基于增量数据的自监督活动表征学习：实证研究

Jason Liu§、Shohreh Deldari§、Hao Xue §、Van Nguyen§§、Flora D. Salim§§ 新南威尔士大学计算机科学与工程学院（UNSW），澳大利亚§§ 国防科学技术组，澳大利亚 电子邮件：jason.liu3@student.unsw.edu.au，{s.deldari、hao.xue1、flora.salim}@unsw.edu.au 以及 van.nguyen5@defence.gov.au

arXiv:2305.00619v1 [cs.LG] 1 May 2023

摘要——**在移动感知环境中，移动设备上的各种传感器持续产生海量数据。分析这些不断增长的数据面临诸多挑战，包括获取标注数据的机会有限以及环境持续变化。近年来，自监督学习取得的进展已被用于预训练，以提升传统监督模型的性能，从而应对带标签数据集缺失的问题。本研究考察了在数据逐步可用的时间序列分类任务中，采用自监督表征学习模型的影响。我们提出并评估了一种工作流程：模型先利用无标签时间序列数据语料学习提取信息丰富的特征，再使用模型提取的特征对带标签数据进行分类。我们在四个公开数据集上分析了无标签数据的规模、分布和来源变化对最终分类性能的影响，这些数据集涵盖了不同应用中的多种传感器类型。**

索引词—**自监督表征学习、增量学习、移动感知、活动识别**

I. 引言

在现实世界场景中，由于隐私问题、缺乏领域知识，或时间和预算限制等各种因素，获取大量带标签数据需要耗费大量时间和精力。因此，传统的基于监督学习的人工智能方法并不适用。近年来，自监督学习(SSL)技术不断发展，能够泛化到各种任务、数据领域和输入结构 [10], [21], [24]。作为一种自监督学习技术，自监督表征学习（SSRL）通常使用未标注数据，通过基于原始数据点构造样本对及其对应的伪标签，再据此训练模型，以学习数据的结构。现有研究着重探讨如何尽可能少地使用带标签数据，同时实现与使用全部带标签数据相当的性能 [8], [12]。

尽管近期已针对各种应用研究了传感器的自监督学习 [4], [6], [8], [14]–[20], [23], [24]，但目前尚未应用于无法一次性获取所有数据的情形。因此，输入数据的动态变化（例如遇到新的任务和类别、分布变化等）可能导致模型失去其最优性。增量学习是指机器学习模型随时间推移学习并适应新信息的能力。这要求模型保留过去的知识。同时能够纳入新信息，并对之前未见过的数据进行预测。我们假设，自监督表征学习模型可以利用大量可用的未标注数据来提升其特征提取能力和分类性能，这与监督分类器可以利用增量数据来提升在现有任务和新任务上的性能类似 [13], [22]。

本研究主要关注的问题是：随着训练数据增多，采用自监督表征学习模型的预训练阶段是否会得到改善。我们考虑了多种场景来回答这一问题。例如，我们希望了解，在预训练阶段使用更多数据是否能提高下游分类准确率；此外，当预训练所用的数据集与待分类数据来自同一数据集，还是来自测量内容相似但采集背景不同的数据集时，准确率是否会有所差异。

持续学习（CL）旨在利用随时间不断产生的数据，在计算和内存资源保持不变的情况下，逐步构建关于研究领域的更复杂知识。任何持续学习框架面临的主要挑战都是解决灾难性遗忘问题，即神经网络模型在使用新数据进行拟合时，往往会忘记先前学到的信息。已有不少研究探讨了持续学习中的表征学习，涉及图像、语音和文本等不同数据类型。然而，据我们所知，针对时间序列分类，尚无研究探讨如何利用增量数据改进预训练阶段使用的自监督表征学习模型。本研究探讨了基于增量数据的自监督学习（SSL）对时间序列数据（具体而言，可穿戴传感器数据）的影响。本文的主要贡献如下：

- 我们在三个知名的公开人体活动识别数据集上，研究了自监督表征学习在增量训练设置中的作用。我们提供了一个训练与评估框架，用于评估自监督表征学习模型在实例增量和类别增量持续学习场景中带来的改进。

