

模拟电路故障诊断的双重扰动支持向量机集成方法

马 超¹, 陈西宏¹, 姚懿玲², 韩 明²

(1 空军工程大学 导弹学院, 陕西 三原 713800; 2 空军驻 210 所军事代表室, 陕西 西安 710065)

摘 要: 为进一步提高模拟电路故障诊断准确率, 提出一种特征和模型参数双重扰动的集成支持向量机新算法. 首先在集合覆盖思想下设计基于混沌蚁群算法的属性约简算法将特征样本空间划分成若干子空间, 然后针对每个子空间, 在“低偏差区域”内进行模型参数扰动, 经过两次多数投票法得到最终集成结果. 故障诊断实例表明, 该方法比多分类支持向量机、Attribute Bagging(AB)算法、Bagging 方法等具有更好的故障诊断率.

关键词: 双重扰动; 支持向量机集成; 属性约简; 模拟电路故障诊断

中图分类号: TP181; TN707

文献标识码: A

文章编号: 1000—7180(2011)03—0017—06

SVM Ensemble Algorithm Based on Double Disturbance Mechanism and Its Application in Analog Circuit Fault Diagnosis

MA Chao¹, CHEN Xi-hong¹, YAO Yi-ling², HAN Ming²

(1 Institute of Missile, AFEU, Sanyuan 713800, China;

2 The Military Deputy Office of 210, Xi'an 710065, China)

Abstract: To improve the diagnosis accuracy in analog circuit, a SVM ensemble algorithm based on double disturbance mechanism of attribute and model parameter is proposed. Firstly, a attribute reduction algorithm based on chaos-ant optimization algorithm is presented under method of set-covering, to partition attribute space into many subspaces. And then in each subspace, the model parameter is disturbed in the region of Low-Bias. Finally, the final Ensemble result is obtained by using two times of majority-voting method. The diagnosis instance indicates that the proposed algorithm performace better than many other algorithms, take multi-SVM, AB algorithm, Bagging and so on for example.

Key words: double disturbance; SVM ensemble; attribute reduction; analog circuit fault diagnosis

1 引言

模拟电路故障诊断领域中应用最多是神经网络^[1]和支持向量机^[2], 支持向量机集成以强弱可学习算法等价性为出发点, 通过训练和组合多个准确、有差异的支持向量机, 提供了一个进一步提高学习机泛化能力的新方法, 文献[3]提出了 Attribute Bagging 方法, 实验结果证明支持向量机对特征扰动比较敏感, 但对特征子空间的选择是随机的, 很难保证特征子空间生成的基分类器具有较高的精度, 因此, 提出基于粗集理论的集成特征选择方法.

为了提高差异性, 文献[4]提出了“Lobag”算法. 属性约简相当于对输入特征空间进行扰动, 而随机选取参数模型是对模型参数的扰动, 两种扰动机制不同. 可以对两者进行结合. 本文结合两种扰动的优点, 提出特征和参数双重扰动支持向量机集成学习算法, 并应用于模拟电路故障诊断.

2 基于混沌蚁群算法的属性约简算法

基于粗糙集的集成特征选择的关键是构造高效的属性约简算法来产生多个用于生成基分类器的特征子空间. 在文献[5]中证明了绝对属性约简和集合

覆盖的等价性.在此基础上,证明了一致决策表中最优相对属性约简和最小集合覆盖的等价性,并提出基于混沌蚁群算法的相对属性约简算法,通过特殊设计来获得多个最优或近似最优属性约简,以生成集成所需的基分类器.

2.1 相对属性约简与集合覆盖的等价性

定义 1 决策表 $S = (U, A = C \cup D, V, f)$, 其中 U 是对象集合, $A = C \cup D$ 是属性集合, C 和 D 分别是条件属性和决策属性, $D \neq \emptyset$, V 是属性值, $f: U \times A \rightarrow V$ 是一个信息函数, 它指定 U 中的每个对象 u 的属性值. 设 $U/D = \{D_1, D_2, \dots, D_k\}$ 为决策属性集 D 对论域 U 的划分, $U/C = \{C_1, C_2, \dots, C_r\}$ 为条件属性集 C 对论域 U 的划分, 其中 $C_i (i = 1, 2, \dots, r)$ 称为基本块. $\text{pos}_C D = \bigcup C_-(D_i) (D_i \in U/D)$ 为 C 关于 D 的正区域. 若 $\text{pos}_C D = U$, 则称决策表是一致的, 否则是不一致的. 设 $B \subseteq C$, 则 B 对应了一个二元不可区分关系, 即等价类: $\text{ind}(B) = \{(x, y) \in U \times U: f(x, q) = f(y, q), \forall q \in B\}$. 设 $B \subseteq C$, 且 $\text{pos}_B D = \text{pos}_C D$, 称 B 为 C 的 D 约简. C 的 D 约简称为相对约简.

