VSCOUT：一种用于高维回顾性监控中离群值检测的混合变分自编码器方法

预印本

Waldyn Martinez迈阿密大学信息系统
与分析系，俄亥俄州牛津 45056
martinwg@miamioh.edu

arXiv:2601.20830v1 [stat.ML] 28 Jan 2026

摘要

现代工业和服务流程会产生高维、非高斯且易受污染的数据，这些数据对经典统计过程控制（SPC）的基本假设构成挑战。重尾、多峰性、非线性依赖以及稀疏的特殊原因观测，可能扭曲基线估计、掩盖真实异常，并妨碍可靠地识别受控（IC）参考集。为应对这些挑战，我们提出 VSCOUT，这是一种专为高维场景中的回顾性（第一阶段）监控设计的无分布假设框架。VSCOUT 将自动相关性确定变分自编码器（ARD-VAE）架构与基于集成的潜在离群值筛选及变点检测相结合。ARD先验可筛选出信息量最高的潜在维度，而集成滤波器和变点滤波器则可在确定的潜在空间中识别点状和结构性污染。第二阶段的重新训练会移除标记观测，并仅使用保留的内点重新估计潜在结构，从而减轻遮蔽效应并稳定受控潜在流形。这种两阶段精炼可生成干净可靠的受控基线，适用于后续第二阶段部署。针对基准数据集开展的大量实验表明，VSCOUT 在控制误报的同时，对特殊原因结构具有更高的灵敏度，性能优于经典统计过程控制程序、稳健估计量和现代机器学习基线。凭借其可扩展性、分布灵活性以及对复杂污染模式的适应能力，VSCOUT 成为一种实用有效的方法，适用于人工智能赋能环境中的回顾性建模和异常检测。

关键词 异常　值检测 ·潜在空间建模 · 集成离群值检测 · 变点检测

1 引言

传感和数据采集领域的最新进展，使高维过程数据得以广泛获取。这些数据具有非线性动力学和复杂的依赖结构，给经典统计过程控制（SPC）的假设带来了挑战。在此类环境中，回顾性（第一阶段）分析仍然至关重要，必须先构建可靠的受控（IC）参考，之后才能有意义地开展前瞻性监控。然而，第一阶段数据往往受到未知特殊原因观测、暂态扰动、重尾、多峰性或非平稳性的污染，所有这些因素都可能扭曲基线估计，并削弱后续控制图的效能[Reis and Gins，2017年，Montgomery，2020a，Goecks等人， 2024]。

传统的多元方法，例如 Hotelling 的 T^2 控制图 [（Hotelling等人， 1931] ）以及基于主成分分析的控制图 [（Ranger and Alt，1996年；Mastrangelo等人， 1996] ），依赖于线性和多元正态性假设。即使是基于核的方法或稳健子空间方法 [（Sun and Tsung，2003年；Camci等人， 2008] ），当数据呈现重尾行为、局部污染或复杂的潜在结构时，也会面临困难。在第一阶段，这些问题会更加突出，因为其首要

目标是在估计受控参数之前识别并剔除受污染观测。存在污染时，经典估计量会产生偏差，而掩蔽效应会破坏第二阶段监控所依赖的潜在结构或协方差结构。

深度生成模型为高维数据建模提供了一种灵活的替代方案，而变分自编码器（VAEs） [Kingma和Welling, 2013] 为学习非线性潜在结构提供了一种有理论依据的方法。然而，标准变分自编码器并非针对第一阶段目标设计：它们可能模糊内点与异常值之间的区分，产生不稳定的基于重构的阈值，或在直接使用未经筛选的回顾性数据进行训练时过拟合异常样本[Ruff等人， 2021]。由于变分自编码器旨在最大化生成似然而非检测异常，因此在存在污染的情况下，其潜在空间可能无法准确表示普通原因变异。
为应对这些挑战，我们提出了VSCOUT（变分自编码器自校正异常点发现技术），这是一种专为高维回顾性监测设计的混合深度学习框架。VSCOUT训练一个变分自编码器以学习初始潜在结构，应用基于集成的检测器和变点分析来识别潜在的特殊原因观测值，移除这些观测值，然后在清理后的数据集上精炼该变分自编码器。精炼阶段不会重新开始训练，而是继续优化初始拟合得到的编码器-解码器权重，在减少异常数据影响的同时保留有用结构。由此得到的潜在表示更接近理想的高斯先验，从而提供稳定的阈值，并改善内点与失控观测之间的区分。

我们在涵盖多种第一阶段污染情景的大规模模拟中评估了 VSCOUT，这些情景包括重尾、对数正态、混合和多峰分布；此外，还在广泛使用的真实世界基准数据集上进行了评估。在所有实验中，VSCOUT 均能可靠地识别干净的内点子集、恢复稳定的受控状态潜在表示，并且在检测特殊原因结构的同时控制误报，其表现优于领先的统计过程控制、集成和深度异常检测基线。

我们的贡献主要有三方面：

- 我们提出了 VSCOUT，这是一种无分布假设的回顾性（第一阶段）框架，它整合了 ARD-VAE 建模、集成过滤和变点检测，以构建适用于高维过程的稳健受控基线。
- 我们开展了一项全面的基准测试研究，在合成数据集和真实数据集上，将 VSCOUT 与经典统计过程控制工具、稳健估计器以及最先进的异常检测模型进行了比较。
- 我们证明，即使在重尾噪声、非线性依赖和低信噪比条件下，VSCOUT 对特殊原因结构仍具有更高的灵敏度，并能保持较高的内点保留率。

本文其余部分的组织结构如下。第2节回顾统计过程控制（SPC）和异常检测的相关工作。第3节介绍 VSCOUT 框架。第4节描述仿真设计和基准测试结果。第5节总结研究启示并展望未来方向。

2 基础知识

本节回顾支撑 VSCOUT 的基础概念，包括统计过程控制（SPC）的经典与现代方法、基于机器学习的异常值检测，以及与变分自编码器相关的深度生成建模原理。我们首先概述回顾性分析和在线监测的传统方法与当代方法，随后介绍变分自编码器的基础知识，这些内容为我们的框架设计提供了动机。

2.1 统计过程控制

近一个世纪以来，统计过程控制（SPC）一直是质量工程的基础方法论，为区分固有的普通原因变异与表明过程发生偏移或退化的特殊原因（可归因）变异提供了工具 [Woodall and Montgomery, 1999, Montgomery，2020b]。SPC 通常分为两个阶段：回顾性分析阶段和在线监控阶段。尽管这种两阶段结构仍是标准做法，但近年来的研究开始探索统一或自适应方法，倾向于采用集成式、数据驱动的监控框架，从而模糊两个阶段之间的界限 [Hou et al., 2020, Bourazas et al.,2022]。

2.1.1 回顾性分析与在线监测

回顾性分析是指检查历史过程数据，以建立可靠的受控（IC）基线。这一阶段传统上称为第一阶段，如今越来越多地称为回顾性

监测，对于刻画过程的自然变异、识别并消除可归因原因，以及估计后续用于确定控制限的参数至关重要。实践中，第一阶段数据集很少包含标示失控（OC）状态的标签，而且往往混杂着瞬态扰动、持续偏移和分布异常。这些特征促使人们开发无监督、无分布假设且抗污染的方法，以便在有意义地开展任何在线控制图监测之前识别受控区域[Qiu，2017]。

多种方法致力于应对回顾性监测中的挑战。变点检测技术提供了一种有理论依据的方法，可将历史数据划分为同质受控区域 [Hawkins 等，2003，Zamba 和 Hawkins，2006，Qiu， 2013]。非参数控制图和基于秩的控制图避免了对分布作出严格假设 [Chen 等， 2016], ，而无分布假设程序则通过重抽样策略增强了对重尾和模型设定错误的稳健性 [Capizzi 和 Masarotto， 2017]。近年来，深度生成模型（包括变分自编码器）已被用于揭示高维回顾性数据集中的潜在结构，并支持对异常或受污染观测值进行无监督识别 [Kingma和Welling， 2013]。

相比之下，在线监测（第二阶段）将回顾性分析得到的受控模型应用于新到达的数据，通常使用 Shewhart 控制图、累积和控制图、指数加权移动平均控制图或类似的控制图 [Qiu，2013年，Montgomery，2020b]。尽管近期研究已探索基于机器学习的方法以及用于前瞻性监测的自适应扩展方法，但这些方法从根本上依赖于回顾性分析期间建立的受控基线的质量。因此，本研究聚焦于回顾性（第一阶段）建模：VSCOUT 旨在识别并去除污染、提取稳定的潜在结构，并生成可靠的受控参考基准，以便在需要时用于第二阶段监控。

2.2 离群点与异常检测方法

异常检测也称为异常值检测，其任务是识别与预期行为显著偏离的观测值或模式。在统计过程控制（SPC）中，异常检测在识别偏离受控（IC）状态的情况方面发挥着核心作用，这些情况可能表明存在过程变化、传感器故障或其他可归因原因 [Chandola 等，2009，Hodge 和 Austin， 2004]。异常通常表现为点异常（孤立的极端观测值）、上下文异常 （仅在特定运行工况，如时间、负载或温度条件下才呈现异常的观测值），或集体异常 （只有联合考察时才显得异常的观测值组或序列） [Chandola 等， 2009]。在回顾性统计过程控制分析中，点异常通常对应暂态扰动，上下文异常与特定工况行为相对应，而集体异常则反映出传统参数控制图常常无法捕捉的持续偏移或漂移。因此，异常检测提供了一套丰富的工具，可在建立在线监测基线之前，将可靠的受控状态数据与受污染片段区分开来。

异常检测文献中已发展出多种方法。基于距离的方法，例如 k近邻（KNN），通过识别位于特征空间稀疏区域的点来检测异常 [Ramaswamy 等， 2000]。基于密度的方法，例如局部离群因子（LOF），通过比较局部密度估计值，检测相对稀疏区域中的点 [Breunig 等， 2000]。集成方法，例如孤立森林（IForest），利用随机划分高效地隔离异常观测，因此在高维环境中表现出良好的效果 [Liu 等， 2008]。近年来，经验累积分布离群检测（ECOD）等无分布假设的方法因其在异质、非参数场景中的可扩展性和稳健性而日益受到关注 [Li 等， 2022]。

深度学习通过生成式和表征学习范式进一步拓展了异常检测的应用范围。例如，变分自编码器（VAEs）能够学习过程数据的非线性潜在表征，而异常则表现为重构效果较差或潜在嵌入具有异常特征 [Kingma和Welling， 2013]。这类模型在高维统计过程控制（SPC）应用中尤为重要，既可用作特征提取器，也可用作异常检测器，从而检测出经典模型难以捕捉的细微偏差或结构化偏差。值得注意的是，现代系统越来越多地采用集成策略，融合统计方法、机器学习和深度生成方法，以发挥各自的互补优势，并提升模型在不同数据情形下的稳健性。

总体而言，异常检测的发展——从经典统计方法到先进的表示学习方法——与现代统计过程控制的目标密切契合：开展稳健的回顾性分析，以建立可靠的受控基线；并进行自适应在线监测，以便实时识别新出现的过程变化。这一广泛的方法工具箱为 VSCOUT 等混合框架奠定了基础。

2.3 统计过程控制中的异常检测深度生成模型

经典异常检测技术为统计过程控制提供了有价值的工具，但在捕捉现代过程数据所具有的非线性依赖和高维结构方面，往往存在局限。深度学习，尤其是深度生成模型，已成为强有力的替代方案，能够以无监督或半监督的方式学习正常过程行为的灵活表示 [Lee等人， 2024]。这类模型主要使用受控数据进行训练，以近似稳定运行的底层分布，从而能够将偏离这一已学习结构的情况标记为异常。这种建模方法天然适用于复杂、数据丰富的统计过程控制环境中的自适应在线监测和回顾性分析。

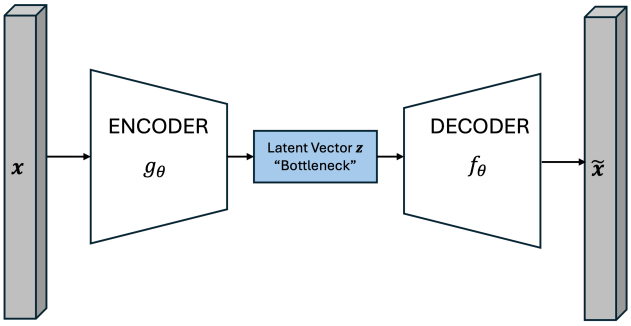

图 1：自编码器架构。

一种用于异常检测的基础深度学习模型是**自编码器（AE）**（图 1）。AE由一个编码器 g_θ：$\mathbb{R}^p \to \mathbb{R}^d$ 组成，它将一个 p 维输入$\mathbf{x}$ 映射为潜在表示$\mathbf{z} = g_\theta(\mathbf{x})$；还包括一个解码器$f_\theta$：$\mathbb{R}^d \to \mathbb{R}^p$，用于将输入重构为 $\tilde{\mathbf{x}} = f_\theta(\mathbf{z})$。参数 θ 通过最小化重构损失进行学习，通常采用均方误差（MSE）：

$$\mathcal{L}_{\mathrm{AE}}(\theta) = \frac{1}{n}\sum_{i=1}^{n} \|\mathbf{x}_i - f_\theta(g_\theta(\mathbf{x}_i))\|_2^2 .$$

由于AE能够学习捕捉正常受控条件数据结构的紧凑非线性流形，因此重构质量可作为一种自然的异常指标。对于每个观测值$\mathbf{x}_i$，重构误差定义为

$$r(\mathbf{x}_i) = \|\mathbf{x}_i - \tilde{\mathbf{x}}_i\|_2^2 = \|\mathbf{x}_i - f_\theta(g_\theta(\mathbf{x}_i))\|_2^2 .$$

在受控条件下，对于每个观测值，$r(\mathbf{x}_i)$往往较小，因为模型已经学会重现正常模式。失控（OC）观测值偏离学习到的流形，因此会产生显著较大的$r(\mathbf{x}_i)$值。这种从重构误差到异常分数的映射，使AE能够通过阈值设定或控制限直接适用于统计过程控制式监控。自编码器的训练依赖于基于梯度的优化，通常采用随机梯度下降（SGD） [Amari, 1993] 或Adam [Kingma and Ba, 2014]，在此过程中，模型参数 θ通过以下方式迭代更新：

$$\theta \leftarrow \theta - \eta \nabla_\theta \mathcal{L}_{\mathrm{AE}}(\theta),$$

其中 η 表示学习率。

变分自编码器（VAE）通过引入概率潜在空间扩展了自编码器（AE）（见图2）。编码器并非将输入映射到单个点，而是输出近似后验分布的参数$q_\phi(\mathbf{z} \mid \mathbf{x}) = \mathcal{N}\big(\boldsymbol{\mu}_\phi(\mathbf{x}), \mathrm{diag}(\boldsymbol{\sigma}_\phi^2(\mathbf{x}))\big)$, 其中 ϕ 表示编码器参数，且$\boldsymbol{\mu}_\phi(\mathbf{x})$ $\boldsymbol{\sigma}_\phi^2(\mathbf{x}) \in \mathbb{R}^d$。潜在样本通过重参数化技巧获得：$\mathbf{z} = \boldsymbol{\mu}_\phi(\mathbf{x}) + \boldsymbol{\sigma}_\phi(\mathbf{x}) \odot \boldsymbol{\epsilon}$，其中 $\boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$, 从而在随机采样过程中保持梯度流动。

解码器定义了一个似然模型 $p_\theta(\mathbf{x} \mid \mathbf{z})$，通常为方差固定的高斯分布，并由$\mathbf{z}$生成重构 $\tilde{\mathbf{x}}$。变分自编码器通过最大化证据下界（ELBO）进行训练：

$$\mathcal{L}_{\mathrm{ELBO}}(\theta, \phi; \mathbf{x}) = \underbrace{\mathbb{E}_{q_\phi(\mathbf{z}|\mathbf{x})}\big[\log p_\theta(\mathbf{x} \mid \mathbf{z})\big]}_{\text{Reconstruction (likelihood) term}} - \beta \underbrace{D_{\mathrm{KL}}(q_\phi(\mathbf{z} \mid \mathbf{x}) \,\|\, p(\mathbf{z}))}_{\text{Regularization term}},$$

其中，$p(\mathbf{z}) = \mathcal{N}(\mathbf{0}, \mathbf{I})$是通常采用的先验分布，而 β控制潜变量正则化的强度。证据下界相对于(θ, ϕ)的梯度通过反向传播计算：

$$(\theta, \phi) \leftarrow (\theta, \phi) - \eta \nabla_{(\theta,\phi)} \mathcal{L}_{\mathrm{ELBO}}.$$

VAE 的概率潜在结构支持基于重构和基于密度的异常检测，因此非常适用于需要灵活建模复杂过程分布的统计过程控制（SPC）应用。然而，VAE 可能会出现后验坍塌、对先验设定错误较为敏感，以及难以在潜在空间中强制形成高斯结构等问题 [Lin 等人， 2019],尤其是在存在污染的情况下。这些局限促使人们采用混合深度生成方法，例如 VSCOUT；这类方法结合重构误差、潜在空间偏差度量和集成异常评分，以提升第一阶段回顾性分析和第二阶段在线监测的稳健性。

