

文章编号:1000-8055(2011)12-2841-08

基于大规模训练集 SVM 的发动机故障诊断

徐启华¹, 耿 帅¹, 师 军²

(1. 淮海工学院 电子工程学院, 江苏 连云港 222005;

2. 西北工业大学 第 365 研究所, 西安 710072)

摘 要: 提出了一种新的学习策略,用于解决发动机故障诊断中大规模支持向量机(SVM)的训练问题. 通过保留初始 SVM 分类器支持向量超平面附近的样本以及错分样本,使最终得到的约减集规模明显缩小,从而可在保持较高分类精度的前提下使训练时间明显缩短;同时,由于支持向量的数量减小,分类时间也相应缩短. 探讨了序贯最小优化(SMO)算法的参数选择和实现过程中的关键问题,为这种极具潜力的算法在发动机故障诊断中的实际应用奠定了坚实的基础. 仿真实例表明,这种基于大规模训练集 SVM 的发动机故障诊断方法有效、可靠,容易实现,可以作为工程应用的基础.

关 键 词: 航空发动机; 支持向量机(SVM); 故障诊断; 大规模训练集; 样本约减

中图分类号: V263.6; TP181

文献标志码: A

Fault diagnosis method for aero-engine based on SVM with large-scale training set

XU Qi-hua¹, GENG Shuai¹, SHI Jun²

(1. College of Electronic Engineering,

Huaihai Institute of Technology, Lianyungang Jiangsu 222005, China;

2. No. 365 Institute, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: A learning strategy was presented to solve the large-scale support vector machines (SVM) training problem of aero-engine fault diagnosis. According to the strategy, only those samples were retained for final training, which were near the support vector hyperplane of the original small-scale SVM classifier or classified mistakenly by the original classifier. The final pruning set was reduced evidently and the training time was shortened obviously on the condition of high classification accuracy. Meanwhile, the classification time was shortened correspondingly because of the decrease of the support vector number. Something about the parameter selection of the sequential minimal optimization (SMO) method and how to use this potential algorithm in aero-engine fault diagnosis were also discussed. Simulation examples show that this fault diagnosis method proposed for aero-engine, based on SVM with large-scale training set, is effective, reliable and easy to be implemented for engineering application.

Key words: aero-engine; support vector machines (SVM); fault diagnosis; large-scale training set; sample pruning

收稿日期:2011-08-08; 修订日期:2011-11-18

基金项目:江苏省“六大人才高峰”计划(07-E-029); 江苏省高校科研成果产业化推进项目(JHZD08-40);

江苏省“青蓝工程”学术带头人基金(苏教师(2007)2号)

作者简介:徐启华(1962—),男,陕西山阳人,教授,博士,主要从事故障诊断与容错控制研究.

支持向量机(support vector machine, 简称 SVM)是一种新兴的、基于统计学习理论的机器学习方法,其突出的优点主要表现在:能够得到唯一的全局最优解,具备良好的泛化性能,巧妙地解决了维数问题从而使得算法的复杂度与样本维数无关.由于上述优越性,SVM已被积极用于航空发动机的故障诊断,并被证明是一种有效方法^[1-8].

SVM的训练最后归结为求解线性约束下的凸二次规划(quadratic programming, 简称 QP)问题.当训练集较大时,SVM在实现上会出现一些困难.首先,SVM要计算和存储核函数矩阵,计算工作量和存储空间都随着训练样本数目的平方而增加^[2,9-10],当训练样本数目较大时,开销很大;其次,SVM在二次型寻优过程中要进行大量耗时的矩阵运算,多数情况下,寻优算法占用了 SVM 计算的大部分时间^[2,9-10].而且,训练集增大,支持向量数目一般也会随之增大,分类速度也会相应减低^[1-2,9-10].