- 我们研究了使用来自各种领域和分布的数据训练编码器和分类器的效果。

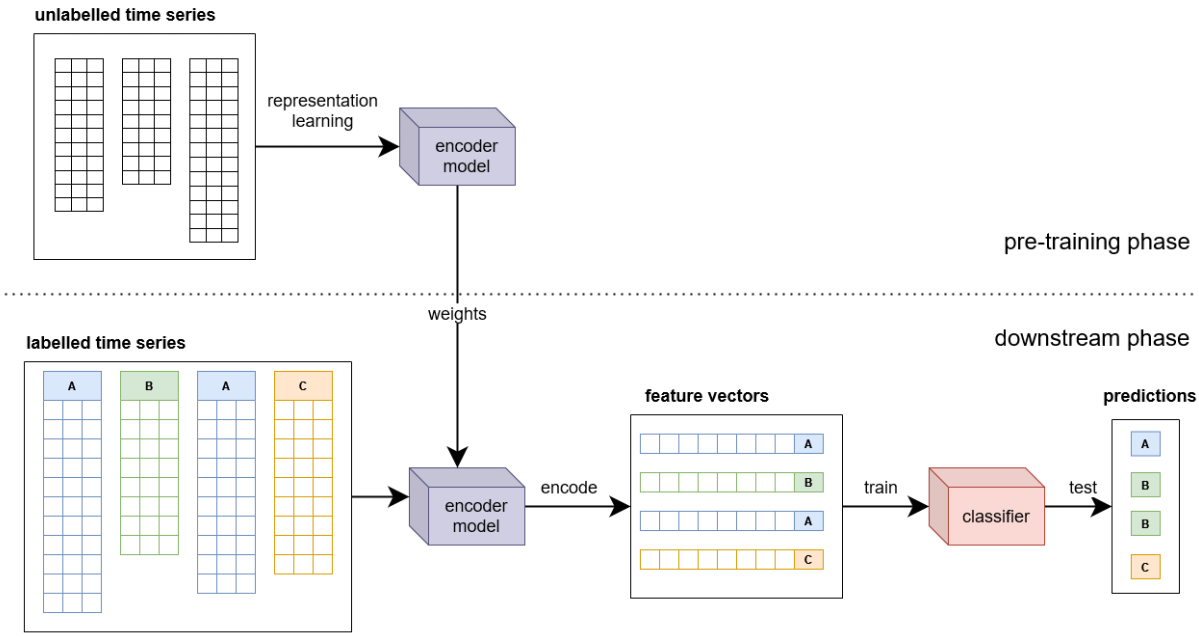

图 1. 工作流程概览。未带标签的时间序列数据用于在预训练阶段训练编码器模型，随后在下游阶段用于从带标签数据中提取特征，并作为下游分类器的输入。

- 我们评估了自监督表征学习在低标签数据场景中的有效性。

II. 研究空白

过去几年，研究者针对少量带标签数据下的自监督表征学习开展了大量研究，旨在使其在计算机视觉 [3], [9], [11],自然语言处理 [7],移动与泛在传感器数据 [4], [6], [21], [24]等不同领域中保持与监督学习方法相当的性能。 [5] 全面综述了不同模态下的自监督学习方法。然而，自监督学习模型学习未见数据的能力，以及提升现有持续学习框架的性能、使其能够适应并持续从新的、不断变化的数据中学习的能力，仍有待探索 [9]。

Li 等人从理论和实证两方面阐明了持续表示学习的优势，并揭示了任务顺序、多样性和样本量的作用。他们还提出了一种新的持续学习算法 ESPN [16]，用于学习高质量的图像表示。大量实验评估表明，该算法不仅能取得良好的准确率，推理速度也很快。Hsu 等人开展了首项受控研究，以更好地理解自监督学习在自动语音识别中的领域偏移 [15]。结果表明，加入未标注的域内数据能够提升性能，即使微调数据与测试领域不匹配也是如此。在多个领域上训练的自监督表示具有较强的鲁棒性，并能在预训练和微调期间完全未曾见过的领域上实现更好的泛化性能。我们将探究其他数据类型中的发现是否也适用于时间序列数据。

