3
葡萄酒	178	13	3

表 2 各算法的分类准确率(%)

数据集	NB	C4.5	3NN	RIPPER	BP	SMO	CLCMTVDAIS	CLFDMDTVS
天平	90.53(±1.67)	77.82(±3.42)	86.74(±2.72)	80.91(±3.31)	85.67(±2.55)	87.62(±2.64)	88.27($p_m=2, \pm 0.13$)	87.49($p_m=2, \pm 0.51$)
糖尿病	75.75(±5.32)	74.49(±5.27)	73.86(±4.55)	75.22(±4.86)	77.04(±4.85)	77.07(±4.14)	74.49($p_m=6, \pm 0.65$)	75.22($p_m=3, \pm 0.56$)
哈伯曼生存	75.06(±5.42)	71.05(±5.20)	69.77(±5.72)	72.72(±5.90)	74.20(±6.27)	73.40(±1.06)	73.27($p_m=4, \pm 0.74$)	71.73($p_m=4, \pm 0.83$)
心脏病	83.59(±5.98)	78.15(±7.42)	79.11(±6.77)	78.70(±6.62)	83.30(±6.20)	83.81(±5.59)	83.53($p_m=2, \pm 0.35$)	80.89($p_m=2, \pm 1.16$)
电离层	82.17(±6.14)	89.74(±4.38)	86.02(±4.31)	89.30(±4.63)	87.07(±5.52)	87.93(±4.69)	92.11($p_m=8, \pm 0.50$)	94.10($p_m=3, \pm 0.33$)
鸢尾花卉	95.53(±5.02)	94.73(±5.30)	95.20(±5.11)	93.93(±6.57)	84.80(±7.10)	84.87(±7.63)	96.35($p_m=3, \pm 0.66$)	96.33($p_m=4, \pm 0.90$)
国际象棋	87.79(±1.91)	99.44(±0.37)	96.56(±1.00)	99.13(±0.44)	98.92(±0.60)	95.78(±1.20)	86.63($p_m=10, \pm 0.37$)	93.56($p_m=4, \pm 0.18$)
字母	64.12(±0.94)	87.95(±0.61)	94.54(±0.23)	87.10(±0.45)	81.93(±0.62)	81.57(±0.19)	84.53($p_m=10, \pm 0.09$)	90.82($p_m=9, \pm 0.10$)
淋巴造影	83.13(±8.89)	75.84(±11.05)	81.74(±8.45)	77.36(±11.11)	82.26(±8.05)	85.94(±8.75)	80.41($p_m=9, \pm 0.78$)	81.42($p_m=10, \pm 1.16$)
和尚问题 1	73.38(±12.49)	80.61(±11.34)	78.97(±11.89)	83.87(±16.34)	97.69(±5.99)	79.58(±11.99)	85.58($p_m=9, \pm 1.50$)	91.45($p_m=10, \pm 1.71$)
和尚问题 2	56.83(±8.71)	57.75(±11.18)	54.74(±9.20)	56.21(±8.89)	100(±0.00)	58.70(±5.80)	63.87($p_m=9, \pm 1.75$)	63.79($p_m=8, \pm 1.14$)
和尚问题 3	93.45(±6.57)	92.95(±6.68)	86.72(±9.99)	84.80(±9.27)	88.32(±8.49)	93.45(±6.57)	88.79($p_m=10, \pm 1.36$)	88.52($p_m=6, \pm 1.34$)
托儿所	90.30(±0.72)	97.18(±0.46)	97.36(±0.24)	98.67(±0.35)	99.43(±1.05)	93.02(±0.34)	95.96($p_m=10, \pm 0.05$)	78.56($p_m=10, \pm 0.03$)
图像分割	80.16(±2.10)	96.79(±1.29)	96.12(±1.19)	95.53(±1.16)	91.35(±1.90)	89.72(±1.72)	94.29($p_m=8, \pm 0.14$)	96.28($p_m=6, \pm 0.17$)
声呐	67.71(±8.66)	73.61(±9.34)	83.76(±8.51)	75.45(±10.01)	78.67(±9.21)	77.88(±8.45)	76.18($p_m=4, \pm 1.28$)	75.10($p_m=8, \pm 1.84$)
垃圾邮件	79.56(±1.56)	92.68(±1.08)	89.80(±1.35)	92.67(±1.21)	91.22(±2.52)	90.48(±1.22)	90.97($p_m=10, \pm 0.18$)	91.56($p_m=10, \pm 0.22$)
车辆	44.68(±4.59)	72.28(±4.32)	70.21(±3.93)	68.32(±4.59)	81.11(±3.84)	74.08(±3.82)	71.23($p_m=6, \pm 0.79$)	71.21($p_m=6, \pm 0.65$)
元音	62.90(±4.38)	80.20(±4.36)	96.99(±2.13)	71.17(±5.14)	92.73(±3.14)	70.61(±3.86)	91.63($p_m=5, \pm 0.45$)	95.83($p_m=4, \pm 0.22$)
波形	80.01(±1.45)	75.25(±1.90)	77.67(±1.79)	79.14(±1.72)	86.56(±1.56)	86.94(±1.48)	81.63($p_m=4, \pm 0.19$)	82.43($p_m=3, \pm 0.14$)
葡萄酒	97.46(±3.70)	93.20(±5.90)	95.85(±4.19)	93.14(±6.94)	98.02(±3.26)	98.76(±2.73)	97.57($p_m=2, \pm 0.65$)	97.58($p_m=4, \pm 0.53$)

