

中图法分类号: TP181 文献标识码: A 文章编号: 1006-8961(2025)08-2599-34

论文引用格式: Lyu F, Wang L, Li X, Zheng W S, Zhang Z, Zhou T and Hu F Y. 2025. Comprehensive survey of continual learning. Journal of Image and Graphics, 30(8):2599-2632(吕凡, 王亮, 李玺, 郑伟诗, 张彰, 周涛, 胡伏原. 2025. 持续学习研究进展. 中国图象图形学报, 30(8):2599-2632)[DOI:10.11834/jig.240661]

持续学习研究进展

吕凡¹, 王亮¹, 李玺², 郑伟诗³, 张彰¹, 周涛⁴, 胡伏原^{5*}

1. 中国科学院自动化研究所模式识别实验室, 北京 100190; 2. 浙江大学计算机科学与技术学院, 杭州 310027;
3. 中山大学计算机学院, 广州 510006; 4. 北方民族大学计算机科学与工程学院, 银川 750021;
5. 苏州科技大学电子与信息工程学院, 苏州 215000

摘要: 持续学习(continual learning, CL)是机器学习领域的一个关键问题,旨在使模型在不断学习新任务的同时,避免灾难性遗忘,保持对先前任务的记忆。持续学习已在多个实际应用中扮演重要角色,如自动驾驶、机器人控制和医疗诊断系统等。本文旨在为学界提供持续学习领域的最新研究进展综述,并对未来可能的研究方向进行展望。为实现持续学习中新旧知识学习的“可塑性—稳定性”平衡,国内外研究者们提出多种方法,根据方法的发展路径可以分为传统持续训练方法和基于预训练模型的方法。首先,本文介绍了传统持续训练的关键技术和方法,包括记忆重放法、正则化法和动态结构法。记忆重放法通过将先前任务的样本存储并重放,以帮助模型回忆过去的知识。正则化法则通过对模型参数的更新进行约束,防止新任务对旧任务的干扰。动态结构法通过调整模型结构或引入新的模型模块以应对新任务的挑战,避免灾难性遗忘的发生。接着,本文进一步探讨了基于预训练模型的持续学习方法的进展。随着大规模预训练模型的广泛应用,这类预训练模型展示了强大的泛化能力和知识迁移能力。基于预训练模型的持续学习方法可以分为基于微调和基于提示的方法。微调方法可以通过冻结部分预训练模型参数,仅对特定层进行更新,或采用学习率调节等技术,避免对预训练模型的过度修改。基于提示的方法通过设计和输入提示来引导模型处理新任务,而无需大规模调整模型参数。本文提供的实验结果建议,当前持续学习任务应优先考虑采用基于预训练模型的方法。最后,本文对当前持续学习领域的挑战与未来发展方向进行了展望,重点讨论了各种实际约束条件下,如何结合预训练模型和经典持续学习方法,构建新的架构设计和优化策略,以应对日益复杂的现实任务需求。

关键词: 持续学习(CL);灾难性遗忘(CF);记忆重放;正则化;动态结构;预训练模型(PTM);综述

Comprehensive survey of continual learning

Lyu Fan¹, Wang Liang¹, Li Xi², Zheng Weishi³, Zhang Zhang¹, Zhou Tao⁴, Hu Fuyuan^{5*}

1. New Laboratory of Pattern Recognition, Institute of Automation, Chinese Academy of Science, Beijing 100190, China; 2. College of Computer Science and Technology, Zhejiang University, Hangzhou 310027, China; 3. School of Computer Science and Engineering, Sun Yat-sen University, Guangzhou 510006, China; 4. School of Computer Science and Engineering, North Minzu University, Yinchuan 750021, China; 5. School of Electric and Information Engineering, Suzhou University of Science and Technology, Suzhou 215000, China

收稿日期: 2024-11-11; 修回日期: 2025-01-21; 预印本日期: 2025-01-28

* 通信作者: 胡伏原 fuyuanhu@usts.edu.cn

基金项目: 新一代人工智能国家科技重大专项(2022ZD0117901); 国家自然科学基金项目(62406323, 62476189, 62373355); 国家资助博士后研究人员计划(GZC20232993); 中国博士后科学基金资助项目(2024M753496)

Supported by: National Science and Technology Major Project (2022ZD0117901); National Natural Science Foundation of China (62406323, 62476189, 62373355); Postdoctoral Fellowship Program of China Postdoctoral Science Foundation (GZC20232993); China Postdoctoral Science Foundation (2024M753496)

