

## 类增量学习研究进展

张文卓,徐昕\*,蒯杨柳,崔家宝,丁智勇,谢旭辉  
(国防科技大学智能科学学院,湖南长沙410073)

**摘要:**类增量学习要求模型在学习新类别的同时保持对已学类别的判别能力,但训练过程中易发生灾难性遗忘。本文系统综述与分析类增量学习及其发展趋势;阐述类增量学习的基本定义,厘清其与其他增量学习设定的区别;从记忆回放、参数与优化约束、模型预测校正、模型结构设计、预训练模型迁移五个维度,对主流的方法进行分类总结;进一步梳理类增量学习常用的评价指标和数据集,总结其在图像生成、目标检测、语义分割等典型视觉任务,以及在视频理解、三维视觉等新兴领域中的应用情况;最后对类增量学习的未来研究方向进行展望。

**关键词:**类增量学习;灾难性遗忘;记忆回放;参数与优化约束;模型预测校正;模型结构设计;预训练模型迁移

中图分类号:TP183 文献标志码:A 文章编号:1001-2486(2026)03-316-23

## Recent advances in class-incremental learning

ZHANG Wenzhuo, XU Xin\*, KUAI Yangliu, CUI Jiabao, DING Zhiyong, XIE Xuhui

(College of Intelligence Science and Technology, National University of Defense Technology, Changsha 410073, China)

**Abstract:** CIL (class-incremental learning) aims to enable models to maintain discriminative ability on previously learned classes while incrementally acquiring new ones, a process in which catastrophic forgetting often occurs. This paper provided a comprehensive survey and analysis of CIL and its development trends. It clarified the definition of CIL and distinguished it from other incremental learning settings. Mainstream approaches were categorized and summarized from five perspectives: memory replay, parameter and optimization constraints, model prediction calibration, model architecture design, and transfer of pre-trained models. In addition, the commonly used evaluation metrics and datasets of CIL were reviewed, and its applications in typical vision tasks such as image generation, object detection, and semantic segmentation, as well as in emerging areas including video understanding and 3D vision were summarized. Finally, the future research directions of CIL were prospected.

**Keywords:** class-incremental learning; catastrophic forgetting; memory replay; parameter and optimization constraints; model prediction calibration; model architecture design; transfer of pre-trained models

近些年来,深度学习技术在计算机视觉<sup>[1]</sup>、语音识别<sup>[2]</sup>、自然语言处理<sup>[3]</sup>等领域取得了长足的发展。在实际应用中,为了适应复杂多变的环境,模型需要具备持续获取新知识的能力<sup>[4]</sup>。传统深度神经网络依靠固定的训练数据集来完成训练,在迁移到新的数据或者任务的时候,容易出现对原有类别识别精度显著降低的问题,学术界将其称为“灾难性遗忘”<sup>[5]</sup>。如何在学习新知识的同时保持对已有知识的稳定记忆,成为当前研究的核心挑战之一。

为缓解灾难性遗忘,研究者提出了持续学习(continual learning)这一学习范式,该范式在文献中有时也被称为增量学习(incremental learning)或终身学习(lifelong learning),旨在使模型能够在数据分阶段到达的情况下持续获取新知识,同时保持对已有知识的记忆能力。三者文献中常被交替使用,通常强调模型在动态环境中的长期学习能力与抗遗忘能力。根据任务设定的不同,持续学习通常可划分为任务增量学习(task-incremental learning)、域增量学习(domain-

收稿日期:2026-02-10

基金项目:国家自然科学基金资助项目(62403485)

第一作者:张文卓(1996—),男,湖南长沙人,博士研究生,E-mail:zhangwenzhuo21@nudt.edu.cn

\*通信作者:徐昕(1974—),男,湖北宜昌人,教授,博士,博士生导师,E-mail:xinxu@nudt.edu.cn

引用格式:张文卓,徐昕,蒯杨柳,等.类增量学习研究进展[J].国防科技大学学报,2026,48(3):316-338.

Citation:ZHANG W Z, XU X, KUAI Y L, et al. Recent advances in class-incremental learning[J]. Journal of National University of Defense Technology, 2026, 48(3): 316-338.

incremental learning) 和类增量学习(class-incremental learning)。其中,任务增量学习依赖显式的任务标识,在测试阶段可利用任务边界进行判别;域增量学习保持类别空间不变,仅数据分布发生变化;而类增量学习则在训练过程中逐步引入新的类别,并在测试阶段要求模型在统一的类别空间中对所有已学习类别进行预测<sup>[6-7]</sup>。由于在测试阶段需要在统一类别空间内进行预测,而训练过程中无法访问完整的历史数据,类增量学习更容易受到灾难性遗忘问题的影响。

针对类增量学习的灾难性遗忘问题,早期的研究多采用记忆相关的方法,在增量阶段保存历史样本来缓解模型对于旧类别的性能衰减。随后,一部分学者开始研究参数空间以及优化过程,使用正则化、知识蒸馏或梯度约束等方法降低模型更新对已有知识的影响。除此之外,还有一部分学者对类增量学习中出现的预测偏置问题进行了研究,通过校正模型的预测输出来缓解新旧类别之间的不平衡问题。与此同时,基于模型结构设计的思想也被提出,例如固定部分网络结构或

者引入可扩展子网络,给新类别提供更多的表示能力。近几年来,预训练模型的成功对类增量学习研究产生了影响,相关的研究也开始尝试使用提示学习、参数高效微调等方式,在利用预训练通用特征表示的基础上适应新的类别。

尽管上述方法在一定程度上缓解了灾难性遗忘问题,但不同方法在问题设定、适用场景方面仍存在较大差异,尚未形成统一的分类框架。围绕持续学习与增量学习,已有学者开展了综述性研究,从方法分类、实验基准以及应用场景等角度进行了总结,如表1所示。然而,现有综述大多从持续学习整体视角展开,对类增量学习这一特定设定的系统梳理相对有限,尤其在预训练模型背景下的相关方法归纳方面仍有进一步整合空间。

基于此,本文聚焦类增量学习,对近年来相关方法与研究进展进行系统梳理,重点总结记忆回放、参数与优化约束、预测校正、模型结构设计及预训练模型迁移等代表性技术路线,并结合常用数据集、评价指标及典型应用分析该领域的发展现状与未来趋势。

表1 类增量学习相关综述工作的对比

Tab.1 Comparison of related survey works on class-incremental learning

综述	覆盖范围	分类框架	实验基准	应用场景
文献[8]	面向广义增量学习设置	正则约束、信息存储和动态网络	在统一实验设置下的主流方法评测	主要面向图像分类等典型增量识别任务
文献[9]	面向广义增量学习设置	正则化、回放、梯度约束和网络结构调整	常用数据集、评价指标,未涉及统一实验评测	面向视觉任务,并扩展到自然语言处理等场景
本文	聚焦类增量学习	记忆回放、参数与优化约束、模型预测校正、模型结构设计、预训练模型迁移	数据集、评价指标,代码库与代表性方法评测	聚焦类增量视觉任务,并讨论生成式与开放场景下的扩展应用

## 1 类增量学习介绍

本节对类增量学习的基本问题设定进行形式化说明。首先给出类增量学习的统一建模方式,并分析其在训练和测试阶段的关键假设;随后将其与任务增量和域增量的设定进行对比,明确类增量学习在研究目标和评测方式上的独特性。

### 1.1 类增量学习的定义

类增量学习是持续学习的一种典型设定,其研究目标是在数据以时间序列方式到达且类别空间随时间不断扩展的场景下,使模型能够在不断学习新类别的同时,保持对已学习类别的判别能力。在该设定中,新类别数据分阶段逐步引入,模型在

训练过程中无法访问先前阶段的完整训练数据,且在测试阶段需要在不提供其他标识的情况下对所有已学习类别进行预测。

给定一系列按时间顺序到达且类别互不重叠的数据集 $\{D^1, D^2, \dots, D^T\}$ 。其中,每个子数据集对应一个增量训练阶段,按时间顺序依次到达。对于 $t \in \{1, \dots, T\}$ ,第 $t$ 个任务对应的子数据集为 $D^t$ ,其训练数据定义为 $D^t = \{(x_i^t, y_i^t)\}_{i=1}^{s_t}$ ,包含 $s_t$ 个训练样本。其中, $x_i^t \in \mathbb{R}^D$ 表示输入样本, $y_i^t \in Y_t$ 表示其类别标签, $Y_t$ 表示第 $t$ 个任务对应的子数据集的标签空间。在训练第 $t$ 个任务对应的子数据集时,模型只能访问当前子数据集 $D^t$ 中的数据。在测试阶段,模型需要在所有已学习类别的联合标签空间 $Y_{1:T} = Y_1 \cup \dots \cup Y_T$ 上进行预测。

形式化地,类增量学习旨在通过最小化期望风险来学习一个分类函数:  $f(x): X \rightarrow Y_{1:t}$ , 其定义如式(1)所示。

$$f^* = \arg \min_{f \in H} \mathbb{E}_{(x,y) \sim D^1 \cup \dots \cup D^t} [\mathbb{I}(y \neq f(x))] \quad (1)$$

式中:  $H$  表示假设空间;  $\mathbb{I}(\cdot)$  为指示函数, 当条件成立时取值为 1, 否则为 0;  $\mathbb{E}[\cdot]$  表示经验风险。一个理想的类增量学习模型应当在测试阶段能够在所有已学类别构成的联合标签空间上进行有效判别, 从而在学习新类别的同时保持对旧类别的识别能力。

### 1.2 类增量学习与其他增量学习设定的对比

在持续学习的不同增量设定中, 类增量学习由于其测试阶段缺乏任务标识且类别空间持续扩展, 被普遍认为是最具挑战性的情形之一。为突出其设定特点, 下面将类增量学习与任务增量学习和域增量学习进行对比。

表 2 对比了三种常见的增量学习设定在任务标识可获得性和判别空间上的差异。三种设定的核心区别体现在测试阶段模型是否已知当前任务标识(identity, ID), 以及模型需要进行判别的类别范围, 这两点直接导致了学习与推理难度上的差异。

表 2 三种典型增量学习设定的对比

Tab. 2 Comparison of three typical incremental learning settings

设定	任务 ID	判别空间
域增量学习	不可知	固定类别
任务增量学习	已知	任务内类别
类增量学习	不可知	全类别

在域增量学习设定下, 测试阶段模型无法获得任务 ID, 即无法获知当前样本所属任务。然而, 各任务之间共享相同的标签空间, 模型在所有阶段所面对的判别类别集合保持一致。需要强调的是, 这里的“类别集合”指的是任务间共享的标签空间, 而非数据集中所有可能类别的全局集合。以图 1 所示为例, 尽管不同任务引入了不同的数字实例, 但模型在测试阶段始终需要解决的是同一个判别问题, 即判断输入数字为奇数还是偶数。

在任务增量学习设定下, 测试阶段模型可以获得当前样本所属的任务标识, 即任务 ID 已知, 模型的判别空间被限制在当前任务对应的类别子集内。以图 2 所示的任务序列为例, 在任务 1 中




图 1 Split MNIST 数据集下域增量学习设定的示意图<sup>[7]</sup>

Fig. 1 Illustration of domain-incremental learning settings on the Split MNIST dataset<sup>[7]</sup>

模型仅需在类别 {0, 1} 内进行判别, 在任务 2 中仅需在 {2, 3} 内进行判别。




图 2 Split MNIST 数据集下任务增量学习设定的示意图<sup>[7]</sup>

Fig. 2 Illustration of task-incremental learning settings on the Split MNIST dataset<sup>[7]</sup>

相比域增量学习和任务增量学习, 类增量学习在测试阶段既无法获得任务标识, 又需要在不断扩展的统一标签空间中进行判别, 因此通常被认为更具挑战性。在该设定下, 不同任务会逐步引入新的类别, 模型在任一阶段都必须在所有已学习类别构成的整体标签空间中进行预测。如图 3 所示, 模型在完成任务 1 后需要能够区分类别 {0, 1}, 在完成任务 N 后需要能够区分 {0, 1, ..., 4, 5}。




图 3 Split MNIST 数据集下类增量学习设定的示意图<sup>[7]</sup>

Fig. 3 Illustration of class-incremental learning settings on the Split MNIST dataset<sup>[7]</sup>

### 1.3 类增量学习中灾难性遗忘的机理分析

在类增量学习场景下, 由于历史任务数据通常不可访问, 模型在第  $t$  个任务阶段的更新仅由当前数据  $D^t$  驱动, 其优化目标可表示为:

$$\theta_t^* = \operatorname{argmin}_{\theta} \mathbb{E}_{(x,y) \sim D^t} [L(f_{\theta}(x), y)] \quad (2)$$

式中:  $L(\cdot, \cdot)$  表示损失函数, 通常用于衡量模型预测  $f_{\theta}(x)$  与真实标签  $y$  之间的差异。

这意味着参数更新主要服务于当前任务, 而难以同时维持旧任务对应的最优解区域。若记旧

任务与当前任务在参数  $\theta$  处的梯度分别为

$$\begin{cases} g_{\text{old}} = \nabla_{\theta} L_{1:t-1}(\theta) \\ g_{\text{new}} = \nabla_{\theta} L_t(\theta) \end{cases} \quad (3)$$

当  $\langle g_{\text{old}}, g_{\text{new}} \rangle < 0$  时,表明两者存在明显的梯度冲突,此时沿新任务梯度方向更新虽可降低当前任务损失,却往往会增大旧任务损失,使模型参数逐渐偏离旧任务的稳定解,从而引发旧类别性能退化。