需要注意的是, 由于 CLCMTVDAIS 和 CLFDMDTVS 在处理高维数据时是分段进行的, 各段数据在训练和测试时互不影响, 因此可以构建并行计算结构, 提高计算效率。但是如果数据集中的数据值重复率很高, 如国际象棋数据集和波形数据集, 这两种方法生成的多核记忆细胞太多, 导致分

类效果很差。仿真试验中使用主成分分析技术(Principal components analysis, PCA)将数据旋转后, 分类效果有很大改善。

另外, 由于 CLFDMDTVS 的亲密度计算公式无法充分发挥出多核记忆细胞中核数量的优势, 导致和尚问题 3 数据集和托儿所数据集的分类效果很

差。因此,仿真试验中也使用 PCA 对数据进行了旋转,和尚问题 3 数据集的分类效果有所提高,然而托儿所数据集的分类效果依旧很差。

从表 2 可以看出,与 NB、C4.5、3NN、RIPPER、BP、SMO 等经典的分类算法相比,除托儿所数据集外,CLFDMDTV S 均取得了良好的分类效果。

3.2 二维人造数据集仿真分析

CLFDMDTV S 涉及到 4 个重要参数 p_m 、 t_l 、 a_t 和 a_n 。 p_m 决定了记忆细胞的大小, p_m 越大,记忆细胞越小,相同条件下产生的记忆细胞数量越多。 t_l 决定了记忆细胞的存活时间, t_l 越大,记忆细胞存活时间越长,在状态空间存在的记忆细胞数量越多。 a_t 是判别某样本是否为新类型样本的重要依据, a_t 值较大时,容易引起过学习,将已知类型数据识别为新类型数据; a_t 值较小时,容易引起欠学习,无法识别出新类型数据。 a_n 用于保证新增已知类型记忆细胞质量, a_n 值较大时,新增已知类型记忆细胞质量高,但是细胞更新慢; a_n 值较小时,新增已知类型记忆细胞质量低,容易将错误识别的细胞进化为此类型记忆细胞,从而引起过学习。

用图 7 所示数据集分析各参数对 CLFDMDTV S 故障诊断性能的影响。将相同时间点上的参数 1 和参数 2 值构建成特征向量,作为一个样本。图 7 中所示数据集中共有 6 类故障数据,其中故障 1 缺失了量纲一时间 1 201~1 500 之间的数据,故障 4、故障 5、故障 6 分别缺失了量纲一时间 1~500、1~750 和 1~1 000 之间的数据。

图 7 不连续时变故障数据

3.2.1 参数 t_l 对 CLFDMDTV S 故障诊断性能的影响

图 8 是选取量纲一时间为 100、200、300 和 400

时采集的数据构建各类故障样本为训练样本,其余样本为测试样本,参数 $p_m=5$, t_l 分别取 20、30、40、50、60、70、80、90 和 100 时,CLFDMDTV S 的故障诊断准确率。