Abstract: Continual learning (CL), which is also known as lifelong learning, is a major concern in the field of machine learning. It refers to the capability of a system to learn new tasks while retaining knowledge gained from previous ones. CL has broad relevance in many real-world applications that require continual adaptation and learning such as autonomous driving, robotics, and medical diagnosis. CL succumbs to the catastrophic forgetting issue, which occurs when a model overwrites or significantly diminishes previously learned information while training on new tasks. This issue is prominent in traditional machine learning paradigms where models are trained on static datasets. The goal of CL is to develop models that exhibit plasticity, which allows them to adapt to new information, and stability, which ensures that previous knowledge is not lost. Various strategies have been proposed in the literature to address this challenge, which are comprehensively reviewed in this study. Broadly, CL techniques can be classified into those based on continual training and those based on prompts. Methods based on continual training can be further divided into three main categories: replay-based, regularization-based, and dynamic architecture methods. Replay-based methods are among the most popular and well-established techniques in CL. These methods aim to mitigate catastrophic forgetting by storing and replaying data from previously learned tasks. By revisiting samples from prior tasks during training on new tasks, the model is effectively reminded of past knowledge, which helps maintain accuracy on earlier tasks. Replay-based methods can be further categorized into two types: replay memory construction and replay memory utilization. Replay memory construction focuses on saving the replay memory, and methods can be categorized into three types depending on how knowledge is stored: storing raw data, building generative models, and storing data features to construct memory. Memory replay methods that store raw data directly save the original data from old tasks along with the corresponding labels. The raw data are available in various formats, such as images, videos, audio, or text. During training on a new task, the stored memory data from old tasks are trained together with the new task data, which helps prevent forgetting. Storing raw data for memory replay requires no additional operations for storage and utilization, and it maintains consistency with the training process of the original model. The method of building generative models has been influenced by the recent development of generative models, where representative samples of past knowledge are generated for replay. These methods can be classified based on the type of generative model used. In CL, the strength of generative models lies in their ability to generate high-quality synthetic data, which helps the model overcome catastrophic forgetting issues common in traditional methods. Ultimately, the long-term memory capacity of the model is significantly enhanced. The method of storing data features is chosen when data features provide a good representation of the original data. In situations where privacy protection and storage constraints are a concern, storing data features rather than raw data or additional models becomes a practical solution. Replay memory utilization focuses on effectively leveraging the stored samples to enhance the efficacy of replay. This approach includes techniques such as data augmentation, knowledge distillation, Bayesian methods, optimization, and gradient projection, as well as representation alignment and bias correction. Regularization-based methods aim to address catastrophic forgetting by introducing constraints on the parameters of the model, which prevents them from undergoing drastic changes when learning new tasks. This approach enforces stability by preserving the critical aspects of previously learned knowledge through penalizing large deviations in the parameters of the model. Regularization methods can be categorized into those based on Laplace approximation, task representation constraints, Bayesian regularization, and knowledge distillation. The Laplace approximation technique approximates the posterior distribution of the old task as a Gaussian distribution, which imposes constraints on the important parameters of the old tasks. This type of regularization method works by adding penalty terms to the loss function to restrict changes to the parameters related to previous tasks when training on new tasks. In doing so, it achieves balanced learning of new and old tasks, which reduces the risk of catastrophic forgetting. Task representation constraint-based methods utilize the historical model to generate representations of current samples while applying regularization constraints based on these historical representations. The core idea of Bayesian regularization is to use a Bayesian framework to update model parameters, which allows the retention of knowledge from previous tasks while learning new ones. By regularizing model parameters within the Bayesian framework, this approach effectively balances the learning of new and old tasks, which reduces catastrophic forgetting. By contrast, knowledge distillation-based regularization methods do not require additional storage of replay memories. Instead, they leverage stored historical models as teachers while using the current training samples as input to guide learning. Dynamic architecture methods address new tasks

and knowledge by gradually adjusting the structure of the model. These methods dynamically modify the architecture or parameters of the neural network based on changes in input data and the demands of new tasks. Thus, they add or reallocate network resources to learn new knowledge without forgetting the old. Dynamic architecture methods ensure CL by automatically expanding the network, activating important parameters, and freezing irrelevant parts, which allow the model to adapt to new tasks while avoiding catastrophic forgetting. Dynamic architecture methods can be further divided into multi-expert and subnetwork structures, dynamic scarification and masking techniques, dynamic structural adjustment, and the learning of additional task-related modules. In recent years, pre-trained large models, such as Transformer-based architectures, have achieved remarkable success across various domains due to their ability to generalize effectively across tasks. These models, which are commonly pre-trained on vast amounts of data, have strong representational power and are increasingly being applied in CL scenarios due to their ability to learn new tasks with minimal forgetting. Pre-trained models can be used in CL through two primary strategies: fine-tuning- and prompt-based methods. Fine-tuning involves adapting a pre-trained model to a new task by updating some or all of its parameters. In the context of CL, fine-tuning can be performed by freezing certain layers of the pre-trained model and only updating specific parts, such as task-specific layers, to prevent the model from losing knowledge gained from earlier tasks. Another approach is to fine-tune the model using task-specific learning rates, which ensures that important parameters for previous tasks are modified less during the training of new tasks. Prompt-based methods represent a newer approach to leveraging pre-trained models for CL. Rather than adjusting the internal parameters of the model, prompt-based methods guide its behavior by designing and inputting task-specific prompts. These prompts serve as auxiliary information that helps the model focus on the relevant aspects of the new task without altering its underlying architecture or parameters. Despite the advancements in CL techniques, several challenges remain. An important concern is the scalability of CL methods, especially in real-world applications where the number of tasks and data diversity can be vast. Another issue is achieving an optimal balance between plasticity and stability, given that methods that overemphasize stability may limit the ability of the model to learn effectively from new tasks. Future research in CL is expected to focus on the integration of pre-trained large models with traditional CL techniques. It will explore novel architectural designs and optimization strategies that can better address the demands of complex, real-world tasks. Additional works are needed to develop CL methods that are computationally efficient, particularly for large-scale models, without sacrificing performance or flexibility. By combining the strengths of large models with classical CL techniques, the field is set to achieve considerable advancements in creating intelligent systems capable of lifelong learning in dynamic and ever-changing environments.

