

Beijing Forest Studio
北京理工大学信息系统及安全对抗实验中心



流式数据漂移应对方法

硕士研究生 郭汝赞

2026年 05月 06日

- 总结反思
 - 语调平淡、语言信息量少
 - TIPO讲解少，没有突出创新点
- 相关内容
 - 2025.07.27 马西洋：《数据集不平衡评估方法》

- 预期收获
- 内容引入
- 内涵解析与研究目标
- 研究背景与研究意义
- 研究历史与现状
- 知识基础
- 算法原理
 - PUDD
 - CALIPER
- 特点总结与工作展望
- 参考文献


- 预期收获
 - 1. 了解基于数据漂移的基本概念和问题框架
 - 2. 理解数据漂移检测与重训练的必要性
 - 3. 了解数据漂移检测与重训练前沿方法

- 研究目标

- 让机器学习模型在**数据持续变化**的环境中仍然保持可靠

- 在模型性能明显下降前识别漂移

- 在漂移后判断是否需要更新模型、何时更新模型

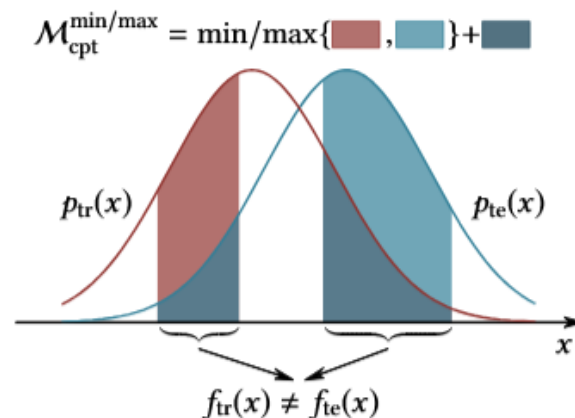



(a) Data at time t (b) Data at time $t+1$

- 内涵解析

- 数据漂移：数据流随时间变化后，模型原先学到的规律不再完全适用

- 漂移检测：在连续到来的数据中比较过去和当前数据是否仍属于**同一种规律**




• 研究背景

- 当前很多系统都在处理持续到来的数据，而不是处理静态数据集
- 数据发生漂移时，模型可能表面仍在运行，但实际判断已经**逐渐失准**
 - 检测太晚会让错误决策持续发生
 - 检测太敏感又会造成频繁误报和反复重训

• 研究意义

- 根据数据变化情况触发模型更新，提高真实环境中的**长期可用性**
- 帮助系统及时发现模型失效风险、降低维护成本



Bifet提出了ADWIN，与需要预设窗口大小的算法不同，ADWIN核心是使用一个动态调整大小的数据窗口检测数据流中的漂移。它通过滑动窗口比较历史数据和当前数据，从而判断数据分布是否发生变化

Yuan等人梳理了深度学习模型在漂移环境下的适应问题，他们梳理了突变漂移、渐进漂移、增量漂移和循环漂移，并把深度模型适应方法分为参数更新和结构更新两类，说明单纯检测漂移已经不够，还要解决深度模型**如何稳定更新**的问题

Wan等人出 MCD-DD，把窗口样本集合编码为**概念嵌入**，再利用最大概念差异和对比学习来检测高维数据流中的概念漂移，减少对标签、错误率或简单统计假设的依赖，更接近图像、复杂传感器和真实线上系统的需求，但训练和参数设置较复杂

Ren等人提出CALIPER，一个与检测器、模型无关的纯数据驱动方法，用来估计后漂移数据量的充足性。他们假设特征空间中距离近的点，其下一步的演化也相似，并利用它进行回归预测，根据误差趋势判断重训练时机

2007

2020

2022

2023

2024

2025

2026

Christoph等人提出了KSWIN，它使用一个固定大小的滑动窗口，并持续比较窗口内两部分**数据的分布**，通过KS检验来判断数据分布是否发生了显著变化，但固定窗口对不同漂移速度不够灵活

Zhang等人提出了OneNet，认为不同模型对数据有不同偏好，而这种偏好会随着漂移变化，因此提出在线集成网络，动态组合多个预测模型，用来缓解时间序列预测中分布持续变化带来的性能下降，缺点是系统复杂度更高；对漂移解释性有限

Lu等人提出了PUDD，首次理论上证明**预测不确定性**比错误率更敏感，它不依赖错误率下降，因此能实现早期检测，并且已在图像数据流上验证有效，不过概率校准质量会影响检测效果

数据漂移

— 指数据流的统计特性随时间发生不可预见

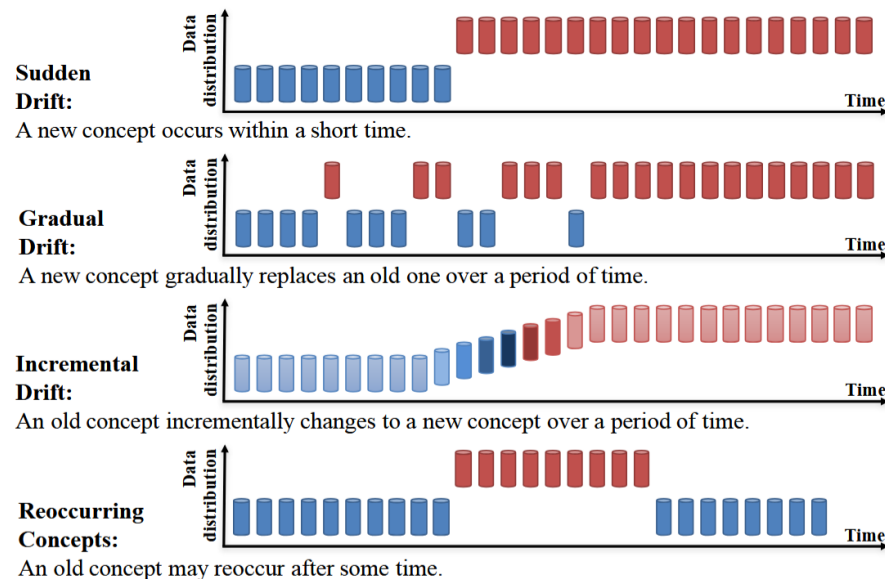

$$P_t(X, y) \neq P_{t+1}(X, y)$$

— 由 $P(X, y) = P(X) \times P(y | X)$ ，漂移可以来自：

- 特征分布变化 ($P(X)$ 变化)：输入数据的分布变了，但分类边界没变
- 决策边界变化 ($P(y | X)$ 变化)：分类规则变了，模型准确率下降
- 两者同时变化：最常见的情况

