

如何可持续地监控支持 ML 的系统？概念漂移检测中的精度和能效权衡

Rafiullah Omar*, Justus Bogner†, Joran Leest†, Vincenzo Stoico†, Patricia Lago†, Henry Muccini*

*FrAmeLab, University of L’ Aquila, L’Aquila, Italy,

rafiullah.omar@graduate.univaq.it, henry.muccini@univaq.it

†Vrije Universiteit Amsterdam, Amsterdam, The Netherlands,

j.bogner@vu.nl, j.g.leest@vu.nl, v.stoico@vu.nl, p.lago@vu.nl

Abstract—部署在生产环境中的 ML 系统通常会因概念漂移而遭受模型预测质量下降的影响，即某个现实世界域的统计特征逐渐变化。为了解决这个问题，一个简单的解决方案是定期重新训练 ML 模型，不幸的是，这会消耗大量能量。因此，提高能源效率的一种推荐策略是系统地监测概念漂移的水平，只有在不可避免时才进行重新培训。有不同的方法可以做到这一点，但我们对它们对精度和能源效率之间权衡的具体影响知之甚少，因为这些方法本身也会消耗能源。因此，为了解决这个问题，我们进行了一项对照实验，以研究七种常用概念漂移检测方法的准确性与能效权衡。我们使用了五个合成数据集，每个数据集都有一个突变的版本，一个是渐进漂移的版本，并训练了六个不同的 ML 模型作为基本分类器。基于全因子设计，我们测试了 420 种组合（7 个漂移检测器 × 5 个数据集 × 2 种漂移 × 6 个基本分类器），并比较了能耗和漂移检测精度。我们的结果表明，有三种类型的探测器：a) 为了检测精度而牺牲能效的探测器 (KSWIN)，b) 平衡探测器，消耗低到中等能量且精度高 (HDDM_W, ADWIN)，以及 c) 消耗很少能量但由于精度非常差而在实践中无法使用的探测器 (HDDM_A, PageHinkley, DDM, EDDM)。通过为这种能效策略提供丰富的证据，我们的研究结果支持机器学习从业者为他们机器学习系统选择最适合的概念漂移检测方法。

Index Terms—energy efficiency, machine learning, concept drift, Green AI, controlled experiment

I. 介绍

越来越多的行业领域采用机器学习 (ML) [?] 来实现高级预测功能。一旦训练了具有足够预测质量的 ML 模型，它就会被集成到一个 ML 组件中，该组件将作为支持 ML 的系统的一部分部署 [?]。然而，由于许多挑战，ML 系统的成功开发，尤其是长期运行需要相当多的专业知识 [?]。在快速发展的领域中，一个特殊的问题是真实世界数据的动态性质。这种现象被称为概念漂移，即由于现实世界现象的基础数据分布中的统计关系发生变化，预测准确性随时间下降 [?]。对于大多数用例，这意味着部署的 ML 模型将不可避免地随着时间的推移而衰减，而无需根据新收集的数据进行定期重新训练。为了确定生产系统中何时发生这种情况，需要复杂的监控功能，这需要开发强大的漂移检测器。到目前为止，已经提出了各种各样的此类技术 [?] 并实现了流行的 ML 框架，例如 `scikit-multiflow`。¹

漂移检测器的主要质量问题显然是它们能够快速正确地识别漂移，这反过来又是通过再训练提高监控模型精度的基础。然而，有证据表明，漂移探测器对支持 ML 的系统消耗的能量有负面影响，[?]，这些系统已经需要大量的能量，导致二氧化碳排放。虽然这些系统也可用于改善环

境的可持续性，例如支持识别水污染物及其回收²的 ML 系统，但其开发和运行产生的排放是一个日益受到关注的问题 [??]。例如，LLaMA [?] 和 Code LLaMA [?] 的训练阶段分别释放了 1,015 吨碳排放量 (tCO₂eq) 和 63.5 吨二氧化碳当量。

由于（重新）训练一个复杂的模型（在我们的上下文中称为基本分类器）会消耗大量的能量 [?]，简单的定期重新训练通常不是一个有利于能源效率的解决方案。取而代之的是，依靠通过监测和仅在必要时进行再培训的知情适应是这个领域的推荐策略 [?]。虽然各种研究人员已经分析了漂移检测器的精度 [??]，但几乎没有证据和细粒度的分析来检查不同漂移检测器对支持 ML 的系统在运行时消耗的能量影响。漂移检测可以通过两种主要方式增加系统消耗的能量：a) 探测器本身消耗的能量，以及 b) 一旦探测器触发警报，通过模型重新训练消耗的能量。第一个实例的单个实例比第二个实例小得多，但这种能量也会在系统运行期间不断消耗，并且可能也用于多个 ML 模型。其次，重新训练 ML 模型的决定会导致大量能源的消耗，这意味着检测器的精度也会间接影响系统级的能源效率。为了在何种条件下使用哪种漂移检测器做出明智的决定，从整体上看待这两个质量属性非常重要。

在这个实验中，我们专注于能源效率与准确性之间的权衡，同时使用各种概念漂移检测器进行再训练决策，并检查它们在合成数据集中的性能。对能耗的探索至关重要，因为它直接影响这些探测器在实际应用中的实际可行性。通过阐明概念漂移检测的能量动力学，本研究旨在为机器学习系统的优化提供有价值的见解，确保其在动态、数据演变场景中的有效性和环境可持续性。机器学习研究人员和从业者可以使用我们的结果来指导他们选择漂移检测器。我们的研究回答了以下研究问题：

