

doi: 10.11823/j.issn.1674-5795.2015.05.04

基于在线 SVDD 的航空发动机异常检测方法

周胜明, 王小飞, 高峰, 曲建岭

(海军航空工程学院青岛校区, 山东 青岛 266041)

摘 要: 针对飞参数据样本量大、分布不均衡且随时间不断积累的特点给航空发动机异常检测带来的问题, 提出采用在线 SVDD 进行航空发动机异常检测的方法。首先介绍了在线 SVDD 的基本原理, 然后采用大规模数据对比分析了现有在线 SVDD 方法的性能, 最后采用两组典型发动机典型异常进行实验。结果表明, 在线 SVDD 能够快速准确地识别发动机异常。

关键词: 航空发动机; 异常检测; 飞参数据; 在线 SVDD

中图分类号: V328.3

文献标识码: A

文章编号: 1674-5795(2015)05-0020-03

Aeroengine Novelty Detection Method Based on Online SVDD

ZHOU Shengming, WANG Xiaofei, GAO Feng, QU Jianling

(Naval Aeronautical Engineering Institute Qingdao Branch, Qingdao 266041, China)

Abstract: To tackle the aeroengine novelty detection problems resulted from the characteristics of flight data including large scale, unbalanced distribution and increasing with time, a method of aeroengine novelty detection based on online SVDD is proposed. Firstly, the theory of online SVDD is introduced briefly; secondly, the performances of current online SVDD methods are investigated comparably with large scale dataset; lastly, two typical novelties are used to execute aeroengine novelty detection. Experimental results show that online SVDD can recognize the aeroengine novelty rapidly and accurately.

Key words: aeroengine; novelty detection; flight data; online SVDD

0 引言

航空发动机的故障和状态参数之间有着极其重要的联系^[1], 尽管每一种故障的参数表现形式各不相同, 但大多数故障的早期表现形式都可以由参数的异常变化来体现^[2]。飞参数据是航空发动机状态参数的重要来源, 而通过一定的手段快速准确地检测飞参数据异常, 对于实时掌握发动机的性能状况, 预防和排除故障, 进而保障飞行安全具有重要意义。

一方面, 尽管航空发动机故障机理的复杂性使得其参数表现形式复杂多变, 但由于发动机在飞行过程中通常工作在正常状态下, 因而飞参数据包含有大量正常样本而缺乏异常样本, 样本分布很不均衡^[3], 异常样本缺乏使得传统异常检测方法难以建立精确的发动机异常检测模型。另一方面, 飞参数据的样本量随飞行时间累积不断增加, 而累积样本的特征空间对于

建立精确的异常检测模型至关重要。飞参数据样本量大、分布不均衡且不断累积的特征, 对异常检测算法的速度和性能提出了很高的要求。

针对飞参数据样本分布不均衡的问题, 本文采用支持向量数据描述(support vector data description, SVDD)来建立发动机正常状态下参数样本的边界描述, 进而进行发动机异常状态的检测。与此同时, 为了降低大样本飞参数据的训练复杂度和解决 SVDD 模型随样本数据累积不断更新的问题, 提出采用在线 SVDD 来进行航空发动机异常检测的方法, 以提高异常检测的速度和精度。

1 SVDD 基本原理

设 $T = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ 为给定训练集, $\mathbf{x}_i \in \mathbf{R}^d$ ($\mathbf{R}$ 为欧氏空间, d 为空间维数), n 为样本数量。SVDD 的目标是寻找最小体积超球 $B(\mathbf{c}, r)$, 并使其尽可能多地包含目标样本, $\mathbf{c}$ 为超球球心, r 为超球半径。SVDD 优化问题可以表示为

$$\begin{aligned} \min B(\mathbf{c}, r) &= r^2 + C \sum_i \xi_i \\ \text{s.t. } \|\mathbf{x}_i - \mathbf{c}\|^2 &\leq r^2 + \xi_i, \quad \xi_i \geq 0, \quad \forall i = 1, \dots, n \end{aligned} \quad (1)$$