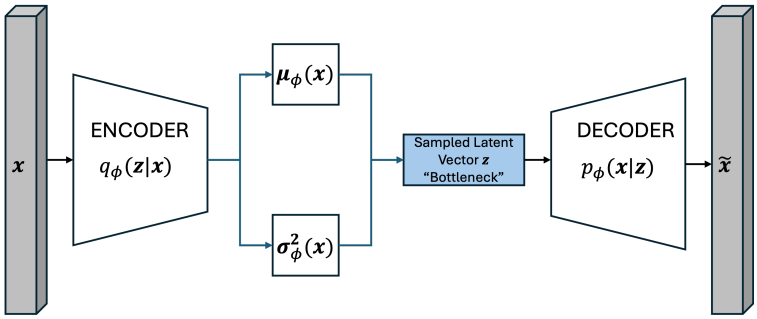

图 2：变分自编码器（VAE）架构。

尽管自编码器和变分自编码器具有诸多优势，但当训练数据中的异常值比例较高时，它们也会表现出明显的局限性。由于重构损失直接驱动参数更新，受污染观测可能会对梯度产生不成比例的影响，使学习到的流形向异常区域偏移。这种影响会造成流形扭曲，使模型部分重构异常值，而非将其区分出来。随着失控数据比例增加，受控观测值与失控观测值之间的重构误差差距会缩小，从而降低判别能力。变分自编码器也会受到类似影响：其潜在分布会偏向受污染区域 [Akrami 等，2019，Li 等， 2020], 从而破坏潜在空间的高斯结构，并导致 KL 正则化项无法准确表征真实的 IC 变异性。

3 方法论

变分自编码器容易受到数据污染影响，因此在统计过程控制（SPC）中需要采用专门的训练方案。上一节详细说明了失控（OC）观测值如何扭曲潜在流形，而回顾性分析面临的实际挑战是缺乏干净且带标签的受控（IC）数据。直接将变分自编码器应用于受污染的历史数据集会导致较高的假阴性率，因为模型会无意中将过程偏移学习为标称分布的一部分。这种失效模式削弱了第一阶段监测的核心目标：为未来的过程行为建立稳健的基线。为克服这些局限，所提出的方法不再局限于简单的密度估计，而是转向稳健的迭代学习过程。通过明确将过程变异性的学习与异常的影响分离，我们可以确保最终的重构分数和潜在嵌入仍能敏锐地反映工业过程故障所特有的偏差。

为使变分自动编码器适用于异常检测与回顾性统计过程控制分析，必须重新构建方法论，以便：(i) 异常观测能够被识别并隔离，而不是被吸收进学习到的流形；(ii) 重构质量能够反映相对于受控变异的真实偏离；(iii) 潜在分布保持稳定、近似高斯，并代表底层受控过程。实现这些目标需要相应机制，以迭代方式精炼训练数据集、降低异常样本的影响，并更新变分自编码器参数，从而使潜在空间逐步得到净化。如此，重构误差与潜在嵌入均可成为失控行为的可靠指标，为后续阶段稳健的在线监测奠定基础。

所提出的VSCOUT框架通过一条集成式流程将这一策略付诸实施，该流程结合了基于集成的异常值检测、VAE训练及持续精炼，以及潜在空间监控。该方法论的各个组成部分将在后续各节中详细阐述。

3.1 步骤1：初始ARD-VAE训练（相关潜在维度提取）

VSCOUT 基于 VAE框架构建，但选择合适大小的潜在向量$\mathbf{z} \in \mathbb{R}^d$ 对于实现准确的统计过程控制监测既具有挑战性又至关重要。过大的潜在空间可能会吸收噪声和异常变化，而过小的潜在空间则可能无法捕捉集成电路结构的内在特征。为解决这一问题，VSCOUT 融入了

自动相关性确定变分自编码器（ARD-VAE）框架 [Saha 等人， 2025], 该框架将潜在维度的选择从固定的超参数转变为数据驱动推断问题（见图 3）。
在标准变分自编码器中，潜在向量的先验分布是各向同性的，

$$p(\mathbf{z}) = \mathcal{N}(\mathbf{0}, \mathbf{I}),$$

这隐式地将所有 d 潜在轴视为同等重要。ARD-VAE 用分层相关性先验取代此先验分布，为每个潜在坐标 z_ℓ 分配各自的精度参数 α_ℓ:

$$p(\mathbf{z} \mid \boldsymbol{\alpha}) = \prod_{\ell=1}^{d} \mathcal{N}(z_\ell; 0, \alpha_\ell^{-1}), \qquad p(\alpha_\ell) = \mathrm{Gamma}(a_0, b_0).$$

α_ℓ 的较大取值会迫使先验方差 α_ℓ^{-1} 趋近于零，从而有效地剪除不相关的潜在轴。对 α_ℓ 积分后，可得到重尾的 Student-t 先验分布，它自然地促进稀疏性，同时允许有信息量的维度保持活跃。

与标准变分自编码器一样，编码器会输出一个变分后验

$$q_\phi(\mathbf{z} \mid \mathbf{x}) = \mathcal{N}\big(\boldsymbol{\mu}_\phi(\mathbf{x}), \mathrm{diag}\left(\boldsymbol{\sigma}_\phi^2(\mathbf{x})\right)\big),$$

其中，$\boldsymbol{\mu}_\phi(\mathbf{x})$ 和 $\boldsymbol{\sigma}_\phi^2(\mathbf{x})$ 分别表示编码器针对给定观测值 $\mathbf{x}$ 估计的均值和方差。然而，在 ARD 先验下，证据下界中的 KL 项会因维度而异，并将不相关轴对应的后验推向零方差，使后验与收缩中的先验保持一致。

为确定哪些潜在轴确实相关，ARD-VAE 会同时评估：(i) 特定轴的先验精度 α_ℓ，以及 (ii) 解码器对潜在均值扰动的灵敏度。解码器灵敏度通过雅可比矩阵来衡量

$$J_\theta(\mathbf{x}) = \frac{\partial f_\theta(\boldsymbol{\mu}_\phi(\mathbf{x}))}{\partial \boldsymbol{\mu}_\phi(\mathbf{x})},$$

其 ℓ 列衡量潜在维度 ℓ 的变化对重构 $\tilde{}\mathbf{x}$的影响程度。后验方差较小、精度 α_ℓ 较高且雅可比范数接近零的潜在维度会被视为无关维度。
由此得到一条有原则的剪枝规则，可生成精简后的相关潜在表示：

$$\boldsymbol{\mu}_\phi^*(\mathbf{x}) = (\mu_{\phi,\ell}(\mathbf{x}) : \ell \in \mathcal{R}), \qquad \boldsymbol{\sigma}_\phi^{2*}(\mathbf{x}) = (\sigma_{\phi,\ell}^2(\mathbf{x}) : \ell \in \mathcal{R}),$$

其中， $\mathcal{R}$ 表示由 ARD 机制识别出的相关潜在维度索引集。因此，有效潜在维度 $d_{\text{eff}} = |\mathcal{R}|$ 由数据直接确定，而非预先指定。
对于 VSCOUT，这种基于 ARD 的潜在维度选择可确保学习到的潜在空间仅捕捉稳定的 IC 变异性，同时抑制噪声或异常方向。由此形成紧凑且易于解释的潜在表示，为第一阶段和第二阶段统计过程控制监测中的基于重构和潜在距离的异常评分提供可靠基础。

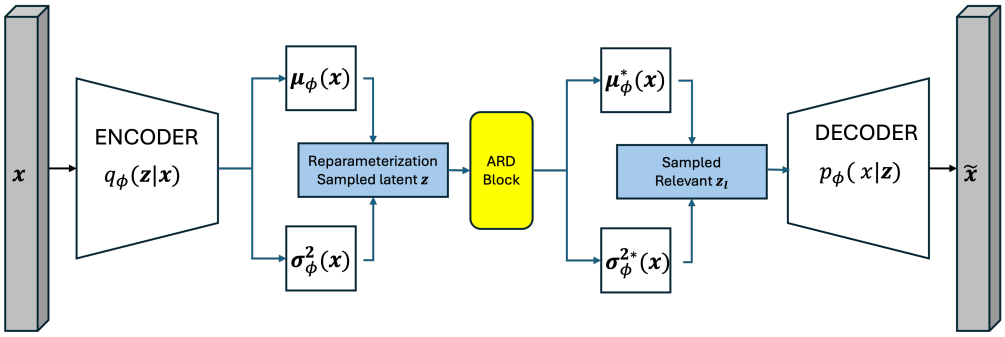

图 3：自动相关性确定变分自编码器（ARD-VAE）架构。

图4通过一个实证示例展示了 ARD-VAE机制：编码器和解码器均采用含64个神经元的前馈架构，初始潜在维度为32。在两个示例中，ARD先验都将潜在表示剪枝至三个相关维度（$d_{\text{eff}} = 3$），展现了模型恢复紧凑且易于解释的潜在空间的能力。左图对应一个受污染正态数据集，其中降维后的潜在

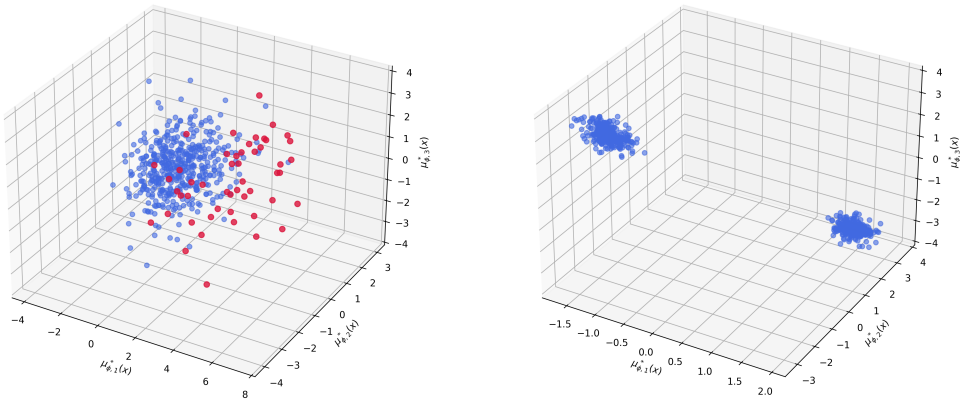

图4：左：受污染正态数据集的 ARD-VAE 潜在空间，其中包含 450 个受控观测值和 50 个偏移观测值（$\delta = 1$），$p = 250$。右：包含两个高斯簇的多模态数据集的 ARD-VAE 潜在空间（每簇 250 个观测值），簇中心分别为 -5 和 5，$p = 250$。

空间清晰地分离出偏移观测，同时保留了受控分布的连贯表示。右图展示了一个多模态数据集；尽管维度有所降低，ARD-VAE仍保留了其固有的双簇结构。

为考察 ARD-VAE 的剪枝行为，我们将初始潜在维度从 2 调整到 64，并测量训练后的有效维度 d_{eff}。图5总结了四种数据情形下的结果：干净正态数据、含 20% 污染的正态数据、干净的 t 分布数据（自由度 df 为 $= 5$），以及含 20% 污染的 t 分布数据。在所有情况下，即使名义潜在容量很大，ARD-VAE 仍会大幅降低潜在空间的维度。对于干净数据集，d_{eff} 先增加，随后稳定在 12 至 15 之间，反映出模型恢复了内在结构。在存在污染或重尾的情况下，d_{eff} 始终较小，表明 ARD-VAE 能够适当降低不稳定方向的权重，并避免对异常观测过拟合。在所有设置中，模型都表现出很强的自正则化能力：冗余的潜在坐标会受到抑制，只有具有信息量的轴得以保留，显示出模型对分布偏移和异常值存在的稳健性。

符号说明。 对于每个观测值$\mathbf{x}_i$，ARD-VAE 编码器输出降维后的潜在表示

$$\mathbf{z}_i = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i) \in \mathbb{R}^{d_{\text{eff}}},$$

其中，$d_{\text{eff}} = |\mathcal{R}|$是 ARD 机制保留的相关潜在维度数量。对于整个数据集$X = \{\mathbf{x}_1, \ldots, \mathbf{x}_n\}$，我们将堆叠潜在矩阵定义为$\mathbf{Z} = \boldsymbol{\mu}_\phi^*(X) = \left[\mathbf{z}_1^\top, \ldots, \mathbf{z}_n^\top\right] \in \mathbb{R}^{n \times d_{\text{eff}}}$。该矩阵是步骤 2 中用于集成过滤和变点检测的潜在表示。经过步骤 3 的细化后，更新后的潜在向量表示为

$$\mathbf{z}_i^{\text{in}} = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i), \qquad \mathbf{x}_i \in X_{\text{in}},$$

whe其中，X_{in} 是经过集成和变点过滤后保留的观测值集合。 bl

3.2 步骤2a：在相关潜在子空间中进行基于集成的异常值过滤

VSCOUT 的此阶段直接在相关潜在子空间中执行逐点异常值过滤。对于每个观测值$\mathbf{x}_i$，ARD-VAE 编码器输出降维后的潜在表示

$$\mathbf{z}_i = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i) \in \mathbb{R}^{d_{\text{eff}}},$$

其中，$d_{\text{eff}} = |\mathcal{R}|$ 是 ARD 机制保留的潜在维度数。在这个紧凑的潜在空间中运行，可以提高经典异常检测器的稳定性；这些检测器在原始高维特征空间中可能表现不佳，同时还可防止无关变异影响筛选步骤。

对于完整数据集 $X = \{\mathbf{x}_1, \ldots, \mathbf{x}_n\}$，我们将堆叠潜在矩阵记为

$$\mathbf{Z} = \boldsymbol{\mu}_\phi^*(X) = \begin{bmatrix} \mathbf{z}_1^\top \\ \vdots \\ \mathbf{z}_n^\top \end{bmatrix} \in \mathbb{R}^{n \times d_{\text{eff}}}.$$

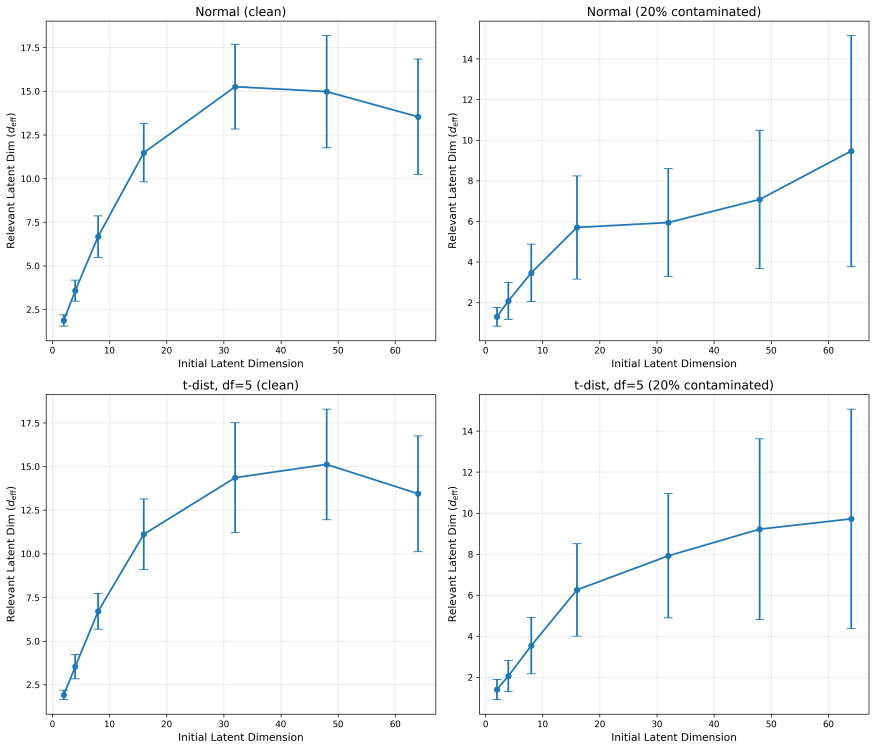

图5：对于初始潜在维度从 2 到 64 的情况，ARD-VAE 选出的平均有效潜在维度为 d_{eff}，误差线表示多次拟合结果的一个标准差。上排：干净正态数据（左）和污染率为 20% 的正态数据（右）。下排：干净的 t 分布数据（自由度为 $=5$）（左），以及污染率为 20% 的相同分布数据（右）。

集成中的每个检测器 D_j 都会将潜在向量映射为二元决策，

$$D_j : \mathbb{R}^{d_{\text{eff}}} \to \{0, 1\},$$

此外，VSCOUT 兼容多种检测器类别，包括基于距离的检测器（k近邻 [Angiulli 和 Pizzuti， 2002]）、基于密度的检测器（局部离群因子 [Breunig 等， 2000]）、基于隔离的检测器（孤立森林 [Liu 等， 2008]）、无分布假设的检测器（ECOD [Li 等， 2022]）、基于直方图的检测器（HBOS [Goldstein 和 Dengel，2012]），以及诸如在 $d_{\text{eff}} = 1$ 时使用箱线图围栏等单变量规则。由于这些检测器各自独立运行，该集成完全模块化，可配置为侧重灵敏度、特异度或均衡鲁棒性。

对于每个观测值，检测器输出会被聚合为单一的临时集成标记 g

$$e_i^{(0)} = \mathcal{C}(D_1(\mathbf{z}_i), \ldots, D_m(\mathbf{z}_i)), \qquad e_i^{(0)} \in \{0, 1\},$$

其中，共识函数 $\mathcal{C}$ 可以是：

- 多数投票：大多数检测器必须将该观测值标记为异常；
- 任一（并集）规则：至少一个检测器将该观测值标记为异常；
- 全部（交集）规则：每个检测器都必须将该观测值标记为异常。

“任一”规则是 最敏感，而“全部”规则最为保守；多数投票则提供了 n 中间平衡 .

