

文章编号:1007-5321(2021)06-0096-07

DOI:10.13190/j.jbupt.2021-045

# 敏捷化 AIOps 框架及运维数据质量评估方法

吴振宇, 施 畅

(北京邮电大学 教育部信息网络工程研究中心, 北京 100010)

**摘要:** 敏捷化智能运维(AIOps)框架将模型构建提前至测试阶段,利用该阶段产生的监控数据代替线上采集的数据以训练 AIOps 模型,进而实现智能运维的早开发与早使用. 运维数据质量评估方法通过最大均值差异度量方式,分别在健康评估与故障诊断运维场景下对训练数据分别进行趋势性、阶段性、可检测性及可诊断性评估,以预估数据对模型的适用性. 基于华为技术有限公司提供的测试环境设置测试用例并构建实验数据集,在该数据集上的实验结果验证了敏捷化 AIOps 框架的可行性及数据质量评估方法的有效性.

**关 键 词:** 智能运维; 敏捷化框架; 数据质量评估; 最大均值差异

**中图分类号:** TP311

**文献标志码:** A

## Agile AIOps Framework and Maintenance Data Quality Assessment Method

WU Zhen-yu, SHI Chang

(Engineering Research Center for Information Network(Ministry of Education), Beijing University of Posts and Telecommunications, Beijing 100010, China)

**Abstract:** An agile artificial intelligence for information technology operations(AIOps) framework and maintenance data quality assessment method are proposed. The agile AIOps framework advances the model construction stage to the test stage, and uses the monitoring data generated during the test stage to replace the data collected online to train the model, thereby realizing the early development and early use of intelligent operation. The maintenance data quality assessment method is based on the maximum mean discrepancy to evaluate the trend, stage, detectability, and diagnosability of training data for health assessment and fault diagnosis, so as to estimate the applicability of the data to the model. Based on the test environment provided by Huawei, the test cases are set up and the experimental data set is constructed. The experimental results on the data set verify the feasibility of the agile AIOps framework and the effectiveness of the data quality assessment method.

**Key words:** artificial intelligence for information technology operations; agile framework; data quality assessment; maximum mean discrepancy

随着云计算与人工智能的快速发展,信息技术的智能运维(AIOps, artificial intelligence for information technology operations)已成为热门的运维技

术<sup>[1]</sup>. 2016 年, Gartner 公司提出了 AIOps 概念, AIOps 将人工智能技术与运维场景相结合,在性能指标、监控日志、应用信息等海量数据中学习并不断

收稿日期: 2021-04-09

基金项目: 广东省重点领域研发计划项目(2020B0101130013); 2020 年工业互联网创新发展工程项目(2020GXb001)

作者简介: 吴振宇(1986—), 男, 副教授, E-mail:shower0512@bupt.edu.cn.

提炼规则来代替人为制定的规则,进而解决自动化运维无法解决的问题<sup>[2]</sup>. AIOps 建立在大数据的基础上,常采用在线数据或离线历史数据训练 AIOps 模型<sup>[3-5]</sup>,但对于不具有历史数据的新系统而言,系统需在无智能运维环境下运行足够时间以采集满足模型构建需求的数据,而在此期间极易使系统性能的可靠性下降.

除此之外,监控数据通常存在一些问题,如数据包含监控指标众多或包含多种事件发生阶段,难以确定哪些指标或阶段的数据有助于模型的构建,如果选用数据不恰当,将会影响模型的效果. 因此,需要在模型构建之前,用数据质量评估系统预估数据的适用性. 现有的数据质量评估系统主要评估数据的基本属性,例如一致性、完整性等<sup>[6-8]</sup>,然而这些属性并不能很好地衡量数据集是否适用于 AIOps 模型的构建. 决定 AIOps 模型性能的重要因素是特征的“代表性”. 以健康评估和故障诊断 2 个运维场景为例,代表性度量指标可划分为趋势性、阶段性、可检测性及可诊断性. 目前针对这方面的研究较少, Jia 等<sup>[9]</sup>在工业领域提出了评估数据是否符合故障预测与健康管理的研 究,基于最大均值差异评估了数据的趋势性、可检测性及可诊断性. 然而工业数据与信息技术(IT, information technology)运维数据存在差异,评估系统无法通用,所以针对 AIOps 模型构建的实际数据需求,需要改进数据质量的评估方法.