从表示几何角度进一步分析:在交叉熵损失充分优化后,深度网络通常会呈现神经坍缩现象,即类内特征向类别中心收缩、类间中心形成规则分布,且分类器权重与类别中心方向对齐。设特征提取映射为  $\phi(x)$ ,第  $k$  类中心定义为:

$$\mu_k = \frac{1}{N_k} \sum_{i: y_i=k} \phi(x_i) \quad (4)$$

在类增量阶段,由于旧类样本不可访问,新任务驱动的参数更新不仅会调整分类器权重,还会扰动特征空间结构,使旧类类别中心发生偏移,并破坏原有的神经坍缩几何形态。由此,旧类决策边界逐渐退化,最终导致旧类别性能下降。

因此,灾难性遗忘不仅源于梯度冲突引起的参数偏移,也源于参数更新对神经坍缩结构的破坏,二者共同作用,最终导致旧类别性能下降。

## 2 类增量学习方法

类增量学习方法的发展体现了对灾难性遗忘机理认识的不断深化,其演进脉络大致可概括为三个阶段:首先是“外部数据补偿”阶段,主要通过记忆回放或生成式回放近似恢复旧任务数据分布,以缓解历史样本不可访问带来的信息缺失;其次是“内部参数调控”阶段,研究者从参数更新与梯度干扰出发,借助参数正则化、梯度约束和输出分布校正等策略抑制新旧任务冲突;进一步地,方法发展进入“结构与表示适应”阶段,即通过动态扩展网络结构或利用大规模预训练模型进行迁移适配,从抑制遗忘逐步转向提升表示稳定性与泛化能力。

在这一演进框架下,现有类增量学习方法可根据其缓解遗忘的核心作用机制划分为基于记忆回放、参数与优化约束、模型预测校正、模型结构设计以及预训练模型迁移等类别,如表3所示。需要说明的是,实际方法设计往往融合多种技术机制,例如部分结构扩展方法同时结合特征回放或蒸馏约束。因此,各类别之间并非严格互斥。本文基于方法的主要设计动机与核心创新点进行归类,以突出不同研究思路的发展脉络,而对于涉及多种机制的交叉型方法,将在具体方法介绍中加以说明。

表3 不同类增量学习方法的特点

Tab. 3 Characteristics of different class-incremental learning methods

类别	方法	特点
记忆回放	原始数据回放	存储真实样本,遗忘缓解效果显著;存储开销大,存在隐私风险
	压缩数据回放	降低存储成本并保持一定性能;压缩引入信息损失,对压缩方式依赖性强
	生成式数据回放	无须保存真实数据,扩展性和隐私性较好;依赖生成质量,训练复杂
参数与优化约束	知识蒸馏约束	保持旧类判别能力且无须原始数据;限制新类学习并依赖教师模型质量
	参数正则化约束 梯度约束	实现简单,额外开销低;对大规模类增量学习性能提升有限 从优化角度抑制遗忘,理论可解释性强;计算复杂度较高
模型预测校正	模型预测校正	缓解新旧类别预测偏差;无法从根本上避免特征遗忘
模型结构设计	固定模型结构	推理成本稳定,易于部署;模型容量受限,适应性不足
	模型结构扩展	提升模型容量以适应新类别;模型规模持续增长,计算代价较高
预训练模型迁移	提示学习	参数更新少,遗忘风险低;提示设计依赖经验
	主干参数微调 视觉-语言模型驱动	对新类别适应能力强;参数更新范围大,易导致旧类别特征漂移 泛化能力强;模型规模较大,计算成本高,对提示设计与文本表达较为敏感

### 2.1 基于记忆回放的方法

基于记忆回放的方法通过保存少量旧类别样本或其替代表示,并在学习新类别时将其与当前

类别数据共同用于模型优化,从而缓解灾难性遗忘。其核心在于利用有限的历史信息重新引入旧类别的监督约束,使模型参数更新兼顾新旧知识。

如图 4 所示,在每个增量阶段,模型一方面接收当前任务数据,另一方面从记忆缓冲区中采样少量历史样本,并将二者联合用于训练。相应地,该类方法的训练目标通常可表示为当前数据损失与回放数据损失的加权联合:

$$\min_{\theta} \mathbf{E}_{(x,y) \sim D^t} [L(f_{\theta}(x), y)] + \lambda \mathbf{E}_{(x,y) \sim B} [L(f_{\theta}(x), y)] \quad (5)$$

式中,  $\lambda$  为用于平衡新旧任务影响的权重系数,  $B$  是一个规模受限的记忆缓冲区。根据回放信息构造方式的不同,现有方法可进一步分为原始数据回放、压缩数据回放和生成式数据回放。

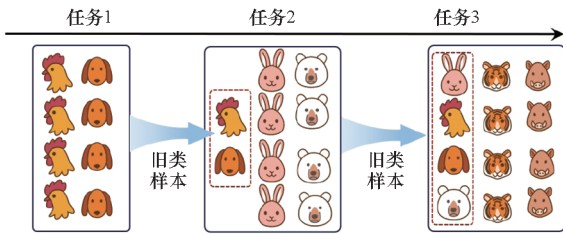


图 4 基于记忆回放的类增量学习方法示意图

Fig. 4 Schematic diagram of memory replay-based class-incremental learning method

### 2.1.1 原始数据回放

原始数据回放方法是最早被系统性引入并进行研究的一类回放策略。该类方法直接存储旧类别的原始训练样本,单个样本的信息不变,核心问题在于怎样在有限的存储空间里设计有效的样本选择和替换策略,使得回放样本尽可能地代表历史数据或者对模型更新起到关键作用。

增量分类与表征学习<sup>[10]</sup> (incremental classifier and representation learning, iCaRL) 方法是原始数据回放方法中早期的代表性工作,其主要思想是维持一组由原始样本组成的缓冲区,从而减少类增量学习中的灾难性遗忘。iCaRL 中缓冲区样本的选择采用集聚选择策略<sup>[11]</sup> (Herding strategy),在特征空间中贪心地构造样本子集,使有限的记忆可以近似类别整体的特征分布。第  $k$  步,选择样本的方式可以表示为:

$$x_k = \arg \min_{x \in D_c} \left\| \mu_c - \frac{1}{k} (\phi(x) + \sum_{i=1}^{k-1} \phi(x_i)) \right\|_2 \quad (6)$$

式中,  $D_c$  表示类别  $c$  的完整训练数据集,  $\mu_c$  表示类别  $c$  的特征均值,  $\phi(\cdot)$  为特征提取函数。在利用回放样本进行联合训练的同时, iCaRL 还通过知识蒸馏对齐新旧模型的输出分布来缓解表示漂移,从而进一步减轻遗忘现象。

在此基础上,后续研究主要围绕回放样本的

选择和组织展开:

1) 一类方法侧重从表示学习、样本价值评估等角度改进样本筛选策略。例如,文献[12]延续 Herding 的基本思想,但通过端到端方式联合优化特征表示与分类器参数,使记忆样本能够更直接地参与表示学习,从而提升类增量过程中的表示一致性;也有研究从合作博弈的角度出发,利用沙普利值度量单个样本对整体训练性能的边际贡献,并据此指导记忆样本选择<sup>[13]</sup>;还有方法采用动态聚类建立记忆结构,并依据样本间的知识差异自适应扩展内存,以提升记忆的多样性与有效性<sup>[14]</sup>。

2) 另一类方法将样本选择视为样本子集<sup>[15]</sup> (coreset) 构建问题,利用小规模样本近似完整历史数据,相关方法通常从梯度近似或优化建模角度出发。例如:通过梯度匹配原则选择加权样本子集,使回放缓冲区产生的梯度尽可能逼近完整历史数据的梯度<sup>[16]</sup>;或将离散的样本选择问题转化为连续概率分布,并在双层优化框架下学习样本选择机制<sup>[17-18]</sup>;此外,也有方法在类均衡记忆设置下结合分类器梯度信息,在类别内部协同选择关键样本<sup>[19]</sup>。

总体而言,原始数据回放通过保留原始数据样本能够有效地缓解灾难性遗忘,但是其性能高度依赖于存储预算与样本选择策略,同时也面临数据隐私、存储开销和长期扩展性不足等问题。

### 2.1.2 压缩数据回放

压缩数据回放方法从样本的存储表示入手,在固定内存约束下,通过压缩单个样本的存储成本来扩大可回放的信息量。与通过筛选有限数量高保真样本进行回放的方法不同,该类方法更关注如何以紧凑形式保留和利用旧类别信息。

现有方法大致可以从输入压缩和表示压缩两个方面展开。一种直接思路是利用有损压缩减少单个样本的存储开销,如采用低分辨率表示存储历史图像,并结合知识蒸馏缓解压缩带来的信息损失<sup>[20]</sup>。在此基础上,有研究分析了不同压缩策略对历史任务分布恢复能力的影响,指出压缩强度与判别性能之间存在权衡关系<sup>[21]</sup>。相比之下,表示压缩不再直接保存原始输入,而是转向存储中间层或高层特征表示,以实现更高效的内存利用。例如,文献[22]通过对中间特征进行张量量化,实现特征级回放,在显著降低存储成本的同时保持较好性能。也有方法借助特征适配机制,在保持历史判别信息的同时显著降低特征存储成本<sup>[23]</sup>。面向类增量学习的特征增强与压缩方

法<sup>[24]</sup> (feature boosting and compression for class-incremental learning, FOSTER) 在增强历史类别表示能力的同时引入特征压缩机制,通过紧凑存储历史类别的特征表示提升回放效率,并结合模型扩展策略进一步增强表示能力。

除上述两种思路外,还有研究将数据集压缩的方法引入类增量学习,通过在低维流形上构造小规模合成数据集来近似原始数据的训练效果<sup>[25]</sup>。这类方法可被视为压缩数据回放的一种扩展形式,其回放样本并非真实历史数据,而是经过优化得到的合成实例。

总体而言,压缩数据回放能够在有限的存储预算下提高样本利用效率,但相关研究数量较少,其性能在很大程度上依赖于压缩方式、模型表示以及回放机制之间的协同设计。

### 2.1.3 生成式数据回放

生成式数据回放的方法通过训练生成模型来近似历史任务的数据分布,并在后续任务中生成伪样本参加训练,从而在不直接存下真实样本的条件下缓解灾难性遗忘。

早期研究主要在输入空间生成样本。其中,深度生成回放方法<sup>[26]</sup> (deep generative replay, DGR) 利用生成对抗网络产生旧类别样本并与新类别数据一起训练分类器,从而奠定了生成数据回放的基本范式。此后,相关工作主要围绕生成稳定性与类别可控性展开改进,例如通过约束新旧生成模型的一致性减小分布漂移<sup>[27]</sup>,以及利用条件生成机制实现特定类别样本或表示的生成<sup>[28]</sup>。除输入空间外,一些方法开始研究在特征空间进行回放,生成中间层特征表述替换原始样本,从而降低高维数据建模的复杂度<sup>[29]</sup>。

随着生成模型能力的提升,扩散模型因其在分布建模稳定性和生成质量方面的优势,逐渐被引入类增量学习框架。代表性方法如基于深度扩散的生成回放方法<sup>[30]</sup> (deep diffusion-based generative replay, DDGR)、文献[31]和面向蒸馏与回放的稳定扩散方法<sup>[32]</sup> (stable diffusion for distillation and replay, SDDR),它们分别从生成回放、类别增量建模以及蒸馏结合等角度推动了扩散模型在类增量学习中的应用。相比传统对抗生成方法,扩散模型显著提升了生成样本的质量与多样性,已成为生成式回放的重要发展方向。

为避免显式生成器在持续训练过程中对历史分布本身发生遗忘,研究者进一步提出了基于模型反演的生成式回放方法。这类方法不再单独训练生成模型,而是直接利用当前模型合成旧类别

样本。文献[33]首先证明了模型反演生成样本在类增量学习中的可行性,文献[34]将其进一步拓展到无样本类增量学习场景。在此基础上,双重一致性模型反演<sup>[35]</sup> (dual consistency model inversion, DCMI) 通过引入双重一致性约束,进一步提升了生成样本的稳定性与判别性。

总体而言,生成式数据回放通过生成模型替代显式样本存储,在一定程度上缓解了内存受限问题,并推动了类增量学习从对抗生成向扩散建模、再到模型反演的发展。然而,该类方法的性能仍依赖于对历史数据分布的准确刻画,一旦生成分布偏离真实分布,误差便可能在后续任务中持续累积,从而影响整体性能。

## 2.2 基于参数与优化约束的方法

在类增量学习场景中,模型在每一阶段的训练目标由当前任务数据所主导,参数更新过程容易偏离对历史类别有利的优化区域,从而导致灾难性遗忘。基于参数与优化约束的方法不再依赖历史数据的显式回放,而是试图通过约束模型参数或优化过程本身,抑制新任务学习对已有知识的破坏。

这类方法通常将当前任务的优化目标表示为:

$$\min_{\theta} \mathbb{E}_{(x,y) \sim D^t} [L(f_{\theta}(x), y)] + \lambda R(\theta; \theta^{t-1}) \quad (7)$$

其中,  $\theta^{t-1}$  表示在历史任务上学习得到的模型参数,  $R(\cdot)$  为与历史知识相关的约束项,  $\lambda$  用于平衡新旧任务之间的影响。

参数与优化约束方法的核心思想是通过参数更新路径施加限制,使模型在学习新类别时尽量保持与历史任务解的一致性。根据约束施加的对象不同,现有方法大致可以分为知识蒸馏约束、参数正则化约束和梯度约束。

### 2.2.1 知识蒸馏约束

知识蒸馏约束方法通过引入历史模型作为教师网络,在不显式访问旧任务数据或仅依赖少量回放样本的条件下,约束当前模型在旧类别上的预测行为,从而缓解灾难性遗忘,如图5所示。这类方法通常通过最小化新模型与历史模型在输出分布、特征表示或结构关系上的差异,实现对旧知识的保留。