收稿日期: 2015-07-20

作者简介: 周胜明(1962-), 男, 教授, 研究方向为飞参数据研究及应用。

式中： ξ_i 为松弛变量； C 为由潜在异常样本比例确定的预置平衡参数。




图1 SVDD 训练样本分布示意图

引入 Lagrange 乘子来简化式(1)中的约束问题，然后采用正定核函数 ($K: \mathbf{R}^d \times \mathbf{R}^d \in \mathbf{R}^d$) 诱导下的内积来表示高维空间 $\mathbf{O}'(\mathbf{x}_i \in \mathbf{O} \rightarrow \Phi(\mathbf{x}_i) \in \mathbf{O}', \Phi$ 为映射) 中的内积形式，即 $K(\mathbf{x}_i, \mathbf{x}_j) = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$ ，这样就可以得到优化问题在核函数引导下的对偶形式：

$$\begin{aligned} \max L = & \sum_i \alpha_i K(\mathbf{x}_i, \mathbf{x}_i) - \sum_{i,j} \alpha_i \alpha_j K(\mathbf{x}_i, \mathbf{x}_j) \\ \text{s. t. } & \sum_i \alpha_i = 1, 0 \leq \alpha_i \leq C, \forall i = 1, \dots, n \end{aligned} \tag{2}$$

式(2)为二次规划 (quadratic programming, QP) 问题，在其全局最优解中， α_i 与 $\mathbf{x}_i$ 一一对应。其中， $\alpha_i > 0$ 对应的 $\mathbf{x}_i$ 为支持向量，代入 $\mathbf{c} = \sum \alpha_i \mathbf{x}_i$ 即可计算球心 $\mathbf{c}$ 。超球半径 r 为任一超球面支持向量 $\mathbf{x}_k (0 < \alpha_k < C)$ 到球心 $\mathbf{c}$ 的距离，即 $r^2 = \|\Phi(\mathbf{x}_k) - \Phi(\mathbf{c})\|^2$ 。未知样本 $\mathbf{x}$ 的决策方式为

$$f(\mathbf{x}) = \|\Phi(\mathbf{x}) - \Phi(\mathbf{c})\|^2 - r^2 \tag{3}$$

若 $f(\mathbf{x}) \leq 0$ ， $\mathbf{x}$ 为目标样本，否则， $\mathbf{x}$ 为异常样本。

2 在线 SVDD 方法

在线 SVDD 的基本原理是以部分样本为训练集得到分类器模型，然后通过逐步检测剩余样本或新添加样本来更新分类型模型。其目的是为了降低大规模样本集的训练负责度，同时可以解决分类器模型随样本累积更新的问题。

Tax 和 Laskov 首先提出了基于有限训练集的经典在线 SVDD (online SVDD, OSVDD) 算法^[4]，该算法仅采用部分样本来求解 QP 问题，然后在每次迭代时增加一个新样本并去掉相关度最低的样本，该方法的缺点是仍采用传统方法来解 QP 问题。为进一步提高在线 SVDD 的速度，Hua 等^[5] 和 Tavakkoli^[6] 等分别提出了不同的增量式 SVDD (incremental SVDD, ISVDD) 方法，

此类方法均以支持向量为原始训练集，然后逐个检测新加入样本，若其不满足 Karush-Kuhn-Tucker (KKT) 条件，便将其加入训练集来更新分类器模型。此类方法的问题是采用一些近似方法来保证整个训练过程的收敛速度，无法控制在线学习过程中支持向量增加对分类器模型更新时间的影响。Theljani 等在 ISVDD 的基础上提出了非稳态 SVDD (nonstationary SVDD, NSVDD) 算法^[7]，用于非稳态数据的处理，其主要思路是在每一次模型更新时去掉相关性最小的样本，以控制在线学习训练集的规模，减小单次模型更新时间。

3 在线 SVDD 算法性能比较

为对比分析上述三种在线 SVDD 方法的性能，选取 Mnist 大规模数据集进行实验。Mnist 数据集包含了 60000 个训练样本和 10000 个测试样本，每个样本均为包含 784 个特征维 (28 × 28 个像素点) 的手写数字图像。实验过程中依次以训练样本中的 0 ~ 9 为目标类训练集 (0 ~ 9 的手写数字图像分别有 5923, 6742, 5958, 6131, 5842, 5421, 5918, 6265, 5851 和 5949 张)，以测试样本 (0 ~ 9 的手写数字图像分别有 980, 1135, 1032, 1010, 982, 892, 958, 1028, 974 和 1009 张) 为固定的测试集。三种算法的训练速度 (以训练时间来描述，训练时间越短，代表训练速度越快) 和分类精度实验结果如表 1 所示。