Key words: continual learning(CL); catastrophic forgetting (CF); memory replay; regularization; dynamic architecture; pre-trained model(PTM); review

0 引言

人工智能技术已进入飞速发展时期,机器学习尤其是深度学习(江铃焱等,2023)在图像识别(He等,2016)、自然语言处理(Vaswani等,2017)等领域取得显著成就。现有机器学习模型大多在静态数据集上进行训练,模型一旦训练完成,其参数和结构将固定不变。然而,现实世界中环境不断产生动态变化,新的任务和数据持续出现,这种静态学习方式面临巨大挑战。

持续学习(continual learning, CL)的概念旨在解决静态学习在动态环境中的局限性。持续学习要求

模型在不断学习新知识的同时,能够保留对旧知识的记忆能力,避免灾难性遗忘(catastrophic forgetting, CF)。这种学习方式更接近人类的学习过程,人类在学习新知识时,需要保持历史知识的记忆从而形成技能积累。现实世界的需求推动了持续学习研究的发展。在资源受限和数据安全要求下,持续学习的重要性愈发凸显。例如,在医疗领域,持续学习可以帮助模型不断吸收新的医疗数据和研究成果,同时保留对旧病例的记忆,从而提供更准确的诊断和治疗建议。持续学习有助于实现机器的终身学习、提高机器的适应性和泛化能力,推动人工智能向更高层次发展。因此,深入研究持续学习,探索有效的持续学习策略和模型,对于人工智能领域具有重

要的理论和实践意义。

持续学习中,灾难性遗忘指当模型学习新任务时,对旧任务的记忆和知识会大幅丧失。如果模型不能持续学习,就无法有效地应对这些变化。然而,在持续学习中抑制灾难性遗忘容易降低对新知识的学习能力。一般地,对旧知识的有效记忆能力称为稳定性,对新知识的有效学习能力称为可塑性。持续学习在长时间维度的主要目标通常可以表示为达到“稳定性—可塑性”平衡。这种需求在现实应用中十分常见,例如,在自动驾驶领域,车辆需要不断适应新的交通规则、道路状况和环境变化,而且不能忘记过去已学习的知识。

持续学习经过多年的发展,经典方法主要依赖传统持续训练的方式,即对骨干模型不断更新使其适应新任务,目前已经形成了几类主要的解决路径,包括基于记忆重放的方法(replay-based methods)、基于正则化的方法(regularization-based methods)和基于动态结构的方法(dynamic architecture-based methods)。其中,基于重放的方法通过重放旧任务的数据或使用生成模型生成旧任务的样本,帮助模型在学习新任务时保持对旧任务的记忆。这种方法虽然性能较好,但需要额外的存储空间或计算资源来存储或生成旧数据。基于正则化的方法通过在损失函数中加入正则化项,限制模型参数在学习新任务时的变化,减少遗忘旧任务的风险。这类方法不需要额外的存储空间,适合内存有限的情况,但可能会限制模型对新任务的学习能力。基于动态结构的方法通过为每个新任务扩展网络或调整网络结构,确保模型同时适应新旧任务,避免遗忘。然而,随着任务数量的增加,模型的承载力降低,计算开销显著增加。每种方法都有其优缺点,具体选择取决于应用场景中的存储、计算资源和任务数量等多种因素。

近年来,预训练模型(pre-trained model, PTM)(Han等,2021)获得了巨大发展,学者们利用预训练模型在许多机器学习领域取得了新的突破。在持续学习中,如何利用预训练模型解决灾难性遗忘,研究者们提出多种方法,这些方法主要分为两类:基于微调(fine-tuning-based)的方法,不直接修改模型结构,而侧重于直接微调预训练模型或构建新的适配器,使模型能够适应新任务;基于提示(prompt-based)的方法,这类方法通过引入轻量级的可训练组件(如提示符)调整预训练模型,以适应新任务。这些方法不

仅展示了预训练模型在持续学习领域的应用潜力,同时也指出了在实际应用中需要进一步研究和改进的方向。

本文旨在提供对持续学习领域研究进展的全面回顾和最新介绍,并对未来可能的研究方向进行展望。近年来,国内外学术界对持续学习已经存在一些综述。然而其中大多数聚焦于单一持续学习场景,或缺乏最新技术进展的介绍。Parisi等人(2019)提供了早期神经启发的持续学习方法,缺乏对基于深度网络的持续学习方法的系统性总结。de Lange等人(2022)聚焦于早期的任务增量持续学习任务,总结了2020年之前的持续学习方法。该综述较早地将持续学习方法分为基于正则化方法、基于重放的方法和基于动态结构的方法。但仅聚焦任务增量持续学习且缺乏新的结构和方法,如基于预训练模型的持续学习方法。Masana等人(2023)、朱飞等人(2023)和周大蔚等人(2023)只考虑了类别增量持续学习。Mai等人(2022)只整理了在线持续学习的研究进展。与以上综述大多聚焦于持续学习的单一场景不同,本文主要关注持续学习的发展路径,提供近期最新的研究进展,例如结合预训练模型的持续学习等。

1 持续学习的基础知识

1.1 学习与记忆的神经科学基础

持续学习将机器学习的概念拓展到了长时,而形成鲁棒的长时智能需要同时兼备学习和记忆能力。从神经科学角度来看,人类和动物大脑中,学习与记忆的过程由神经元控制。这些神经元通过突触相互连接,形成了复杂的神经网络。学习是通过经验改变行为的过程,表现为神经网络中海马体(hippocampus)的突触连接变化,这种变化称为突触可塑性(Reber,2013)。记忆是学习过程中获得的信息在大脑中的存储和回忆,短期记忆需要大脑前额叶的短期活动,而长期记忆则依赖于大脑结构的持久性变化,记忆的效果表现为稳定性(Bisaz等,2014)。

