arXiv:2304.02947v1 [cs.LG] 6 Apr 2023

用于实时物联网系统新颖性检测的可适应且可解释框架

Marek Wadinger 和MichalKvasnica信息工程、自动化与数学研究所斯洛伐克布拉迪斯拉发工业大学斯洛伐克，布拉迪斯拉发{marek.wadinger, michal.kvasnica}@stuba.sk

摘要—**本文介绍了实时自适应可解释检测（RAID）算法。本文介绍了实时自适应可解释检测（RAID）算法。该新方法解决了当前最先进的多变量动态过程异常检测方法的局限性，这些方法仅限于检测模型训练条件范围内的异常。RAID算法能够适应模型开发期间可能未被考虑的数据漂移和变点等非平稳效应，从而延长服务寿命。基于联合概率分布的动态模型可处理系统中的异常行为检测，以及基于自适应过程限值的根因隔离。RAID 算法无需更改现有的过程自动化基础设施，因此能够广泛部署于不同领域。涉及真实动态系统数据的两个案例研究展示了RAID 算法的优势，包括变点自适应、根因隔离和检测准确率提升。**

索引词—**故障诊断；迭代学习控制；统计学习**

I. 引言

异常检测系统能够辨别异常、意外的模式，并适应数据中预期出现的新模式，是规避风险系统的重要组成部分。尤其是，异常检测系统能够评估正常运行条件，使物联网（IoT）设备向控制单元传输高保真数据。

在其极具影响力的论文中，Chandola等人回顾了涵盖多种应用领域的早期研究工作[1]。近期研究凸显出，有必要开发具有通用适用性且便于操作人员调整的方法 [2], [3], [4]。

Cook 等人指出，异常检测在 IoT 中面临若干重大挑战，包括测量数据具有时间、空间和外部背景信息，多变量特性、噪声以及非平稳性 [4]。特征工程方法能够对上下文属性进行编码，并提升性能 [5]。然而，大量特征工程可能会显著增加维度，导致需要大量数据存储空间和较高的计算资源[6]。

此外，概念漂移（即统计分布发生变化导致数据模式交替）以及变点（即系统状态发生永久性变化）所造成的非平稳性，也是一个相当严峻的难题。在真实场景中，这些变化往往难以预测。因此，异常检测方法能否适应数据结构的变化，对于长期部署至关重要。前述可扩展性问题如今导致检测器自适应的延迟显著增加[7]。增量学习方法在实现自适应的同时，避免存储整个数据集。Pannu 等人提出的监督式操作员参与方案，展示了检测器如何适应飞行过程中标注的数据。其他研究则将这一问题视为对单变量信号 [8] 和多变量系统[9]中有界数据缓冲区的序列处理。

最后，近期将异常检测任务扩展至根因隔离的研究，推动了可解释方法的发展，这些方法能够诊断并跟踪系统中的故障。相关研究可分为两类。第一类将可解释性视为各个特征的重要性 [10], [11], [12]。这类研究通过独立考察特征来解释新颖性。第二类采用统计学习，构建可通过概率进行解释的模型。Yang 等人最近针对故障检测与诊断任务提出了一种贝叶斯网络（BN）。网络中的各个节点表示服从正态分布的变量，而多元回归模型则定义了权重和关系。作者利用预先设定的 BN 结构，提出了一种离线训练、在线检测与诊断的模型 [13]。然而，正如前文所述，离线训练无法适应预期的新模式，因此据我们所知，这种方法不适用于在真实物联网设备上长期运行。

本文强调了这种适应性在异常检测中的重要性，并提出了一种应对这一挑战的方法。本文报告了针对流式物联网数据的一种自适应异常检测方法的发现与表征。能够诊断多变量数据，同时

作者谨此感谢斯洛伐克研究与发展署通过项目 APVV-20-0261 提供的支持。作者谨此感谢斯洛伐克共和国科学资助署通过资助项目 1/0490/23 提供的支持。本研究由欧盟委员会通过资助项目 101079342（促进斯洛伐克在智能产业先进控制领域迈向卓越）资助。

提供根因隔离能力（这是单变量情形所固有的），将我们在[14]中提出的工作拓展到了该领域。所提出的算法为各类安全关键系统提供了一种通用方法，在这些系统中，异常诊断与识别至关重要。

两项案例研究表明，所提出的基于动态联合正态分布的方法能够解释新颖情况、隔离异常的根本原因，并适应变点，从而推动近期开发的异常检测技术在服务长期部署和跨领域使用中的应用。我们发现，其检测性能相近，但可扩展性较低。

