

定向蚕食快速增量 SVDD 算法及其应用

仝奇¹, 胡双演¹, 叶霞¹, 张仲敏², 李俊山¹

(1. 火箭军工程大学信息工程系, 西安 710025; 2. 西安通信学院, 西安 710106)

摘要: 针对支持向量数据描述(SVDD)处理大规模样本时存在训练效率低的问题,提出了一种定向蚕食快速增量SVDD算法。首先随机抽取一定规模样本利用增量SVDD训练初始超球,并蚕食满足超球样本;然后每次选取距离上一超球最远的样本作为新增量样本,更新超球模型,使得增量SVDD的增长步长大于1;最后通过循环迭代,生成整个训练集的SVDD分类器。仿真和实例实验结果表明,与普通SVDD算法和增量SVDD算法相比,新算法在保证分类器性能的前提下,时间复杂度有了显著降低,模型训练效率也得到了进一步提高。

关键词: 支持向量数据描述; 模拟电路; 故障检测; 训练效率; 定向蚕食

中图分类号: TP391 **文献标志码:** A **文章编号:** 1671-637X(2016)10-0049-05

Directional Greed Incremental SVDD Algorithm and Its Application

TONG Qi¹, HU Shuang-yan¹, YE Xia¹, ZHANG Zhong-min², LI Jun-shan¹

(1. Department of Information Engineering, Rocket Force University of Engineering, Xi'an 710025, China;
2. Xi'an Communications Institute, Xi'an 710106, China)

Abstract: Considering that the Support Vector Data Description (SVDD) has low efficiency in training large scale samples, we put forward a novel directional greed incremental SVDD algorithm. Firstly, a certain amount of samples are randomly selected to train the original hypersphere by incremental SVDD, and the samples meeting the hypersphere requirement are nibbled away. Secondly, we choose the sample at the farthest distance to the former hypersphere as the new incremental sample at each time, and update the hypersphere model to make incremental SVDD growth step greater than the prior one. Finally, through iterative loop, the final SVDD is established for classifying whole training samples. The simulation results show that, compared with ordinary SVDD and incremental SVDD, the new algorithm has the advantages of lower time-consuming and higher model training efficiency in the premise of guaranteed classifier performance.

Key words: support vector data description; analog circuit; fault detect; training efficiency; directional greed

0 引言

当前,导弹电子防护装备中的电路板集成度越来越高,而模拟电路的故障诊断和维修能力相对较弱。在模拟电路故障判别初期,不可能包含所有的故障模式,如果盲目识别,必然会造成误判,因此采用合适的方法对电路进行快速高效的故障检测显得尤为重要。近几年,支持向量数据描述(Support Vector Domain Description, SVDD)^[1]解决了神经网络容易陷入局部极小点的问题,且具有依赖先验知识较少、泛化能力强等

优点,在异常检测中获得了越来越广泛的应用^[2-4]。

SVDD最早由文献[5]在支持向量机(Support Vector Machine, SVM)的基础上提出的,它的基本思想是寻找一个尽可能包含所有训练样本的最小超球体。与SVM相比,SVDD训练效率更高,可扩展性更强,虽然在异常检测中获得了一些成果,但是在处理大样本问题时,依然存在计算复杂度较大的问题,严重影响了战时电路的检测及设备维修的效率。为此,研究者又提出了许多改进方法,例如:文献[6]侧重凸二次规划问题的求解,提出了一种加速SVDD的方法;文献[7]针对SVDD计算复杂度太大的问题,提出了一种基于样本约简的实时SVDD算法,实验验证了算法能够有效削减训练复杂度,满足了故障检测的要求;文献[8-9]把

收稿日期:2015-09-14

修回日期:2015-10-16

作者简介:仝奇(1988—),男,河南开封人,硕士生,研究方向为装备故障诊断。

增量 SVM 的思想应用到 SVDD 的求解中,提出了增量 SVDD 算法 (Incremental SVDD, ISVDD),使 SVDD 的增长步长为 1,从而大大降低了算法复杂度。

为了让 SVDD 的增长步长以大于 1 的方式进行,从而进一步降低算法的时间复杂度,提高其模型训练的效率,本文提出了一种定向蚕食快速增量 SVDD 算法 (Directional Greed ISVDD, DGISVDD),并对 DGISVDD 进行了算法复杂度分析,先利用仿真数据集验证了算法的有效性,而后将该算法应用于模拟电路的故障检测,进一步验证了算法的实用性。