为了克服这些困难,对于大规模训练集,一般从两个方面着手.第一,采用新的实现算法,减少参与寻优运算的样本数目,如文献[2]采用“块算法(Chunking)”实现发动机的故障诊断,取得了良好的效果.这一领域目前已经提出的训练算法大部分基于分解迭代的思想,即将原始的 QP 问题分解成若干规模较小的 QP 问题求解.具体来说,在每一步迭代计算中都把训练集分解为工作集与非工作集两个子集,只对工作集中的数据样本进行优化,而非工作集中样本数据所对应的 Lagrange 乘子保持不变.上述“块算法”就是这种分解迭代思想的一个典型应用,而 Platt 提出的序贯最小优化(sequential minimal optimization, 简称 SMO)算法则是把分解迭代思想运用到极致的结果^[10].SMO 算法的工作集只包含两个数据样本,在每一步迭代中都只对两个 Lagrange 乘子进行优化,由于对 Lagrange 乘子的线性等式约束,因此,这是可能达到的最小优化问题.尽管在 SMO 中 QP 子问题增多了,但总的计算速度大大提高了,而且这种算法完全不需要处理大矩阵,因而对存储空间没有额外要求,规模很大的 SVM 训练问题也能用 PC 机完成. SMO 是目前大规模训练集 SVM 训练中实际应用最为广泛和成功的一种方法^[10].本文也将采用 SMO 算法进行 SVM 的训练,并对 SMO 算法的参数选择和算法实施中的相关实际问题进行探讨.

第二方面从删减训练集着手,基本思想是:从

训练集中去掉对学习帮助不大的样本,重点保留对分类面影响较大的样本,使训练集规模减小,从而减小 SVM 训练的代价,同时保证分类器的分类正确率,并且降低分类所用的时间.已有不少研究者提出了基于这种思想的删减算法^[11-15].李红莲等人^[15]提出的算法是,先用一个小规模的样本集训练得到一个具有一定分类精度的初始分类器,用这个分类器对原始的大规模训练集进行修剪,修剪策略为,保留与初始分类器支持向量距离比较近的样本,删除其他样本,得到一个规模减小的删减集;然后,用修剪后的删减集进行训练得到最终的分类器;这种算法抓住了 SVM 的本质,即分类器只与支持向量有关,而与其他样本无关,算法思路明确、简洁有效、便于实现.本文在相关研究的基础上,进一步考虑了被初始分类器错分的样本,提出了一种新的修剪策略,用于解决发动机故障诊断中大规模训练集 SVM 的训练问题.

1 基于 SVM 的航空发动机故障诊断问题

航空发动机的故障一般分为气路部件故障、附件故障和转子机械故障三类,在上述三类故障中,气路部件故障往往是潜在且难以判断的,因此对它进行研究具有重要的实际意义^[2-3].本文以一双转子涡喷发动机为实例,采用 SVM 进行气路部件故障诊断,其任务就是根据发动机故障征兆数据推断出故障的类型.

发动机的故障诊断问题实质上是模式分类问题^[2].对发动机两类故障数据进行分类的 SVM 算法简介如下.

对于训练样本 $(\mathbf{x}_i, y_i) \in R^l \times \{+1, -1\}$, $i = 1, 2, \dots, n$, SVM 求解的优化问题为

$$\left. \begin{aligned} \max W(\boldsymbol{\alpha}) = & \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s. t.} \quad & \sum_{i=1}^n \alpha_i y_i = 0 \\ & 0 \leq \alpha_i \leq C, i = 1, 2, \dots, n \end{aligned} \right\} \quad (1)$$

这里,各参数的意义与通常文献中的一致^[9].

测试样本 $\mathbf{x}$ 的决策规则为

$$f(\mathbf{x}) = \text{sgn} \left[\sum_{i=1}^n y_i \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b \right] \quad (2)$$

这里,SVM 的输入为 8 个故障征兆参数,包括:高、低压转速 N_h, N_l ;高、低压压气机出口压 p_2, p_x ;高、低压涡轮出口压力 p_y, p_t ;高压压气机

出口温度 T_2 ; 低压涡轮出口温度 T_4 .

如果训练样本规模较小,可以直接求解式(1);把它整理成以 Lagrange 乘子 α_i 为变量的标准形式二次优化问题,即可方便地利用 MATLAB 的优化工具箱求解.若训练样本规模较大,正如上面所说,由于计算工作量和存储空间的问题,直接求解难以进行,此时需要采用后面介绍的 SMO 算法求解.

基本 SVM 可以直接实现两类故障的分类.双转子涡喷发动机气路部件单一故障的种类有:无故障(NON),低压压气机故障(LP),高压压气机故障(HP),低压涡轮故障(LT)和高压涡轮故障(HT).若要诊断出上述 5 类故障,必须构造多元分类器.本文采用成熟的“one-against-one”方法构造多元分类器^[3].

2 SMO 算法及其实现中的有关问题

2.1 SMO 基本算法简介

SMO 算法原理在很多文献中都有介绍,文献[10]中还给出了详细的 Platt SMO 程序伪码,因与本文后面的内容有关,这里只进行简介.