为防止过度激进的剔除，VSCOUT 允许用户指定最大污染水平 α，表示期望的标记观测值比例。检测器特定阈值会在内部进行调整，以确保在任何一次迭代中，最多只有 αn 个点被赋予 $e_i^{(0)} = 1$。这一限制可稳定早期的细化轮次，并确保潜在空间估计仍以足够大的受控子集为基础。

带有 $e_i^{(0)} = 1$ 的观测值会暂时移除，随后在剩余数据上重新训练 ARD-VAE。这一迭代式集成过滤过程逐步净化潜在空间，从而为最终异常评分和第一阶段统计过程控制估计提供更准确、更可靠的基线。

3.3 步骤 2b：相关潜在子空间中的变点检测过滤器

除了逐点异常值过滤，VSCOUT 还采用变点检测来识别潜在表示中的持续性或结构性偏移，这些偏移可能表明存在持续的过程偏差。对于每个观测值$\mathbf{x}_i$，ARD-VAE 编码器会生成降维后的潜在向量

$$\mathbf{z}_i = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i) \in \mathbb{R}^{d_{\text{eff}}},$$

并对潜在幅值序列进行变点分析

$$s_i = \|\mathbf{z}_i\|_2, \qquad i = 1, \ldots, n.$$

步骤2a中的集成检测器能够识别局部或孤立的异常值，而序列 $\{s_i\}$ 分布中的结构变化则揭示了经典的逐点 SPC 工具可能忽略的持续偏移。

为检测此类分布变化，VSCOUT 应用剪枝精确线性时间（PELT）算法 [Killick 等人，2012] 对 $\{s_i\}$ 进行检测。给定分段代价函数 $\mathcal{C}(\cdot)$（通常为 L_2 或径向基函数代价）和惩罚参数 $\beta > 0$，PELT 求解

$$\min_{K,\,\tau_{1:K}} \left\{ \sum_{k=0}^{K} \mathcal{C}\big(s_{(\tau_k+1):\tau_{k+1}}\big) \;+\; \beta K \right\},$$

其中 $0 = \tau_0 < \tau_1 < \cdots < \tau_K < \tau_{K+1} = n$ 表示变点位置。惩罚项 β 控制有效虚警率：值越大，检测到的变点越少（更为保守）；值越小，灵敏度越高。类比经典 SPC 实践，β 可与期望的变点污染水平 α_{cp} 相关联，使从业者能够校准过滤器的保守程度。实现时使用 ruptures 软件包 [Truong 等人， 2018]。

从检测到的变点集合 $\{\tau_1, \ldots, \tau_K\}$中，VSCOUT使用最早的变点

$$\tau^* = \min\{\tau_k\}$$

作为潜在持续偏移的起始点。临时变点标志的分配方式为

$$c_i^{(0)} = \begin{cases} 1, & i > \tau^*, \\ 0, & i \le \tau^*. \end{cases}$$

带有 $c_i^{(0)} = 1$的观测值会在第二阶段 ARD-VAE 训练之前被临时移除。这遵循标准的回顾性统计过程控制目标，即在估计基线参数之前，先在数据集开头分离出受控片段。

PELT的行为主要由其目标函数中的惩罚参数 β 决定

$$\sum_{k=0}^{K} \mathcal{C}\big(s_{\tau_k+1:\tau_{k+1}}\big) + \beta K,$$

其中较大的 β 会抑制额外变点并减少虚假检测。尽管PELT不使用正式的统计显著性水平，β 仍充当隐式误报控制器。额外的稳定性来自所选代价函数 $\mathcal{C}$ （例如 L_2、高斯或RBF）以及最小分段长度约束，该约束可防止由短时振荡或噪声引起的检测。

集成过滤（步骤2a）与基于PELT的变点检测（步骤2b）相结合，使VSCOUT对瞬态异常和持续结构偏差均具有灵敏度。违反潜在流形的局部异常由集成识别，而 $\{s_i\}$ 中渐进或持续的分布变化则由PELT捕获。这种双重机制为后续统计过程控制监测生成稳健的第一阶段受控基线，并在复杂的高维过程条件下提高检测可靠性。

3.4 步骤 3：ARD-VAE 精炼（第二训练阶段）

通过集成和变点滤波器移除暂定异常后，VSCOUT 使用保留的受控观测值进行第二轮 ARD-VAE 训练。此精炼阶段通过确保编码器–解码器对仅在被认为来自受控分布的数据上进行优化，从而稳定潜在表示，减少潜在失真，并提升重构质量和概率编码效果。

令 m_i 表示步骤 2 得到的暂定内点掩码，并定义

$$X_{\text{in}} = \{\mathbf{x}_i : m_i = 1\}$$

为精炼时保留的观测值子集。第二阶段优化不会从头重新初始化 ARD-VAE，而是从步骤 1 学到的编码器和解码器参数 $(\theta,\ \phi)$热启动。由于这些参数已经反映了完整数据集的全局结构，精炼阶段只需进行增量更新，以消除异常样本的残余影响。参数按照以下方式更新：

$$(\theta,\phi) \leftarrow (\theta,\phi) - \eta\,\nabla_{(\theta,\phi)}\mathcal{L}_{\mathrm{ELBO}},$$

采用学习率 η 和小批量更新，并使用与初始训练相同的 ELBO目标函数和重参数化采样机制。

细化后，更新潜在均值

$$\mathbf{z}_i^{\mathrm{in}} = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i), \qquad \mathbf{x}_i \in X_{\mathrm{in}},$$

并计算相应的方差 $\boldsymbol{\sigma}_\phi^2(\mathbf{x}_i)$。随后，针对每个潜在坐标 ℓ计算新的 KL散度值：

$$\mathrm{KL}_\ell = \mathbb{E}_{\mathbf{x}\in X_{\mathrm{in}}}\left[D_{\mathrm{KL}}(q_\phi(z_\ell \mid \mathbf{x}) \,\|\, p(z_\ell))\right].$$

相关潜变量集通过以下方式更新

$$\mathcal{R} = \left\{\ell \ :\ \mathrm{KL}_\ell > \tau\right\},$$

.

如果细化后的集合 $\mathcal{R}$ 与步骤 1 得到的集合不同，VSCOUT 会保留新选出的坐标，以用于后续建模。如果 $\mathcal{R}$ 保持不变，则恢复第一阶段训练得到的编码器和解码器权重，以避免潜在几何结构发生不必要的漂移。

这一精炼阶段会移除异常或偏移观测，从而得到一个经过清理且稳定的潜在子空间，用以表征受控过程的内在变异。VSCOUT 后续的所有组成部分——Hotelling 的T^2、重构误差阈值、集成重训练以及变点重新校准——均基于这一精炼后的潜在表示运行。

3.5 步骤4：通过共识规则最终确定异常值

VSCOUT 的各组成部分——ARD-VAE 潜变量建模、集成过滤和变点检测——分别捕捉过程异常行为的互补特征。为生成稳定的受控（IC）参考和最终的失控标签，这些组成部分先通过初始过滤步骤，再结合精炼与共识阶段。

完成初始 ARD-VAE 拟合（步骤1）后，通过以下两种方式标记暂定异常：（i）作用于相关潜在子空间的集成；（ii）应用于潜在幅度轨迹的变点检测。对于每个观测值 $\mathbf{x}_i$，ARD-VAE 编码器输出一个降维后的潜在向量

$$\mathbf{z}_i = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i) \in \mathbb{R}^{d_{\mathrm{eff}}}, \qquad s_i = \|\mathbf{z}_i\|_2,$$

其中 s_i 表示相关潜在表示的 L_2 幅值。对序列 $\{s_i\}_{i=1}^n$ 应用 PELT 得到变点位置 $\{\tau_1,\ldots,\tau_K\}$，最早的变点

$$\tau^* = \min\{\tau_k\}$$

会产生暂定变点标记

$$c_i^{(0)} = \begin{cases} 1, & i > \tau^*, \\ 0, & i \le \tau^*. \end{cases}$$

与此同时，将集成检测器应用于$\mathbf{z}_i$ ，得到暂定集成标记 $e_i^{(0)} \in \{0,1\}$。这些标记合并为暂定内点掩码

$$m_i = 1 - \max\{e_i^{(0)},\, c_i^{(0)}\}, \qquad m_i \in \{0,1\},$$

以及相应的内点子集

$$X_{\mathrm{in}} = \{\mathbf{x}_i : m_i = 1\}$$

用于细化。

在步骤 3中，ARD-VAE 在 X_{in} 上重新训练。关键在于，编码器和解码器的参数不会重新初始化：第二阶段优化从初始拟合过程中学到的权重开始热启动。因此，梯度下降从已适应数据全局结构的参数状态继续进行，优化重点是消除

异常样本的残余影响，而不是重新学习整个生成模型。重新训练后的编码器会生成经过优化的潜在向量

$$\mathbf{z}_i^{\text{in}} = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i), \qquad i = 1, \ldots, n,$$

并在必要时更新相关潜变量集 $\mathcal{R}$。

VSCOUT 随后仅使用经过精炼的内点（$m_i = 1$），在最终相关潜在子空间中估计受控状态统计量：

$$\boldsymbol{\mu}_{\text{IC}} = \frac{1}{n_{\text{in}}} \sum_{i:m_i=1} \mathbf{z}_i^{\text{in}}, \qquad \Sigma_{\text{IC}} = \text{Cov}\big(\mathbf{z}_i^{\text{in}} : m_i = 1\big),$$

其中 $n_{\text{in}} = \sum_i m_i$。这些定义了 Hotelling 监测统计量

$$T_i^2 = \left(\mathbf{z}_i^{\text{in}} - \boldsymbol{\mu}_{\text{IC}}\right)^\top \Sigma_{\text{IC}}^{-1} \left(\mathbf{z}_i^{\text{in}} - \boldsymbol{\mu}_{\text{IC}}\right),$$

其阈值 h 设定为受控条件下的经验或理论（$1 - \alpha_{T^2}$）分位数。

有必要简要讨论协方差估计 Σ^{-1} 受控 在 T^2 中的稳定性。尽管 ARD-VAE 通常会将相关潜变量维度缩减至较小的 d_{eff}，但在受控样本量有限的情况下，协方差矩阵仍可能出现轻度病态。在所有仿真场景中，ARD 驱动的降维足以确保数值稳定性，无需显式收缩；不过，在 n_{in}极小的应用中，实践者可以选择使用正则化估计量（例如 Ledoit–Wolf）。

重构误差

$$r(\mathbf{x}_i) = \|\mathbf{x}_i - \tilde{\mathbf{x}}_i\|_2^2$$

会针对所有观测值进行计算，并从 $\{r(\mathbf{x}_i)$ 估计受控状态截断值 q_α （例如第 95 百分位数）： $m_i = 1\}$。随后，集成检测器在经过优化的潜在向量 $\mathbf{z}_i^{\text{in}}$上针对 $m_i = 1$ 重新拟合，然后应用于所有 $\mathbf{z}_i^{\text{in}}$，以获得更新后的集成标记 e_i。

最终判定规则。 对于每个观测值 $\mathbf{x}_i$，VSCOUT 生成四个二元指标：

$$c_i \text{ (changepoint-based)}, \qquad e_i \text{ (ensemble)}, \qquad u_i = \mathbb{I}(T_i^2 > h), \qquad q_i = \mathbb{I}(r(\mathbf{x}_i) > q_\alpha).$$

如果至少有两个指标一致，则将该观测值标记为失控：

$$\hat{y}_i = \mathbb{I}(c_i + e_i + u_i + q_i \ \geq \ 2)\,.$$

该共识规则降低了对任何单一组件产生的虚假误差的灵敏度，同时保留了检测突发点异常和持续分布偏移的能力。通过在优化后的潜在空间中结合统计距离、重构行为、集成一致性和序列结构，VSCOUT 能够生成稳健且易于解释的失控标签，适用于回顾性第一阶段分析，并可用于为后续在线监测建立可靠的受控状态基线。

图6对VSCOUT 流程进行了高层概述，展示了ARD-VAE潜变量建模、基于集成的筛选、变点检测、细化以及最终共识评分之间的顺序交互。算法1中的相应伪代码将这些步骤形式化，并明确了潜变量编码、临时异常剔除、热启动细化、受控状态参数估计以及最终指标评估的执行顺序。步骤1至3通过训练ARD-VAE、借助集成标记和变点标记剔除临时异常，并在不重新初始化参数的情况下于内点子集上重新训练模型，从而实现潜在空间的迭代净化。步骤4将四项互补指标——变点标记、集成标记、Hotelling T^2 超限以及重构误差超限——汇总为稳健的4中取2共识判定规则，以得到最终异常值标签$\hat{}y_i$。

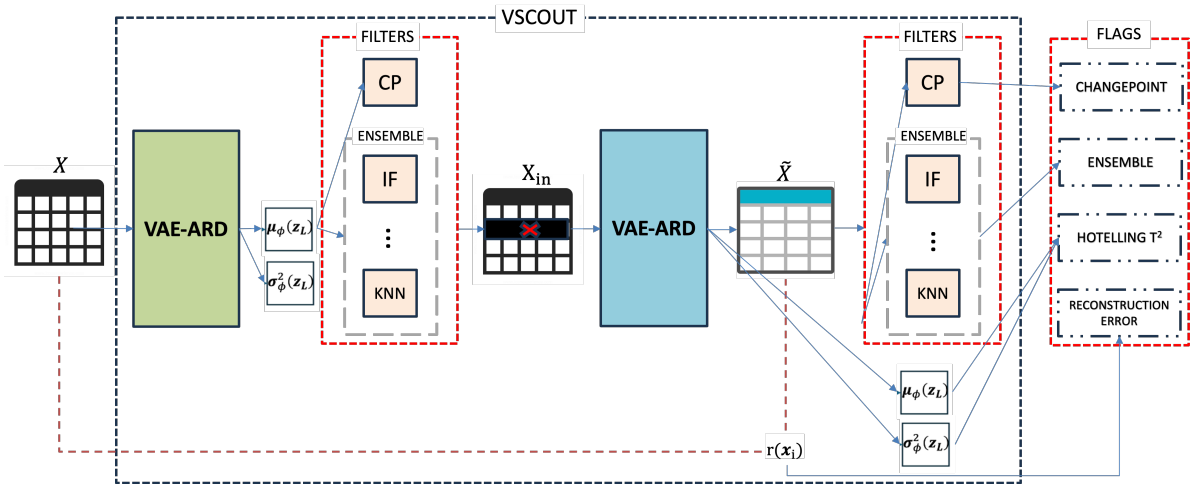

图6：VSCOUT 工作流程。

算法1 VSCOUT：变分自校正异常值发现技术 **要求：**数据集 $X \in \mathbb{R}^{n\times p}$；潜在维度 d；KL阈值 λ；惩罚项 β；显著性水平 α，架构神经元。**确保：**异常值标签 $\hat{}y \in \{0,1\}^n$。 1：（步骤1）在 X上训练ARD-VAE；获得潜在向量 $\mathbf{z}_i = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i)$。 2：（步骤2b）计算模长 $s_i = \|\mathbf{z}_i\|_2$；以惩罚项 β应用PELT；定义暂定变点标记 $c_i^{(0)}$。 3：（步骤2a）将集成检测器应用于 $\mathbf{z}_i$；获得暂定集成标记 $e_i^{(0)}$。 4：形成暂定内点掩码 $m_i = 1 - \max\{e_i^{(0)}, c_i^{(0)}\}$ 以及内点集 $X_{\text{in}} = \{\mathbf{x}_i : \ m_i = 1\}$。 5：（步骤 3）在 X_{in}上重新训练ARD-VAE；获得细化后的潜在向量 $\mathbf{z}_i^{\text{in}}$并在必要时更新 $\mathcal{R}$。 6：由 $\{\mathbf{z}_i^{\text{in}} : \ m_i = 1\}$估计受控状态均值 $\boldsymbol{\mu}_{\text{IC}}$ 和协方差 Σ_{IC}。 7：在细化后的潜在向量上重新拟合集成检测器。 8：计算重构误差 $r(\mathbf{x}_i)$并确定截断值 q_{α° 9：对每个观测值 $i = 1, \ \ldots, \ n$ 执行 10：计算 $c_i = \mathbb{I}(i > \tau^*)$、集成标记 e_i、 $u_i = \mathbb{I}(T_i^2 > h)$以及 $q_i = \mathbb{I}(r(\mathbf{x}_i) > q_\alpha)$。 11：赋予最终标签 $\hat{}y_i = \mathbb{I}(c_i + e_i + u_i + q_i \geq 2)$。 12：结束循环 13：返回 $\hat{}y$