为了解决上述问题,笔者提出了敏捷化 AIOps 框架及运维数据质量的评估方法,主要工作包括:

1) 设计了一种敏捷化 AIOps 框架,将智能运维模型的构建阶段提前至系统测试阶段,并利用测试阶段产生的监控数据训练 AIOps 模型,以实现智能运维的早开发、早使用和敏捷迭代;

2) 提出了一种基于最大均值差异(MMD, maximum mean discrepancy)的运维数据质量评估方法,在健康评估和故障诊断运维场景下预估训练数据对模型训练的适用性,避免无效数据参与训练带来的时间和资源上的损失;

3) 基于华为技术有限公司提供的测试环境设置测试用例并构建实验数据集,实验结果验证了敏捷化 AIOps 框架的可行性及数据质量评估方法的有效性.

# 1 面向 AIOps 敏捷化的数据质量评估方法

## 1.1 AIOps 敏捷化方案

在传统 AIOps 流程(见图 1)中,运维模型的训练与开发在系统的部署上线之后,需收集足够有效的数据才能对运维模型进行构建,然而收集数据阶段并没有部署完善的运维系统,导致系统不可靠甚至影响用户体验. 由此,提出了一种敏捷化 AIOps 框架,将运维模型的构建任务提前到测试阶段. 为了更好地利用测试数据,在 AIOps 模型训练之前设计了数据质量评估模块,以预估数据对模型的适用性,最后将运维模型部署到系统上,再通过不断采集在线数据,对运维模型进一步优化.

从软件敏捷化开发角度来看,AIOps 框架无需

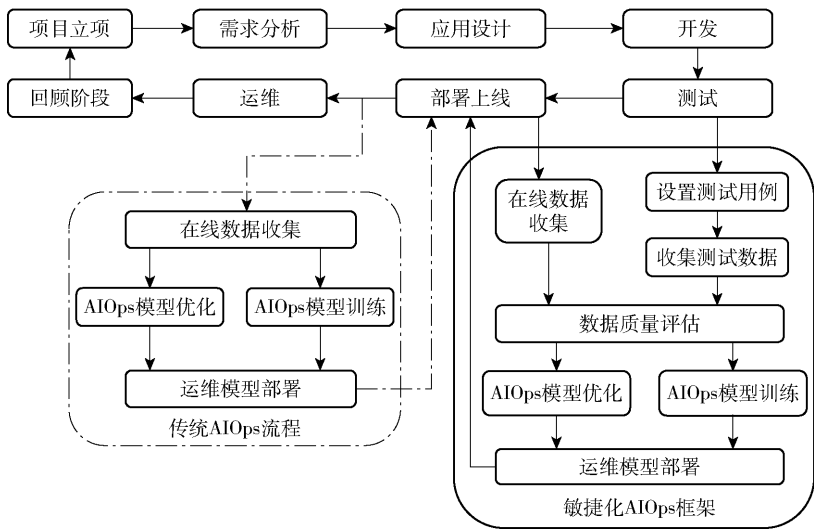


图 1 AIOps 传统流程及敏捷化 AIOps 框架

等待系统上线后采集监控数据,缩短了运维模型的开发时间,使 AIOps 模型在系统上线前即完成构建,在系统部署上线之后降低了系统风险,提高了系统的可靠性及用户体验。