RQ1: 精度和能效之间的权衡在不同概念漂移检测器中是如何体现的？

理想情况下，漂移检测器将同时表现出非常好的精度和能源效率。然而，一些探测器也有可能为了精度而牺牲能源效率，反之亦然。我们想分析不同探测器的这种关系。

RQ2: 数据集的类型如何影响这种权衡？

不同类型的数据集可能会改变这种权衡的表现方式，例如，对于突然漂移或逐渐引入的漂移。现有的研究表明，基于不同的漂移数据集 [?]，精度存在差异，因此很自然地假设能量消耗也存在差异。

¹<https://scikit-multiflow.github.io>

²<https://www.cbsnews.com/news/water-reuse-recycling-toilet-to-tap-yuck-factor/>

RQ3: 基分类器的类型如何影响这种权衡?

此外,受监控的 ML 模型(基本分类器)的类型也可能影响结果,先前的研究表明,其准确性 [?]。由于我们还从整体上考虑了重新训练基本分类器的能耗,因此对于不同类型的 ML 模型,这种权衡可能会有所不同。

在以下各节中,我们首先解释了我们研究的必要背景,并介绍了该领域的相关工作。然后,我们描述了详细的实验设计,提供了结果,并讨论了它们的含义。最后,我们评论了对我们研究有效性的威胁并得出结论。

II. 背景及相关工作

A. ML 中的概念漂移

支持 ML 的系统是独特的软件系统,其行为受其应用程序上下文的严重影响 [?]。这种上下文依赖性对保持 ML 模型预测质量提出了挑战,尤其是在面对影响数据分布的非平稳上下文时。我们可以确定影响模型准确性的概念漂移的两个主要原因 [??]。第一个原因是在启用 ML 的系统环境中出现的外部事件。这些事件的示例包括针对特定人口统计数据的营销活动、用户行为的转变以及用户界面的更改。支持 ML 的系统中概念漂移的第二个原因源于数据完整性问题 [?]。这些源于数据管道中的持续更新,这是 ML 工程中动态工作流的一个常见方面。此类更新可能会意外引入错误或错误,例如交换列或使用错误的度量单位表示列,例如,使用英里而不是公里。

分布变化对模型准确性的影响(无论是由于外部事件还是数据完整性问题)都因漂移的严重性和类型而异。我们区分了虚拟漂移(也称为特征漂移或协变量漂移),前者是输入分布 $P(X)$ 的变化,后者是给定输入 $P(Y|X)$ [?] 的目标变量的条件概率分布的变化。虚拟漂移通常具有良性影响,仅当新观测值落入训练分布中不确定或代表性不足的区域时,才会影响预测质量。相反,实际概念漂移总是导致模型准确性下降,因为学习的映射函数不再捕获基本关系。这种差异在图 ?? 中可视化。




Fig. 1: 概念漂移(中)和虚拟漂移(右)的区别,摘自 [?]

概念漂移原因的性质会影响其特征,如突然性或渐进性、严重性、复发性和持续时间 [?]。在设置监控系统和选择概念漂移检测算法时,这些因素是需要考虑的重要因素。例如,数据完整性问题经常导致突然的变化,导致数据分布的即时变化 [?]。相比之下,外部事件往往会导致更渐进的变化,表现为数据分布的缓慢但持续的演变。因此,渐进漂移有开始和结束,之后变化成为永久性的。起点和终点之间的距离称为漂移宽度(见图 ??)。

几十年来,概念漂移一直是数据挖掘界的一个研究课题,导致了各种检测器和缓解方法的发展 [?]。传统上,这些工具是在即时标签反馈的假设下设计的,其中预测的标签在预测后不久就可用。在此假设下,没有必要区分漂移类型。相反,模型精度用作漂移的一般指标,从而可以使用




Fig. 2: 渐进式概念漂移(上)与突然的概念漂移(下),摘自 [?]

单个漂移检测器来分析模型误差以识别分布偏移。在这项工作中,我们专注于具有即时标签反馈的设置,允许漂移检测器通过直接将模型预测与真实标签进行比较来识别任何类型的漂移。

B. 支持 ML 的系统的能耗

近年来,ML 模型和集成它们的系统越来越多地与大量的能源和碳足迹联系在一起。例如,训练基于 transformer 的通用自然语言处理(NLP)模型会导致温室气体排放,其排放量与几辆汽车在其整个生命周期中产生的温室气体排放量相似 [?]。因此, [?] 创造了绿色人工智能和红色人工智能之间的区别。从历史上看,人工智能开发的主要目的是实现高预测质量,而不太关心能源效率(红色人工智能)。另一方面,绿色人工智能的发展意识到人工智能对环境的潜在影响,并试图在不对准确性产生实质性影响的情况下最大限度地减少能源消耗和碳排放。

虽然精度和能效仍然经常被看作是一种权衡 [?],但研究表明,有许多技术可以大大降低能耗,而精度的下降可以忽略不计 [??]。今天,绿色人工智能是一个活跃的研究领域,最近来自 [?] 的综述确定了关于该主题的 98 项主要研究。由于 ML 模型的初始开发通常被认为是 ML 系统生命周期中最耗能的阶段 [?],使 ML 训练更节能受到广泛关注。然而,其他阶段,如支持 ML 的系统的运行,在减少其环境足迹方面也有很大的潜力。在这项研究中,我们重点关注此类系统的连续运行阶段。