1 定向蚕食快速增量 SVDD 算法

1.1 ISVDD 算法

ISVDD 算法的基本思想可以概括为:首先利用两个原始样本作为目标样本训练初始超球,然后在此基础上,让剩余样本逐一加入目标样本集,通过调整相应参数,使得当前所有目标样本满足 KKT (Karush-Kush-Tucher)^[10] 条件,直至全部样本训练完毕。

SVDD 的目标样本集为 $X = \{x_1, x_2, \dots, x_N\}$,在其两类分类过程中,样本类别的判决函数为

$$f(x) = K(x, x) - 2 \sum_i \alpha_i K(x, x_i) + \sum_{i,j} \alpha_i \alpha_j K(x_i, x_j) \quad (1)$$

式中: x 为任意样本; x_i 为训练样本; α_i 为 SVDD 优化的拉格朗日系数; $K(\cdot, \cdot)$ 表示核函数。

SVDD 的训练优化经过对偶变换后,形成一个凸二次优化函数形式,即

$$\min_{0 \leq \alpha_i \leq C} W = - \sum_i \alpha_i Q_{ii} + \sum_{i,j} \alpha_i \alpha_j Q_{ij} + b \left(\sum_i \alpha_i - 1 \right) \quad (2)$$

式中: $Q_{ij} = K(x_i, x_j)$; b 为 SVDD 的优化补偿因子, $b = R^2 - \sum_{j,k} \alpha_j \alpha_k K(x_j, x_k)$; R 为目标超球体的半径。KKT 条件通过 W 的一阶导数可以表示为

$$g_i = \frac{\partial W}{\partial \alpha_i} = -Q_{ii} + 2 \sum_j \alpha_j Q_{ij} + b = \begin{cases} \geq 0 & \alpha_i = 0 \\ = 0 & 0 < \alpha_i < C \\ \leq 0 & \alpha_i = C \end{cases} \quad (3)$$

$$\frac{\partial W}{\partial b} = \sum_i \alpha_i - 1 = 0 \Rightarrow \sum_i \alpha_i = 1 \quad (4)$$

式中, C 为惩罚因子。式(3)和式(4)是式(2)凸二次优化的约束条件,所有训练样本的最优解都必须满足,当有新增加的样本出现时,可以通过改变整个模型的优化系数,使新的样本集合重新满足 KKT 条件,达到一种新的稳定最优解状态。

根据式(3)可以将目标训练样本集分为 3 部分:

1) 标准支持向量集 $S, R^2 = f(x)$; 2) 边界支持向量集 $E, R^2 < f(x)$; 3) 球内样本集 $R, R^2 > f(x)$ 。

当加入新的增量样本 x_c 时,为了保证所有训练样本能够满足 KKT 条件,系数变化量应满足

$$\Delta g_i = 2Q_{ic} \Delta \alpha_c + 2 \sum_{j \in S} Q_{ij} \Delta \alpha_j + \Delta b \quad (5)$$

$$\forall_i \in X \cup \{x_c\}$$

$$\Delta \alpha_c + \sum_{j \in S} \Delta \alpha_j = 0 \quad (6)$$

式(5)中: Δg_i 为 KKT 条件的微分形式; α_c 为新增样本 x_c 的优化系数; $\Delta \alpha_j$ 为加入新增样本以后,原有训练集中优化系数的变化量; $\Delta \alpha_c$ 为新增样本系数变化量,它的变化控制了整个 $\Delta \alpha_j$ 和 Δb 的变化,使最终所有样本都满足 KKT 条件,这是增量方法样本系数变化的理论依据。

1.2 DGISVDD 算法

ISVDD 相较于 SVDD,使 SVDD 增长步长为 1,时间复杂度由 $O(N^3)$ 降为 $O(N)$, N 为训练样本个数,从而大大降低了算法复杂度,模型训练效率也有了很大提高。而 DGISVDD 在 ISVDD 的基础上对其进行了改进,使得 SVDD 以大于 1 的步长增长,相较于 ISVDD 进一步降低了算法复杂度,提高了训练效率。