## 1.2 数据质量评估方法

根据敏捷化 AIOps 框架,针对健康评估和故障诊断 2 种运维场景,设计了一种数据质量的评估方法,其流程如图 2 所示。

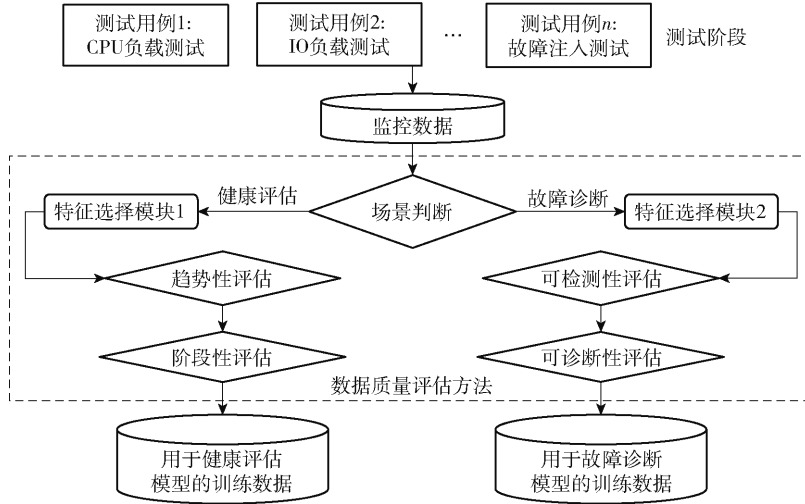


图2 数据质量评估流程

在数据质量评估流程中,将测试阶段采集的监控数据作为系统的输入。对于每个场景,采用相应的特征选择方法对特征空间数据进行相应的评估,并进行排序,排名最高的特征空间数据将用于该场景下的 AIOps 模型训练。

### 1.2.1 健康评估场景下的数据质量评估方法

适用于构建健康评估模型的数据应具备的特征包括两方面。

- 1) 趋势性。数据总体趋势与 IT 系统健康趋势保持一致或相反,即数据可以表征系统的健康变化;
- 2) 阶段性。数据可划分成若干阶段,不同阶段对应 IT 系统的不同健康状态。

针对健康评估的需求,特征选择模块 1 提供了  $m$  种特征选择方法,将每个特征空间的数据切分成  $N$  个大小为  $w$  的时间窗,计算每个时间窗的特征分布与第 1 个时间窗特征分布之间的最大均值差异,记作  $D$ , $D$  是长度为  $N$  的时间序列,其中第  $t$  个窗口的 mmd 值记作  $D_t$ ,其计算方法为

$$D_t(X_1, X_t) = \left\| \frac{1}{w} \sum_{i=1}^w \phi(X_{1i}) - \frac{1}{w} \sum_{i=1}^w \phi(X_{ti}) \right\|_H^2 \quad (1)$$

其中: $w$  为时间窗的大小, $X_1$  为第 1 个时间窗的特征分布, $X_t$  为第  $t$  个时间窗的特征分布, $H$  表示此公式是在再生希尔伯特空间中进行的。

可通过 Mann-Kendall 检验法中的统计量  $S_{\text{UFk}}$  和

$S_{\text{UBk}}$  表示  $D$  的变化趋势。根据先验知识设置一个能够直接反映系统运行状况的趋势指标,作为“健康特征”,记作  $A$ ,用于评估系统趋势的基准。同样利用 Mann-Kendall 检验法中的统计量  $S'_{\text{UFk}}$  和  $S'_{\text{UBk}}$  表示健康特征的变化趋势,并利用 Pearson 相关系数计算健康特征与特征空间数据趋势的一致性  $\rho_v$ ,计算方法为

$$\rho(S_{\text{UFk}}) = \frac{\text{cov}(S_{\text{UFk}}(D_t), S_{\text{UFk}}(A))}{\sigma_{S_{\text{UFk}}(D_t)} \sigma_{S_{\text{UFk}}(A)}} \quad (2a)$$

$$\rho(S_{\text{UBk}}) = \frac{\text{cov}(S_{\text{UBk}}(D_t), S_{\text{UBk}}(A))}{\sigma_{S_{\text{UBk}}(D_t)} \sigma_{S_{\text{UBk}}(A)}} \quad (2b)$$

$$\rho_v = \frac{(|\rho(S_{\text{UFk}})| + |\rho(S_{\text{UBk}})|)}{2} \quad (2c)$$

将不同特征空间获取的  $\rho_v$  进行排序,选择最大的  $\rho_v$  记为  $\rho_{v,m}$ ,同时设置阈值  $\rho'$ ,若  $\rho_{v,m} > \rho'$ ,则  $\rho_{v,m}$  对应的特征空间数据可进入下一个模块,即阶段性评估;若  $\rho_{v,m} \leq \rho'$ ,则说明原始数据并不包含能表征系统健康趋势的特征,需要重新设置测试用例或采集更有效的监控数据。