定义 2 设 $S = (U, A = C \cup D, V, f)$ 是一致决策表, 其基本块集合为 $X = \{X_1, X_2, \dots, X_r\}$, 条件属性集为 $C = \{C_1, C_2, \dots, C_n\}$, 由基本块族 X 中任意两个不同基本块组成集合记为 $U' = \{(X_i, X_j)/X_i, X_j \in X, i < j \leq r\}$, 显然 $|U'| = r(r-1)/2$. 定义一个 $r(r-1)/2$ 行 n 列的矩阵 M , 其中行代表 U' 中的元素, 列表示 C 中的元素. 任给 $u_i = (X', X'') \in U'$, $C_j \in C$, 矩阵第 i 行第 j 列元素 m_{ij} 取值如下表示:

$$m_{ij} = \begin{cases} 1 & f(x, C_j) \neq f(y, C_j), \forall x \in X', y \in X'' \\ 0 & f(x, C_j) = f(y, C_j), \forall x \in X', y \in X'' \end{cases} \quad (1)$$

由 m_{ij} 组成的矩阵 $M = m_{ij}$ 称为一致决策表 S 的相关矩阵.

定义 3 最小集合覆盖问题: S 是一个集合, $S_1, S_2, \dots, S_m$ 是 S 的子集, 且构成 S 的覆盖, 即 $\bigcup_{i=1}^m S_i = S$, 求最小的覆盖.

定义 4 区分集合: 由 U' 中所有能被 C_j 区分的 $u = (X', X'')$ 的全体组成的集合叫作属性 C_j 的区分集合, 记为 S_{C_j} . 即 $S_{C_j} = \bigcup_{i=1}^{|U'|} \{u_i/m_{ij} = 1, u_i = (X', X'') \in U'\}$.

定理 1 所有属性的区分集合构成集合 U' 的

覆盖, 即 $U' = \bigcup_{j=1}^n S_{C_j}$.

定理 2 U' 的一个集合覆盖等价于一致决策表的一个相对属性约简.

证明: 设 $B = \{C_1, C_2, \dots, C_{n'}\} \subseteq C, n' \leq n$, 且 $U' = \bigcup_{j=1}^{n'} S_{C_j}$, 即 $U/B = \{X_1, X_2, \dots, X_r\}$, 即集合 B 包含的属性可以区分所有基本块. 又因决策表为一致决策表, 每个基本块对应于不同决策类, 即根据 B 的知识可以将 U 中所有元素划分到不同决策类中去, 即 $\text{pos}_B D = U$, 由定义 1 可知, 对于一致决策表 $\text{pos}_C D = U$, 则 $\text{pos}_B D = \text{pos}_C D = U$, 即 $\text{pos}_B D = \text{pos}_C D = U$, B 是 C 相对于 D 的约简.

定理 2 说明对于一致决策表, U' 的一个集合覆盖对应一个相对属性约简, 一个相对属性约简对应一个集合覆盖. 值得注意的是, 对于不一致决策表定义 2 中的相关矩阵需要作一定改动, 才能满足 U' 的集合覆盖与决策表相对属性等价性.

由定理 2 可以直接得到推理 1 和推理 2.

推理 1 一致决策表的最小相对属性约简对应 U' 的最小集合覆盖, U' 的最小集合覆盖也对应一致决策表的最小属性约简.

推理 2 求最小集合覆盖是 NP-hard 问题, 所以求最小相对属性约简也是 NP-hard 问题.

2.2 基于混沌蚁群算法的相对属性约简

由推理 1, 可将求解一致决策表最小相对属性约简转化为如下最小集合覆盖问题:

U' 由一致决策表生成, $S_{C_j} (j = 1, 2, \dots, n)$ 为 U' 的子集, 且构成 U' 的覆盖, 即 $\bigcup_{j=1}^n S_{C_j} = U'$, 求最小覆盖. 其中 $S_{C_j} (j = 1, 2, \dots, n)$ 为由 U' 得到的属性区分集合.