所提出的解决方案对现有研究成果的主要贡献在于：

- 兼具自适应能力和可解释性
- 识别系统性离群值及其根本原因
- 采用流数据自学习方法
- 利用现有 IT 基础设施
- 为信号设定动态限值

II. 预备知识

本节介绍构成所提出方法基础的核心思想。II-A 小节阐述 Welford 在线算法，该算法能够实时适应分布的变化。II-B 小节提出一种双遍实现方法，可以消除过期样本的影响。II-C 小节中关于分布建模的数学原理，为预备知识最后一节 II-D 所讨论的高斯异常检测模型奠定了基础。

A. Welford 在线算法

Welford 提出了一种数值稳定的在线算法，可通过单遍计算均值和方差。该算法使 IoT 设备测量值无需存储即可进行处理 [15]。

给定测量值 x_i，其中 $i = 1$、.....， n 是样本总体 n 中的样本索引，校正平方和 S_n 定义为

$$S_n = \sum_{i=1}^{n} (x_i - \bar{x}_n)^2, \tag{1}$$

其中，运行均值 $\bar{x}_n$ 定义为按此前已观测总体 $n-1$ 的比例加权的先前均值 $\bar{x}_{n-1}$，并由当前样本修正为

$$\bar{x}_n = \frac{n-1}{n}\bar{x}_{n-1} + \frac{1}{n}x_n = \bar{x}_{n-1} + \frac{x_n - \bar{x}_{n-1}}{n}. \tag{2}$$

在本文中，我们考虑以下对校正平方和进行更新的公式：

$$S_n = S_{n-1} + (x_n - \bar{x}_{n-1})(x_n - \bar{x}_n), \tag{3}$$

因为它不太容易受到灾难性消去导致的数值不稳定性的影响。最后，相应的无偏方差是

$$s_n^2 = \frac{S_n}{n-1}. \tag{4}$$

这种 Welford 方法的实现需要存储三个标量： $\bar{x}_{n-1}$； n； S_n。

B. 逆 *Welford* 算法

根据 (2)，显然，随着总体n 增大，最新样本对运行均值的影响会减小。因此，调节用于样本均值和方差计算的样本数量对自适应至关重要。已知用于计算的实例和过期周期 $t_e \in \mathbb{N}_0^{n-1}$，回退 x_{n-t_e} 的影响可写为

$$S_{n-1} = S_n - (x_{n-t_e} - \bar{x}_{n-1})(x_{n-t_e} - \bar{x}_n), \tag{5}$$

其中回退后的均值为

$$\bar{x}_{n-1} = \frac{n}{n-1}\bar{x}_n - \frac{1}{n-1}x_{n-t_e} = \bar{x}_n - \frac{x_{n-t_e} - \bar{x}_n}{n-1}. \tag{6}$$

最后，无偏方差的计算公式为：

$$s_{n-1}^2 = \frac{S_{n-1}}{n-2}. \tag{7}$$

C. 多变量系统的统计模型

多元正态分布将多元系统推广到这样一种模型：变量之间的相关程度由协方差矩阵表示。对于过程测量值而言，假设变量服从高斯正态分布是合理的，因为高斯正态分布是一种常见的分布，源于在噪声影响下测量的稳定物理过程。多元正态分布的一般表示形式为：

$$\mathbf{X} \sim \mathcal{N}_k(\boldsymbol{\mu}, \boldsymbol{\Sigma}), \tag{8}$$

其中， k维均值向量记为 $\boldsymbol{\mu} = (\bar{x}_1, ..., \bar{x}_k)^T \in \mathbb{R}^k$， $\boldsymbol{\Sigma} \in \mathbb{R}^{k\times k}$ 是 $k \times k$ 协方差矩阵，其中 k 是最后一个随机变量的索引。

多元正态分布的概率密度函数 (PDF) $f(\boldsymbol{x};\ \boldsymbol{\mu}, \boldsymbol{\Sigma})$ 表示为：

$$f(\boldsymbol{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{k/2}|\boldsymbol{\Sigma}|^{1/2}} e^{-\frac{1}{2}(\boldsymbol{x}-\boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\boldsymbol{x}-\boldsymbol{\mu})}, \tag{9}$$