阶段性评估首先将通过趋势性评估的特征空间数据的第 1 个时间窗口设置为基准窗口,计算下一个时间窗与基准窗口的 mmd 值,如第 2 个时间窗与基准窗口的 mmd 值,记为  $D_2$ ,同时设置阈值  $D'$ 。若  $D_2 \leq D'$ ,则认为第 2 个窗口与第 1 个窗口属于 1 个阶段,继续计算第 3 个窗口与基准窗口的 mmd 值,

依此类推;若  $D_2 > D'$ , 则认为第 2 个窗口与第 1 个窗口不属于 1 个阶段, 第 1 阶段结束, 转而将第 2 窗口作为基准窗口, 继续计算下一个窗口与基准窗口之间的最大均值差异。重复上述操作直至遍历所有时间窗口, 并统计设置过的基准窗口数量, 即可划分的阶段数为  $n$ 。根据 IT 系统健康状态的变化, 预估不同状态的种类数目作为阈值, 若  $n$  超过阈值范围, 则认为该数据具有足够的阶段性, 可用于构建健康评估模型; 否则认为该数据阶段性不够明显, 不适用构建健康评估模型, 需要重新设置测试用例或采集更有效的监控数据。

### 1.2.2 故障场景下的数据质量评估方法

适用于构建故障诊断模型的数据应具备的特征包括两方面。

1) 可检测性。可区分故障与正常样本。

2) 可诊断性。可区分不同故障。

针对故障诊断模型的需求, 特征选择模块 2 提供了  $m$  种特征选择方法。将每个特征空间的数据切分成  $N$  个大小为  $w$  的时间窗。选取部分正常样本作为基准样本  $S$ , 计算每个时间窗样本与基准样本的 mmd 值, 根据各个窗口的 mmd 值分布, 找到最佳分类边界  $D_{\text{bord}}$ 。采用  $F_1$  分数评估故障样本的识别效果, 通过比较不同特征空间数据产生的  $F_1$  分数, 得到最大的  $F_1$  分数, 记为  $F_{1-\max}$ , 同时设置阈值  $F$ , 若  $F_{1-\max} > F$ , 则认为  $F_{1-\max}$  对应特征空间数据的可检测性较好, 可进入下一阶段的可诊断性评估; 否则认为该原始数据不包含区分正常与故障的重要特征, 不适用构建故障诊断模型, 需要重新设置测试用例或采集更有效的监控数据。

可诊断性评估模块的输入数据为完成可检测性评估的数据样本, 其中包含多种不同的故障样本, 选择每种故障样本的部分数据作为基准样本  $S_1, S_2, \dots, S_m$ , 计算每个时间窗口与每个基准样本的 mmd 值, 并根据 mmd 值的分布, 自动查找最佳分类边界  $D'_{\text{bord}}$ 。同样采用  $F_1$  分数来评估故障的识别效果, 每个故障会得到一个  $F_1$  分数并计算其平均值:

$$F_{1-\text{avg}} = \frac{(F_{1-1} + F_{1-2} + \dots + F_{1-m})}{m} \quad (3)$$

其中  $F_{1-1}, F_{1-2}, \dots, F_{1-m}$  分别表示不同类故障得到的  $F_1$  分数。设置阈值  $F'$ , 若  $F_{1-\text{avg}} > F'$ , 则认为该特征空间的数据不仅可以区分故障与正常样本, 也可以区分不同类别的故障, 可以用于构建故障诊断模

型; 否则认为该原始数据不能区分不同类别的故障, 不适用于构建故障诊断模型, 需要重新设置测试用例或重新采集其他有效的监控指标。

## 2 实验与评估

### 2.1 实验环境及数据集介绍

华为技术有限公司提供的测试环境(见图 3)模拟了微服务的通信过程, 并针对 2 个场景分别设置测试用例。

1) 测试用例 1。针对健康评估场景, 进行负载加压测试, 使通信过程中的健康状态呈现一定的变化, 将通信时延作为表征微服务通信系统运行健康状态的通用指标, 监控测试实验的进行。

2) 测试用例 2。针对故障诊断场景, 采用 linux 命令在微服务正常通信的过程中注入了进程退出、进程挂死、节点宕机、CPU 过载以及内存溢出 5 种常见故障。