表 1 Mnist 数据集实验结果

目标类	训练时间/s			分类精度/%		
	OSVDD	ISVDD	NSVDD	OSVDD	ISVDD	NSVDD
0	2048.02	166.61	118.49	97.18	97.15	97.44
1	1992.40	154.32	115.55	99.38	98.67	99.42
2	2167.69	137.10	106.72	97.62	96.99	97.56
3	2485.35	205.56	169.47	97.20	96.38	97.24
4	2379.20	213.33	141.08	92.11	92.16	91.57
5	2107.17	199.91	132.03	94.53	93.22	95.21
6	2542.92	184.85	137.18	97.69	97.30	98.05
7	2265.83	176.69	122.19	95.98	94.37	96.56
8	1914.78	191.24	150.80	97.75	96.45	98.42
9	1987.96	172.58	128.76	98.43	96.27	99.02

由表 1 可以看出：①ISVDD 和 NSVDD 的训练速度要明显优于 OSVDD，其中 NSVDD 的训练速度最快；②OSVDD 和 NSVDD 的分类精度大体相当，都要优于 ISVDD。因而，NSVDD 的训练速度和分类精度最为理想，适合大规模数据的异常检测问题。

4 发动机异常检测实例

本节采用两组典型发动机异常实例进行实验，来

验证 NSVDD 在发动机异常检测中的有效性。

4.1 气路参数不匹配异常检测

发动机各气路部件之间具有复杂的随动和调控关系,因而相关气路参数存在高度相关性,气路系统异常会导致相关参数出现不匹配异常。某型发动机气路参数不匹配统计结果表明,转子转速和排气温度参数不匹配在气路参数不匹配中最为常见,二者不匹配的具体表现形式包括:一者保持稳定或正常变化,但另一者匀速变化或恒定不变;二者均“正常变化”,但总体变化趋势高度不相关等。

某架次飞行中出现了气路参数不匹配异常,相关时段的排气温度和高压转子转速参数变化曲线如图 2 和图 3 所示。在 1771 s 之前,排气温度和高压转子转速呈高相关性;在 1772 s 到 1790 s 之间,排气温度变化正常,而高压转子转速匀速下降,二者在多个时段出现明显的不匹配现象;在 1790 s 后的短时间内,排气温度和高压转子转速均比较稳定,二者变化关系恢复正常。




图2 排气温度参数




图3 高压转子转速参数

从某型发动机本架次以前 6 个月同 68 个飞行架次的飞参数据中,提取高压转子转速等 10 个气路参数构成训练集。训练集规模为 372945,均为发动机正常工作状态下的飞参数据。以本架次飞参数据中的 10 个气路参数构成测试集。NSVDD 参数 C 和 σ 分别设置为 0.5 和 0.05,异常检测结果如图 4 所示(标签 0 为正常,1 为异常)。可以看到,1772 s 到 1781 s,1785 s 到 1788 s 均检测出异常,与参数不匹配时段基本一致。经过地面排查,异常现象原因为转速传感器插头较脏且出现松动,造成飞参数据采集过程中的信号失真,清洁重插后试车,参数不匹配现象消失。




图4 气路参数不一致检测结果

4.2 双发参数不一致异常检测

某型飞机配备了左/右两台发动机,除单发启动、单发故障关车和特殊机动要求等情况外,左/右发动机均采用同步操作,即双发在绝大部分飞行时间内具有相同的调节控制率。另外,由于飞行过程中左/右发动机所处的环境条件也大致相同,故正常情况下双发的对应参数变化情况基本一致。某型发动机参数监控的实践经验表明,左/右发动机的对应参数构成参照关系,当单发出现异常状况时,会导致双发对应参数的变化趋势出现明显的不一致。

某架次飞行中,发生了双发排温不一致的异常状况,左/右发动机排气温度参数变化(局部)如图 5 所示,可以看出,右发动机排气温度全程低于左发动机,二者平均温差在 25℃ 左右。然而,对应时刻的左/右发动机高压转子转速(图 6 所示)基本一致,没有出现不一致状况,说明左/右发动机在该时段内为同步操作。由图 6 的高压转子转速参数变化范围可以判断该飞行时段内左/右发动机均处于巡航态,而由图 5 可以看出,右发动机排气温度平均值明显低于该型发动机巡航段的排气温度标准值,故可以初步推断导致参数不一致的故障发生在右发动机相关部件。




图5 排气温度参数




图6 高压转子转速参数

(下转第 56 页)

4 结论

1) 同一喷嘴装置采用多个喷嘴组合的方法对被检表进行检定实验, 多个不同喉部尺寸的喷嘴之间存在相互影响。由于喷嘴加工、安装和使用影响, 不同音速喷嘴装置间多个喷嘴组合的实验结果是不同的。所以在对音速喷嘴装置进行不确定度分析时应引入这一不确定度分量, 这样, 标准装置的评价工作以及流量计校准的结果才更加科学和准确。