其中， $\boldsymbol{x}$ 是时间 i 的 k 维测量向量， $|\boldsymbol{\Sigma}|$ 表示 $\boldsymbol{\Sigma}$ 的行列式，而 $\boldsymbol{\Sigma}^{-1}$ 是 $\boldsymbol{\Sigma}$ 的逆矩阵。

多元高斯分布的累积分布函数（CDF）描述了随机矩阵 $\boldsymbol{X}$ 的所有分量取小于或等于空间中特定点 $\boldsymbol{x}$ 的值的概率，并可用于评估观测到一组特定测量值或数据点的可能性。累积分布函数通常用于统计应用中，以计算置信区间、执行假设检验，并基于观测数据进行预测。换句话说，它给出了观测到落在空间某个特定区域内的随机向量的概率。累积分布函数的标准表示法如下：

$$F(\boldsymbol{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \int_{-\infty}^{\boldsymbol{x}} f(\boldsymbol{x}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) \mathrm{d}\boldsymbol{x}, \tag{10}$$

其中，$\mathrm{d}\boldsymbol{x}$ 表示对$\boldsymbol{x}$的所有 k 维度进行积分。

由于方程（10）无法显式积分， [16]提出了一种数值计算算法。

给定概率密度函数（PDF），我们还可以使用累积分布函数（CDF）反演的数值方法，确定与给定分位数 q 对应的 $\boldsymbol{x}$ 值。该方法通常称为百分位点函数（PPF），或 $F(\boldsymbol{x};\ \boldsymbol{\mu}, \boldsymbol{\Sigma})^{-1}$。下面将计算单变量正态分布的 PPF 值的算法列为算法 1。

算法 1 正态分布的百分位点函数

输入： 分位数 q, 样本均值 $\bar{x}_n$ (2), 样本方差 s_n^2 (4)

输出： 阈值$x_{n,\ q}$

初始化：

$f \leftarrow 10;\ \ l \leftarrow -f;\ \ r \leftarrow f;$

LOOP 流程

当 $F(l;\ \bar{x}_n,\ \ s_n^2) > 0$ **时执行**

$r \leftarrow l;$

$l \leftarrow lf;$

结束 while

当 $F_X(r)\ - q < 0$ **时执行**

$l \leftarrow r;$

$r \leftarrow rf;$

结束循环

$\tilde{x}_{n,q} = \arg\min_{x_n} \|F(x_n;\ \bar{x}_n, s_n^2)\ - q\|$ 满足条件 $\ l \le x_n \le r$

返回 $\tilde{x}_{n,q}\sqrt{s_n^2 + \bar{x}_n}$

算法 1 中百分位点函数的计算采用迭代求根算法，例如 Brent 方法 [17]。

D. 多元高斯异常检测 *on*

从统计学角度来看，离群值可表示为与均值显著偏离的值。假设系统在滑动窗口内的空间和时间特征可编码为正态分布的特征，那么我们可以认为，任何异常都可能被检测为离群值。

在机器学习等经验领域，三西格玛规则（3σ）定义了分布的一个区域，正常值几乎可以确定会出现在该区域内。这一假设意味着，给定分布中约有 0.27% 的值被视为异常。

3σ 规则规定，随机变量 $\boldsymbol{X}$ 的任意样本$\boldsymbol{x_i}$ 落在给定累积分布函数的半闭区间内的概率，该区间以样本均值 $\boldsymbol{\mu}$为中心，距离为 3 个样本标准差 $\boldsymbol{\Sigma}$，并给出 q 的近似值：

$$q = P\{|\boldsymbol{x_i} - \boldsymbol{\mu}| < 3\boldsymbol{\Sigma}\} = 0.99730. \tag{11}$$

利用正常行为的概率模型，我们可以查询阈值向量 $\boldsymbol{x_l}$ 和 $\boldsymbol{x_u}$，它们对应于已确定概率的累积分布函数闭区间。对式 (10) 求逆可用于此类查询，结果如下：

$$\boldsymbol{x_l} = F((1 - P\{|\boldsymbol{x_i} - \boldsymbol{\mu}| < 3\boldsymbol{\Sigma} \circ \boldsymbol{I}\}); \boldsymbol{\mu}, \boldsymbol{\Sigma} \circ \boldsymbol{I})^{-1}, \tag{12}$$

对于下限，

$$\boldsymbol{x_u} = F((P\{|\boldsymbol{x_i} - \boldsymbol{\mu}| < 3\boldsymbol{\Sigma} \circ \boldsymbol{I}\}); \boldsymbol{\mu}, \boldsymbol{\Sigma} \circ \boldsymbol{I})^{-1}, \tag{13}$$