早期工作主要在输出层和特征层进行直接对齐,其中无遗忘学习方法<sup>[36]</sup> (learning without forgetting, LWF) 是该方向的代表性工作,其核心思想是在学习新类别时,通过蒸馏损失约束旧类别的输出分布,使模型在学习新任务的时候保持

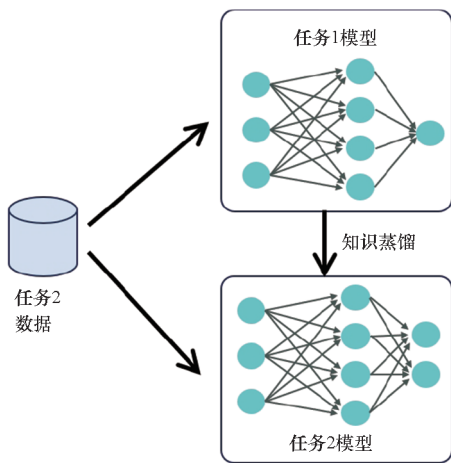


图 5 基于知识蒸馏约束的类增量学习方法

Fig. 5 Class-incremental learning method based on knowledge distillation constraints

旧类别的决策边界。该方法建立了类增量学习中“历史模型监督当前模型”的基本蒸馏范式,为后续研究奠定了基础。随后,研究者进一步关注蒸馏位置与蒸馏形式对性能的影响。例如,文献[37]利用池化特征进行蒸馏,提高了特征约束对局部扰动的鲁棒性;文献[38]则进一步通过自适应方式选择更敏感的特征进行蒸馏,以平衡稳定性与可塑性。

随着研究深入,蒸馏目标逐渐由逐样本预测或特征对齐扩展到对样本间关系及表示空间整体结构的保持。相较于仅约束单个样本的输出或特征,这类方法更加关注旧知识在表示空间中的组织形式及判别关系。具体而言,文献[39]从拓扑结构层面约束特征空间,以维持表示空间的整体组织形式;文献[40]通过保持样本相似性排序的稳定性来约束模型判别方式;文献[41]进一步将蒸馏对象集中于原型与样本之间的关系层级,从而在无回放场景下提升知识保持能力。总体来看,这类方法表明知识蒸馏已由局部对齐逐步发展为对全局表示结构与判别关系的建模。

然而,随着任务序列变长,教师模型自身的退化逐渐成为限制知识蒸馏的重要因素。教师网络通常来源于前一阶段模型,其表征与预测误差可能在持续传递过程中不断累积,从而导致蒸馏目标随时间发生漂移。针对这一问题,文献[42]通过快慢学习机制构建更稳定的教师参考,以缓解蒸馏目标随时间漂移的问题;文献[43]在此基础上进一步引入多机制协同,以同时促进知识保持与新知识迁移;文献[44]则通过显式调整教师模型来缓解教师-学生间的分布偏移,进一步提升

蒸馏稳定性。

总体而言,知识蒸馏约束方法围绕蒸馏对象、对齐粒度和教师构建方式不断演化,在缓解灾难性遗忘方面具有较强灵活性。然而,该类方法的长期性能仍高度依赖教师模型质量,误差累积以及稳定性-可塑性权衡问题仍是其面临的主要挑战。

### 2.2.2 参数正则化约束

参数正则化约束方法在新类别训练时,通过显式约束对旧任务较为重要的参数,降低新类别学习对旧类别知识的影响。该类方法通常首先估计参数的重要性,然后在目标函数中引入相应的正则项,使对旧任务贡献较大的参数在后续学习过程中尽可能保持稳定。

早期研究主要从二阶近似角度刻画参数重要性。其中弹性权重巩固方法<sup>[45]</sup>(elastic weight consolidation, EWC)是该方法的代表性工作。EWC利用费歇耳信息矩阵估计参数对旧类别的敏感性,并通过二次惩罚项限制重要参数的更新,从而在学习新任务时尽可能保留旧知识。在此基础上,文献[46]用结构化拉普拉斯近似,对在线学习环境中参数不确定性进行更精细的建模;文献[47]则从变分推断角度统一了参数正则化和贝叶斯更新的过程,为后续方法提供了更完整的理论解释框架。

除基于二阶信息的重要性估计方法外,另一类研究利用任务训练过程中的梯度轨迹来衡量参数的重要性。这类方法避免了对费歇耳信息的显式计算,降低了计算复杂度。例如,文献[48]通过参数在训练过程中对损失下降的累积贡献来度量其重要性;文献[49]在此基础上进一步增强了参数选择与保护机制,以提高对历史知识的保持能力;文献[50]则从几何角度重新解释参数约束问题,在黎曼流形上限制参数更新的方向来缓解遗忘。

随着任务复杂度的增加,仅依赖参数级重要性估计的约束方式难以获得较高精度。为此,部分研究从更高层次的表示或预测行为出发,对模型更新施加间接约束。文献[51]通过匹配新旧类别激活分布的统计矩阵来间接约束参数更新,从而避免显式计算单个参数的重要性;文献[52]进一步将正则化思想应用于分类器投影空间,以减弱新类别学习对旧类别判别边界的冲击;文献[53]则将约束对象由参数空间扩展到函数空间,从模型输出行为层面保持历史知识,为参数正则化方法提供了更一般的表述形式。

总体而言,参数正则化约束方法的主要优势是低存储开销和实现简单,但是性能高度依赖于参数重要性估计的准确性。当任务差异较大或者网络容量不足的时候,过强的参数约束会降低模型对新类别的适应能力。

### 2.2.3 梯度约束

梯度约束方法通过在参数更新阶段直接干预梯度方向或梯度空间结构,限制新任务学习对旧任务性能的负向影响,如图6所示。与参数正则化在参数空间施加静态约束不同,该方法从优化过程入手,通过约束梯度投影、抑制梯度冲突或引导梯度落入特定子空间,在保证可塑性的同时维持对历史任务的稳定性。




图6 基于梯度约束的类增量学习方法

Fig.6 Class-incremental learning method based on gradient constraints

早期研究主要通过构造受约束的梯度更新来保护历史任务性能。梯度情景记忆方法<sup>[54]</sup> (gradient episodic memory, GEM)通过保存少量历史任务的原始样本来构建记忆缓冲区,在每一次参数更新的时候要求当前类别的梯度不增加旧类别的损失,把优化问题转化为带约束的投影问题。为降低其计算开销,文献[55]采用合并参考梯度近似原始约束集合,在保留主要约束效果的同时显著提高了训练效率。进一步地,文献[56]从梯度相互作用角度系统分析了持续学习中的迁移与干扰现象,指出应通过增强正迁移、减弱梯度冲突来指导后续优化设计。

随着研究深入,梯度约束逐渐由显式约束扩展为对子空间结构的建模。在此类方法中,研究者不再仅关注单次梯度更新是否违反历史约束,而是进一步刻画新旧任务梯度之间的结构关系。例如,文献[57]将当前梯度投影到与历史梯度正交的子空间,以减少新旧任务之间的干扰;文献[58]进一步在网络层级上分解梯度,使不同层能够分别调节稳定性与可塑性;文献[59]通过构造历史任务相关的梯度子空间来约束参数更新方

向,从而保留已有知识;文献[60]则对零空间约束进行更细致建模,以提升稳定性与可塑性之间的平衡能力。此外,文献[61]进一步利用曲率正则化稳定锐度感知优化过程,从而改善持续学习中的梯度更新质量。

总体而言,梯度约束方法能够直接从优化层面缓解任务间冲突,因此在在线学习或任务快速切换场景中具有明显优势。然而,这类方法常常需要额外的梯度存储、子空间估计或投影计算,在大规模任务序列和高维模型下仍面临计算复杂度与训练稳定性之间的权衡问题。

## 2.3 基于模型预测校正的方法

基于模型预测校正的方法从输出层偏置问题出发,认为类增量学习中的性能退化并不完全源于特征表示的遗忘,还与模型预测结果对新类别的系统性偏向密切相关。如图7所示,在增量训练过程中,新类别通常因样本数量和训练频率而获得更高的预测概率,导致模型在测试阶段更倾向于将样本判为新类别。针对这一问题,该方法通常不显式重构特征表示,也不直接约束参数更新,而是通过对模型输出重新标定或变换来缓解新旧类别之间的预测偏置。对输入样本 $x$ 的输出可表示为:

$$p(y|x) = \text{softmax}(z(x)), z(x) = \phi(x) \quad (8)$$

其中, $z(x)$ 为分类层输出的逻辑值, $\phi(\cdot)$ 是特征提取函数。在此基础上,模型预测校正方法进一步引入校正函数 $\zeta(\cdot)$ ,对原始输出进行变换:

$$\tilde{z}(x) = \zeta(z(x)) \quad (9)$$

并基于校正后的输出 $\tilde{z}(x)$ 进行最终预测。




图7 基于模型预测校正的类增量学习方法

Fig.7 Class-incremental learning method based on model prediction correction

基于模型预测校正的方法主要通过分类器校准、结构设计、分类过程调整以及表示约束等方

式,对模型输出行为进行修正,使模型在新旧类别之间获得更加均衡和稳定的判别能力。该类方法通常不直接约束参数或梯度更新,而是在训练或推理阶段对模型输出行为进行校正,从而缓解由数据分布不平衡和训练顺序带来的性能退化。

早期研究主要集中在分类器层面的偏置校正。偏置校正方法<sup>[62]</sup> (bias correction, BiC) 指出类增量学习中统一分类器易受到新类别样本数量优势的影响,并通过后处理校准策略缓解预测偏置。与此同时,文献[63]从类别不平衡优化的角度出发,在训练阶段引入重平衡机制,使新旧类别在统一分类器中得到更公平的优化。权重对齐方法<sup>[64]</sup> (weight aligning, WA) 则从判别性与公平性角度分析分类偏置问题,通过约束分类器更新以维持旧类别的判别能力。除偏置后处理外,后续方法还从三个方面对模型输出进行校正:一是通过结构设计减弱新旧类别之间的分类干扰,如文献[65]提出的分离式 softmax;二是通过损失解耦分别优化表征学习与分类器更新<sup>[66]</sup>;三是通过分阶段分类逐步修正新类别判别边界<sup>[67]</sup>。这些方法均不直接约束参数更新,而是通过调整分类过程缓解预测偏置。

除直接调整分类器外,后续研究还从类别分布与表示几何两个方面对模型行为进行校正。一类方法利用类别分布信息缓解新旧类别之间的不平衡影响<sup>[68]</sup>。另一类方法则借助神经坍塌理论约束特征与分类器之间的几何关系:文献[69]指出,在类别不平衡条件下,固定或约束分类器结构有助于维持更均衡的类别间几何分布,从而缓解分类器偏向多数类或新类别的问题;文献[70]进一步将这一思想引入少样本类增量学习,通过对齐特征表示与分类器结构来减少预测偏置。

总体而言,基于模型预测校正的方法通过直接调节模型输出行为,在缓解类增量学习中的预测偏置方面表现出较高的有效性,且通常具有较低的实现复杂度。然而,该类方法多依赖特定任务设置或分类结构,其泛化能力在复杂任务序列和跨范式模型中仍有进一步探索空间。

## 2.4 基于模型结构设计的方法

基于模型结构设计的方法通过改变网络结构或参数使用方式来减轻不同增量阶段之间的参数干扰,对于第  $t$  个任务增量阶段,模型的预测函数可统一表示为:

$$f_t(x) = \mathbf{W}_t^T \phi_t(x) \quad (10)$$

其中,  $\phi_t(x)$  为第  $t$  个任务增量阶段样本  $x$  的特征

表示,  $\mathbf{W}_t$  为对应的分类器参数矩阵。

在固定模型结构的设定下,新类别学习易覆盖旧知识对应的参数表示。为此,一类方法在固定参数集合上引入阶段相关的掩码或门控机制,使不同阶段使用不同参数子集:

$$\phi_t(x) = \phi(x; \Theta \odot m_t) \quad (11)$$

其中:  $m_t$  表示掩码或门控机制,用于控制在任务阶段  $t$  实际参与计算的参数子集;  $\odot$  表示逐元素乘法,用于控制参数集合  $\Theta$  中实际参与当前阶段计算的有效参数子集。另一类方法则通过动态扩展网络结构,为新阶段分配新增参数或模块:

$$\phi_t(x) = \phi(x; \Theta_t), \Theta_t \supset \Theta_{t-1} \quad (12)$$

通过在结构层面为新类别引入额外的网络单元或模块,该类方法能够显式提升模型容量,并减少新旧类别在参数空间中的直接冲突。

### 2.4.1 固定模型结构

在固定模型结构的持续学习方法中,模型的整体网络拓扑在训练过程中是不变的,新类别的出现不会引起神经元、层或者分支的直接扩展。这类方法的核心是在共享网络结构的前提下,通过调整参数使用方式、激活路径或有效子网络的选择,实现任务间的功能隔离与干扰缓解。

这类方法主要可分为三种思路:

1) 第一种思路是通过显式掩码或子网络选择实现任务隔离。文献[71]采用迭代剪枝的方式为每个任务分配互不重叠的参数子集,后续任务只能调用未分配的模型权重参数;文献[72]在共享主干参数的基础上引入可学习掩码,通过选择性激活不同权重实现任务适配;文献[73]则利用任务相关的注意力掩码对网络激活路径进行控制。进一步地,文献[74]和文献[75]表明,即使在固定权重空间中,不同任务仍可通过不同掩码选择出性能良好的任务子网络,从而支持多个任务在同一模型中的共存。

