

基于限定样本序贯极端学习机的模拟电路在线故障诊断

何星, 王宏力, 陆敬辉, 姜伟

(第二炮兵工程大学控制工程系, 西安 710025)

摘要: 为解决故障特征样本分批加入时分类模型的在线更新问题, 提出一种限定样本序贯极端学习机(LSSELM)。LSSELM通过逐步添加新样本, 同时剔除与其相似度最高的同类别旧本来提高模型的动态适应能力, 并通过 Sherman-Morrison 矩阵求逆引理来降低计算复杂度, 实现输出权值的递推求解, 完成模型的在线训练。将 LSSELM 用于模拟电路在线故障诊断, 结果表明相比在线序贯极端学习机(OS-ELM)和 LSSELM 的诊断准确率更高, 具有更好的泛化性能。

关键词: 序贯极端学习机; 模拟电路; 故障诊断; 限定样本; 相似度

中图分类号: TP181

文献标志码: A

Online fault diagnosis of analog circuit based on limited-samples sequence extreme learning machine

HE Xing, WANG Hong-li, LU Jing-hui, JIANG Wei

(Department of Control Engineering, The Second Artillery Engineering University, Xi'an 710025, China.

Correspondent: HE Xing, E-mail: trees241@163.com)

Abstract: To solve the problem of on-line updating for the classification model in the case of fault feature samples added in batches, a dynamic sequence extreme learning machine(LSSELM) is proposed. Dynamic adaptability of LSSELM is improved by adding a new feature sample, and meanwhile, abandoning an old one with the highest similar degree of the same label to it iteratively. Then, the Sherman-Morrison formula is used to decrease the calculation complexity, and the output weights are solved recursively, and the online training of classification model is completed. Finally, applying LSSELM to online fault diagnosis of the analog circuit, the simulation results show that the LSSELM can get higher diagnosis accurate and better generalization than the online sequence extreme learning machine(OS-ELM).

Keywords: sequence extreme learning machine; analog circuit; fault diagnosis; limited-samples; similar degree

0 引言

故障诊断技术作为保证复杂电子系统正常运转的关键技术, 一直是各国研究人员关注的热点问题。据统计, 在大部分电子系统中, 虽然模拟电路所占规模比例不到 20%, 但其故障却占整个系统故障的 80% 以上^[1]。然而, 由于非线性、元件容差等特点使得模拟电路故障建模困难, 传统的故障字典法、参数辨识法等方法已很难适应^[2]。随着人工智能方法的快速发展, 许多研究者开始尝试将其用于模拟电路故障诊断, 并取得了较好的效果^[3-7]。但传统神经网络存在训练时间长、过学习和局部收敛等问题, 且对新样本无法在线学习, 不适合进行模拟电路在线故障诊断。

极端学习机是一种新型单隐层前馈神经网络

(SLFNs)^[8], 其输入权值和隐层神经元偏差随机生成, 在训练过程中无需反复调整, 并且将传统单隐层前馈神经网络参数训练问题转化为求解线性方程组, 利用得到的最小范数最小二乘解作为网络输出权值, 整个训练过程一次完成。与传统神经网络方法相比, 训练速度得到极大的提高, 有效避免了局部收敛等问题, 已成功应用于回归和分类领域^[9-15]。最初的极端学习机进行训练时基于已有的全部训练样本, 当有新的样本产生时, 与传统神经网络一样必须重新进行训练, 这不利于进行在线故障诊断。针对这一问题, Liang 等^[16]提出了在线序贯极端学习机(OS-ELM), 利用递推思想不断利用新样本实现输出权值的在线更新, 大大缩短了训练时间。然而, OS-ELM 只是不断地

收稿日期: 2013-11-20; 修回日期: 2014-05-08.

基金项目: 国家自然科学基金项目(61004128).