3.6 总体误报控制

VSCOUT 通过组合四个二元指标来生成最终的失控标签：基于变点的标记 c_i、集成异常值投票 e_i、经由 T_i^2 的潜在空间霍特林超限 u_i，以及重构误差超限 q_i。每个组件都对应一个受控状态误报概率，

$$\alpha_{\text{cp}} = \Pr(c_i = 1), \qquad \alpha_{\text{ens}} = \Pr(e_i = 1), \qquad \alpha_{T^2} = \Pr(u_i = 1), \qquad \alpha_{\text{rec}} = \Pr(q_i = 1).$$

当至少两个指标触发时，VSCOUT 会将某个观测值判定为失控，

$$y_i = \mathbb{I}(c_i + e_i + u_i + q_i \geq 2), \qquad \alpha_{\text{global}} = \Pr(y_i = 1 \mid \text{IC}).$$

集成级误报。 该集成由 m 个基础检测器组成，每个检测器均以名义单检测器误报率 α_0运行。根据聚合规则，集成继承有效误报率 $\alpha_{\text{ens}^\circ}$ 在近似独立的条件下：

$$\alpha_{\text{ens}}^{(\text{any})} \approx m\alpha_0, \qquad \alpha_{\text{ens}}^{(\text{all})} = \alpha_0^m,$$

而对于多数投票，

$$\alpha_{\text{ens}}^{(\text{maj})} = \sum_{k=\lceil m/2 \rceil}^{m} \binom{m}{k} \alpha_0^k (1-\alpha_0)^{m-k}.$$

这一有效集成率直接用于全局四取二决策规则。

近似全局误报概率。由于这四个指标旨在检测不同类型的偏差，其受控超限虽不常见，但并非严格独立。特别是，基于变分自编码器得出的量 u_i 和 q_i 往往呈正相关，因为远离潜在均值的观测值通常会产生较大的重构误差。因此，以下近似可作为一种一阶校准启发式，而非正式的独立性假设。

设 $I_i^{(j)} \in \{c_i, e_i, u_i, q_i\}$。在受控条件下，全局四中取二误报主要由任意两个指标触发的概率决定：

$$\alpha_{\text{global}} \approx \sum_{(j,k)} \Pr\Big(I_i^{(j)} = 1,\, I_i^{(k)} = 1\Big),$$

其中 su m 遍历六个指标对。用边际概率的乘积替代联合概率可得 s

$$\alpha_{\text{global}} \approx \alpha_{\text{cp}}\alpha_{\text{ens}} + \alpha_{\text{cp}}\alpha_{T^2} + \alpha_{\text{cp}}\alpha_{\text{rec}} + \alpha_{\text{ens}}\alpha_{T^2} + \alpha_{\text{ens}}\alpha_{\text{rec}} + \alpha_{T^2}\alpha_{\text{rec}}.$$

如果将非集成分量调至共同的基线水平 α_{base}，即

$$\alpha_{\text{cp}} \approx \alpha_{T^2} \approx \alpha_{\text{rec}} \approx \alpha_{\text{base}},$$

则上式化简为

$$\alpha_{\text{global}} \approx 6\,\alpha_{\text{base}}^2, \qquad \Rightarrow \qquad \alpha_{\text{base}} = \sqrt{\alpha_{\text{global}}/6}.$$

这为选择分量阈值提供了透明的解析指南。由于在实践中 u_i 和 q_i 通常呈正相关，因此通过经验受控验证对解析近似进行补充，以确保在有限样本条件下，实际全局误报率与期望的 α_{global} 相符。

4 回顾性监测实验

本节在模拟的偏移情景下，评估 VSCOUT 在回顾性（第一阶段）统计过程控制（SPC）环境中的性能。目标是评估 VSCOUT 构建稳定受控基线并识别高维过程中特殊原因偏差的能力。

VSCOUT 默认设置。除非另有说明，所有实验均采用一组通用超参数（VSCOUT 的默认值）。ARD-VAE 组件采用前馈编码器-解码器架构，编码器和解码器各包含一个由 64 个神经元组成的隐藏层，潜在维度为 $L = 32$，并使用 ReLU 激活函数。学习率固定为 $\eta = 10^{-4}$，并采用早停策略，耐心值为 10 个周期。当 $\text{KL}_\ell > \tau$且阈值为 $\tau = 1.0$时，保留潜在坐标ℓ。使用 PELT算法和惩罚项 $\beta = 40$进行变点检测。潜在空间监控基于名义水平为 $\alpha = 0.05$的 Hotelling T^2 统计量；重构误差监控则采用相同的名义水平，阈值由受控数据的相应经验分位数确定。

集成过滤。 VSCOUT 使用多种经典检测器对降维后的潜在表示 $\mathbf{z}_i = \boldsymbol{\mu}_\phi^*(\mathbf{x}_i)$ 进行集成过滤，这些检测器代表互补的异常检测范式，包括孤立森林、局部异常因子、ECOD、 k近邻、HBOS、核密度估计，以及直接在潜在空间中应用的 Hotelling's T^2 统计量。当有效潜在维度降至一维时（$d_{\text{eff}} = 1$），还会额外采用基于箱线图的单变量规则。所有检测器均使用默认超参数，集成聚合遵循"任一"规则：只要某个检测器将某个观测值识别为异常，该观测值就会被暂时标记。此保守筛查策略有助于实现 VSCOUT 第一阶段的目标，即在 ARD-VAE 进一步优化之前移除可能受污染的观测值。

评估指标。 模型采用离群点检测率（召回率）、精确率、假阳性率（FPR）、受试者工作特征曲线下面积（AUROC）和内点保留率进行评估；纳入最后一项是为了体现第一阶段的目标。这些指标权衡了对真实异常的灵敏度与误报风险；这一权衡对于一般异常检测和回顾性统计过程控制（SPC）场景都至关重要。

4.1 VSCOUT 在回顾性监测中的应用

我们在回顾性（第一阶段）统计过程控制（SPC）环境下评估 VSCOUT，主要目标是在受控（IC）条件下保持名义第一类错误控制的同时，识别潜在的特殊原因偏差

。与激进的检测范式不同，第一阶段分析强调所估计基线的稳定性和稳健性。我们将 VSCOUT 与几种具有代表性的第一阶段方法进行比较，包括无分布假设的第一阶段程序 [Qiu、 2013], 基于秩的第一阶段控制图 [Qiu、 2018], 基于变分自编码器的监测方法 [Lee等人、 2019], Zamba多变量变点程序 [Zamba and Hawkins、 2006], 以及 Zou等人的变点检测器 [2008]。对角协方差稳健第一阶段控制图同样具有相关性，但其轴对齐的依赖性假设不同于 VSCOUT 的非线性潜在空间框架。深度孤立森林[Hariri等人、 2019] 以及通过 ELBD 进行潜变量选择 [Dong and Gao 2021] ，也同样是值得关注的竞争方法。

模拟研究涵盖四种数据生成机制：多元正态分布、 t分布（$df = 5$）、对数正态分布和混合分布（50% 正态分布和 50% t）。维度在 $p \in \{150, 250\}$ 范围内变化，样本量固定为 $n = 500$。通过对所有特征统一施加幅度为 $\delta \in \{1, 2, 3\}$ 的全局均值偏移来引入失控行为，而 $\delta = 0$ 则对应无异常值受控数据。此外，我们还改变污染比例 γ，该比例定义为被偏移样本替换的观测值所占比例，并考察低污染情形（$\gamma \in \{0.01, 0.03, 0.05\}$）和高污染情形（$\gamma \in \{0.10, 0.15, 0.20\}$）。对于分布形式、维度 p、偏移幅度 δ和污染比例 γ的每种独特组合，均进行 50 次独立蒙特卡洛重复试验，总计 9,600 次重复试验。

表1报告了不同分布和维度下的平均假阳性率（FPR）。VSCOUT 的 I 类错误控制表现稳定，整体平均假阳性率为 0.0418，表明其在所有情形下略显保守，但总体接近名义水平。包括 DF-第一阶段和 Rank-第一阶段在内的经典程序与名义水平（$\approx 0.049-0.050$）保持高度一致，而孤立森林则体现了用户指定的污染设置。相比之下，普通变分自编码器基线的假阳性率膨胀最为严重（平均值为 $= 0.0610$），尤其是在对数正态分布和混合分布下，这凸显了基于重构的阈值在使用受污染的受控数据进行训练时的敏感性。Zamba-CP 是整体上最保守的方法（平均假阳性率为 $= 0.0119$），而 RMDP 在不同分布下表现出显著的变异性。

表1：平均假 阳性率（FPR）在无异常值数据（$\delta = 0$）中的表现，按分布和维度划分。

分布。	p	DF-第一阶段孤立森林		Rank-第一阶段	VAE	Zamba-CP	RMDP	VSCOUT
正常	150	0.0490	0.0500	0.0500	0.0491	0.0110	0.0001	0.0290
	250	0.0490	0.0500	0.0500	0.0513	0.0015	0.0000	0.0310
t分布（自由度 = 5）	150	0.0489	0.0500	0.0500	0.0549	0.0181	0.0225	0.0400
	250	0.0488	0.0500	0.0500	0.0579	0.0208	0.0044	0.0420
对数正态分布	150	0.0491	0.0500	0.0500	0.0692	0.0125	0.2333	0.0490
	250	0.0489	0.0500	0.0500	0.0700	0.0133	0.1042	0.0530
混合	150	0.0491	0.0500	0.0500	0.0665	0.0160	0.0088	0.0440
	250	0.0489	0.0500	0.0500	0.0733	0.0021	0.0020	0.0460
多模态	150	0.0490	0.0500	0.0500	0.0399	0.0000	0.0000	0.0289
	250	0.0490	0.0500	0.0500	0.0402	0.0000	0.0000	0.0312
平均值	—	0.0490	0.0500	0.0500	0.0610	0.0119	0.0469	0.0418

4.1.1 瞬态过程偏移下的性能（$\delta > 0$）

在确认 VSCOUT 在无离群值条件下（$\gamma = 0$）能够维持严格的误报控制后，我们接下来考察它在存在瞬态过程偏移时的表现。瞬态异常是第一阶段中尤具挑战性的情形：偏移信号既微弱又短暂，而灵敏度过高则可能引发虚假警报，进而扭曲基线估计。因此，有效的回顾性监测需要一种方法，能够将间歇性偏差汇总为连贯的证据，同时抑制噪声驱动的偏离。

图8展示了 VSCOUT 对一种代表性瞬态偏移场景的响应。该场景由包含 $n = 500$ 个观测值和 $p = 150$ 个变量的不相关正态分布生成。在此示例中，50 个观测值受到从 $N(0, I)$ 短暂偏移至 $N(1.5, I)$ 的随机污染。尽管偏移幅度有限、持续时间较短，VSCOUT 仍成功识别出受污染片段，同时在受控区间保持稳定。这一表现凸显了 VSCOUT 能够将随时间和维度变化的微弱、间歇性异常信号整合起来，形成一致的控制图行为。从定量结果来看，该场景的精确率为 0.8596，召回率为 0.9800，F1分数为 0.9159，假阳性率仅为 0.0178，体现了较高的灵敏度和出色的克制性。

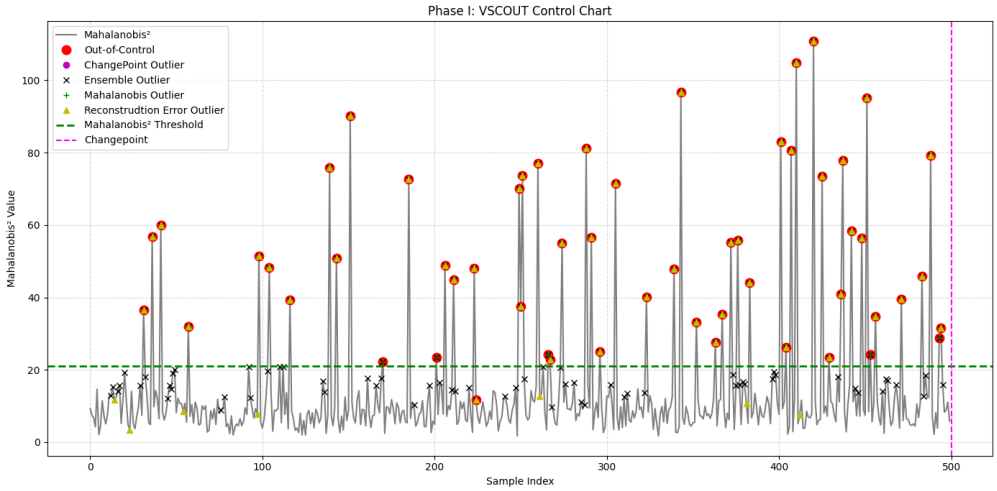

图 7：VSCOUT 控制图应用于存在瞬态偏移的数据的示意图，偏移从 $N(0,\ I)$ 变为 $N(1.5,\ I)$（$\gamma = 0.1$），其中 $n = 500$、$p = 150$。

在低污染情况下，若干方法表现出较强的检测能力，但在稳定性、稳健性和计算表现方面仍存在重要差异。VAE 的平均 F1分数最高，这主要得益于其在大多数分布和维度下近乎完美的召回率。然而，这种激进的灵敏度是以更高的计算负担和较不稳定的假阳性表现为代价的；尤其是在重尾和偏斜分布情形下，基于重构的阈值更容易受到失真影响。在对数正态分布和混合分布设置中，这种权衡尤为明显：VAE 较高的召回率伴随着更大的假阳性率和运行时间波动。

相比之下，VSCOUT 展现出更加均衡的检测表现。在大多数分布下，其召回率始终超过 90%，同时假阳性率通常低于 5%，因此在不牺牲 I 类错误控制的前提下，取得了有竞争力的 F1分数。这一表现得益于潜在空间细化与基于集成的筛选共同发挥作用，二者既抑制了虚假变异，又保留了对真实瞬态偏移的灵敏度。值得注意的是，随着维度从 $p = 150$ 增加到 $p = 250$，VSCOUT 的性能仍保持稳定，表明其能够稳健应对高维噪声和弱信息特征。

例如，在正态（$p = 250$）设置下，VSCOUT 的 F1分数为 0.6122，召回率为 0.9474，在灵敏度-特异度权衡方面优于孤立森林和 DF–Phase I。在 t分布数据和混合数据下也观察到类似模式；与经典第一阶段方法相比，VSCOUT 避免了其表现的大幅下降。Rank–Phase I 在低污染情况下也表现良好，但其有效性在很大程度上取决于基于秩的假设是否成立，并且在多模态或高度偏斜的结构下性能会下降。
经典的无分布第一阶段方法在非高斯条件下退化最为明显：重尾和偏度违背了隐含的模型假设，导致其在若干设置下的召回率接近于零。Zamba–CP 在所有低污染场景下都表现得十分保守，几乎不产生任何检测结果，因此尽管误报控制出色，F1 分数仍几乎为零。RMDP 展现出局部优势，尤其是在正态数据下，但其在不同分布之间表现出显著的波动，且运行时间始终更长，从而限制了其在大规模第一阶段研究中的实际吸引力。

综合来看，这些结果表明，尽管多种方法都能在轻度污染下检测到瞬态偏移，VSCOUT仍在灵敏度、特异度与计算效率之间实现了最可靠的折中之一。它在不同分布和维度下表现稳定，因此尤其适用于回顾性监测场景：在识别瞬态异常的同时，不会扰乱受控基线。

表 2：平均性能　瞬态均值偏移下低污染水平（$\gamma \in \{0.01, 0.03, 0.05\}$）时的指标 .