集合覆盖是经典 NP-hard 问题之一, 已在多个领域得到应用, 如航空时间调度, 数据逻辑分析和设备选址等. 目前已经有许多解决此问题的算法被提出, 如 Lagrangian 启发式算法, 启发式函数法 SCHF^[6] 等, 但这些算法收敛速度比较慢, 有些算法易陷入局部最小. 本文提出一种混沌蚁群算法, 首先根据问题本身信息减小问题规模, 提炼启发式信息, 然后利用混沌的遍历性生成初始信息素分布来加快收敛速度, 并对信息素进行混沌扰动避免算法陷入局部极小.

2.2.1 启发式信息

推理 3 相关矩阵的某一列的元素全部取值为 1 时, 说明 U' 中的元素能够被此列对应的属性全部

分开,则此属性即为最小相对属性约简.

推理4 相关矩阵的某一行的元素只有一个取值为1时,说明此行对应的 $u = (X', X'')$ 只能被取值为1的元素对应的属性分开,则此属性对应的区分集合为必选集合.

为讨论启发式信息,首先给出一些定义^[6].

定义5 设 $\forall u \in S$, 如果 u 当且仅当只属于 $S_{C_1}, S_{C_2}, \dots, S_{C_j}, \dots, S_{C_n} (j = 1, 2, \dots, n)$ 中的 K 个集合,则称 u 的频率为 K .

定义6 S_{C_j} 是任意一个区分集合,令 $F(S_{C_j}) = \min[k(u); u \in S_{C_j}]$, 其中 $k(u)$ 为 u 的频率,则称 $F(S_{C_j})$ 为 S_{C_j} 的覆盖度.

定义7 在 $S_{C_j} (j = 1, 2, \dots, n)$ 中排除一个集合 S_{C_j} 后,出现 M 个必选的集合(覆盖度为1的集合),则称 S_{C_j} 的必选度为 M ,用 $M(S_{C_j})$ 表示.

启发式信息1:设 $|S_{C_j}|$ 为集合 S_{C_j} 的基数.若 $|S_{C_m}| = |S_{C_n}|$, 且 $F(S_{C_m}) < F(S_{C_n})$, 选择 S_{C_m} 的概率比较高.

启发式信息2:若 $|S_{C_m}| = |S_{C_n}|$, $F(S_{C_m}) = F(S_{C_n})$, 且 $M(S_{C_m}) < M(S_{C_n})$, 则选择 S_{C_n} 的概率比较高.

启发式信息3:若 $F(S_{C_m}) = F(S_{C_n})$, $M(S_{C_m}) = M(S_{C_n})$, 且 $|S_{C_m}| > |S_{C_n}|$, 则选择 S_{C_n} 的概率比较高.

由启发式信息构造启发式函数:

$$\eta_j = \frac{aM(S_{C_j})/\max(M(S_{C_j})) + b|S_{C_j}|/|S|}{cF(S_{C_j})/\max(F(S_{C_j}))} \quad (2)$$

a, b, c 为调节系数,由式(2)可知,启发式函数的大小由 $M(S_{C_j})$ 、 $F(S_{C_j})$ 、 $|S_{C_j}|$ 共同决定,为平衡三个因素对启发式信息的影响,做归一化处理.

2.2.2 初始信息素分布

基本蚁群算法计算初期,各路径的信息素相等,仅靠启发式信息决定转移方向,很难在大量候选解中快速找出较好解,造成初始阶段收敛速度比较慢,利用混沌优化形成初始信息素分布可以加快收敛速度.具体步骤如下:

Step1:混沌映射选择.文献[7]在基本 Tent 映射的基础上,加入随机函数使得 Tent 映射能跳出小周期或不动点重新进入混沌状态.本文采用文献[7]提出的改进 Tent 映射进行混沌优化.改进 Tent 映射如式(3)所示.

$$x_{k+1} =$$

$$\begin{cases} 2(x_k + 0.1 \times \text{rand}(0,1)), & 0 \leq x_k \leq 0.5 \\ 2(1 - (x_k + 0.1 \times \text{rand}(0,1))), & 0.5 < x_k \leq 1 \end{cases} \quad (3)$$

Step2:在 $[0, 1]$ 范围内随机选择 m 个混沌初始值 $X_0^1, X_0^2, \dots, X_0^m$, m 为属性区分集合个数.