常见的漂移类型

- 突变漂移，概念在某一时刻瞬间变化
- 渐进漂移，概念在一段时间内逐渐变化
- 增量漂移，概念逐步演变，每一步变化很小
- 循环漂移，旧概念在未来重新出现



流式数据

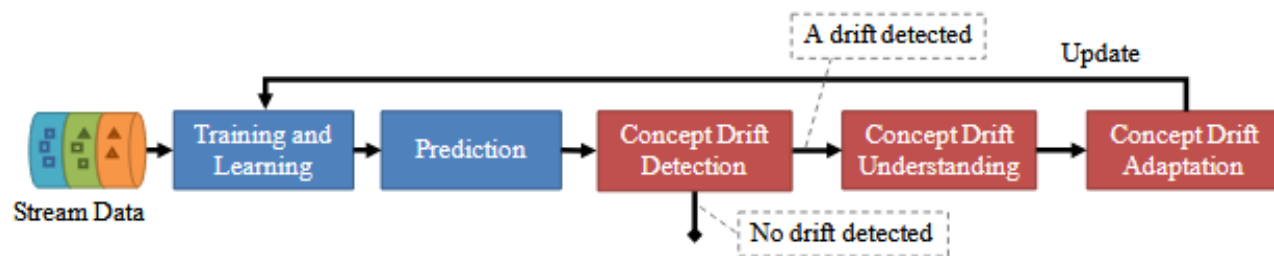
• 流式数据vs时序数据

数据类型	核心定义	对数据点间关系的假设	主要处理模式	对分布变化的要求	主要应用领域
时序数据	按时间顺序排列的观测值序列，存在 自相关 、 趋势 、 季节性 或 周期性	关注相邻点或滞后点之间的统计关系，不能随意打乱顺序	批处理建模、滚动预测、递推预测	常要求 平稳性 或经过差分、去趋势等处理后近似平稳	能源负荷预测、气候建模、生物信号分析、设备状态预测
流式数据	连续、快速、潜在无限到达的数据序列，实时到达	样本间依赖弱，重点研究连续到达和 分布变化	增量学习、滑动窗口更新、先预测后学习处理	需要检测、理解和 适应 分布变化	实时欺诈检测、在线推荐、广告点击率预测、传感器网络监控

数据漂移

• 流程框架

- 传统的机器学习有两个主要组成部分：
 - 训练和学习、预测
- 概念漂移下的学习研究提出了三个新的组成部分：
 - 漂移检测：是否发生漂移
 - 漂移理解：何时、如何、在哪里发生
 - 漂移适应：对漂移存在的反应





Early Concept Drift Detection via Prediction Uncertainty

TIPO

T	目标	在流式分类任务中实现 早期检测漂移 ，提升检测灵敏度并保持模型性能稳定
I	输入	分类模型输出概率、流式分类数据集（表格*3、合成*3、图像*1）
P	处理	1.使用滑动窗口策略，丢弃过期数据 2.按正确、错误分类划分，构建直方图 3.检验计算，判断是否发生漂移
O	输出	是否发生概念漂移，最优 切分点 位置

P	问题	传统分类模型在流式场景下基于错误率的漂移检测不敏感，在漂移早期（分布变化但准确率未变）无法检测，导致检测延迟、漏检
C	条件	可及时获得数据真实标签、分类器可以输出概率
D	难点	如何构造更敏感的检测信号，保证在流式环境中准确性
L	水平	AAAI 2025 (CCF A)

- 算法原理图

- 构建滑动窗口

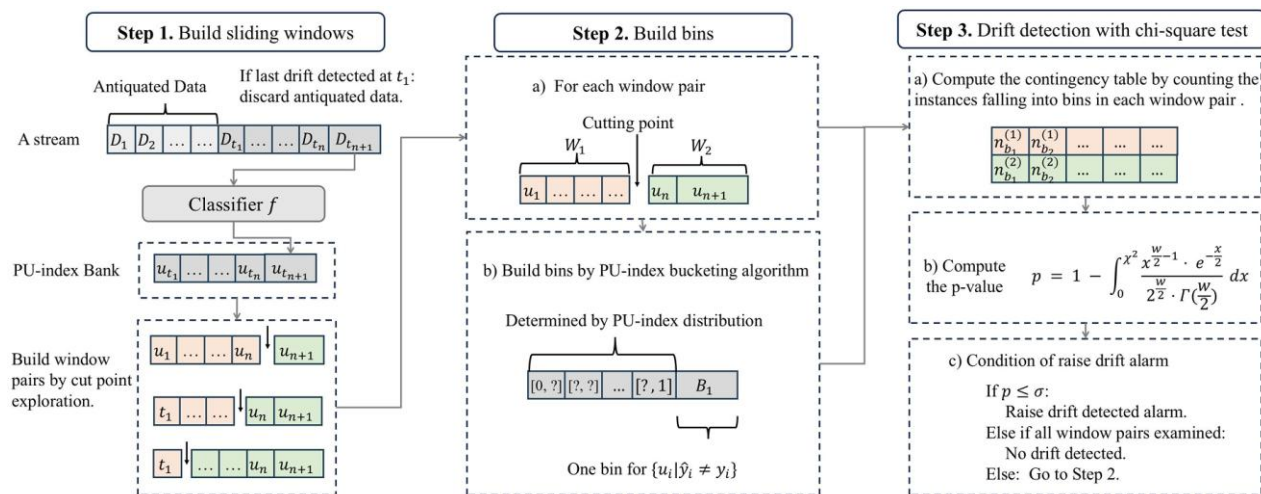
- 先丢弃上一次漂移之前的过期数据，只保留最近的数据流
- 枚举不同切分点，把当前数据流划分成两个窗口

- 基于PU-index构建分桶

- 对每个样本计算预测不确定性指数，再根据PU-index分布构造直方图分桶

- 使用卡方检验判断漂移

- 对两个窗口的PU-index分布建立列联表，计算卡方检验的p-value
- 如果小于阈值，触发漂移警告



- 创新点

- 把漂移检测信号从错误率换成PU-index


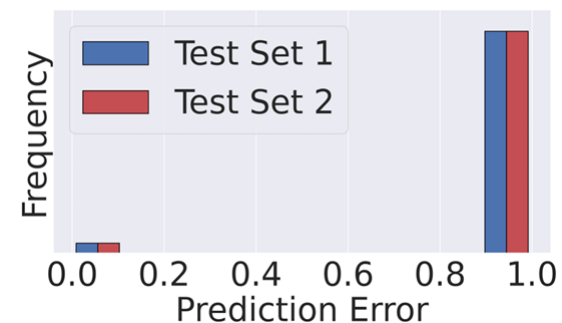
- 错误率是0/1信号，只能告诉我们模型是否预测错误
- PU-index是连续信号，可以捕捉早期漂移的状态

- 理论上证明PU-index比错误率更敏感

- 如果PU-index分布没有变化，那么错误率也不会变化
- 即使错误率不变，PU-index分布仍可能变化

- 设计了自适应分桶方法算法

- PU-index是连续值，不能直接做卡方检验
- 把PU-index分布转化为直方图，同时尽量满足卡方检验对样本频数的要求
- 既保留不确定性分布变化，又避免检测过于敏感导致误报



