arXiv:2304.01239v1 [cs.CV] 3 Apr 2023

利用持续学习应对循环域偏移的在线蒸馏

Joachim Houyon[1], * Anthony Cioppa[1], [2], * Yasir Ghunaim[2] Motasem Alfarra[2]Ana´ıs Halin[1] MaximHenry[1] Bernard Ghanem[2] MarcVan Droogenbroeck[11] 列日大学 `KAUST

摘要

近年来，在线蒸馏已成为一种强大的技术，能够利用速度较慢但精度较高的教师模型，实时动态地适配深度神经网络。然而，在线蒸馏面临的一项主要挑战是域偏移情况下的灾难性遗忘：当学生模型使用来自新领域的数据进行更新时，会遗忘此前已学习的知识。本文提出了一种解决方案，借助持续学习方法的优势，减轻域偏移的影响。具体而言，我们在在线蒸馏的背景下整合了多种先进的持续学习方法，并证明了它们在减少灾难性遗忘方面的有效性。此外，我们针对循环域偏移的情况，对所提出的解决方案进行了详细分析。实验结果表明，我们的方法能够提升在线蒸馏的鲁棒性和准确性，并有望应用于视频监控或自动驾驶等领域。总体而言，我们的工作是在线蒸馏与持续学习领域向前迈出的重要一步，有望对现实世界的应用产生重大影响。

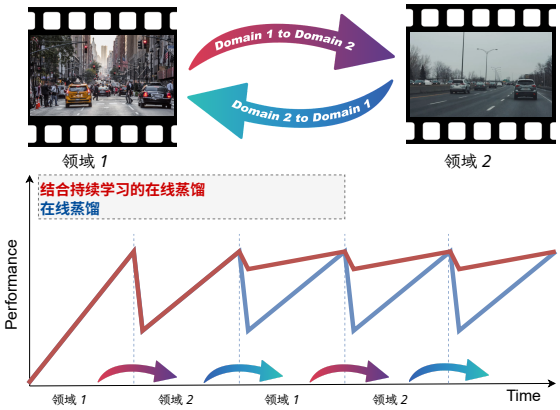

图 1. **结合持续学习的在线蒸馏**。 长视频中发生循环域偏移时，Cioppa 提出的在线蒸馏框架 等人。 [10] 会在针对当前领域进行微调时遗忘先前获取的知识。在这项工作中，我们研究了将最先进的持续学习方法纳入在线蒸馏框架，以缓解域偏移期间的这种灾难性遗忘。

1. 引言

深度神经网络（DNNs）之所以能在各种计算机视觉任务中表现出色，部分原因在于人们假设训练数据和测试数据服从相同的分布 [21, 27, 37]。然而，当在分布外数据上测试时，DNNs 的性能会显著下降，例如测试数据相对于训练数据存在域偏移 [22, 23]。更糟的是，DNNs 在任务数据流中持续学习时，往往会遗忘先前学到的分布 [24]。这种性能损失令人深感担忧，因为在真实世界部署中，变化可能会导致域偏移例如昼夜之间的亮度变化、不同季节的天气条件变化以及传感器扰动 [35]。因此，亟需开发能够使 DNNs 适应此类域偏移，并在真实环境中保持高性能的算法。

持续学习旨在构建能够从连续数据流中学习、同时不会遗忘此前已学习知识的机器学习模型 [9,20,26]。我们研究在线持续学习的一种实际场景 [7]。具体而言，我们考虑循环域偏移：数据流在一段时间内持续交替地从两个分布之一中揭示新的 未标注数据。例如，考虑一个经常往返于城市和乡村之间的自动驾驶系统，其中实例的分布会在这两种场景之间发生变化。这种领域变化可能导致在线学习器无法适应这一分布偏移，从而引发人们对这类系统实际部署的担忧。尽管在线持续学习已经在

(*) 贡献均等。联系邮箱：joachim.jouyon@student.uliege.be, anthony.cioppa@uliege.be。数据/代码可在 github.com/Houyon/online-distillation-cl 获取。

一些场景中得到研究，例如领域增量学习 [18],无监督领域自适应 [39], 和测试时自适应 [41], 但这些工作通常分析的是一种更为一般、也可能不太现实的设置，其中领域变化是无条件发生的。我们对循环域偏移的关注使我们能够探索一种务实的场景，并开发出能够更好地适应这些变化的新颖算法。

在这项工作中，我们提出了一种新方法，以应对在线领域增量学习中适应循环域偏移的挑战。具体而言，我们采用了一种此前发表的实时在线蒸馏技术 [10] ，从无标签循环数据流中学习。在线蒸馏会根据接收到的数据异步更新基于学生-教师的方法，使模型能够持续从新数据中学习。然而，我们发现，循环域偏移可能导致学生遗忘此前学习过的领域，造成性能显著下降。为缓解这一不良影响，我们将在线蒸馏与最先进的持续学习方法相结合，如图1所示，借鉴持续学习文献中的正则化方法和基于回放的方法。我们提出的方法使学生能够有效适应循环域偏移，并长期保持较高性能，因此适用于真实世界部署。

贡献。 我们的贡献概括为两点：**(i)** 我们定义了循环在线持续学习问题的设置，并提出了相应的评估指标。**(ii)** 我们将在线蒸馏与正则化和基于回放的持续学习方法相结合，以便在循环领域上更好地学习。我们在所提出的数据流上进行了实验，结果表明，我们的方法能够缓解原始在线蒸馏框架中的遗忘问题。

2. 相关工作

领域偏移。领域偏移是不同领域之间数据统计分布的变化 [15]。在开放世界场景中，这种现象在测试时十分常见 [4, 19, 28, 42]。在自动驾驶中，域偏移可能由多种不同因素造成 [40], , 例如不同的环境（例如乡村或城市道路）、照明条件（例如白天或夜晚）、天气条件（例如晴天或下雪） [35], 、交通状况，甚至不同国家的道路或交通标志外观差异 [44]。然而，自动驾驶汽车必须拥有能够适应这些动态领域偏移的算法，才能持续感知并理解周围环境，从而避开障碍物。领域自适应是一个积极发展的研究领域，旨在解决域偏移问题，尤其是在自动驾驶等开放世界应用中——辆 [25, 30, 32, 33, 40], 数据是在高度动态环境中采集的。在这项工作中，我们研究自动驾驶领域中循环域偏移这一特定情形，其中各领域可表示为高速公路与市中心驾驶条件的交替序列。