对于上界，其中 $\boldsymbol{\Sigma} \circ \boldsymbol{I}$ 表示 $\boldsymbol{\Sigma}$ 的对角元素。

然而，计算多元正态分布的累积分布函数时，较小的概率可能会导致数值问题。为避免下溢，计算累积分布函数的对数（对数累积分布函数），将各个元素的乘积转换为数值上更稳定的求和。 T 的值表示一个阈值，用于定义正常运行与异常之间的判别边界。在时间 i，系统的预测状态 Y_i 定义为

$$y_i = \begin{cases} 0 & \text{if } T \le \log F(\boldsymbol{x_i}; \boldsymbol{\mu}, \boldsymbol{\Sigma}) \\ 1 & \text{if } T > \log F(\boldsymbol{x_i}; \boldsymbol{\mu}, \boldsymbol{\Sigma}), \end{cases} \tag{14}$$

其中， $y_i = 0$ 表示系统正常运行，$y_i = 1$ 表示系统异常运行。

III. 新颖性检测与解释框架

在本节中，我们提出了一种适用于具有流式物联网设备的多变量系统的实时自适应可解释检测（RAID）方案。所提出的方法将系统建模为动态联合正态分布，以实现对过程普遍存在的非平稳效应的自适应，并处理变点、概念漂移和季节性效应。我们的主要贡献在于将可自适应的自监督系统与根因识别能力相结合，使在线统计模型具备以两种方式诊断异常的能力。首先，通过计算全局对数概率来检测系统的运行状况。其次，根据动态告警触发过程限值，隔离单个信号测量值和特征中的离群值。下文将该方法分为三个部分，并在各小节中进行描述。第一小节重点介绍模型参数的初始化。第二小节描述在线训练和自适应过程。最后一小节介绍模型的预测和诊断能力。算法2给出了该方法的简化表示。

A. Model Parameters Initialization

模型初始化通过指定模型的可调超参数来控制：过期周期 t_e 和阈值 T。过期周期设定时间滚动计算的窗口大小，以改变给定时间范围内离群值的比例，并直接影响动态信号限值的放宽（过期周期较长）或收紧（过期周期较短）。宽限期默认为 $3/4t_e$，表示模型校准所需的充足时间。在此期间，不会检测离群值，以避免误报，并加快后文 III-B 小节介绍的自监督学习过程。

过期周期越长，模型的变点适应能力越弱，但对突发变化的鲁棒性越强。模型通过适应周期 t_a来适应底层数据生成过程的变化，例如过程均值或方差的偏移。 t_a 越长，自适应速度越慢，代价是警报持续时间更长；不过，当意外离群值持续时间范围较长时，这有时反而很有价值。在大多数情况下，模型在 $t_a = 1/4t_e$时效果最佳。

一般而言，过期周期 t_e 应根据多变量系统中最慢的动态过程来选择。由于存在两个可调且易于理解的超参数，因此很容易将该解决方案适配到任何多变量系统。

B. 在线训练

在数据流上进行训练需要采用增量学习方案，即在每个样本到达时一次处理一个样本。增量学习支持在线适应，指的是根据新的观测结果更新模型参数的能力。这种能力需要付出计算延迟的代价，可能会给检测器响应的延迟带来挑战。

对于动态联合概率分布，时刻 i 的参数为 $\boldsymbol{\mu_i}$ 和 $\boldsymbol{\Sigma_i}$ 。均值向量 $\boldsymbol{\mu_i}$ 和协方差矩阵 $\boldsymbol{\Sigma_i}$ 的更新分别按照 Welford 在线算法，使用公式 (2) 和 (4) 进行。在第二遍处理中，过期周期 t_e 之后的样本将被遗忘。通过访问缓冲区中的数据，使用均值的逆 Welford 算法 (6) 和方差的逆 Welford 算法 (7) 撤销过期样本的影响。在第二遍处理中，这些过期样本将被丢弃。详情请参阅第 II-B 小节。

需要注意的是，自适应采用自监督方式进行。如果时刻 i 的观测被视为正常，则会执行先前的常规运行。适应周期t_a 也允许模型更新离群值的分布。根据式 (14) 得出的预测系统异常状态y_i，在过去观测值的窗口 $\boldsymbol{y_i} = \{y_{i-t_a}, ..., y_i\}$内，对离群值进行自适应时，满足以下检验条件：

$$\frac{\sum_{y \in \boldsymbol{y_i}} y}{n(\boldsymbol{y_i})} > 2 * (q - 0.5). \tag{15}$$