Step3:将 m 个混沌初始值分别赋给 m 个属性区分集合,以 m 个属性区分集合为出发点,利用式(3)和式(4)进行迭代,计算各个区分集合下一步要选择的区分集合 $M_{k+1}^j (j = 1, 2, \dots, m)$,直到找到的区分集合能完成对 U' 的集合覆盖,共得到 m 个解.

$$M_{k+1}^j = [X_k^j \cdot m + 1] \quad ([\] \text{ 为求整运算符}) \quad (4)$$

Step4:重复 Step2 和 Step3 k 次,共得到 km 个解.

Step5:从找到的 km 个解中,找出相对较优的一部分解,只在这些解包含的区分集合上留下信息素,从而形成初始信息素分布.

说明: k 值越大,求得的初始信息素分布越有利于整体算法的收敛,但是形成初始信息素分布时间会延长,经实验,当 $k = 3$ 时,整体效果较佳.

2.2.3 属性约简算法

集合覆盖思想下基于混沌蚁群算法的最小相对属性约简算法如下:

Step1:求决策表的相关矩阵 $\mathbf{M} = m_{ij}$;

Step2:由相关矩阵求决策表 U 各个属性的区分集合 $S_{C_j} (j = 1, 2, \dots, n)$;

Step3:如果存在满足推理3的属性,则输出此属性作为最小属性约简.否则,转到 Step4;

Step4:设 $S = (S_{C_1}, S_{C_2}, \dots, S_{C_n})$, 找出满足推理4的属性区分集合 $S_{C_j} \in S$, 令 $S_0 = S - \{S_{C_j}\}$, $A = \{S_{C_j}\}$, $U'' = U' - u$, 其中, $u \in S_{C_j} (j = 1, 2, \dots, n)$;

Step5:初始化蚁群算法参数:令迭代次数 $NC = 0$, 设最大迭代次数为 $NC_{\max}$, 将 $A = A_1 = A_2 = \dots = A_j = \dots = A_m$ 和 $U'' = U''_1 = \dots = U''_j = \dots = U''_m$ 分别赋予 S_0 中的 m 个子集,利用混沌优化生成 S_0 中各子集的初始信息素分布 $\tau_i (i = 1, 2, \dots, m)$.根据式(2)计算中各子集的启发信息 $\eta_i (i = 1, 2, \dots, m)$;

Step6:将 m 只蚂蚁分配给 S_0 中的 m 个子集 $S_1, S_2, \dots, S_i, \dots, S_m$, 令 $A_i = A_i + S_i$, $U''_i = U''_i - u, u \in S_i (i = 1, 2, \dots, m)$.每只蚂蚁从各自集合出发在剩余子集中按照概率公式寻找下一个子集 S_j , 令 $A_i = A_i + S_j$, $U''_i = U''_i - u, u \in S_j (i, j = 1, 2, \dots,$

m), 当 $U''_i = \emptyset$ 时, $A_i (i = 1, 2, \dots, m)$ 便是寻找到的集合覆盖. 记录当前各只蚂蚁的解 A_i , 计算 A_i 包含的子集个数, 保留子集个数最少解即本次迭代最优解. 更新信息素, 将蚂蚁放回初始点进行下一次迭代;

Step7: 当 $NC = NC_{\max}$ 时, 停止迭代, 选择并保留最优解;

Step8: 最优解包含的区分集合所对应属性构成的集合即是最小相对约简. 当约简数量大于等于 10 时, 转到 Step10. 否则转到 Step9;

Step9: 寻找近似最优约简, 使最优解和近似最优解的数量和大于等于 10. 转到 Step10;

Step10: 将 Step4 中选出的区分集合对应的属性加入到每个所求解对应的属性集合中, 形成的新属性集合即算法所求属性约简, 输出结果.

算法说明:

(1) 转移概率公式:

$$P_{ij}^k = \begin{cases} \tau_j^\alpha(t) \cdot \eta_j^\beta(t) / \sum_{s \in \text{allowed}_k} \tau_s^\alpha(t) \cdot \eta_s^\beta(t) & j \in \text{allowed}_k \\ 0 & \text{otherwise} \end{cases},$$

式中, $\tau_i(t)$ 为 t 时刻区分集合 i 上的信息素, $\eta_i(t)$ 为 t 时刻区分集合 i 的启发式信息, α 为区分集合信息素的重要度, β 为区分集合启发信息的重要度. $\text{allowed}_k = \{0, 1, \dots, n-1\} - \text{tabu}_k$ 表示蚂蚁 k 下一步允许选择的集合.