在线蒸馏。 在深度神经网络领域，速度、性能以及跨多个领域的泛化能力之间存在权衡。尽管性能最佳的模型通常能在不同领域中表现出色，但它们往往占用大量内存，不适用于嵌入式系统，或速度太慢，无法用于实时应用 [43, 46, 47]。相比之下，轻量快速的网络在较小的领域中表现良好，但缺乏泛化能力 [12]。为了解决这一问题，Cioppa 等人. [10]提出了一种面向视频的在线蒸馏方法，使轻量级学生网络能够利用速度较慢、规模较大的教师模型进行在线训练。在测试时，教师向学生提供伪真实标注，使其能够针对正在分析的特定领域进行专门适配。因此，学生模型能够适应不断变化的视频条件，甚至达到与速度较慢的教师相当的性能。这种在线蒸馏方法可用于语义分割 [10]或多模态目标检测 [11]等不同任务。然而，在发生域偏移时，该技术会导致性能暂时下降。本文研究了多种持续学习技术，以减轻在线蒸馏中的灾难性遗忘，尤其是在循环域偏移的情况下。我们将在线蒸馏与正则化和基于回放的方法相结合，以构建更好的持续学习方案。

持续学习。 持续学习（CL）旨在从分布不断变化、以数据流形式到达的数据中学习 [16, 31]。然而，这种学习范式面临灾难性遗忘的挑战，即在适应新到达的数据样本时，先前已学习的知识会被遗忘 [9, 24]。缓解遗忘影响的一种方法是通过限制重要网络参数的变化来对训练过程进行正则化 [2, 8, 24] ，或执行知识蒸馏 [17, 26, 38]。另一种方法是基于回放的方法，它们将部分已观测数据存储在回放缓冲区中，以重现先前见过的样本 [3, 9, 29, 34]。这两种方法最初都是为类别增量设置和分类任务提出的，近期则被扩展至更贴近现实的领域增量设置和更具挑战性的语义分割任务 [1, 18]。然而，现有研究假设采用完全有监督的设置，即数据流会向学生学习器提供带标签数据。为此，我们分析无监督设置下用于语义分割的领域增量设置。

3. 方法论

本节首先在适用于持续学习的数学框架中介绍在线蒸馏。接下来，我们详细说明纳入在线蒸馏框架的基于正则化和基于回放的持续学习方法。最后，我们解释如何在循环流下评估和基准测试在线持续学习方法。

3.1. 在线蒸馏框架

Cioppa 等人提出的在线蒸馏框架 [10] 使实时网络能够在测试时适应域偏移。形式上，给定一个由帧流 x_i 构成的长未剪辑视频 $\mathcal{V}$，该帧流以速率 $r_{\mathcal{V}}$生成，且给定一个任务 $\mathcal{T}$（例如目标检测、语义分割等），目标是实时为每一帧 x_i 生成一系列预测 $\hat{}y_i$（即以速率 $r_{\mathcal{V}}$生成）。为此，作者采用了包含快速路径和慢速路径的学生-教师架构。在快速路径（推理）中，学生网络 S 以速率 $r_{\mathcal{V}}$计算 $\hat{}y_i = \mathrm{S}(x_i)$。与此同时，在慢速路径（训练）中，速度较慢但性能更高的冻结教师网络 T 以异步的较低速率 $r_{\mathbf{T}}$，针对 $\mathcal{V}$的一个子集生成伪真实标签$\tilde{y}_{i'} = \mathrm{T}(x_{i'})$。然后，通过更新函数 f_U 将每一对新数据（$x_{i'}$，$\tilde{y}_{i'}$）存入大小为 N 的在线数据集 $\mathcal{D}$，该数据集用于训练学生网络副本 S_c。在原始框架中，f_U 选用先进先出（FIFO）算法。随后，S_c 通过函数 f_S从 $\mathcal{D}$ 中提取选定样本进行训练，以最小化损失：

$$\mathcal{L} = \sum_{n=1}^{N} L(\mathbf{S}_c(x_n), \tilde{y}_n) \,,$$

其中 L 是适用于学习任务 $\mathcal{T}$的距离函数。在原始框架中，f_S 会一次性选取 $\mathcal{D}$ 中的所有样本对。通过以$\mathbf{S}$ 的参数 θ 的$\mathbf{S}_c$ 参数更新 $r_{\mathbf{S}_c}$，对应于在$\mathbf{S}_c$ 上训练一个轮次 $\mathcal{D}$所需时间的倒数。完整流程见图2。

得益于这一框架，$\mathbf{S}$会逐渐专门适应其正在分析的特定视频最后几分钟的内容。只要$\mathbf{T}$ 能够生成可靠的预测，它就能适应 $\mathcal{V}$ 中缓慢变化的领域。然而，这种持续微调会使它随着时间推移逐渐遗忘先前获得的知识。例如，当领域突然发生偏移时，即使同一领域已在视频中出现过，$\mathbf{S}$ 仍需要经过多次更新才能恢复良好的性能。下文中，我们提出将持续学习（CL）技术纳入现有的在线蒸馏框架，以尽可能减少循环域偏移情况下先前获得知识的灾难性遗忘。具体而言，我们对多种基于回放的方法（CL_{Rep}）作用于 $\mathcal{D}$，以及基于正则化的方法（CL_{Reg}）作用于 $\mathcal{L}$，如图2所示。

3.2. 基于回放的方法

这类方法会利用一个有限大小的回放缓冲区（即由数据及其对应的真实标签组成的集合），选择函数 f_S 会访问该缓冲区，并且更新函数 f_U 会在每个训练轮次用新数据更新缓冲区。上述在线蒸馏框架可以表述为一种基于回放的方法，其中回放缓冲区对应于 $\mathcal{D}$，标签是伪真实标签预测 $\tilde{y}_n$，f_S 会选取回放缓冲区中的所有数据用于该训练轮次，而 f_U 则决定如何更新回放缓冲区中的样本。在原始在线蒸馏框架中，回放缓冲区的大小也等于每个训练步骤传入模型的样本数 N。我们将回放缓冲区扩展为包含 $M \geq N$ 个样本，并在每个训练步骤从缓冲区中无放回抽取 N 个样本。我们将选出的样本与数据流中新到达的数据进行增强。

我们考虑采用多种策略来修改 f_U 和 f_S，以减少灾难性遗忘：先进先出、均匀、优先级和 MIR。

先进先出：f_U 将最新样本存入回放缓冲区，同时移除最旧的样本。这等同于原框架采用的更新策略，该策略用作与其他方法比较的基线。

均匀：f_U 将新到达的数据存入随机选取的回放缓冲区索引处。该策略使数据的预期剩余寿命呈指数衰减 [5], ，从而可能避免遗忘。至于内存选择，f_S它会从内存中随机选取样本来构建训练批次。