III. 方法

我们的研究旨在探索如何以自监督方式利用大量无标签时间序列数据，在输入数据和类别逐步提供的现实场景中提升监督模型的分类准确率。具体而言，我们旨在确定表示学习模型能否从逐步到来的无标签数据中受益，以及为此采用持续学习（CL）策略是否值得。我们专注于时间序列分类，并希望了解自监督表征学习对这项任务的影响。

A. 研究框架

如图 1 所示，所提出的框架处于多个研究领域的交叉点：我们探究在时间序列分类的背景下，利用增量数据为自监督表征学习模型带来的潜在益处。在研究中，我们首先使用不同规模、分布和领域的无标签数据对表示学习模型（编码器）进行预训练。在此步骤中，我们采用 *TS2Vec* [24]，，这是一种用于时间序列数据的最先进的自监督学习模型，作为编码器骨干网络。预训练是指在无标签（或移除标签）数据上拟合编码器模型，以学习其特征的过程。在下一步中，根据最终任务，编码器可以直接使用，也可以与下游分类器一起进行微调。编码器的主要目的是将高维输入数据映射为低维特征向量，以表示输入所属的类别。为评估增量预训练的影响，我们为每个阶段分别保留独立的训练集。我们探究

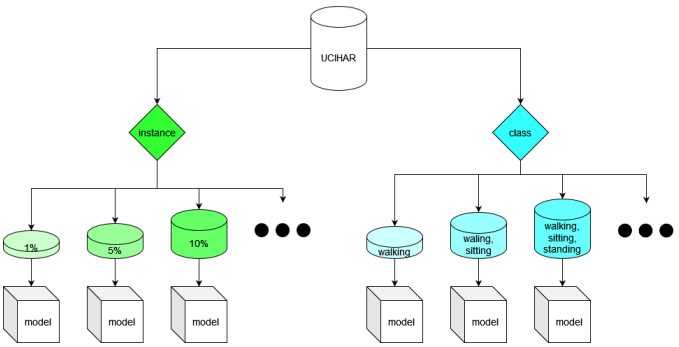

图 2. UCIHAR 的增量预训练数据设置。在实例增量设置中，模型针对不同比例的实例进行训练。在类别增量设置中，模型针对不同数量的类别进行训练。

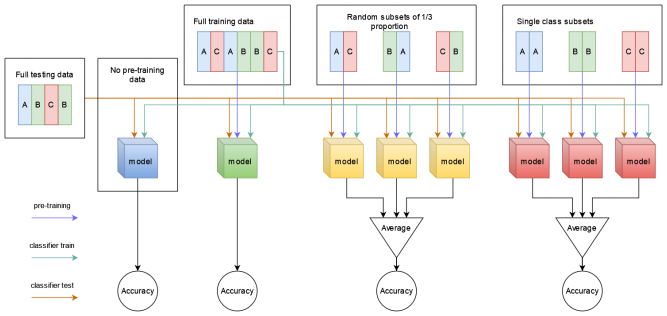

图 3. UEA 数据集研究的工作流程。将完整训练数据随机划分为多个子集，子集大小根据数据集中的类别数量确定，同时还创建了单一类别子集。这些子集用于预训练编码器模型，并与未使用预训练数据以及使用完整预训练数据训练的模型进行比较。

自监督预训练在两种不同设置中的有效性，包括：

- 实例增量：在此设置中，根据各数据集中的受试者，通过随机划分将数据集拆分为互不重叠的批次或子集。
- 类别增量：在此设置中，根据实例的类别标签将数据集划分为互不重叠的集合。

IV. 实证研究

A. 数据集

我们的研究采用了四个广泛使用的人体活动识别数据集。这些数据集在以往的时间序列和可穿戴传感器研究中被广泛采用，也用于自监督表征学习领域的先进模型 [4], [6], [24]。

1)UEA [2]：UEA基准数据集 [1] 包含 30 个数据集，涵盖多种案例、维度和序列长度。所有数据均采用等长格式，没有缺失数据，并提供了训练集/测试集划分。这些数据集分为以下类别：人体活动识别（HAR）、运动分类、心电图分类、脑电图/脑磁图分类、音频频谱分类等。