(2) 信息素更新公式:

$$\tau_j(t + T_j) = \rho \cdot \tau_j(t) + \Delta\tau_j; \Delta\tau_j = \sum_{k=1}^m \Delta\tau_j^k,$$

$$\Delta\tau_j^k = \begin{cases} Q / |S| & \text{若蚂蚁 } k \text{ 经过 } j \\ 0 & \text{否则} \end{cases},$$

式中, ρ 表示信息素持久性, $1 - \rho$ 表示信息消逝程度. $\Delta\tau_j^k$ 表示第 k 只蚂蚁在本次求解中留在集合 j 上的信息素, $\Delta\tau_j$ 表示本次循环集合 j 上信息增量, $|S|$ 表示第 k 只蚂蚁寻找到的集合覆盖包含的子集个数, Q 为常数.

3 双重扰动学习算法

Valentini 研究了对模型参数进行扰动后支持向量机的期望误差、偏差和方差的变化趋势^[4]. 期望误差 $Err = E^*[L(y, t)]$ 在“0-1”损失函数 $L(y, t)$ 下可以分解成 3 项, 即

$$Err = E^*[N(x)] + E^*[B(x)] + E^*[V(x)] \quad (5)$$

式中, $N(x)$, $B(x)$ 和 x 分别表示期望误差的固有噪声部分、偏差部分和方差部分.

Valentini 的实验结论指出, 扰动模型参数能够显著影响支持向量机的期望误差、偏差和方差. 并且, 模型参数在 (σ, C) 的取值空间内, 存在一个“低偏差区域”, 使得 (σ, C) 在该区域内取值时, 产生的基分类器具有低偏差的特性. 据此 Valentini 设计了一种集成算法, 称其为“低偏差 Bagging”. 通过在“低偏差区域”随机扰动模型参数, 一方面可以使基分类器具有低偏差的特点; 另一方面, 基分类器之间由于模型参数不同而具有一定的差异性, 最后还可以通过多数投票法缩减方差. 因此, 产生的分类器同时具有低偏差和低方差的特点, 根据式(5)的解释, 它容易获得更好的泛化性能.

属性约简集成和参数模型集成的关键是分别在输入特征空间和参数模型的“低偏差区域”进行扰动, 两种方法扰动机制不同, 故可以进行组合以产生更大的差异性, 目的是进一步提高集成输出的泛化能力. 双重扰动下支持向量机学习算法为:

输入: 故障特征决策表 $S = \{U, C \cup D, V, f\}$, 其中 U 为故障样本空间 $\{x_i\} (i = 1, 2, \dots, l)$, C 为故障特征的条件属性集合, D 为故障类别 $y_j (j = 1, 2, \dots, c)$;

输出: 集成 f_E ;

Step1: 采用 RSBRA 对属性离散化, 并进行归一化处理, 建立离散决策表 $S^* = \{U, C \cup D, V, f\}$.

Step2: 对 $S^* = \{U, C \cup D, V, f\}$ 用混沌蚁群算法进行属性约简, 获得 $M (M > 1)$ 个约简结果, 记为 $S_m = \{U, C_m \cup D_m, f_m\}, m = 1, 2, \dots, M$;

Step3: for $m = 1, 2, \dots, M$

Step4: for $n = 1, 2, \dots, N$

Step5: 从低偏差区域中随机选取模型参数对 (σ^n, C^n) ;

Step6: 以 (σ^n, C^n) 作为模型参数在 $S_m = \{U, C_m \cup D_m, f_m\}$ 上训练基分类器 f_{mn} ;

Step7: 将 f_{mn} 按多数投票法获得 $S_m = \{U, C_m \cup D_m, f_m\}$ 空间的集成分类器 f_E^m ;

Step8: end

Step8: 将 f_E^m 按多数投票法获得最终的集成 f_E

Step9: end

算法设计说明:

(1) 采用一对多法组合多类分类支持向量机.