C. 相关工作

在软件能耗的探索中,各种研究都考察了不同编程语言 [?]、数据结构 [?]、框架 [??] 的影响。随着人工智能的进步和人工智能系统固有的能源密集型性质,在训练和维护这些系统方面对能源的需求越来越大 [?]。最近的研究对 ML 系统的能耗进行了深入研究,旨在减轻支持 ML 的系统的能源需求 [??]。不同的研究集中在 ML 系统开发各个阶段的能耗上。例如,Verdecchia 等人 [?] 专注于以数据为中心的方法,以最大限度地减少训练期间的能耗。在影响和降低 ML 准确性的数据不断发展的背景下,概念漂移需要模型重新训练 [?]。已经制定了解决漂移检测和管理概念的策略 [?],并且比较研究,例如 Goncalves 等人 [?] 的研究,评估了不同漂移检测器的精度。在漂移检测领域,包括 Barros 等人 [?] 的研究,已经仔细研究了使用不同分类器和数据集的各种方法。然而,这种分析缺乏一个基本指标:能源消耗。我们通过对不同的漂移检测方法进行全面比较来弥补这一差距。在考虑准确性的同时,我们的主要关注点集中在分析准确性和能量

之间的权衡，阐明这些不同检测方法的能源效率。据我们所知，到目前为止，还没有其他研究详细考虑过这种权衡。

III. 实验设计

我们设计了一个对照实验来回答我们的研究问题 [?]。在本节中，我们将描述与该研究方法相关的重要细节，即我们的实验对象（概念漂移检测器、数据集和基分类器）、实验变量、实验执行和数据分析。

A. 概念漂移检测器

对于流行的 ML 框架，已经研究和实施了许多不同的概念漂移检测方法。由于所选框架也可能影响能耗，因此专注于单个框架非常重要。因此，为了进行准确的比较，我们选择了 `scikit-multiflow`³ 中实现的所有七个概念漂移检测器：ADWIN、DDM、EDDM、HDDM-A、HDDM-W、KSWIN 和 PageHinkley。这些方法在相同的流行 ML 框架 `scikit-learn`⁴ 中使用，也是概念漂移研究中最常用的检测器之一 [?]。他们还采用可能影响其能源消耗的合理不同的策略。为了公平地进行比较，我们实现了每个探测器的默认配置。我们在下面简要介绍每个探测器。有关详细信息，请参阅每个探测器的官方文档。⁵

- ADWIN（自适应窗口）根据统计度量动态调整其窗口大小。它监控传入数据的平均值和方差，以检测渐进和突然概念漂移的变化。
- DDM（漂移检测方法）是一种基于性能测量标准差的统计方法，用于识别变化。当偏差超过预定义阈值时，它会触发警报。
- EDDM（指数加权移动检测方法）通过将权重呈指数递减的权重分配给较旧的实例来扩展 DDM。它优先考虑最近的数据，同时对噪音具有鲁棒性。
- HDDM_A（Hoeffding 漂移检测方法 - 自适应）是 Hoeffding 方法的自适应版本，使用 Hoeffding 边界来检测数据分布变化并根据观察到的方差调整灵敏度。
- HDDM_W（Hoeffding’s Drift Detection Method - Window）是 Hoeffding 方法的基于窗口的改编。它维护一个固定大小的窗口，以使用 Hoeffding 边界监控均值变化。
- KSWIN（Kernelized Sliding Window INterval）使用滑动窗口将内核函数应用于数据。它监控估计的核密度是否有重大变化。
- PageHinkley 计算预期值和观测值之间的累积差值总和。当累积总和超过预定义的阈值时，它会触发警报。

B. 数据

为了将我们的实验与以前的工作联系起来，我们选择了哈佛 Dataverse⁶（研究数据的公共存储库）中提供的五个流行的合成数据集。这个漂移数据集集合是由 [?] 通过流生成器整理的。2024 年 1 月，它已累计下载超过 7,600 次。这些数据集已被用于类似的研究 [?]，并具有渐进和突然的概念漂移。为了将一些多样性纳入我们的实验中，我们从集合中选择了五个不同的数据集：

³<https://scikit-multiflow.github.io>

⁴<https://scikit-learn.org>

⁵https://scikit-multiflow.readthedocs.io/en/stable/api/api.html#module-skmultiflow.drift_detection

⁶<https://dataverse.harvard.edu>

- `sine`：两个数值属性（X1 和 X2），其中类是根据正弦函数分配的
- `stagger`：三个标称属性（X1、X2 和 X3）
- `mixed`：两个数值属性（ x_1 和 x_2 ）和两个布尔属性（ x_3 和 x_4 ）
- `sea`：三个数值属性（ x_1 、 x_2 和 x_3 ）
- `RT`：两个数值属性（ x_1 和 x_2 ）