其中， $n(\boldsymbol{y_i})$表示 $\boldsymbol{y_i}$的维度。式 (15) 的逻辑遵循异常的概率方法，该方法假设异常的数量小于或等于分布两端的条件概率

C. 在线预测

在预测阶段，将评估多个指标，以判断建模系统的状态。

针对时刻 i 的过程观测向量 $\boldsymbol{x_i}$ ，使用 [16]，中提出的数值算法计算多元高斯分布的全局对数累积分布函数，用于确定整个系统的异常/正常行为。输入信号与特征之间的相互作用也得到了自然考虑。

为进行根因隔离，将输入与由下限和上限阈值构成的区间进行比较，分别记为式 (12) 中的 $\boldsymbol{x_l}$ 和式 (13) 中的 $\boldsymbol{x_u}$ 。算法 1 用于在每个时刻使用模型的更新参数计算输入的百分位点函数。单独来看，上限和下限可解释为动态过程限值；它们会更新传感器文档所提供的保守过程限值，并考虑老化以及影响传感器运行的环境条件。

信号丢失是一种意外的新颖行为，预计会出现在该框架中；该框架对采样时间戳之间的差值所服从的单变量正态分布计算累积分布函数。我们假设，从长远来看，采样时间分布不会发生漂移。因此，采用基于 (2) 和 (4) 的单次遍历更新。为了预见采样中的细微变化，自监督学习使用按 $(1 - F(\boldsymbol{x_i};\ \boldsymbol{\mu},\ \boldsymbol{\Sigma}))$ 的偏差加权的异常进行训练。

当（15）中的自适应检验成立时，变点将被隔离，从而触发模型更新。

算法2 在线检测与识别工作流程
使用 RAID 方法

输入： 过期周期 t_e
输出： 系统异常 y_i^g ，信号异常 $\boldsymbol{y_i^s}$，采样异常 y_i^t、变点 y_i^c、降低阈值$\boldsymbol{x_{l,i}}$、上限阈值 $\boldsymbol{x_{u,i}}$,
初始化 :

$i \leftarrow 1$; $n \leftarrow 1$; $q \leftarrow 0.9973$; $\boldsymbol{\mu} \leftarrow \boldsymbol{x_0}$; $\boldsymbol{\Sigma} \leftarrow \mathbf{1}_{k \times k}$;
使用 [16] 中的算法计算 $F(\boldsymbol{x_0};\ \boldsymbol{\mu}, \boldsymbol{\Sigma})$;
循环处理
循环
  $\boldsymbol{x_i} \leftarrow$ 接收();
  $y_i^g \leftarrow$ 使用 (14) 进行预测($\boldsymbol{x_i}$);
  $\boldsymbol{x_{l,i}},\ \boldsymbol{x_{u,i}} \leftarrow$ GET($q, \boldsymbol{\mu}, \boldsymbol{\Sigma}$) 使用算法 1;
  $\boldsymbol{y_i^s} \leftarrow$ INRANGE($\boldsymbol{x_i}, [\boldsymbol{x_{l,i}},\ \boldsymbol{x_{u,i}}]$);
  如果 (14)**或** (15) **那么**
    $\boldsymbol{\mu}, \boldsymbol{\Sigma} \leftarrow$ 更新($\boldsymbol{x_i}, \boldsymbol{\mu}, \boldsymbol{\Sigma}, n$) 使用公式 (2)、(4);
    如果(15) **则**
      $y_i^c \leftarrow 1$;
    else
      $y_i^c \leftarrow 0$;
    结束如果
    $n \leftarrow n + 1$;
    对于 $\boldsymbol{x_{i-t_e}}$ **do**
      $\boldsymbol{\mu}, \boldsymbol{\Sigma} \leftarrow$ 回退($\boldsymbol{x_{i-t_e}}, \boldsymbol{\mu}, \boldsymbol{\Sigma}, n$) 使用 (6), (7);
      $n \leftarrow n - 1$;
    结束循环
  end if
  $i \leftarrow i + 1$;
结束循环

IV. 案例研究

本节提供了两个案例研究，展示了我们所提出方法的有效性和适用性。在这些研究中，我们利用微电网系统中的流式基准测试系统数据和来自物联网设备的信号，探究了该方法的特性和性能。成功部署表明，该方法适用于现有的过程自动化基础设施。