SMO 每步选择两个元素优化,不失一般性,假定选定的两个元素是 α_1 和 α_2 . 优化问题(1)可以通过下面的计算实现^[10]:

$$E_i = \left(\sum_{j=1}^n \alpha_j y_j K(\mathbf{x}_i, \mathbf{x}_j) + b \right) - y_i \quad i = 1, 2 \quad (3)$$

$$\kappa = K(\mathbf{x}_1, \mathbf{x}_1) + K(\mathbf{x}_2, \mathbf{x}_2) - 2K(\mathbf{x}_1, \mathbf{x}_2)$$

$$L = \begin{cases} \max(0, \alpha_2^{\text{old}} - \alpha_1^{\text{old}}), y_1 \neq y_2 \\ \max(0, \alpha_1^{\text{old}} + \alpha_2^{\text{old}} - C), y_1 = y_2 \end{cases}$$

$$H = \begin{cases} \min(C, C - \alpha_1^{\text{old}} + \alpha_2^{\text{old}}), y_1 \neq y_2 \\ \min(C, \alpha_1^{\text{old}} + \alpha_2^{\text{old}}), y_1 = y_2 \end{cases}$$

$$\alpha_2^{\text{new,unc}} = \alpha_2^{\text{old}} + y_2(E_1 - E_2)/\kappa$$

$$\alpha_2^{\text{new}} = \begin{cases} H, \alpha_2^{\text{new,unc}} > H \\ \alpha_2^{\text{new,unc}}, L \leq \alpha_2^{\text{new,unc}} \leq H \\ L, \alpha_2^{\text{new,unc}} < L \end{cases}$$

$$\alpha_1^{\text{new}} = \alpha_1^{\text{old}} + y_1 y_2 (\alpha_2^{\text{old}} - \alpha_2^{\text{new}})$$

其中,标注“old”的表示上一步的计算值,标注“new”的表示得到的新计算值.

2.2 SMO 算法实现的几个关键技术

每次进行更新计算时,都要计算式(3)中的 $E_i (i = 1, 2)$ 和式(1)中的目标函数 $W(\alpha)$. 若直接由式(1)和式(3)进行计算,需要利用全体训练

样本,当训练样本数目大时,计算工作量不小.为了减少计算开销,本文对它们的计算公式进行改写,不必每次都直接计算,而是充分利用上一次的计算结果,迭代计算.

2.2.1 阈值 b 的更新

得到 $\alpha_1^{\text{new}}, \alpha_2^{\text{new}}$ 后,若有 $0 < \alpha_1^{\text{new}} < C$, 则首先根据 KKT(Karush-Kuhn-Tucker)条件^[10]更新式(2)中的阈值 b , b 的初始值取为零

$$\begin{aligned} b_1^{\text{new}} &= -E_1 - y_1(\alpha_1^{\text{new}} - \alpha_1^{\text{old}})K(\mathbf{x}_1, \mathbf{x}_1) - \\ &\quad y_2(\alpha_2^{\text{new}} - \alpha_2^{\text{old}})K(\mathbf{x}_1, \mathbf{x}_2) + b^{\text{old}} \\ b &= b_1^{\text{new}} \end{aligned}$$

若同时还有 $0 < \alpha_2^{\text{new}} < C$, 则

$$\begin{aligned} b_2^{\text{new}} &= -E_2 - y_1(\alpha_1^{\text{new}} - \alpha_1^{\text{old}})K(\mathbf{x}_1, \mathbf{x}_2) - \\ &\quad y_2(\alpha_2^{\text{new}} - \alpha_2^{\text{old}})K(\mathbf{x}_2, \mathbf{x}_2) + b^{\text{old}} \\ b &= (b_1^{\text{new}} + b_2^{\text{new}})/2 \end{aligned}$$

2.2.2 E_i 的迭代计算

E_i 是预测函数输出与期望输出之间的差值,可按下式迭代计算

$$E_i^{\text{new}} = E_i^{\text{old}} + (\alpha_1^{\text{new}} - \alpha_1^{\text{old}})y_1 K(\mathbf{x}_i, \mathbf{x}_1) + (\alpha_2^{\text{new}} - \alpha_2^{\text{old}})y_2 K(\mathbf{x}_i, \mathbf{x}_2) + (b^{\text{new}} - b^{\text{old}}) \quad (4)$$

式(3)的运算次数为 $O(n)$ 量级;与式(3)相比,式(4)利用了上一次的计算结果,仅需重新根据两个样本计算,需要做 4 次乘法,6 次加法,显然,在训练样本规模较大的情况下,收益较大.