DGISVDD 算法的基本思路是:首先从目标样本中随机抽取一定规模样本利用增量 SVDD 算法建立初始超球模型,将满足初始超球的剩余样本直接蚕食;然后每次选取距离上一超球最远的样本作为最新样本,利用增量 SVDD 算法重新训练,得到新的超球模型,使得 SVDD 的增长步长以大于 1 的方式进行;最后通过循环迭代,生成整个训练集的 SVDD 分类器。

DGISVDD 的算法流程如图 1 所示。

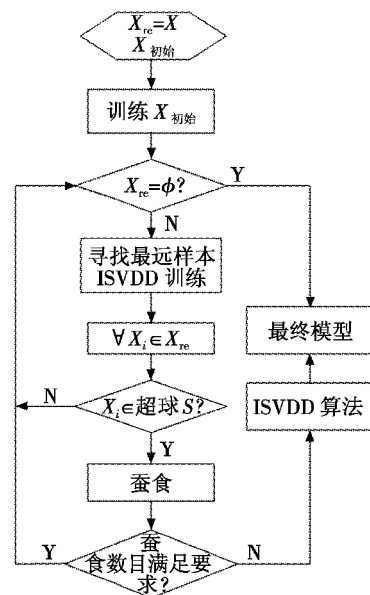


图 1 DGISVDD 算法流程

Fig. 1 Flow chart of DGISVDD algorithm

具体实施步骤如下:

1) 规范化原始样本集 X , 随机选取 n_0 个样本作为初始训练集 X_0 , 记剩余样本集为 X_m , 利用 X_0 训练得到初始超球体 S_0 和支持向量集 SV_0 ;

2) 将 X_m 中满足超球体 S_{i-1} 的样本直接蚕食;

3) 选取 X_m 中距离超球体 S_{i-1} 最远的样本作为 X_{new} , 利用 ISVDD 算法得到新的超球体 S_i 和支持向量集 SV_i ;

4) 若蚕食样本数满足要求, 则重复执行步骤 2) ~ 3), 否则转步骤 5);

5) 若 X_m 不为空, 则对 X_m 执行 ISVDD 算法, 更新超球体和支持向量集;

6) 返回当前超球体 S_i 和支持向量集 SV_i 作为最终模型。

1.3 DGISVDD 算法复杂度分析

传统 SVDD 由于需要求解二次规划问题, 其时间复杂度为 $O(N^3)$, 其中, N 为训练样本个数, 而 ISVDD 的时间复杂度为 $O(N)$, 相比之下, 时间复杂度已有了显著降低, 模型训练效率也有了很大提高^[9]。

对于 DGISVDD 而言, 每次模型更新都是选取距离上一超球最远的样本进行迭代, 而这些样本往往位于原始训练集边缘, 一般会成为最终模型的支持向量样本。因此, DGISVDD 的迭代次数会稍大于最终模型的支持向量样本个数, 设 N_{sv} 为支持向量样本数, 则算法的时间复杂度略大于 $O(N_{sv})$ 。一般情况下, 支持向量样本只占原始训练样本的一小部分, 所以 DGISVDD 算法可以进一步提高模型训练效率, 特别是当大样本问题的 N_{sv} 相对较少时, DGISVDD 的优势会更加明显。分析 DGISVDD 的训练过程, 可以发现以下现象。

1) 每次执行步骤 2) ~ 3) 时, 都需要测试当前剩余样本集 X_m , 但相比于求解 QP 问题或反复调整 Lagrange 系数, 它只涉及简单的运算, 复杂度可以忽略不计。

2) 执行步骤 5) 时, 需要对当前 X_m 执行 ISVDD 算法, 这会使得 DGISVDD 算法复杂度高于 $O(N_{sv})$, 具体情况由 X_m 规模决定, 而 X_m 规模取决于样本蚕食情况, 存在两种极端情形: 一种是算法没有蚕食任何样本, 此时 DGISVDD 退化为 ISVDD, 时间复杂度为 $O(N)$; 另一种是 X_m 为空集, 此时 DGISVDD 的时间复杂度为 $O(N_{sv})$ 。通常 DGISVDD 的时间复杂度在这两者之间, 一般会稍大于 $O(N_{sv})$ 。

2 仿真验证与结果分析

为了验证定向蚕食快速增量 SVDD 算法的有效性, 并与普通 SVDD 和 ISVDD 的训练效率进行对比, 在 Matlab2014a 环境平台下使用 dd_tools 工具箱, 通过 banana 数据进行仿真分析。