2) 第二种思路是从稀疏表示和参数选择角度提升固定结构下的持续学习能力。文献[76]在稀疏网络中动态调节连接的重要性,以兼顾旧任务保持与新任务适应;文献[77]通过估计参数不确定性,自适应控制关键参数的更新幅度;文献[78]则利用连续可学习的软掩码调节参数在新任务中的可塑性,使参数分配由硬约束进一步过渡到柔性控制。这种方法的共同特点是:在不改变网络拓扑的前提下,通过控制参数可塑性实现不同任务之间的资源分配。

3) 第三种思路是在固定结构下引入更灵活的任务调度机制。文献[79]通过建模任务间关联性,

选择性地促进有益迁移并抑制负迁移,从而在共享结构中实现更细粒度的知识协调。与单纯依赖掩码或稀疏约束的方法相比,这种方法更关注任务之间的关系建模及知识共享方式的动态调整。

总体来看,固定模型结构方法能够在不增加模型容量的前提下,通过掩码、稀疏性和软选择机制实现多任务共存,具有参数规模稳定和部署友好的优点。然而,当任务数量持续增加时,模型可用容量会逐渐被占用,其表示能力和长期可扩展性仍受到固定结构本身的限制。

#### 2.4.2 模型结构扩展

模型结构扩展方法通过在持续学习过程中显式引入新的结构单元,为新任务分配额外的表示能力,从而缓解不同任务间的参数冲突,如图8所示。这类方法的共同特征在于,模型的结构规模会随着任务的到来不断增长,从而使新旧任务主要依赖于不同的结构单元进行表示,因此能够在一定程度上避免共享参数所带来的直接干扰。




图8 基于模型结构扩展的类增量学习方法

Fig. 8 Class-incremental learning method based on model structure extension

这类方法主要可分为四种思路:

1) 第一种思路是通过直接扩展网络宽度或层级结构来适应新任务。文献[80]通过为新任务引入新的网络分支,并利用侧向连接复用旧任务知识,为后续结构扩展方法奠定了基础;文献[81]进一步根据任务需求动态增加网络容量,不再简单执行单一扩展,而是在共享、复用和扩展之间进行自适应选择,使模型能够在性能提升与参数增长之间取得更合理的平衡。此外,还有研究引入强化学习策略来决定网络结构的扩展方式,从而提升结构增长过程中的自适应性<sup>[82]</sup>。

2) 第二种思路是关注表示层或者特征空间的动态扩展。动态可扩展表征方法<sup>[83]</sup>(dynamically expandable representation, DER)通过不断为新类别引入新的表示维度来增强判别能力,并结合压缩样本回放机制,以在受限存储预算下缓解旧类别性能退化;文献[84]将此思想应用

到视觉变换器(vision transformer, ViT),通过扩展token或相关模块以适应新任务;文献[85]则结合扩展与融合机制,在新旧模块之间建立双向兼容关系,从而减轻结构增长过程中可能出现的模块冲突。

3) 第三种思路是从专家模块角度实现结构扩展。文献[86]为不同任务逐步引入新的专家网络,并学习任务到专家的映射关系,从而在多专家体系中不断拓展模型能力;文献[87]进一步通过选择性训练专家,构建随任务增长的专家集合,以提升多专家结构的扩展效率与任务适应性。

4) 第四种思路是从模块化和概率建模角度提升结构扩展的灵活性。文献[88]将模型表示为可组合的功能单元,并依据任务需求动态引入新的模块;文献[89]借鉴神经发生机制,在无回放条件下为新类别生成新的结构编码,从而增强类增量学习中的表征能力。

总体而言,模型结构扩展方法通过不断加入新的结构单元为新任务赋予特定表示空间,因此在缓解灾难性遗忘方面具有天然优势。但是,其参数规模会随着任务数量的增加而不断增大,导致存储和计算成本上升,这是这类方法面临的主要问题。

## 2.5 基于预训练模型迁移的方法

基于预训练模型迁移的方法通过在大规模数据上进行预训练,使模型学习到具有较强泛化能力的通用特征表示。因此类增量学习阶段的关键不再是重新学习特征表示,而是如何在尽量保持预训练知识不变的前提下,使模型能够有效适应新引入的类别。为此,该类方法通常将预训练模型视为特征提取骨干,并围绕其设计轻量级的阶段相关适配机制。

在形式上,基于预训练模型的类增量学习方法可统一表示为:

$$f_t(x) = g(\phi(x; \Theta), a_t) \quad (13)$$

其中: $\phi(x; \Theta)$ 表示参数为 $\Theta$ 的预训练模型; $a_t$ 表示阶段 $t$ 的适配变量,用于引导模型完成对当前类别集合的判别。根据适配变量 $a_t$ 在模型中的作用方式不同,相关方法主要可分为提示学习、主干参数微调和视觉-语言模型(vision-language models, VLMs)驱动三类。

### 2.5.1 提示学习

随着预训练模型的广泛应用,基于提示的方法逐渐成为类增量学习中的重要研究方向。这类方法的核心思想在于:通过在输入空间或中间表示中引入可学习提示,引导预训练模型适应新任

务分布。该方法的预训练模型通常保持冻结,仅优化少量提示参数,在充分利用预训练知识的同时,降低参数更新带来的遗忘风险。

这类方法首先关注提示参数的分配与选择机制。学会提示方法<sup>[90]</sup>(learning to prompt, L2P)通过构建可学习的提示池,并结合提示选择机制为不同输入分配合适的提示,从而实现对不同类别的有效区分。与此不同,文献[91]则将提示划分为通用提示和类别特定提示,使模型在保留共享知识的同时兼顾类别间的表示隔离,从而在知识共享与任务区分之间取得更好的平衡。

在提示参数的分配机制之外,研究者进一步关注提示学习在类增量学习过程中的稳定性与可控性。文献[92]引入自调节机制抑制不同提示之间的相互干扰,以减轻旧类别性能的显著退化;文献[93]则从优化角度出发,通过约束梯度更新方向,避免新任务学习过程对已有提示造成过大破坏;文献[94]指出,在无回放场景下,保持不同任务之间提示表示的一致性,有助于提升持续学习过程中的稳定性与知识保持能力。

除稳定性问题外,另一类工作从提示的结构化建模与分解角度展开研究。文献[95]对提示学习过程中的层次结构进行分析,指出其中可能存在的次优结构;文献[96]将提示机制与注意力机制相结合,通过分解式设计提升类别建模的细粒度能力;文献[97]则引入动态记忆机制,使提示能够随着任务序列的推进持续积累与更新,从而增强模型对长期任务演化的适应能力。

此外,还有研究探索多模态或跨结构的提示设计。文献[98]将语言信息加入提示学习过程当中,从而加强语义层面的任务区分能力。文献[99]将提示学习的思想扩展到卷积特征空间,提出卷积提示方法,用于提升 VLMs 在类增量学习中的性能。文献[100]则系统分析了基于提示的增量学习方法的适用条件与局限性,指出当预训练能力不足或任务差异较大时,单纯依赖提示学习难以取得理想效果。

总的来说,基于提示的类增量学习方法通过冻结预训练模型并仅更新少量提示参数,实现了较高的参数效率和良好的知识保持能力。但是这些方法的性能很大程度上取决于预训练模型,在复杂任务序列以及长时间学习场景下,其有效性仍有待进一步验证。

### 2.5.2 主干参数微调

主干参数微调方法通过对预训练模型主干网络的部分或全部参数进行更新,使模型在共享参

数空间内逐步适应新任务分布。与提示机制主要通过条件调节实现适配不同,主干微调直接在原有参数空间中进行优化,因此在特征表示和决策边界调整方面具有更大的优化空间。

早期研究主要关注如何对预训练主干进行受限更新,以兼顾模型的稳定性与适应性。文献[101]在预训练模型基础上采用深度线性微调策略,通过限制非线性参数更新来减弱不同任务之间的相互干扰;文献[102]则从迁移学习视角出发,在无回放条件下探索有效的主干参数更新机制,以提升模型对连续新类的适应能力;文献[103]进一步结合卷积结构与自注意力机制,通过持续微调增强局部特征建模能力,从而在不依赖样本回放的条件下提高类增量学习的稳定性。

除了直接约束主干更新,另一类工作更加重视微调过程中的阶段控制与优化策略设计。文献[104]指出,首个任务的主干微调方式对后续类增量学习性能具有显著影响,因而初始阶段的参数适配策略具有基础性作用;文献[105]提出结合慢学习器和分类器的框架,以缓解微调中由于类别不平衡、决策边界漂移带来的性能退化;文献[106]从模型组合的角度出发,研究连续微调模型的协同集成效果,以增强模型的鲁棒性。

近年来,随着参数高效持续学习研究的发展,部分工作开始在更新主干参数的同时引入轻量级适配模块,以兼顾训练稳定性与参数效率。文献[107]引入任务相关的适配器(Adapter),并在语义层面对其进行调节,以实现 ViT 模型的持续适配;文献[108]进一步提出融合任务特定 Adapter 与通用 Adapter 的框架,在大规模预训练模型基础上开展类增量学习,通过分离共享表示与任务特定调节模块,在保持模型稳定性的同时提升其可塑性。

总体而言,主干参数微调方法具有较强的任务适应能力和较高的性能上限,但由于不同任务在同一参数空间中竞争表示能力,在长序列或分布差异较大的场景下仍可能出现遗忘累积。因此,如何在保证模型可塑性的同时有效约束主干更新,是当前研究的重要方向。

### 2.5.3 视觉-语言模型驱动

在基于预训练模型的迁移框架下,VLMs 提供了不同于纯视觉模型的建模思路。该类模型通过图文联合预训练构建共享语义空间,使类别的文本语义信息能够直接参与类别判别过程。根据预训练目标与模型机制的不同,现有

面向类增量学习的 VLMs 大致可分为两类:一类基于对比式语言-图像预训练模型(contrastive language-image pretraining, CLIP),另一类基于自举式语言-图像预训练模型(bootstrapped language-image pretraining, BLIP)。

基于 CLIP 的类增量学习主要利用视觉编码器与文本编码器构建的共享嵌入空间,将类别名称与图像特征映射到统一语义表征中,从而缓解类增量过程中由类别扩展带来的表征漂移问题。现有研究主要通过自适应表示调整、类别感知建模以及模态差距补偿等机制维持视觉与文本嵌入空间的一致性<sup>[109]</sup>,并进一步在不同特征层级上引入表示匹配约束以减轻持续更新中的表示漂移<sup>[110]</sup>。此外,也有工作利用语言空间中的结构信息组织类别关系,通过构建层级语义树或引入语言引导的概念瓶颈来增强表示稳定性与模型可解释性<sup>[111-112]</sup>;在参数更新方面,则通过低秩融合、知识蒸馏以及生成回放等机制减轻遗忘问题<sup>[113-115]</sup>。

基于 BLIP 的持续学习研究相对较少。与依赖对齐嵌入进行分类的 CLIP 不同, BLIP 类模型通常兼具跨模态理解与生成能力,因此在知识保持与语义重构方面具有一定优势。文献[116]通过图像描述生成与跨模态重建机制实现旧知识保持与新类别扩展;文献[117]则研究大规模多模态模型中的持续指令微调问题,以维持跨任务更新过程中的表示一致性与泛化能力。

总体来看,视觉-语言模型为类增量学习提供了跨模态语义支撑,使类别保持不仅依赖参数约束,也依赖共享语义空间一致性。但其效果仍受预训练语义覆盖范围和跨模态对齐质量的影响,在复杂任务序列下的稳定性仍有待进一步研究。

## 2.6 方法对比与分析

综上所述,基于记忆回放的方法通过显式或隐式重建旧任务数据分布,通常能够取得较好的性能,但需要额外存储或生成机制,存储与计算开销随任务数量增长而增加。基于参数与优化约束的方法则通过限制模型更新方向保持旧任务知识,结构相对简洁,额外开销较小,但在类别规模持续扩大时约束能力可能不足。基于模型预测校正的方法主要针对类别不平衡带来的输出偏置问题,实现简单,但难以从表示层面根本解决遗忘。基于模型结构设计的方法通过容量分配或模型扩展缓解干扰问题,在稳定性方面具有一定优势,但模型规模增长可能带来效率问题。基于预训练模型迁移的方法依托大规模预训练知识,具备较强的初始泛化能力和参数效率,但对模型规模和提

示设计较为依赖。

## 3 数据集、评价指标与基准测试

本节从数据集、评价指标和基准测试这三个方面对类增量学习进行梳理。首先对文献中常用的典型数据集进行归纳总结,分析这些数据集类别规模、任务划分方式、增量设置等方面的特点;然后介绍类增量学习中常用的评价指标及其关注的重点,以此来刻画模型在类增量学习过程中旧类知识保持和新类学习能力之间权衡的情况;最后对目前主流的类增量学习代码库和工具进行概述,给出代表性方法的性能对比。

### 3.1 数据集介绍

本文选取了当前类增量学习研究中广泛使用的数据集,如表4所示。不同数据集在类别规模、语义复杂度及场景变化程度等方面存在显著差异,因此在类增量任务中承担着不同的评测角色。

表4 类增量学习常用数据集

Tab.4 Common datasets for class-incremental learning

数据集	类别数	数据量	分辨率/像素
MNIST <sup>[118]</sup>	10	60 000	28 × 28 × 1
Fashion-MNIST <sup>[119]</sup>	10	60 000	28 × 28 × 1
CIFAR-10 <sup>[120]</sup>	10	60 000	32 × 32 × 3
CIFAR-100 <sup>[120]</sup>	100	60 000	32 × 32 × 3
SVHN <sup>[121]</sup>	10	99 289	32 × 32 × 3
Tiny ImageNet <sup>[122]</sup>	200	120 000	64 × 64 × 1
Sub-ImageNet <sup>[123]</sup>	100	60 000	224 × 224 × 3
Full-ImageNet <sup>[123]</sup>	1 000	1 280 000	224 × 224 × 3
CUB-200 <sup>[124]</sup>	200	11 788	224 × 224 × 3
CORe50 <sup>[125]</sup>	50	15 000	128 × 128 × 3