作者简介: 何星(1985-), 男, 博士生, 从事智能故障诊断、测试性分析与评估的研究; 王宏力(1965-), 男, 教授, 博士生导师, 从事复合制导技术、惯性系统可靠性分析等研究。

将新样本加入训练集中进行输出权值的递推更新, 没有旧样本的存在可能导致更新后的模型不能很好地跟踪待测对象的变化, 尤其对于模拟电路故障在线诊断, 元件本身存在的容差导致故障特征样本取值出现波动, 若不及时更新分类模型, 会导致错误的诊断结果。

针对此问题, 本文提出一种在更新过程中考虑消除旧样本影响的限定样本序贯极端学习机, 并通过模拟电路的故障诊断验证了其有效性。

1 极端学习机

给定 N 个训练样本 $\{(\mathbf{x}_i, \mathbf{t}_i)\}_{i=1}^N$, $\mathbf{x}_i \in \mathbf{R}^n$, $\mathbf{t}_i \in \mathbf{R}^m$, 则具有 L 个隐藏神经元, 激活函数为 $G(x)$ 的 SLFNs 输出为

$$\mathbf{o}_i = \sum_{j=1}^L \beta_j G(\mathbf{w}_j, b_j, \mathbf{x}_i), i = 1, 2, \dots, N. \quad (1)$$

其中: $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]$ 为连接第 j 个隐层神经元和输入神经元之间的权值向量, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T$ 为连接第 j 个隐层神经元和输出神经元之间的权值向量, b_j 为第 j 个隐层神经元偏差。

若使具有 L 个隐层神经元和激活函数为 $G(x)$ 的 SLFNs 能够零误差逼近这 N 个样本, 则等同于

$$\sum_{j=1}^L \|\mathbf{o}_i - \mathbf{t}_i\| = 0,$$

即存在 β_j , \mathbf{w}_j 和 b_j 使得下式成立:

$$\sum_{j=1}^L \beta_j G(\mathbf{w}_j, b_j, \mathbf{x}_i) = \mathbf{t}_i, i = 1, 2, \dots, N. \quad (2)$$

式(2)的 N 个方程可以简写为

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{T}. \quad (3)$$

其中

$$\mathbf{H} = \begin{bmatrix} G(\mathbf{w}_1, b_1, \mathbf{x}_1) & \cdots & G(\mathbf{w}_L, b_L, \mathbf{x}_1) \\ \vdots & \ddots & \vdots \\ G(\mathbf{w}_1, b_1, \mathbf{x}_N) & \cdots & G(\mathbf{w}_L, b_L, \mathbf{x}_N) \end{bmatrix}_{N \times L},$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_L^T \end{bmatrix}_{L \times m}, \quad \mathbf{T} = \begin{bmatrix} \mathbf{t}_1^T \\ \vdots \\ \mathbf{t}_N^T \end{bmatrix}_{N \times m};$$

\mathbf{H} 为隐层输出矩阵, 其第 j 列表示第 j 个隐层神经元关于输入 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ 的输出矩阵。

大多数情况下, 隐层神经元数目远远小于训练样本数目, 即 $L \ll N$, 此时根据广义逆引理, 上述线性系统的最小范数最小二乘解为

$$\boldsymbol{\beta} = \mathbf{H}^\dagger \mathbf{T}. \quad (4)$$

其中: $\mathbf{T} = [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_N]^T$, \mathbf{H}^\dagger 是矩阵 \mathbf{H} 的 Moore-Penrose 广义逆。

对于多分类问题, ELM 采用多输出回归算法实

现, 其原理如下。

假设对于一个 s 类的分类问题, 其样本集为 $\aleph = \{(\mathbf{x}_i, y_i)\}_{i=1}^N$, $\mathbf{x}_i \in \mathbf{R}^d$, $y_i \in \{1, 2, \dots, s\}$, 定义新的多维目标向量

$$\mathbf{c}_i \triangleq [c_{i1} \ c_{i2} \ \cdots \ c_{is}]. \quad (5)$$

其中

$$c_{ij} = \begin{cases} 1, & y_i = j; \\ -1, & \text{others.} \end{cases}$$

对待测新样本集 $\{(\mathbf{x}_i, \mathbf{c}_i)\}_{i=1}^N$, 按照 ELM 算法步骤完成训练后, 由下式得出最终分类结果:

$$\hat{y}_i = \max(\hat{\mathbf{c}}_i). \quad (6)$$

其中: $\hat{\mathbf{c}}_i$ 为 \mathbf{c}_i 经 ELM 测试后的结果, $\max(\cdot)$ 表示向量“ \cdot ”中最大元素的下标。