案例研究使用Python3.10.1 在一台配备 8核 Apple M1 中央处理器和 8 GB 内存的机器上完成。

A. 基准测试

在本小节中，我们将所提出的方法与标准自适应无监督检测方法进行比较。两种最知名的方法——单类支持向量机（OC-SVM）和半空间树（HS-Trees）——都具备在多变量时间序列数据上迭代学习的能力。这两种方法在动态系统数据异常检测领域均代表了当前最先进的水平。比较基于真实基准测试数据进行，数据标注了观测结果是异常还是正常。本次比较使用 Skoltech 异常基准（SKAB） [18] 数据集。该数据集汇集了多项实验，研究转子不平衡情况下系统的行为，并考察了为控制动作引入的各种功能，以及回路中水量的缓慢变化和突变。系统由 8 个特征描述。数据按照相应方法的最佳实践进行预处理：OC-SVM 使用标准缩放，HS-Trees 使用归一化，而所提出的方法不进行缩放。使用网格搜索为两种基准方法找到最优分位数阈值。结果列于表 I，评估指标包括 F1 分数、召回率和精确率。每项指标达到 100% 表示检测完美。延迟表示流水线（包括训练和数据预处理）处理每个样本的平均计算时间。

表 I SKAB 数据集上的指标评估

指标	RAID	OC-SVM	HS-Trees
F1 [%]	**48.70**	44.42	34.10
召回率 [%]	49.90	**56.67**	32.57
精确率 [%]	**47.56**	36.52	35.77
平均延迟 [ms]	1.55	0.44	**0.21**

表 I 中的结果表明，我们的算法性能略优于参考方法。根据 SKAB 的 Kaggle 页面上各算法的排行榜，我们的迭代方法与评估的批量训练模型表现相当。这种模型拥有全部训练

与我们的方法不同，该方法使用预测前可用的数据，在流式数据集上迭代评估各项指标。

B. 电池储能系统（*BESS*）

在第二个案例研究中，我们在电池储能系统上验证所提出的方法。电池储能系统报告了荷电状态的测量值（SoC）、供能/取能设定值，以及电池储能系统顶部、中部和底部的内部温度。严格控制电池单元温度对于优化性能并延长电池寿命至关重要。识别异常事件并移除损坏数据，可能会显著提升过程控制水平。

信号测量的默认采样率为 1 分钟。然而，物联网设备的网络通信容易发生数据包丢失，从而导致非均匀采样。数据已归一化至范围 $[0, 1]$ ，以保护敏感的业务数值。所提出的方法部署在系统现有基础设施中，从而实现系统的实时检测与诊断。

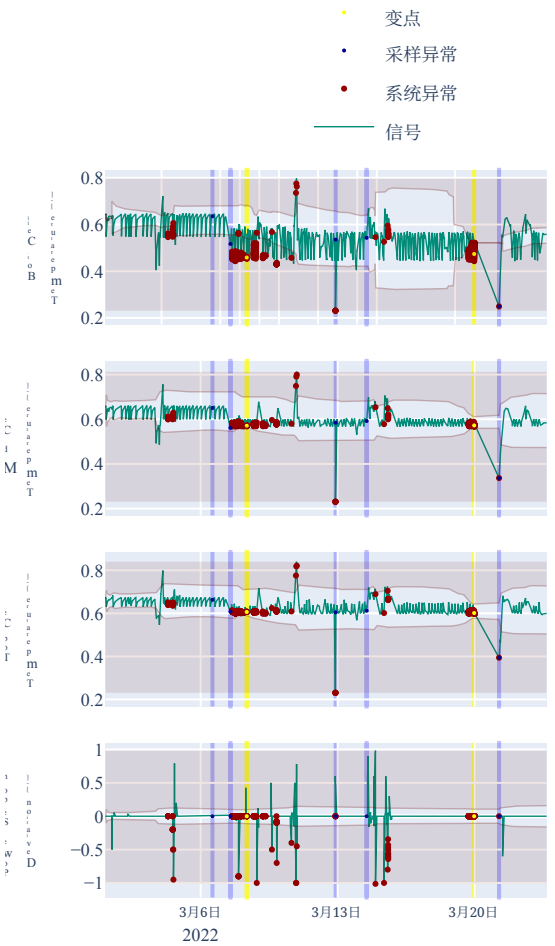

图 1. 电池储能系统（BESS）过程变量测量值的时间序列（绿色线条）。x轴上的非均匀刻度标记感兴趣的日期（注：为保证可读性，部分标记已隐藏）。y轴显示归一化后的过程变量。系统异常以红点标记。蓝色竖线表示检测到非均匀采样的位置。黄色竖线表示变点适应