在类增量学习研究中,不同数据集反映了不同类型的评测需求。MNIST<sup>[118]</sup>、Fashion-MNIST<sup>[119]</sup>、CIFAR-10<sup>[120]</sup>与SVHN<sup>[121]</sup>类别规模较小,常用于机制分析和基础性能验证;CIFAR-100<sup>[120]</sup>、Tiny ImageNet<sup>[122]</sup>和Sub-ImageNet<sup>[123]</sup>包含较多类别,更适合评估增量过程中灾难性遗忘、类别竞争和分类偏置等问题,也是当前最常用的标准基准;Full-ImageNet<sup>[123]</sup>拥有上千类别与大规模样本量,常用于大规模类增量学习设定;CUB-200<sup>[124]</sup>适用于评估高类间相似度条件下的判别稳定性;CORe50<sup>[125]</sup>更适合检验场景变化条件下的泛化能力与鲁棒性。

### 3.2 评价指标

在类增量学习问题中,模型需要在持续引入新类别的过程中,同时保持对已学类别的识别能力。因此,评价指标不仅需要反映模型在当前阶段的分类性能,还需要刻画其对旧知识的保持能力以及跨任务的知识迁移特性。现有研究通常采用多种互补指标,从准确性、遗忘程度和迁移能力等不同角度对类增量学习方法进行综合评估。

分类准确率是最基础的评价指标。在完成第  $t$  个任务训练后,模型通常在包含截至当前所有已见类别的测试集上进行评估。设  $R_{t,i}$  表示模型在完成第  $t$  个任务后对第  $i$  个任务类别的分类准确率,则阶段平均准确率定义为:

$$A_t = \frac{1}{t} \sum_{i=1}^t R_{t,i} \quad (14)$$

当训练完成全部  $T$  个任务后,得到的  $A_T$  用于衡量模型在完整类增量学习过程结束时的整体性能。此外,为反映模型在整个学习过程中的平均表现,部分研究还会计算所有阶段平均准确率的均值,作为增量平均准确率。

灾难性遗忘是类增量学习面临的核心问题之一,因此平均遗忘被广泛用于衡量模型对旧类别知识的保持能力。对于第  $i$  个任务,其遗忘程度通常定义为该任务在学习完成后所达到的最佳准确率与最终阶段准确率之间的差值,即:

$$F_i = \max_{t \in \{i, \dots, T\}} R_{t,i} - R_{T,i} \quad (15)$$

整体平均遗忘通过对所有已学任务取平均获得,通常定义为:

$$F = \frac{1}{T-1} \sum_{i=1}^{T-1} F_i \quad (16)$$

该指标能够直观反映模型在持续学习新类别过程中对已学类别性能退化的程度。

除了准确率与遗忘程度,迁移相关指标被用于刻画不同任务之间的知识交互行为。其中,前向迁移(forward transfer, FWT)用于衡量模型在尚未学习某一任务之前,已有知识对该任务学习的促进作用。设  $b_i$  表示在未学习第  $i$  个任务前的基线性能(通常为随机初始化模型),则前向迁移的性能  $P_{\text{FWT}}$  定义为:

$$P_{\text{FWT}} = \frac{1}{T-1} \sum_{i=2}^T (R_{i-1,i} - b_i) \quad (17)$$

前向迁移为正值表明模型能够有效利用已学知识加速或改善新类别的学习过程。

与之相对,反向迁移(backward transfer, BWT)用于衡量模型在学习新类别之后,对已学

类别性能的影响,其性能  $P_{\text{BWT}}$  定义为:

$$P_{\text{BWT}} = \frac{1}{T-1} \sum_{i=1}^{T-1} (R_{T,i} - R_{i,i}) \quad (18)$$

当反向迁移为负值时,通常意味着模型在后续学习过程中出现了遗忘;若反向迁移为正,则说明新知识的引入对旧类别识别产生了积极影响。

在实际研究中,平均遗忘与反向迁移从不同角度刻画了模型的稳定性特征,而前向迁移则反映了模型对新类别的可塑性。因此,许多类增量学习综述和基准工作往往同时报告上述指标,以对方法在长期连续学习过程中的行为特性进行全面分析。

### 3.3 代表性方法的对比

为了对不同类增量学习方法进行系统比较,本文选取具有代表性的算法,从平均准确率(见式(14))、整体平均遗忘(见式(16))两个常用指标对其进行比较,见表 5。

需要说明的是,由于不同技术路线依赖的模型结构与输入分辨率存在差异,表中结果并非在完全统一的实验设置下获得,而是基于各方法主流实验范式进行复现或引用原文结果。因此,表 5 主要展示具有代表性且相对可比的方法,部分固定模型结构类方法由于与其他方法在模型结构、输入规格或实验数据等方面差异较大,未纳入该表的集中比较。具体设置如下:

1) 记忆回放、参数与优化约束、模型预测校正及模型结构扩展类方法:在 CIFAR-100 ( $32 \times 32$ ) 数据集上进行 10-10 类划分实验,主干网络为 ResNet18。其中, iCaRL、FOSTER、BiC、WA 和 DER 的最大记忆容量为 2 000 个样本,随着类别数的增加,每类可保存的样本逐步减少;LWF、EWC、GEM 和 DCMI 无须保存样本。

2) 提示学习与主干参数微调方法:在 CIFAR-224 数据集上进行 10-10 类划分实验,主干网络为 Vision Transformer。

3) 视觉-语言模型方法:在 CIFAR-224 数据集上,采用 CLIP 预训练模型作为主干。

从表 5 结果可以观察到,不同类别方法在性能表现与资源依赖方面存在明显差异。在计算资源受限或难以利用大规模预训练模型场景下,记忆回放与模型结构扩展类方法具有实现简单、稳定性较好的优势;参数与优化约束类方法适用于对模型结构改动较小、需保持网络规模稳定的应用环境;在具备预训练模型条件且对性能要求较高的场景中,参数高效适配与视觉-语言模型方法通常能够取得更优表现。

表 5 代表性类增量学习方法的性能

Tab. 5 Performance of representative class-incremental learning methods

方法名称		方法	平均准确率/%	整体平均遗忘/%
记忆回放	原始数据回放	iCaRL <sup>[10]</sup>	61.56	46.99
	压缩数据回放	FOSTER <sup>[24]</sup>	68.79	29.93
	生成式数据回放	DCMI <sup>[35]</sup>	53.24	15.14
参与与优化约束	知识蒸馏约束	LWF <sup>[36]</sup>	46.82	56.14
	参数正则化约束	EWG <sup>[45]</sup>	28.49	84.64
	梯度约束	GEM <sup>[54]</sup>	27.32	86.88
模型预测校正	模型预测校正	BiC <sup>[62]</sup>	62.68	13.75
		WA <sup>[64]</sup>	68.46	25.31
模型结构设计	模型结构扩展	DER <sup>[83]</sup>	72.42	20.61
预训练模型迁移	提示学习	L2P <sup>[90]</sup>	89.24	6.70
	主干参数微调	文献 <sup>[108]</sup>	94.89	3.57
	视觉-语言模型驱动	文献 <sup>[109]</sup>	87.52	10.89

注:不同类别方法基于各自主流实验设置复现。

### 3.4 典型类增量学习代码库与工具

为了支持类增量学习算法的实现、复现和公平比较,现有多种持续学习代码库与工具,见表 6。这些框架大都基于 PyTorch 构建数据流、

模型、训练策略、评价指标解耦,提供统一的实验接口,支持多阶段类别增量训练和标准化测试,从而提高不同方法之间的可比性与实验复现性。

表 6 类增量学习代码库

Tab. 6 Class-incremental learning code library

代码库	定位	方法覆盖度	典型用途
Avalanche <sup>[126]</sup>	通用持续学习	中	规范化的评测与可复现实验
Mammoth <sup>[127-128]</sup>	通用持续学习	高	大规模方法对比评测
PyCIL <sup>[129]</sup>	类增量学习	高	类增量学习算法复现与对比
FACIL <sup>[130]</sup>	类增量学习	中	类增量学习基准评测与性能分析
PILOT <sup>[131]</sup>	预训练的类增量学习	中	基于提示的类增量学习研究
C3Box <sup>[132]</sup>	CLIP 的类增量学习	低	基于 CLIP 的类增量学习研究

从适用范围角度分析,现有代码库可以分为通用持续学习框架、类增量学习专用框架和面向预训练模型的框架。Avalanche<sup>[126]</sup>与 Mammoth<sup>[127-128]</sup>属于通用持续学习框架,支持类增量学习、任务增量学习与域增量学习等多种设置。PyCIL<sup>[129]</sup>与 FACIL<sup>[130]</sup>则专门面向类增量学习场景设计,前者在算法覆盖和复现中应用较广,后者更注重标准化基准测试。PILOT<sup>[131]</sup>和 C3Box<sup>[132]</sup>支持基于提示学习和视觉-语言模型的类增量研究,分别面向预训练模型适配与基于 CLIP 的类增量学习。

## 4 类增量学习的应用扩展

类增量学习最初主要面向图像分类任务,但随着视觉模型能力的提升和应用场景的不断拓展,其应用已逐步扩展至图像生成、目标检测、语义分割等更复杂的视觉任务,并进一步延伸至视频理解、三维视觉和多模态学习等新兴领域。相比于图像分类,这些任务在输出形式、空间结构以及时序建模方面具有更高的复杂度,使得类增量学习在不同任务中呈现差异化的挑战与技术演进路径。

## 4.1 图像生成

与判别式的图像分类任务不同的是,类增量图像生成更关注模型在不断加入新类别后,对多类别数据分布的长期建模能力。该任务的目标已经不是保持分类性能,而是保证模型在生成样本时仍然可以覆盖已学类别的多样性以及分布特征。由于生成模型一般学习整体数据分布来实现样本的合成,新类别的加入很容易造成模型分布发生偏移,从而导致对旧类别的快速遗忘。

早期图像生成中的类增量学习主要用生成对抗网络来实现。终身生成对抗网络方法<sup>[133]</sup> (lifelong generative adversarial network, LifelongGAN) 用条件生成机制和生成式重放,在不断引入新类别的过程中利用模型生成的旧类别样本参与训练,从而在一定程度上缓解了灾难性遗忘的问题。文献[134]在此基础上进一步关注参数效率,通过在共享生成器结构上引入任务相关的轻量化参数,实现了更高效的持续条件生成。

近年来,随着扩散模型成为主流生成范式,研究者开始关注其在持续学习场景下的稳定性问题。例如,文献[135]分析了扩散模型在连续训练中的遗忘现象,而文献[136]在扩散模型中引入一致性约束以支持长期生成建模。这些工作表明,扩散模型在持续生成场景下具有潜力,但其在严格类增量设置下的系统研究仍然相对有限。

综上,类增量图像生成的研究正在从基于对抗训练的经验重放机制,逐步拓展至在更大规模生成框架中引入参数约束与结构稳定策略。无论是在对抗训练还是扩散模型中,新类别的加入都会引起生成分布的整体偏移,从而影响旧类别样本的质量与多样性。因此,在保持生成质量的同时实现长期稳定的分布建模,是该方向面临的核心挑战。此外,随着生成模型规模持续扩大,如何在控制计算成本与存储开销的前提下实现高效持续更新,也成为类增量生成研究的重要方向。

## 4.2 目标检测

相较于图像分类而言,目标检测场景下的类增量学习更加复杂。模型不仅需要缓解灾难性遗忘的困扰,还需要解决目标检测中特有的背景漂移、类别混淆和前景-背景不平衡等问题<sup>[137]</sup>。

文献[138]将类增量学习引入检测变换器(detection transformer, DETR)框架,通过对查询和特征表示进行约束,以缓解新类别引入对旧类别检测性能的影响。文献[139]通过对历史目标框进行增强式重放,缓解了新类别样本引入导致的

前景偏移问题,从而在保持旧类别检测性能方面取得了显著改进。这类方法体现了重放机制在结构化输出任务中的重要作用。

近年来,视觉语言模型在类增量学习的目标检测场景中也开始显现其作用。文献[140]用视觉-语言模型生成高质量伪标签,为旧类别提供额外的监督信号,进而缓解由于标注数据缺乏所引发的遗忘问题。该方向展示了跨模态先验在类增量学习任务中的应用潜力。

此外,也有研究从优化层面缓解新旧类别之间的冲突。文献[141]通过对梯度进行分解与对齐,减少新旧类别学习目标之间的冲突,为类增量学习在目标检测中的实现提供了一种无须显式重放的替代思路。

除自然图像场景外,类增量目标检测在遥感影像和医疗影像等垂直领域同样具有重要应用价值。在遥感目标检测中,图像分辨率高、目标尺度差异大且跨区域分布差异显著,新类别的逐步引入更容易导致背景统计特性变化和检测器漂移。部分研究在遥感场景下构建类增量检测框架,通过特征对齐与样本重放策略实现地物类别的渐进式扩展<sup>[142-143]</sup>。在医疗影像检测任务中,新类别通常对应新的病灶类型或异常结构,数据规模有限且类别不均衡问题突出。相关工作结合知识蒸馏与不确定性建模策略,在逐步扩展病变类别的同时维持既有检测性能<sup>[144]</sup>。