在持续学习中,一个关键的神经科学概念是“稳定性—可塑性”平衡(Mermillod等,2013;Schulz,2006),即大脑需要在维持现有记忆和学习新知识之间找到平衡。真实生活环境不会一成不变,这需要

人脑具有持续的学习能力,不断学习新知识的同时保证旧知识不被遗忘。持续学习模仿了人脑的学习方式,表现为对环境变化的持续适应和过去知识的持续记忆。

1.2 持续学习增量类型

持续学习也称为增量学习,这是因为新知识通

常以增量的方式有监督地输入到模型中。根据增量载体的不同,持续学习可分为任务增量、类别增量、域增量和无边界增量 4 种主要类型。给定任务 t 的训练样本集 X_t 和其对应的标签集 Y_t ,用 $p(X_t)$ 和 $p(Y_t)$ 代表样本和标签的分布。表 1 给出了不同增量载体下持续学习的区别。

表 1 持续学习增量场景
Table 1 Incremental scenarios of continual learning

增量类别	样本分布	标签分布	标签集关系	任务标签
任务增量	$P(X_{t-1}) \neq P(X_t)$	$P(Y_{t-1}) \neq P(Y_t)$	$Y_{t-1} \neq Y_t$	有
类别增量	$P(X_{t-1}) \neq P(X_t)$	$P(Y_{t-1}) \neq P(Y_t)$	$Y_{t-1} \neq Y_t$	无
域增量	$P(X_{t-1}) \neq P(X_t)$	$P(Y_{t-1}) \neq P(Y_t)$	$Y_{t-1} \neq Y_t$	无
无边界增量	$P(X_{t-1}) \neq P(X_t)$	不确定	不确定	无

任务增量持续学习(Rebuffi 等, 2017; Lopez-Paz 和 Ranzato, 2017; Chaudhry 等, 2018)假设各任务的数据标签空间不重叠,且训练和测试时均提供任务标识。每个任务相互独立,拥有不同的数据分布和标签集合,适用于多任务差异较大,需根据输入执行特定任务的场景。因其训练和测试都有任务标签约束解空间,效果更好且易训练。类别增量持续学习(Zhang 等, 2020; Zhao 等 2020; Yan 等, 2021)适用于分类任务,新知识以新类别呈现,训练和测试时都不提供任务标签。类别增量与任务增量一样,不同任务有独立分布,但其训练和测试的类别标签集包含所有学过类别。因训练新任务时只有新标签样本却要计算旧任务的损失,导致旧类别遗忘严重,且新类别训练困难。域增量持续学习(Mirza 等, 2022; Churamani 等, 2023; Garg 等, 2022)有别于任务增量连续学习以及类别增量连续学习,在其连续学习里,不同任务只是考虑到样本分布有所不同,然而样本却有着相同的标签集。如,过去是在晴朗天气下进行自动驾驶中的语义分割学习,而新任务则是在恶劣天气下开展自动驾驶语义分割的学习。无边界增量持续学习(Aljundi 等, 2019b; Pourcel 等, 2022; Jin 等, 2021)特指模糊任务边界的连续学习。该增量场景考虑到现实中的增量并不一定有严格的任务边界,即新旧任务的标签空间可能存在重叠,贴合实际需求,具有更高实用性。上述持续学习增量类型提供了不同的新知识输入方式,衍生出的方法大体可以通用,有一定细微区别,在实际场景中应视具体情况而定。与之前综述相比,本文将介绍持续学习的

发展路径,而不具体从某一场景出发。

1.3 “稳定性—可塑性”困境

如前文所述,长时的持续学习模仿了人类的学习方式,学习和记忆是其需要具备的主要能力。但是因为新学习,机器学习模型不可避免地面临灾难性遗忘(CF)挑战。灾难性遗忘指在机器学习模型训练过程中,当模型学习新任务时,显著忘记之前已经学到的任务知识的现象。该现象是由于模型参数在训练新任务时会被调整、覆盖或改变了之前任务的参数配置,导致模型在旧任务上的性能急剧下降。灾难性遗忘是持续学习领域的一个主要挑战,因为在动态和多任务环境中,模型需要保持并利用过去的知识来有效应对新的数据和任务。尽管传统的机器学习方法在单一任务上表现出色,但在面对逐步增加的新任务时,难以同时保持对先前任务的良好记忆,这对实现真正的智能系统构成了障碍。

对灾难性遗忘现象的明确记载最早可追溯到 1989 年,McCloskey 和 Cohen(1989)发现连接结构中旧知识会被新学习干扰。早期诸多研究试图改进模型和算法来抑制这种干扰,如 Hinton 和 Plaut(1987)构建快慢两套训练参数用于控制不同阶段模型的学习,Robins(1995)发现可存储部分过去数据,并与当前混合训练来抑制遗忘,启发了近年持续学习的重要方法——重放法。这些工作证明,机器学习模型为了抑制灾难性遗忘将会导致新任务的学习效果降低,而提升学习效果又易导致旧知识的遗忘,这个挑战称为“稳定性—可塑性”困境。该命名来自神

经科学,在神经科学中记忆和学习表现为神经突触的稳定性和可塑性。由图1可知,持续学习的主要目标就是在长时的学习过程中,克服稳定性—可塑性困境,实现快速学习新知识的同时有效保持旧知识的记忆。