从图 8 中可以看出,随着 t_l 的增大,故障诊断准确率呈下降趋势。这是因为当 t_l 较大时,记忆细胞的生存时间变长,导致多核记忆细胞增多,从而产生了过学习,使得诊断准确率下降。另外,随着训练样本采集时间的增加,CLFDMDTV S 的诊断准确率下降,这是因为训练样本采集时间相对较长时,各类训练样本的可分降低,在学习新样本时,易引起过学习,从而导致准确率较低。

图 8 参数 t_l 对 CLFDMDTV S 故障诊断准确率的影响

3.2.2 参数 p_m 对 CLFDMDTV S 故障诊断性能的影响

图 9 是选取量纲一时间为 100、200、300 和 400 时采集的数据构建各类故障样本为训练样本,其余样本为测试样本,参数 $t_l=20$, p_m 分别取 4、5、6 和 7 时,CLFDMDTV S 的故障诊断准确率。

图 9 参数 p_m 对 CLFDMDTV S 故障诊断准确率的影响

从图 9 中可以看出,当训练样本较少时, p_m 的变化对故障诊断准确率影响不大,这是因为训练样本采集时间相对较短时,各类训练样本是非线性可分的,以单核记忆细胞为主,在通过对新样本的学习时,不易引起过学习,从而导致准确率较高。当训练样本较多时,随着 p_m 的增大,故障诊断准确率较低,且出现波动。诊断准确率较低是因为训练样

本采集时间相对较长时, 各类训练样本是非线性不可分的, 以多核记忆细胞为主, 在通过对新样本的学习时, 易引起过学习, 从而导致准确率较低; 诊断准确率出现波动是因为随着 p_m 的变化, 寻找的确定新样本类型的相邻记忆细胞发生了变化, 导致过学习程度不一样, 从而导致准确率出现波动。

3.2.3 参数 a_t 和 a_n 对 CLFDMDTV 故障诊断性能的影响

选取量纲一时间为 100 时采集的数据构建的样本为训练样本, 其余为测试样本, 各类故障的训练样本数量分别为 100、100、100、0、0、0, 测试样本数量分别为 1 600、1 900、1 900、1 500、1 250 和 1 000。参数 $t_f=20$, $p_m=5$, a_t 分别取 0.8、0.85、0.9、0.93 和 0.95, a_n 与 a_t 的取值相同。故障诊断结果如表 3、表 4、表 5、表 6 和表 7 所示, 为了方便绘制表格, 样本集 S 中样本数量少于 100 的不列入表格。由于传统的故障诊断方法无法很好的处理时变样本^[16], 即使是理想状态下, 也会将故障 4、故障 5 和故障 6 样本全部误诊断, 显然, 在此条件下, 理论诊断准确率为 59.02%。

表 3 $a_t, a_n=0.8$ 时统计结果

序号	样本数量	样本类型
1	2 100	故障 1 (1 100) 故障 6 (1 000)
2	3 400	故障 2 (1 900) 故障 4 (1 500)
3	3 150	故障 3 (1 900) 故障 5 (1 250)
4	500	故障 1
准确率	(1 100+1 900+1 900+500)/9 150=59.02% (1 100+1 900+1 900)/9 150=53.55%	

从表 3 可以看出, 由于 a_t 和 a_n 取值很小, 故障 6 样本被误诊断为故障 1 类型, 故障 4 样本被误诊断为故障 2 类型, 故障 5 样本被误诊断为故障 3 类型, 发生间断的故障 1 样本被正确识别。若考虑发生间断后诊断出的故障 1 样本, 则准确率为 59.02%; 若不考虑发生间断后诊断出的故障 1 样本, 则准确率为 53.55%。

表 4 $a_t, a_n=0.85$ 时统计结果

序号	样本数量	样本类型
1	1 100	故障 1
2	1 900	故障 2
3	3 150	故障 3 (1 900) 故障 5 (1 250)
4	1 500	故障 4
5	1 000	故障 6
6	500	故障 1
准确率	(1 100+1 900+1 900+1 500+1 000+500)/9 150=86.34% (1 100+1 900+1 900+1 500+1 000)/9 150=80.87%	

表 5 $a_t, a_n=0.9$ 时统计结果

序号	样本数量	样本类型
1	1 100	故障 1
2	1 900	故障 2
3	1 900	故障 3
4	1 500	故障 4
5	1 250	故障 5
6	1 000	故障 6
7	500	故障 1
准确率	(1 100+1 900+1 900+1 500+1 250+1 000+500)/9 150=100% (1 100+1 900+1 900+1 500+1 250+1 000)/9 150=94.54%	