由此可见,类增量目标检测的研究正从自然图像数据集逐步拓展至更具挑战性的垂直领域场景。在复杂数据分布和高分辨率输入条件下,如何在保持检测精度的同时实现长期稳定更新,仍然是该方向的重要研究课题。

## 4.3 语义分割

语义分割属于类增量学习中较为困难的视觉任务之一。由于类别在空间上高度交织,并且背景语义会随着类别集合的扩大而不断变化,新类别的出现会使得旧类别的区域被错误地预测为背景或者混入新类别当中,从而加重灾难性遗忘。

现有面向语义分割任务的类增量学习大多采用知识蒸馏框架,用像素级或者特征级表示来约束新旧模型的一致性。不确定性感知对比蒸馏方法<sup>[145]</sup> (uncertainty-aware contrastive distillation, UCD) 在蒸馏过程中显式建模预测不确定性,从而抑制噪声伪标签对旧类别学习造成的负面影响。端点权重融合方法<sup>[146]</sup> (endpoints weight fusion, EWF) 从参数层面提出端点权重融合的方法,即在保留旧类别决策边界的同时加入新类别,

可以较好地达到稳定和可塑之间的平衡。

除蒸馏机制外,背景建模以及分布漂移问题也开始引起研究者们关注。其中,文献[147]提出了基于残差建模的背景自适应方法,用于应对背景类别随前景类别增多而不断变化的问题,在无须样本重放的情况下提高了旧类别的保持能力。随后,文献[148]从系统角度分析了分布调整策略对类增量学习在语义分割场景中的影响,发现不正确的分布对齐反而会加重遗忘。

近两年,在遥感影像和医疗影像等垂直领域,类增量语义分割研究进一步深化<sup>[149]</sup>,针对领域特定挑战(如遥感图像的高分辨率与分布差异、医疗数据的隐私保护与模态特异性)提出了更多针对性方法。在遥感领域,文献[150]提出记忆启发的语义分割增强网络,通过记忆机制增强模型对历史类别的保留能力,适用于遥感图像类增量学习场景。文献[151]则重点缓解表示偏差问题,该偏差源于交叉熵损失与蒸馏损失的冲突以及多步增量后的类别不平衡与相似性问题;它通过特征交互实现从粗到细的隐式分割,有效平衡了遗忘缓解与新类学习,在遥感图像上取得了较好效果。在医疗影像领域,由于隐私限制难以获取旧样本,研究重点转向无旧样本或少样本的原型引导与蒸馏策略。文献[152]提出原型引导校准和双对齐蒸馏方法,在不依赖旧类标签的情况下实现类增量医疗图像分割,有效保留了先前器官或病灶的分割知识,在腹部多器官等任务中表现出色。

类增量学习在语义分割任务中的研究已由早期依靠简单的蒸馏范式,逐渐发展成为考虑不确定性建模、背景语义变化、数据分布调整的综合策略。但是,在大规模类别设置、高分辨率输入和跨场景泛化等方面仍存在较大困难,需要进一步研究。

#### 4.4 新兴视觉任务

随着类增量学习研究的深入,其应用已逐渐扩展至视频理解、三维视觉以及多模态等新兴视觉任务。这些任务通常面临更高的复杂性:视频数据包含丰富的时序信息,三维点云具有无序性和几何结构特性,而多模态任务则需维持视觉与语言等不同模态之间的对齐关系,这些特性均显著加剧了灾难性遗忘问题。

在视频理解领域,类增量动作识别是典型代表。文献[153]提出了一种基于时序注意力知识蒸馏的框架,通过帧级特征表示存储历史样本,并估计时间通道重要性以加权蒸馏,同时鼓励特征

多样性,实现稳定性和可塑性的平衡。该方法在UCF101、HMDB51等数据集的类增量划分上取得了较好效果。随后,文献[154]进一步针对视频动作识别中的背景偏差问题,提出背景去偏的类增量学习方法,有效缓解了背景变化对旧类别识别的干扰。

三维视觉中的类增量学习主要集中在点云语义分割和物体分类任务上。由于点云的无序性与稀疏性,传统方法难以直接迁移。文献[155]提出几何与不确定性感知的3D点云类增量语义分割框架,通过几何特征建模和不确定性估计来缓解新类别引入对旧类别几何结构的破坏,在S3DIS和ScanNet数据集上验证了其有效性。文献[156]则聚焦少样本类增量场景,针对合成数据与真实扫描数据之间的域差异,提出基于微形状的表达方法,有效提升了三维数据的类增量学习性能。

在多模态领域,音频-视觉类增量学习成为新的研究热点。由于需要同时处理视觉和音频信息,且往往面临无历史样本的约束,研究难度进一步增加。文献[157]构建了音频-视觉问答持续学习基准,创建了相应的数据集,并提出了问题引导的跨模态信息融合、带时空特征约束的任务特定知识蒸馏以及问题语义一致性约束等方法,在细粒度场景理解和时空推理方面取得了显著进展。随后,文献[158]采用解析学习的闭式解形式,在不存储历史样本的情况下有效缓解了灾难性遗忘,提升了多模态类增量学习的性能。

类增量学习在新兴视觉任务中的研究仍处于快速发展阶段。已有工作虽然分别针对时序建模、几何感知和跨模态对齐提出了针对性策略,但在长序列增量、大规模类别、高分辨率3D数据以及真实世界多模态场景下,仍面临计算开销大、泛化能力不足以及隐私保护等问题。未来研究需进一步探索参数高效、跨模态统一且隐私友好的持续学习范式。

## 5 总结与展望

本文对类增量学习在方法设计、评测设置、应用拓展等各方面的研究进展进行系统综述,主要分析了不同技术路线在解决灾难性遗忘、适应新类别加入过程中所取得的优势和不足。尽管现有方法在标准基准数据集上取得了一定成效,但在更加复杂、动态且接近真实应用的场景中,类增量学习仍面临诸多基础性挑战。整体来看,未来研

究可从数据层面、策略层面与系统层面三个维度展开:数据层面关注弱监督、噪声与长尾分布等现实数据特性;策略层面关注多种持续学习机制的协同与统一;系统层面则涉及在线学习、评估体系、理论刻画与可信部署等更深层问题。在此框架下,未来可能的研究方向包括以下几个方面:

1) 半监督类增量学习。当前类增量学习方法依赖充足的标注数据,而现实环境中新类别的出现往往仅伴随少量标注样本甚至无标注数据。如何在类增量学习框架下充分利用未标注数据,通过一致性正则化、自训练、对比表示学习或伪标签筛选等机制提升新类别的建模能力,同时避免误导性伪标签对旧类别产生负迁移,是一个尚未系统解决的重要问题。此外,还需要研究未标注数据在不同增量阶段的作用机制,例如其是否会加剧旧类别表示漂移,以及如何在蒸馏约束与半监督信号之间建立稳定的协同优化关系。

2) 噪声数据的类增量学习。真实场景中数据不可避免地存在标注噪声、类别混淆或者样本污染,而类增量学习往往依赖历史模型输出作为蒸馏目标或伪标签来源,因此对错误监督尤为敏感。噪声会随着阶段逐步累积并被放大,导致长期性能下降。未来可探索在增量过程中引入不确定性估计、样本置信度动态加权或噪声识别机制,构建具有自纠错能力的持续学习框架,从而在保持可塑性的同时提升整体鲁棒性。

3) 数据长尾分布下的类增量学习。许多现实任务中新加入的类别样本数量很少,整体数据呈长尾分布。然而现有方法大多基于相对均衡的类别分布设计,对尾部类别的表示能力和判别能力仍然不足。在类增量情形下,类别不平衡与类别持续扩展相互叠加,使问题更加复杂。未来研究可以从分布重加权、原型重构、特征重校准及类别关系建模等角度出发,建立对尾部类别更加友好的类增量学习机制。

4) 多种持续学习策略的有效融合。目前类增量学习方法大多侧重于单一技术路线,比如记忆回放、参数约束或结构扩展等,不同策略之间的协同机制尚不清晰。未来可从统一优化视角出发,将历史分布保持视为一类约束项,在同一目标函数中整合重放、蒸馏与参数限制机制,并研究不同策略之间的互补与冲突关系。

5) 在线类增量学习与动态任务边界。多数现有研究仍采用阶段式或离线增量设置,而在实际应用中,数据和类别往往以连续流式方式到达,任务边界模糊甚至不可感知。因此,有必要构建

更加贴近真实环境的评估范式,例如在无显式任务划分的条件下持续监测模型性能变化,结合时间维度刻画稳定性-可塑性的动态权衡,并将计算开销、更新频率与存储成本纳入统一评价指标体系。建立面向动态任务边界的评测协议,有助于推动类增量学习从理想化设定走向真实应用场景。

6) 类增量学习的理论刻画与性能界限。目前大多数方法仍以经验性设计为主,性能比较依赖实验结果,缺乏统一的理论分析框架。在资源受限条件下,模型对旧类别信息的保持能力与记忆容量或参数规模之间的关系,需要从理论上加以刻画,例如分析是否存在可形式化的性能下界,以及是否可以借助互信息或表示压缩率等信息论指标量化遗忘程度。同时,优化过程中产生的梯度冲突也有必要在几何层面进行表达,例如通过向量夹角或子空间重叠度刻画更新方向之间的关系,从而为梯度投影或正交约束方法提供更明确的理论解释。此外,稳定性与可塑性的权衡可以被建模为带约束的双目标优化过程,并进一步分析其收敛性质与最优解条件。

7) 面向实际系统的高效可信类增量学习。在真实部署环境中,类增量学习模型不仅需要保持较高性能,还需满足计算效率、存储限制、隐私保护与系统可靠性等多方面要求。未来研究可进一步探索参数高效更新机制、边缘设备友好的模型压缩策略,以及隐私保护场景下的联邦类增量学习框架。同时,还需关注模型决策的可解释性与风险可控性,建立异常检测与不确定性评估机制,使模型在开放环境中能够对未知类别或异常样本给出合理响应。

## 参考文献 (References)

- [1] 王泽龙, 吴宇航, 李健, 等. 面向图像处理逆问题的扩散模型研究综述[J]. 国防科技大学学报, 2025, 47(4): 91-110.  
WANG Z L, WU Y H, LI J, et al. Review of diffusion models for inverse problems in image processing[J]. Journal of National University of Defense Technology, 2025, 47(4): 91-110. (in Chinese)
- [2] 刘丽, 隋金坪, 丁丁, 等. 深度视觉语音生成研究进展与展望[J]. 国防科技大学学报, 2024, 46(2): 123-138.  
LIU L, SUI J P, DING D, et al. Reasearch progress and prospects of deep learning for visual speech generation[J]. Journal of National University of Defense Technology, 2024, 46(2): 123-138. (in Chinese)
- [3] 张天成, 王雅婷, 李凡, 等. 机器阅读理解研究综述[J/OL]. 计算机学报, 2026; 1-31 [2026-03-17]. <https://link.cnki.net/urlid/11.1826.tp.20260109>.

- 1045.002.
- ZHANG T C, WANG Y T, LI F, et al. A survey on machine reading comprehension [J/OL]. Chinese Journal of Computers, 2026; 1 - 31 [2026 - 03 - 17]. <https://link.cnki.net/urlid/11.1826.tp.20260109.1045.002>. (in Chinese)
- [4] WANG L Y, ZHANG X X, SU H, et al. A comprehensive survey of continual learning: theory, method and application[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(8): 5362 - 5383.
- [5] FRENCH R M. Catastrophic forgetting in connectionist networks[J]. Trends in Cognitive Sciences, 1999, 3(4): 128 - 135.
- [6] BELOUADAH E, POPESCU A, KANELLOS I. A comprehensive study of class incremental learning algorithms for visual tasks[J]. Neural Networks, 2021, 135: 38 - 54.
- [7] VAN DE VEN G M, TUYTELAARS T, TOLIAS A S. Three types of incremental learning [J]. Nature Machine Intelligence, 2022, 4(12): 1185 - 1197.
- [8] 孙文举, 李清勇, 张靖, 等. 基于深度神经网络的增量学习研究综述[J]. 数据分析与知识发现, 2025, 9(1): 1 - 30.
- SUN W J, LI Q Y, ZHANG J, et al. Survey of incremental learning with deep neural networks[J]. Data Analysis and Knowledge Discovery, 2025, 9(1): 1 - 30. (in Chinese)
- [9] 张东阳, 陆子轩, 刘军民, 等. 深度模型的持续学习综述: 理论、方法和应用[J]. 电子与信息学报, 2024, 46(10): 3849 - 3878.
- ZHANG D Y, LU Z X, LIU J M, et al. A survey of continual learning with deep networks: theory, method and application[J]. Journal of Electronics & Information Technology, 2024, 46(10): 3849 - 3878. (in Chinese)
- [10] REBUFFI S A, KOLESNIKOV A, SPERL G, et al. iCaRL: incremental classifier and representation learning [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 5533 - 5542.
- [11] WELLING M. Herding dynamical weights to learn [C]// Proceedings of the 26th Annual International Conference on Machine Learning, 2009: 1121 - 1128.
- [12] CASTRO F M, MARÍN-JIMÉNEZ M J, GUIL N, et al. End-to-end incremental learning [C]// Computer Vision - ECCV 2018, 2018: 241 - 257.
- [13] SHIM D, MAI Z D, JEONG J, et al. Online class-incremental continual learning with adversarial Shapley value [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(11): 9630 - 9638.
- [14] YE F, BORS A G. Online task-free continual generative and discriminative learning via dynamic cluster memory [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 26202 - 26212.
- [15] MAALOUF A, EINI G, MUSSAY B, et al. A unified approach to coreset learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(5): 6893 - 6905.
- [16] TIWARI R, KILLAMSETTY K, IYER R, et al. GCR: gradient coreset based replay buffer selection for continual learning [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 99 - 108.
- [17] ZHOU X, PI R J, ZHANG W Z, et al. Probabilistic bilevel coreset selection [C]// Proceedings of the 39th International Conference on Machine Learning, 2022.
- [18] HAO J, JI K Y, LIU M R. Bilevel coreset selection in continual learning: a new formulation and algorithm [C]// Proceedings of the Advances in Neural Information Processing Systems 36, 2023: 51026 - 51049.
- [19] LUO Y T, ZHAO S Q, WU H R, et al. Dual-enhanced coreset selection with class-wise collaboration for online blurry class incremental learning [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 23995 - 24004.
- [20] ZHAO H B, WANG H, FU Y J, et al. Memory-efficient class-incremental learning for image classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(10): 5966 - 5977.
- [21] WANG L Y, ZHANG X X, YANG K, et al. Memory replay with data compression for continual learning [C]// Proceedings of the International Conference on Learning Representations (ICLR), 2022.
- [22] HAYES T L, KAFLE K, SHRESTHA R, et al. REMIND your neural network to prevent catastrophic forgetting [C]// Computer Vision - ECCV 2020, 2020: 466 - 483.
- [23] ISCEN A, ZHANG J, LAZEBNIK S, et al. Memory-efficient incremental learning through feature adaptation [C]// Computer Vision - ECCV 2020, 2020: 699 - 715.
- [24] WANG F Y, ZHOU D W, YE H J, et al. FOSTER: feature boosting and compression for class-incremental learning [C]// Computer Vision - ECCV 2022, 2022: 398 - 414.
- [25] YANG E N, SHEN L, WANG Z Y, et al. An efficient dataset condensation plugin and its application to continual learning [C]// Proceedings of the 37th International Conference on Neural Information Processing Systems, 2023: 67625 - 67642.
- [26] SHIN H, LEE J K, KIM J, et al. Continual learning with deep generative replay [C]// Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 2994 - 3003.
- [27] WU C S, HERRANZ L, LIU X L, et al. Memory replay GANs: learning to generate new categories without forgetting [C]// Proceedings of the Advances in Neural Information Processing Systems 31 (NeurIPS 2018), 2018.
- [28] XIANG Y, FU Y, JI P, et al. Incremental learning using conditional adversarial networks [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 6618 - 6627.
- [29] LIU X L, WU C S, MENTA M, et al. Generative feature replay for class-incremental learning [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2020: 915 - 924.
- [30] GAO R, LIU W W. DDGR: continual learning with deep diffusion-based generative replay [C]// Proceedings of the 40th International Conference on Machine Learning, 2023: 10744 - 10763.
- [31] MENG Z C, ZHANG J, YANG C D, et al. DiffClass:

- diffusion-based class incremental learning [C]//Computer Vision – ECCV 2024, 2024; 142 – 159.
- [32] JODELET Q, LIU X, PHUA Y J, et al. Class-incremental learning using diffusion model for distillation and replay[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops (ICCVW), 2023; 3417 – 3425.
- [33] YIN H X, MOLCHANOV P, ALVAREZ J M, et al. Dreaming to distill: data-free knowledge transfer via DeepInversion[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020; 8712 – 8721.
- [34] SMITH J, HSU Y C, BALLOCH J, et al. Always be dreaming: a new approach for data-free class-incremental learning[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2021; 9354 – 9364.
- [35] QIU Z H, XU Y, MENG F M, et al. Dual-consistency model inversion for non-exemplar class incremental learning[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2024; 24025 – 24035.
- [36] LI Z Z, HOIEM D. Learning without forgetting[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(12): 2935 – 2947.
- [37] DOUILLARD A, CORD M, OLLION C, et al. PODNet: pooled outputs distillation for small-tasks incremental learning[C]//Computer Vision – ECCV 2020, 2020; 86 – 102.
- [38] KANG M, PARK J, HAN B. Class-incremental learning by knowledge distillation with adaptive feature consolidation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022; 16050 – 16059.
- [39] TAO X Y, CHANG X Y, HONG X P, et al. Topology-preserving class-incremental learning[C]//Computer Vision–ECCV 2020, 2020; 254 – 270.
- [40] LIU Y, HONG X P, TAO X Y, et al. Model behavior preserving for class-incremental learning [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(10): 7529 – 7540.
- [41] ASADI N, DAVARI M, MUDUR S, et al. Prototype-sample relation distillation: towards replay-free continual learning[C]// Proceedings of the 40th International Conference on Machine Learning, 2023; 1093 – 1106.
- [42] ARANI E, SARFRAZ F, ZONOOZ B. Learning fast, learning slow: a general continual learning method based on complementary learning system [C]//Proceedings of the International Conference on Learning Representations (ICLR), 2022.
- [43] ARANI E, BHAT P, VIJAYAN P, et al. TriRE: a multi-mechanism learning paradigm for continual knowledge retention and promotion[C]//Proceedings of the Advances in Neural Information Processing Systems 36, 2023; 73775 – 73792.
- [44] SZATKOWSKI F, PYLA M, PRZEWI EŻ LIKOWSKI M, et al. Adapt your teacher: improving knowledge distillation for exemplar-free continual learning [C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 2024; 1977 – 1987.
- [45] KIRKPATRICK J, PASCANU R, RABINOWITZ N, et al. Overcoming catastrophic forgetting in neural networks [J]. Proceedings of the National Academy of Sciences, 2017, 114(13): 3521 – 3526.
- [46] RITTER H, BOTEV A, BARBER D. Online structured Laplace approximations for overcoming catastrophic forgetting[C]// Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018; 3742 – 3752.
- [47] NGUYEN C V, LI Y Z, BUI T D, et al. Variational continual learning [C]//Proceedings of the International Conference on Learning Representations (ICLR), 2018.
- [48] ZENKE F, POOLE B, GANGULI S. Continual learning through synaptic intelligence [C]//Proceedings of the 34th International Conference on Machine Learning, 2017; 3987 – 3995.
- [49] ALJUNDI R, BABILONI F, ELHOSEINY M, et al. Memory aware synapses: learning what (not) to forget [C]// Proceedings of the 15th European Conference on Computer Vision (ECCV), 2018; 144 – 161.
- [50] CHAUDHRY A, DOKANIA P K, AJANTHAN T, et al. Riemannian walk for incremental learning: understanding forgetting and intransigence [C]//Proceedings of the 15th European Conference on Computer Vision (ECCV), 2018; 556 – 572.
- [51] LEE S W, KIM J H, JUN J, et al. Overcoming catastrophic forgetting by incremental moment matching[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017; 4655 – 4665.
- [52] CHA S, HSU H, HWANG T, et al. CPR: classifier-projection regularization for continual learning [C]// Proceedings of the 9th International Conference on Learning Representations, 2021.
- [53] RUDNER T G J, SMITH F B, FENG Q X, et al. Continual learning via sequential function-space variational inference[C]// Proceedings of the 39th International Conference on Machine Learning, 2022; 18871 – 18887.
- [54] LOPEZ-PAZ D, RANZATO M A. Gradient episodic memory for continual learning [C]//Proceedings of the 31st Conference on Neural Information Processing Systems (NIPS 2017), 2017.
- [55] CHAUDHRY A, RANZATO M A, ROHRBACH M, et al. Efficient lifelong learning with A-GEM[C]//Proceedings of the International Conference on Learning Representations (ICLR), 2018.
- [56] RIEMER M, CASES I, AJEMIAN R, et al. Learning to learn without forgetting by maximizing transfer and minimizing interference[C]//Proceedings of the International Conference on Learning Representations (ICLR), 2019.
- [57] FARAJTABAR M, AZIZAN N, MOTT A, et al. Orthogonal gradient descent for continual learning [C]//Proceedings of the Twenty Third International Conference on Artificial Intelligence and Statistics, 2020; 3762 – 3773.
- [58] TANG S X, CHEN D P, ZHU J G, et al. Layerwise optimization by gradient decomposition for continual learning[C]//Proceedings of the IEEE/CVF Conference on

- Computer Vision and Pattern Recognition (CVPR), 2021: 9629 – 9638.
- [59] SAHA G, GARG I, ROY K. Gradient projection memory for continual learning [C]//Proceedings of the International Conference on Learning Representations(ICLR), 2021.
- [60] KONG Y J, LIU L, WANG Z, et al. Balancing stability and plasticity through advanced null space in continual learning[C]//Proceedings of the 17th European Conference on Computer Vision, 2022: 219 – 236.
- [61] WU T, LUO T, WUNSCHII D C. CR-SAM: curvature regularized sharpness-aware minimization[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(6): 6144 – 6152.
- [62] WU Y, CHEN Y P, WANG L J, et al. Large scale incremental learning [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 374 – 382.
- [63] HOU S H, PAN X Y, LOY C C, et al. Learning a unified classifier incrementally via rebalancing [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 831 – 839.
- [64] ZHAO B W, XIAO X, GAN G J, et al. Maintaining discrimination and fairness in class incremental learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 13205 – 13214.
- [65] AHN H, KWAK J, LIM S, et al. SS-IL: separated softmax for incremental learning[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 824 – 833.
- [66] LIANG Y S, LI W J. Loss decoupling for task-agnostic continual learning [C]//Proceedings of the Advances in Neural Information Processing Systems 36, 2023: 11151 – 11167.
- [67] XIANG X, TAN Y W, WAN Q, et al. Coarse-to-fine incremental few-shot learning[C]//Computer Vision – ECCV 2022, 2022: 205 – 222.
- [68] GOSWAMI D, LIU Y Y, TWARDOWSKI B, et al. FeCAM: exploiting the heterogeneity of class distributions in exemplar-free continual learning[C]//Proceedings of the Advances in Neural Information Processing Systems 36, 2023: 6582 – 6595.
- [69] YANG Y B, CHEN S X, LI X T, et al. Inducing neural collapse in imbalanced learning: do we really need a learnable classifier at the end of deep neural network? [C]//Proceedings of the Advances in Neural Information Processing Systems 35, 2022: 37991 – 38002.
- [70] YANG Y B, YUAN H B, LI X T, et al. Neural collapse inspired feature-classifier alignment for few-shot class incremental learning [C]//Proceedings of the International Conference on Learning Representations(ICLR), 2023.
- [71] MALLYA A, LAZEBNIK S. PackNet: adding multiple tasks to a single network by iterative pruning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018: 7765 – 7773.
- [72] MALLYA A, DAVIS D, LAZEBNIK S. Piggyback: adapting a single network to multiple tasks by learning to mask weights[C]//Computer Vision – ECCV 2018, 2018: 72 – 88.
- [73] SERRÀ J, SURÍ S D, MIRON M, et al. Overcoming catastrophic forgetting with hard attention to the task [C]//Proceedings of the 35th International Conference on Machine Learning, 2018.
- [74] WORTSMAN M, RAMANUJAN V, LIU R, et al. Supermasks in superposition [C]//Proceedings of the 34th Conference on Neural Information Processing Systems (NeurIPS 2020), 2020.
- [75] KANG H, MINA R J L, MADJID S R H, et al. Forget-free continual learning with winning subnetworks [C]//Proceedings of the 39th International Conference on Machine Learning, 2022.
- [76] GURBUZ M B, DOVROLIS C. NISPA: neuro-inspired stability-plasticity adaptation for continual learning in sparse networks [C]//Proceedings of the 39th International Conference on Machine Learning, 2022.
- [77] AHN H, CHA S, LEE D, et al. Uncertainty-based continual learning with adaptive regularization[C]//Proceedings of the 33rd Conference on Neural Information Processing Systems (NeurIPS 2019), 2019.
- [78] KONISHI T, KUROKAWA M, ONO C, et al. Parameter-level soft-masking for continual learning[C]//Proceedings of the 40th International Conference on Machine Learning, 2023.
- [79] JIN H, KIM E. Helpful or harmful: inter-task association in continual learning [C]//Computer Vision – ECCV 2022, 2022: 519 – 535.
- [80] YOON J, YANG E, LEE J, et al. Lifelong learning with dynamically expandable networks [C]//Proceedings of the International Conference on Learning Representations, 2018.
- [81] LI X L, ZHOU Y B, WU T F, et al. Learn to grow: a continual structure learning framework for overcoming catastrophic forgetting [C]//Proceedings of the 36th International Conference on Machine Learning, 2019.
- [82] XU J, ZHU Z X. Reinforced continual learning [C]//Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018: 907 – 916.
- [83] YAN S P, XIE J W, HE X M. DER: dynamically expandable representation for class incremental learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021: 3013 – 3022.
- [84] DOUILLARD A, RAMÉ A, COUAIROU G, et al. DyTox: transformers for continual learning with dynamic token expansion[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 9275 – 9285.
- [85] WANG F Y, ZHOU D W, LIU L, et al. Beef: bi-compatible class-incremental learning via energy-based expansion and fusion[C]//Proceedings of the International Conference on Learning Representations, 2023.
- [86] ALJUNDI R, CHAKRAVARTY P, TUYTELAARS T. Expert gate: lifelong learning with a network of experts [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 7120 – 7129.
- [87] RYPEŠĆ G, CYGERT S, KHAN V, et al. Divide and not forget: ensemble of selectively trained experts in continual learning[C]//Proceedings of the International Conference on