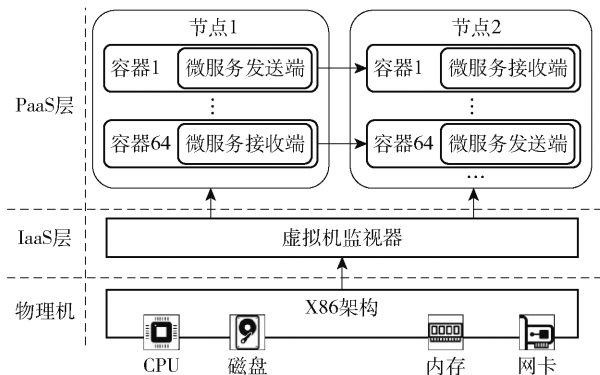


图3 测试环境

在测试阶段, 采集监控日志并进行时间序列提取等操作, 最终得到一个包含近 20 维的初始数据集, 用于数据质量评估方法的评估实验。

### 2.2 健康评估场景下的实验设置与结果分析

对于测试用例 1 中得到的监控数据集, 根据先验知识将通信时延设为健康特征  $A$ , 并在特征选择模块 1 上设置如下 3 种特征空间。

1) S1: 未经过特征选择的全特征空间。

2) S2: 基于 Pearson 相关系数的特征选择方法。

3) S3: 基于 Mann-Kendall 和 Pearson 相关系数的特征选择方法。

将数据切分成若干个时间窗, 计算每个窗口与第 1 个窗口的 mmd 值, 最终获得随时间变化的  $D$ 。再用 Mann-Kendall 方法表征变化趋势, 如图 4 所示。






图 4 基于 Mann-Kendall 表征 mmd 值序列与通信时延的趋势

计算的相关系数如表 1 所示.  $\rho_{v,m}$  出现在 S3, 并远大于阈值 0.8, 所以特征空间 S3 可作为阶段性评估的输入.

表 1 不同特征空间的相关系数

特征空间	$\rho(S_{UFk})$	$\rho(S_{UBk})$	$\rho_v$
S1	-0.656 7	0.045 2	0.351 0
S2	-0.742 7	0.392 8	0.567 8
S3	-0.929 9	0.899 5	0.914 7

不同特征空间的相关系数如表 2 所示. 对于 S3 的数据, 将基准窗口设置成 win\_1, 计算 win\_2 与 win\_1 的 mmd 值  $D_2$ , 并设置阈值  $D'$  为 1.0. 由于  $D_2 < D'$ , 说明第 2 个时间窗与第 1 个时间窗属于同一阶段, 继续计算下一个窗口与基准窗口的 mmd 值, 直到 win\_244 对应的  $D_{244} > D'$ , 说明从第 244 个时间窗开始进入了第 2 阶段, 并将 win\_244 作为基准窗口, 重复上述操作, 直至遍历所有窗口. 阶段性评估过程中设置过 3 次基准窗口, S3 的数据可以划分成 3 个阶段, 具有一定的阶段性, 可用于构建健康评估模型.

为了验证趋势性和阶段性评估的有效性, 利用

表 2 不同特征空间的相关系数

时间窗口 ID	win_1	win_244	win_2600
win_1	0	/	/
win_2	0.301 2	/	/
...	...	...	...
win_243	0.351 7	/	/
win_244	1.775 3	0	/
win_245	/	0.392 8	/
...	...	...	...
win_2599	/	0.951 8	/
win_2600	/	2.748 6	0
win_2601	/	/	0.107 6
...	...	...	...

3 种特征空间的数据训练基于 TICC (toeplitz inverse covariance-based clustering) 时间聚类分割的健康评估模型<sup>[10]</sup>, 结果如图 5 所示.

从图 5 中可以看到, 忽略一些噪声点, 不同特征空间的数据可以聚类分割成多个阶段, 也呈现出一定的趋势. 对照图 4 (b) 中通信时延的变化, 即真实的通信健康状态变化, 可以看出, 由 S3 构




图 5 不同特征空间数据得到的健康评估结果

建的健康评估模型很好地表征了通信状态的健康趋势[见图 5(c)],而图 5(a)和(b)所示的趋势性和阶段性并不符合真实的健康变化情况. 由此可以验证,通过趋势性与阶段性评估的 S3 更适用于构建健康评估模型,也进一步验证了所提评估方法的有效性.