2.2.3 目标函数 $W(\alpha)$ 的更新计算

$$\Delta \alpha_i = (\alpha_i^{\text{new}} - \alpha_i^{\text{old}}) \quad i = 1, 2$$

$$W^{\text{new}}(\alpha) = W^{\text{old}}(\alpha) + \Delta \alpha_1 + \Delta \alpha_2 -$$

$$\Delta \alpha_1 y_1 \sum_{i \neq 1, 2} \alpha_i y_i K(\mathbf{x}_1, \mathbf{x}_i) -$$

$$\Delta \alpha_2 y_2 \sum_{i \neq 1, 2} \alpha_i y_i K(\mathbf{x}_2, \mathbf{x}_i) -$$

$$\Delta \alpha_1 \Delta \alpha_2 y_1 y_2 K(\mathbf{x}_1, \mathbf{x}_2) -$$

$$[\Delta \alpha_1^2 K(\mathbf{x}_1, \mathbf{x}_1) + \Delta \alpha_2^2 K(\mathbf{x}_2, \mathbf{x}_2)]/2 \quad (5)$$

根据式(1)计算目标函数,运算次数为 $O(n^2)$ 量级;而式(5)的运算次数为 $O(n)$ 量级,显然,在大规模训练集下,式(5)比式(1)要减少很多计算工作量.

另外,根据 Platt 的 SMO 算法伪码,迭代过程中还要计算 $\alpha_2 = L$ 或 $\alpha_2 = H$ 处的目标函数值,此时,也只需计算出增量,与上一次的计算结果相加即可. $\alpha_2 = L$ 时的目标函数增量为

$$\begin{aligned} \Delta W_L(\alpha) &= \Delta \alpha_1 - \Delta \alpha_1 y_1 \sum_{i \neq 1, 2} \alpha_i y_i K(\mathbf{x}_1, \mathbf{x}_i) - \\ &\quad [\Delta \alpha_1^2 K(\mathbf{x}_1, \mathbf{x}_1)]/2 \end{aligned}$$

$\alpha_2 = H$ 时有类似的结果.

3 大规模训练集的修剪策略

对于大规模训练集 L , 本文尝试采用这样的修剪策略, 即首先用一个小规模的样本集 S_0 训练得到一个初始的 SVM 分类器 F_0 , 然后用 F_0 对 L 进行修剪, 修剪后得到一个规模较小的约减集 S , 再用 S 进行训练得到最终的分分类器, 我们称为 NL(Newton Lagrangian)-SVM 分类器. 具体步骤如下:

1) 从大规模样本集 L 中随机抽取一个小规模样本集 S_0 , 用 S_0 训练得到初始的 SVM 分类器 F_0 . S_0 的规模依据两个条件来确定: ①使用它训练代价不高; ②保证用它训练得到的分类器 F_0 有一定的分类精度. 文献[15]和本文的实验表明, 这还是很容易做到的.

2) 修剪 L , 得到约减集 S , 然后用 S 训练得到最终的分分类器. 设 F_0 的分类超平面为 H , 对于 L 的任意一个样本 x , 设 x 与 H 的距离为 r , 则有^[9]

$$r = g(x) / \|w\|,$$

$$g(x) = \sum_{i=1}^n y_i \alpha_i K(x, x_i) + b$$

其中 w 是 SVM 的权值向量, 而两类支持向量所在超平面到 H 的距离分别为 $\pm 1 / \|w\|$. 具体修剪方法是: 若 x 被 F_0 错分, 则保留此样本; 若 x 被 F_0 正确分类, 当 $1 - \epsilon \leq |g(x)| \leq 1 + \epsilon$ 时, 保留 x , 否则删除它, 其中 $0 < \epsilon < 1$ 为可以调整的阈值. 阈值 ϵ 的调节具有两个功能: ①控制约减集的规模; ②影响最终分类器的分类精度. 实际应用中可以通过调节 ϵ 来得到近似最优分类器, 而 ϵ 的调节并不困难^[15].