五个数据集中的每一个都有两个版本：一个是突然漂移的，另一个是渐进漂移的。值得注意的是，数据集创建者在三个位置将概念漂移引入到每个数据集中。在每个位置，即在每次出现概念漂移时，分类都是相反的，或者换句话说，条件概率 $P(Y|X)$ 变化。每个突发数据集由 40,000 个实例和渐变数据集 41,000 个实例组成。漂移按特定时间间隔定位：10,000、20,000 和 30,000 个实例用于突然漂移数据集，9,500、20,000 和 30,500 个实例用于渐进漂移数据集。渐进漂移的宽度为 1,000，即漂移从时间步长 9,500 左右开始，并在 1,000 个实例中增加，涵盖从 9,500 到 10,500 的范围。同样，另一个逐渐漂移发生在时间步长 20,000 左右，涵盖从 20,000 到 21,000 的实例。第三个渐进漂移从时间步长 30,500 左右开始，涵盖从 30,500 到 31,500 的实例。与无法客观确定概念漂移的精确起点的真实数据集相比，漂移的人工放置有助于评估概念漂移检测器的受控环境，从而简化结果的比较。这种预定义的漂移位置特别有利，为评估精度和能耗之间的权衡提供了清晰一致的基础。

C. 基本分类器

对于漂移检测器比较，我们还需要 ML 模型作为基本分类器来预测传入数据流的类别，并将其与正确的类别进行比较。在类似的研究中，通常使用两种 ML 算法作为基本分类器：朴素贝叶斯和决策树。由于这些分类器在能效方面有所不同，我们还想了解它们对漂移检测器和整体能耗的影响，其中包括模型的重新训练。因此，除了朴素贝叶斯和决策树之外，我们还选择了另外五个分类器，这些分类器在之前的工作中已经研究过 [?]，因为它们训练阶段的能效。我们想调查在处理概念漂移时，以前的发现是否对这些分类器有效。包含的六个分类器是支持向量机（SVM）、Hoeffding Tree、k 最近邻（KNN）、随机森林、AdaBoost、袋装分类器。

这种选择为分析在这种情况下下的能源消耗提供了相当多的多样性。对于每个分类器，我们使用具有默认配置的 `scikit-learn` 实现。有关每个分类器的更多详细信息，请参阅官方文档。⁷ 请注意，我们有意识地专注于更传统的机器学习算法，而排除了深度学习。虽然不同的神经网络架构也是此类分析的有趣候选者，但它们超出了本研究的范围。

D. 实验变量

我们专注于两个因变量的比较：

- 能耗以焦耳（J）为单位；这包括漂移检测器消耗的能量，以及检测到漂移时对基本分类器的重新训练。
- 每个漂移检测器的检测精度；如果探测器正确识别了窗口内的漂移（新概念的开始到概念的结束），我们将其记录为真正的警报。关于窗外漂移的警告被记录为误报。我们计算了真实报警百分比。对于真正的警报，

⁷https://scikit-learn.org/stable/supervised_learning.html

我们还计算检测到漂移的速度，即漂移开始与检测到漂移的实例之间的距离。

基于我们的实验对象，我们操纵了几个自变量，以了解它们如何影响因变量：

- 漂移检测器：ADWIN, DDM, EDDM, HDDM_A, HDDM_W, KSWIN, PageHinkley
- 数据集：正弦波、混合波、RT、海波、交错
- 漂移类型：突然、渐进
- 基本分类器：朴素贝叶斯、SVM、决策树、KNN、随机森林、AdaBoost、袋装分类器

不同的漂移检测器是我们操纵 RQ1 的主要自变量（处理）。对 RQ2 的合成数据集和漂移类型进行操作，基分类器操作回答 RQ3。由于这项研究本质上是探索性的，我们没有任何先入为主的假设来证实。

E. 实验执行

基于不同的自变量，我们选择了全因子设计 [?]，这意味着我们有一个 7 个漂移检测器 \times 5 个数据集 \times 2 种漂移 \times 6 个基本分类器（420 种组合）的实验空间。对于每个组合，我们遵循以下步骤，这些步骤构成了我们实验中的一次迭代：

- 1) 在数据集的前 8.5k 实例上训练初始基分类器。
- 2) 记录能耗和准确性。
- 3) 预测数据集其余实例的标签。
- 4) 将每个预测和真实标签分别传递给漂移检测器。
- 5) 如果检测到漂移，则停止检测并记录漂移位置和消耗的能量，以便进行漂移检测。
- 6) 计算从 10k 到漂移位置的数据的基本分类器精度。
- 7) 将数据集上的基分类器从 0 重新训练到漂移位置，并记录能量和精度。

在实验开始之前，在数据收集开始之前，执行了预热功能以稳定系统并优化其性能。为了尽量减少实验基础设施中非确定性和潜在波动的影响，例如，其他过程短暂地消耗比平时更多的能量，每次迭代重复 10 次。此外，在每次迭代之间加入了 5 秒的睡眠间隔，以确保基础设施条件可以恢复到更接近初始状态。这些措施共同提高了我们实验框架的可靠性，从而可以对机器学习中概念漂移检测器的能耗进行全面可靠的评估。