2.3 故障诊断场景下的实验设置与结果分析

对于测试用例 2 中得到的监控数据集,特征选择模块 2 设置了以下 3 种特征空间.

- 1) P1: 未经过特征选择的全特征空间.
- 2) P2: 基于递归特征消除的特征选择方法.
- 3) P3: 基于 Lasso 正则化的特征选择方法.

对于可检测性评估,同样切分时间窗口,选择基准样本  $S$ , 计算每个时间窗口与基准窗口的 mmd 值,图 6 所示为不同特征空间 mmd 值随时间窗口的分布. 通过计算最佳分类边界  $D_{bord}$ ,得到的  $F_1$  分数分别为 81.81%, 88.89%, 100%, 其中特征空间 P3 表现出的可检测性较强,可选择其进入下一阶段的可诊断性评估.

可诊断性评估模块在每种故障中选择其类别故障的基准样本,计算每个窗口与基准样本的

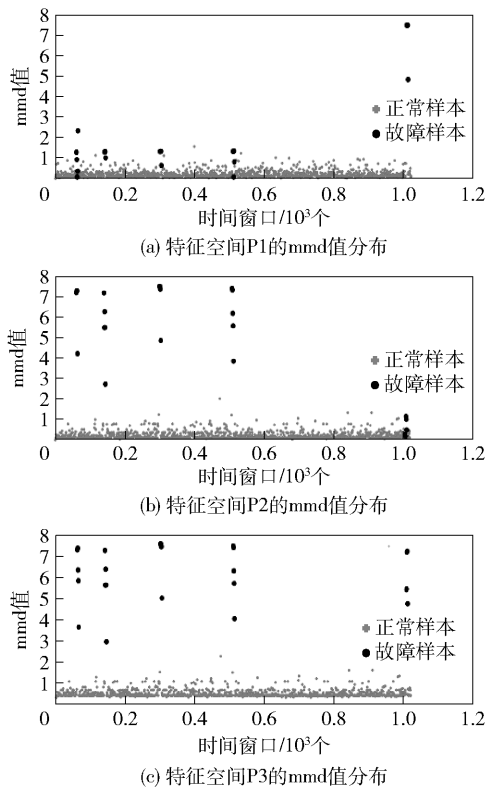


图 6 不同特征空间的 mmd 值随时间的分布

mmd 值. 图 7 所示为不同故障作为基准窗口时的 mmd 值分布. 通过计算最佳分类边界  $D'_{bord}$ ,得到图中对应  $F_1$  分数分别为 100%, 97.58%, 98.55%, 99.10% 和 94.53%, 计算求得  $F_{1-avg} = 97.952\%$ , 设置阈值  $F' = 0.9$ ,  $F_{1-avg}$  超过阈值. 从图 7 可以看出, P3 的数据分布可以很好地区分不同类型的故障,即具有较好的可诊断性,可以用于构建故障诊断模型.

为了验证可检测性与可诊断性评估的有效性,采用上述 3 种数据对基于支持向量机的故障诊断模型进行训练和验证.

如表 3 所示,区分故障和正常样本时, P3 表现最佳, P2 次之, P1 最差, 与图 6 所示的评估结果一致. 从表 4 可见, 区分不同类型故障时, P3 的表现仍然最佳, 与图 7 所示的评估结果一致, 由此验证此方法有效地评估了数据的可检测性和可诊断性.

为了验证 MMD 的优势, 利用其他测量分布差异的方法在 P3 进行上述实验. 从表 5 和表 6 可以看出, 基于 MMD 评估的  $F_1$  值比其他测量方式的  $F_1$  值要大, 即基于 MMD 的评估会更准确地评估故障和正常以及故障和故障样本间的差异.