分布	大小（n，p）	指标	DF-第一阶段	孤立森林	Rank-第一阶段	VAE	Zamba-CP	RMDP	VSCOUT
正常	(500, 150)	F1	0.0000	0.4266	0.6781	0.5651	0.0030	0.9975	0.6035
		FPR	0.0507	0.0735	0.0220	0.0378	0.0010	0.0000	0.0262
		精确率	0.0000	0.2912	0.5771	0.4115	0.0078	1.0000	0.4780
		召回率	0.0000	0.9970	0.9997	0.9989	0.0033	0.9953	0.9173
		运行时间（秒）	1.6057	0.0677	0.0972	1.9419	0.8585	3.8525	6.7294
正常	(500, 250)	F1	0.0000	0.4274	0.6785	0.5568	0.0000	0.7636	0.6122
		FPR	0.0507	0.0734	0.0220	0.0393	0.0000	0.0000	0.0273
		精确率	0.0000	0.2918	0.5774	0.4030	0.0000	0.7822	0.4792
		召回率	0.0000	0.9988	1.0000	0.9988	0.0000	0.7529	0.9474
		运行时间（秒）	2.6697	0.0704	0.1578	2.2095	2.1385	9.7310	8.5476
t (df=5)	(500, 150)	F1	0.0001	0.4062	0.5955	0.5306	0.0000	0.6396	0.4562
		FPR	0.0506	0.0750	0.0259	0.0429	0.0000	0.0146	0.0364
		精确率	0.0001	0.2769	0.5038	0.3812	0.0000	0.5662	0.3504
		召回率	0.0004	0.9562	0.8925	0.9832	0.0000	0.8123	0.7632
		运行时间（秒）	1.5531	0.0784	0.0971	2.5903	0.8517	3.7634	9.8595
t（自由度=5）	(500, 250)	F1	0.0000	0.4133	0.6418	0.5360	0.0017	0.6194	0.5179
		FPR	0.0506	0.0744	0.0238	0.0425	0.0008	0.0025	0.0334
		精确率	0.0000	0.2819	0.5433	0.3851	0.0019	0.6977	0.3996
		召回率	0.0000	0.9686	0.9585	0.9923	0.0031	0.6291	0.8398
		运行时间（秒）	2.5569	0.0908	0.1577	6.1467	2.1502	9.7411	11.3769
对数正态分布	(500, 150)	F1	0.3825	0.4282	0.6755	0.7720	0.0174	0.2152	0.4798
		FPR	0.0352	0.0733	0.0222	0.0125	0.0021	0.2086	0.0543
		精确率	0.3049	0.2924	0.5745	0.6957	0.0595	0.1242	0.3406
		召回率	0.6598	1.0000	0.9970	0.9951	0.0146	1.0000	0.9656
		运行时间（秒）	1.5651	0.0640	0.0974	1.9652	0.8605	3.6044	6.5718
对数正态分布	(500, 250)	F1	0.3748	0.4282	0.6783	0.7922	0.0133	0.3416	0.5031
		FPR	0.0355	0.0733	0.0220	0.0105	0.0012	0.1052	0.0483
		精确率	0.2982	0.2924	0.5772	0.7208	0.0373	0.2145	0.3630
		召回率	0.6496	1.0000	0.9998	0.9988	0.0125	1.0000	0.9627
		运行时间（秒）	2.6154	0.0677	0.1581	2.1961	2.1299	12.5166	8.4695
混合	(500, 150)	F1	0.0000	0.3976	0.5668	0.5034	0.0039	0.4503	0.4040
		FPR	0.0506	0.0756	0.0272	0.0493	0.0004	0.0536	0.0531
		精确率	0.0000	0.2709	0.4797	0.3545	0.0082	0.3285	0.2905
		召回率	0.0000	0.9376	0.8493	0.9897	0.0026	0.8904	0.7928
		运行时间（秒）	1.5671	0.0793	0.0971	2.5545	0.8663	3.6775	9.8029
混合	(500, 250)	F1	0.0000	0.4068	0.5855	0.4894	0.0002	0.5348	0.4379
		FPR	0.0506	0.0749	0.0264	0.0529	0.0011	0.0123	0.0518
		精确率	0.0000	0.2773	0.4955	0.3411	0.0007	0.5057	0.3137
		召回率	0.0000	0.9591	0.8764	0.9948	0.0001	0.6904	0.8521
		运行时间（秒）	2.5728	0.0859	0.1577	3.6048	2.1502	9.6398	13.9198
多模态	(500, 150)	F1	0.6942	0.4282	0.0000	0.4844	0.0000	0.0000	0.6263
		FPR	0.0200	0.0733	0.0527	0.0308	0.0000	0.0000	0.0294
		精确率	0.5997	0.2924	0.0000	0.3734	0.0000	0.0000	0.4794
		召回率	0.9997	1.0000	0.0000	0.7618	0.0000	0.0000	0.9937
		运行时间（秒）	1.5710	0.0692	0.0969	1.7580	0.8582	3.6633	6.7035
多模态	(500, 250)	F1	0.6943	0.4282	0.0000	0.5172	0.0000	0.0000	0.6223
		FPR	0.0200	0.0733	0.0527	0.0298	0.0000	0.0000	0.0307
		精确率	0.5998	0.2924	0.0000	0.3989	0.0000	0.0000	0.4748
		召回率	0.9997	1.0000	0.0000	0.8120	0.0000	0.0000	0.9992
		运行时间（秒）	2.5746	0.0706	0.1577	1.9427	2.1383	9.7407	7.5452

为更系统地评估稳健性，我们考察了两种污染情形下的瞬态均值偏移：低污染（$\gamma \in \{0.01, 0.03, 0.05\}$）和高污染（$\gamma \in \{0.10, 0.15, 0.20\}$）。我们考察了五种数据生成机制（正态、 t 和 $df = 5$、对数正态分布、混合和多模态），以及两种维度（$p = 150$ 和 $p = 250$）。平均性能指标见表2和表3。

在低污染情况下，多种方法都展现出较强的检测能力，但也显现出重要差异。VAE 的平均 F1分数最高，这主要得益于其近乎完美的召回率；然而，这一性能伴随着更高的计算成本，而且在非高斯情形下假阳性表现不够稳定。VSCOUT 在大多数分布上的召回率始终超过 90%，同时假阳性率通常低于 5%，因此在正常、对数正态分布和混合设置下均取得了具有竞争力的 F1分数。例如，在正常（$p = 250$）情形下，VSCOUT 的 F1分数为 0.6122，召回率为 0.9474，在灵敏度-特异度权衡方面优于孤立森林和 DF–Phase I。当其基于秩的假设与数据结构相符时，Rank–Phase I 在这一情形下也表现良好。相比之下，DF–Phase I 在重尾和

偏态分布下性能下降，而 Zamba–CP 仍过于保守，在大多数设置中的召回率几乎为零。RMDP 在个别情况下表现出优势，但其表现波动较大，且运行时间始终更长。

表 3：瞬态均值偏移下高污染水平（$\gamma \in \{0.10, 0.15, 0.20\}$）时的平均性能指标。

分布	大小（n, p）	指标	DF-第一阶段	孤立森林	Rank-第一阶段	VAE	Zamba-CP	RMDP	VSCOUT
正常	(500, 150)	F1	0.0000	0.7965	0.5303	0.3225	0.0000	0.0026	0.6507
		FPR	0.0580	0.0041	0.0000	0.0389	0.0000	0.0000	0.0212
		精确率	0.0000	0.9652	1.0000	0.4327	0.0000	0.0511	0.7460
		召回率	0.0000	0.7022	0.3687	0.3057	0.0000	0.0013	0.6394
		运行时间（秒）	1.7906	0.0684	0.1250	2.1077	0.9052	3.5257	7.0242
正常	(500, 250)	F1	0.0000	0.8042	0.5303	0.3242	0.0000	0.0000	0.6880
		FPR	0.0580	0.0030	0.0000	0.0402	0.0000	0.0000	0.0207
		精确率	0.0000	0.9742	1.0000	0.4238	0.0000	0.0000	0.7645
		召回率	0.0000	0.7091	0.3687	0.3138	0.0000	0.0000	0.6913
		运行时间（秒）	2.9463	0.0750	0.2048	2.6477	2.1849	8.8990	8.9833
t (df=5)	(500, 150)	F1	0.0001	0.7281	0.4712	0.2752	0.0000	0.0212	0.5613
		FPR	0.0580	0.0138	0.0067	0.0405	0.0000	0.0009	0.0304
		精确率	0.0001	0.8831	0.8889	0.3897	0.0000	0.1617	0.6421
		召回率	0.0001	0.6414	0.3276	0.2485	0.0000	0.0120	0.5542
		运行时间（秒）	1.7584	0.0813	0.1253	4.6474	0.9073	3.4729	9.5022
t (df=5)	(500, 250)	F1	0.0001	0.7497	0.4998	0.2916	0.0000	0.0014	0.6344
		FPR	0.0580	0.0105	0.0035	0.0408	0.0000	0.0001	0.0269
		精确率	0.0002	0.9101	0.9420	0.4041	0.0000	0.0344	0.7089
		召回率	0.0001	0.6602	0.3476	0.2687	0.0000	0.0007	0.6329
		运行时间（秒）	2.9152	0.0883	0.2046	3.6755	2.1968	8.9617	19.7778
对数正态分布	(500, 150)	F1	0.1121	0.8213	0.5302	0.6725	0.0096	0.6311	0.8847
		FPR	0.0454	0.0007	0.0000	0.0015	0.0009	0.1948	0.0222
		精确率	0.2158	0.9940	0.9999	0.9816	0.1535	0.4669	0.8650
		召回率	0.0774	0.7248	0.3686	0.5428	0.0051	1.0000	0.9205
		运行时间（秒）	1.7423	0.0637	0.1253	1.9732	0.9126	3.4518	6.9867
对数正态分布	(500, 250)	F1	0.1136	0.8213	0.5303	0.6823	0.0053	0.7340	0.8961
		FPR	0.0453	0.0007	0.0000	0.0008	0.0003	0.1211	0.0209
		精确率	0.2189	0.9940	1.0000	0.9898	0.0861	0.5830	0.8719
		召回率	0.0784	0.7248	0.3687	0.5566	0.0027	1.0000	0.9357
		运行时间（秒）	2.8680	0.0712	0.2051	2.3809	2.1842	10.3278	9.1787
混合	(500, 150)	F1	0.0000	0.7131	0.4625	0.2850	0.0000	0.0481	0.5710
		FPR	0.0580	0.0160	0.0076	0.0452	0.0000	0.0017	0.0404
		精确率	0.0000	0.8643	0.8731	0.3783	0.0000	0.1820	0.6148
		召回率	0.0000	0.6287	0.3214	0.2709	0.0000	0.0332	0.5803
		运行时间（秒）	1.7618	0.0810	0.1255	4.5020	0.9131	3.4244	9.5293
混合	(500, 250)	F1	0.0001	0.7214	0.4887	0.2985	0.0000	0.0029	0.5935
		FPR	0.0579	0.0147	0.0046	0.0465	0.0000	0.0001	0.0390
		精确率	0.0001	0.8754	0.9227	0.3904	0.0000	0.0548	0.6356
		召回率	0.0000	0.6353	0.3397	0.2878	0.0000	0.0015	0.6104
		运行时间（秒）	2.9691	0.0878	0.2057	3.6811	2.1976	9.7347	19.7218
多模态	(500, 150)	F1	0.4270	0.7229	0.0000	0.2313	0.0000	0.0000	0.8191
		FPR	0.0000	0.0145	0.0578	0.0336	0.0000	0.0000	0.0083
		精确率	1.0000	0.8680	0.0000	0.3168	0.0000	0.0000	0.8691
		召回率	0.2890	0.6406	0.0000	0.2032	0.0000	0.0000	0.8035
		运行时间（秒）	1.7628	0.0769	0.1250	2.3330	0.9081	3.5358	7.0006
多模态	(500, 250)	F1	0.4284	0.7290	0.0000	0.2520	0.0000	0.0000	0.8258
		FPR	0.0000	0.0138	0.0578	0.0316	0.0000	0.0000	0.0081
		精确率	1.0000	0.8805	0.0000	0.3621	0.0000	0.0000	0.8752
		召回率	0.2902	0.6416	0.0000	0.2115	0.0000	0.0000	0.8106
		运行时间（秒）	2.9104	0.0841	0.2052	2.5939	2.1901	9.0117	8.4727
F1平均值			0.1139	0.7620	0.4043	0.3453	0.0015	0.1441	0.7099
F1排名			(6)	(1)	(3)	(4)	(7)	(5)	(2)

4.1.2 持续过程漂移下的性能（$\gamma > 0$）

为评估模型在持续异常和短期异常下的稳健性，我们也考察了持续过程偏移下的模型性能。图8展示了 VSCOUT 应用于瞬态偏移场景的示例，其中数据暂时从 $N(0, I)$ 基线偏移至 $N(1.5, I)$。模型准确地识别出受污染批次，且偏移区域之外没有误报。从定量结果来看，该示例的精确率为 0.9434，召回率为 1.0000，F1分数为 0.9709，假阳性率仅为 0.0257，展现了 VSCOUT 即使在短暂异常期间也能兼顾高灵敏度和特异度的能力。

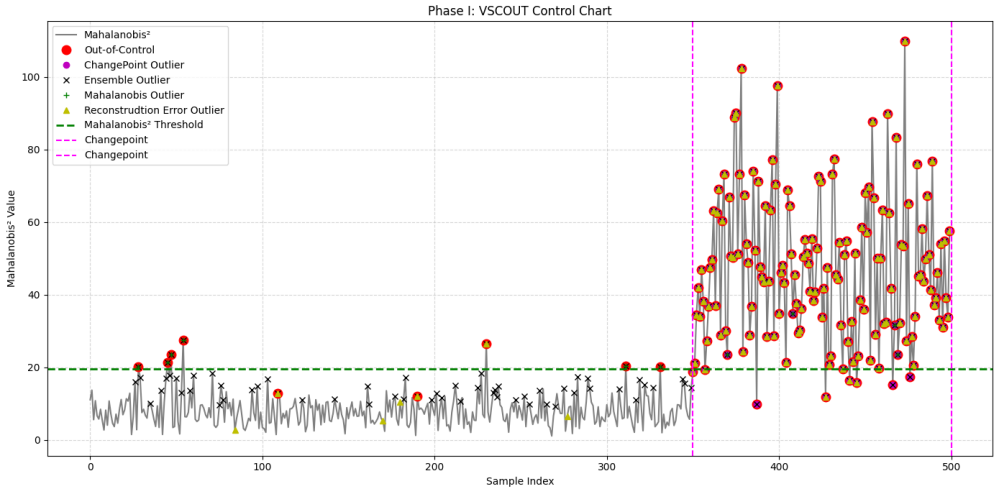

图8：VSCOUT控制图应用于瞬态过程偏移的示意图： $N(0, I) \rightarrow N(1.5, I)$，其中$n = 500$， $p = 150$。

我们进一步分析持续偏移下的性能，并报告低污染（$\gamma \in \{0.01, 0.03, 0.05\}$）和高污染（$\gamma \in \{0.10, 0.15, 0.20\}$）水平下的平均结果。在低污染条件下（表4），VSCOUT 名列表现最佳的方法之中，并在所有分布和维度下均保持稳定出色的 F1 分数。一项重要观察是，随着维度从 $p = 150$ 增至 $p = 250$，VSCOUT 的性能保持稳定，而若干基线方法（尤其是 Rank–Phase I 和变分自编码器）则随着 p 增加而出现明显退化。例如，在 $p = 250$ 维的 t 分布下，VSCOUT 的 F1分数提升至 0.5612，高于 $p = 150$ 维时的 0.5111，体现了其在重尾分布下稳健性的增强。即使在正常和混合设置中，某些经典方法表现不俗，VSCOUT 仍保持 0.54–0.66 的 F1 值，表明即便持续偏移仅影响一小部分数据，它依然能够可靠地进行检测。

VSCOUT在非高斯情形下尤其有效。在对数正态分布中——这一设定通常因偏度和乘性噪声而对经典的基于距离的检测器构成挑战——VSCOUT在两个维度上的F1 分数均高于0.86，假阳性率低于2.1%。相比之下，DF–Phase I的召回率经常骤降至接近于零，Rank–Phase I尽管召回率较高，但假阳性率偏高，而RMDP则因标记过于激进而精确率较低。Zamba–CP在某些正常设定下可保持完美的精确率和召回率，但在其他分布中几乎完全失效，在对数正态分布或混合情形下检测接近于零。在所有这些情形中，VSCOUT保持了均衡的精确率–召回率表现，体现了潜在空间细化、重构诊断和集成共识的优势。

在高污染水平下（表5），检测任务会变得更具挑战性。多种方法的性能急剧下降：孤立森林在所有分布中的假阳性率都接近 100%；随着γ 增加，Rank–Phase I 的检测能力减弱；而 DF–Phase I 无论维度或分布如何，整体上都难以奏效。变分自编码器的精确率尚可，但往往无法达到足够的召回率，尤其是在重尾或多模态情形下，其重构模型会变得不稳定。这些趋势在$p = 250$下的 t 分布和混合分布中最为明显，此时变分自编码器的召回率分别降至 0.2748 和 0.2802。
尽管面临这些挑战，VSCOUT 仍是表现最可靠的方法之一，整体 F1分数平均值位居第二（0.7483），且在所有分布中始终保持较强的精确率与召回率平衡。其稳健性在重尾或偏态情形下尤为明显。例如，在对数正态分布（$p = 250$）中，VSCOUT 的 F1分数达到 0.8920，召回率超过 0.97，假阳性率低于 3.4%，优于所有传统基线和深度学习基线。即使在困难的多模态场景中——许多竞争方法的精确率或召回率几乎降至零——VSCOUT 仍保持 F1分数分别为 0.5858（$p = 150$）和 0.6834（$p = 250$），体现了潜在空间细化和共识筛选带来的稳定效果。

尽管 Zamba–CP 的平均 F1 值最高，但在若干设置中看似完美的召回率，很大程度上是其在高污染情况下倾向于将几乎所有点都标记出来所造成的假象，从而人为抬高了性能指标，却无法转化为统计过程控制中的实际用途。相比之下，即使观测值的污染比例高达 20%，VSCOUT 仍能保持受控的假阳性率，同时维持较高的精确率和召回率，提供一种可解释且稳定的检测器。在严重污染情况下仍具备这种可靠性，凸显了 VSCOUT 对于具有挑战性的第一阶段环境的适用性：在不损害 I 类错误控制的前提下，识别细微和密集的过程偏移。

表4：平均性能 指标（低污染水平（$\gamma \in \{0.01, 0.03, 0.05\}$）下的持续均值偏移 .