对于实验工具，我们用 Python 编写了几个脚本，Python 是数据和 ML 从业者事实上的标准语言，它自动化了上述整个过程。为了估算能耗，我们使用了 CodeCarbon 软件包。⁸ 虽然 CodeCarbon 不如基于硬件的测量精确，但事实证明它仅低报了几个百分点 [?]，两种测量之间的相关性非常强 ($\rho = 0.94$)。因此，当研究的重点是比较几种变体之间的能耗差异时，使用基于软件的估算工具（如 CodeCarbon）是公认的做法。完整的可重现代码在我们的工件存储库中公开提供。⁹ 我们对位于我们大学的软件能量实验的专用实验基础设施进行了研究。该基础架构包含一台配备 36 TB HDD、384 GB RAM 和 Intel Xeon CPU（包括 16 个内核的超线程运行频率为 2.1GHz）（即 32 个 vCPU）的服务器。在实验执行期间限制了对服务器的访问，以防止不必要的额外负载。

⁸<https://codecarbon.io>

⁹<https://doi.org/10.5281/zenodo.10613150>

F. 数据分析

作为第一步，我们用 Shapiro-Wilk 检验 [?] 评估了结果分布的正态性。所得结果表明，数据表现出非正态分布特征，p 值为 $\leq 5.6e-45$ 。为了比较和识别各种漂移检测器之间能耗的显著差异，我们采用了 Mann-Whitney U 检验 [?]，它可以处理这种分布。为了比较影响的幅度，我们计算了不同漂移探测器的平均能耗值之间的百分比差异。此外，计算 Cohen 的 d 值是为了更全面地理解效应大小 [?]。在探索漂移类型的影响时，我们进行了与用于比较漂移检测器的测试类似的测试。由于我们进行了多次成对假设检验，因此使用 Holm-Bonferroni 校正来应对多元比较问题 [?]。为了研究基分类器对漂移检测器能耗及其精度的影响，我们应用了 Spearman 相关检验 [?]。

IV. 结果

在本节中，我们根据研究问题介绍了实验结果。

A. RQ1: 精度和能效之间的权衡在不同概念的漂移检测器中是如何体现的？

我们深入研究了各种概念漂移探测器的能耗，结果如图 ?? 所示，揭示了它们之间的几种变化。值得注意的是，对于突然漂移和渐进漂移，最耗能的方法是 KSWIN。紧随其后的是 ADWIN，作为第二高的能源消耗者，而其余的探测器显示出不同程度的能源消耗，尽管差异不那么明显。

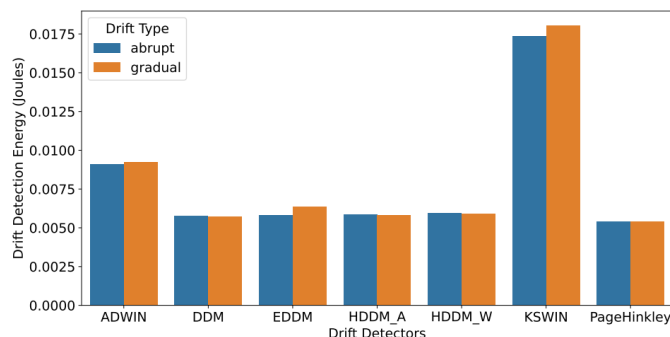


Fig. 3: 不同漂移检测器和漂移类型的能耗




Fig. 4: 真实报警百分比与能耗的关系

TABLE I: 探测器能耗的成对 Mann-Whitney U 检验 (Holm-Bonferroni 调整的 p 值, $\alpha = 0.05$, 粗体的显着 p 值)

Detector 1	Detector 2	p-value	Detector 1 Mean	Detector 2 Mean	Difference (%)	Cohen's d
KSWIN	PageHinkley	0.00013	0.0181	0.0055	69.8	7.53
KSWIN	HDDM_A	0.00015	0.0181	0.0058	67.7	7.20
KSWIN	DDM	0.00011	0.0181	0.0059	67.6	7.24
KSWIN	EDDM	0.00012	0.0181	0.0060	67.0	6.82
KSWIN	HDDM_W	0.00013	0.0181	0.0060	67.0	7.16
KSWIN	ADWIN	0.00014	0.0181	0.0091	49.4	4.97
ADWIN	PageHinkley	0.00034	0.0091	0.0055	40.2	6.16
ADWIN	HDDM_A	0.00022	0.0091	0.0058	36.2	5.15
ADWIN	DDM	0.00024	0.0091	0.0059	35.9	5.20
ADWIN	HDDM_W	0.00030	0.0091	0.0060	34.7	5.07
ADWIN	EDDM	0.00026	0.0091	0.0060	34.7	3.98
PageHinkley	EDDM	0.00048	0.0055	0.0060	8.5	1.25
PageHinkley	HDDM_W	0.00060	0.0055	0.0060	8.5	1.47
PageHinkley	DDM	0.00040	0.0055	0.0059	6.7	0.90
HDDM_A	PageHinkley	0.00020	0.0058	0.0055	6.3	1.16
HDDM_A	EDDM	0.00017	0.0058	0.0060	2.3	0.44
HDDM_A	HDDM_W	0.00018	0.0058	0.0060	2.3	0.23
EDDM	DDM	0.00238	0.0060	0.0059	0.9	0.57
HDDM_W	DDM	0.00079	0.0060	0.0059	0.9	0.41
HDDM_A	DDM	0.00016	0.0058	0.0059	0.4	0.19
HDDM_W	EDDM	0.00119	0.0060	0.0060	0.0	0.28




