

多分类 SVM 的代价敏感加权故障诊断方法*

向阳辉¹, 张千清¹, 庞佑霞¹, 郭振华²

(1. 长沙学院机电工程系 长沙, 410003) (2. 宁波高博科技有限公司 宁波, 315400)

摘要 为了在支持向量机(support vector machine, 简称 SVM)中合理引入代价敏感机制来降低故障误诊断的代价, 提出一种多分类 SVM 的代价敏感加权故障诊断方法。该方法通过对多分类 SVM 的硬判决得票矩阵进行代价敏感加权, 将故障误诊断的代价作为权重融入 SVM 的硬判决, 并分析硬判决的得票数和得票权重, 从而构造出各故障的概率分配, 最终实现多分类故障的 SVM 代价敏感加权诊断及概率输出。实验结果表明, 多分类 SVM 代价敏感加权处理的诊断结果更趋向于高代价故障, 所提方法能够有效降低故障误诊断的代价。

关键词 代价敏感; 支持向量机; 故障诊断; 代价矩阵; 加权

中图分类号 TP206.3; TH165.3; TH132.41

引言

在工业生产过程中, 不同故障对设备的危害程度通常是不同的, 即故障误诊断所带来的代价(损失)存在较大差异^[1-2]。如果将存在故障的设备误诊断为正常, 将会延误故障处理, 危害设备安全, 造成巨大经济损失, 甚至危及人身安全; 反之虽也需花费人力、物力来处理该误报故障, 但相比前者所付出的代价显著降低。同样, 将高危害故障误诊断为低危害故障也要比相反情况付出更高的代价。因此在实际故障诊断中, 不能只追求最大化诊断正确率, 而应以误诊断代价最小化为故障诊断目标。面向实际问题的代价敏感故障诊断已经被看作是未来故障诊断领域的重要研究方向^[3-4]。

为了有效提升故障诊断性能, 降低故障误诊断代价, 在故障诊断领域已提出了许多代价敏感学习算法^[5-6]。其中, 由于支持向量机是基于结构风险最小化原则, 具有小样本学习能力和较好的泛化能力^[7-9]等优越性, 因此将 SVM 与代价敏感相结合应用于故障诊断研究具有非常重要的实际意义。文献^[10-12]已经对 SVM 的代价敏感故障诊断进行了研究, 提出了一些 SVM 的代价敏感改进算法, 取得了良好效果, 较好地解决了二分类故障问题。这些算法在解决多分类故障问题时都存在困难, 且无

法得到故障分类的概率输出。

笔者为了在 SVM 中合理引入代价敏感机制来降低故障误诊断的代价, 着重研究多分类 SVM 与代价敏感结合的问题。通过对多分类 SVM 的硬判决得票矩阵进行代价敏感加权处理, 将故障误诊断的代价作为权重合理融入 SVM 的硬判决, 并综合分析硬判决得票数和得票权重构造出各故障的概率分配, 实现多分类故障的 SVM 代价敏感加权诊断及概率输出, 提出了一种多分类 SVM 的代价敏感加权故障诊断方法。通过转子实验测试, 验证了该方法的有效性。

1 支持向量机及其代价敏感加权

1.1 代价敏感学习

代价敏感学习是近年来机器学习和数据挖掘领域的一个新的研究热点^[4,6,12]。在代价敏感学习中, 假设有 n 类样本, 代价矩阵定义为 $C(i, j)$, 表示将第 i 类样本误分为第 j 类时的代价, 通常 $C(i, j) \neq C(j, i)$ 。当正确分类时代价为 0, 即 $C(i, i) = 0$ 。

以二分类问题为例, 误分类代价所用的代价矩阵如表 1 所示。其中: T_P 为正例分类是正例的代价; F_P 为反例分类是正例的代价; F_N 为正例分类是反例的代价; T_N 为反例分类是反例的代价。正确分类代价 $T_P = T_N = 0$ 。

* 国家自然科学基金资助项目(51475049); 高校人才引进科研基金资助项目(12004); 湖南省“十二五”重点建设学科资助项目(2012); 湖南省教育厅科研资助项目(15C0123, 14C0094)

收稿日期: 2014-09-19; 修回日期: 2014-12-17

表1 二分类问题代价矩阵

Tab.1 Cost matrix for binary classification problems

种类	预测的正例	预测的反例
真实的正例	$C(1,1)$ 或 T_P	$C(1,0)$ 或 F_N
真实的反例	$C(0,1)$ 或 F_P	$C(0,0)$ 或 T_N