分布	大小（n，p）	指标	DF-第一阶段	孤立森林	Rank-第一阶段	VAE	Zamba-CP	RMDP	VSCOUT
正常	(500, 150)	F1	0.0000	0.7813	0.6781	0.3271	1.0000	0.9976	0.6263
		FPR	0.0507	0.0052	0.0220	0.0412	0.0000	0.0000	0.0234
		精确率	0.0000	0.9496	0.5771	0.4385	1.0000	1.0000	0.7166
		召回率	0.0000	0.6815	0.9997	0.3159	1.0000	0.9954	0.6043
		运行时间（秒）	1.5930	0.0651	0.1011	2.0004	0.7706	3.7547	6.7510
正常	(500, 250)	F1	0.0000	0.7900	0.6785	0.3314	1.0000	0.7664	0.6616
		FPR	0.0506	0.0037	0.0220	0.0433	0.0000	0.0000	0.0230
		精确率	0.0000	0.9592	0.5774	0.4295	1.0000	0.7844	0.7375
		召回率	0.0000	0.6890	1.0000	0.3213	1.0000	0.7557	0.6450
		运行时间（秒）	2.6509	0.0726	0.1650	2.5298	1.8791	9.6796	8.9585
t (df=5)	(500, 150)	F1	0.0001	0.6954	0.5955	0.2832	1.0000	0.6420	0.5111
		FPR	0.0506	0.0151	0.0259	0.0428	0.0000	0.0144	0.0355
		精确率	0.0001	0.8458	0.5038	0.3846	1.0000	0.5694	0.5883
		召回率	0.0004	0.6034	0.8925	0.2573	1.0000	0.8133	0.4669
		运行时间（秒）	1.5500	0.0781	0.1012	4.4701	0.7583	3.7593	9.5587
t（自由度=5）	（500，250）	F1	0.0000	0.7141	0.6418	0.2972	1.0000	0.6182	0.5612
		FPR	0.0506	0.0122	0.0238	0.0430	0.0000	0.0025	0.0315
		精确率	0.0000	0.8679	0.5433	0.4010	1.0000	0.6958	0.6250
		召回率	0.0000	0.6269	0.9585	0.2785	1.0000	0.6291	0.5191
		运行时间（秒）	2.5783	0.0857	0.1663	3.6357	14.2300	9.6600	19.6590
对数正态分布	(500, 150)	F1	0.3821	0.8156	0.6755	0.6833	0.9998	0.2152	0.8612
		FPR	0.0352	0.0013	0.0222	0.0024	0.0000	0.2090	0.0206
		精确率	0.3046	0.9822	0.5745	0.9486	1.0000	0.1242	0.8444
		召回率	0.6593	0.7011	0.9970	0.5395	0.9996	1.0000	0.8820
		运行时间（秒）	1.5743	0.0614	0.1006	1.8531	0.7543	3.5918	6.6938
对数正态分布	(500, 250)	F1	0.3751	0.8163	0.6783	0.7008	1.0000	0.3411	0.8743
		FPR	0.0355	0.0011	0.0220	0.0011	0.0000	0.1052	0.0185
		精确率	0.2986	0.9823	0.5772	0.9578	1.0000	0.2140	0.8534
		召回率	0.6498	0.7011	0.9998	0.5584	1.0000	1.0000	0.8971
		运行时间（秒）	2.5494	0.0683	0.1636	2.2321	1.8665	12.4648	9.2487
混合	(500, 150)	F1	0.0003	0.6921	0.5700	0.2984	0.9998	0.4496	0.5198
		FPR	0.0507	0.0168	0.0271	0.0491	0.0000	0.0547	0.0445
		精确率	0.0003	0.8405	0.4823	0.3815	0.9996	0.3246	0.5754
		召回率	0.0003	0.5991	0.8542	0.2790	1.0000	0.9025	0.4961
		运行时间（秒）	1.5473	0.0778	0.1012	4.3396	0.7615	3.6740	9.5354
混合	(500, 250)	F1	0.0000	0.6999	0.5865	0.3134	1.0000	0.5388	0.5433
		FPR	0.0507	0.0157	0.0263	0.0506	0.0000	0.0124	0.0428
		精确率	0.0000	0.8517	0.4964	0.3962	1.0000	0.5036	0.5996
		召回率	0.0000	0.6134	0.8780	0.2984	1.0000	0.6975	0.5207
		运行时间（秒）	2.5986	0.0843	0.1653	3.5565	1.8623	9.5064	19.7125
多模态	(500, 150)	F1	0.6940	0.0000	0.0000	0.4951	0.0000	0.0000	0.4299
		FPR	0.0200	0.9780	0.0527	0.0305	0.0000	0.0000	0.2121
		精确率	0.5998	0.0000	0.0000	0.3820	0.0000	0.0000	0.3185
		召回率	0.9994	0.0001	0.0000	0.7834	0.0000	0.0000	0.9969
		运行时间（秒）	1.5706	0.0595	0.0971	1.7572	0.0000	0.0000	6.5569
多模态	(500, 250)	F1	0.6939	0.0000	0.0000	0.5172	0.0000	0.0000	0.3681
		FPR	0.0200	0.9780	0.0527	0.0306	0.0000	0.0000	0.2632
		精确率	0.5996	0.0000	0.0000	0.3990	0.0000	0.0000	0.2718
		召回率	0.9995	0.0000	0.0000	0.8038	0.0000	0.0000	0.9973
		运行时间（秒）	2.5843	0.0708	0.1582	3.3755	0.0000	0.0000	7.5624
F1平均值			0.2145	0.6005	0.5104	0.4233	0.8212	0.4569	0.5967
F1排名			(7)	(2)	(4)	(6)	(1)	(5)	(3)

仔细观察会发现，VSCOUT 的优势在所有分布族中均持续存在。例如，在 $p = 250$的对数正态分布设置下，VSCOUT 的 F1 = 0.8920，召回率为 = 0.9773，同时将假阳性率控制在 3.4% 以下。在混合分布和多峰分布中，密度呈碎片化，聚类结构会在污染作用下发生偏移；VSCOUT 的 F1 分数仍保持在 0.59 到 0.74 之间，而竞争方法往往会彻底失效（例如，在多峰数据中，Rank-第一阶段的 F1 = 0.0000）。在正态分布和 t 设置下，VSCOUT 同样优于大多数其他方法，即使在 $\gamma = 0.20$时也能提供稳定的精确率和召回率。

这些结果表明，VSCOUT不仅善于捕捉密集的持续性异常，而且在正常运行期间避免过度触发。在各种污染情形、维度和分布族中，VSCOUT始终位列前两名检测器之列，同时保持较低的误报率。其在非高斯和高维情形下的稳健性，加上均衡的精确率-召回率表现，使其在需要尽早且准确检测持续偏移时，成为现代过程监控中可靠而实用的工具。

表5：所有特征发生持续均值偏移时，高污染水平（$\gamma \in \{10, 15, 20\}$）下的平均性能指标。

分布	大小（n, p）	指标	DF-第一阶段	孤立森林	Rank-第一阶段	VAE	Zamba-CP	RMDP	VSCOUT
正常	(500, 150)	F1	0.0000	0.1779	0.5303	0.3263	1.0000	0.0026	0.7442
		FPR	0.0580	0.9995	0.0000	0.0389	0.0000	0.0000	0.0233
		精确率	0.0000	0.1044	1.0000	0.4364	1.0000	0.0511	0.7759
		召回率	0.0000	0.6342	0.3687	0.3102	1.0000	0.0013	0.7684
		运行时间（秒）	1.8085	0.0596	0.1304	2.0604	0.8145	3.4145	6.9730
正常	(500, 250)	F1	0.0000	0.1775	0.5303	0.3336	1.0000	0.0000	0.8298
		FPR	0.0580	0.9997	0.0000	0.0400	0.0000	0.0000	0.0243
		精确率	0.0000	0.1042	1.0000	0.4346	1.0000	0.0000	0.8145
		召回率	0.0000	0.6326	0.3687	0.3231	1.0000	0.0000	0.8778
		运行时间（秒）	3.0058	0.0669	0.2156	2.3620	1.9220	8.7846	9.2365
t (df=5)	(500, 150)	F1	0.0003	0.1834	0.4712	0.2821	1.0000	0.0210	0.6097
		FPR	0.0580	0.9960	0.0067	0.0402	0.0000	0.0009	0.0308
		精确率	0.0005	0.1076	0.8889	0.3960	1.0000	0.1589	0.6605
		召回率	0.0002	0.6565	0.3276	0.2560	1.0000	0.0120	0.6238
		运行时间（秒）	1.7692	0.0704	0.1307	4.5323	0.8028	3.4844	9.4876
t (自由度 =5)	(500, 250)	F1	0.0001	0.1820	0.4998	0.2970	1.0000	0.0014	0.7236
		FPR	0.0580	0.9969	0.0035	0.0406	0.0000	0.0001	0.0289
		精确率	0.0002	0.1068	0.9420	0.4088	1.0000	0.0344	0.7380
		召回率	0.0001	0.6504	0.3476	0.2748	1.0000	0.0007	0.7597
		运行时间（秒）	2.9442	0.0724	0.2168	3.6622	58.9700	8.8992	19.3802
对数正态分布	(500, 150)	F1	0.1121	0.1771	0.5302	0.6707	1.0000	0.6311	0.8843
		FPR	0.0455	1.0000	0.0000	0.0016	0.0000	0.1948	0.0337
		精确率	0.2156	0.1040	0.9999	0.9802	1.0000	0.4669	0.8238
		召回率	0.0774	0.6313	0.3686	0.5415	1.0000	1.0000	0.9631
		运行时间（秒）	1.7902	0.0609	0.1300	2.0136	0.7947	3.4577	7.0255
对数正态分布	(500, 250)	F1	0.1136	0.1771	0.5303	0.6851	1.0000	0.7338	0.8920
		FPR	0.0453	1.0000	0.0000	0.0009	0.0000	0.1213	0.0337
		精确率	0.2189	0.1040	1.0000	0.9890	1.0000	0.5828	0.8252
		召回率	0.0784	0.6313	0.3687	0.5592	1.0000	1.0000	0.9773
		运行时间（秒）	2.9106	0.0670	0.2143	2.3529	1.9055	10.2069	9.0301
混合	(500, 150)	F1	0.0003	0.1856	0.4635	0.2889	1.0000	0.0479	0.6274
		FPR	0.0580	0.9945	0.0074	0.0445	0.0000	0.0017	0.0415
		精确率	0.0005	0.1089	0.8757	0.3855	1.0000	0.1872	0.6343
		召回率	0.0002	0.6651	0.3221	0.2721	1.0000	0.0324	0.6656
		运行时间（秒）	1.7667	0.0763	0.1313	2.8813	0.8062	3.4276	11.2641
混合	(500, 250)	F1	0.0003	0.1836	0.4876	0.2921	1.0000	0.0030	0.7382
		FPR	0.0579	0.9958	0.0047	0.0467	0.0000	0.0001	0.0417
		精确率	0.0007	0.1077	0.9207	0.3817	1.0000	0.0559	0.7076
		召回率	0.0002	0.6575	0.3389	0.2802	1.0000	0.0016	0.8008
		运行时间（秒）	2.9991	0.0949	0.2139	3.6590	1.9094	9.5943	19.5682
多模态	(500, 150)	F1	0.5172	0.1969	0.0000	0.2292	0.0000	0.0000	0.5858
		FPR	0.0000	0.9862	0.0600	0.0298	0.0000	0.0000	0.3320
		精确率	1.0000	0.1158	0.0000	0.3505	0.0000	0.0000	0.4686
		召回率	0.3562	0.6918	0.0000	0.2022	0.0000	0.0000	0.9871
		运行时间（秒）	1.7875	0.0609	0.1257	2.1216	0.0000	0.0000	6.5844
多模态	(500, 250)	F1	0.5386	0.1956	0.0000	0.2343	0.0000	0.0000	0.6834
		FPR	0.0000	0.9873	0.0600	0.0301	0.0000	0.0000	0.3313
		精确率	1.0000	0.1152	0.0000	0.3652	0.0000	0.0000	0.5509
		召回率	0.3705	0.6873	0.0000	0.2031	0.0000	0.0000	0.9313
		运行时间（秒）	2.9922	0.0894	0.2165	3.0748	0.0000	0.0000	17.5843
F1平均值			0.1224	0.1834	0.5011	0.3962	0.8571	0.1801	0.7483
F1排名			(7)	(5)	(3)	(4)	(1)	(6)	(2)

在所有模拟的瞬态和持续偏移情景中，VSCOUT在竞争方法中提供了最为稳定的强劲性能，在保持较低误报率的同时取得了最高的总体F1 分数（表6–7）。其召回率在各情形中保持稳定（持续偏移约为0.75，瞬态偏移约为0.74），且精确率超过大多数替代方法，尤其是在中等和大幅度偏移下。相比之下，经典的Phase I 方法（DF-第一阶段、Rank-第一阶段）灵敏度有限，变分自编码器在不同分布上的性能不一致，孤立森林在持续污染下急剧恶化。Zamba-CP在持续偏移上表现完美，但对瞬态偏移几乎完全失效，凸显了其适用范围狭窄。按偏移幅度 δ分组时，所有模型都随偏移增大而改善，但VSCOUT在瞬态和持续两种设定下的F1分数和召回率增幅最为均匀。

表6：所有污染水平和分布下瞬态及持续过程偏移的总体平均性能指标。

方法	偏移类型	召回率	精确率	FPR	F1	运行时间（秒）
DF-第一阶段	瞬态	0.3065	0.2455	0.0429	0.1763	2.1533
DF-第一阶段	持续	0.3462	0.2483	0.0426	0.2135	2.1266
孤立森林	瞬态	0.8348	0.6837	0.0411	0.6448	0.0773
孤立森林	持续	0.6735	0.6344	0.5071	0.6234	0.0764
Rank-第一阶段	瞬态	0.6795	0.6973	0.0156	0.5607	0.1506
Rank-第一阶段	持续	0.6992	0.6981	0.0161	0.5712	0.1524
VAE	瞬态	0.6253	0.5065	0.0301	0.4598	2.9476
VAE	持续	0.4998	0.5715	0.0291	0.4516	2.8801
Zamba-CP	瞬态	0.0178	0.0753	0.0005	0.0054	1.5498
Zamba-CP	持续	1.0000	1.0000	0.0000	1.0000	6.0863
RMDP	瞬态	0.6214	0.4743	0.0420	0.4876	6.8241
RMDP	持续	0.5850	0.5113	0.0410	0.4796	7.0324
VSCOUT	瞬态	0.7455	0.6455	0.0311	0.6365	9.7082
VSCOUT	持续	0.7543	0.7273	0.0306	0.6725	10.5666

表7：性能 按偏移类型分组的指标 δ，针对瞬态和持续偏移，按分布取平均值，p，以及 γ .