优先级：借鉴 Schaul 等人在强化学习方面的工作，[36] 我们设置 f_U 为回放缓冲区中的每个样本分配一个重要性分数 $\mathcal{I}$，如下所示：

$$\mathcal{I}_n = L(\mathbf{S}(x_n), \mathbf{T}(x_n)) \,.$$

随后，将重要性分数用作概率，以确定按以下方式从回放缓冲区中移除哪些样本：

$$p_n = \frac{\mathcal{I}_n^{-1}}{\sum_{n'=1}^{M} \mathcal{I}_{n'}^{-1}} \,.$$

在执行内存选择 f_S 操作时，优先级策略遵循上述针对更新函数 f_U所述的相同策略。

MIR [3]：是一种选择函数 f_S，用于从数据流的回放缓冲区样本中选出一部分受新到达的数据干扰最大的样本。换言之，它会从记忆中构建一个训练样本集合，其中的样本受到下一次参数更新的负面影响最大。

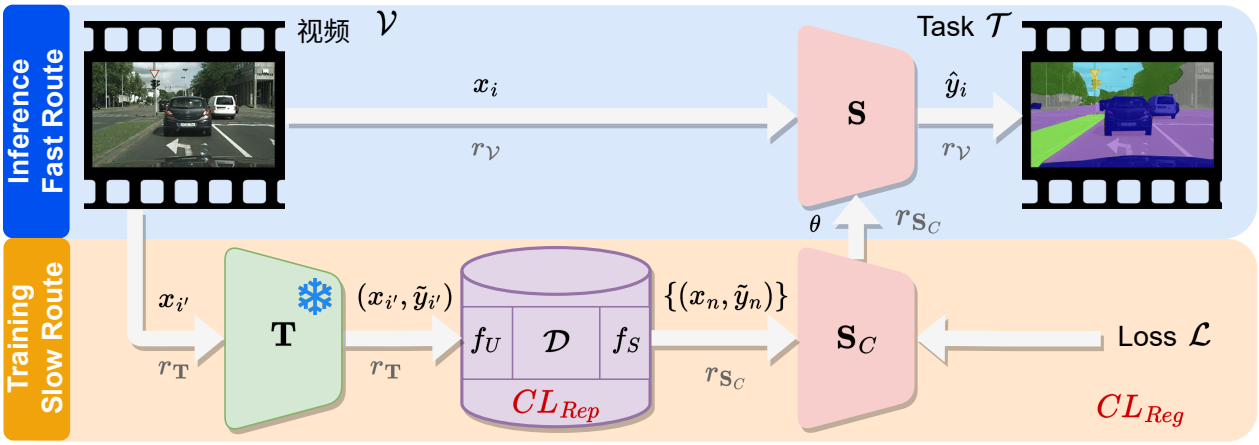

图 2. **在线蒸馏**。该框架由快速路径和慢速路径组成。在快速路径（推理）中，视频流 $\mathcal{V}$ 由学生网络 $\mathbf{S}$ 针对任务 $\mathcal{T}$（例如，用于自动驾驶的语义分割）进行处理，并以原始视频速率 $r_{\mathcal{V}}$（即，实时）为视频 x_i 的每一帧生成预测 $\hat{y}_i$。与此同时，在慢速路径（训练）中，冻结教师网络 $\mathbf{T}$ 以较低速率 $r_{\mathbf{T}}$ 为一部分帧 $x_{i'}$ 生成伪真实标签 $\tilde{y}_{i'}$。随后，通过更新函数 f_U 将配对数据（$x_{i'}$，$\tilde{y}_{i'}$）存入在线数据集（或回放缓冲区）$\mathcal{D}$。通过选择函数 f_S 从中采样 $\mathcal{D}$，并使用选出的配对数据（x_n，$\tilde{y}_n$）对学生网络 $\mathbf{S}_c$ 的一个副本进行一轮次训练，训练时使用损失 $\mathcal{L}$。然后，以速率 $r_{\mathbf{S}_c}$（对应于学生网络 $\mathbf{S}_c$ 训练一个轮次所需时间的倒数）将 $\mathbf{S}_c$ 的参数 θ 传递给 $\mathbf{S}$，使其在 $\mathcal{V}$ 的最新领域上不断改进。本文的一项贡献是在 $\mathcal{D}$ 中纳入基于回放的持续学习（CL）方法 CL_{Rep}，并在 $\mathcal{L}$ 中纳入基于正则化的方法 CL_{Reg}。

3.3. 基于正则化的方法

基于正则化的方法通过在训练损失函数中添加正则化项 $\mathcal{L}$ 来减轻遗忘。一般而言，这可以表述为：

$$\mathcal{L} = \sum_{n=1}^{N} L(\mathbf{S}_c(x_n), \tilde{y}_n) + \mathcal{R}\,,$$

其中 $\mathcal{R}$ 是特定于方法的正则化项。本文考虑了四种不同的基于正则化的持续学习方法：ER-ACE [6], LwF [26], MAS [2],和 RWalk [8]。下文将对这些方法进行总结。

ER-ACE [6] 旨在减少在新类别样本上训练时学习到的表征变化。具体而言，它会对新到达的数据和从回放缓冲区中采样的先前见过的数据采用非对称参数更新。ER-ACE 会限制新到达数据中所呈现类别的损失计算，同时忽略其余类别。需要注意的是，ER-ACE 仅作用于新到达的数据，而对从回放缓冲区采样的数据保留原始损失。

以下方法最初是为具有明确任务边界的设置提出的。我们利用两个特性将其应用于没有任务边界的在线数据流：**(i)** 预热和**(ii)** 更新频率。预热为网络在预热阶段完成初始化规定了一段时间，我们将其设为 $\mathcal{R} = 0$。更新频率则每隔 k 步模拟一次人工任务边界，其中 k 是所有方法均固定使用的超参数。

LwF [26] 使用知识蒸馏，促使当前网络的输出与使用先前时间步数据训练的网络输出相似。在我们的设置中，LwF保留学生网络$\mathbf{S}_c$ 的先前版本，以指导该网络未来的参数更新。维护一个可能更适合先前领域的网络，有助于保留已学习的知识。

MAS [2] 通过近似网络输出对参数变化的敏感性，为每个网络参数分配一个重要性权重。在新分布上进行训练时，它会惩罚重要参数的大幅变化，从而保留先前学习到的知识。

RWalk [8] 是一种泛化形式，结合了两种流行的基于重要性的方法的改进版本：EWC [24]和 PI [45]。RWalk 会计算网络参数的重要性分数，与 MAS 类似，并对网络参数进行正则化。

3.4. 评估方法

为了评估对新领域的适应能力以及对过去领域的遗忘情况，我们提出了若干评估指标。遵循 Cioppa 等人. [10], 的工作，学生网络 $\mathbf{S}_c$（等同于 $\mathbf{S}$）随时间变化的性能定义如下：给定一个任务特定指标 $\mathcal{M}$（例如$mIoU$ 用于语义分割，或 $accuracy$ 用于分类）、一组大小为 I 的帧 $X'_i = \{x_{i'}, ..., x_{i'+I}\}$ 和伪真实标注 $Y'_i = \{\tilde{y}_{i'}, ..., \tilde{y}_{i'+I}\}$，其性能——