1.4 持续学习的基本算法框架

给定 T 个不同的任务对应数据集或数据流 $\{D_1, \dots, D_T\}$ 。对于第 t 个任务, $D_t = \{(x_{t,1}, y_{t,1}), \dots, (x_{t,N_t}, y_{t,N_t})\}$, 其中, $x_{t,i} \in X_t$ 是第 i 个输入数据, $y_{t,i} \in Y_t$ 是对应的标签, N_t 是样本数目。 D_t 可以分解为训练集 D_t^{trn} 和测试集 D_t^{test} 。训练过程在训

练集 D_t^{trn} 上进行,本文在下面简化表述,用 D_t 表示 D_t^{trn} 。持续学习目的在于学习一个多任务共享的表征模型 $h(\theta): x \rightarrow u$ 和多个任务特有的预测器 $f(\theta_i): u \rightarrow p$, 其中 u 代表了数据表征, p 代表模型预测结果。 θ 和 θ_i 分别代表共享骨干模型参数和任务独有的分类器参数。对于 θ_i 来说,不受其他任务的目标函数影响,更新不存在多任务冲突。由于任务数据是顺次接入,因此分类器 f 是自适应地被创建,当训练到任务 t 时,由于只有该任务的数据,则所有分类器中只有 $f(\theta_i)$ 被激活,且并不存在未来的分类器 $f(\theta_{i+1})$ 。



图1 持续学习研究发展路径

Fig. 1 Research development path of continual learning

2 传统持续训练方法

综合不同的技术路线,持续学习方法主要可以分为基于记忆重放的方法、基于正则化的方法和基于动态结构的方法,如图2所示。每类方法可以进行细分,但这些方法并不独立,可以相互组合叠加使用。本节重点介绍持续学习方法的研究进展。

2.1 基于记忆重放的方法

持续学习中记忆重放指的是存储部分过去任务的信息,并在新任务学习的时候重新利用这部分信息,从而实现抑制遗忘的效果。相对于其他方法,记忆重放具有易操作、效果好的优势。如图3所示,记忆重放法的核心思路在于解决两个问题,分别是如何构建重放记忆和如何高效利用记忆。针对前者,记忆重放法包含以下几种数据存储方式:1)通过存储原数据的重放法,这种重放法在存储的原始数据上重训练,约束所有模型参数的更新,通常考虑的核心问题是在有限存储下如何有效选择样本;2)通过构建生成模型合成数据进行重训练,该方法通过存

储模型而非存储数据来达成重放的效果;3)通过存储特征的重放法,该方法通常存储更轻量化的数据表征或类别原型实现特征重放。此外,不同的存储方式可以构建多记忆系统,为不同记忆系统设置不同的记忆任务从而提升重放的效果。存储记忆的构建通常考虑到存储设备的约束,一些学者在记忆重放的基础上,探索高效的存储治理技术。针对后者,学者们通常利用经典的重放记忆构建方法,但将重点聚焦于如何高效利用记忆。根据利用方法不同,可以将这部分方法分为基于特征蒸馏、基于优化、基于贝叶斯、优化与梯度投影以及表征对齐与偏差校正等方法。其中特征蒸馏考虑在重放的同时,利用过去知识的表征同时对重放的特征进行约束。基于优化的方法考虑将重放的过程表示为优化问题,寻找能够同时保证可塑性和稳定性的模型更新方法。基于贝叶斯的方法将记忆重放问题表示为一种后验估计过程,利用贝叶斯法则对重放过程建模。优化与梯度投影方法通过操控模型的训练梯度,将梯度投影到影响任一任务的更新。表征对齐与偏差校正则在特征空间上进行正则,减少特征的过度偏




图 2 持续学习算法发展历程

Fig. 2 Development of continual learning algorithm




图 3 记忆重放的存储与利用的主要方法

Fig. 3 Major approaches of the storage and utilization of knowledge replay

移。接下来, 本文将对这几种方法详细介绍。

2.1.1 选择原始数据存储构建重放记忆

存储原数据(raw data)的记忆重放法直接存下

旧任务的原始数据和对应数据标签, 原始数据可以是图像、视频、语音和文本等各种格式。在新任务训练时, 将旧任务存储的记忆数据和新任务的数据一

起训练,从而达到抑制遗忘的效果。存储原数据的记忆演练法优点是,原始数据的存储和利用无需额外操作,和原模型的训练具有一致性。缺点是需要开辟额外的存储空间并有隐私泄露的风险。

存储原始数据的重放法在任务 t 训练时,从数据集 D_t 中采样极小部分数据存储在记忆单元 M_t , 即 $|M_t| \ll |D_t|$ 。各任务记忆单元中的数据将会在接下来的任务学习中,用来重训练而抑制遗忘。基于存储原数据的记忆单元,在任务 t 学习时,训练问题可以表示为如下的多目标优化问题:

$$\min_{\theta, \{\theta_1, \dots, \theta_t\}} \{ \ell(f_{\theta}, f_{\theta_t}, D_t) \} \cup \{ \ell(f_{\theta}, f_{\theta_k}, M_k) | \forall k < t \} \quad (1)$$

因为隐私保护、存储约束的影响,记忆重放法通常仅考虑存储极少量训练样本。早期方法采用随机存储方法,例如 ER (experience replay) (Rolnick 等, 2019) 提出一种简单的存储重放的方法,将过去随机存储的样本和当前样本一起进行重训练。然而,随机存储存在大量不确定因素,难以满足效果。