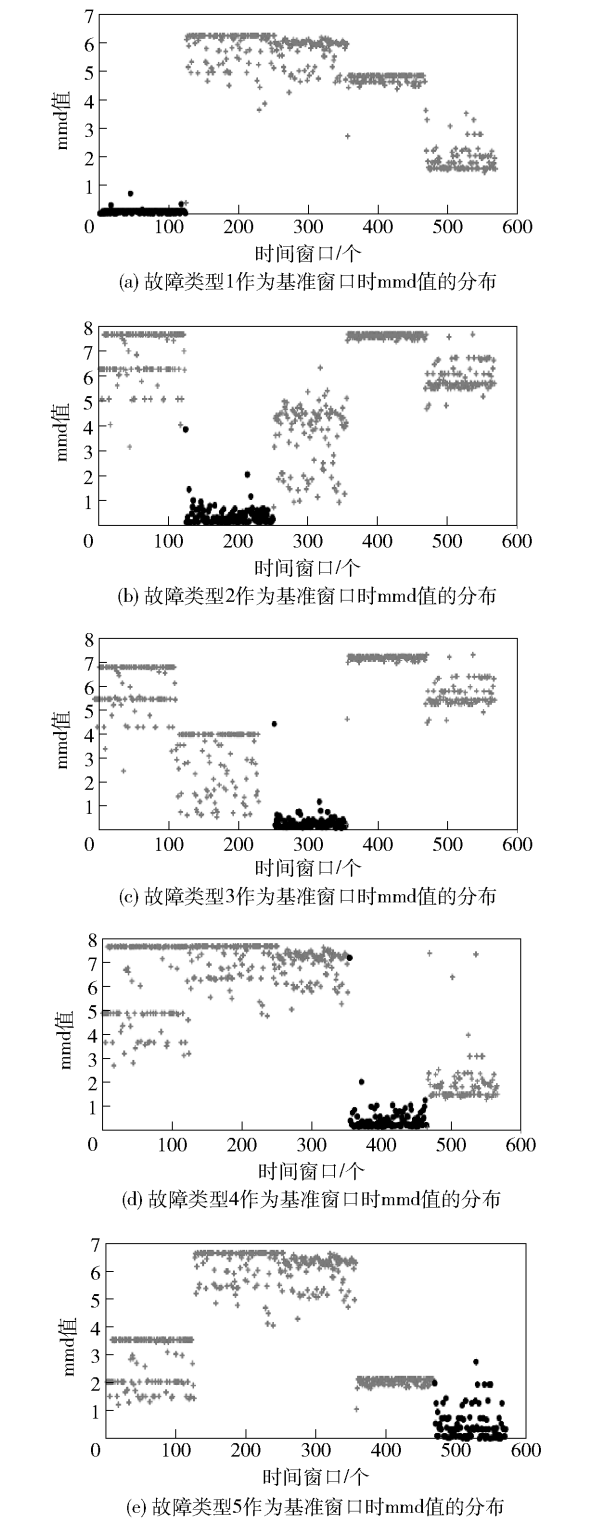


图 7 不同故障诊断类型作为基准窗口时 mmd 值的分布

表 3 不同特征空间数据得到的正常与故障诊断结果			
状态	P1	P2	P3
故障, $F_1$	0.68	0.91	0.98
正常, $F_1$	0.99	1.00	1.00

表 4 不同特征空间数据得到的不同类型故障诊断结果

故障类型	P1	P2	P3
1, $F_1$	0.99	0.99	1.00
2, $F_1$	0.97	1.00	0.98
3, $F_1$	0.92	0.97	0.99
4, $F_1$	0.99	0.99	1.00
5, $F_1$	0.90	0.94	0.97
平均 $F_1$	0.954	0.978	0.988

表 5 基于不同测量分布差异方法的可检测性评估结果

状态	MMD	EUD	CHED	MAND	WASD
故障, $F_1$	0.98	0.75	0.73	0.75	0.72
正常, $F_1$	1.00	0.80	0.78	0.80	0.78

表 6 基于不同测量分布差异方法的可诊断性评估结果

故障类型	MMD	EUD	CHED	MAND	WASD
1, $F_1$	1.00	0.98	0.98	0.98	0.73
2, $F_1$	0.98	0.92	0.82	0.99	0.78
3, $F_1$	0.99	0.84	0.63	1.00	0.84
4, $F_1$	1.00	0.99	0.99	0.99	0.98
5, $F_1$	0.97	0.46	0.46	0.56	1.00
平均 $F_1$	0.988	0.838	0.776	0.904	0.988

3 结束语

提出了敏捷化 AIOps 框架,以解决新系统缺少数据的问题并降低系统风险. 同时,针对健康评估与故障诊断场景设计了一种基于最大均值差异的数据质量评估方法,以预估数据对模型构建的适用性. 最后,通过案例验证了敏捷化 AIOps 框架的可行性和数据质量评估方法的有效性.