学生网络在时刻 i' 的性能定义为:

$$\mathcal{M}(\mathbf{S}_c(X_{i'};\theta_{i'}),\tilde{Y}_{i'}) ,$$

其中， $\theta_{i'}$ 是$\mathbf{S}_c$ 在时间 i' 的参数，该时间可能与$\mathbf{S}_c$ 的训练以及$\mathbf{S}$ 的更新不同步，因为它以不同的速率运行 $r_{\mathbf{S}_c}$。

后向迁移（BWT）：受后向迁移离散实现方式的启发 [14],，我们针对在线数据流提出了一个修改版本，用于衡量当前学生网络相对于先前数据的遗忘；在我们的情形中，这对应于先前的领域:

$$\text{BWT}(i') = \mathcal{M}(\mathbf{S}_c(X_{i'-h};\theta_{i'}),\tilde{Y}_{i'-h}) ,$$

其中， h 表示向后的时间偏移。

此外，我们还报告**最终后向迁移（Final BWT）**。给定长度为 K 的数据流，我们在整个数据流上评估最终模型 θ_K 的后向迁移，即，在 BWT 中设定 $h = 0$ 。该指标可用于在所有先前的领域上评估最终学生模型，而不仅仅是在某个特定的先前领域上评估。

前向迁移（FWT）：与后向迁移类似，我们针对在线设置调整了前向迁移的离散版本 [14] ，如下所示:

$$\text{FWT}(i') = \mathcal{M}(\mathbf{S}_c(X_{i'+h};\theta_{i'}),\tilde{Y}_{i'+h}) .$$

前向迁移用于衡量模型在未来未见数据上的表现。在我们的案例中，这一指标有助于评估当前模型在下一个领域上的表现。

4. 实验

本节首先介绍用于基准测试我们提出的持续在线蒸馏框架的实验设置。接着，我们采用所提出的评估方法，对框架进行定量评估，包括比较研究。最后，我们展示一些定性结果，以说明该框架对自动驾驶应用的实际影响。

4.1. 实验设置

我们的在线持续学习框架不受任务、指标和训练参数的限制。本节将介绍各种设置下实验的技术细节。

任务。我们在室外语义分割任务上对框架进行基准测试，该任务旨在为帧中的每个像素分配一个类别标签。我们研究的具体场景是车辆挡风玻璃后方拍摄的视频，这也是自动驾驶应用中的典型研究场景。

数据集。在线蒸馏框架需要较长的未剪辑视频；在我们的研究中，这些视频包含循环域偏移。此外，这些视频还必须与任务目标相关。由于大多数语义分割数据集由帧或较短的视频片段组成（例如，CityScapes [13], BDD100K [44], 等），因此无法用于我们的在线持续学习场景。因此，我们遵循 [10] 中模拟包含域偏移的长视频的相同策略，并提出通过拼接来自两个不同领域 D^A 和 D^B 的序列，人工构建视频 $\mathcal{V}$，使其在两个领域之间循环交替。由此得到的视频是一个有序集合 $\mathcal{V} = \{\mathcal{V}_1^A, \mathcal{V}_1^B, \mathcal{V}_2^A, \mathcal{V}_2^B, ...\}$，其中 $\mathcal{V}_i^A$ 和 $\mathcal{V}_i^B$ 分别是来自领域 D^A 和领域 D^B 的序列。在自动驾驶场景中，我们将两个领域 D^A 和 D^B 定义为高速公路环境和市中心环境；二者在语义类别的先验分布上有所不同（例如，高速公路上的行人应少于市中心），背景也有所不同（例如，市中心的建筑更多，而高速公路的空旷区域更多）。我们从每个领域提取若干片段，并交替拼接它们以构建 $\mathcal{V}$。为考虑不同时长的片段，我们构建了两个视频 $\mathcal{V}$ 数据流，其中提取的片段时长分别为 20 分钟和 40 分钟。

评估指标。按照语义分割领域的标准，我们使用 $\mathcal{M} = mIoU$ 来评估第3节所述的每一帧分割掩码。遵循 Cioppa等人的工作， [10], 由于我们的数据集没有真实标注数据，我们根据教师生成的伪真实标注来评估学生的性能。这衡量了学生模仿教师的能力。我们提供$mIoU$、FWT、BWT 和最终后向迁移指标，这些指标既可在视频播放过程中计算，也可对整个视频取平均值（称为均值）。根据领域序列的长度，我们选择 $I = 1$ 分钟和 $h = 20$分钟，或 $h = 40$分钟，以评估对先前或未来领域的遗忘。最后，我们还计算每次域偏移发生前后± 2 分钟时间窗口内的平均值。我们将此指标称为 $mIoU$ 近域偏移（$mIoU$ NDS）。

网络与训练参数。对于教师网络 $\mathbf{T}$，我们选择了在 CityScapes数据集上训练的 SegFormer [43] ，它在该数据集的语义分割任务中达到了最先进水平。对于学生网络$\mathbf{S}$ 和 $\mathbf{S}_c$，我们选择了 TinyNet [10, 12], ，这是一种轻量级分割网络，只需少量训练样本即可针对特定领域进行适配，训练速度快，并可实时运行（在 Nvidia 1080 GPU 上处理全高清视频时，至少达到每秒 30 帧）。学生网络 $\mathbf{S}_c$在视频开始时从头训练，采用学习率 10^{-4} 和 ADAM 优化器进行在线学习，遵循 [10]。回放缓冲区大小设为 $M = 250$，选取的帧数设为 $N = 100$ 帧。给定所选视频、网络和回放缓冲区大小，

表1. **定量结果**。 我们将若干无记忆方法和基于回放的方法与 Cioppa 等人提出的原始基线框架进行比较 等人。 [10]。对于每个类别，我们对多种选择函数进行基准测试 f_S、更新函数 f_U和正则化器 $\mathcal{R}$。我们针对 20/40 个拼接序列，给出了所提出评估指标的性能。基于回放的方法通常优于基线和无记忆方法。LwF 和 MAS 正则化方法会降低性能，而 ACE 和 RWalk 则会提升性能。使用均匀回放缓冲区、MIR、MIR+ACE 和 MIR+RWalk 可获得最佳结果。我们在图 基线 与表现最佳的方法之一 MIR+RWalk 的性能时间演变进行了比较，见图 3。