样本选择问题是一个开放问题。一些学者研究挑选更具代表性的样本,构建代表性选择。Castro 等人(2018)提出利用 Herding 选择方法挑选最具代表性样本,该方法对于每个类别,根据样本到该类别均值的距离进行排序,然后选择排序列表中靠前的样本。Herding 算法包含以下两个关键步骤:1)根据样本到对应类平均样本的特征距离对样本进行排序,得到一个有序列表;2)从排序后的列表中选择前 n 个样本。这些被选择的样本被认为是最能代表该类的样本。此外,不同学者提出不同的重要性的定义,例如 Shim 等人(2021)利用合作博弈论中用于公平分配总收益的方法 Shapley 值来确定记忆样本对学习性能的贡献,根据样本与当前输入任务的关系,定义对抗性 Shapley 值,以选择对学习有益的记忆样本。如图4所示,Koh 等人(2022)提出通过计算每个样本对训练的有用性来决定哪些样本应该被保留或丢弃,即在每次训练迭代后根据训练批次样本损失差异更新得分,还使用指数移动平均作为经验估计以提高计算效率。仅存储代表性样本,这意味着这样重放获得的模型将获得较差的泛化性。为克服该问题,一些学者开始研究提升重放方法泛化性的多样性选择策略。MIR (maximal interfered retrieval) (Aljundi 等, 2019a) 提前估计模型参数的更新,并根据更新后的参数计算样本的损失,然后选择

损失最大的样本进行重放。Sun 等人(2022b)提出了一个基于信息论的记忆样本选择框架,通过评估数据的“新奇”和“可学习性”选择记忆样本。DCM (dynamic cluster memory) (Ye 和 Bors, 2024) 引入了基于知识差异度量的内存扩展机制,将相似语义信息的数据样本自动存储在相同的内存聚类中,同时促进内存聚类间的知识多样性。此外,部分研究者认为采用启发式的选择策略难以获得较优的重放效果,并将样本选择问题建模为优化问题。BCSR (bilevel coresets selection via regularization) (Hao 等, 2023) 通过学习一个概率分布,使得在该分布下采样的数据集上训练得到的模型参数,也是整个数据集上的最优解。Luo 等人(2024)通过建立类间平衡记忆来解决数据不平衡问题,并通过类间基于梯度的相似度评分系统来精细化存储样本的选择策略。



图4 动态计算重放样本的重要性以调整存储 (Koh 等, 2022)

Fig. 4 Dynamically calculate the importance of replay samples to adjust storage (Koh et al., 2022)

2.1.2 构建基于生成模型的重放记忆

存储原始数据尽管已经获得了一定的效果,但仍然存在隐私泄露的风险,且泛化性较大受到存储样本量的影响。受到近年来生成模型发展的影响,一些方法不再存储原始数据,而选择利用生成模型生成代表过去知识的样本进行重放。这类方法可以根据生成模型的不同进行分类。在持续学习中,生成模型的优势在于可以通过生成高质量的合成数据,帮助模型克服传统方法中容易发生的灾难性遗忘问题,从而有效提升模型的长期记忆能力。

首先,生成对抗网络 (generative adversarial network, GAN) 是一种由生成器和判别器相互对抗学习的深度学习模型。DGR (deep generative replay) (Shin 等, 2017) 提出一种基于深度生成模型的持续学习框架,通过生成过去任务的数据并与新任务的数据混合,以减轻模型在学习新任务时对旧任务的遗忘。LwP (learning without prejudices) (Jeon 等, 2023) 使用生成对抗网络生成包含先前信息的特征,

并通过对比学习进行训练,以鼓励良性遗忘减少恶性遗忘。其次,变分自动编码器(variational auto-encoder, VAE)是一种基于概率图模型的生成模型,通过学习数据的概率分布生成相似数据,在持续学习中,VAE 的优势在于可以为不同任务生成潜在空间的连续表示,帮助模型在多个任务间灵活迁移知识,减轻灾难性遗忘。

FearNet(Kemker 和 Kanan, 2018)是一种基于脑启发的模型,该模型使用生成式自动编码器生成以前学习过的示例,通过将新记忆与旧记忆进行重放来巩固近期记忆,从而缓解灾难性遗忘。DRI(deep retrieval and imagination)(Wang 等, 2022c)是一种包含嵌入网络和生成模型的框架,其中嵌入网络用于构建统一的嵌入空间,无需在新任务到来时增加模型参数,生成模型则基于有限记忆生成额外的数据。此外,扩散模型(diffusion model)是一种通过逐步将数据加入噪声再逆向还原生成数据的生成模型,在

持续学习中,扩散模型的优势在于其逐步生成过程能够更好地平衡新旧任务之间的知识更新,减少灾难性遗忘并提高模型的泛化能力。DDGR(deep diffusion-based generative replay)(Gao 和 Liu, 2023)采用扩散模型作为生成器,通过分类器计算指令运算符指导扩散模型在每个时间步骤的样本生成过程,该方法还允许使用预训练的分类器来指导扩散模型的生成过程,如图 5 所示。DCMI(dual-consistency model inversion)(Qiu 等, 2024)提出两种一致性对齐策略来生成更好的旧类别合成样本,包括合成图像与相应原型之间的语义一致性和域一致性。

尽管生成模型的优势是可以通过参数对历史数据分布进行建模,生成的数据可同时具备代表性和多样性,且有效地避免了隐私泄露问题。然而,生成模型本身同样带来了较大的存储资源消耗,且生成模型本身也存在遗忘的风险,这限制了基于生成模型的重放方法的推广。




图5 利用扩散模型生成样本进行重放(Gao 和 Liu, 2023)

Fig. 5 Generate samples for replay using a diffusion model(Gao and Liu, 2023)