代价敏感评价指标有全局误分代价 β 和平均误分代价 ρ 等

$$\beta = F_P |F_P| + F_N |F_N| \quad (1)$$

$$\rho = \frac{F_P |F_P| + F_N |F_N|}{|T_P| + |T_N| + |F_P| + |F_N|} \quad (2)$$

其中: $|\cdot|$ 表示分类样本个数,如 $|F_P|$ 表示反例分类为正例的个数。

1.2 支持向量机理论

SVM是建立在统计学习理论和结构风险最小化原理基础上的新型机器学习方法^[13],其分类方法的实质就是寻找一个最优分类超平面,使得从这个超平面到两类样本集的距离之和(即分类间隔)最大。

假定2类线性可分样本集 (x_i, y_i) ($x_i \in R^d; y_i \in \{-1, +1\}; i=1, 2, \dots, n$), SVM把寻找分类间隔最大的最优超平面问题转化为求解凸二次优化问题

$$\begin{cases} \min & \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s. t.} & y_i [(\omega x_i) + b] \geq 1 - \xi_i \end{cases} \quad (3)$$

其中: ω 为权重向量; b 为偏置; ξ 为松弛因子; C 为惩罚因子。

当式(3)中 $y_i [(\omega x_i) + b] \geq 1 - \xi_i$ 的等号成立时,对应的样本称之为支持向量。它是由训练样本集的一个子集样本向量构成的展开式。从训练集中得到了描述最优分类超平面的决策函数即支持向量机,它的分类功能由支持向量决定。

对于线性可分问题,求解得到决策函数

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^k \alpha_i y_i (x, x_i) + b \right\} \quad (4)$$

其中: α_i 为拉氏乘子; k 为支持向量数目。

若样本集 (x_i, y_i) ($x_i \in R^d; y_i \in \{-1, +1\}; i=1, 2, \dots, n$)线性不可分,可以通过非线性变换映射到某个高维的特征空间,即用核函数 $K(x, x_i)$ 代替原空间的内积,使得其在该高维空间下线性可分

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^k \alpha_i y_i K(x, x_i) + b \right\} \quad (5)$$

标准SVM解决的是二分类问题,而故障诊断等领域需要解决的是多分类问题。目前已经提出一些有效的多分类支持向量机,包括一对多、一对一、

有向无环图、二叉树和纠错编码等。

1.3 SVM的代价敏感加权

标准SVM解决的是二分类问题,其输出结果为硬判决输出 $[+1, -1]$ 。假定在标准SVM二分类 (A_i, A_j) 问题中,定义 $F(A_i, A_j)$ 表示故障样本是否属于 A_i 类的标准SVM硬判决投票输出,如果故障样本判定属于 A_i 类,则向 A_i 类投票 $F(A_i, A_j) = 1$,不向 A_j 类投票 $F(A_j, A_i) = 0$;如果判定属于 A_j 类,则向 A_j 类投票 $F(A_j, A_i) = 1$,不向 A_i 类投票 $F(A_i, A_j) = 0$ 。标准SVM二分类判决,故障样本只能判定属于某一类,即 $F(A_i, A_j)$ 和 $F(A_j, A_i)$ 只能有一个为1,另一个为0。

为了合理考虑故障误诊断代价的差异,对标准SVM硬判决的投票输出进行代价敏感加权, $C(A_i, A_j)$ 表示把 A_i 类故障误诊断为 A_j 类的代价,则标准SVM二分类问题的代价敏感加权的硬判决投票权重输出 F_c 为

$$\begin{cases} F_c(A_i, A_j) = F(A_i, A_j) C(A_i, A_j) \\ F_c(A_j, A_i) = F(A_j, A_i) C(A_j, A_i) \end{cases} \quad (6)$$