方法	参数			指标（平均值 %）				
	f_S	f_U	$\mathcal{R}$	$mIoU$	$mIoU$ NDS	FWT	BWT	最终后向迁移
无记忆	/	/	/	18.4/19.4	14.9/15.1	6.8/4.8	7.8/7.5	14.9/15.0
	/	/	MAS	14.0/14.0	13.0/13.3	11.1/11.1	12.9/12.9	14.2/14.2
	/	/	LwF	15.7/15.9	12.0/11.0	9.7/6.8	11.3/8.9	14.7/12.9
	/	/	RWalk	18.3/19.3	14.6/14.7	7.5/4.7	8.6/6.5	15.1/14.2
基线	All	FIFO	/	23.4/24.2	19.8/18.2	14.5/9.5	17.7/13.9	21.9/19.9
回放缓冲区	均匀	均匀	/	25.5/25.0	23.6/21.1	**22.2**/17.3	30.6/28.8	29.4/28.4
	优先级	优先级	/	25.1/25.1	23.2/20.8	21.3/17.3	29.2/28.4	29.2/28.9
	MIR	均匀	/	25.2/25.2	23.7/**24.5**	21.9/**22.5**	30.5/28.6	29.5/29.7
	MIR	均匀	MAS	14.5/14.9	13.4/14.7	12.1/13.6	13.9/15.2	15.1/15.4
	MIR	均匀	LwF	18.7/18.1	17.6/15.7	17.4/13.9	21.0/20.2	22.4/21.1
	MIR	均匀	ACE	**25.6/25.5**	**24.2**/21.8	22.0/17.5	**30.8**/29.4	28.8/28.5
	MIR	均匀	RWalk	25.2/25.4	23.4/22.0	21.8/18.0	30.0/**30.8**	**30.1/30.8**

速率如下： $r_{\mathcal{V}} = 30$ 帧每秒、 $r_{\mathbf{T}} = 3$ 每帧秒数，以及 $r_{\mathbf{S}_c} = 60$每轮秒数。

4.2. 定量结果

我们比较了原始框架与所提出的持续学习方法的性能。作为一种朴素方法，我们还研究了无记忆的在线蒸馏框架，在该框架中，在线数据集不存储任何帧。在这种设置下，教师生成的样本对仅用于训练一次，随后便会被删除。如表 1 所示，对于所有度量指标，无记忆方法的表现都不如原始框架，这表明在在线数据集中保留一些信息（或使用回放缓冲区）能够提升性能。有趣的是，不使用正则化器的所有基于回放的方法都比基线有所改进，其中 MIR 的整体表现最佳。然而，添加正则化器并不总是有益的。例如，MAS 和 LwF 会持续降低性能，而 ACE 和 RWalk 则会略微提升性能。我们推测，这可能是因为 MAS 和 LwF 是针对离线设置提出的，旨在降低模型适应新信息的灵活性。虽然这种方法已被证明在多种场景中有用，但在在线设置下，它可能会妨碍学生快速适应新领域。因此，最大的改进主要来自采用 MIR 的回放缓冲区方法。

在图 3中，我们展示了基线方法和一种最佳方法随时间变化的性能演进（MIR+RWalk）在周期数为 20 时的表现。从$mIoU$ 图中可以看出，在前两个周期中，两种方法的结果相近。这是预期之中的，因为它们都在探索新的领域。首次差异出现在第二次转换时，此时第一个领域再次出现。基线方法的性能大幅下降，而持续学习方法则表现良好。在之后的每次转换中，MIR+RWalk 都不会因遗忘先前领域而导致性能下降。我们通过分析 $mIoU$、BWT、最终后向迁移（Final-BWT）和前向迁移（FWT）这些度量指标随时间的变化，对 MIR+RWalk 方法与原始在线蒸馏框架（基线）进行了比较。在先前领域上进行评估时，MIR+RWalk 的后向迁移（BWT）显著优于基线，表明它能够保留在已训练帧上有关先前领域的信息。在最终后向迁移（Final-BWT）方面，基线会迅速遗忘先前知识，而 MIR+RWalk 能够在多个周期中维持两个领域的高性能。最后，在未来领域上进行评估时，MIR+RWalk 的前向迁移（FWT）也显著优于基线，表明它能够将在先前领域中学到的知识泛化到新帧。