模块概述

– 目标：漂移发生位置是未知的，使用两个滑动窗口准确定位**漂移发生位置**，避免之后进行的分布比较失真

– 输入：

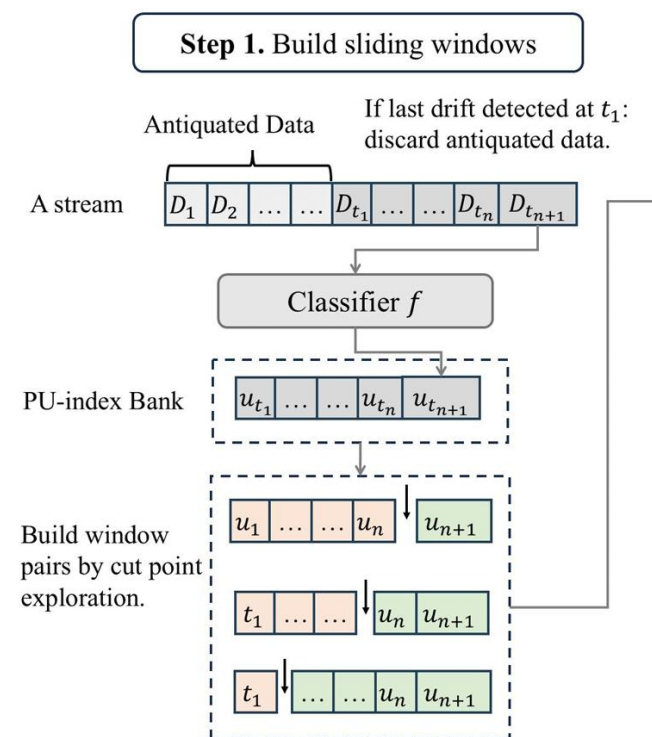
- 当前保留的数据子流、分类器

– 操作：


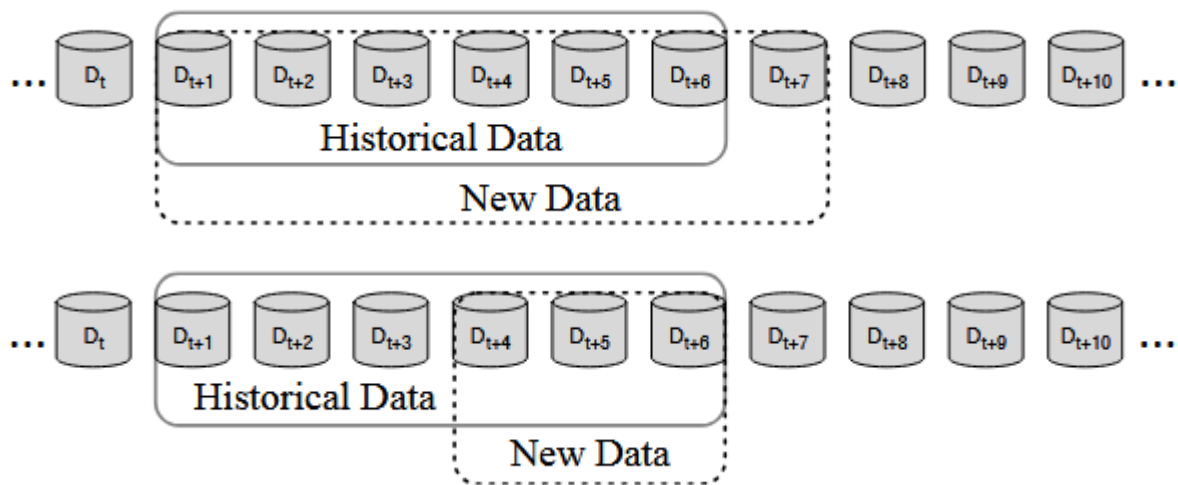
- 丢弃漂移前的**过期数据**
- 在当前子流中枚举所有可能切分点、并划分为两个窗口
- 每个窗口对进入后续统计检测流程

– 输出：

- 一组候选窗口对



- 丢弃过期数据
 - 作用：确保后续比较是在当前分布附近进行，而**不会被早期分布干扰**
 - 从上次发生漂移的时间点 t_1 开始，将之前的数据 D_{1,t_1} 丢弃，保留 $D_{t_1,t}$
- 枚举切分点
 - 对于子流中的每一个位置 r ，都将数据划分为两部分
 - 一部分代表**较早阶段的数据**，另一部分代表**较新的数据**



基于PU-index构建分桶

模块概述

– 目标：构建一个比错误率更敏感的漂移检测信号表示形式，并将其转化为可用于统计检验的分布结构

– 输入：

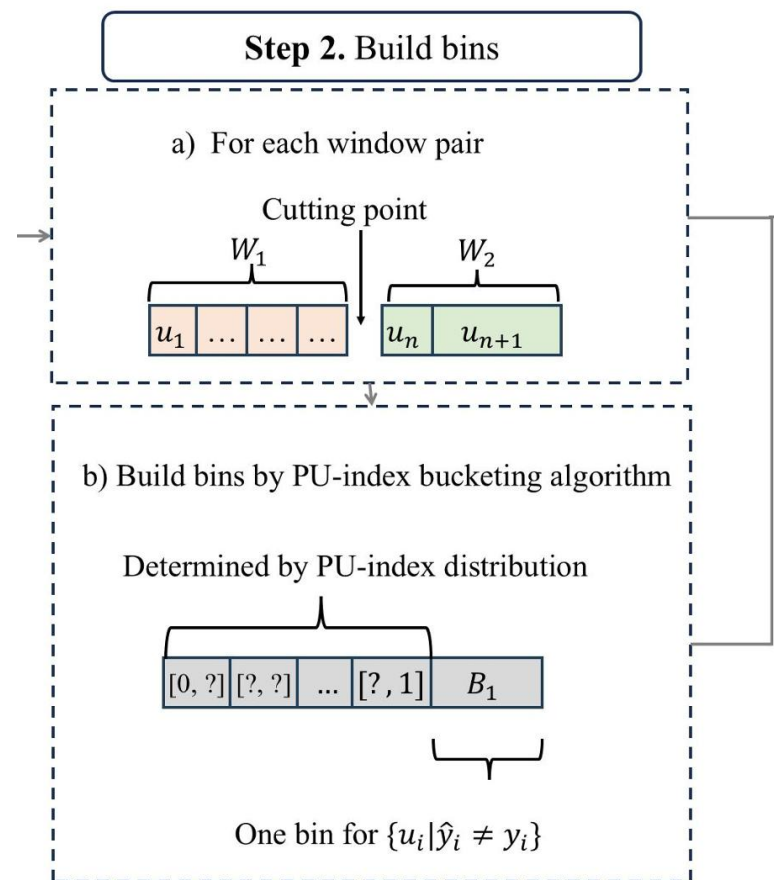
- 当前两个窗口的数据 $D_{t_1,r}$ 和 $D_{r,t}$
- 分类器输出的预测概率 $f(x)$
- 每个样本的真实标签 y_i

– 操作：

- 计算每个样本的PU-index
- 对正确分类样本的PU-index进行自适应分桶

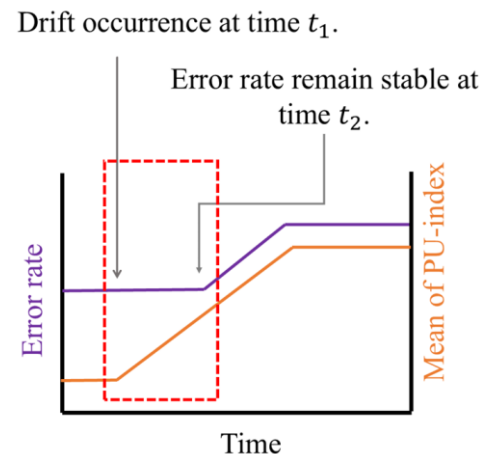
– 输出：

- 两个窗口对应的PU-index直方图分布



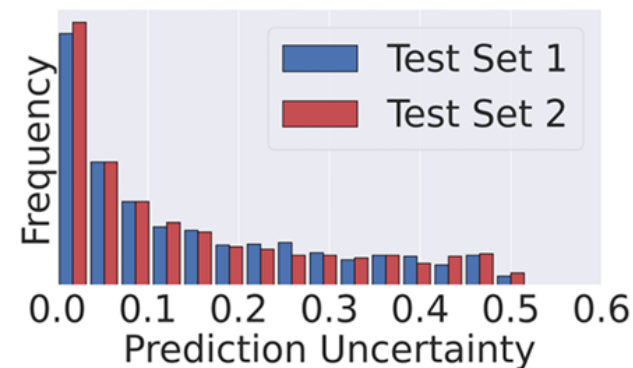
• 预测不确定性指数

- 对于样本中的已分类数据，定义PU-index为 $u_i = 1 - f_{y_i}(x_i)$
- 优点
 - 相比于错误率保留更多信息，可以衡量模型对真实标签的不确定性
 - 和分类任务目标**直接相关**，原始特征分布可能高维、噪声大