表 6 $a_t, a_n=0.93$ 时统计结果

序号	样本数量	样本类型
1	1 100	故障 1
2	1 894	故障 2
3	1 900	故障 3
4	1 499	故障 4
5	1 250	故障 5
6	990	故障 6
7	500	故障 1
准确率	(1 100+1 894+1 900+1 499+1 250+990+500)/9 150=99.81% (1 100+1 894+1 900+1 499+1 250+990)/9 150=94.35%	

从表 4 可以看出, 由于 a_t 和 a_n 取值较小, 故障 5 样本被误诊断为故障 3 类型。同时, 未参与训练的故障 4 和故障 6 样本以及发生间断的故障 1 样本均被正确识别。若考虑发生间断后诊断出的故障 1 样本, 则准确率为 86.34%; 若不考虑发生间断后诊断出的故障 1 样本, 则准确率为 80.87%。

从表 5 可以看出, 由于 a_t 和 a_n 取值理想, 未参与训练的故障 4、故障 5 和故障 6 样本以及发生间断的故障 1 样本均被正确识别。若考虑发生间断后诊断出的故障 1 样本, 则准确率为 100%; 若不考虑发生间断后诊断出的故障 1 样本, 则准确率为 94.54%, 由此可见, 当 a_t 取值合理时能得到理想的效果。

各类记忆细胞随时间的变化情况如图 10 所示。图 10a 是训练产生的三类记忆细胞; 图 10c、图 10f 和图 10h 是新类型记忆细胞产生前的已有的各类型记忆细胞分布图; 图 10d、图 10g 和图 10i 是故障 4、故障 5 和故障 6 等新类型记忆细胞产生时各类型记忆细胞的分布图; 图 10e 是故障 4 记忆细胞经过 10 个量纲一时间后各类型记忆细胞分布图; 图 10j、图 10k 和图 10l 是故障 1 类型样本间断后, 各类型记忆细胞分布图, 可以看出故障 1 记忆细胞的淘汰过程; 图 10m 和图 10n 是故障 1 样本发生间断后重新出现前后的各类型记忆细胞分布图。

图 10 不同时刻各类记忆细胞分布状态

从表 6 可以看出, 由于 a_t 和 a_n 取值较好, 未参与训练的故障 4、故障 5 和故障 6 样本以及发生中断的故障 1 样本均被正确识别, 但是 6 个故障 2 样本被识别为新类型样本, 样本集 S 共有 12 种类别。若考虑发生中断后诊断出的故障 1 样本, 则准确率为 99.81%; 若不考虑发生中断后诊断出的故障 1 样本, 则准确率为 94.35%。

从表 7 可以看出, 由于 a_t 和 a_n 取值较大, 虽然能诊断出未参与训练的故障 4、故障 5 和故障 6 样本以及发生中断的故障 1 样本, 但是部分故障 1 个故障 2 样本和 6 个故障 3 样本被识别为新类型样本, 样本集 S 共有 255 种类别。

由于故障 1、故障 2 和故障 3 样本参与训练, 因此, 样本集 S 中序号 1、2 和 3 视为正确诊断的结

果, 其余被识别为新类型样本的, 全部视为诊断错误, 故障 4、故障 5 和故障 6 以及中断后的故障 1 取样本集 S 中数量较多的, 若考虑发生中断后诊断出的故障 1 样本, 则准确率为 69.92%; 若不考虑发生中断后诊断出的故障 1 样本, 则准确率为 65.10%。

表 7 $a_t, a_n=0.95$ 时统计结果

序号	样本数量	样本类型
1	1 100	故障 1
2	1 363	故障 2
3	908	故障 3
4	673	故障 4
5	1 246	故障 5
6	667	故障 6
7	906	故障 3
8	288	故障 4
9	440	故障 2
10	441	故障 1
11	277	故障 4
12	195	故障 6
准确率	$(1\ 100+1\ 363+908+673+1\ 246+667+441)/9\ 150=69.92\%$ $(1\ 100+1\ 363+908+673+1\ 246+667)/9\ 150=65.10\%$	