4.3. 定性结果

我们定性展示了表现最佳的持续学习方法对灾难性遗忘的影响。为此，我们考察了从高速公路转换到

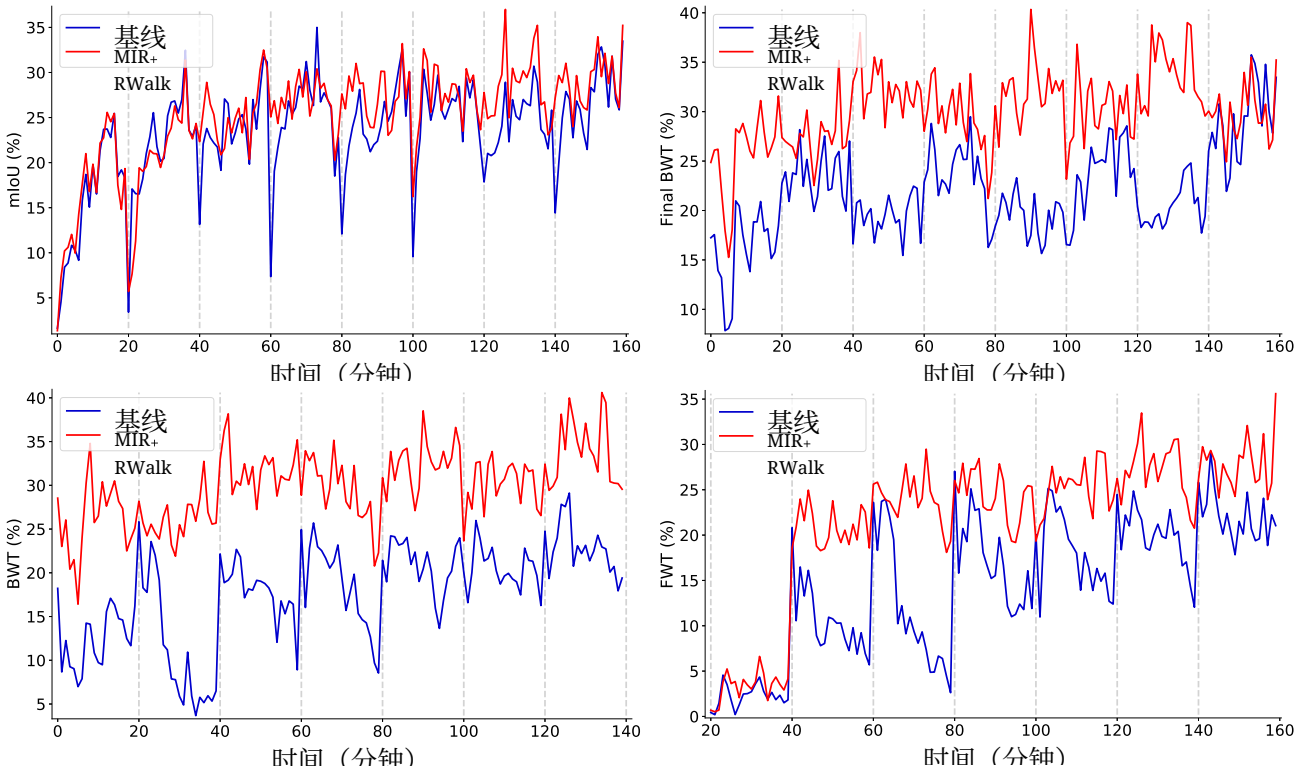

图3. **性能随时间的演变**。我们比较了 MIR+RWalk 方法与原始在线蒸馏框架（基线）在 $mIoU$、后向迁移、最终后向迁移和前向迁移方面的演变情况。（左上）$mIoU$：在同一领域内，两者的性能大多相近；但在域偏移发生时（从第二个周期开始），基线会出现遗忘，而 MIR+RWalk 则能保持较高的性能。（左下）后向迁移：在先前领域上进行评估时，MIR+RWalk 明显优于基线，表明它能够保留有关先前领域的信息，并在已训练过的帧上保持性能。（右上）最终后向迁移：基线很快就会遗忘先前知识，而 MIR+RWalk 能够在多个周期中，在两个领域上都保持较高的性能。（右下）前向迁移：在未来领域上进行评估时，MIR+RWalk 也明显优于基线，表明它能够利用先前接触过的领域中的信息，泛化到特定领域的新帧。

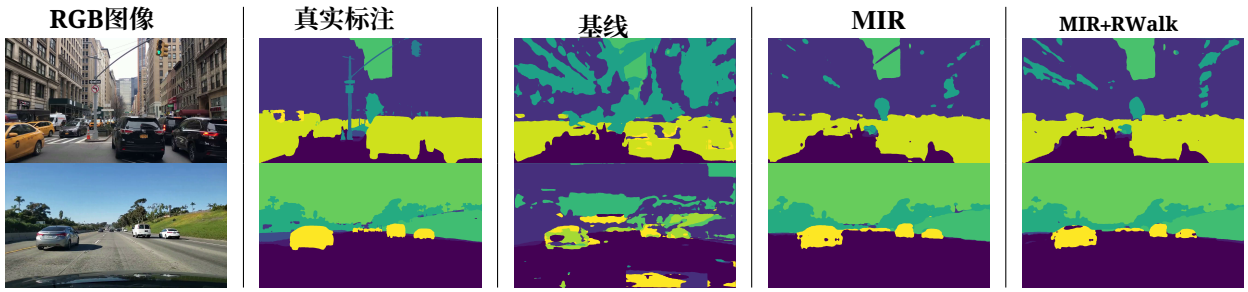

图4. **定性结果**。 不同在线持续学习方法得到的分割掩码对比：（上排）高速公路与市中心之间第二次转换后拍摄的一帧，（下排）市中心与高速公路之间第七次转换后拍摄的一帧。尽管基线方法之前已经见过这个领域，但在域偏移后仍预测出较差的分割掩码。相比之下，MIR 和 MIR+RWalk 生成的分割掩码效果更好。

市中心后（学生此前只见过一次市中心），以及从市中心转换到高速公路的第七次转换后（学生此前已经见过高速公路领域6 次）。图4比较了基线方法、MIR 和 MIR+RWalk 与真实掩码相比。如图所示，即使学生模型之前已经见过该领域，基线模型在域偏移后立即生成的分割掩码仍然很差。实际上，这可能会使自动驾驶汽车及其乘客面临危险。相较之下，

使用 MIR 和 MIR+RWalk 获得的分割掩码与真实掩码更加接近。定量结果表明，将持续学习算法融入在线蒸馏框架，能够显著提升预测质量，使其更适用于现实世界的应用。

5. 结论

总之，在线蒸馏的发展为深度神经网络的实时适配带来了新的机遇，使其更适用于自动驾驶等实际应用。然而，在域偏移时发生的灾难性遗忘问题，一直是该技术应用中的一项重大挑战。本文通过引入持续学习方法，提出了一种解决这一问题的新方案。通过实验，我们评估了几种最先进的持续学习方法，并证明它们能够有效减少灾难性遗忘。我们还针对循环域偏移的情形，对所提出的方案进行了详细分析。结果表明，我们的方法提高了在线蒸馏的鲁棒性和准确率，使其成为一种很有前景的现实应用技术。这项工作标志着在线蒸馏与持续学习领域迈出了重要一步，有望对自动驾驶等多个领域产生切实影响。

致谢。A. Cioppa 的研究经费由 F.R.S.-FNRS 提供。A. Halin 的研究经费由瓦隆大区（比利时瓦隆公共服务部研究处）通过编号为 2010235 的资助项目提供（ARIAC，由 DIGITALWALLONIA4.AI 支持）。M. Henry 的研究经费由比利时 PIT MecaTech 通过编号为 C8650 的资助项目提供（ReconnAIssance）。本研究部分由阿卜杜拉国王科技大学（KAUST）赞助研究办公室（OSR）通过编号为 OSR-CRG2021-4648 的奖项资助。