$F_c(A_i, A_j)$ 为故障样本是否属于 A_i 类的标准SVM硬判决投票权重输出,如果判定属于 A_i 类,则 $F_c(A_i, A_j)$ 有权重输出,其权重输出等于 A_i 类误诊断为 A_j 类的代价,它表示故障样本是属于 A_i 类,且SVM也正确地将其判决投票给了 A_i 类的重要程度, A_i 类误诊断为 A_j 类的代价越大,该次判决投票为 A_i 类的重要程度就越高;如果判定不属于 A_i 类,则 $F_c(A_i, A_j) = 0$,其该次判决投票为不属于 A_i 类(即该次判决投票属于 A_j 类)的重要程度就由 $F_c(A_j, A_i)$ 的权重输出进行体现。同样,在标准二分类SVM判决中,故障样本只能判定属于某一类,即 $F_c(A_i, A_j)$ 和 $F_c(A_j, A_i)$ 只能有一个有权重输出,另一个为0。

由此可见,在进行代价敏感加权前,标准SVM硬判决输出结果为 $+1$ 或 -1 ,没有权重差异;而进行代价敏感加权后,误诊断代价作为权重有效融入标准SVM硬判决加权输出 F_c ,充分体现了误诊断代价的差异。当然这种代价敏感加权在标准SVM二分类问题中并没有实际意义,但在故障诊断等多分类问题中,通过后续处理能够对诊断结果产生积极影响,能有效降低故障误诊断的代价。

2 SVM代价敏感加权的故障诊断应用模型

2.1 SVM代价敏感加权诊断应用框架

本研究中多分类支持向量机的代价敏感加权故

障诊断过程可分为3大模块:a. 信号预处理模块;b. 多分类SVM代价敏感加权处理模块;c. 多分类SVM概率输出及诊断决策模块。其应用框架如图1所示。

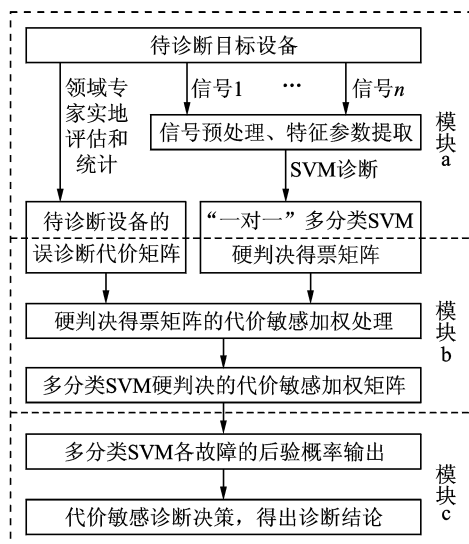


图1 SVM的代价敏感加权故障诊断应用框架

Fig. 1 The application frame of the weighted cost-sensitive fault diagnosis of SVM

1) 预处理模块。对待诊断目标设备进行信号采集、故障特征参数提取等,并按传统“一对一”多分类SVM故障诊断方法进行诊断,得到其硬判决得票矩阵;同时领域专家实地评估和统计目标设备的各故障代价,建立该设备的误诊断代价矩阵。

2) 多分类SVM代价敏感加权处理模块。对“一对一”多分类SVM硬判决得票矩阵按误诊断代价矩阵进行代价敏感加权处理,得到多分类SVM硬判决的代价敏感加权矩阵。

3) 多分类SVM概率输出及诊断决策模块。对硬判决加权矩阵进行分析,综合考虑各故障的硬判决得票数和得票权重,合理构造出各故障的概率输出,并按相应诊断决策规则得出最终诊断结论。

2.2 SVM的代价敏感加权处理

故障诊断领域需要解决的通常都是多分类问题,笔者采用“一对一”多分类SVM方法进行处理。假设辨识框架中共有 n 类故障模式 $\{A_1, A_2, \dots, A_n\}$,通过“一对一”两两分类方法建立起该多分类故障SVM的硬判决得票矩阵 F

$$F = \begin{bmatrix} F(A_1, A_1) & F(A_1, A_2) & \cdots & F(A_1, A_n) \\ F(A_2, A_1) & F(A_2, A_2) & \cdots & F(A_2, A_n) \\ \vdots & \vdots & & \vdots \\ F(A_n, A_1) & F(A_n, A_2) & \cdots & F(A_n, A_n) \end{bmatrix}$$

$F(A_i, A_j)$ 表示故障样本如果属于 A_i 类则投票 $F(A_i, A_j)=1$,否则不投票 $F(A_i, A_j)=0$ 。当 $i=j$ 时, $F(A_i, A_j)$ 没有实际意义,为了便于矩阵 F 的后续处理设定其等于0。矩阵 F 的第1行表示第 A_1 类与其他类两两分类的SVM硬判决得票结果;矩阵 F 的第 n 行表示第 A_n 类与其他类两两分类的SVM硬判决得票结果。