• 自适应分桶

- 先在第一个窗口的正确分类上构建，用**同一套**去统计第二个窗口
- 正确分类样本：PU-index的变化最有价值
 - 虽然分类正确，但它们的置信度可能已经发生变化
 - 早期漂移信号主要藏在**正确分类样本内部**
- 错误分类样本：统一进入一个桶
 - 样本数量少，分桶后容易稀疏，且分桶收益不明显



• 模块概述

– 目标：利用两个窗口的PU-index分布，进行统计显著性检验并输出是否发生漂移

– 输入：

- 两个窗口的PU-index分桶结果

– 操作：

- 将分桶结果转化为列联表
- 根据列联表计算期望频数、卡方统计量
- 取最小p_value和阈值比较

– 输出：

- 是否发生概念漂移、最优切分点

Step 3. Drift detection with chi-square test

a) Compute the contingency table by counting the instances falling into bins in each window pair .

$n_{b_1}^{(1)}$	$n_{b_2}^{(1)}$
$n_{b_1}^{(2)}$	$n_{b_2}^{(2)}$

b) Compute the p-value
$$p = 1 - \int_0^{\chi^2} \frac{x^{\frac{w}{2}-1} \cdot e^{-\frac{x}{2}}}{2^{\frac{w}{2}} \cdot \Gamma(\frac{w}{2})} dx$$

c) Condition of raise drift alarm

If $p \leq \sigma$:

Raise drift detected alarm.

Else if all window pairs examined:

No drift detected.

Else: Go to Step 2.

- **数据资源**
 - 表格数据: **airline**、 **elec2**、 **powersupply**、 **sine**、 **mixed**、 **sea variants**
 - 图像数据: **CIFAR-10-CD**
- **分类模型**
 - 深度神经网络 (**DNN**)、 高斯朴素贝叶斯 (**GNB**)、 流式决策树 (**VFDT**)
- **对比方法**
 - **错误率**基准方法: **DDM**、 **EDDM**、 **ADWIN**、 **HDDM**、 **PH**
 - **分布**基准方法: **KSWIN(2020)**、 **MCDD(2024)**
 - 适应方法: **AMF(2021)**、 **IWE(2022)**、 **NS(2021)**、 **ADLTER(2022)**、
MCD-DD (2024)
- **指标: 分类准确率**

• 实验结果


ddm name	airline	elec2	mixed	ps	sea0	sine
AMF	38.56	66.24	49.49	69.63	93.67	49.52
IWE	38.02	68.90	49.47	64.10	93.14	49.51
NS	67.91	76.42	81.09	72.39	93.54	91.01
ADLTER	70.00	76.10	87.63	72.48	93.40	92.18
MCD-DD	63.65	69.81	86.68	71.66	97.66	90.21
PUDD-1	63.78	77.28	89.51	72.68	98.47	94.52
PUDD-3	64.62	76.77	89.47	72.79	98.44	94.76
PUDD-5	64.45	76.92	89.37	72.74	98.49	90.90

• 分析


- PUDD在多数情况下进入前三
- PUDD对不同分类模型的适配性不同
- 阈值的选择对性能有影响，但一般不起决定性作用

Classifier	ddm name	Incremental Training						Training only at Initialization or Adaptation					
		airline-I	elec2-I	mixed-I	ps-I	sea0-I	sine-I	airline-O	elec2-O	mixed-O	ps-O	sea0-O	sine-O
DNN	ADWIN	61.65	71.94	78.45	71.12	97.70	79.27	59.36	69.71	84.41	65.95	95.18	86.59
	DDM	61.29	71.02	80.72	71.37	96.86	86.41	56.79	69.51	83.03	69.35	93.55	80.32
	EDDM	62.13	70.39	78.01	65.21	96.89	75.34	61.17	69.22	71.16	67.57	92.18	76.54
	HDDM-A	62.70	71.16	76.70	68.97	97.84	81.65	59.13	68.98	84.27	67.81	95.11	86.82
	HDDM-W	61.50	71.23	77.07	68.74	97.84	85.43	62.42	68.48	84.32	66.89	92.24	86.57
	KSWIN	63.02	70.56	78.58	70.80	97.88	79.00	61.34	69.08	84.43	66.46	91.60	83.66
	PH	62.15	72.25	79.49	70.86	97.73	78.07	60.36	68.24	84.36	68.83	95.21	86.88
	PUDD-1	63.31	74.92	77.39	72.25	97.94	86.19	60.90	69.35	82.65	71.47	94.89	83.39
	PUDD-3	63.21	74.93	80.05	72.23	98.04	85.12	60.16	68.98	84.65	70.37	95.99	84.97
	PUDD-5	63.35	74.92	82.81	72.24	98.23	82.51	60.19	68.68	84.90	70.20	96.29	85.09
GNB	ADWIN	50.17	68.90	83.95	70.06	94.18	82.49	54.66	68.30	83.62	68.78	93.93	82.45
	DDM	52.94	67.75	83.82	69.63	93.97	82.07	52.43	67.60	83.59	67.52	93.48	81.90
	EDDM	62.72	67.73	83.19	70.04	94.06	83.12	54.11	67.64	74.65	70.04	94.06	73.88
	HDDM-A	52.80	67.73	83.92	70.87	94.28	83.25	55.62	67.73	83.66	71.24	93.96	83.36
	HDDM-W	48.66	67.73	83.91	71.06	92.11	82.83	48.62	67.71	83.60	69.53	91.63	83.25
	KSWIN	49.84	67.87	83.92	71.23	91.72	81.88	48.83	67.63	83.59	67.99	90.02	81.32
	PH	49.35	70.12	83.88	70.36	94.34	83.54	49.02	70.04	83.61	68.67	94.12	83.10
	PUDD-1	53.57	70.85	82.99	71.88	94.61	83.12	51.05	62.76	79.23	71.13	94.25	81.48
	PUDD-3	53.03	70.85	83.92	71.59	94.81	83.39	49.45	59.32	83.58	71.20	94.60	83.80
	PUDD-5	52.16	70.69	84.12	71.59	94.85	83.43	54.37	59.44	83.96	70.40	94.62	83.38
VFDT	ADWIN	60.39	73.98	84.30	71.69	94.77	87.11	61.22	74.29	83.54	68.78	92.96	85.74
	DDM	60.16	74.82	84.14	70.68	94.86	86.50	59.28	74.75	82.31	67.53	93.63	82.23
	EDDM	61.19	73.81	83.15	70.06	94.17	85.59	62.31	73.81	73.73	70.06	93.60	77.72
	HDDM-A	60.95	73.90	84.40	70.84	95.20	87.53	60.29	73.83	83.66	71.24	93.93	85.21
	HDDM-W	61.11	73.80	84.40	70.99	93.50	87.45	61.92	73.73	83.59	69.54	91.76	85.28
	KSWIN	61.30	74.10	84.42	71.27	93.40	86.22	62.06	74.10	83.57	67.51	89.84	82.60
	PH	60.95	73.70	83.56	70.88	94.69	87.15	60.97	73.99	83.30	68.67	93.85	85.19
	PUDD-1	61.38	73.86	84.25	71.77	95.13	87.33	61.16	69.79	82.13	71.13	94.10	82.21
	PUDD-3	61.57	73.84	83.94	71.79	95.21	87.42	59.90	69.79	84.04	71.20	94.63	85.81
	PUDD-5	61.57	73.64	84.01	71.79	95.24	87.63	57.04	71.83	84.16	70.40	94.56	86.01