方法	偏移类型	δ	召回率	精确率	FPR	F1	运行时间（秒）
DF-第一阶段	持续	1	0.0886	0.0863	0.0526	0.0747	2.1466
	持续	2	0.1415	0.1325	0.0524	0.1136	2.1471
	持续	3	0.1691	0.1610	0.0522	0.1378	2.1384
	瞬态	1	0.1779	0.1448	0.0435	0.1257	1.9442
	瞬态	2	0.3541	0.2818	0.0427	0.2104	2.1585
	瞬态	3	0.3874	0.3099	0.0426	0.2285	2.3571
孤立森林	持续	1	0.4497	0.5283	0.0537	0.4851	0.0772
	持续	2	0.5841	0.5796	0.0535	0.5694	0.0759
	持续	3	0.6744	0.6025	0.0535	0.6083	0.0758
	瞬态	1	0.8122	0.6385	0.0487	0.6074	0.0776
	瞬态	2	0.8354	0.6397	0.0487	0.6133	0.0768
	瞬态	3	0.8369	0.6425	0.0487	0.6167	0.0759
Rank-第一阶段	持续	1	0.5362	0.6483	0.0163	0.4868	0.1492
	持续	2	0.7093	0.7077	0.0163	0.5804	0.1493
	持续	3	0.8159	0.7350	0.0163	0.6146	0.1491
	瞬态	1	0.5516	0.6552	0.0195	0.5303	0.1558
	瞬态	2	0.6865	0.7107	0.0195	0.6088	0.1554
	瞬态	3	0.7262	0.7468	0.0194	0.6759	0.1549
RMDP	持续	1	0.5367	0.5056	0.0415	0.4682	7.0371
	持续	2	0.5901	0.5109	0.0415	0.4950	7.0427
	持续	3	0.6282	0.5165	0.0415	0.5158	7.0232
	瞬态	1	0.4496	0.4206	0.0415	0.4452	6.5492
	瞬态	2	0.5619	0.4502	0.0415	0.4784	6.5517
	瞬态	3	0.6088	0.4582	0.0415	0.4924	6.5538
VAE	持续	1	0.2829	0.4485	0.0366	0.3396	3.9392
	持续	2	0.4704	0.5312	0.0366	0.4458	3.9351
	持续	3	0.5663	0.5760	0.0365	0.4487	3.9300
	瞬态	1	0.5284	0.4716	0.0336	0.4363	3.8693
	瞬态	2	0.6888	0.5529	0.0337	0.5262	3.8692
	瞬态	3	0.7223	0.5830	0.0337	0.5529	3.8656
VSCOUT	持续	1	0.7067	0.7051	0.0306	0.6385	10.5135
	持续	2	0.7818	0.7350	0.0306	0.6806	10.4907
	持续	3	0.7880	0.7423	0.0306	0.6963	10.4886
	瞬态	1	0.7032	0.6133	0.0308	0.6130	9.9238
	瞬态	2	0.7817	0.6477	0.0308	0.6453	9.9242
	瞬态	3	0.7898	0.6546	0.0308	0.6515	9.9223
Zamba-CP	持续	1	0.9995	0.9996	0.0001	0.9996	5.9222
	持续	2	0.9995	0.9996	0.0001	0.9996	6.0142
	持续	3	0.9996	0.9996	0.0001	0.9997	6.1021
	瞬态	1	0.0076	0.0381	0.0006	0.0028	1.6372
	瞬态	2	0.0185	0.0743	0.0007	0.0053	1.6373
	瞬态	3	0.0259	0.0967	0.0007	0.0066	1.6374

4.2 在基准异常检测高维数据中的应用

我们通过将 VSCOUT 应用于异常检测文献中广泛使用的一组基准数据集以及一个高维半导体传感器数据集，展示其实际表现。这些示例不仅旨在评估预测性能，还旨在突出 VSCOUT 在实践中常见的异构数据几何结构、维度和异常结构下的表现。

这些基准数据集涵盖了广泛的样本量和维度，包括低维表格数据、中等维度的生物医学数据集以及高维图像衍生特征。根据文献中的标准实践，竞争方法均采用默认超参数设置进行实现，以便对开箱即用的性能进行中立比较。基准方法包括孤立森林（IForest）、局部离群因子（LOF）、ECOD、 k近邻（KNN）、HBOS、基线变分自编码器（VAE）以及 SUOD 集成框架 [Zhao 等人， 2021]。

表 8 汇总了每个数据集 50 次独立重复实验的平均性能，括号内报告的是蒙特卡罗标准差。这些数据集的一个显著特点是 VSCOUT 始终表现出较强的灵敏度。在大多数基准数据集上——包括心律失常、心血管、玻璃、电离层和 MNIST——VSCOUT 的召回率最高或接近最高，表明即使在异质或高维场景中，也能可靠地识别异常观测。在漏检会造成重大运营或安全成本的应用中，这一表现尤为重要。

在麝香和 pendigits 等更具挑战性的数据集上，VSCOUT 仍展现出较强的检测能力，尽管基于树的方法或基于直方图的方法偶尔能取得更高的召回率或 AUROC。相比之下，在 optdigits 等异常与正常数据分离较弱、且与潜在重构结构关联较小的数据集上，VSCOUT 的性能有所下降，反映出其建模假设的局限性。这些结果强调，VSCOUT 在异常表现为偏离主导潜在模式的结构性变化，而非弥散噪声时最为有效。

尽管侧重于灵敏度，VSCOUT 在大多数数据集上仍保持着有竞争力的精确率和假阳性率。尤其是在电离层和 MNIST 等中高维基准数据集上，VSCOUT 能够同时实现较高的召回率和精确率，其 AUROC 值与其他方法相当，甚至更高。与异常分数往往因数据集而显著波动的传统基于变分自编码器的检测器不同，VSCOUT 的性能相对稳定。这种稳定性可归因于其基于ARD的潜在压缩：该机制削弱了无关或信息量较低的维度的影响，避免它们主导异常分数。

另一个值得注意的现象是，尽管 SUOD 明确集成了多个检测器，VSCOUT 的性能仍经常与其相当，甚至更胜一筹。这表明，VSCOUT 将重构误差、潜在空间偏差和自适应相关性加权相结合的混合结构，捕捉到了经典集成方法未能充分利用的互补信息。在各个数据集上，内点保留率通常维持在 90% 或以上，这说明灵敏度的提升并非源于不加区分地将正常观测值标记为异常。
为总结整体趋势，表9报告了所有基准数据集上的平均性能。VSCOUT的召回率排名第一，AUROC排名第三，这体现了其设计侧重于捕获真实异常，同时保持具有竞争力的整体判别能力。相比之下，孤立森林和ECOD等方法通过平衡灵敏度与特异度取得最高AUROC，但代价是召回率显著较低。基线变分自编码器的精确率和假阳性率表现良好，却未能检测出很大一部分真实异常。这些结果凸显了异常检测中固有的权衡，并表明VSCOUT适用于将检测灵敏度和稳健性作为首要目标的应用场景。

最后，我们将VSCOUT应用于一个高维半导体传感器数据集（表10），该数据集代表了现代工业监测环境。在这一场景下，所有方法的AUROC均不高，反映出任务的难度和极高维度。与经典多元控制图和现代异常检测器相比，VSCOUT的召回率具有竞争力，同时保持了合理的内点保留率。值得注意的是，VSCOUT中的其他决策规则能够明确控制灵敏度-特异度权衡，使从业者可以根据特定领域的风险偏好调整检测器。

综上，这些应用表明，VSCOUT 为各种真实数据集和基准数据集提供了一个稳健且可解释的异常检测框架。VSCOUT 并非在所有指标上都全面占优，而是展现出稳定且可预测的性能特征，因此适用于高维、异构环境下的回顾性监测任务。

Tabl表 8：基准离群点检测数据集上的比较（括号内为标准差）).

数据集	大小（n, p）	模型	召回率	精确率	FPR	内点保留率	AUROC
心律失常	(452, 274)	VSCOUT	0.3494 (0.07)	0.3976 (0.04)	0.0906 (0.02)	0.9094 (0.02)	0.7756 (0.03)
		VAE	0.2385 (0.03)	0.5454 (0.04)	0.0339 (0.00)	0.9661 (0.00)	0.7564 (0.01)
		孤立森林	0.2161 (0.01)	0.6200 (0.04)	0.0226 (0.00)	0.9774 (0.00)	0.8026 (0.01)
		LOF	0.1061 (0.00)	0.3333 (0.00)	0.0363 (0.00)	0.9637 (0.00)	0.7597 (0.00)
		ECOD	0.2273 (0.00)	0.6522 (0.00)	0.0207 (0.00)	0.9793 (0.00)	0.8052 (0.00)
		KNN	0.1667 (0.00)	0.5000 (0.00)	0.0285 (0.00)	0.9715 (0.00)	0.7684 (0.00)
		SUOD	0.1912 (0.01)	0.6111 (0.03)	0.0209 (0.00)	0.9791 (0.00)	0.7950 (0.00)
心血管	(1831, 21)	VSCOUT	0.5068 (0.21)	0.4597 (0.08)	0.0602 (0.01)	0.9398 (0.01)	0.9251 (0.04)
		VAE	0.3007 (0.05)	0.4776 (0.06)	0.0348 (0.00)	0.9652 (0.00)	0.7283 (0.05)
		孤立森林	0.3090 (0.02)	0.5912 (0.04)	0.0227 (0.00)	0.9773 (0.00)	0.9247 (0.01)
		LOF	0.0852 (0.00)	0.1974 (0.00)	0.0369 (0.00)	0.9631 (0.00)	0.5458 (0.00)
		ECOD	0.2955 (0.00)	0.5652 (0.00)	0.0242 (0.00)	0.9758 (0.00)	0.9350 (0.00)
		KNN	0.2045 (0.00)	0.4800 (0.00)	0.0236 (0.00)	0.9764 (0.00)	0.6861 (0.00)
		SUOD	0.2523 (0.02)	0.5128 (0.03)	0.0255 (0.00)	0.9745 (0.00)	0.9019 (0.01)
玻璃	(214, 9)	VSCOUT	0.2600 (0.10)	0.0808 (0.03)	0.1295 (0.03)	0.8705 (0.03)	0.7235 (0.05)
		VAE	0.1222 (0.03)	0.0801 (0.02)	0.0625 (0.01)	0.9375 (0.01)	0.6861 (0.06)
		孤立森林	0.1111 (0.00)	0.0909 (0.00)	0.0488 (0.00)	0.9512 (0.00)	0.7001 (0.02)
		LOF	0.1111 (0.00)	0.1000 (0.00)	0.0439 (0.00)	0.9561 (0.00)	0.8347 (0.00)
		ECOD	0.1111 (0.00)	0.0909 (0.00)	0.0488 (0.00)	0.9512 (0.00)	0.6206 (0.00)
		KNN	0.1111 (0.00)	0.1000 (0.00)	0.0439 (0.00)	0.9561 (0.00)	0.8325 (0.00)
		SUOD	0.1156 (0.03)	0.0998 (0.03)	0.0460 (0.01)	0.9540 (0.01)	0.7013 (0.03)
电离层	(351, 34)	VSCOUT	0.4983 (0.06)	0.9575 (0.02)	0.0124 (0.01)	0.9876 (0.01)	0.8832 (0.03)
		VAE	0.0941 (0.01)	0.7432 (0.15)	0.0206 (0.02)	0.9794 (0.02)	0.7359 (0.03)
		孤立森林	0.1429 (0.00)	1.0000 (0.00)	0.0000 (0.00)	1.0000 (0.00)	0.8540 (0.01)
		LOF	0.1190 (0.00)	1.0000 (0.00)	0.0000 (0.00)	1.0000 (0.00)	0.8939 (0.00)
		ECOD	0.1270 (0.00)	0.8889 (0.00)	0.0089 (0.00)	0.9911 (0.00)	0.7353 (0.00)
		KNN	0.1190 (0.00)	1.0000 (0.00)	0.0000 (0.00)	1.0000 (0.00)	0.9337 (0.00)
		SUOD	0.0933 (0.02)	1.0000 (0.00)	0.0000 (0.00)	1.0000 (0.00)	0.8795 (0.01)
信件	(1600, 32)	VSCOUT	0.1658 (0.10)	0.1860 (0.03)	0.0561 (0.09)	0.9439 (0.09)	0.6671 (0.02)
		VAE	0.1470 (0.03)	0.3230 (0.06)	0.0208 (0.00)	0.9792 (0.00)	0.6199 (0.06)
		孤立森林	0.0642 (0.02)	0.0803 (0.02)	0.0491 (0.00)	0.9509 (0.00)	0.6273 (0.02)
		LOF	0.3300 (0.00)	0.5410（0.00）	0.0187（0.00）	0.9813（0.00）	0.8988（0.00）
		ECOD	0.0600（0.00）	0.0750（0.00）	0.0493（0.00）	0.9507（0.00）	0.5723（0.00）
		KNN	0.2900（0.00）	0.4143（0.00）	0.0273（0.00）	0.9727 (0.00)	0.9012 (0.00)
		SUOD	0.1182 (0.02)	0.1757 (0.02)	0.0370 (0.00)	0.9630 (0.00)	0.7457 (0.01)
淋巴造影	(148, 18)	VSCOUT	0.8000 (0.12)	0.3559 (0.06)	0.0624 (0.01)	0.9376 (0.01)	0.9567 (0.03)
		VAE	0.7933 (0.08)	0.4425 (0.06)	0.0431 (0.01)	0.9569 (0.01)	0.9112 (0.04)
		孤立森林	0.9233 (0.08)	0.6925 (0.06)	0.0173 (0.00)	0.9827 (0.00)	0.9970 (0.00)
		LOF	0.6667 (0.00)	0.6667 (0.00)	0.0141 (0.00)	0.9859 (0.00)	0.9683 (0.00)
		ECOD	1.0000 (0.00)	0.7500 (0.00)	0.0141 (0.00)	0.9859 (0.00)	0.9965 (0.00)
		KNN	0.6667 (0.00)	0.8000 (0.00)	0.0070 (0.00)	0.9930 (0.00)	0.9484 (0.00)
		SUOD	0.8167 (0.06)	0.7143 (0.08)	0.0144 (0.01)	0.9856 (0.01)	0.9907 (0.00)
MNIST	(7603, 100)	VSCOUT	0.6723 (0.03)	0.7420 (0.07)	0.0245 (0.01)	0.9755 (0.01)	0.8568 (0.01)
		VAE	0.2406（0.01）	0.4956（0.03）	0.0250（0.00）	0.9750（0.00）	0.8506（0.02）
		孤立森林	0.1809 (0.01)	0.3323 (0.01)	0.0369 (0.00)	0.9631 (0.00)	0.8005 (0.01)
		LOF	0.1886 (0.00)	0.4000 (0.00)	0.0287 (0.00)	0.9713 (0.00)	0.6728 (0.00)
		ECOD	0.0871 (0.00)	0.1601 (0.00)	0.0464 (0.00)	0.9536 (0.00)	0.7463 (0.00)
		KNN	0.2414 (0.00)	0.5121 (0.00)	0.0233 (0.00)	0.9767 (0.00)	0.8368 (0.00)
		SUOD	0.1974 (0.01)	0.3767 (0.02)	0.0331 (0.00)	0.9669 (0.00)	0.8193 (0.01)
musk	(3062, 166)	VSCOUT	0.8557 (0.01)	0.2325 (0.09)	0.0924 (0.01)	0.9076 (0.01)	0.8816 (0.01)
		VAE	0.4711 (0.19)	0.4085 (0.09)	0.0211 (0.00)	0.9789 (0.00)	0.9881 (0.01)
		孤立森林	0.9732 (0.06)	0.6130 (0.04)	0.0201 (0.00)	0.9799 (0.00)	0.9979 (0.00)
		LOF	0.3093 (0.00)	0.2256 (0.00)	0.0347 (0.00)	0.9653 (0.00)	0.6357 (0.00)
		ECOD	0.5567 (0.00)	0.3506 (0.00)	0.0337 (0.00)	0.9663 (0.00)	0.9559 (0.00)
		KNN	0.1856 (0.00)	0.2000 (0.00)	0.0243 (0.00)	0.9757 (0.00)	0.6157 (0.00)
		SUOD	0.6412 (0.05)	0.4682 (0.04)	0.0239 (0.00)	0.9761 (0.00)	0.9730 (0.00)
光学数字	(5216, 64)	VSCOUT	0.0147 (0.02)	0.0064 (0.01)	0.0664 (0.01)	0.9336 (0.01)	0.6579 (0.01)
		VAE	0.0027 (0.01)	0.0018 (0.00)	0.0530 (0.01)	0.9470 (0.01)	0.4975 (0.22)
		孤立森林	0.0507 (0.01)	0.0291 (0.01)	0.0499 (0.00)	0.9501 (0.00)	0.7080 (0.03)
		LOF	0.0667 (0.00)	0.0439 (0.00)	0.0430（0.00）	0.9570（0.00）	0.5372（0.00）
		ECOD	0.0200（0.00）	0.0115（0.00）	0.0509（0.00）	0.9491（0.00）	0.6045（0.00）
		KNN	0.0067（0.00）	0.0045（0.00）	0.0438（0.00）	0.9562（0.00）	0.3948 (0.00)
		SUOD	0.0173 (0.01)	0.0103 (0.01)	0.0486 (0.00)	0.9514 (0.00)	0.6343 (0.02)
pendigits	(6870, 16)	VSCOUT	0.4282 (0.10)	0.1460 (0.03)	0.0581 (0.01)	0.9419 (0.01)	0.6851 (0.05)
		VAE	0.1885 (0.08)	0.1046 (0.04)	0.0379 (0.00)	0.9621 (0.00)	0.7958 (0.05)
		孤立森林	0.5115 (0.06)	0.2320 (0.03)	0.0394 (0.00)	0.9606 (0.00)	0.9497 (0.01)
		LOF	0.1090 (0.00)	0.0578 (0.00)	0.0413 (0.00)	0.9587 (0.00)	0.4991 (0.00)
		ECOD	0.5064 (0.00)	0.2297 (0.00)	0.0395 (0.00)	0.9605 (0.00)	0.9274 (0.00)
		KNN	0.1410 (0.00)	0.0812 (0.00)	0.0371 (0.00)	0.9629 (0.00)	0.7430 (0.00)
		SUOD	0.3436 (0.03)	0.1861 (0.02)	0.0350 (0.00)	0.9650 (0.00)	0.9037 (0.01)

为总结整体趋势，表9报告了所有数据集上的平均指标（每个数据集进行了50次独立重复实验）。VSCOUT的排名如下：召回率排名第一，AUROC排名第三，精确率和假阳性率处于中游。VSCOUT优先捕获真实异常，其召回率显著高于经典变分自编码器；后者的精确率和假阳性率表现良好，但在实际识别异常方面表现不佳。与此同时，孤立森林和ECOD通过平衡灵敏度与特异度取得最高的AUROC，但其召回率通常低于VSCOUT。