2) UCIHAR [1]：UCIHAR数据集 [2] 是一个人体活动识别数据集，包含 30 名志愿者完成六种活动的记录，包括步行、上楼、下楼、坐、站立和躺。活动数据由佩戴在志愿者腰部的智能手机设备记录。数据采用滑动窗口格式，重叠率为 50%，并已划分为包含 21 名受试者的训练集和包含 9 名受试者的测试集。

3）PAMAP2 [18]：身体活动监测数据集[3]，包含九名受试者佩戴三个惯性测量单元和一个心率监测器进行 18 种不同身体活动的数据。在这组实验中，我们只使用了三个加速度计和陀螺仪传感器数据以及 12 活动，包括躺、坐、站立、熨衣、吸尘、上楼梯、下楼梯、步行、北欧式健走、骑自行车、跑步和跳绳。

4) Opportunity [19]：Opportunity数据集 [4] 由 4 名受试者在进行日常生活活动时采集的数据组成，采集设备为 17 个体载传感器设备。评估时，我们使用了背部惯性测量单元中的加速度计和陀螺仪数据。

B. 评估设置

表示学习模型用于将原始时间序列实例编码为表征。我们使用未标记的时间序列实例对 TS2Vec 编码器进行预训练，从而生成一个可用于从其他实例中提取特征的编码器模型。我们使用人体活动识别数据集（UCIHAR、PAMAP2、Opportunity）来考察在一个数据集上预训练的编码器模型在另一个数据集上测试时的表现。我们还测量了预训练期间所用类别的不同占比和数量下的性能。对于每个人体活动识别数据集，我们随机选取 $1/4$ 的受试者作为预训练数据集（UCIHAR：8，PAMAP2：2，Opportunity：1）。针对每个数据集，使用选定的受试者对编码器模型（TS2Vec）进行预训练。我们特别选择UCIHAR数据集来研究实例增量和类别增量持续学习设置，如图 2 所示。因此，如图所示，我们逐步向训练集中添加新类别或新受试者，并据此训练模型。为使数据更加多样化，预训练阶段使用了原始训练划分（21 名受试者），且每个活动类别所含实例的比例大致相等。

我们使用了 Avalanche [17], 一个基于 Python 的库，在每个数据集上尝试朴素的实例增量和类别增量持续学习策略。每个数据集都被转换为一个经验流，其中每个经验根据增量设置包含一部分训练数据。对于实例增量，每个经验中都有 $1/m$ 一定比例的数据在每次经验中，其中 e m 是该数据集中的类别数

[1]http://www.timeseriesclassification.com [2] https://archive.ics.uci.edu/ml/datasets/human+activity+recognition+using+smartphones [3]https://archive.ics.uci.edu/ml/datasets/pamap2+physical+activity+monitoring

[4]http://opportunity-project.eu

表 I 三个人体活动识别数据集上不同基线方法在无预训练阶段情况下取得的准确率。我们提出的基于自监督学习的框架始终能够达到较高的准确率。

模型	预训练	UCIHAR	PAMAP2	Opportunity
TS2Vec	None	0.92	0.74	0.87
TS2Vec	UCIHAR	**0.97**	0.81	0.86
TS2Vec	PAMAP2	0.95	0.84	0.85
TS2Vec	Opportunity	0.93	**0.89**	0.86
InceptionTime	-	**0.97**	0.87	**0.90**
LSTM	-	0.20	0.16	0.46
GRU	-	0.20	0.15	0.46
TCN	-	0.60	0.16	0.89
RNN	-	0.20	0.15	0.46
mWDN	-	0.89	-	0.87

；对于类别增量设置，每次经验包含一个单一类别。在每次经验中，都使用该次经验的数据对新的编码器模型进行预训练；汇总所有经验中的模型，以评估其在该持续学习设置下的性能。对于每个数据集，均根据训练集对训练集和测试集进行归一化。使用整个训练集拟合下游支持向量机分类器，评估结果则基于测试集。图 3 展示了 UEA 数据集这一工作流程的概览。在所有实验中，我们将结果分别与未进行预训练、采用随机初始化的模型以及完全监督分类器进行比较，前者和后者分别作为性能下界和上界基线。