同时,领域专家实地评估和统计目标设备的各故障代价,建立起该设备的误诊断代价矩阵 C

$$C = \begin{bmatrix} C(A_1, A_1) & C(A_1, A_2) & \cdots & C(A_1, A_n) \\ C(A_2, A_1) & C(A_2, A_2) & \cdots & C(A_2, A_n) \\ \vdots & \vdots & & \vdots \\ C(A_n, A_1) & C(A_n, A_2) & \cdots & C(A_n, A_n) \end{bmatrix}$$

$C(A_i, A_j)$ 表示把 A_i 类误诊断为 A_j 类的代价。当 $i=j$ 时, $C(A_i, A_j)$ 表示诊断正确,其代价为0。矩阵 C 的第1行表示把 A_1 类误诊断为其他类的代价值;矩阵 C 的第 n 行表示把 A_n 类误诊断为其他类的代价值。

投票矩阵 F 和代价矩阵 C 都是 $n \times n$ 维矩阵,两矩阵对应位置元素体现的都是各故障模式两两之间对应的相互关系。为了对“一对一”多分类SVM的硬判决得票矩阵 F 按各故障模式的误诊断代价矩阵 C 进行代价敏感加权处理,将矩阵 F 和 C 中对应各元素按式(6)进行计算,从而得到该多分类故障SVM硬判决的代价敏感加权矩阵 F_c

$$F_c = \begin{bmatrix} F_c(A_1, A_1) & F_c(A_1, A_2) & \cdots & F_c(A_1, A_n) \\ F_c(A_2, A_1) & F_c(A_2, A_2) & \cdots & F_c(A_2, A_n) \\ \vdots & \vdots & & \vdots \\ F_c(A_n, A_1) & F_c(A_n, A_2) & \cdots & F_c(A_n, A_n) \end{bmatrix}$$

$F_c(A_i, A_j)$ 表示故障样本两两分类属于 A_i 类的得票权重。当 $i=j$ 时, $F_c(A_i, A_j)$ 没有实际意义,其得票权重为0。矩阵 F_c 的第1行表示第 A_1 类与其他类两两分类的SVM硬判决得票权重输出;矩阵 F_c 的第 n 行表示第 A_n 类与其他类两两分类的SVM硬判决得票权重输出。

2.3 多分类支持向量机的概率输出及诊断决策

笔者为了有效降低故障误诊断的代价,同时兼顾故障诊断的准确率,需综合合理考虑多分类SVM的硬判决得票数和得票权重,可先分别计算其得票隶属度和权重隶属度,再构造其概率输出。

将第 A_i 类的得票总权重与该类的误诊断总代价之比定义为该类故障的得票隶属度 $q'(A_i)$

$$\begin{cases} q'(A_i) = \frac{\sum_{j=1}^n F_c(A_i, A_j)}{\sum_{j=1}^n C(A_i, A_j)} \\ q'(\Theta) = 1 - \max\{q'(A_1), q'(A_2), \dots, q'(A_n)\} \end{cases} \quad (7)$$

如果第 A_i 类参与的 SVM 两两分类判定属于第 A_i 类的得票数越多,则 $q'(A_i)$ 值越大。 $q'(\Theta)$ 表示得票判定的不确定隶属度,得票数越集中, $q'(\Theta)$ 值越小。

将第 A_i 类的得票总权重与辨识框架中各类故障的误诊断总代价最大值之比定义为该类故障的权重隶属度 $q''(A_i)$

$$\begin{cases} q''(A_i) = \frac{\sum_{j=1}^n F_c(A_i, A_j)}{\max_{i=1}^n \{\sum_{j=1}^n C(A_i, A_j)\}} \\ q''(\Theta) = 1 - \max\{q''(A_1), q''(A_2), \dots, q''(A_n)\} \end{cases} \quad (8)$$

如果第 A_i 类参与的 SVM 两两分类获得的得票权重越大,则 $q''(A_i)$ 值越大; $q''(\Theta)$ 表示权重判决的不确定隶属度,得票权重越集中, $q''(\Theta)$ 值越小。