2 限定样本序贯极端学习机

ELM 是一种批处理神经网络学习方法, 即需要利用全部训练样本进行训练, 但大多数情况下, 训练样本是逐步加入的, 这时需反复利用 ELM 进行训练, 使得训练时间成倍增加, 不利于实现在线故障诊断。为解决此问题, 本文提出的 OS-ELM 通过递推求解输出权值的方式不断利用新样本对极端学习机进行更新训练, 大大减少了 ELM 的训练时间。但是, OS-ELM 不断添加新样本, 在样本数量巨大的情况下对计算机的存储空间需求很大, 而且, 其将新旧样本赋予同等地位用于输出权值的更新, 此时旧样本的信息作用已基本丧失, 反而可能影响分类模型对当前系统状态的准确判别。

针对上述问题, 本文提出的限定样本序贯极端学习机思路为: 初始化阶段训练完毕后, 当在序贯学习阶段加入一个新特征样本后, 找出训练集同一类别中与其相似度最高的旧样本进行剔除, 从而实现在不增加样本容量的同时更新样本信息。假设当前训练样本集为 $(\mathbf{X}_k, \mathbf{T}_k)$, 特征向量 $\mathbf{X}_k = [\mathbf{x}_k, \mathbf{x}_{k+1}, \dots, \mathbf{x}_{k+s-1}]^T$, 类别向量为 $\mathbf{T}_k = [\mathbf{t}_k, \mathbf{t}_{k+1}, \dots, \mathbf{t}_{k+s-1}]^T$, 对应的隐层输出矩阵为 $\mathbf{H}_k = [\mathbf{h}_k^T, \mathbf{h}_{k+1}^T, \dots, \mathbf{h}_{k+s-1}^T]^T$ 。同时为了避免因隐层输出矩阵出现病态而导致伪逆计算结果错误, 借鉴岭回归的思想^[17], 输出权值可表示为

$$\boldsymbol{\beta}_k = \left(\frac{1}{\lambda} + \mathbf{H}_k^T \mathbf{H}_k \right)^{-1} \mathbf{H}_k^T \mathbf{T}_k. \quad (7)$$

为实现训练样本集尺寸固定, 需要重新计算加入新样本和剔除与其最相似的旧样本之后的输出权值, 即当新样本 $(\mathbf{x}_{k+s}, \mathbf{t}_{k+s})$ 加入训练样本集后, 通过比较同类各样本与其相似度, 剔除相似度最高的旧样本 $(\mathbf{x}_{k+i}, \mathbf{t}_{k+i})$, 此时, 隐层输出矩阵变为 $\mathbf{H}_{k+1} = [\mathbf{h}_k^T, \dots, \mathbf{h}_{k+i-1}^T, \mathbf{h}_{k+i+1}^T, \dots, \mathbf{h}_{k+s}^T]^T$, 类别向量为 $\mathbf{T}_{k+1} =$

$[t_k, \dots, t_{k+i-1}, t_{k+i+1}, \dots, t_{k+s}]^T$, 则输出权值变为

$$\beta_{k+1} = \left(\frac{1}{\lambda} + \mathbf{H}_{k+1}^T \mathbf{H}_{k+1} \right)^{-1} \mathbf{H}_{k+1}^T \mathbf{T}_{k+1}. \quad (8)$$

其中

$$\begin{aligned} \frac{1}{\lambda} + \mathbf{H}_{k+1}^T \mathbf{H}_{k+1} &= \\ \frac{1}{\lambda} + [h_k^T \dots h_{k+i-1}^T h_{k+i+1}^T \dots h_{k+s}^T] \cdot \\ [h_k^T \dots h_{k+i-1}^T h_{k+i+1}^T \dots h_{k+s}^T]^T &= \\ \frac{1}{\lambda} + h_k^T h_k + \dots + h_{k+i-1}^T h_{k+i-1} + \\ h_{k+i+1}^T h_{k+i+1} + \dots + h_{k+s}^T h_{k+s} &= \\ \frac{1}{\lambda} + \mathbf{H}_k^T \mathbf{H}_k + h_{k+s}^T h_{k+s} - h_{k+i}^T h_{k+i}, \end{aligned} \quad (9)$$

$$\begin{aligned} \mathbf{H}_{k+1}^T \mathbf{T}_{k+1} &= \\ [h_k^T \dots h_{k+i-1}^T h_{k+i+1}^T \dots h_{k+s}^T] \cdot \\ [t_k \dots t_{k+i-1} t_{k+i+1} \dots t_{k+s}]^T &= \\ \mathbf{H}_k^T \mathbf{T}_k + h_{k+s}^T t_{k+s} - h_{k+i}^T t_{k+i}. \end{aligned} \quad (10)$$