C. 实验

*1) UCIHAR*数据集：我们将该假设的有效性与几种知名的时间序列分类基线方法进行了比较，这些方法采用了基于长短期记忆网络、门控循环单元、时间卷积网络、循环神经网络、mWDN 和 InceptionTime 的编码器。表 I 显示，TS2Vec 在不同模型上的表现始终更优。准确率似乎主要取决于下游分类所用的数据集，而非预训练所用的数据集；例如，使用 PAMAP2 数据预训练基础模型，再在 UCIHAR 上进行分类，其准确率与使用 UCIHAR 本身进行预训练相同。即使编码器模型是随机初始化的，在这三个数据集上，分类性能仍然很高。在所有完全监督的基线方法中，只有 InceptionTime 效果显著；其他方法的表现相当差，或者训练时资源消耗过大（例如在 PAMAP2 上训练 mWDN）。总体而言，我们提出的基于自监督学习的预训练对下游分类器学习新数据产生了积极影响。如图所示，我们提出的框架（采用预训练的 TS2Vec）在所有数据集上都持续取得了相当高的分数。接下来，我们将在人体活动识别数据集上探索两种增量设置：

a) 实例增量： 如图 4 所示，增加预训练阶段所用数据的比例，可以提高最终准确率。然而，当预训练数据比例较高（超过训练数据的 25%）时，准确率并未显著提升；这一结果也证实了 [8], [12] 中的发现。

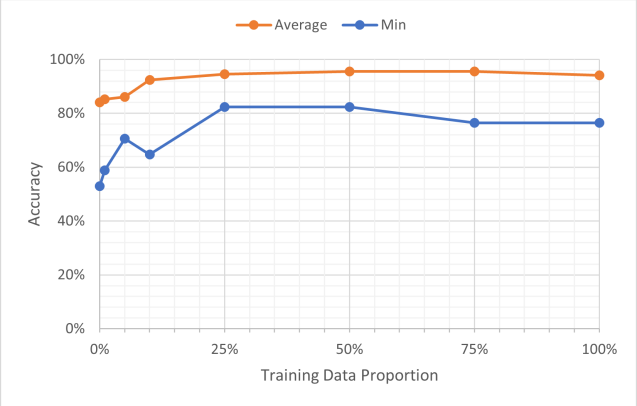

图 4. UCIHAR数据集的实例增量设置。在前25%的训练数据上，性能有所提升，但之后趋于平稳。



图 5. UCIHAR数据集的类别增量设置。在用于预训练的前两个类别上，性能有所提升，但之后趋于平稳。

b) 类别增量： 在此情境中，每个类别包含的数据比例大致相等。从预训练阶段不使用任何类别开始，逐步增加所用类别的数量，直至使用 UCIHAR数据集中的全部 6 个类别，下游阶段的准确率随之提高，并在使用 2 个类别时达到峰值，如图 5 所示。与使用包含两个类别实例的数据子集预训练的编码器模型相比，使用包含全部六个类别的数据集预训练的模型，准确率仅有细微差异。由于各类别均衡，使用 6 个类别中的 2 个相当于使用约 33% 的可用训练数据；其准确率（94%）与此前实例增量情境中使用 25% 数据时的准确率（95%）相近。这表明，对于 UCIHAR数据集，预训练模型仅使用四分之一的数据就学到了大部分特征。

2) UEA 数据集：通过比较表 II 中第 (2) 列的报告值和第 (3) 列的复现值，我们能够验证 TS2Vec 在 UEA 数据集上的有效性。该表还显示，在将 TS2Vec 模型调整到我们的工作流程中进行实验的过程中，我们没有显著改变原始模型的行为或性能，这一点可以从第 (5) 列与第 (2) 列和第 (3) 列的分数对比中看出。使用列之间的配对 t 检验进行