参考文献:

[1] 裴丹, 张圣林, 裴昶华. 基于机器学习的智能运维[J]. 中国计算机学会通讯, 2017, 13(12): 68-72.

[2] 彭冬, 朱伟, 刘俊, 等. 智能运维: 从 0 搭建大规模分布式 AIOps 系统[M]. 北京: 电子工业出版社, 2018.

[3] Dang Yingnong, Lin Qingwei, Huang Peng. AIOps: real-world challenges and research innovations [C] // 2019 IEEE/ACM 41st International Conference on Software Engineering: Companion Proceedings (ICSE-Companion). Montreal: IEEE ACM, 2019: 4-5.

- of miniaturized microstrip antenna for WiMAX [J]. *Electronic Components and Materials*, 2019, 38(5): 68-72.
- [6] 严冬, 杜培勋, 王平, 等. 2.4 GHz 宽带圆极化微带天线的研究与实现[J]. *电波科学学报*, 2019, 34(3): 380-389.
- Yan Dong, Du Peixun, Wang Ping, et al. Research and implementation of 2.4 GHz broadband circularly polarized microstrip antenna [J]. *Chinese Journal of Radio Science*, 2019, 34(3): 380-389.
- [7] 刘敏, 张斌珍, 段俊萍, 等. 应用于 WLAN/WIMAX 的宽带单极子天线[J]. *测试技术学报*, 2017, 31(5): 410-415.
- Liu Min, Zhang Binzhen, Duan Junping, et al. Broad-band monopole antenna applied to WLAN/WIMAX [J]. *Test Technology Xuebao*, 2017, 31(5): 410-415.
- [8] 严冬, 李思伟, 胡安沙, 等. 基于耦合倒 L 加载法的 WLAN 双频印刷天线的设计[J]. *电子元件与材料*, 2019, 38(3): 56-61.
- Yan Dong, Li Siwei, Hu Ansha, et al. Design of WLAN dual-band printed antenna based on coupled inverted L loading method [J]. *Electronic Components and Materials*, 2019, 38(3): 56-61.
- [9] Dou Y. A low profile dual-band high gain directional antenna for anti-interference WLAN station applications[J]. *Applied Sciences-Basel*, 2021, 11(5): 2007-2014.
- [10] Khan Z. A single-fed multiband antenna for WLAN and 5G applications[J]. *Sensors*, 2020, 20(21): 1-13.

(上接第 102 页)

- [4] Fu Qiang, Lou Jianguang, Lin Qingwei, et al. Performance issue diagnosis for online service systems[C]//2012 IEEE 31st Symposium on Reliable Distributed Systems. Irvine: IEEE Press, 2012: 273-278.
- [5] 凌政, 安藤. AIOPS 平台建设和实践[J]. *网络安全和信息化*, 2020, 46(2): 8-9.
- [6] Mendes P N, Mühleisen H, Bizer C. Sieve: linked data quality assessment and fusion[C]//Proceedings of the 2012 Joint EDBT/ICDT Workshops on-EDBT-ICDT'12. Berlin: ACM Press, 2012: 116-123.
- [7] Cai Li, Zhu Yangyong. The challenges of data quality and data quality assessment in the big data era[J]. *Data Science Journal*, 2015, 14: 2-3.
- [8] Guo Aizhang, Liu Xiuyuan, Sun Tao. Research on key problems of data quality in large industrial data environment[C]//Proceedings of the 3rd International Conference on Robotics, Control and Automation-ICRCA'18. Chengdu: ACM Press, 2018: 245-248.
- [9] Jia Xiaodong, Zhao Ming, Di Yuan, et al. Assessment of data suitability for machine prognosis using maximum mean discrepancy[J]. *IEEE Transactions on Industrial Electronics*, 2017, 7(65): 5872-5881.
- [10] Hallac D, Vare S, Boyd S, et al. Toeplitz inverse covariance-based clustering of multivariate time series data[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Halifax NS Canada: ACM Press, 2017: 5254-5258.