图1展示了2022年3月电池储能系统的运行情况。操作人员报告了多起异常行为事件，这些事件可通过给定时间段内测量值的突然或显著变化观察到。作为第一步，模型完成初始化；根据III-A小节，系统参数选定为 $t_e = 4$ 天和 $T = -25$ ，用于

相应地调整过期周期和阈值。根据设计，前 3 天处于宽限期内，在此期间对模型进行校准。

异常检测系统的部署和运行取得了成功，如其在 7th 2022年3月对变化点的自适应所示；该变化点是由于电池储能系统迁移至室外而出现的。模型根据第 III-B 小节进行了在线自适应。环境条件的剧烈变化改变了系统温度的动态特性。然而，顶层异常隔离系统在两天内便适应了新的行为，之后显著减少了警报数量。有趣的是，系统校准情况也得到了捕捉，表现为设定值偏离实际功率需求，以及温度出现多个峰值。

系统识别出 5 次采样偏差，如图 1 中的蓝线所示。观测到的最长数据包丢失发生在 20th 3月到 21st期间。出乎意料的是，变化点检测模块将丢失开始时刻识别为变化点，而采样偏差检测器只能在丢失后的下一次观测时捕捉到该事件。红点表示根据公式 (14) 得出的系统级异常。在系统发生异常期间，一个或多个信号会超出动态信号限值。此外，模型还根据相关矩阵考虑变量之间关系的变化。

五、结论

本文考察了联合概率分布对采用流式物联网设备的动态系统正常运行进行建模的能力。该模型采用 Welford 在线算法来描述系统动态，能够实时更新并回退多元高斯分布的充分参数，从而可以描述过程变量中的非平稳性。

我们假设，在与系统动态相关的有界时间范围内，测量值服从高斯分布。我们认为这一假设是合理的，多次试验的结果也支持这一点，因为柯尔莫哥洛夫–斯米尔诺夫检验未拒绝该假设。该统计模型能够将异常解释为相对于均值向量极度偏离的观测值。本研究中的另一项假设是，任何空间或时间异常都可以通过某种方式进行变换，使其在一个或多个相互作用的信号下成为离群值。

我们的方法通过考虑输入测量值与工程化特征之间的交互，在全局异常层面确定系统的运行状态。在第二层级中，基于给定多变量分布参数和阈值概率下的百分位点函数（PPF）所建立的动态过程限值，有助于隔离异常的根本原因。该层级用于实现模型运行的诊断功能。各个信号共同促成全局异常预测，而所提出的动态限值则为单个过程运行提供限制性较低的约束。与此同时，检测器能够区分由数据包丢失和传感器故障引起的信号丢失。

在两个基于真实数据的案例研究中，展示了该系统检测和识别异常、将异常根因定位到特定信号或特征，以及识别信号丢失的能力。与许多异常检测方法不同，所提出的 RAID 方法不需要历史数据或关于异常的真实标签信息，从而消除了常见的局限性。

基于基准工业数据开展的第一个案例研究表明，该方法能够提供与其他自学习型自适应异常检测方法相当的结果，同时还能够实现根因隔离。第二个案例研究基于电池储能系统的实际运行数据，考察了该系统，并证明了其能够捕捉系统异常，并为信号和提取的特征提供限制性更低的边界。

该方法未来的工作将包括提升可扩展性、降低高维数据上的延迟，以及减少一般即插即用模型所存在的误报率。

参考文献

[1] V. Chandola、A. Banerjee 和 V. Kumar，《异常检测：综述》，《*ACM* 计算调查》，第 41 卷，第 3 期，2009 年 7 月。 [在线]。网址：https://doi.org/10 1145 1541880 1541882 。/ 。

[2] N. Laptev、S. Amizadeh 和 I. Flint，《用于自动化时间序列异常检测的通用且可扩展框架》，载于第 *21* 届 *ACM SIGKDD* 知识发现与数据挖掘国际会议论文集，KDD ’15 系列。美国纽约州纽约市：计算机协会，2015 年，第 1939–1947 页。 [在线]。网址：https://doi.org/10 1145 2783258 2788611 。/ 。