表 II 不同场景下 30 个 UEA 数据集的准确率。

数据集	报告值 at [24]	复现值	No data pre-训练	完整数据预-训练	随机子集预训练	单一类别子集预训练
关节词识别	**0.99**	**0.99**	0.98	**0.99**	0.98	0.95
心房颤动	0.20	0.20	0.07	0.20	0.20	**0.22**
基本动作	**0.98**	**0.98**	0.97	0.97	**0.98**	0.97
字符轨迹	**1.00**	0.99	0.98	0.99	0.99	0.99
板球	0.97	**0.99**	**0.99**	**0.99**	0.97	0.96
鸭子与鹅	**0.68**	0.50	0.54	0.46	0.48	0.50
特征蠕虫	0.85	0.83	0.82	0.82	**0.87**	0.85
癫痫	0.96	0.96	0.95	0.96	**0.97**	0.96
电子环	0.87	0.85	**0.89**	0.85	0.85	0.83
乙醇浓度	**0.31**	**0.31**	0.27	0.26	0.27	0.28
人脸检测	0.50	**0.51**	**0.51**	**0.51**	**0.51**	**0.51**
手指运动	0.48	0.50	0.45	**0.56**	0.52	0.55
手部运动方向	0.34	0.31	0.27	**0.36**	0.31	0.29
手写	0.52	**0.55**	0.25	**0.55**	0.46	0.43
心跳	0.68	0.69	**0.72**	0.69	0.71	0.70
昆虫翅膀振动	**0.47**	0.46	**0.47**	**0.47**	0.46	**0.47**
日语元音	**0.98**	**0.98**	0.97	**0.98**	**0.98**	**0.98**
Libras	**0.87**	0.84	0.83	0.84	0.86	0.81
LSST	0.54	0.55	**0.59**	0.57	0.56	0.57
运动想象	**0.51**	0.50	0.50	0.50	0.50	0.46
NATOPS	0.93	0.91	0.93	0.92	**0.94**	0.91
PEMS-SF	**0.68**	0.65	0.65	0.66	0.66	**0.68**
手写数字	**0.99**	**0.99**	0.98	**0.99**	**0.99**	**0.99**
PhonemeSpectra	0.23	0.23	0.21	0.23	**0.24**	**0.24**
RacketSports	**0.86**	**0.86**	0.77	**0.86**	**0.86**	0.83
SelfRegulationSCP1	**0.81**	0.77	0.78	0.79	0.77	0.80
SelfRegulationSCP2	**0.58**	0.55	0.57	**0.58**	**0.58**	0.56
SpokenArabicDigits	**0.99**	**0.99**	0.92	0.97	0.97	0.97
StandWalkJump	0.47	0.47	0.27	**0.53**	0.42	0.33
UWaveGestureLibrary	**0.91**	0.90	0.69	0.90	0.90	0.85
平均值	**0.70**	0.69	0.66	**0.70**	0.69	0.68

在这 30 个数据集中，我们发现不使用数据进行预训练与使用完整训练数据进行预训练之间存在显著差异（p值为 0.02），但使用完整数据进行预训练与使用随机抽样数据子集或来自单一类别的数据进行预训练之间不存在统计学差异（p值大于 0.05）。这表明，虽然使用表示学习模型和预训练确实能提高分类准确率，但即使在较小的数据子集上进行预训练，也能达到与整个数据集相近的性能。有趣的是，仅包含单一类别样本的数据子集上的预训练似乎不会显著降低性能。

随机子集预训练或单类别预训练的得分有时明显低于复现值（降幅超过 5%），但即使使用完整数据进行预训练，其中大多数数据集的得分也较低（低于 60%）。因此，对于许多此类数据集而言，预训练数据的选择并没有太大影响。

V. 讨论与局限性

自监督学习的主要优势在于能够从未注释数据中学习有用的表示。由于未标注数据易于获取，一旦有新信息可用，就可以自然地将其逐步纳入自监督学习模型中。The

对采用增量数据进行自监督学习的研究，有望为数据持续变化且不断有新信息可用的现实世界应用提供先进能力。因此，本文对使用增量时间序列数据的自监督学习范式进行了实证研究。

鉴于本研究是首个针对数据逐步呈现的时间序列和可穿戴设备数据，探讨如何使用自监督学习进行持续学习的实证研究，我们仍有一些局限性，并计划在未来工作中加以解决。首先，如前文所述，我们考察了预训练阶段数据逐步呈现的情况，随后将所学知识迁移到一个数据集完全可用的场景中，用于训练下游任务（即分类器）。然而，在现实世界场景中，数据会持续生成，这一点应在上游预训练和下游任务中都予以考虑。结合自监督学习范式的主要动机，我们将研究在低标注数据场景中，增量式自监督学习技术所产生的影响。