这里, 与文献[15]不同, 本文把被 F_0 错分的样本也吸纳进最终的训练集 S , 其主要理由是: 如果任意一个样本 x 被 F_0 错分, 说明初始分类器 F_0 没有正确反映样本 x 的特性, 也就是说, x 对于最终的训练集 S 是一个能够提供分类新信息的非冗余样本, 它对分类的结果是有影响的, 不应该被删除. x 被 F_0 正确分类后的修剪策略, 简言之, 就是留下与初始分类器的支持向量距离比较近的样本^[15], 这种策略抓住了支持向量机的本质, 即 SVM 分类器仅与支持向量有关, 与其他样本无关. 通过采用这种修剪策略, 留下的样本将是对分类大有帮助的, 而删除的样本对分类没有什么帮助.

4 实验结果与分析

4.1 数据的产生及预处理

文献[16]的表 7-3 中的 5 类故障样本数据共有 72 组. 其中 NON 有 32 组, LP, HP, LT 和 HT 各 10 组, 每组数据 8 维, 包括 8 个故障征兆参数, 均采用偏离基准状态的相对量表示, 无量纲. 用上述 72 组数据计算出 5 类各自的均值和方差, 形成正态分布数据. 产生的数据每类 2000 组, 其中 1500 组用于训练, 另外 500 组作为检验样本. 这样, 训练两类 SVM 时, 训练集 L 共有 3000 组样本, 再从 L 中随机抽取 200 (每类各 100) 组作为 S_0 训练初始分类器 F_0 , 检验样本有 1000 (每类各 500) 组.

为了减小计算量, 先对数据进行主成分分析 (principal component analysis, 简称 PCA) 处理. 经过 PCA 处理后的数据从 8 维变成 4 维, 每个特征分量对应特征值所占的比例 (%) 依次为

[44.0540, 22.9027, 9.8467, 8.4468, 7.4567, 4.8838, 1.6521, 0.7572], 而前 4 个特征分量的贡献率为 85.25%, 可以满足要求.

4.2 本文算法的仿真结果与分析

故障分类在 MATLAB 环境下实现, 仿真计算的 PC (personal computer) 机为 Pentium (R) 4, CPU (central processing unit) 为 3.6 G, 内存为 2 GB.

采用 Gauss 核函数

$$K(x, x_i) = \exp \left\{ -\frac{\|x - x_i\|^2}{2\sigma^2} \right\}$$

4.2.1 初始分类器 F_0

以 NON 和 LP 两类故障为例. 核函数参数 $\sigma^2 = 0.8$, SVM 正则化参数 $C = 100$. 此时, 得到的初始分类器 F_0 , 其分类精度为 89.2%, 符合要求.

4.2.2 NL-SVM 分类器

在阈值 $\epsilon = 0.5$ 时, 我们得到较好的训练结果. 为了比较, 把本文算法的结果与未经样本约减的基本 SVM 的计算结果同时列在表 1. 仿真计算时, 两种分类器的训练都采用 SMO 算法实现, SMO 的有关参数如下:

τ 为判定是否满足 KKT 条件的容忍等级, Cristianini 等^[10]建议在 10^{-2} 以内, 这里取 $\tau = 10^{-2}$.

μ 为决定两次计算的 α_2 是否舍弃的阈值, 应是很小的正数, 这里取 $\mu = 10^{-3}$. 若两次计算的 α_2 之差的绝对值大于 μ , 就更新 α_2 , 否则, 舍弃新计

算的 α_2 , 保留上一次的计算值。

表 1 与基本 SVM 分类器的比较(NON 和 LP 故障)

Table 1 Simulation results according to the basic SVM and our NL-SVM (for fault NON and LP)

分类器	分类精度/%	训练样本/组	训练时间/s	支持向量/个
SVM	94.0	3000	10500	371
NL-SVM	94.5	939	680	128

从表 1 的数据可以看出,与基本 SVM 分类器相比,采用本文约减算法的 NL-SVM 分类器在保持分类精度稍高的条件下,由于最终参与训练的样本数减少到 939 组,所用的训练时间还不到前者的 1/15,训练速度提高非常明显。与此同时,NL-SVM 得到的支持向量数也减少到 128 个,只有基本 SVM 的 1/3,这将有利于缩短分类时间。

表 2 是本文算法的结果与文献[15]中 LSVM(Lagrangian SVM)仿真结果的对比。对应每一个 ϵ 值,表中的第一行是 NL-SVM 的结果,第二

表 2 与 LSVM 分类器的比较(NON 和 LP 故障)

Table 2 Simulation results according to LSVM and our NL-SVM (for fault NON and LP)