3.3 XJTU-SY 滚动轴承加速寿命试验数据集分析

为了进一步验证 CLFDMDTV 的故障诊断性能, 采用西安交通大学 XJTU-SY 滚动轴承加速寿命试验数据集中试验工况为转速 2 400 r/min、径向力 10 kN 的数据对其进行验证, 数据集的详细信息如表 8 所示^[19-20]。

表 8 XJTU-SY 轴承数据集信息

数据集	样本数量	实际寿命	失效位置
Bearing3_1	2 538	42 h 18 min	外圈
Bearing3_2	2 496	41 h 36 min	内圈、滚动体、保持架、外圈
Bearing3_3	371	6 h 11 min	内圈
Bearing3_4	1 515	25 h 15 min	内圈
Bearing3_5	114	1 h 54min	外圈

采样数据用 db16 小波包 8 层分解, 使用高频小波系数能量作为特征向量。将 XJTU-SY 数据集集中的每个样本的水平方向振动信号和竖直方向振动信号平均分成 8 段, 分别生成 8 个特征向量, 并将对应的水平特征向量和竖直特征向量组合, 形成 8 个 16 维的故障样本。共计生成 5 类 56 272 个故障样本, 所有数据归一化至 $[0,1]$ ¹⁶。

使用实际寿命前 5 分钟采集的数据生成的样本为训练样本, 即每个数据集选用前 40 个特征向量作为训练样本, 其余为测试样本。为模拟不连续时变样本空间的故障诊断问题, 进行两组分析, 第一组,

所有类型数据均参与训练, Bearing3_1 中实际寿命 750.125~1 000 min 之间采集的数据, 其计 2 000 样本缺失; 第二组, Bearing3_1 中实际寿命前 1 000 min 之间采集的数据, 其计 8 000 个样本缺失。

CLFDMDTV 的故障诊断结果与 BP 神经网络、支持向量机(Support vector machine, SVM)、卷积神经网络(Convolutional neural networks, CNN)和长短时记忆网络(Long short term memory network, LSTM)的诊断结果进行对比。

CLFDMDTV 参数取值为: $p_m=5$, $t_l=200$, $a_r=0.5$, $a_n=0.9$; BP 选用 45 隐层节点, 其他参数选用 tansig、logsig 和 trainlm; SVM 选用 RBF 核函数, 采用交叉验证法选取最佳 c 和 g 参数; 将样本转换成 32*32 的灰度图片, 然后用 15 层 CNN 进行训练和识别; LSTM 采用 5 层双向 LSTM 网络。

当训练样本与参数不变, CLFDMDTV 构建的记忆细胞不变, 从而导致 CLFDMDTV 的诊断结果不变, 因此, 试验中 CLFDMDTV 只运行一次。BP、SVM、CNN 和 LSTM 分别运行 50 次, 结果取平均值。

在第一组试验中, CLFDMDTV 最终的样本集中有 12 类, 具体统计结果如表 9 所示。所有类型的数据均参与了训练, 从表 9 中可以看出, Bearing3_2 中 29 个样本由于过学习别识别为新类型数据, Bearing3_3 中有 233 个样本被错误识别为 Bearing3_2, Bearing3_5 中只有 8 个样本被正确识别, 其余 864 个被错误的识别为 Bearing3_2。Bearing3_4 全部正确识别, 虽然 Bearing3_1 发生了间断, 导致时变样本空间不连续, 但是间断后的样本仍然被聚集在一起。若考虑发生间断后诊断出的 Bearing3_1 样本, 则准确率为 97.90%; 若不考虑发生间断后诊断出的 Bearing3_1 样本, 则准确率为 75.15%。

表 9 第一组统计结果

序号	Bear3_2	Bear3_3	Bear3_4	Bear3_5	Bear3_1
1	19 899	233	0	864	4
2	0	2 688	0	0	0
3	0	0	12 080	0	0
4	0	0	0	8	0
5	0	0	0	0	5 960
6	0	7	0	0	0
7	8	0	0	0	0
8	1	0	0	0	0
9	1	0	0	0	12 300
10	4	0	0	0	0
11	10	0	0	0	0
12	5	0	0	0	0
准确率	(19 899+2 688+12 080+8+5 960)/54 072*100=97.90%				
	(19 899+2 688+12 080+8+5 960)/54 072*100=75.15%				