VI. 结论

在本研究中，我们关注的是：时间序列分类问题能否利用自监督学习范式下预训练阶段逐步获得的大量

无标签数据。为此，我们使用来自不同分布和领域等多种来源的数据，评估了自监督预训练对时间序列分类任务的影响。我们还考察了随着预训练期间可用数据增多，分类任务的性能如何变化，以模拟无法立即获取全部数据的场景。此外，我们探究了基于不同领域和分布的数据训练编码器与分类器所产生的影响。根据在多个数据集上的实验结果，我们发现，增加预训练数据并未给预训练阶段带来明显益处，分类性能也没有提升。相反，如果仅使用部分类别进行预训练，或将数据划分为不同分布，最终性能也不会下降。即使预训练和分类使用的是来自不同领域的数据集，其性能也与其他时间序列分类模型相当。

致谢

作者谨此感谢 Dong Gong 博士对本项工作所作出的宝贵贡献。此外，他们还感谢国防科学与技术集团人工智能决策（AI4DM）研究计划为题为“基于不规则时间序列数据的在线学习预测”的项目提供的资助支持。

参考文献

[1] Anguita, D., Ghio, A., Oneto, L., Parra, X., Reyes-Ortiz, J.L.：使用智能手机进行人体活动识别的公共领域数据集。载于：欧洲人工神经网络、计算智能与机器学习研讨会。ESANN（2013）[2] Bagnall, A., Dau, H.A., Lines, J., Flynn, M., Large, J., Bostrom, A., Southam, P., Keogh, E.：UEA多变量时间序列分类档案，2018（2018）。https://doi.org/10.48550/ARXIV.1811.00075, https://arxiv.org/abs/ 1811 00075 。Chen, T., [3] Kornblith, S., Norouzi, M., Hinton, G.：视觉表示对比学习的简单框架。载于：国际机器学习会议。第1597–1607页。PMLR（2020）[4] Deldari, S., S mith, D.V., Xue, H., Salim, F.D.：利用自监督对比预测编码进行时间序列变点检测。载于：2021年万维网大会论文集。第3124–3135页。WWW '21，计算机协会，纽约州纽约，美国（2021）。https://doi.org/10.1145/3442381.3449903，https://doi.org/10.1145/3442381.3449903[5] Deldari, S., Xue, H., Saeed, A., He, J., Smith, D.V., Salim, F.D.：不止于视觉：多模态与时序数据上的自监督表征学习综述。arXiv预印本 arXiv:2206.02353（2022）[6] Deldari, S., Xue, H., Saeed, A., Smith, D.V., Salim, F.D.：Co- coa：传感器数据的跨模态对比学习。《ACM交互式、移动、可穿戴与泛在技术学报》**6**（3）（2022年9月）。https://doi.org/ 10 1145 3550316, 10 1145 3550316 。 / [7] https://doi.org/ 。 / Devlin, J., Chang, M.W., Lee, K., Toutanova, K.：BERT：面向语言理解的深度双向变换器预训练。arXiv预印本 arXiv:1810.04805（2018）[8] Eldele, E., Ragab, M., Chen, Z., Wu, M., Kwoh, C.K., Li, X., Guan, C.：通过时间与上下文对比进行时间序列表征学习（2021）。https://doi.org/10.48550/ARXIV.2106.14112，https: //arxiv.org/abs/ 2106 14112 。Fini, E., da Costa, V.G.T., Alameda-Pineda, [9] X., Ricci, E., Alahari, K., Mairal, J.：自监督模型是持续学习者。载于：IEEE/CVF计算机视觉与模式识别会议论文集。第9621–9630页（2022）[10] Franceschi, J.Y., Dieuleveut, A., Jaggi, M.：多变量时间序列的无监督可扩展表示学习（2019）。https://doi.org/10.48550/ARXIV.1901.10738, https://arxiv.org/abs/1901. 10738[11] Gomez-Villa, A., Twardowski, B., Yu, L., Bagdanov, A.D., van de Weijer, J.：通过投影函数正则化持续学习自监督表示。载于：IEEE/CVF计算机视觉与模式识别会议论文集。第3867–3877页（2022）[12] Gorade, V., Singh, A., Mishra, D.：通过同时进行低频与高频特征自举实现大规模时间序列表征学习（2022）。https://doi.org/10.48550/ARXIV.2204.11291，https://arxiv. org/abs/ 2204 11291 。