ϵ	分类精度/%	训练样本/组	样本比例/%	支持向量/个
0.2	90.5	551	18.37	103
	89.6	416	13.87	106
0.3	93.0	696	23.20	117
	90.1	561	18.70	111
0.4	93.7	812	27.07	123
	90.2	677	22.57	116
0.5	94.5	939	31.30	128
	90.2	804	26.80	121
0.6	94.0	1049	34.97	136
	91.0	914	30.47	123
0.7	94.2	1133	37.77	142
	91.4	998	33.27	122
0.8	94.5	1229	43.30	148
	91.5	1094	36.47	123
0.9	94.4	1321	44.03	156
	91.4	1186	39.53	121

行是 LSVM 的结果;而“样本比例”是指最终参与训练的样本数与基本 SVM 样本数,即 3000 的比值。

LSVM 的情况是:开始,随着 ϵ 增加,参与训练的样本增加,分类精度缓慢增加;但超过 0.8 后,分类精度反而缓慢下降,这可能是过学习的原因。

NL-SVM 的情况是:开始,随着 ϵ 增加,参与训练的样本增加,分类精度在一个较高水平上增加,增加速度比 LSVM 明显快;到 0.5 时,已经达到 94.5% 的精度;随后,随着 ϵ 增加,分类精度小幅缓慢下降,这也可能是过学习的原因。但波动范围不大,表明 ϵ 达到一定数值即主要训练样本(支持向量所在超平面附近样本以及错分样本)足够多时, ϵ 的增加对精度的影响已经较弱。

仿真结果同时表明,同样分类精度,NL-SVM 参与训练的样本数量和支持向量个数明显少于 LSVM,这主要是它吸收了错分样本,而错分样本对最终的分界面有较大影响,从而加快了训练速度;由于参与训练的样本少,最终得到的支持向量个数也相应减少。这个结论说明,根据本文约减算法设计的 NL-SVM 分类器在训练速度和分类速度上具有更好的效果。例如,LSVM 在分类精度 90.2% 时,训练样本/样本比例和支持向量个数分别为 677/22.57% 和 116,而 NL-SVM 在分类精度 90.5% 时,上述数据却分别只有 551/18.37% 和 103;类似地,LSVM 在分类精度 91.5% 时,三项数据依次为 1094/36.47% 和 123,而 NL-SVM 在分类精度 93.0% 时,对应的数据分别是 696/23.2% 和 117,后者在训练速度上的效果更加明显。

4.2.3 发动机故障分类结果

根据“one-against-one”多元分类方法,若要对 5 类故障进行分类,需要构造 10 个二元 SVM 分类器并进行相应的表决。与 NON-LP 二元分类器类似,由其他故障样本数据训练得到的二元 NL-SVM 分类器也都取得了满意的效果,具体数值见表 3。最终,对发动机 NON,LP,HP,LT,HT 等 5 类故障的 2500 组检验样本的分类结果是,2419 组样本被正确分类,仅有 81 组样本被错分,分类正确率达到 96.8%。

由于多类故障分类需要训练多个二元分类器,采用本文提出的算法,总的训练时间缩短效果

更加显著。

表3 二元分类器训练结果

Table 3 Simulation results of the binary SVMs

二元 分类器	分类 精度/%	训练 样本/组	训练 时间/s	支持 向量/个
NON-LP	94.5	939	680	128
NON-HP	95.0	917	663	122
NON-HT	93.6	956	692	136
NON-LT	100.0	881	638	117
LP-HP	98.2	892	645	120
LP-HT	94.7	931	675	125
LP-LT	100.0	839	608	115
HP-HT	94.9	926	670	123
HP-LT	100.0	853	617	115
LT-HT	100.0	869	630	116

4.3 SMO 的有关仿真结果

4.3.1 与标准解的比较

利用 MATLAB 优化工具箱提供的二次规划子模块可以直接求解 SVM 问题,这可以看成是 SVM 的一种标准解。通过与标准解比较,可以看出 SMO 的效果。以 NON 和 LP 两类故障为例,两类各随机取 100 组数据作为训练样本,各取 500 组数据作为检验样本。核函数参数 $\sigma^2 = 0.8$, SVM 正则化参数 $C=100$, SMO 参数为 $\tau=10^{-2}$, $\mu=10^{-3}$ 时的计算结果如表 4。