在第二组试验中, CLFDMDTV 最终的样本集中有 10 类, 具体统计结果如表 10 所示。由于 Bearing3_1 中实际寿命前 1 000 min 之间采集的数据缺失, 导致参与训练的类型有 Bearing3_2、Bearing3_3、Bearing3_4 和 Bearing3_5。从表 10 中可以看出, Bearing3_2、Bearing3_3、Bearing3_4 和 Bearing3_5 的诊断结果与第一组相同。虽然 Bearing3_1 未参与训练, 但是它的 12 995 个样本聚集为一类, 只有 9 个样本被错误的识别为 Bearing3_2。若考虑未参与训练却能正确诊断出的 Bearing3_1 样本, 则准确率为 97.63%; 若不考虑诊断出的 Bearing3_1 样本, 则准确率为 72.07%。

表 10 第二组统计结果

序号	Bear3_2	Bear3_3	Bear3_4	Bear3_5	Bear3_1
1	19 899	233	0	864	9
2	0	2 688	0	0	0
3	0	0	12 080	0	0
4	0	0	0	8	0
5	0	7	0	0	0
6	9	0	0	0	0
7	1	0	0	0	12 295
8	4	0	0	0	0
9	10	0	0	0	0
10	5	0	0	0	0
准确率	(19 899+2 688+12 080+8+12 295)/48 112*100=97.63%				
	(19 899+2 688+12 080+8)/48 112*100=72.07%				

与其他经典的故障诊断方法的对比情况如表 11 所示。从表 11 中可以看出 CLFDMDTV 在处理不连续时变故障空间的故障诊断问题时, 具有明显的优势。

表 11 不同算法的故障诊断结果

算法名称	第一组 (%)	第二组 (%)
BP	70.85	50.42
SVM	70.82	42.57
CNN	62.41	44.40
LSTM	77.29	50.50
CLFDMDTV	97.90 (75.15)	97.63 (72.07)

4 结论

(1) CLFDMDTV 是在生物免疫系统利用记忆细胞快速识别二次入侵抗原, 以及记忆细胞随入侵抗原进化而进化等智能机理的启发下, 提出一种针对不连续时变样本空间的具有连续学习能力的故障诊断方法, 在一定程度上解决了基于时变样本空间的故障诊断问题。当样本与时间无关时, 其退化为

一般的监督学习故障诊断方法。

(2) CLFDMDTVVS 在诊断过程中通过对诊断到的新样本不断学习, 持续更新记忆细胞, 利用亲和度阈值 a_i 识别未参与训练以及发生间断后再次出现的故障样本。

(3) CLFDMDTVVS 对参与学习训练的各类型样本进行分类, 对未参与学习训练以及发生间断再次出现的各类型样本进行聚集。使用 20 个 UCI 标准数据集、二维人造数据集和西安交通大学的 XJTU-SY 滚动轴承加速寿命试验数据集对 CLFDMDTVVS 的故障诊断性能进行了分析, 试验结果表明, 无论是针对时不变样本空间还是不连续时变样本空间的故障诊断问题, CLFDMDTVVS 均能取得理想的故障诊断结果。

(4) CLFDMDTVVS 涉及到四个主要参数, 取值主要依靠经验。其中亲和度阈值 a_i 对 CLFDMDTVVS 的诊断结果影响最大。 a_i 较小, 引起欠学习, 无法识别新类型样本; a_i 较大, 引起过学习, 容易把已知类型样本作为新类型样本处理。如何通过分析训练样本优选参数是需要进一步探讨的问题。

(5) CLFDMDTVVS 依靠样本与相邻记忆细胞的亲和度进行分类, 分类性能相对较弱, 需要结合其他分类方法, 改进其分类性能。此外, CLFDMDTVVS 处理高维数据的方法过于简单, 需要探索更好的高维数据处理方法。

(6) CLFDMDTVVS 在记忆细胞进化过程中, 采用了相同的记忆细胞失活时间, 需要进一步研究根据对样本的学习, 找到各类样本最佳的记忆细胞失活时间, 以提高 CLFDMDTVVS 的故障诊断性能。