第 A_i 类故障的综合隶属度 $q(A_i)$ 定义为得票隶属度 $q'(A_i)$ 与权重隶属度 $q''(A_i)$ 之和,即

$$\begin{cases} q(A_i) = (2 - k)q'(A_i) + kq''(A_i) \\ q(\Theta) = (2 - k)q'(\Theta) + kq''(\Theta) \end{cases} \quad (9)$$

其中: k 为平衡系数, $0 \leq k \leq 2$ 。

k 是用来调节误诊断代价作为权重对故障诊断结果影响的尺度, k 值越大则误诊断代价矩阵 C 对故障诊断结果的影响越大。本实例为了兼顾故障诊断的准确率和故障误诊断的代价,平衡系数 k 取 1。

综合隶属度 $q(A_i)$ 越大,则故障样本属于第 A_i 类的可能性越大, $m(A_i)$ 得到的概率输出也应越大,可以构造如下公式得到各故障模式的概率分配

$$\begin{cases} m(A_i) = \frac{q^M(A_i)}{q^M(\Theta) + \sum_{i=1}^n q^M(A_i)} \\ m(\Theta) = 1 - \sum_{i=1}^n m(A_i) \end{cases} \quad (10)$$

其中: M 表示多分类 SVM 的规模,多分类规模越大 M 值应越大。

定义 M 为

$$M = \sum_{i=1}^n q(A_i) + q_\Theta \quad (11)$$

根据各故障的概率输出, $m(A_i)$ 可由以下诊断决策规则判定得出最终的诊断结论 A_j :

- 1) $m(A_j) = \max\{m(A_i), A_i \subseteq \Theta\}$;
- 2) $m(A_j) - m(A_i) > \epsilon; m(A_j) > m(\Theta)$;
- 3) $m(\Theta) < \gamma$ 。

规则 1 是诊断的基本条件,即所判定故障模式具有最大的概率输出;规则 2 表明所判定故障模式的概率输出必须比其他故障模式的概率输出大 ϵ ,即占有相当优势;规则 3 表明不确定度必须小于 γ ,保证故障样本是充分可判断的。其中, ϵ 和 γ 应根据实际情况确定。

3 实验分析

在转子实验台上分别进行不平衡、不对中、油膜涡动、径向碰磨和转子正常 5 种故障状态的代价敏感故障诊断识别研究。系统辨识框架为 $\Theta = \{F_1, F_2, F_3, F_4, F_5\}$ 。其中: F_1 为不平衡状态; F_2 为不对中状态; F_3 为油膜涡动状态; F_4 为径向碰磨状态; F_5 为正常状态。为了更有效地进行实验分析,所有样本数据都加入了占信号幅值 10% 左右的白噪声信号。

由于在实际生产过程中,旋转机械故障所带来的代价(损失)涉及人力、物力等许多因素,为了使各故障之间的误诊断代价更加合理,一般需要领域专家实地评估和统计才能给出。在本研究的实验分析中,直接引用文献[14]给出的故障误诊断代价矩阵,如表 2 所示。

表 2 故障误诊断代价矩阵

Tab. 2 The cost matrix of failure mistaken diagnosis

真实状态	预测状态				
	F_1	F_2	F_3	F_4	F_5
F_1	0	2	2	2	4
F_2	3	0	3	3	5
F_3	6	6	0	6	9
F_4	7	7	7	0	10
F_5	1	1	1	1	0

分析辨识框架中 5 种故障模式的发生机理,基于频域小波能量分析特征向量(E_1, E_2, \dots, E_6)搭建“一对一”多分类 SVM 进行故障诊断,其投票判决过程如图 2 所示。现取该转子一组实测信号样本,如图 3 所示。首先,输入到上述已搭建好的 SVM 进行故障诊断;其次,得到多分类故障的 SVM 硬判决得票矩阵,如表 3 所示;然后,根据式(6)进行代价敏感加权处理得到 SVM 代价敏感加权矩阵,如表 4 所示;最后,根据式(7)~式(11)计算得出各故障的综合隶属度和概率输出,如表 5 所示。