表9：所有基准数据集上的平均性能指标。上标表示排名（1 = 最佳）。

模型	召回率	精确率	FPR	AUROC
VSCOUT	**0.4545**$^{(1)}$	0.3590$^{(6)}$	0.0647$^{(7)}$	0.7924$^{(3)}$
孤立森林	0.3483$^{(2)}$	**0.4281**$^{(1)}$	0.0307$^{(4)}$	**0.8362**$^{(1)}$
ECOD	0.2991$^{(3)}$	0.3774$^{(4)}$	0.0337$^{(5)}$	0.7899$^{(4)}$
SUOD	0.2787$^{(4)}$	0.4155$^{(2)}$	0.0284$^{(2)}$	0.8344$^{(2)}$
VAE	0.2599$^{(5)}$	0.3622$^{(5)}$	0.0353$^{(6)}$	0.7570$^{(6)}$
KNN	0.2133$^{(6)}$	0.4092$^{(3)}$	**0.0259**$^{(1)}$	0.7661$^{(5)}$
LOF	0.2092$^{(7)}$	0.3566$^{(7)}$	0.0298$^{(3)}$	0.7246$^{(7)}$

我们进一步在半导体制造过程（SECOM）数据集上评估 VSCOUT。该数据集是工业环境中广泛研究的异常检测高维基准数据集，包含从半导体制造工艺中采集的 $n = 1567$ 个观测值，每个观测值由 $p = 590$ 个传感器测量值构成。与真实制造环境中的典型情况一样，这些数据具有高维、噪声大和相关结构复杂等特点，使得可靠的异常检测尤具挑战性。该数据集提供了真实标签，因此可以对检测性能进行定量评估。

我们首先考虑回顾性第一阶段设置，在这种设置中，同时分析所有观测值，目标是在保留稳定受控基线的同时识别可能异常的运行批次。表10（每个数据集经过50次独立重复实验后的平均性能）将 VSCOUT 与一系列无监督离群点检测方法进行了比较，包括变分自编码器、孤立森林、局部离群因子、ECOD、K近邻和 SUOD 集成。在此设置下，VSCOUT 的召回率最高（0.1519），优于所有其他方法，表明它在这个污染程度高且异质性强的数据集中，对异常观测值具有更高的灵敏度。灵敏度的提升伴随着假阳性率的适度增加（FPR = 0.1050），但 VSCOUT 仍保留了近90%的内点，体现了异常移除与基线保留之间的合理平衡。

相比之下，VAE、KNN 和 SUOD 等方法具有较高的精确率和较低的假阳性率，但代价是召回率下降，这表明其检测策略更为保守，可能会漏掉相当一部分真实异常。经典的基于密度和基于距离的方法（LOF、ECOD、孤立森林）表现出类似特征，召回率有限，AUROC 值集中在 0.55 附近。总的来说，这些结果表明，尽管 SECOM 对无监督第一阶段检测而言仍是一个难处理的数据集，但即使传感器噪声和高维性掩盖了正常与异常观测值之间的明显区分，VSCOUT 仍能更有效地揭示数据中的异常结构。

表10：半导体传感器数据集对比（括号内为标准差）。

数据集	大小 (n, p)	模型	召回率	精确率	FPR	内点保留率	AUROC
半导体	(1567, 590)	VSCOUT	0.1519 (0.05)	0.0918 (0.02)	0.1050 (0.01)	0.8950 (0.01)	0.5155 (0.03)
		VAE	0.1173 (0.01)	0.1556 (0.01)	0.0452 (0.00)	0.9548 (0.00)	0.5548 (0.00)
		孤立森林	0.1038 (0.01)	0.1367 (0.01)	0.0466 (0.00)	0.9534 (0.00)	0.5299 (0.03)
		LOF	0.0962 (0.00)	0.1333 (0.00)	0.0444 (0.00)	0.9556 (0.00)	0.5440 (0.00)
		ECOD	0.0865 (0.00)	0.1139 (0.00)	0.0478 (0.00)	0.9522 (0.00)	0.5591 (0.00)
		KNN	0.1154 (0.00)	0.1600 (0.00)	0.0431 (0.00)	0.9569 (0.00)	0.5563 (0.00)
		SUOD	0.1096 (0.00)	0.1567 (0.01)	0.0420 (0.00)	0.9580 (0.00)	0.5683 (0.00)

接下来，我们将更仔细地考察一个更贴近过程控制实践的第二阶段监控场景。在该实验中，前500个观测值被视为第一阶段数据，用于构建受控参考基准，其余观测值则按顺序进行监控。表11（每个数据集50次独立重复实验的平均性能）比较了 VSCOUT 与经典第二阶段控制图（Hotelling's T^2、多元指数加权移动平均）、单类支持向量机和孤立森林。经典多元控制图的召回率达到完美水平，但精确率极低，几乎将所有观测值都标记为失控，且几乎未能保留任何内点。这种表现反映了它们对偏离高斯假设的情况较为敏感，并且在高维、非平稳环境中缺乏稳健性。

在其余方法中，VSCOUT 的精确率最高（0.0968），召回率与单类支持向量机持平（0.2000），并高于孤立森林。值得注意的是，VSCOUT 的假阳性率低于单类支持向量机，并保留了超过91%的受控观测值，因此监控结果更易于解读，也更具可操作性。尽管所依赖的分布假设更少，其 AUROC（0.5741）仍与孤立森林相当，仅略低于单类支持向量机。

综合来看，这些结果表明，VSCOUT 为高维工业数据的回顾性监测和在线监测提供了一种稳健且灵活的方法。尽管没有任何方法能在 SECOM 上实现良好的区分效果——这反映了该数据集本身的难度——VSCOUT 始终倾向于实现均衡检测，既避免了经典控制图病态的过度标记问题，又比标准无监督基线方法具有更高的异常灵敏度。这种平衡使 VSCOUT 特别适合部署于复杂的制造业环境，在这些环境中，误报和漏检都会造成重大的运营成本。

表11：半导体传感器数据比较（括号内为标准差）。

数据集	大小（n，p）	模型	召回率	精确率	FPR	内点保留率	AUROC
半导体传感器数据	(1567, 590)	霍特林T^2	1.0000	0.0422	0.9990	0.0010	0.5005
		多元指数加权移动平均	1.0000	0.0422	1.0000	0.0000	0.5000
		单类支持向量机	0.2000	0.0687	0.1194	0.8806	0.5857
		孤立森林	0.1111	0.0521	0.0890	0.9110	0.5906
		VSCOUT	0.2000	0.0968	0.0822	0.9178	0.5741

5 结论

本文介绍了 VSCOUT，这是一种用于回顾性（第一阶段）统计过程控制的混合框架，旨在应对高维、非高斯且易受污染的过程数据所带来的挑战。VSCOUT 将自动相关性确定融入变分自编码器，并结合基于集成的潜变量滤波、重构诊断和变点分析，提供了一种有理论依据且无分布假设的方法，可在构建稳定的受控（IC）基线的同时识别特殊原因结构。该框架明确针对第一阶段的目标：剔除受污染观测、减轻掩蔽效应，并生成可靠的参考集，用于后续监控。

大量模拟研究表明，在分布、维度、污染水平和偏移情景各异的情况下，VSCOUT 均能在灵敏度与误报控制之间实现出色且稳定的平衡。在无离群值的情况下，VSCOUT 能维持接近标称水平的第一类错误率；在瞬态和持续偏移情景下，其总体 F1 分数均名列前茅，且精确率和召回率稳定。与在重尾或多峰性情况下性能下降的经典第一阶段方法不同，也不同于在污染情况下会出现潜在失真的独立深度生成模型，VSCOUT 凭借两阶段精炼策略保持稳健。临时过滤与热启动 ARD-VAE 重新训练相结合，能够生成纯化后的潜在空间，更准确地反映真实的受控变异。

在各类基准异常检测数据集中，VSCOUT 的召回率始终排名第一，且 AUROC 表现仍具竞争力，表明它能够可靠地检测结构化异常，而不会不加区分地将正常观测值标记为异常。应用于高维工业数据（包括半导体传感器测量值）的结果进一步凸显了 VSCOUT 的实用价值：与经典和现代基线方法相比，它能更有效地揭示异常结构，同时保留比例合理、可辩护的内点。重要的是，最终采用的 4 项中取 2 项的共识规则汇总了变点、集成、潜在距离和重构信号，降低了对任何单一诊断方法的依赖，并得出适用于回顾性分析、可解释且稳定的决策。

总体而言，VSCOUT 为人工智能赋能环境中的现代第一阶段 SPC 提供了一种灵活且可扩展的解决方案。在这类环境中，高维性、复杂依赖关系和未知污染是常态，而非例外。其自适应潜在压缩、考虑污染的重新训练以及多信号决策结构，使其特别适合寻求在不依赖强参数假设的情况下构建可靠基线的从业者。未来的工作可以将 VSCOUT 扩展至完全在线的第二阶段监控，纳入时序或基于注意力机制的潜在结构，并为潜在相关性和异常判定开发正式的不确定性量化方法。

利益披露

作者声明，他们不存在任何利益冲突。

数据可用性声明

本研究结果所依据的数据要么是模拟数据，要么取自异常检测和机器学习文献中常用的公开基准数据集。这些数据集可从其原始公共资料库获取，包括 UCI机器学习资料库及相关开放基准数据源。本研究未使用任何专有或受限数据。VSCOUT 的开源实现，以及重现所报告结果所需的所有模拟脚本和实验配置，均可通过 https://github.com/martinwg/VSCOUT.git 公开获取。

资助

本研究未获得任何经费支持。

参考文献

Marco S Reis 和 Geert Gins. 大数据/工业4.0时代的工业过程监控：从检测到诊断，再到预后。*Processes*, 5(3):35, 2017年。Douglas C Montgomery. 统计质量控制导论。John wiley & sons, 2020a。Lucas Schmidt Goecks, Anderson Felipe Habekost, Antonio Maria Coruzzolo, 和 Miguel Afonso Sellitto. 工业4.0与制造业中的智能系统：智能统计过程控制实施指南。*AppliedSystemInnovation*, 7(2):24, 2024年。Harold Hotelling等人。学生比率的推广。1931年。George C Ranger 和 Frank B Alt. 为多变量统计过程控制选择主成分。统计学通讯——理论与方法, 25(5):909–922, 1996年。Christina M Mastrangelo, George C Runger, 和 Douglas C Montgomery. 基于主成分的统计过程监控。国际质量与可靠性工程, 12(3):203–210, 1996年。Ruixiang Sun 和 Fugee Tsung. 一种采用支持向量方法的基于核距离的多变量控制图。国际生产研究杂志, 41(13):2975–2989, 2003年。Fatih Camci, Ratna B Chinnam, 和 Richard D Ellis. 基于支持向量原理的鲁棒核距离多变量控制图。国际生产研究杂志, 46(18):5075–5095, 2008年。Diederik P Kingma 和 Max Welling. 自编码变分贝叶斯。*arXiv*预印本 *arXiv:1312.6114*, 2013年。Lukas Ruff, Jacob R Kauffmann, Robert A Vandermeulen, Grégoire Montavon, Wojciech Samek, Marius Kloft, Thomas G Dietterich, 和 Klaus-Robert Müller. 深层与浅层异常检测的统一综述。*IEEE*会刊, 109(5):756–795, 2021年。William H Woodall 和 Douglas C Montgomery. 统计过程控制中的研究议题与思路。质量技术杂志, 31(4):376–386, 1999年。Douglas C Montgomery. 统计质量控制导论。John Wiley & Sons, 2020b。Yuxiang Hou, Baotong He, Xin Zhang, Ying Chen, 和 Qiang Yang. 一种用于自启动过程均值监控的新贝叶斯方案。质量技术与定量管理, 17(6):661–684, 2020年。Konstantinos Bourazas, Dimitrios Kiagias, 和 Panagiotis Tsiamyrtzis. 预测控制图（PCC）：一种用于短批次在线监测的贝叶斯方法。质量技术杂志, 54(4):367–391, 2022年。Peihua Qiu. 统计过程控制的机器学习方法。*Wiley StatsRef*：统计学参考在线, 页码 1–8, 2017年。Douglas M Hawkins, Peihua Qiu, 和 Chang Wook Kang. 用于统计过程控制的变点模型。质量技术杂志, 35(4):355–366, 2003年。KD Zamba 和 Douglas M Hawkins. 一种用于统计过程控制的多变量变点模型。*Technometrics*, 48(4):539–549, 2006年。Peihua Qiu. 统计过程控制导论。CRC出版社, 2013年。

Nan Chen, Xuemin Zi, 和 Changliang Zou. 一种无分布假设的多变量控制图。*Technometrics*, 58(4): 448–459, 2016年。Giovanna Capizzi 和 Guido Masarotto. 多元数据的第一阶段无分布分析。*Technometrics*, 59(4): 484–495, 2017年。Varun Chandola, Arindam Banerjee, 和 Vipin Kumar. 异常检测：综述。*ACM*计算调查（*CSUR*）, 41(3):1–58, 2009年。Victoria Hodge 和 Jim Austin. 离群点检测方法综述。*Artificial intelligence review*, 22(2): 85–126, 2004年。Sridhar Ramaswamy, Rajeev Rastogi, 和 Kyuseok Shim. 从大型数据集中挖掘离群点的高效算法。载于*2000*年*ACM SIGMOD*数据管理国际会议论文集, 页码 427–438, 2000年。Markus M Breunig, Hans-Peter Kriegel, Raymond T Ng, 和 Jörg Sander. 局部离群因子：识别基于密度的局部离群点。载于*2000*年*ACM SIGMOD*数据管理国际会议论文集, 页码 93–104。ACM, 2000年。Fei Tony Liu, Kai Ming Ting, 和 Zhi-Hua Zhou. 孤立森林。载于*2008*年第八届*IEEE*国际数据挖掘会议, 页码 413–422。IEEE, 2008年。Yue Zhao Li, Zheng Li, Shubham Singh, Chen Hu, Andy Barnett, Charu Aggarwal, 和 Deepak Turaga. ECOD：利用经验累积分布函数进行无监督离群点检测。*Neurocomputing*, 481:389–400, 2022年。Sang H. Lee, Jae H. Lee, 和 Hyo J. Yoon. 一种采用Huber支持向量回归监测条件异方差时间序列的鲁棒控制图。*PLOS ONE*, 19(3):e0299120, 2024年。Shun-Ichi Amari. 反向传播与随机梯度下降方法。*Neurocomputing*, 5(4-5):185–196, 1993年。Diederik P. Kingma 和 Jimmy Ba. Adam：一种随机优化方法， 2014年。Shuyu Lin, Stephen Roberts, Niki Trigoni, 和 Ronald Clark. 平衡变分自动编码器证据下界中的重构质量与正则化。*arXiv*预印本 *arXiv:1909.03765*, 2019年。Haleh Akrami, Anand A. Joshi, Jian Li, Sergul Aydore, 和 Richard M. Leahy. 鲁棒变分自动编码器。*arXiv*预印本 *arXiv:1905.09961*, 2019年。Tian Li, Ronak Mehta, Zhaozhi Qian, 和 Jimeng Sun. 重新思考自编码器：鲁棒流形学习。载于*ICML*深度学习不确定性与鲁棒性研讨会, 第2卷, 2020年。Surojit Saha, Sarang Joshi, 和 Ross Whitaker. ARD-VAE：一种用于找出变分自编码器相关潜在维度的统计表述。载于*2025*年*IEEE/CVF*冬季计算机视觉应用会议（*WACV*）, 页码 889–898。IEEE, 2025年。Fabrizio Angiulli 和 Clara Pizzuti. 高维空间中的快速离群点检测。载于欧洲数据挖掘与知识发现原理会议, 页码 15–27。Springer, 2002 年。Markus Goldstein 和 Andreas Dengel. 基于直方图的离群点分数（HBOS）：一种快速无监督异常检测算法。*KI-2012*：海报与演示专题, 1:59–63, 2012年。Rebecca Killick, Paul Fearnhead, 和 Idris A Eckley. 以线性计算成本实现变点的最优检测。美国统计学会杂志, 107(500):1590–1598, 2012年。Charles Truong, Laurent Oudre, 和 Nicolas Vayatis. ruptures：Python中的变点检测。*arXiv*预印本 *arXiv:1801.00826*, 2018年。Peihua Qiu. 关于非参数统计过程控制的若干观点。质量技术杂志, 50(1): 49–65, 2018年。Seulki Lee, Mingu Kwak, Kwok-Leung Tsui, 和 Seoung Bum Kim. 使用变分自编码器监控高维非线性过程。*Engineering Applicationsof Artificial Intelligence*, 83:13–27, 2019年。Changliang Zou, Fugee Tsung, 和 Yukun Liu. 一种用于多阶段过程第一阶段分析的变点方法。*Technometrics*, 50(3):344–356, 2008年。Sahand Hariri, Matias Carrasco Kind, 和 Robert J Brunner. 扩展孤立森林。*IEEE*知识与数据工程汇刊, 33(4):1479–1489, 2019年。Yiran Dong 和 Chuanhou Gao. ELBD：一种用于变分自编码器潜变量特征选择的高效评分算法。*arXiv*预印本 *arXiv:2111.08493*, 2021年。Yue Zhao, Xiyang Hu, Cheng Cheng, Cong Wang, Changlin Wan, Wen Wang, Jianing Yang, Haoping Bai, Zheng Li, 等人. SUOD：加速大规模无监督异构离群点检测。机器学习与系统会议录, 3:463–478, 2021年。