Fig. 5: 漂移检测接近度, 实现真实报警与能耗的关系

这些发现通过统计分析得到进一步证实, 采用 Mann-Whitney U 检验, 使用 Holm-Bonferroni 方法调整 p 值。对所有探测器的总能耗差异进行成对测试, 每次比较都存在显著差异。为了量化每对方法之间的差异程度, 我们计算了百分比差异和 Cohen 的 d 值。KSWIN 和 PageHinkley 之间的最大差异 (69.78 %), 这意味着使用 KSWIN 比 PageHinkley 多消耗近 70 个% 的能量, 效应量非常大, 为 $d = 7.53$ 。同样, KSWIN 比 ADWIN 多消耗 49.44 % 的能量。在频谱的另一端, HDDM_W 和 EDDM 之间的差异最小, 总计仅为 0.02 %。DDM、DDM_A 和 DDM_W 以及 EDDM 表现出相对相等的能耗, 差异低于 2.3 %。因此, DDM、DDM_A、DDM_W 和 EDDM 之间的效应

大小很小, 因为它们的 Cohen d 值低于 0.5。有关检验和方法间平均差异的详细信息见表 ??。

在这些实验中, 记录了漂移位置, 从而能够评估警报与实际漂移位置相关的准确性。这涉及计算真警报的百分比、误报的数量和错过的警报。此外, 还量化了检测到的漂移与实际漂移位置的相对接近程度, 其值范围在 0 和 1 之间, 即接近值越高, 检测到的漂移位置与实际开始漂移位置之间的距离越小。接近 1 的值表示检测器识别漂移的速度非常快, 而接近 0 的值表示检测非常晚。这些结果显示在 Table ?? 中。在精度方面, KSWIN 成为突然漂移场景中表现最好的方法, 具有令人印象深刻的 93 % 真实报警率和 0.998 的接近度。然而, 对于渐进漂移, 其性能明显较差 (57 %, 0.804)。在这些场景中, HDDM_W 位居第一 (60 %, 0.838)。它在突然漂移方面同样具有良好的性能 (59.7 %, 0.873), 使其成为一种平衡且性能最佳的方法。相当平衡的 ADWIN 排在第三位。它在渐进漂移场景 (58.3 % vs. 50.7 %) 中的表现略好于突然漂移场景 (50.7 %, 0.843)。有趣的是, 根据我们的结果, 所有其他四种方法 (HDDM_A、PageHinkley、DDM、EDDM) 都可以被认为对生产系统毫无用处。尽管其中一些方法对真警报的检测接近度不错, 但在所有情况下, 它们的总体真实报警率都低于 10 %。效果最差的方法是 EDDM。考虑到漏报, 我们观察到在漂移检测接近度和真报警百分比方面表现最好的方法在最大限度地减少漏报方面也表现出色。重要的是, 结果强调缺乏一种在所有比较指标上都表现出色的单一方法。重要的是要承认, 这种比较是笼统的, 没有考虑所使用的特定数据集或基分类器。漂移类型和基本分类器的细微影响在 RQ2 和 RQ3 中得到了更详细的审查。

TABLE II: 漂移检测器对突然和渐进漂移的精度（按真实报警百分比排序）

Drift Detector	Drift Type	# of True Alarms	# of False Alarms	# of Missed Alarms	True Alarm %	Mean Detection Closeness
KSWIN	abrupt	279	21	0	93.0	0.998
HDDM_W	gradual	180	120	0	60.0	0.838
HDDM_W	abrupt	179	121	0	59.7	0.873
ADWIN	gradual	175	118	7	58.3	0.830
KSWIN	gradual	171	129	0	57.0	0.804
ADWIN	abrupt	152	136	12	50.7	0.843
HDDM_A	gradual	24	243	33	8.0	0.734
PageHinkley	abrupt	23	259	18	7.7	0.849
HDDM_A	abrupt	21	240	39	7.0	0.679
PageHinkley	gradual	19	252	29	6.3	0.779
DDM	gradual	18	240	42	6.0	0.679
DDM	abrupt	10	252	38	3.3	0.711
EDDM	gradual	4	223	73	1.3	0.435
EDDM	abrupt	2	242	56	0.7	0.365

Answer to RQ1: KSWIN trades off energy efficiency for very good detection accuracy. It consumes by far the most energy. ADWIN shows good detection accuracy and requires less energy, but still more than the remaining detectors. The most balanced detector is HDDM_W, which consumes little energy with very good detection accuracy. The remaining four detectors consume even less energy, but are useless from an accuracy perspective ($< 10\%$).

B. RQ2: 漂移类型如何影响这种权衡？

图 ?? 中两种漂移类型能量消耗的直观比较表明，三种漂移检测器（KSWIN、EDDM 和 ADWIN）在渐变漂移中消耗的能量似乎比在突然漂移时消耗的能量更多。为了验证这些视觉观察结果，进行了 Mann-Whitney U 检验，并计算了每个漂移探测器的百分比差异和 Cohen's d。结果显示在 Table ?? 中。