- Learning Representations, 2024.
- [88] VENIAT T, DENOYER L, RANZATO M A. Efficient continual learning with modular networks and task-driven priors [ C ] // Proceedings of the International Conference on Learning Representations, 2021.
- [89] GURBUZ M B, MOORMAN J M, DOVROLIS C. NICE: neurogenesis inspired contextual encoding for replay-free class incremental learning [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2024: 23659 – 23669.
- [90] WANG Z F, ZHANG Z Z, LEE C Y, et al. Learning to prompt for continual learning [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2022: 139 – 149.
- [91] WANG Z F, ZHANG Z Z, EBRAHIMI S, et al. DualPrompt: complementary prompting for rehearsal-free continual learning [ C ] // Computer Vision – ECCV 2022, 2022: 631 – 648.
- [92] KHATTAK M U, WASIM S T, NASEER M, et al. Self-regulating prompts: foundational model adaptation without forgetting [ C ] // Proceedings of the IEEE/CVF International Conference on Computer Vision ( ICCV ), 2023: 15144 – 15154.
- [93] QIAO J Y, ZHANG Z Z, TAN X, et al. Prompt gradient projection for continual learning [ C ] // Proceedings of the International Conference on Learning Representations, 2024.
- [94] GAO Z X, CEN J, CHANG X B. Consistent prompting for rehearsal-free continual learning [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2024: 28463 – 28473.
- [95] HUANG M Y, SU H, WANG L Y, et al. Hierarchical decomposition of prompt-based continual learning: rethinking obscured sub-optimality [ C ] // Proceedings of the Advances in Neural Information Processing Systems 36, 2023: 69054 – 69076.
- [96] SMITH J S, KARLINSKY L, GUTTA V, et al. CODA-prompt: continual decomposed attention-based prompting for rehearsal-free continual learning [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2023: 11909 – 11919.
- [97] KURNIAWAN M R, SONG X, MA Z H, et al. Evolving parameterized prompt memory for continual learning [ C ] // Proceedings of the 38th AAAI Conference on Artificial Intelligence, 2024: 13301 – 13309.
- [98] ALI KHAN M G Z, NAEEM M F, VAN GOOL L, et al. Introducing language guidance in prompt-based continual learning [ C ] // Proceedings of the IEEE/CVF International Conference on Computer Vision ( ICCV ), 2023: 11429 – 11439.
- [99] ROY A, MOULICK R, VERMA V K, et al. Convolutional prompting meets language models for continual learning [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2024: 23616 – 23626.
- [100] TANG Y M, PENG Y X, ZHENG W S. When prompt-based incremental learning does not meet strong pretraining [ C ] // Proceedings of the IEEE/CVF International Conference on Computer Vision ( ICCV ), 2023: 1706 – 1716.
- [101] SHON H, LEE J, KIM S H, et al. DLCFT: deep linear continual fine-tuning for general incremental learning [ C ] // Computer Vision – ECCV 2022, 2022: 513 – 529.
- [102] BOSCHINI M, BONICELLI L, PORRELLO A, et al. Transfer without forgetting [ C ] // Computer Vision – ECCV 2022, 2022: 692 – 709.
- [103] ROY A, VERMA V K, VOONNA S, et al. Exemplar-free continual transformer with convolutions [ C ] // Proceedings of the IEEE/CVF International Conference on Computer Vision ( ICCV ), 2023: 5874 – 5884.
- [104] PANOS A, KOBE Y, REINO D O, et al. First session adaptation: a strong replay-free baseline for class-incremental learning [ C ] // Proceedings of the IEEE/CVF International Conference on Computer Vision ( ICCV ), 2023: 18774 – 18784.
- [105] ZHANG G W, WANG L Y, KANG G L, et al. SLCA: slow learner with classifier alignment for continual learning on a pre-trained model [ C ] // Proceedings of the IEEE/CVF International Conference on Computer Vision ( ICCV ), 2023: 19091 – 19101.
- [106] LIU T Y, SOATTO S. Tangent model composition for ensembling and continual fine-tuning [ C ] // Proceedings of the International Conference on Computer Vision, 2023.
- [107] TAN Y W, ZHOU Q H, XIANG X, et al. Semantically-shifted incremental adapter-tuning is a continual ViTransformer [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2024: 23252 – 23262.
- [108] WANG Y, ZHOU D W, YE H J. Integrating task-specific and universal adapters for pre-trained model-based class-incremental learning [ C ] // Proceedings of the International Conference on Computer Vision, 2025: 806 – 816.
- [109] HUANG L L, CAO X S, LU H R, et al. Class-incremental learning with CLIP: adaptive representation adjustment and parameter fusion [ C ] // Computer Vision – ECCV 2024, 2024: 214 – 231.
- [110] WEN Z H, WANG Y, FENG J, et al. Hierarchical representation matching for CLIP-based class-incremental learning [ C ] // Proceedings of the International Conference on Learning Representations, 2025.
- [111] HU T, LI L, XIE Z H, et al. Hierarchical semantic tree anchoring for CLIP-based class-incremental learning [ EB/OL ]. ( 2025 – 11 – 19 ) [ 2026 – 01 – 02 ]. <https://arxiv.org/abs/2511.15633>.
- [112] YU L, HAN H Y, TAO Z, et al. Language guided concept bottleneck models for interpretable continual learning [ C ] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition ( CVPR ), 2025: 14976 – 14986.
- [113] LI L, HU T, ZHOU D W, et al. BOFA: bridge-layer orthogonal low-rank fusion for CLIP-based class-incremental learning [ J ]. Proceedings of the AAAI Conference on Artificial Intelligence, 2026, 40(27): 22967 – 22975.
- [114] ZHOU D W, ZHANG Y H, WANG Y, et al. Learning without forgetting for vision-language models [ J ]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(6): 4489 – 4504.

- [115] FRASCAROLI E, PANARIELLO A, BUZZEGA P, et al. CLIP with generative latent replay: a strong baseline for incremental learning [C]//Proceedings of the 35th British Machine Vision Conference, 2024.
- [116] SOLOMON I, AUNG A P P, KUMAR U, et al. Caption, create, continue: continual learning with pre-trained generative vision-language models [C]//Proceedings of the 34th ACM International Conference on Information and Knowledge Management, 2025; 5258–5262.
- [117] HE J H, GUO H Y, ZHU K, et al. Continual instruction tuning for large multimodal models [J]. IEEE Transactions on Image Processing, 2026, 35: 2699–2713.
- [118] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [119] KADAM S S, ADAMUTHE A C, PATIL A B. CNN model for image classification on MNIST and Fashion-MNIST dataset [J]. Journal of Scientific Research, 2020, 64(2): 374–384.
- [120] KRIZHEVSKY A. Learning multiple layers of features from tiny images [EB/OL]. (2009–04–08) [2026–01–02]. <https://www.semanticscholar.org/paper/Learning-Multiple-Layers-of-Features-from-Tiny-Krizhevsky/5d90f06bb70a0a3dc ed62413346235c02b1aa086>.
- [121] NETZER Y, WANG T, COATES A, et al. Reading digits in natural images with unsupervised feature learning [EB/OL]. [2026–01–02]. [https://www-cs.stanford.edu/people/twangeat/papers/nips2011\\_housenumbers.pdf](https://www-cs.stanford.edu/people/twangeat/papers/nips2011_housenumbers.pdf).
- [122] LE Y, YANG X. Tiny ImageNet visual recognition challenge [EB/OL]. [2026–01–02]. [https://cs231n.stanford.edu/reports/2015/pdfs/yle\\_project.pdf](https://cs231n.stanford.edu/reports/2015/pdfs/yle_project.pdf).
- [123] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248–255.
- [124] WAH C, BRANSON S, WELINDER P, et al. The Caltech-UCSD Birds-200–2011 dataset [EB/OL]. [2026–01–02]. <https://gwern.net/doc/ai/dataset/2011-wah.pdf>.
- [125] LOMONACO V, MALTONI D. CORe50: a new dataset and benchmark for continuous object recognition [C]//Proceedings of the 1st Conference on Robot Learning (CoRL 2017), 2017: 17–26.
- [126] CARTA A, PELLEGRINI L, COSSU A, et al. Avalanche: a PyTorch library for deep continual learning [J]. Journal of Machine Learning Research, 2023, 24: 1–6.
- [127] BOSCHINI M, BONICELLI L, BUZZEGA P, et al. Class-incremental continual learning into the extended DER-verse [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(5): 5497–5512.
- [128] BUZZEGA P, BOSCHINI M, PORRELLO A, et al. Dark experience for general continual learning: a strong, simple baseline [C]//Proceedings of the Advances in Neural Information Processing Systems 33 (NeurIPS 2020), 2020.
- [129] ZHOU D W, WANG Q W, QI Z H, et al. Class-incremental learning: a survey [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 9851–9873.
- [130] MASANA M, LIU X L, TWARDOWSKI B, et al. Class-incremental learning: survey and performance evaluation on image classification [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(5): 5513–5533.
- [131] ZHOU D W, SUN H L, NING J Y, et al. Continual learning with pre-trained models: a survey [C]//Proceedings of the Thirty-Third International Joint Conference on Artificial Intelligence, 2024.
- [132] SUN H, ZHOU D W. C3Box: a CLIP-based class-incremental learning toolbox [EB/OL]. (2026–01–28) [2026–02–01]. <https://arxiv.org/abs/2601.20852>.
- [133] ZHAI M Y, CHEN L, TUNG F, et al. Lifelong GAN: continual learning for conditional image generation [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2019: 2759–2768.
- [134] ZHAI M Y, CHEN L, HE J W, et al. Piggyback GAN: efficient lifelong learning for image conditioned generation [C]//Computer Vision – ECCV 2020, 2020: 397–413.
- [135] MASIP S, RODRIGUEZ P, TUYTELAARS T, et al. Continual learning of diffusion models with generative distillation [C]//Proceedings of the 3rd Conference on Lifelong Learning Agents (CoLLAs), 2024.
- [136] LIU J R, XU S N, WANG Y, et al. CCD: continual consistency diffusion for lifelong generative modeling [EB/OL]. (2025–05–17) [2026–02–02]. <https://arxiv.org/pdf/2505.11936>.
- [137] MENEZES A G, DE MOURA G, ALVES C, et al. Continual object detection: a review of definitions, strategies, and challenges [J]. Neural Networks, 2023, 161: 476–493.
- [138] LIU Y Y, SCHIELE B, VEDALDI A, et al. Continual detection transformer for incremental object detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 23799–23808.
- [139] LIU Y Y, CONG Y, GOSWAMI D, et al. Augmented box replay: overcoming foreground shift for incremental object detection [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 11333–11343.
- [140] KIM J, KU Y, KIM J, et al. VLM-PL: advanced pseudo labeling approach for class incremental object detection via vision-language model [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2024: 4170–4181.
- [141] LUO W L, ZHANG S Z, CHENG D, et al. Gradient decomposition and alignment for incremental object detection [C]//Proceedings of the IEEE International Conference on Computer Vision, 2025: 4486–4495.
- [142] FENG H T, ZHANG L, YANG X, et al. Enhancing class-incremental object detection in remote sensing through instance-aware distillation [J]. Neurocomputing, 2024, 583: 127552.
- [143] LI W Z, ZHOU J W, LI X, et al. InfRS: incremental few-shot object detection in remote sensing images [J]. IEEE

- Transactions on Geoscience and Remote Sensing, 2024, 62: 5644314.
- [144] HUANG C, SHI Y S, ZHANG B, et al. Uncertainty-aware prototypical learning for anomaly detection in medical images[J]. Neural Networks, 2024, 175: 106284.
- [145] YANG G L, FINI E, XU D, et al. Uncertainty-aware contrastive distillation for incremental semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(2): 2567–2581.
- [146] XIAO J W, ZHANG C B, FENG J K, et al. Endpoints weight fusion for class incremental semantic segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 7204–7213.
- [147] ZHANG A Q, GAO G Y. Background adaptation with residual modeling for exemplar-free class-incremental semantic segmentation [C]//Computer Vision – ECCV 2024, 2024: 166–183.
- [148] ZHANG X Y, LUO W J, WANG G D, et al. Rethinking the influence of distribution adjustment in incremental semantic segmentation[J/OL]. IEEE Transactions on Multimedia, 2025: 1–12 [2026–02–02]. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&number=11248941>.
- [149] REN R M, ZHAO H B, WANG Y R, et al. Learn from past to future: exploiting self-training and curriculum learning in remote sensing class-incremental semantic segmentation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2025, 63: 5657215.
- [150] XIE J J, PAN B, XU X, et al. MiSSNet: memory-inspired semantic segmentation augmentation network for class-incremental learning in remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 5607913.
- [151] SUN X Q, WENG X X, PANG C, et al. Mitigating representation bias for class-incremental semantic segmentation of remote sensing images[J]. Science China Information Sciences, 2025, 68(8): 182301.
- [152] ZHU S Q, YU C R, WANG Q, et al. Class incremental medical image segmentation via prototype-guided calibration and dual-aligned distillation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2026, 40(16): 13961–13969.
- [153] PARK J, KANG M, HAN B. Class-incremental learning for action recognition in videos[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2021: 13678–13687.
- [154] NGUYEN L Q, CHOI J, DANG L M, et al. Background debiased class incremental learning for video action recognition[J]. Image and Vision Computing, 2024, 151: 105295.
- [155] YANG Y W, HAYAT M, JIN Z, et al. Geometry and uncertainty-aware 3D point cloud class-incremental semantic segmentation [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023: 21759–21768.
- [156] CHOWDHURY T, CHERAGHIAN A, RAMASINGHE S, et al. Few-shot class-incremental learning for 3D point cloud objects[C]//Computer Vision – ECCV 2022, 2022: 204–220.
- [157] YUE X H, ZHANG X Y, CHEN Y M, et al. MMAL: multi-modal analytic learning for exemplar-free audio-visual class incremental tasks[C]//Proceedings of the 32nd ACM International Conference on Multimedia, 2024: 2428–2437.
- [158] WU K X, LI X D, LI X L, et al. AVQACL: a novel benchmark for audio-visual question answering continual learning[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2025: 3252–3261.