Gupta, V., Narwariya, J., Malhotra, P., Vig, L., [13] Shroff, G.：针对可变输入维度多变量时间序列任务的持续学习（2022）。https://doi.org/10.48550/ARXIV.2203.06852，https://arxiv. org/abs/ 2203 06852 。Haresamudram, H., Beedu, A., Agrawal, V., [14] Grady, P.L., Essa, I., Hoffman, J., Pl¨otz, T.：基于掩码重建的自监督人体活动识别。载于：2020年国际可穿戴计算机研讨会论文集。第45–49页（2020）[15] Hsu, W.N., Sriram, A., Baevski, A., Likhomanenko, T., Xu, Q., Pratap, V., Kahn, J., Lee, A., Collobert, R., Synnaeve, G., Auli, M.：稳健的wav2vec 2.0：分析自监督预训练中的领域偏移（2021）。https://doi.org/10.48550/ARXIV.2104.01027，https: //arxiv.org/abs/ 2104 01027 。Li, Y., Li, M., Asif, M.S., Oymak, S.：可证 [16] 明且高效的持续表征学习（2022）。https://doi.org/10.48550/ARXIV.2203.02026，https://arxiv.org/abs/2203.02026[17] Lomonaco, V., Pellegrini, L., Cossu, A., Carta, A., Graffieti, G., Hayes, T.L., Lange, M.D., Masana, M., Pomponi, J., van de Ven, G., Mundt, M., She, Q., Cooper, K., Forest, J., Belouadah, E., Calderara, S., Parisi, G.I., Cuzzolin, F., Tolias, A., Scardapane, S., Antiga, L., Amhad, S., Popescu, A., Kanan, C., van de Weijer, J., Tuytelaars, T., Bacciu, D., Maltoni, D.：Avalanche：持续学习的端到端库。载于：IEEE计算机视觉与模式识别会议论文集。第2届计算机视觉持续学习研讨会（2021）[18] Reiss, A., Stricker, D.：介绍一个新的活动监测基准数据集。载于：2012年第16届国际可穿戴计算机研讨会。第 108 109 2012 10 1109 2012 13 –页 [19] （）。https://doi.org/ 。 /ISWC。 。Roggen, D., Calatroni, A., Rossi, M., Holleczek, T., Forster, K., Troster, G., Lukowicz, P., Bannach, D., Pirkl, G., Ferscha, A., Doppler, J., Holzmann, C., Kurz, M., Holl, G., Chavarriaga, R., Sagha, H., Bayati, H., Creatura, M., Mill`an, J.d.R.：在高度丰富的联网传感器环境中收集复杂活动数据集。载于：2010年第七届联网感知系统国际会议（INSS）。第233–240页（ 2010 10 1109 2010 5573462 ）。https://doi.org/ 。 [20] /INSS。 。Saeed, A., Ungureanu, V., Gfeller, B.：感知与学习：泛在传感器的自监督。《机器学习及其应用》第100152页（2021）[21] Tonekaboni, S., Eytan, D., Goldenberg, A.：通过时间邻域编码进行时间序列的无监督表示学习（2021）。https://doi.org/10.48550/ARXIV.2106.00750, https://arxiv.org/abs/2106. 00750[22] Xu, H., Xing, Y., Shen, F., Zhao, J.：一种面向时间序列的在线增量学习算法。第1–5页（2015年7月）。https://doi.org/ 10 1109 2015 7280833 。 /IJCNN。 。 [23] Xue, H., Salim, F.D.：探索用于新冠肺炎咳嗽分类的自监督表示集成。载于：第27届ACM SIGKDD知识发现与数据挖掘会议论文集。第1944–1952页（2021）[24] Yue, Z., Wang, Y., Duan, J., Yang, T., Huang, C., Tong, Y., Xu, B.：TS2Vec：迈向时间序列的通用表示。载于：AAAI人工智能会议论文集。第36卷，第8980– 8987页（2022）