仿真实验主要验证 DGISVDD 的时间复杂度, 随机生成 600 个目标类 banana 样本和 100 个非目标类样本作为数据来源, 其中, 500 个目标样本用于超球模型训练, 剩余的 100 个目标样本和 100 个非目标样本用于模型测试。应用交叉验证法确定 DGISVDD 参数为 $(fracrej, \sigma) = (0.01, 0.5)$, 先通过随机抽样的方法随机从目标样本中选取 20 个样本训练初始超球模型, 然后按 DGISVDD 算法流程执行, 实验结果如图 2 所示。

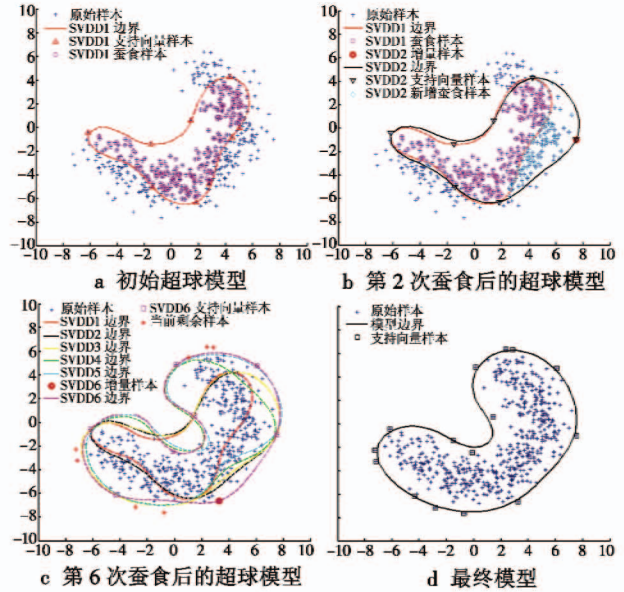


图 2 DGISVDD 算法效果图

Fig. 2 The effect of DGISVDD algorithm

从图 2 的实验结果可以看出, 超球模型蚕食样本的速度很快, 使得 SVDD 的增长步长以大于 1 的方式进行, 经过 6 次 SVDD 循环训练, 原始样本基本被蚕食完毕, 仅剩余 7 个样本, 6 次训练各自蚕食的样本数如图 3 所示。




图 3 6 次蚕食样本数

Fig. 3 Six rounds of greeding samples

将剩余的 100 个目标样本和 100 个非目标样本共 200 个样本作为测试样本, 分别对普通 SVDD, ISVDD 及 DGISVDD 的训练效果进行测试, 其中测试的准确率分别为 97%, 98% 和 97.5%, CPU 时耗分别为 5.25 s, 1.13 s 和 0.26 s。测试结果表明, DGISVDD 在保持训练

准确率基本不变的前提下,与普通 SVDD 和 ISVDD 相比,运行时间更快,时间复杂度明显降低。

为验证本文算法的通用性,从 UCI 的机器学习库

表1 算法在 UCI 数据的应用效果

Table 1 The application effect of algorithm in the UCI data

UCI 数据	训练样本	测试样本	准确率/%			CPU/s		
			SVDD	ISVDD	DGISVDD	SVDD	ISVDD	DGISVDD
Vehicle	200 (bus)	100;100 (bus;van)	0.97	0.98	0.96	5.43	1.24	0.23
Ionosphere	250 (good)	150;50 (good;bad)	0.96	0.96	0.98	6.62	1.34	0.28
Breastcancer	300 (ben)	150;100 (ben;mal)	0.98	0.96	0.96	7.13	1.35	0.31

从表1的实验结果可以看出,在同等实验条件下,DGISVDD 的诊断准确率与 SVDD 和 ISVDD 相比相差不大,基本相当。而在算法运行时间上,DGISVDD 与 SVDD 和 ISVDD 相比明显快了很多,DGISVDD 模型在 ISVDD 模型的基础上诊断效率有了进一步的提升。

经过分析可知,定向蚕食快速增量 SVDD 算法与普通 SVDD 和增量 SVDD 相比,在保证分类器性能的前提下,时间复杂度有了显著降低,模型训练效率也得到了进一步提高,说明本文算法是有效的。