- 实验结果
- 分析
 - PUDD 不只适用于低维表格流，也能用于高维图像数据
 - PUDD 没有直接在图像像素空间做分布比较，而是在分类器输出概率上做PU-index检测，进而绕开了高维图像分布检测困难的问题



- 实验结果



- 消融情况

- EK(Ei-kMeans)采用传统空间分桶方法
- DNN提升最明显
 - DNN 输出概率分布更丰富



**When to Retrain after Drift:
A Data-Only Test of Post-Drift Data Size Sufficiency**

TIPO

T	目标	能够在漂移后，自动判断何时积累了足够数据并触发稳定重训练
I	输入	漂移报警后的流数据，数据集(图像-MoCap，表格-TEP、Automobile，合成-Dysts)，外部漂移检测器
P	处理	1.对漂移窗口数据进行标准化，并拆分为一步预测参考对与当前查询对 2.通过不同参数进行加权局部回归，同时利用有效样本数ESS约束 3.检查代理误差，当满足ESS与单调性条件时，触发下游模型重训练
O	输出	漂移后是否可以重训练，估计出的最小重训练数据量

P	问题	固定窗口策略容易过早或过晚重训练，导致过拟合、性能退化或恢复延迟
C	条件	数据流已经由外部检测器检测到漂移，数据持续到达，下游预测模型作为黑盒，不依赖漂移后测试标签
D	难点	如何 仅利用漂移后的数据 本身，判断新概念是否已经形成足够稳定的局部状态依赖，从而避免过早重训练或过晚重训练
L	水平	ICLR 2026 (CCF A)

• 算法原理图

– 窗口归一化与分割

- 对当前数据窗口进行标准化处理，并用历史点预测下一时刻

– ESS检查

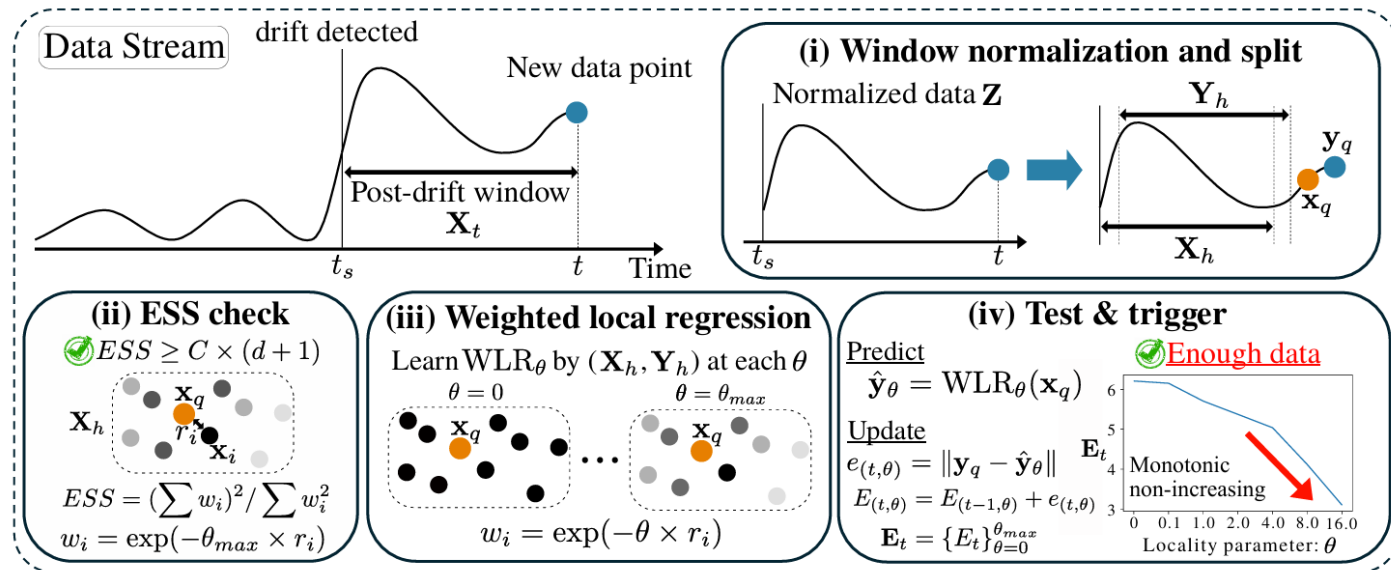
- 在局部的邻域尺度下计算有效样本数

– 加权局部回归

- 在不同局部性参数下，对邻近样本进行加权回归来预测当前点
- 计算对应的预测误差

– 测试与触发

- 判断预测误差是否随局部性增强而**单调不增**
- 若满足条件，则认为数据足够，触发模型重训练




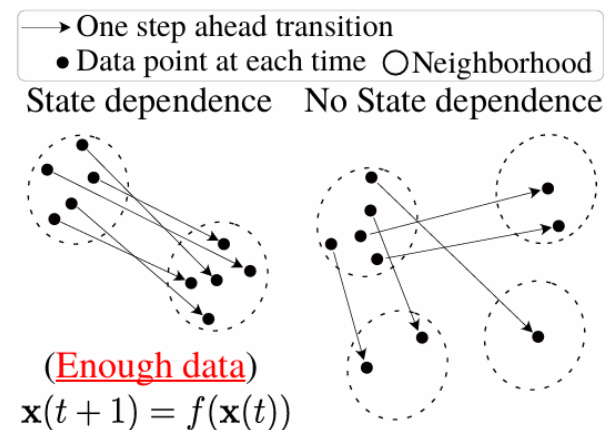
- 创新点

- 问题建模的改变

- 使问题从检测问题变成决策问题
 - 完全围绕数据本身展开，**不依赖**模型内部信息或标签

- 局部状态依赖

- 如果偏移后更局部的邻域能带来更低的一步预测误差，并且邻域有效样本数足够，就认为当前数据量足以稳定重训
 - 利用有效样本数（ESS）约束来**避免样本稀疏**导致的错误判断



- 模块概述

- 目标:

- 将原始的偏移后数据窗口转化，为后续操作提供统一、可比较的数据表示分类

- 输入:

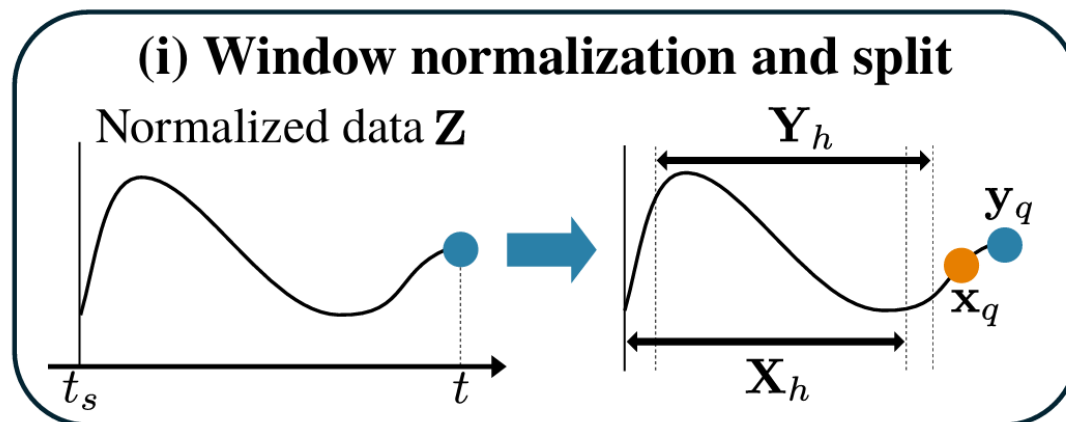
- 漂移发生后累积得到的时间序列窗口

- 操作:

- 对窗口内数据进行标准化处理
 - 将连续时间序列重构为**一步预测样本对**

- 输出

- 历史样本对
 - 当前查询点



- 窗口归一化

- 原始数据流中，不同时间段的数据尺度可能完全不同
- 保证后续距离、邻域、局部性这些概念是有意义的


- 一步预测

- 用当前状态预测下一步状态，判断数据是否已经形成稳定的动态规律

X_h : 历史输入 (过去状态) Y_h : 历史输出 (下一步状态)

x_q : 当前状态 (query) y_q : 当前真实下一步

- 原始数据 $x(t_s), x(t_s + 1), \dots, x(t)$
- 重构数据 $(x_1 \rightarrow x_2), (x_2 \rightarrow x_3), \dots, (x_{n-1} \rightarrow x_n)$



ESS检查

- 模块概述

- 目标:

- 确保在进行局部建模时，参与计算的有效样本数量足够，避免因为邻域过小或权重过于集中导致的偶然拟合和错误判断

- 输入:

- 历史样本对
 - 当前查询点

- 操作:


- 根据加权样本计算有效样本数
 - 与阈值 $C(d + 1)$ 进行比较

- 输出

- 判断当前窗口在局部尺度下是否具有足够的有效样本数

(ii) ESS check

✔ $ESS \geq C \times (d + 1)$

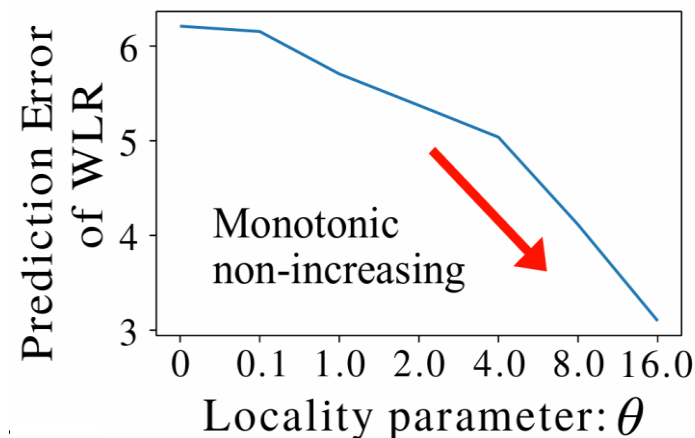
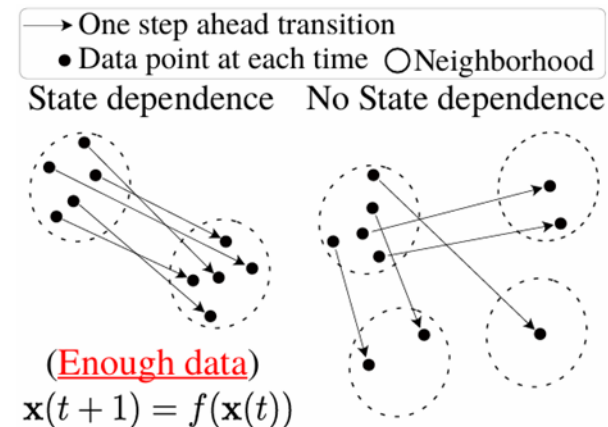


$$ESS = (\sum w_i)^2 / \sum w_i^2$$

$$w_i = \exp(-\theta_{max} \times r_i)$$


ESS检查

- 错误触发
 - 如果邻域过小（也就是局部性参数 θ 很大）
 - 误差看起来很小，因为只是过拟合了几个点
- 有效样本数(ESS)
 - 衡量在加权情况下，参与建模的等效样本数量
 - $w_i(\theta) = \exp(-\theta \cdot r_i)$ ，其中 r 是距离， w_i 是权重
 - $ESS = \frac{(\sum_i w_i)^2}{\sum_i w_i^2}$
 - 所有样本权重差不多：ESS 接近样本总数
 - 只有少数样本权重大：ESS 会很小
 - 只在最大局部性下检查 ESS，最极端的局部情况满足，其他情况都满足



E22 烤豆

- 阈值 $C(d + 1)$
 - d 是数据维度, $+1$: 对应偏置项
 - 局部回归模型不仅拟合斜率, 还要拟合截距
 - 有效样本数必须至少大于模型参数个数, 并且具有一定冗余
 - 参数 C
 - 有效样本数要明显多于参数数目
 - 降低方差, 提高数值稳定性, 再次避免局部过拟合



• 模块概述

– 目标:

- 在不同局部尺度下，对当前数据的预测能力进行估计，构造一个能够反映数据稳定性的误差信号

– 输入:

- 历史样本对 (X_h, Y_h)
- 当前查询点 x_q 及其真实下一步 y_q

– 操作:


- 在每个 θ 下，用**加权**最小二乘拟合一个局部线性模型，并用该模型预测当前点的下一步，然后计算预测误差

– 输出

- 对每个 θ ，得到一个预测值 \hat{y}_θ 和对应误差 $e(t, \theta)$ ，并逐步累计为 $E(t, \theta)$

(iii) Weighted local regression

Learn WLR_θ by (X_h, Y_h) at each θ



加权局部回归

- 加权拟合

- 线性模型的优势

- 计算快、易解释、在小邻域内近似合理

$$\min_{\beta} \sum_i w_i(\theta) \|Y_h^{(i)} - X_h^{(i)} \beta\|^2$$

- 用拟合后的函数去预测 $\hat{y}_\theta = f_\theta(x_q)$

- 获得误差并累加 $e(t, \theta) = \|y_q - \hat{y}_\theta\|$, $E(t, \theta) = E(t-1, \theta) + e(t, \theta)$

- 单次误差：噪声大、不稳定、容易误判
- 累加的作用：**平滑**时间维度的波动，误差趋势更稳定，更适合做单调性判断

• 模块概述

– 目标:

- 在不同局部尺度下, 对当前数据的预测能力进行估计, 构造一个能够反映数据稳定性的误差信号

– 输入:

- 不同局部性参数下的**累计误差** $E(t, \theta_1), E(t, \theta_2), \dots, E(t, \theta_k)$
- 已通过 ESS 检查的数据窗口

– 操作:

- 检查误差序列是否满足随局部性增强**单调不增**

– 输出

- $R(X_t) = 1$: 触发重训练
- $R(X_t) = 0$: 继续积累数据

(iv) Test & trigger

Predict

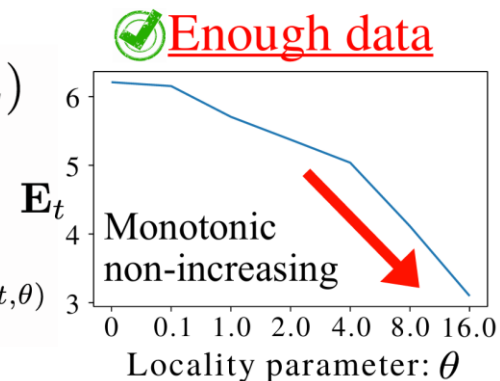
$$\hat{y}_\theta = \text{WLR}_\theta(\mathbf{x}_q)$$

Update

$$e_{(t,\theta)} = \|\mathbf{y}_q - \hat{y}_\theta\|$$

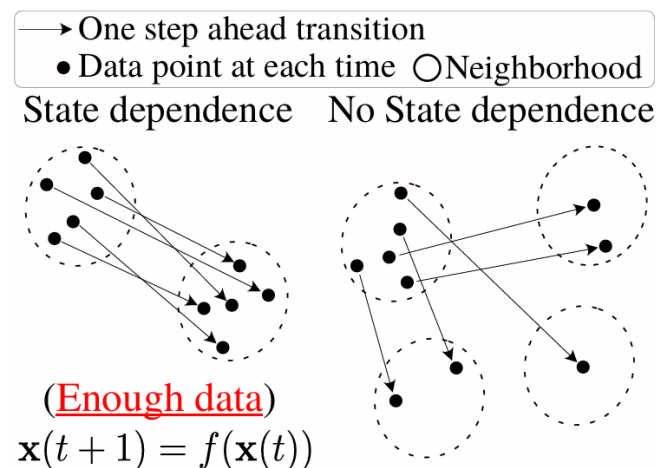

$$E_{(t,\theta)} = E_{(t-1,\theta)} + e_{(t,\theta)}$$

$$\mathbf{E}_t = \{E_t\}_{\theta=0}^{\theta_{max}}$$

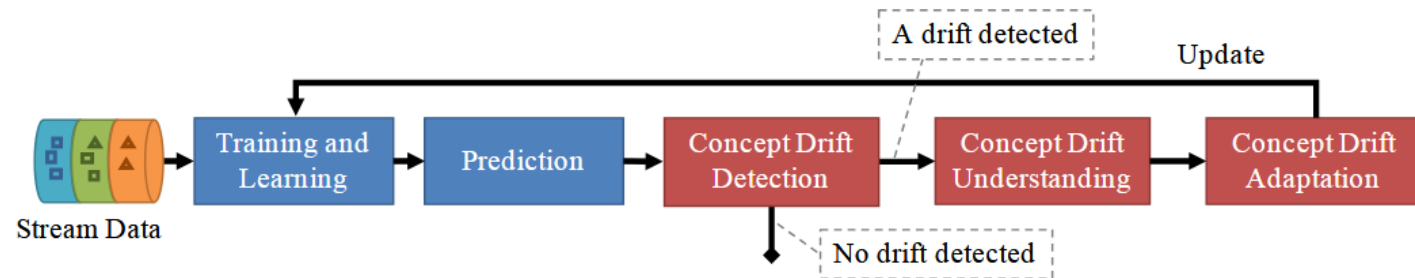


• 重训练判据

- $E(t, \theta_1) \geq E(t, \theta_2) \geq \dots \geq E(t, \theta_k)$
 - 随着 θ 增大（邻域越来越局部），预测误差不增加
- 单调下降证明数据已经**稳定**
 - 数据不稳定：
 - 在漂移过渡期，局部结构混乱
 - 数据已经稳定：
 - 数据**内部有规律**，相似的数据有相似的未来状态



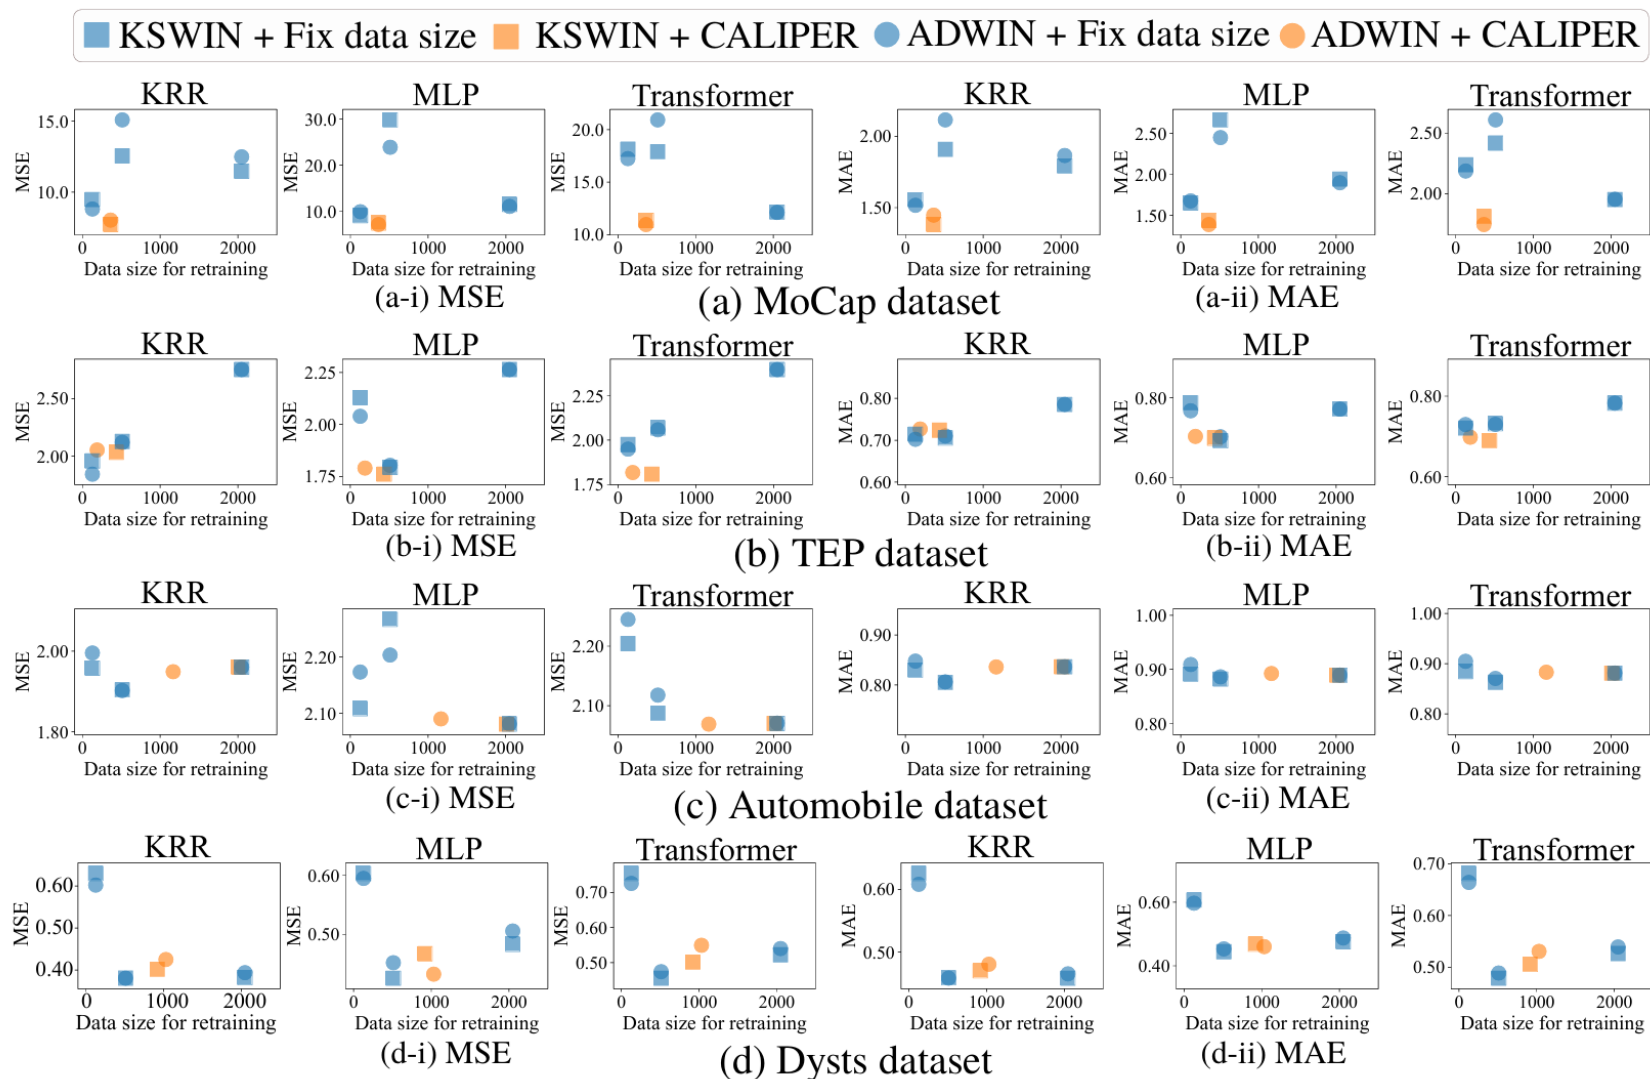
- 数据资源
 - (图像-人体动作MoCap, 表格-工业控制TEP、多传感器Automobile, 合成-Dysts)
- 对比方法
 - 漂移检测器: ADWIN (2007)、KSWIN (2020)
 - 重训练方法: 固定窗、增量学习
 - 下游模型: KRR、MLP、Transformer
- 指标: 均方误差 (MSE)、平均绝对误差 (MAE)