(2) 采用试探法选择“低偏差区域”内的模型参

数. 首先由5倍交叉验证法得到最优模型参数 (σ^0, C^0) , 由文献[4]中的定义求偏差 $(E[B(x)])^0$, 然后在 (σ, C) 平面内搜索 (σ^i, C^i) , 若 $(E[B(x)])^i \leq (E[B(x)])^0$, 则说明 (σ^i, C^i) 位于“低偏差区域”。

(3) 采用内外嵌套两层集成. 针对每个约简结果形成的特征子空间, 进行模型参数扰动, 利用多数投票法得到内层集成结果 $f_{E^m}^*$, 再对 $f_{E^m}^*$ ($m = 1, 2, \dots, M$) 使用多数投票法进行外层集成得到最终结果 f_E . 多数投票法能有效缩减方差, 而采用内外嵌套两层集成能实现方差更大程度地减小, 进一步提高了集成的泛化性能。

4 模拟电路故障诊断实例

通过 Sallen-Key 带通滤波器为故障诊断实例, 验证本文算法的可行性和有效性. 电路图如图 1 所示。




图1 25 kHz Sallen-Key 带通滤波器电路图

元件的标称值为: $R_1 = 3 \text{ k}\Omega$, $R_2 = 1 \text{ k}\Omega$, $R_3 = 4 \text{ k}\Omega$, $R_4 = 2 \text{ k}\Omega$, $R_5 = 4 \text{ k}\Omega$, $C_1 = C_2 = 5 \text{ nF}$, 设电阻的容差为 10%, 电容的容差为 5%。电路分析仿真使用 Multisim7 电路仿真平台。

对电路进行灵敏度分析, 发现 R_1, R_4, C_1, C_2 发生变化时, 对电路的频率响应产生的影响比较大. 假设该电路发生单个软故障时, 该器件的值高于或者低于标称值的 50%, 又假设电路发生四类单软故障分别是: C_1 增故障, $C_1 = 7.5 \text{ nF}$; C_2 减故障, $C_2 = 2.5 \text{ nF}$; R_1 增故障, $R_1 = 4.5 \text{ k}\Omega$; R_4 减故障, $R_4 = 1 \text{ k}\Omega$. 在这四种故障和无故障五种状态下电路的幅频响应如图 2 所示。

提取电路幅频响应曲线上的离散点为故障特征, 对响应曲线上位于区间 $[1, 1000] \text{ kHz}$ 的 16 个点进行采样作为原始故障特征值, 每个样本含有 16 个属性. 对于电路的正常状态和各种故障状态分别进行 100 次蒙特卡洛仿真获得故障样本, 共有 5 类样本数据. 从每类样本中随机选取 50 个样本组成决策表, 剩余样本用于测试. 利用 ROSETTA 工具进行离散化, 然后采用混沌蚁群算法进行属性约简, 其




图2 25 kHz Sallen-Key 带通滤波器幅频响应曲线

结果共有 19 个, 核属性为 $\{25k, 800k\}$. 约简结果比较多表明原始故障样本中含有大量冗余属性. 当原特征空间含有大量冗余属性时, 在特征子空间进行训练的基分类器有显著的差异性, 所以对故障样本经属性约简进行特征空间扰动是合理的。

将基于混沌蚁群算法和蚁群算法的属性约简方法进行比较, 两种算法的收敛曲线如图 3 所示. 参数设置为: 启发式函数调节系数 $a = b = c = 1$, 初始信息素控制参数 $k = 3$, 模式种类 $r = 5$, 属性个数 $n = 16$, 初始蚂蚁个数 $m = 16$, $\alpha = 1.4$, $\beta = 1.9$, $\rho = 0.9$, $Q = 1$, 最大迭代数 $NC_{\max} = 110$ 。




图3 算法收敛曲线

由图 3 可知, 两种方法都可以找到最优解 (包含 5 个特征), 比较而言, 本文算法在算法运行初期收敛速度比较快, 迭代 45 次即可找到最优解, 而基本蚁群算法需要迭代 60 次, 说明由混沌算法生成的初始信息素分布有助于加速算法收敛。

实验时, 支持向量机的核函数使用高斯核函数, 采用 5 倍交叉验证法得到各个基分类器的最优模型参数 (σ^0, C^0) , 然后通过试探法获得 5 个位于“低偏差区域”的参数 (σ^i, C^i) , 采用多数投票法对每个特征子空间的基分类器集成, 最后, 再次采用多数投票法对所有特征子空间的结果进行二次集成得到最终结果。

分别使用本文算法与多分类支持向量机 (一对多方法组合而成), Bagging 算法, AB 算法^[3]对测试

样本进行故障诊断,10 次实验,取平均值. 结果如表 1 所示.