3 实例验证与结果分析

为了检验 DGISVDD 算法的实用性,以 Sallen-Key 带通滤波器电路为例进行实验验证,如图4所示。




图4 Sallen-Key 带通滤波电路

Fig. 4 Sallen-Key band-pass filter circuit

1) 激励信号和测试点的选择。

输入节点为5的激励信号是幅度为5 V、基频为10 kHz 的电压信号,节点3为输出测试点。

2) 故障元件及故障模式选择。

采用 Multisim 软件以较难判断的软故障为主仿真待测电路。各元件的标称值已在图中标出,其中,电阻的容差范围为5%,电容的容差范围为10%。通过对电路进行灵敏度分析,发现 R2 和 C1 的灵敏度较高,对电路的输出影响最大,因此,把 R2 和 C1 两种故障模式都设定为异常状态,以便更好地检验算法对电路状态的判定。故障状态设定如表2所示,包括正常模式和两种故障模式,测试输出故障类别为 F1 时即为正常,

中任意选取3类真实数据集进行仿真实验验证,利用交叉验证法对参数进行优化,确定 DGISVDD 参数为 $(fracrej, \sigma) = (0.01, 0.5)$, 实验结果如表1所示。

为 F2 或 F3 时即为异常。

表2 电路故障状态设定表

Table 2 Circuits fault mode

电路状态	故障类型	故障模式	故障类别
正常		正常	F1
R2 故障	↑	超差 50%	F2
C1 故障	↑	超差 50%	F3

3) 故障样本的获取。

采集输出节点3的电压信号,利用 Multisim 先对正常模式进行160次的 Monte Carlo 分析,得到160个正常样本,而后分别对两种故障模式进行30次 Monte Carlo 分析,共得到60个故障样本,其中,120个正常样本用于超球模型训练,剩余的40个正常样本和60个故障样本一并用于模拟测试,以判定电路系统的运行状态是正常还是异常。

4) 故障诊断及结果分析。

先从120个正常样本随机选取10个样本利用 ISVDD 训练初始模型,然后按 DGISVDD 算法流程执行。参数设置为 $(fracrej, \sigma) = (0.01, 0.5)$, CPU 时耗为0.06 s,训练完之后用40个正常样本和60个故障样本共计100个作为测试样本,测试得到分类器准确率为97%。而在同样的实验条件下,用 SVDD 和 ISVDD 训练样本的 CPU 时耗分别为2.45 s 和1.02 s,测试的准确率分别为98%和97%。

根据上述分析及电路实验结果可以看出,在分类器性能没有下降的前提下,DGISVDD 算法有效削减了计算复杂度,模型相较于 ISVDD 算法和 SVDD 算法在训练速度上有一定的提高,说明 DGISVDD 算法应用于模拟电路故障检测是可行有效的。

4 结论

本文针对传统 SVDD 在训练大规模样本时间复杂度太大的问题,提出了一种定向蚕食快速增量 SVDD 算法。通过仿真实验验证了 DGISVDD 算法能够以大于1的步长增长,相较于 ISVDD 算法进一步降低了算法复杂度,提高了训练效率,证实了 DGISVDD 算法的

有效性。另外,将本文算法应用于模拟电路的故障检测,从实验结果可以看出,在保证分类器性能不下降的前提下,算法进一步提高了模拟电路的模型训练效率,证实了 DGISVDD 算法的实用性,表明新算法在模拟电路故障检测中具有很大的应用潜力。