借鉴 OS-ELM 做法, 令

$$\begin{aligned} \mathbf{P}_k &= \left(\frac{1}{\lambda} + \mathbf{H}_k^T \mathbf{H}_k \right)^{-1}, \\ \mathbf{P}_{k+1} &= \left(\frac{1}{\lambda} + \mathbf{H}_{k+1}^T \mathbf{H}_{k+1} \right)^{-1}, \end{aligned}$$

则式(9)可表示为

$$\mathbf{P}_{k+1}^{-1} = \mathbf{P}_k^{-1} + h_{k+s}^T h_{k+s} - h_{k+i}^T h_{k+i}. \quad (11)$$

令 $\mathbf{W} = \mathbf{P}_k^{-1} + h_{k+s}^T h_{k+s}$, 则式(11)变为

$$\mathbf{P}_{k+1}^{-1} = \mathbf{W} - h_{k+i}^T h_{k+i}. \quad (12)$$

根据 Sherman-Morrison 矩阵求逆引理^[18]可得

$$\begin{aligned} \mathbf{W}^{-1} &= \\ (\mathbf{P}_k^{-1} + h_{k+s}^T h_{k+s})^{-1} &= \\ \mathbf{P}_k - \frac{\mathbf{P}_k h_{k+s}^T h_{k+s} \mathbf{P}_k}{1 + h_{k+s}^T \mathbf{P}_k h_{k+s}}, \end{aligned} \quad (13)$$

$$\begin{aligned} \mathbf{P}_{k+1} &= \\ (\mathbf{W} - h_{k+i}^T h_{k+i})^{-1} &= \\ \mathbf{W}^{-1} + \frac{\mathbf{W}^{-1} + h_{k+i}^T h_{k+i} \mathbf{W}^{-1}}{1 - h_{k+i}^T \mathbf{W}^{-1} h_{k+i}}. \end{aligned} \quad (14)$$

将式(7)、(9)和(10)代入(8), 可得训练样本更新后输出权值为

$$\begin{aligned} \beta_{k+1} &= \mathbf{P}_{k+1} \mathbf{H}_{k+1}^T \mathbf{T}_{k+1} = \\ \mathbf{P}_{k+1} (\mathbf{P}_k^{-1} \mathbf{P}_k \mathbf{H}_k^T \mathbf{T}_k + h_{k+s}^T t_{k+s} - h_{k+i}^T t_{k+i}) &= \\ \mathbf{P}_{k+1} (\mathbf{P}_k^{-1} \beta_k + h_{k+s}^T t_{k+s} - h_{k+i}^T t_{k+i}) &= \\ \beta_k - \mathbf{P}_{k+1} h_{k+s}^T (h_{k+s} \beta_k - t_{k+s}) + \\ \mathbf{P}_{k+1} h_{k+i}^T (h_{k+i} \beta_k - t_{k+i}). \end{aligned} \quad (15)$$

从式(15)可以看出, β_{k+1} 可通过前一时刻输出权值 β_k 递推得到, 而不需要通过式(10)反复进行求

逆运算. LSSELM 的训练过程描述如下:

1) 利用初始 s 个样本训练 LSSELM, 得到 \mathbf{P}_0 和初始输出权值 β_0 , 令 $k = 0$.

2) 将新样本 (x_{k+s}, t_{k+s}) 添加至训练样本集中, 计算与 t_{k+s} 以取值相同的类中与 x_{k+s} 相似度最高的样本, 剔除此相似度最高的旧样本. 本文选择夹角余弦作为衡量样本间相似程度的度量, 任意两样本间夹角余弦通过下式计算:

$$c = \frac{\sum_{l=1}^m x_o(l)x_n(l)}{\sqrt{\sum_{l=1}^m [x_o(l)]^2 \sum_{l=1}^m [x_n(l)]^2}}. \quad (16)$$

其中: $x_o(l)$ 代表初始样本集中与新样本同一类的样本包含的特征, $x_n(l)$ 代表新样本包含的特征.