实例表明:Bagging 方法集成的差异性主要来自对样本空间的扰动,应用于不稳定学习算法效果比较明显,但用于稳定学习算法效果不好,当样本达不到一定数量,其预测精度比一般多分类支持向量机还要低.

表 1 测试结果比较				%
	SVM	Bagging	AB	本文方法
$[R_4 \downarrow]$	94	92	94	96
$[R_1 \downarrow]$	94	90	92	98
$[C_1 \uparrow]$	90	92	94	100
$[C_2 \downarrow]$	90	94	96	94
无故障	92	88	92	98
平均	92	91.2	93.6	97.2

AB 算法是基于特征空间扰动的集成方法,对于含有较多冗余属性的样本具有较高的泛化精度,从表 1 可以看出 AB 算法的预测精度要高于多分类支持向量机和 Bagging 算法.

本文算法具有最高泛化精度,原因一是在结合了特征空间扰动和模型参数扰动后,利用本文算法训练的基分类器在保证较高分类精度的前提下具有较大的差异性,二是利用多数投票法进行两次集成能更大程度上减小集成输出的方差.

5 结束语

作为稳定算法,支持向量机对样本空间扰动不敏感,但对特征空间和模型参数空间的扰动比较敏感,据此特点,提出基于特征空间和模型参数空间双重扰动的支持向量机算法并在国际标准电路中进行验证,结果显示了本文方法的优越性. 模拟电路故障

特征形成的决策表,属性大多为连续值,而离散化不当会破坏数据的原始分类能力,因此,广义粗糙集模型下支持向量机连续属性约简集成及其在模拟电路故障诊断中的应用将是进一步研究的内容.

参考文献:

[1] 廖薇,许春冬,刘锦高. 基于神经网络的模拟电路故障诊断研究[J]. 微电子学与计算机,2010,27(5):125-128.

[2] 刘美华,彭良玉. 基于小波分析和信息融合技术的故障诊断[J]. 微电子学与计算机,2009,26(1):166-168.

[3] Robert B, Ricardo G O, Francis Q. Attribute Bagging: Improving accuracy of classifier ensembles by using random feature subsets[J]. Pattern Recognition, 2003, 36(6):1291-1302.

[4] Valentini G, Dietterich T. Bias - variance analysis of support vector machines fo the develop ment of SVM-based ensemble methods[J]. J of Machine Learning Research, 2004, 5(6): 725-775.

[5] 陈彩云,李治国. 关于属性约简和集合覆盖问题的探讨[J]. 计算机工程与应用,2004,(2):44-47.

[6] 权光日,洪炳溶,叶风,等. 集合覆盖的启发函数算法[J]. 软件学报,1998,9(2):156-160.

[7] 张浩,张铁男,沈继红,等. Tent 混沌粒子群算法及其在结构优化决策中的应用[J]. 控制与决策,2008,23(8): 857-862.

作者简介:

马 超 男,(1983-),博士研究生. 研究方向为防空导弹模拟电路智能故障诊断方法.

陈西宏 男,(1961-),博士,教授,博士生导师. 研究方向为防空导弹武器系统信息技术与智能故障诊断方法等.

姚懿玲 女,(1982-),硕士. 研究方向为防空导弹通用测试技术.

韩 明 男,(1982-),硕士. 研究方向为防空导弹故障诊断方法.

(上接第 16 页)

[6] 韦耿,王亮,朱斌. 无线移动环境视频编码动态功耗模型研究[J]. 传感技术学报,2009,22(3): 354-357.

[7] Ortega A, Ramchandran K. Rate - distortion methods for image and video compression[J]. IEEE Signal Processing Magazine, 1998, 15(6): 23-50.

[8] SMPTE Standard for Television: Compressed Video Bitstream Format and Decoding Process (VC1)[S]. White Plains, NY: The Society of Motionpicture and Television Engineers, 2003.

作者简介:

韦 耿 男,(1977-),博士,博士后. 研究方向为多媒体信息处理.

吴乐南 男,(1964-),教授,博士生导师. 研究方向为多媒体信息处理及通信信号处理.

朱 斌 男,(1981-),博士生,讲师. 研究方向为多媒体信息处理.