具体而言，EDDM 在渐变漂移和突然漂移之间表现出最大的差异，渐变漂移消耗的能量增加了 8.3%。这种差异在 Cohen's d 为 0.77 时显著，表明中等到大效应。对于 KSWIN，该测试还产生了显著的 p 值，渐变漂移比突然漂移多消耗 4 个% 的能量。这种差异导致 Cohen's d 为 0.32，表示效应量较小。虽然 ADWIN 也显示出差异，渐变漂移比突然漂移多消耗 1.7% 的能量，但该测试在统计学上并不显著。其余四个检测器也是如此，其中突然漂移和渐变漂移之间的差异在 0.2 和 0.5% 之间。进行了进一步的、更细粒度的分析，以分析数据集生成器和基分类器之间的这种差异。即使对于这些条件，研究结果也表明，在指定的探测器中，渐变漂移平均消耗的能量往往略高于突然漂移。尽管如此，也有一些情况恰恰相反，例如 KSWIN 使用决策树基分类器检测突然漂移，以及使用混合生成器生成的数据集。复制包中提供了详细结果。

关于漂移类型对精度的影响，表 ?? 已经表明，大多数探测器在渐变漂移时达到了更好的真实报警率。值得注意的例外是 PageHinkley 和 KSWIN，后者在渐变漂移方面

的表现要好得多（93% 对 57%）。然而，当成功检测漂移时，除了 EDDM 和 HDDM_A 的情况外，突然漂移的检测接近度通常更好。

Answer to RQ2: We find that most drift detectors consume almost the same amount of energy for both types of drift, with gradual drift showing a tendency for slightly more energy consumption than abrupt drift. Exceptions were EDDM and KSWIN, which both consume significantly more energy when detecting gradual drifts, namely 8.3% for EDDM and 4.0% for KSWIN. In terms of detection accuracy, most detectors perform better with gradual drifts than abrupt ones, except for KSWIN and PageHinkley.

C. RQ3: 基分类器的类型如何影响这种权衡？

为了探索这种关系，我们采用了 Spearman 秩相关检验来评估所用碱基分类器与漂移检测器的能耗之间是否存在统计学上的显著相关性。分析结果表明，根据收集的数据，基分类器的选择与漂移检测器的能耗之间没有明显且具有统计学意义的相关性。复制包中提供了详细信息，包括测试结果的综合表。

此外，为了进一步了解漂移检测接近度与基分类器选择之间的相互作用，我们还应用了 Spearman 秩相关检验。检验结果表明，这两个因素之间也没有显著的相关性，最小 p 值为 0.122。这一发现支持了这样一种观点，即所选的基分类器不会显著影响漂移检测的接近度。可以在复制包中探索更多详细信息，该包提供了测试结果的全面概述。

Answer to RQ3: The choice of base classifier does not have a significant impact on the energy consumption and drift detection closeness of various drift detectors.

TABLE III: 漂移类型的能耗 Mann-Whitney U 检验 (Holm-Bonferroni 调整后的 p 值, $\alpha = 0.05$, 以粗体显示的显著性 p 值, 按效应大小排序)

Detector	Type 1	Type 2	p-value	T1 Mean	T2 Mean	Difference (%)	Cohen's d
EDDM	abrupt	gradual	2.61E-17	0.0058	0.0064	8.3	0.77
KSWIN	abrupt	gradual	2.30E-07	0.0173	0.0181	4.0	0.32
ADWIN	abrupt	gradual	5.02E-01	0.0091	0.0093	1.7	-
DDM	abrupt	gradual	1.00E+00	0.0058	0.0057	0.5	-
HDDM_A	abrupt	gradual	1.00E+00	0.0059	0.0058	0.4	-
PageHinkley	abrupt	gradual	1.00E+00	0.0054	0.0054	0.2	-
HDDM_W	abrupt	gradual	1.00E+00	0.0059	0.0059	0.2	-

V. 讨论

根据我们的结果, 如图 ?? 和图 ?? 所示, 我们可以将我们研究的探测器分为三种类型: a) 为了检测精度而牺牲能源效率的探测器 (KSWIN), b) 消耗低到中等能量且精度高的平衡探测器 (HDDM_W, ADWIN), 以及 c) 消耗很少能量但由于精度非常差而在实践中无法使用的探测器 (HDDM_A, PageHinkley, DDM, EDDM)。从绿色 AI 的角度来看, 最引人注目的节能漂移检测选项是 HDDM_W, 它在高精度和低能耗之间取得了平衡。它在渐进漂移场景中表现出色, 将近距离漂移位置检测与良好的真实报警率相结合。与之前的工作类似 [??], HDDM_W 是另一个很好的例子, 即 ML 从业者并不总是必须在准确性和能效之间做出选择, 并且在许多 ML 用例中, 这两个质量属性之间没有或只有可以忽略不计的权衡。另一方面, KSWIN 在突然漂移方面实现了最高的精度, 但其显著更高的能耗使其吸引力降低。有趣的是, 即使对于突然漂移, HDDM_W 也能提供显著的 67% 节能, 同时保持良好的精度。一般而言, 预期的漂移类型应略微影响探测器的决策, 例如, 在选择 KSWIN 以最好地防止可能发生的突然漂移的情况下, 但远低于预期。同样, 在选择检测器时, 基分类器的类型根本不应该起作用, 至少在我们传统的 ML 算法的上下文中是这样。

虽然没有研究可以将我们的能源效率结果进行比较, 但有关检测精度的结果可以与相关工作进行比较。在另一项关于不同基于误差的漂移检测方法的准确性的研究中, 发现 ADWIN 在漂移位置接近度和误报率方面表现最好 [?]。我们的结果是相似的, 但区别在于我们的研究包括了 scikit-multiflow 中实施的所有基于错误的漂移检测方法, 而上述研究不包括 KSWIN, KSWIN 是我们在突然漂移场景中准确性表现最好的方法。ADWIN 和 HDDM_W 在精度指标上表现出相似的性能, 但与 ADWIN 和 KSWIN 相比, HDDM_W 也是一种节能方法。