2.1.3 选择数据特征存储构建重放记忆

在存储原始数据和构建生成模型各自存在不足的情况下,一些方法考虑了折中方案。因样本特征对原始数据具有较好的表征效果,在考虑隐私保护、存储约束的情况,选择存储样本特征而非原始数据或额外模型。DER(dark experience replay)(Buzzega 等, 2020)存储样本额外的 Logits,通过结合知识蒸馏和正则化来解决灾难性遗忘问题。PRAKA(proto-type reminiscence and augmented asymmetric knowledge aggregation)(Shi 和 Ye, 2023)通过结合新类别特征和旧类别原型动态重塑旧类别特征分布,以维持先前任务的决策边界。CCFA(cross-class feature augmentation)(Kim 等, 2024b)受对抗性攻击启发,在不同类别的样本上合成增强特征,而无需修改架

构或引入生成模型。尽管存储特征的重放方法具有存储占用小、保护隐私的优点,但由于中间层的特征难以提供全面的信息,基于这样的设定构建的损失函数难以更新存储特征层之后的参数,这可能导致部分历史信息丢失。

2.1.4 多记忆系统

上述存储记忆方法各有优缺点,一些学者设计同时兼顾多种记忆方式的多记忆系统。这类方法经常基于脑启发,构建具有不同功能的记忆重放系统,提升整体的记忆效果。FearNet(Kemker 和 Kanan, 2018)是一种早期的双记忆系统,该方法同时结合了自动编码器生成历史知识。Pham 等人(2021)提出一种双记忆系统,包括情景记忆和语义记忆,分别通过情景重放记忆情景知识和控制器泛化到语义记忆

的任务特定特征。Arani 等人(2022)提出通过维护短期和长期语义记忆与情景记忆的交互,采用有效的重放机制,在获取新知识的同时对齐决策边界与语义记忆,以实现有效的知识整合。SCoMMER(multi-memory experience replay mechanism that employs sparse coding)(Sarfraz 等 2023)通过引入稀疏编码和多记忆系统机制,聚合工作记忆中编码的信息,并通过知识检索损失与情景记忆交互,以加强工作记忆函数空间的一致性,如图 6 所示。Sun 等人(2023a)提出通过知识蒸馏将学习过程和记忆过程分离,引入了两个互补的记忆组件,一个用于存储旧知识,另一个用于学习新知识。




图 6 重放多记忆系统(Sarfraz 等,2023)
Fig. 6 Multi-memory system for replay(Sarfraz et al. ,2023)

2. 1. 5 存储治理

记忆重放方法依赖记忆的存储,在此基础上的存储治理目的是为了减少记忆数据的存储量,提升知识利用效率。早期的存储治理和特征重放结合,利用特征大小小于原始数据的特性减少存储量。例如,REMIND(Hayes 等,2020)通过使用张量量化来压缩存储特征,以便后续特征重放。DSDM(dynamic sparse distributed memory)(Pourcel 等,2022)通过动态调整内存节点并计算样本与现有节点的关系进行有效的存储和检索,以实现对样本的学习和记忆。MRDC(memory replay with data compression)(Wang 等,2022a)通过数据压缩技术减少存储旧训练样本的成本,从而在有限的存储空间内存储更多的旧样本,以更有效地恢复过去任务的数据分布。LoDM(low-rank dataset condensation)(Yang 等,2023)在低维流形上将大型真实世界数据集压缩成小型合成数据集,通过在低维空间中匹配原始数据集和合成数据集,显著提高了数据集压缩的效率。此外,记忆重放法对存储空间的大小存在约束,这延

伸出了如何有效划分存储空间的问题。Kim 等人(2020)在在线持续学习中根据数据流的统计信息获得不同类分区比例,然后使用运行类频率设置存储中类的目标比例。RM(rainbow memory)(Bang 等,2021)通过增加样本多样性管理有限容量的样本存储,使用基于样本分类不确定性和数据增强的方法更新样本记忆。

部分学者考虑到在一些应用中,不存在隐私问题且存储量不受约束,并在这类场景中提出贪婪存储的方式,将所有历史样本贪婪地进行重放。这样,该问题的挑战就从如何选择存储样本变成了如何选择重放样本。Gdumb(Prabhu 等,2020)由贪婪平衡采样器和学习器两部分组成,采样器在内存中贪婪地存储样本并平衡类别,学习器在推理时使用内存中的样本从头开始训练模型。Lee 等人(2024)以贪婪的方式存储跨所有训练任务的类别和组的平衡数据,并使用这些平衡数据重新训练神经网络的最后一层。

2. 1. 6 高效利用记忆

在基础的重放方法中,存储合适的样本对效果带来了直接的影响。另一方面,对存储样本的有效重放同样对效果有较大影响。部分研究者在重放的基础上探究如何更加有效地利用存储的有限样本,在重放的过程中提升重放效果。

1)数据增强。可以通过直接对重放数据增强获得更多多样性的重放数据,提升重放效果。例如,RAR(repeated augmented rehearsal)(Zhang 等,2022)让重放结合数据增强,通过多次迭代使用来自记忆和当前数据流的样本进行训练,同时应用随机变换增强记忆样本的表征。Seo 等人(2024)利用神经塌陷现象提高学习模型对数据流的适应性,提出利用负转换的数据增强方法生成不同于原始数据的增强数据,从而缓解新旧类别特征之间的偏差问题。