3) 利用式(14)求解样本集更新后的 \mathbf{P}_{k+1} , 进而利用式(15)计算得到更新后的输出权值 β_{k+1} .

4) 令 $k = k + 1$, 转 2).

上述训练过程结束后, 利用更新后的输出权值建立分类模型, 便可进行故障诊断.

3 LSSELM 在线故障诊断步骤

利用 LSSELM 进行模拟电路故障诊断, 诊断流程如图 1 所示, 具体步骤如下.

Step 1: 通过灵敏度分析, 确定对输出响应影响较大的元件作为故障元件;

Step 2: 设定故障模式, 并针对每种故障模式通过多次 Monte-Carlo 仿真获取故障样本;

Step 3: 对获取的故障样本数据进行小波包分解, 提取底层各项系数的归一化能量值作为 LSSELM 的输入;

Step 4: 利用新样本在线训练 LSSELM;

Step 5: 利用训练好的分类模型对在线采集并经预处理得到的故障特征分类, 完成故障诊断过程.

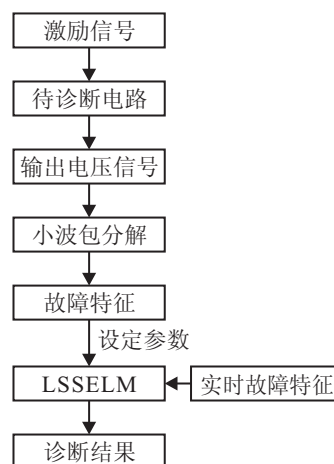


图 1 限定样本序贯极端学习机在线诊断流程

4 实例验证

选择如图 2 所示的带通滤波器电路. 施加激励为 $1\text{V}/1\text{kHz}$ 的正弦信号, 仿真时间为 $0\sim 0.5\text{s}$, 时间步长为 1ms . 利用 Multisim 10.0 软件对电路进行灵敏度分析, 发现 C_1 、 C_2 、 R_2 和 R_3 对输出响应影响最明显, 因此选择这 4 种元件作为故障元件. 由于硬故障可看作是软故障的特例, 本文以软故障为例进行验证. 电阻和电容元件容差分别为 5% 和 10% .




图 2 待诊断电路

4.1 离线故障诊断

4.1.1 单故障

表 1 所示为电路发生单故障时的故障模式设置情况, 包括无故障状态在内共有 9 种故障模式. 设置元件发生故障时参数值超差为 30% 和 50% . 分别对各故障模式进行 60 次 Monte Carlo 仿真, 前 30 次为超差 30% , 后 30 次为超差 50% , 共得到 540 组输出响应数据, 选择 db3 小波对各模式输出电压进行 3 层小波包分解, 可得到 540×8 的故障特征矩阵. 选择各模式前 30 组样本作为初始训练样本, 后 30 组样本用来进行在线更新. 重新仿真 20 次、超差 50% 时的数据用来进行测试.

表 1 单故障模式设置

故障模式	故障描述	类别
f0	NF	1
f1	$C_1 \uparrow$	2
f2	$C_1 \downarrow$	3
f3	$C_2 \uparrow$	4
f4	$C_2 \downarrow$	5
f5	$R_2 \uparrow$	6
f6	$R_2 \downarrow$	7
f7	$R_3 \uparrow$	8
f8	$R_3 \downarrow$	9

在 LSSELM 在线训练阶段, 逐步加入 270 组新样本进行更新. LSSELM 激活函数为 sigmoid 函数, 隐层节点数目在 $2\sim 50$ 之间交叉验证选取, $\lambda = 2^{-10}$. 为

了验证 LSSELM 模型的诊断效果, 选择 RBF、ELM 和 OS-ELM 三种方法进行比较. 对于 RBF 和 ELM, 利用前 270 组初始训练样本建立分类模型, 不进行在线更新; OS-ELM 参数设置同 LSSELM. 4 种方法诊断结果如表 2 所示.