参考文献

[1] Motasem Alfarra、Zhipeng Cai、Adel Bibi、Bernard Ghanem 和 Matthias M¨uller。SimCS：用于在线领域增量持续分割的模拟。*CoRR*，abs/2211 16234，20222。[2] Rahaf Aljundi、Francesca Babiloni、Mohamed Elhoseiny、Marcus Rohrbach 和 Tinne Tuytelaars。记忆感知突触：学习该记住什么（以及不该忘记什么）。载于欧洲计算机视觉会议（*ECCV*），第11207卷，计算机科学讲义，第144–161页。Springer国际出版，2018年。2，4[3] Rahaf Aljundi、Lucas Caccia、Eugene Belilovsky、Massimo Caccia、Laurent Charlin 和 Tinne Tuytelaars。利用最大干扰检索进行在线持续学习。载于神经信息处理系统进展（*NeurIPS*），2019年。2，3 [4] Fatemeh Azimi、Sebastian Palacio、Federico Raue、Jorn Hees、Luca Bertinetto 和 Andreas Dengel。自监督视频数据上的测试时自适应。在 IEEE/CVF 冬季应用计算机视觉会议（WACV）上，页码 2603–2612，威可洛亚，夏威夷州，美国，2022年1月。电气与电子工程师协会（IEEE）。2 [5] Olivier Barnich 和 Marc Van Droogenbroeck。ViBe：一种适用于视频序列的通用背景减除算法。《IEEE图像处理汇刊》，20(6):1709–1724，2011年6月。3[6] Lucas Caccia、Rahaf Aljundi、Nader Asadi、Tinne Tuyte-laars、Joelle Pineau 和 Eugene Belilovsky。关于减少在线持续学习中表征突变的新见解。载于国际学习表征会议（ICLR），2022年。4[7] Zhipeng Cai、Ozan Sener 和 Vladlen Koltun。自然分布偏移下的在线持续学习：基于视觉数据的实证研究。载于 IEEE 国际计算机视觉会议（ICCV），页码 8261–8270，蒙特利尔，加拿大，2021年10月。电气与电子工程师协会（IEEE）。1[8] Arslan Chaudhry、Puneet K. Dokania、Thalaiyasingam Ajan-than 和 Philip H. S. Torr。用于增量学习的黎曼游走：理解遗忘与固执性。载于欧洲计算机视觉会议（ECCV），计算机科学讲义第11215卷，页码 556–572。Springer国际出版，2018年。2, 4[9] Arslan Chaudhry、Marcus Rohrbach、Mohamed Elhoseiny、Thalaiyasingam Ajanthan、Puneet K. Dokania、Philip H. S. Torr 和 Marc'Aurelio Ranzato。利用微型情景记忆进行持续学习。载于国际机器学习会议（ICML），2019年。1, 2[10]Anthony Cioppa、Adrien Deliege、Maxime Istasse、Christophe De Vleeschouwer 和 Marc Van Droogen-broeck。ARTHuS：通过在线蒸馏实现体育场景中的自适应实时人体分割。载于 IEEE 国际计算机视觉与模式识别会议研讨会（CVPRW），CVsports，页码 2505–2514，长滩，加利福尼亚州，美国，2019年6月。电气与电子工程师协会（IEEE）。1, 2, 3, 4, 5, 6[11] Anthony Cioppa、Adrien Deli`ege、Noor Ul Huda、Rikke Gade、Marc Van Droogenbroeck 和 Thomas B. Moeslund。用于足球场球员实时检测的多模态与多视图蒸馏。载于 IEEE 国际计算机视觉与模式识别会议研讨会（CVPRW），CVsports，页码 3846–3855，西雅图，华盛顿州，美国，2020年6月。2[12] Anthony Cioppa、Adrien Deli`ege 和 Marc Van Droogen-broeck。基于语义的自底向上方法：解读足球比赛中的主摄像机视频流。载于 IEEE 国际计算机视觉与模式识别会议研讨会（CVPRW），CVsports，页码 1846–1855，盐湖城，犹他州，美国，2018年6月。2, 5[13] Marius Cordts、Mohamed Omran、Sebastian Ramos、Timo Rehfeld、Markus Enzweiler、Rodrigo Benenson、Uwe Franke、Stefan Roth 和 Bernt Schiele。用于城市场景语义理解的 Cityscapes 数据集。载于 IEEE/CVF 计算机视觉与模式识别会议（CVPR），页码 3213–3223，拉斯维加斯，内华达州，美国，2016年6月。电气与电子工程师协会（IEEE）。5[14] Natalia D´ıaz-Rodr´ıguez、Vincenzo Lomonaco、David Filliat 和 Davide Maltoni。别忘了，遗忘之外还有更多：持续学习的新度量指标。载于《神经信息处理系统持续学习研讨会》（NeurIPS），2018年。5

[15] Abolfazl Farahani、Sahar Voghoei、Khaled Rasheed 和 Hamid R. Arabnia。领域自适应简述。《计算机科学与计算智能汇刊》，页码 877–894，2021年。2[16] Robert M. French。联结主义网络中的灾难性遗忘。《认知科学趋势》，3(4):128–135，1999年4月。2[17] Qiankun Gao、Chen Zhao、Bernard Ghanem 和 Jian Zhang。R-DFCIL：面向无数据类增量学习的关系引导表征学习。载于欧洲计算机视觉会议（ECCV），计算机科学讲义第13683卷，页码 423–439。Springer Nature Switzerland，2022年。2[18] Prachi Garg、Rohit Saluja、Vineeth N. Balasubramanian、Chetan Arora、Anbumani Subramanian 和 C. V. Jawa-har。用于语义分割的多领域增量学习。载于 IEEE/CVF 冬季应用计算机视觉会议（WACV），页码 2080–2090，威可洛亚，夏威夷州，美国，2022年1月。电气与电子工程师协会（IEEE）。2[19] Yasir Ghunaim、Adel Bibi、Kumail Alhamoud、Motasem Alfarra、Hasan Abed Al Kader Hammoud、Ameya Prabhu、Philip H. S. Torr 和 Bernard Ghanem。在线持续学习中的实时评估：新的希望。CoRR，abs/2302.01047，2023年。2[20] Jiangpeng He、Runyu Mao、Zeman Shao 和 Fengqing Zhu。在线场景中的增量学习。载于 IEEE/CVF 计算机视觉与模式识别会议（CVPR），页码 13923–13932，西雅图，华盛顿州，美国，2020年6月。电气与电子工程师协会（IEEE）。1[21] Kaiming He、Xiangyu Zhang、Shaoqing Ren 和 Jian Sun。用于图像识别的深度残差学习。载于 IEEE/CVF 计算机视觉与模式识别会议（CVPR），页码 770–778，拉斯维加斯，内华达州，美国，2016年6月。电气与电子工程师协会（IEEE）。1[22] Dan Hendrycks 和 Thomas Dietterich。神经网络对常见损坏与扰动的鲁棒性基准测试。载于国际学习表征会议（ICLR），2019年。1[23] Oguzhan Fatih Kar、Teresa Yeo、Andrei Atanov 和 Amir Zamir。三维常见损坏与数据增强。载于 IEEE/CVF 计算机视觉与模式识别会议（CVPR），页码 18941–18952，新奥尔良，路易斯安那州，美国，2022年6月。电气与电子工程师协会（IEEE）。1[24] James Kirkpatrick、Razvan Pascanu、Neil Rabinowitz、Joel Veness、Guillaume Desjardins、Andrei A. Rusu、Kieran Milan、John Quan、Tiago Ramalho、Agnieszka Grabska-Barwinska、Demis Hassabis、Claudia Clopath、Dharshan Ku-maran 和 Raia Hadsell。克服神经网络中的灾难性遗忘。《美国国家科学院院刊》（PNAS），114(13):3521–3526，2017年3月。1, 2, 4[25] Jinlong Li、Runsheng Xu、Jin Ma、Qin Zou、Jiaqi Ma 和 Hongkai Yu。雾天自动驾驶中的领域自适应目标检测。载于 IEEE/CVF 冬季应用计算机视觉会议（WACV），页码 612–622，威可洛亚，夏威夷州，美国，2023年1月。电气与电子工程师协会（IEEE）。2[26] Zhizhong Li 和 Derek Hoiem。无遗忘学习。《IEEE模式分析与机器智能汇刊》，40(12):2935–2947，2018年12月。1, 2, 4[27] Ming Liang 和 Xiaolin Hu。用于目标识别的循环卷积神经网络。载于 IEEE/CVF 计算机视觉与模式识别会议（CVPR）。