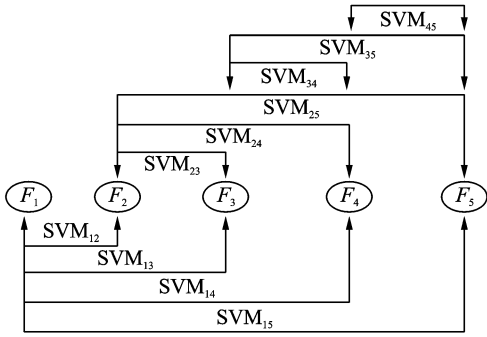


图 2 “一对一”多分类 SVM 的投票判决过程图

Fig. 2 The figure of vote judgment course for one-to-one multi-classification SVM




图 3 实测信号样本图

Fig. 3 The figure of actual measurement signal samples

表 3 SVM 硬判决得票矩阵

Tab. 3 The votes matrix of the hard decision of SVM

F_i	F_j					F_i 得票数
	F_1	F_2	F_3	F_4	F_5	
F_1	0	1	1	0	0	2
F_2	0	0	1	1	0	2
F_3	0	0	0	1	0	1
F_4	1	0	0	0	1	2
F_5	1	1	1	0	0	3

表 4 SVM 代价敏感加权矩阵

Tab. 4 The weighted cost-sensitive matrix of SVM

F_i	F_j					F_i 总权重
	F_1	F_2	F_3	F_4	F_5	
F_1	0	2	2	0	0	4
F_2	0	0	3	3	0	6
F_3	0	0	0	6	0	6
F_4	7	0	0	0	10	17
F_5	1	1	1	0	0	3

表 5 各故障的综合隶属度和概率输出

Tab. 5 The comprehensive membership and probability output of each fault

参数	F_1	F_2	F_3	F_4	F_5	Θ
q_i	0.529 0	0.622 1	0.415 8	1.096 8	0.846 8	0.701 6
m_i	0.028 2	0.055 8	0.010 2	0.608 4	0.204 6	0.092 7

从表 3 可以看出, F_5 的得票数为 3; F_1, F_2, F_4 的得票数都为 2。如果仅从得票数来看, 故障样本应判定为 F_5 。但由于各故障状态的得票数都偏低, F_5 相对于其他状态(如 F_1, F_2, F_4) 的得票优势并不大, 即该诊断判定的可信度偏低, 故障误诊断的可能性比较大。此时应充分考虑各故障误诊断的代价差距, 应尽量避免把代价高的故障(如 F_4, F_3) 误诊断为代价低的故障(如 F_5), 判决结果应更倾向于代价高的故障。从表 5 可以看出, 综合考虑各故障误诊断的代价并进行代价敏感加权处理后, F_4 的概率输出为 0.608 4, F_5 的概率输出为 0.204 6, 最终故障判定为 F_4 。由此可见, 多分类故障 SVM 通过代价敏感加权处理后能够使得判决结果更倾向于代价高的故障, 有利于降低故障误诊断的代价。

为了评估该代价敏感故障诊断方法的性能, 选取不同故障状态典型样本各 100 组进行故障诊断测试。传统“一对一”多分类 SVM 故障诊断方法(票数相同时按文献[15]进行二次细分处理) 诊断得到的混淆矩阵如表 6 所示; 笔者所提代价敏感 SVM 故障诊断方法($\epsilon=0.35, \gamma=0.15$) 诊断得到的混淆矩阵如表 7 所示; 再根据表 6、表 7 统计得到这两种方法的识别正确率对比如表 8 所示; 同时根据式(1)、式(2) 计算得到这两种方法的全局误分代价和平均误分代价对比如表 9 所示。

表 6 传统 SVM 故障诊断混淆矩阵

Tab. 6 The confused matrix of fault diagnosis of traditional SVM

真实状态	预测状态					各类样本总数
	F_1	F_2	F_3	F_4	F_5	
F_1	83	4	3	5	5	100
F_2	5	79	4	6	6	100
F_3	5	2	80	4	9	100
F_4	4	4	5	77	10	100
F_5	3	3	4	5	85	100

表 7 代价敏感 SVM 故障诊断混淆矩阵

Tab. 7 The confused matrix of fault diagnosis of cost-sensitive SVM

真实状态	预测状态					各类样本总数
	F_1	F_2	F_3	F_4	F_5	
F_1	78	5	6	7	4	100
F_2	4	80	6	6	4	100
F_3	3	4	84	5	4	100
F_4	3	3	4	87	3	100
F_5	4	7	6	9	74	100