参考文献

- [1] TAX D M J, DUIN R P W. Support vector data description [J]. *Machine Learning*, 2004, 54(1):45-66.
- [2] SHIN H J, EOM D H, KIM S S. One-class support vector machines-an application in machine fault detection and classification[J]. *Computers & Industrial Engineering*, 2005, 48(2):395-408.
- [3] ZHUANG J F, LUO J, PENG Y Q, et al. On-line fault detection method based on modified SVDD for industrial process system[C]//IEEE Xplore, Intelligent System and Knowledge Engineering, 2008:567-572.
- [4] XIE L, KRUGER U. Statistical processes monitoring based on improved ICA and SVDD[J]. *Intelligent Computing*, 2006, 4113(3):1247-1256.
- [5] TAX D M J. One-class classification [D]. Netherlands: Technische Universiteit Delft, 2001.
- [6] CHU C S, TSANG I W, KWOK J T. Scaling up support vector data description by using core-sets[C]//IEEE International Joint Conference on Neural Networks, 2004: 425-430.
- [7] 杜敏杰,蔡金燕.基于样本约简的实时 SVDD 算法与电路故障检测应用[J]. *微电子学与计算机*, 2013, 30(7): 86-90. (DU M J, CAI J Y. A real time SVDD algorithm based on samples-reduced and its fault detection application in circuit[J]. *Microelectronics & Computer*, 2013, 30(7):86-90.)
- [8] TAX D M J, LASKOV P. Online SVM learning: from classification to data description and back[C]//Proceedings of IEEE International Workshop on Neural Networks for Signal Proceeding, 2003:499-508.
- [9] CAUWENBERGHS G, POGGIO T. Incremental and decremental support vector machine learning[J]. *Advances in Neural Information Processing Systems*, 2001, 13(5):409-415.
- [10] GALMEANU H, ANDONIE R. Implementation issues of an incremental and decremental SVM [C]//The 18th International Conference on Artificial Neural Networks, 2008:325-335.
- (上接第 20 页)
- [J]. *Journal of Beijing University of Chemical Technology; Natural Science Edition*, 2015(2):102-106.)
- [3] LI H, WU Q H, HUANG H. Control of spatially interconnected systems with random communication losses [J]. *Acta Automatica Sinica*, 2010, 36(2):258-266.
- [4] MA W G, SHAO C. Stochastic stability for networked control systems [J]. *Acta Automatica Sinica*, 2007, 33(8): 878-882.
- [5] SIMON D. 最优状态估计:卡尔曼, H_∞ 及非线性滤波 [M]. 北京:国防工业出版社, 2013. (SIMON D. *Optimal state estimation: Kalman, H_∞ and nonlinear approaches* [M]. Beijing: National Defense Industry Press, 2013.)
- [6] 杨小军. 基于 Unscented 信息滤波器的分布式目标融合跟踪[J]. *吉林大学学报:工学版*, 2015, 45(2):658-662. (YANG X J. Distributed fusion and target tracking based on Unscented information filter[J]. *Journal of Jilin University: Engineering and Technology Edition*, 2015, 45(2):658-662.)
- [7] 林浩申,黄璜,刘刚,等.基于 SCKF 算法的空间机动目标跟踪研究[J]. *光电与控制*, 2015, 22(3):64-68. (LIN H S, HUANG H, LIU G, et al. Tracking of maneuvering spatial target based on SCKF [J]. *Electronics Optics & Control*, 2015, 22(3):64-68.)
- [8] 赵光琼,陈绍刚,付奎,等.基于变尺度变换减少 Sigma 点的粒子滤波算法研究[J]. *自动化学报*, 2015, 41(7):1350-1355. (ZHAO G Q, CHEN S G, FU K, et al. A particle filter algorithm based on scaled UKF with reduced Sigma points[J]. *Acta Automatica Sinica*, 2015, 41(7): 1350-1355.)
- [9] 余辉荣,夏侯恺顺,叶景志,等.基于扩展卡尔曼滤波的自适应混合估计算法[J]. *自动化与仪表*, 2014(1):6-10. (YU H R, XIAHOU K S, YE J Z, et al. Self-adaptive hybrid estimation algorithm based on extended Kalman filter[J]. *Automatic & Instrumentation*, 2014(1):6-10.)
- [10] MA J, SUN S L. Information fusion estimators for systems with multiple sensors of different packet dropout rates [J]. *Information Fusion*, 2011, 12(3):213-222.
- [11] LIU X, GOLDSMITH A J. Kalman filtering with partial observations [C]//IEEE Conference Decision Control, 2004:1413-1418.
- [12] MAO Y H, HAN C Z, DUAN Z S. Dynamic error spectrum for estimation performance evaluation;a case study on interacting multiple model algorithm[J]. *The Institution of Engineering and Technology*, 2014, 8(2):202-210.
- [13] SUN S L. Optimal estimator for systems with finite consecutive packet dropouts [J]. *IEEE Signal Processing Letters*, 2009, 16(7):557-560.
- [14] 许大星. 非线性系统的几种滤波算法研究[D]. 杭州:杭州电子科技大学, 2013. (XU D X. *Research on several filtering algorithms with non-linear system* [D]. Hangzhou: Hangzhou Dianzi University, 2013.)