视觉模式识别会议（CVPR），第3367–3375页，美国马萨诸塞州波士顿，2015年6月。电气与电子工程师协会（IEEE）。1[28] Hyesu Lim、Byeonggeun Kim、Jaegul Choo和 Sungha Choi。TTN：一种适用于测试时自适应、能够感知域偏移的批归一化方法。载于国际学习表征会议（ICLR），第1–19页，2023年。2[29] David Lopez-Paz和Marc'Aurelio Ranzato。用于持续学习的梯度情景记忆。载于神经信息处理系统进展（NeurIPS），2017年。2[30] Yawei Luo、Liang Zheng、Tao Guan、Junqing Yu和Yi Yang。深入审视域偏移：用于语义一致的域自适应的类别级对抗者。载于IEEE/CVF计算机视觉与模式识别会议（CVPR），第2502–2511页，美国加利福尼亚州长滩，2019年6月。电气与电子工程师协会（IEEE）。2[31] Michael McCloskey和Neal J. Cohen。联结主义网络中的灾难性干扰：序列学习问题。《心理学、学习与动机》，第109–165页，1989年。2[32] Theodoros Panagiotakopoulos、Pier Luigi Dovesi、Linus H¨arenstam-Nielsen和Matteo Poggi。面向瞬息万变环境下语义分割的在线域自适应。载于欧洲计算机视觉会议（ECCV），计算机科学讲义第13694卷，第128–146页。Springer Nature Switzerland，2022年。2[33] S´ebastien Pi´erard、Anthony Cioppa、Ana¨ıs Halin、Renaud Vandeghen、Maxime Zanella、Beno ̂ıt Macq、Sa¨ıd Mahmoudi和Marc Van Droogenbroeck。通过混合域自适应提升真实世界监控场景中的语义分割。载于IEEE/CVF冬季计算机视觉应用会议研讨会（WACVW），第22–31页，美国夏威夷州威可洛亚，2023年1月。电气与电子工程师协会（IEEE）。2[34] Ameya Prabhu、Philip H. S. Torr和Puneet K. Dokania。GDumb：一种质疑持续学习进展的简单方法。载于欧洲计算机视觉会议（ECCV），计算机科学讲义第12347卷，第524–540页。Springer国际出版，2020年。2[35] Christos Sakaridis、Dengxin Dai和Luc Van Gool。ACDC：包含对应关系、用于语义驾驶场景理解的恶劣条件数据集。载于IEEE国际计算机视觉会议（ICCV），第10745–10755页，加拿大魁北克省蒙特利尔，2021年10月。电气与电子工程师协会（IEEE）。1, 2[36] Tom Schaul、John Quan、Ioannis Antonoglou和 David Silver。优先经验回放。CoRR，abs/1511 05952，2015年3。.[37] J¨urgen Schmidhuber。神经网络中的深度学习：综述。《神经网络》，61：85–117，2015年1月。1[38] James Smith、Yen-Chang Hsu、Jonathan Balloch、Yilin Shen、Hongxia Jin和Zsolt Kira。始终保持梦想：一种无数据类增量学习的新方法。载于IEEE国际计算机视觉会议（ICCV），第9354–9364页，加拿大魁北克省蒙特利尔，2021年10月。电气与电子工程师协会（IEEE）。2[39] Baochen Sun和Kate Saenko。Deep CORAL：用于深度域自适应的相关性对齐。载于欧洲计算机视觉会议（ECCV），计算机科学讲义第9915卷，第443–450页。Springer国际出版，2016年。2

[40] Tao Sun、Mattia Segu、Janis Postels、Yuxuan Wang、Luc Van Gool、Bernt Schiele、Federico Tombari和Fisher Yu。SHIFT：用于连续多任务域自适应的合成驾驶数据集。载于IEEE/CVF计算机视觉与模式识别会议（CVPR），第21339–21350页，美国路易斯安那州新奥尔良，2022年6月。电气与电子工程师协会（IEEE）。2[41] Dequan Wang、Evan Shelhamer、Shaoteng Liu、Bruno Ol-shausen和Trevor Darrell。Tent：通过熵最小化实现完全测试时自适应。CoRR，abs/2006.10726，2020年。2[42] Qin Wang、Olga Fink、Luc Van Gool和Dengxin Dai。持续测试时域自适应。载于IEEE/CVF计算机视觉与模式识别会议（CVPR），第7191–7201页，美国路易斯安那州新奥尔良，2022年6月。电气与电子工程师协会（IEEE）。2[43] Enze Xie、Wenhai Wang、Zhiding Yu、Anima Anandkumar、Jose M. Alvarez和Ping Luo。SegFormer：面向语义分割的简洁高效Transformer设计。载于神经信息处理系统进展（NeurIPS），第34卷，第12077–12090页，2021年。2, 5[44] Fisher Yu、Haofeng Chen、Xin Wang、Wenqi Xian、Yingying Chen、Fangchen Liu、Vashisht Madhavan和Trevor Darrell。BDD100K：用于异构多任务学习的多样化驾驶数据集。载于IEEE国际计算机视觉与模式识别会议（CVPR），第2633–2642页，美国华盛顿州西雅图，2020年6月。电气与电子工程师协会（IEEE）。2, 5[45] Friedemann Zenke、Ben Poole和Surya Ganguli。通过突触智能实现持续学习。载于国际机器学习会议（ICML），2017年。4[46] Hengshuang Zhao、Jianping Shi、Xiaojuan Qi、Xiaogang Wang和Jiaya Jia。金字塔场景解析网络。载于IEEE/CVF计算机视觉与模式识别会议（CVPR），第6230–6239页，美国夏威夷州檀香山，2017年7月。电气与电子工程师协会（IEEE）。2[47] Sixiao Zheng、Jiachen Lu、Hengshuang Zhao、Xiatian Zhu、Zekun Luo、Yabiao Wang、Yanwei Fu、Jianfeng Feng、Tao Xiang、Philip H. S. Torr和Li Zhang。以序列到序列视角结合Transformer重新思考语义分割。载于IEEE/CVF计算机视觉与模式识别会议（CVPR），第6877–6886页，美国田纳西州纳什维尔，2021年6月。电气与电子工程师协会（IEEE）。2