2) 喷嘴间的相互影响在流量小时更为明显, 所以在使用装置检测小流量时, 选择单个喷嘴进行实验可以减小对实验结果的影响。

3) 通过不同喷嘴组合的喷嘴对流量计进行检测, 可以发现和找出喷嘴的问题。装置在使用时, 检测一些常用流量点都使用固定喷嘴或喷嘴组合, 所以长期使用某一喷嘴可能对其造成影响。在进行喷嘴装置设计时, 可以考虑同时安装几个相同口径的喷嘴, 既可以交替使用, 也可以通过组合的方式对装置进行核查。

(上接第 22 页)

从某型发动机本架次以前 6 个月同 62 个飞行架次的飞参数据中, 提取高压转子转速等 18 个双发高相关参数构成训练集。训练集规模为 648762, 均为发动机正常工作状态下的飞参数据。以本架次飞参数据中的 18 个双发高相关参数构成测试集。NSVDD 参数 C 和 σ 分别设置为 0.5 和 0.05, 异常检测结果如图 7 所示。除 2827 s 到 2833 s, 2880 s 到 2883 s 秒等少数时段外, 其它飞行过程都检测出了参数不一致异常。地面排查查明异常现象原因为右发动机单个热电偶出现性能故障, 更换热电偶后试车, 异常现象消除。




图 7 转速排气温度匹配度检测

5 结论

异常检测是航空发动机监控的重要研究内容之一, 然而飞参数据样本分布不均衡、数量大且随时间不断积累, 使得传统异常检测方法难以适用。本文将在线

参考文献

- [1] Stevens RL. Development and Calibration of the Boeing 18 Kg/s (40lbm/sec) Airflow Calibration Standard [C] // International Symposium on Fluid Flow Measurement. American Gas Association, ISFFM, 1986.
- [2] Richard W. Caron, Investigation into the Accuracy of Multiple Critical Flow Venturis Mounted in Parallel within a Common Plenum [C] // 4th International Symposium on Fluid Flow Measurement. ISFFM, 1999.
- [3] Yong Moon Choi. Interference effects between sonic nozzles [J]. Flow Measurement and Instrumentation, 1997, 8(2): 113–119.
- [4] Yong Moon Choi. Interference effects of three sonic nozzles of different throat diameters in the same meter tube [J]. Flow Measurement and Instrumentation, 1999, 10: 175–181.
- [5] Aaron N Johnson. U. S. National Standards for High Pressure Natural Gas Flow Measurement [S]. NISTSP, 2008.
- [6] GB/T21188–2007/ISO9300: 2005 用临界流文丘里喷嘴测量气体流量 [S]. 北京: 中国标准出版社, 2005.
- [7] 国家质量监督检验检疫总局. JJF1024–2010 临界流文丘里喷嘴法气体流量标准装置校准规范 [S]. 北京: 中国计量出版社, 2010.

SVDD 算法引入到航空发动机异常检测, 在对比分析现有在线 SVDD 算法性能的基础上, 采用 NSVDD 算法进行了发动机典型异常检测, 结果验证了 NSVDD 算法在发动机异常检测中的有效性。

参考文献

- [1] Kobayashi T, Simon D L. Integration of on-line and off-line diagnostic algorithms for aircraft engine health management [J]. Journal of Engineering for Gas Turbines and Power, 2007, 129: 986–993.
- [2] 赵连春, 杰克·马丁利. 飞机发动机控制—设计、系统分析和健康监视 [M]. 北京: 航空工业出版社, 2011.
- [3] 孙文柱, 曲建岭, 袁涛, 等. 基于改进 SVDD 的飞参数据新异检测方法 [J]. 仪器仪表学报, 2014, 35(4): 932–939.
- [4] Tax D, Laskov P. Online SVM learning: from classification to data description and back [J]. Neural networks and signal processing, 2003, 1: 499–508.
- [5] Hua X, Ding S. Incremental learning algorithm for support vector data description [J]. Journal of software, 2011, 6(7): 1166–1173.
- [6] Tavakkoli A, Nicolescu M, Nicolescu M, et al. Efficient background modeling through incremental support vector data description [C] // International Conference on Pattern Recognition, Tampa FL, 2008: 1–4.
- [7] Theljani F, Laabidi K, Zidi S, et al. Systems monitoring based on dynamic classification with SVDD [C] // International conference on systems, signal and devices. Hammamet Tunisia; 2013: 1–7.