表 2 4 种方法诊断结果

指标	方 法			
	RBF	ELM	OS-ELM	LSSELM
隐层节点数	180	30	30	30
训练识别率/%	100	100	99.63	100
训练时间/s	0.019 6	0.002 7	0.007 4	0.048 7
测试识别率/%	58.33	77.78	93.33	99.44
测试时间/s	0.018 9	0.000 97	0.000 564	0.000 38

由表 2 可以看出: LSSELM 几乎能够准确识别所有测试样本; OS-ELM 的识别率为 93.33% , 说明分类模型受到旧样本影响, 导致部分特征样本识别错误; 而 ELM 和 RBF 只利用旧的特征样本建立分类模型, 因此识别率不高, 尤其是 RBF 识别率仅为 59.44% , 分类能力最差. 从训练时间看, LSSELM 的训练时间相比其他 3 种方法有所增加, 这是由于在递推更新过程中增加了相似度判别操作所致, 但分类模型建立之后, LSSELM 的测试时间要少于其他 3 种方法.

4.1.2 双故障

双故障情形下电路各项设置与单故障时相同, 不过在同一时刻两种元件同时发生超差, 对于前述 4 个故障元件, 包括无故障在内共有 25 种双故障模式, 本文取表 3 所示的 9 种进行分析.

表 3 双故障分类

故障模式	故障描述	类别
Df0	NF	1
Df1	$C_1 \uparrow \& C_2 \uparrow$	2
Df2	$C_1 \uparrow \& R_2 \uparrow$	3
Df3	$C_1 \downarrow \& R_3 \uparrow$	4
Df4	$C_2 \downarrow \& R_2 \uparrow$	5
Df5	$C_2 \uparrow \& R_3 \downarrow$	6
Df6	$C_2 \uparrow \& R_2 \downarrow$	7
Df7	$R_2 \uparrow \& R_3 \uparrow$	8
Df8	$R_2 \downarrow \& R_3 \downarrow$	9

同样选择 RBE、ELM 和 OS-ELM 建立分类模型进行比较. 表 4 为 4 种方法诊断结果, 从中可以看出,

表 4 4 种方法诊断结果

指标	方 法			
	RBF	ELM	OS-ELM	LSSELM
隐层节点数	180	30	40	40
训练识别率/%	100	100	100	100
训练时间/s	0.049	0.001 3	0.01	0.076 8
测试识别率/%	56.67	85	90.56	97.22
测试时间/s	0.018 9	0.001 2	0.000 8	0.000 61

LSSELM对测试样本的识别率达到97.22%, 优于其他3种方法, 其中RBF对测试样本识别率仅为56.67%, 在4种方法中最差. 4种方法在时间消耗上的结果与单故障情形结论一致.

4.2 在线故障诊断

为验证OS-ELM和LSSELM的在线诊断能力, 对电路各故障模式连续运行5s重新采集50组特征样本用于测试两种方法的在线诊断性能. 设定两种工况:

- 1) 在正常运行2.5s后出现一种单故障(以f5: R2↑&R3↑为例);
- 2) 在正常运行2.5s后出现一种双故障(以Df7: R2↑&R3↑为例).

1) 发生单故障. 图3和图4为发生f5单故障时OS-ELM和LSSELM的在线诊断结果.




图3 发生f5单故障时OS-ELM在线诊断结果




图4 发生f5单故障时LSSELM在线诊断结果

2) 发生双故障. 图5和图6为发生Df7双故障时OS-ELM和LSSELM的在线诊断结果.




图5 发生Df7双故障时OS-ELM在线诊断结果

图3~图6为两种工况下的在线诊断结果. 可以看出, 对于正常状态OS-ELM和LSSELM能够准确实现故障的在线诊断, 但对于单故障R2↑和双故障




图6 发生Df7双故障时LSSELM在线诊断结果

R2↑&R3↑, OS-ELM未能准确给出诊断结果, 尤其对于R2↑&R3↑双故障, OS-ELM全部出现了误诊, 而LSSELM仅出现了两次误诊, 说明LSSELM通过对旧特征样本的剔除能够取得比OS-ELM更好的诊断结果, 可用于模拟电路参数漂移性故障的在线诊断.