实验结果

分析

- 误差曲线通常呈先降后升的趋势
- CALIPER选的点通常落在误差曲线的**低谷**附近
- 不同模型的曲线形状不同，但CALIPER在**不同模型**上仍然有效




• 实验结果


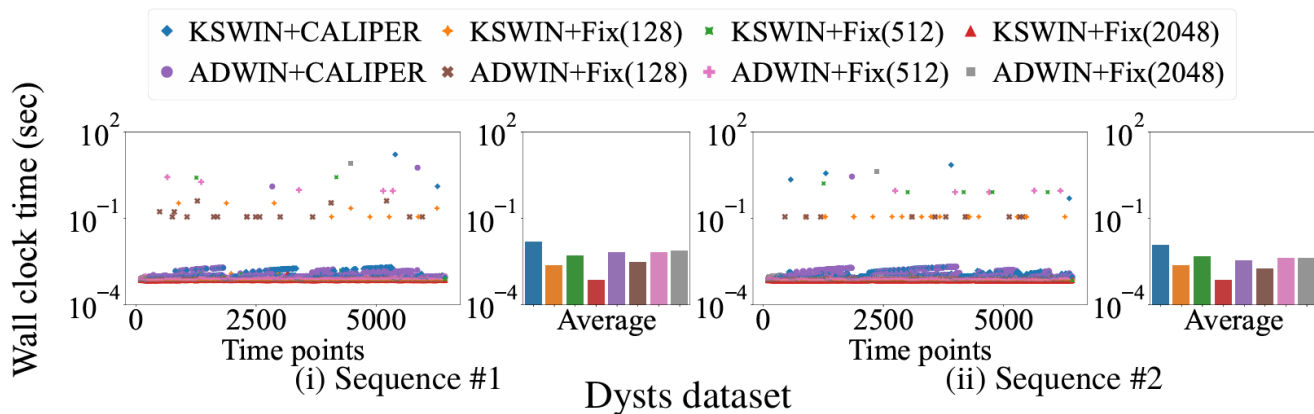
Model	Detector	MoCap		TEP		Automobile		Dysts	
		MSE	MAE	MSE	MAE	MSE	MAE	MSE	MAE
MLP	ADWIN	7.106	1.387	1.790	0.704	2.090	0.892	0.432	0.460
	KSWIN	7.449	1.436	1.760	0.699	2.081	0.889	0.467	0.468
	(Incremental)	412.6	8.462	3.699	0.879	2.406	0.894	71.75	1.524
Transformer	ADWIN	10.96	1.744	1.818	0.698	1.948	0.883	0.549	0.530
	KSWIN	11.35	1.810	1.808	0.690	2.070	0.881	0.501	0.505
	(Incremental)	22.08	2.654	2.376	0.767	1.866	0.773	0.582	0.585

• 分析

- CALIPER在大多数情况下优于增量学习
 - 在突发漂移下，梯度方向错误，增量学习更新会发散
 - CALIPER会等数据稳定了再学习
- CALIPER对参数不敏感



实验结果



分析

- CALIPER的开销和固定窗方法相近
- 曲线平坦且均值较低，偶尔的峰值反映的是重新训练而非CALIPER



工作总结

• 特点总结

算法	所属阶段	核心思想	主要优势	主要不足
PUDD	漂移检测阶段	用 预测不确定性 替代传统错误率作为漂移信号	能发现错误率尚未变化的早期漂移	依赖预测概率质量，阈值仍需设置，标签延迟场景下使用受限
CALIPER	漂移后适应阶段	利用漂移后数据的 状态依赖性 判断数据是否足够	给出了计算漂移后稳定重训需要数据数量的模型	更适合 突变漂移 后的重训数据量判断，高维原始数据中需要良好表征

• 工作展望

- 将早期漂移检测能力与重训时机判断机制结合
- 面向高维、标签延迟等真实场景，提升漂移检测与恢复方法的稳定性、泛化性和实际部署能力

- [1] Lu P, Lu J, Liu A, et al. Early concept drift detection via prediction uncertainty[C]//Proceedings of the Thirty-Ninth AAAI Conference on Artificial Intelligence. 2025.
- [2] Fujiwara R, Matsubara Y, Sakurai Y. When to retrain after drift: A data-only test of post-drift data size sufficiency[C]//Proceedings of the International Conference on Learning Representations. 2026.

知人者智，自知者明。胜人者有力，自胜者强。知足者富。强行者有志。不失其所者久。死而不亡者，寿。

谢谢！