表 8 故障诊断识别正确率对比

Tab. 8 The contrast of the correct recognition rate between two fault diagnoses

诊断方法	F_1	F_2	F_3	F_4	F_5	总识别率
传统 SVM	0.83	0.79	0.80	0.77	0.85	0.808 0
代价 SVM	0.78	0.80	0.84	0.87	0.74	0.806 0

表 9 故障诊断误分代价对比

Tab. 9 The contrast of the incorrect recognition rate between two fault diagnoses

诊断方法	全局误分代价	平均误分代价
传统 SVM	472	0.944
代价 SVM	354	0.708

从表 8 可以看出,多分类故障 SVM 通过代价敏感加权处理后,代价高的故障识别正确率有所提升(F_3 从 0.80 提升到 0.84; F_4 从 0.77 提升到 0.87),代价低的故障识别正确率却有所下降(F_1 从 0.83 下降到 0.78; F_5 从 0.85 下降到 0.74),但故障诊断的总识别正确率变化不大。从表 9 可以看出,代价敏感加权处理能够显著降低故障误诊断的全局误分代价和平均误分代价(全局误分代价从 472 下降到 354,平均误分代价从 0.944 下降到 0.708)。由此可见,代价敏感 SVM 故障诊断方法是以牺牲代价低的故障的识别正确率来提升代价高的故障的识别正确率,故障诊断的总识别正确率并没有得到改善(也许还会稍有下降),但该方法确实能够有效降低故障误诊断的代价。

4 结 论

1) 充分考虑了故障误诊断代价的差异,通过对多分类 SVM 的硬判决得票矩阵进行代价敏感加权,将故障误诊断的代价作为权重合理融入了 SVM 的硬判决,从而有效实现了多分类故障的 SVM 代价敏感加权处理。

2) 综合分析了多分类 SVM 的硬判决得票数 and 得票权重,提出了一种多分类 SVM 概率分配的构造方法,实现了多分类故障的 SVM 诊断结果概率输出。

3) 为了在 SVM 中合理引入代价敏感机制来有效降低故障误诊断的代价,提出了一种多分类 SVM 的代价敏感加权故障诊断方法。通过转子实验测试表明,多分类 SVM 的代价敏感加权处理能够确保

在较高诊断正确率的情况下,使得诊断结果更倾向于高代价故障,从而显著降低了故障诊断的全局误分代价和平均误分代价,充分验证了该方法的有效性。

参 考 文 献

- [1] Rasmussen C E, Williams C K I. Gaussian processes for machine learning[M]. Cambridge, London: The MIT Press, 2006;3-5.
- [2] 吴薇,胡静涛.基于代价敏感直推式学习的故障诊断方法[J].仪器仪表学报,2010,31(5):1023-1027.
Wu Wei, Hu Jingtao. Fault diagnosis based on cost-sensitive transduction inference [J]. Chinese Journal of Scientific Instrument, 2010, 31(5): 1023-1027. (in Chinese)
- [3] Saitta L. Machine learning: a technological roadmap [R]. Netherlands: University of Amsterdam, 2000.
- [4] 尹金良,朱永利,郑晓雨,等.代价敏感 VBG 在变压器故障诊断中的应用[J].电工技术学报,2014,29(3):222-227.
Yin Jinliang, Zhu Yongli, Zheng Xiaoyu, et al. Cost-sensitive gaussian process classification with variational bayesian treatment for fault Diagnosis of power transformers[J]. Transactions of China Electrotechnical Society, 2014, 29(3): 222-227. (in Chinese)
- [5] 唐明珠,阳春华,桂卫华,等.代价敏感概率神经网络及其在故障诊断中的应用[J].控制与决策,2010,25(7):1074-1078.
Tang Mingzhu, Yang Chunhua, Gui Weihua, et al. Cost-sensitive probabilistic neural network with its application in fault diagnosis[J]. Control and Decision, 2010,25(7): 1074-1078. (in Chinese)
- [6] 唐勇波,桂卫华,彭涛.代价敏感核主元分析及其在故障诊断中的应用[J].中南大学学报:自然科学版,2013,44(6):2324-2330.
Tang Yongbo, Gui Weihua, Peng Tao. Cost-sensitive kernel principal component analysis with its application in fault diagnosis[J]. Journal of Central South University: Science and Technology, 2013, 44(6): 2324-2330. (in Chinese)
- [7] 刘永斌,何清波,孔凡让,等.基于 PCA 和 SVM 的内燃机故障诊断[J].振动、测试与诊断,2012,32(2):250-255.
Liu Yongbin, He Qingbo, Kong Fanrang, et al. Fault diagnosis of internal combustion engine using PCA and SVM[J]. Journal of Vibration, Measurement & Diag-