参 考 文 献

- [1] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [2] 王国彪, 何正嘉, 陈雪峰, 等. 机械故障诊断基础研究“何去何从”[J]. 机械工程学报, 2013, 49(1): 63-72.
WANG Guobiao, HE Zhengjia, CHEN Xuefeng, et al. Basic research on machinery fault diagnosis - what is the prescription [J]. Journal of Mechanical Engineering, 2013, 49(1): 63-72.
- [3] BEN A, FNAIECH N, SAIDI L, et al. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. Applied Acoustics, 2015, 89: 16-27.
- [4] 李巍华, 翁胜龙, 张绍辉. 一种萤火虫神经网络及在轴承故障诊断中的应用[J]. 机械工程学报, 2015, 51(7): 99-106.
LI Weihua, WENG Shenglong, ZHANG Shaohui. A firefly neural network and its application in bearing fault diagnosis [J]. Journal of Mechanical Engineering, 2015, 51(7): 99-106.
- [5] LIU Rongnan, YANG Boyuan, ZHANG Xiaoli, et al. Time-frequency atoms-driven support vector machine method for bearings incipient fault diagnosis [J]. Mechanical Systems and Signal Processing, 2015, 75: 345-370.
- [6] HANG Jun, ZHANG Jianzhong, CHENG Ming. Application of multi-class fuzzy support vector machine classifier for fault diagnosis of wind turbine [J]. Fuzzy Sets and Systems, 2016, 297: 128-140.
- [7] LEI Yaguo, ZUO M. Gear crack level identification based on weighted K nearest neighbor classification algorithm [J]. Mechanical Systems and Signal Processing, 2009, 23(5): 1535-1547.
- [8] LIU Ruonan, YANG Boyuan, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: a review [J]. Mechanical Systems and Signal Processing, 2018, 108(5): 1535-1547.
- [9] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data [J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [10] DASGUPTA D, YU S, NINO F. Recent advances in artificial immune systems: Models and applications [J]. Applied Soft Computing, 2011, 11(2): 1574-1587.
- [11] ZHENG Jieqiong, CHEN Yunfang, ZHANG Wei. A survey of artificial immune applications [J]. Artificial Intelligence Review, 2010, 34(1): 19-34.
- [12] DASGUPTA D. Advances in artificial immune systems [J]. IEEE Computational Intelligence Magazine, 2006, 1(4): 40-49.
- [13] BAYAR N, DARMOUL S, HAJRI-GABOUJ S, et al. Fault detection, diagnosis and recovery using artificial

- immune systems: a review [J]. *Engineering Applications of Artificial Intelligence*, 2015, 46: 43-57.
- [14] ZHOU Ji, DASGUPTA D. Revisiting negative selection algorithms[J]. *Evolutionary Computation*, 2007, 15(2): 223-251.
- [15] LI Dong, LIU Shulin, ZHANG Hongli. A method of anomaly detection and fault diagnosis with online adaptive learning under small training samples [J]. *Pattern Recognition*, 2017, 64: 374-385.
- [16] LI Dong, LIU Shulin. Continual learning classification method for time-varying data based on artificial immune system [CP/OL]. [2019-11-25]. <https://doi.org/10.24433/CO.1791866.v2>.
- [17] DUA D, GRAFF C. UCI machine learning repository [EB/OL]. [2019-11-25]. <http://archive.ics.uci.edu/ml>.
- [18] KOTSIANTIS S, ZAHARAKIS I, PINTELAS P. Machine learning: A review of classification and combining techniques [J]. *Artificial Intelligence Review*, 2006, 26(3): 159-190.
- [19] 雷亚国, 韩天宇, 王彪, 等. XJTU-SY 滚动轴承加速寿命试验数据集解读[J]. *机械工程学报*, 2019, 55(16): 1-6.
- LEI Yaguo, HAN Tianyu, WANG Biao, et al. XJTU-SY rolling element bearing accelerated life test datasets: A tutorial [J]. *Journal of Mechanical Engineering*, 2019, 55(16): 1-6.
- [20] WANG Biao, LEI Yaguo, LI Naipeng, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. *IEEE Transactions on Reliability*, 2018: 1-12.
-
- 作者简介: 李栋(通信作者), 男, 1981年出生, 博士, 副教授, 硕士研究生导师。主要研究方向为设备智能故障诊断方法。
E-mail: lidong@cczu.edu.cn
- 刘树林, 男, 1963年出生, 博士, 教授, 博士研究生导师。主要研究方向为复杂设备故障诊断。
E-mail: lsl346@shu.edu.cn
- 孙欣, 女, 1994年出生, 博士研究生。主要研究方向为设备智能故障诊断方法。
E-mail: sunxin52@shu.edu.cn