尽管在高可伸缩性方案中, 每个检测实例的能耗至关重要, 但考虑其他因素也至关重要。漂移位置的接近度直接影响能源使用。与 PageHinkley 等低能耗方法相比, KSWIN 等早期漂移检测可以节省能源, 尽管每个实例的消耗较高, 但漂移检测精度较低。误报率的增加也可能导致更频繁的模型重新训练, 从而由于重新训练间隔的缩短而增加能耗。如果我们考虑到, 例如, 训练 OpenAI 的 GPT-3 一次会产生 552 tCO₂ 并消耗 1,287 MWh [?], 那么这个数量可能很重要。这种能源可以为一个普通的美

国家供电 120 年。因此, 从绿色人工智能的角度来看, 误报比错过的报警要糟糕得多。

然而, 虽然误报可能导致不必要的再培训, 增加能源消耗, 但可以通过优化再培训间隔或采用减少误报的技术来减轻其影响。此外, 真实场景通常缺乏完整的信息, 如真实标签和窗口大小, 因此需要基于数据分布的漂移检测。调查他们的能源消耗仍然是一个开放的领域。此外, 漂移宽度会影响性能 [?]。虽然我们的研究使用了相等的长度, 但探索不同漂移长度对能耗的影响将提供有价值的见解。重要的是, 我们的研究结果支持以下结论 [?], 即由于真实报警率低, 基于错误的漂移检测作为报警系统可能不可靠。

VI. 对有效性的威胁

内部效度由于执行连续迭代对我们的测量的潜在影响, 例如由于硬件温度升高, 我们的实验中可能出现了与历史因素相关的内部效度的潜在挑战。为了解决这个问题, 我们通过在每次实验迭代前引入 5 秒的睡眠操作来实施措施。这确保了所有运行的硬件条件更加一致。同样, 进行了预热操作, 以确保初始迭代在与后续迭代非常相似的条件下进行, 从而减轻了对我们测量的潜在影响。作为对测量可靠性的威胁, 实验执行过程中后台任务的存在可能成为混杂因素, 从而影响我们的能量测量。为了解决这个问题, 我们采取了先发制人的措施, 终止了对执行实验不是必需的进程, 并限制了对基础设施的访问。此外, 我们每个实验进行了 10 次, 以尽量减少任何不可预见的后台过程的影响。

关于我们研究结果的普遍性, 我们仔细选择了具有两种主要概念漂移类型的数据集。这些数据集是使用五个合成数据集生成器生成的。除了选择两个常用的碱基分类器外, 我们还引入了四个额外的碱基分类器, 以增强我们研究的多样性。选择已知漂移位置的合成数据集, 便于轻松比较各种方法的准确性。这种对数据集和分类器的深思熟虑的选择有助于对所检查方法的普遍性和有效性进行更有力的评估。

可靠性为了确保我们研究的可重复性, 我们已使复制包可在线访问。¹⁰ 在不同的硬件上运行实验产生了一致的结果, 加强了我们的研究结果的可靠性, 并为结果的稳健性提供了保证。仅仅依靠一种名为 CodeCarbon 的工具可能会威胁到我们实验的结构有效性。为了降低这种风险, 我们采取了两个步骤。首先, 我们利用其开源特性来检查其实现, 并验证其在 Linux 上使用 RAPL 来收集能源数据。其

¹⁰<https://doi.org/10.5281/zenodo.10613150>

次，我们在两个不同的系统上运行实验，以确认一致的结果。

VII. 结论

本研究考察了各种概念漂移检测器中精度和能效之间的权衡。研究结果显示，没有一种方法在所有指标上都表现出色。KSWIN 和 ADWIN 是最耗能的探测器，而 PageHinkley 是最节能的。另一方面，KSWIN 在突然漂移检测方面表现最好，而 HDDM_W 在渐进漂移检测方面表现最好。漂移类型会影响漂移探测器的能量消耗，对于三种探测器 (KSWIN、EDDM 和 ADWIN)，渐进漂移往往比突然漂移消耗更多的能量。漂移类型也会影响漂移检测器的精度，渐进漂移在真实报警率和漂移位置接近度方面通常表现更好。基本分类器不会显著影响漂移检测器的能耗或精度。

未来的研究有几种途径可以建立和扩展我们的结果。

- 包括更多的漂移检测器，可能在其他库中实现
- 针对各种神经网络架构复制研究，而不是使用更传统的 ML 算法
- 研究在线学习环境中准确性和能源效率之间的权衡

在这项研究中，我们重点关注即时标签反馈的情况，即在做出预测后立即收到标签。这种情况是近年来概念漂移研究中最突出的 [?]。我们的研究全面了解了为这种情况开发的方法中的准确性与能效权衡。然而，在实际环境中，标签通常不存在或延迟。这一现实引发了对检测由概念漂移引起的模型性能问题的新方法的研究，特别是通过各种性能估计技术 [???]。在未来的工作中，我们的目标是扩大我们的研究范围，包括标签反馈延迟和缺失的场景，为从业者提供关于监控 ML 模型的准确性与能效权衡的更全面的见解。