- nosis, 2012, 32(2): 250-255. (in Chinese)
- [8] 蒋玲莉,刘义伦,李学军,等. 基于SVM与多振动信息融合的齿轮故障诊断[J]. 中南大学学报:自然科学版, 2010,41(6): 2184-2188.
Jiang Lingli, Liu Yilun, Li Xuejun, et al. Gear fault diagnosis based on SVM and multi-sensor information fusion[J]. Journal of Central South University: Science and Technology, 2010, 41(6): 2184-2188. (in Chinese)
- [9] Widodo A, Yang B S. Support vector machine in machine condition monitoring and fault diagnosis[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2560-2574.
- [10] Tang Yuchun, Zhang Yanqing, Chawla N V, et al. SVMs modeling for highly imbalanced classification [J]. IEEE Trans on Systems, Man and Cybernetics, Part B: Cybernetics, 2009, 39(1): 281-288.
- [11] 郑恩辉,李平,宋执环. 代价敏感支持向量机[J]. 控制与决策, 2006, 21(4): 473-476.
Zheng Enhui, Li Ping, Song Zhihuan. Cost sensitive support vector machines [J]. Control and Decision, 2006, 21(4): 473-476. (in Chinese)
- [12] 江彤,唐明珠,阳春华. 基于不确定性采样的自训练代价敏感支持向量机研究[J]. 中南大学学报:自然科学版, 2012,43(2): 561-566.
Jiang Tong, Tang Mingzhu, Yang Chunhua. Self-training cost-sensitive support vector machine with uncertainty based on sampling [J]. Journal of Central South University: Science and Technology, 2012, 43(2): 561-562. (in Chinese)
- [13] 李平,李学军,蒋玲莉,等. 基于KPCA和PSOSVM的异步电机故障诊断[J]. 振动、测试与诊断, 2014, 34(4): 616-620.
Li Ping, Li Xuejun, Jiang Lingli, et al. Fault diagnosis of asynchronous motor based on KPCA and PSOSVM [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(4): 616-620. (in Chinese)
- [14] 刘金福,于达仁,胡清华,等. 基于加权粗糙集的代价敏感故障诊断方法[J]. 中国电机工程学报, 2007, 27(23): 93-99.
Liu Jinfu, Yu Daren, Hu Qinghua, et al. Cost-sensitive fault diagnosis based on weighted rough sets [J]. Proceedings of the CSEE, 2007, 27(23): 93-99. (in Chinese)
- [15] 陈中杰,蒋刚,蔡勇. 基于SVM一对一多分类算法的二次细分法研究[J]. 传感器与微系统, 2013, 32(4): 44-47.
Chen Zhongjie, Jiang Gang, Cai Yong. Research of secondary subdivision method for one-versus-one multi-classification algorithm based on SVM [J]. Transducer and Microsystem Technologies, 2013, 32(4): 44-47. (in Chinese)



第一作者简介:向阳辉,男,1981年10月,讲师。主要研究方向为机械设备状态监测与故障诊断。曾发表《加权证据理论信息融合方法在故障诊断中的应用》(《振动与冲击》2008年第27卷第4期)等论文。

E-mail: xiangyanghui@163.com

航空发动机振动监测和分析系统研制成功

森德格公司(sendig.com.cn),经过多年的研究和大量现场试验,在近期成功发布了系列化航空发动机振动监测和分析仪器产品。包括有:SAVT-1H小型手持式振动测量仪器,可测量发动机的多种通频振值;SAVT-2H航空发动机振动分析仪和动平衡仪,可测量多种振值、波形、频谱。同时配有设备状态监测及趋势分析软件和故障诊断专家系统,可以自动生成各种报告;SAVT-5航空发动机振动变送器,是为连续监测发动机振动值的在线监测仪表,可以在驾驶舱实时显示振值,并在振值超标时立即报警以避免重大事故的发生。

SAVT系列仪器已经过生产厂家台架和外场实机的多次成功考验,填补了我国飞行器发动机振动监测和分析仪器缺少自主知识产权产品的历史。