5 结论

OS-ELM作为ELM用于在线训练情况下的改进, 采用递推的思想实现了训练样本的在线快速更新, 极大地提高了训练样本更新速度, 但其只是将新样本不断加入样本集中, 对旧样本不加任何处理, 这种更新方式会影响分类模型准确跟踪新样本的变化, 从而对诊断结果产生不利影响. 本文提出的限定样本序贯极端学习机在将新样本加入的同时剔除与其相似度最高的旧样本, 保持了样本集容量不变, 且能够更好地反映系统当前的状态. 模拟电路故障仿真结果表明, LSSELM具有更好的泛化性能, 可用于模拟电路参数漂移引起的单、双故障的在线诊断结果.

参考文献(References)

- [1] Li F, Woo P Y. Fault detection for linear analog IC-the method of short-circuit admittance parameters[J]. IEEE Trans on Circuits and Systems I: Fundamental Theory and Application, 2002, 49(1): 105-108.
- [2] 杨士元, 胡梅, 王红. 模拟电路软故障诊断的研究[J]. 微电子学与计算机, 2008, 25(1): 1-8.
(Yang S Y, Hu M, Wang H. Study on soft fault diagnosis of analog circuit[J]. Microelectronics & Computer, 2008, 25(1): 1-8.)
- [3] El-gamal M A, Mohamed M D A. Ensembles of neural networks for fault diagnosis in analog circuits[J]. J of Electronic Testing: Theory and Applications, 2007, 23, 323-339.
- [4] Mismar D, AbuBaker A. Neural network based algorithm of soft fault diagnosis in analog electronic circuits[J]. Int J of Computer Science and Network Security, 2010, 10(1): 107-111.
- [5] Cui J, Wang Y R. A novel approach of analog circuit fault diagnosis using support vector machines classifier[J]. Measurement, 2011, 44(1): 281-289.

- [6] 马超, 陈西宏, 徐宇亮, 等. 基于支持向量机属性约简集成的模拟电路故障诊断[J]. 仪器仪表学报, 2011, 32(3): 660-666.
(Ma C, Chen X H, Xu Y L, et al. Analog circuit fault diagnosis based on attribute reduct ensemble of support vector machine[J]. Chinese J of Scientific Instrument, 2011, 32 (3): 660-666.)
- [7] 孙健, 王成华. 基于 mRMR 原则和优化 SVM 的模拟电路故障诊断[J]. 仪器仪表学报, 2013, 34(1): 221-226.
(Sun J, Wang C H. Analog circuit fault diagnosis based on mRMR and optimized SVM[J]. Chinese J of Scientific Instrument, 2013, 34(1): 221-226.)
- [8] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: Theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [9] Yuan Y B, Wang Y G, Cao F L. Optimization approximation solution for regression problem based on extreme learning machine[J]. Neurocomputing, 2011, 74(16): 2475-2482.
- [10] Qi Y, Miche Y, Eirola E, et al. Regularized extreme learning machine for regression with missing data[J]. Neurocomputing, 2013, 102: 45-51.
- [11] Shrivastava N A, Panigrahi B K. A hybrid wavelet-ELM based short term price forecasting for electricity markets[J]. Electrical Power and Energy Systems, 2014, 55: 41-50.
- [12] Huang G B, Ding X J, Zhou H M. Optimization method based extreme learning machine for classification[J]. Neurocomputing, 2010, 74(1): 155-163.
- [13] Huang G B, Zhou H M, Ding X J, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Trans on Systems, Man, and Cybernetics-Part B: Cybernetics, 2012, 42(2): 513-529.
- [14] Lan Y, Hu Z J, Yeng C S, et al. An extreme learning machine approach for speaker recognition[J]. Neural Computer & Application, 2013, 22(3/4): 417-425.
- [15] Cao J W, Lin Z P, Huang G B, et al. Voting based extreme learning machine[J]. Information Sciences, 2012, 185(1): 66-77.
- [16] Liang N Y, Huang G B, Saratchandran P, et al. A fast and accurate on-line sequential learning algorithm for feedforward networks[J]. IEEE Trans on Neural Networks, 2006, 17(6): 1411-1423.
- [17] Hoerl A E, Kennard R W. Ridge regression: Biased estimation for nonorthogonal problems[J]. Technometrics, 1970, 12(1): 55-67.
- [18] 张贤达. 矩阵分析与应用[M]. 北京: 清华大学出版社, 2005: 68-69.
(Zhang X D. Matrix analysis and applications[M]. Beijing: Tsinghua University Press, 2005: 68-69.)

(责任编辑: 孙艺红)