[3] A. Kejariwal，《在时间序列中引入实用且稳健的异常检测》，2015 年。[在线]。网址：https://blog.twitter.com/engineering/en us/a/2015/introducing-practical-and-robust-anomaly-detection-in-a-time-series

[4] A. A. Cook、G. Mısırlı 和 Z. Fan，《物联网时间序列数据的异常检测：综述》，《*IEEE* 物联网期刊》，第 7 卷，第 7 期，第 6481–6494 页，2020 年。

[5] C. Fan、Y. Sun、Y. Zhao、M. Song 和 J. Wang，《基于深度学习的特征工程方法可提高建筑能耗预测精度》，《应用能源》，第 240 卷，第 35–45 页，2019 年。 [在线]。网址：https://www.sciencedirect.com/science/article/pii/S0306261919303496

[6] P. D. Talagala、R. J. Hyndman 和 K. Smith-Miles，《高维数据中的异常检测》，《计算与图形统计学杂志》，第 30 卷，第 2 期，第 360–374 页，2021 年。 [在线]。网址：https://doi.org/10 1080 10618600 2020 1807997 。/ 。

[7] H. Wu 、 J. He 、 M. Tomoskozi 、 Z. Xiang 和 F. H. Fitzek，《软件化网络中低延迟工业异常检测的网络内处理》，载于*2021* 年 *IEEE* 全球通信大会（*GLOBECOM*），2021 年 12 月，第 01–07 页。

[8] S. Ahmad、A. Lavin、S. Purdy 和 Z. Agha，《面向流数据的无监督实时异常检测》，《神经计算》，第 262 卷，第 134–147 页，2017 年，《数据流实时学习策略》在线专刊。 [在线]。网址：https://www.sciencedirect.com/science/ article/pii/S0925231217309864

[9] H. H. Bosman、G. Iacca、A. Tejada、H. J. W¨ortche 和 A. Liotta，《用于检测自组传感器网络中异常的增量学习器集成》，《自组网络》，第 35 卷，第 14–36 页，2015 年，大数据启发的数据感知、处理与网络技术特刊。 [在线]。网址：https: // www.sciencedirect.com/science/article/pii/S1570870515001481

[10] M. Carletti、C. Masiero、A. Beghi 和 G. A. Susto，《工业 4.0 中的可解释机器学习：评估异常检测中的特征重要性以实现根因分析》，载于*2019* 年 *IEEE* 系统、人类与控制论国际会议（*SMC*），2019 年 10 月，第 21–26 页。

[11] Q. P. Nguyen、K. W. Lim、D. M. Divakaran、K. H. Low 和 M. C. Chan，《Gee：基于梯度的可解释变分自编码器，用于网络异常检测》，载于*2019* 年 *IEEE* 通信与网络安全会议（*CNS*），2019 年 6 月，第 91–99 页。[12] K. Amarasinghe、K. Kenney 和 M. Manic，《迈向基于可解释深度神经网络的异常检测》，载于*2018*年第*11*届人机系统交互国际会议，2018 年 7 月，第 311–317 页。[13]W.-T. Yang、M. S. Reis、V. Borodin、M. Juge 和 A. Roussy，《用于故障检测与诊断的可解释无监督贝叶斯网络模型》，《控制工程实践》，第 127 卷，文章编号 105304，2022 年。 [在线]。网址：https://www.sciencedirect.com/science/article/pii/S0967066122001502[14] M. Wadinger 和 M. Kvasnica，《利用动态过程限值进行实时离群点检测》，载于*2023*年第*24*届过程控制国际会议论文集，2023 年，即将出版。[15] B. P. Welford，《关于计算校正平方和与乘积和的一种方法的注记》，《技术计量学》，第 4，3，419–420 卷，第 期，第 1962 [ ] 10 – 页。在线。网址：https://www.tandfonline.com/doi/abs/ 。1080/00401706.1962.10490022[16] A. Genz，《多元正态概率的数值计算》，《计算与图形统计学杂志》，第 1 卷，2000 年 5 月。[17]R. P. Brent，《《无导数极小化算法》》。美国新泽西州恩格尔伍德克利夫斯：普伦蒂斯-霍尔，1972 年。 [在线]。网址：https://openlibrary.org/books/OL4739237M/Algorithms for minimization without derivatives[18] I. D. Katser 和 V. O. Kozitsin，《 _ Skoltech_异常基准（SKAB）》,_ https://www.kaggle.com/dsv/1693952，2020年。