表4 SMO与标准解法的对比

Table 4 Simulation results according to SMO and ordinary SVM

SVM 解法	标准解	SMO
b	-0.5442	-0.5445
目标函数值	223.1589	223.1504
训练样本分类精度/%	100	100
检验样本分类精度/%	90.1	90.1
支持向量/个	45	45

Lagrange 乘子 $\alpha_i (i=1, \dots, 200)$ 的数值未列在表 4 中,具体情况是,若 $\alpha_i = 0$ 或 $\alpha_i = C$,两者的计算结果完全相同,当 $0 < \alpha_i < C$ 时,SMO 与标准解的平均误差仅为 3.0557%。

两种解法由于得到的 α, b 误差很小,故据此计算的目标函数值几乎完全接近,而分类精度、支

持向量个数量则完全相同。以上结果表明,SMO 的计算效果是非常令人满意的。

4.3.2 参数对 SMO 计算结果的影响

1) τ 的影响

不同 τ 时的 SMO 计算结果列在表 5 中。可以看出,当 τ 提高一个量级到 10^{-3} 时,只是 SVM 参数更接近标准解,并未影响分类结果,但训练时间的开销则差别较大。由于 $\tau=10^{-2}$ 时 SVM 参数与标准解的误差本身已非常小,所以再提高满足 KKT 条件的容忍等级,对目标函数的影响肯定非常小,它已不可能影响分类结果。就是说, $\tau=10^{-2}$ 已经完全能够满足要求,不必去追求更高的计算精度而导致训练时间的增加。

表5 不同 τ 时的 SMO 计算结果

Table 5 Simulation results at different τ values

参数	数值	
τ	10^{-2}	10^{-3}
α 误差/%	3.0557	0.4134
b	-0.5445	-0.5444
目标函数值	223.1504	223.1575
训练样本精度/%	100	100
检验样本精度/%	90.1	90.1
支持向量/个	45	45
训练时间/s	33	176

“numChanged” 是 Platt 给出的 SMO 程序伪码中一个重要变量,它指每轮迭代能找到的优化变量对数,只有在内外循环中 numChanged=0 都成立,迭代计算才结束^[10]。因此,从 numChanged 每轮的变化情况可以看出迭代收敛的快慢。图 1 是 τ 取不同值时 numChanged 的变化情况,其中图 1(a) 对应的训练样本为 2×100 组, (b) 对应的训练样本为 2×300 组。

图 1(a),图 1(b) 中的虚线对应 $\tau=10^{-3}$,它们下降慢,总的迭代轮次多,计算时间长。而且,训练样本越多,这种情况越严重,图 1(b) 说明了这个结论。从图中可以看出,在大部分迭代轮次中,虚线下降慢,特别是在第 700 轮之后的 200 多个轮次中,由于 τ 太小, KKT 条件不能满足, numChanged 在很小的范围之间反复来回震荡,极大地增长了总的迭代轮次,延长了计算时间。

2) μ 的影响

μ 对最终计算精度影响小,但对计算时间影




图 1 不同 KKT 条件容忍等级时 numChanged 的变化情况

Fig. 1 Curves of numChanged according to different τ values

响较大,一般取较小的 μ 值,可以减小训练时间。

5 结 论

本文在已有研究的基础上,提出了一种新的学习策略,用于解决发动机故障诊断中大规模 SVM 的训练问题。研究结论如下:

1) 通过保留初始 SVM 分类器支持向量超平面附近的样本以及错分样本,使最终得到的约减集规模明显缩小,从而可在保持较高分类精度的前提下使训练时间明显缩短;同时,由于支持向量减小,分类时间也相应缩短。这种策略对于具有多类故障的大规模训练集发动机故障诊断问题效果非常显著。

2) 探讨了 SMO 算法的参数选择和实现过程中的关键问题,为这种极具潜力的算法在发动机故障诊断中的实际应用奠定了坚实的基础。

3) 仿真实例表明,本文提出的算法有效、可靠,容易实现,因而具有工程应用的基础,可以为

大规模训练集航空发动机的故障诊断提供一种良好的方法。

参考文献:

- [1] XU Qihua, SHI Jun. Fault diagnosis for aero-engine applying a new multi-class support vector algorithm[J]. Chinese Journal of Aeronautics, 2006, 19(3): 175-18.
- [2] 徐启华, 师军. 应用 SVM 的发动机故障诊断若干问题研究[J]. 航空学报, 2005, 26(6): 686-690.
XU Qihua, SHI Jun. Some studies in aero-engine fault diagnosis using support vector machines[J]. Acta Aeronautica et Astronautica Sinica, 2005, 26(6): 687-690. (in Chinese)
- [3] 徐启华, 师军. 基于支持向量机的航空发动机故障诊断[J]. 航空动力学报, 2005, 20(2): 298-302.
XU Qihua, SHI Jun. Aero-engine fault diagnosis based on support vector machine[J]. Journal of Aerospace Power, 2005, 20(2): 298-302. (in Chinese)
- [4] 徐启华, 师军. 一种新型多分类支持向量算法及其在故障诊断中的应用[J]. 系统仿真学报, 2005, 17(11): 2766-2768, 2784.
XU Qihua, SHI Jun. New multi-class support vector algorithm and its application in fault diagnosis[J]. Acta Simulata Systematica Sinica, 2005, 17(11): 2766-2768, 2784. (in Chinese)
- [5] 尉询楷, 陆波, 汪诚. 支持向量机在航空发动机故障诊断中的应用[J]. 航空动力学报, 2004, 19(6): 844-848.
WEI Xunkai, LU Cheng, WANG Cheng. Applications of support vector machines to aeroengine fault diagnosis[J]. Journal of Aerospace Power, 2004, 19(6): 844-848. (in Chinese)
- [6] HAO Ying, SUN Jianguo, YANG Guoqing, et al. The application of support vector machines to gas turbine performance diagnosis[J]. Chinese Journal of Aeronautics, 2005, 18(1): 15-19.
- [7] 王旭辉, 黄圣国, 舒平. 基于最小二乘支持向量机的航空发动机故障远程诊断[J]. 机械科学与技术, 2007, 26(5): 595-599.
WANG Xuhui, HUANG Shengguo, SHU Ping. Remote diagnosis of aeroengine's fault using LS-SVM[J]. Mechanical Science and Technology, 2007, 26(5): 595-599. (in Chinese)
- [8] 杨俊, 谢寿生, 于东军. 基于支持向量机的航空发动机故障诊断[J]. 机械科学与技术, 2005, 24(1): 123-126.
YANG Jun, XIE Shousheng, YU Dongjun. Aero-engine fault diagnosis based on support vector machine[J]. Mechanical Science and Technology, 2005, 24(1): 123-126. (in Chinese)
- [9] Haykin S. Neural networks: a comprehensive found[M]. 2nd ed. Beijing: China Machine Press, 2004.
- [10] Cristianini N, Shawe-Taylor J. An introduction to support vector machines and other kernel-based learning methods[M]. Beijing: Publishing House of Electronic Industry, 2004.
- [11] Barros de Almeida M, de Padua Braga A, Braga J P. SVM-KM: speeding SVMs learning with a priori cluster selection

- and k -means[C]//Proceedings of the Sixth Brazilian Symposium on Neural Networks, Rio de Janeiro, R J, Brazil: IEEE Computer Society, 2000:162-167.
- [12] 徐红敏,王若鹏,张怀念. 支持向量机的快速分类算法[J]. 北京石油化工学院学报, 2009, 17(4): 55-58.
- XU Hongmin, WANG Ruopeng, ZHANG Huainian. Fast classification algorithm for support vector machine[J]. Journal of Beijing Institute of Petro-Chemical Technology, 2009, 17(4): 55-58. (in Chinese)
- [13] HE Qiang, XIE Zongxia, HU Qinghua. Neighborhood based sample and feature selection for SVM classification learning[J]. Neurocomputing, 2011, 74(10): 1585-1594.
- [14] 李红莲,王春花,袁保宗. 一种改进的支持向量机 NN-SVM[J]. 计算机学报, 2003, 26(8): 1015-1020.
- LI Honglian, WANG Chunhua, YUAN Baozong. An improved SVM; NN-SVM[J]. Chinese Journal of Computers, 2003, 26(8): 1015-1020. (in Chinese)
- [15] 李红莲,王春花,袁保宗. 针对大规模训练集的支持向量机的学习策略[J]. 计算机学报, 2004, 27(5): 715-719.
- LI Honglian, WANG Chunhua, YUAN Baozong. A learning strategy of SVM used to large training set[J]. Chinese Journal of Computers, 2004, 27(5): 715-719. (in Chinese)
- [16] 杨蔚华. 航空发动机建模及故障诊断[D]. 南京:南京航空航天大学, 2000.
- YANG Weihua. Aero-engine modelling and fault diagnosis [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2000. (in Chinese)