2)知识蒸馏。另一种常用的重放强化方法是在重放过程中结合知识蒸馏。在持续学习中,知识蒸馏可通过保留旧任务的知识避免灾难性遗忘。当模型在学习新任务时,通过蒸馏技术将之前任务的知识迁移到当前模型中,即可以兼顾学习新知识和保留旧知识。iCaRL(incremental classifier and representation learning)(Rebuffi 等,2017)利用存储的样本直接构建蒸馏损失以抑制灾难性遗忘。He 等人(2020)提出使用修改后的交叉蒸馏损失和两步学习

技术解决在线持续学习中的灾难性遗忘问题。HAL (hindsight anchor learning) (Chaudhry 等, 2021) 通过在重放的基础上增加一种锚定目标, 并采用双层优化进行训练, 其中内层优化用于最小化当前小批量数据的损失, 外层优化用于保持所有锚点的预测不变。SS-IL (separated softmax for incremental learning) (Ahn 等, 2021) 提出一种分离式 softmax 方法, 该方法构建分离的 softmax 输出层和任务式知识蒸馏, 以解决由于数据不平衡导致的分类分数偏差问题。Boschini 等人 (2023) 改进了 DER 的知识蒸馏, 通过引入未来准备策略, 使模型更好地适应未来的任务, 处理新发现的类与旧类之间的表征的相似性, 从而引导学生获得更丰富的次级信息。尽管知识蒸馏可以有效地为当前训练带来更丰富的历史特征信息, 缓解灾难性遗忘, 但蒸馏过程中知识仍可能丢失, 导致当前模型性能下降, 任务间的知识冲突可能导致模型难以平衡新旧任务的表现。此外, 受历史模型的质量影响较大, 训练过程也会增加额外计算开销。

3) 贝叶斯方法。在持续学习中, 贝叶斯方法可以通过将过去学到的知识作为先验, 不断更新模型对新任务的认知, 避免灾难性遗忘。VCL (variational continual learning) (Nguyen 等, 2018) 将持续学习过程表示为后验分布传递的过程, 并提出变分持续学习的思想, 利用存储的旧样本对当前参数分布进行变分推断。KCL (kernel continual learning) (Derakhshani 等, 2021) 通过变分推断问题的形式, 将随机傅立叶基作为潜在变量, 并从每个任务的重放存储中推断出变分后验分布。SNCL (sparse neural network for continual learning) (Yan 等, 2022) 通过引入变分贝叶斯稀疏性先验学习稀疏网络, 并提出通过存储和重放旧样本的中间层特征增强对稀疏神经元的监督, 如图 7 所示。然而, 贝叶斯方法计算复杂度较高, 特别是在高维空间或大规模数据情况下, 求解后验分布较为耗时, 可能导致模型对新任务的适应能力减弱, 限制其在复杂任务中的应用。

4) 优化与梯度投影。在记忆重放方法中, 存储的历史知识重放和当前数据的训练都会通过各自的损失函数获得梯度。一些研究者认为不同任务存在梯度冲突, 从而导致无法获得较好的模型更新, 难以抑制历史知识的遗忘, 且新知识的学习也受到影响。为此, 这类方法通过操控模型的训练梯度, 将梯度投




图7 变分贝叶斯稀疏网络的重放训练(Yan 等, 2022)

Fig. 7 Replay training in variational Bayesian sparse model
(Yan et al., 2022)

影到影响任一任务的更新。GEM (gradient episodic memory) (Lopez-Paz 和 Ranzato, 2017) 通过情景记忆存储部分过去任务的数据, 并在新任务训练时, 构建二次规划问题约束优化方向, 以减轻遗忘并促进知识的正向迁移。Chaudhry 等人 (2019) 提出 GEM 算法的效率版本 A-GEM (averaged gradient episodic memory), 将原本每个旧任务各自有一个梯度转化为只计算所有旧任务平均梯度。MER (meta-experience replay) (Riemer 等, 2019) 在存储样本上设计了一种基于优化的元学习方法, 目的是在知识转移和干扰之间找到权衡。此外, 还有部分学者选择更新存储样本本身, 即将存储的记忆参数化, 并在训练的过程中进行更新, 直至优化获得最优的记忆参数。该参数充当原始样本在后续的训练中进行重放。例如, Mnemonics (Liu 等, 2020b) 通过参数化存储样本并以端到端的方式进行优化, 使用双层优化程序交替优化模型和样本, 以解决灾难性遗忘问题。GMED (gradient-based memory editing) (Jin 等, 2021) 提出利用损失差异指导梯度对样本实施像素级更新。

5) 表征对齐与偏差校正。记忆重放过程中, 由于历史知识存储的数据量远小于当前任务训练的数据量, 这在训练过程中导致了严重的不平衡, 表现为历史知识在特征空间中产生一定的漂移。为解决该漂移问题, 一些学者研究如何在重放过程中实现历史知识的表征对齐。BiC (bias correction) (Wu 等, 2019) 验证了持续学习的分类器有严重的偏见, 并提出利用存储的验证集进行可训练的偏差校正。MDMT-R (multi-domain multi-task replay) (Lyu 等,

2021)提出一种跨任务的两级边距损失,通过控制任务间、类间的分类间隔提升模型的表征能力。Co2l (contrastive continual learning)(Cha等,2021)提出一种通过非对称监督对比损失学习任务表征,通过实例关系蒸馏来保存学习到的表征,以在持续学习场景中学习和维护可迁移的表示。ER-ACE(experience replay with asymmetric cross-entropy)(Caccia等,2022)通过不对称的更新规则减轻由于重放导致的新旧类表征重叠问题,使得新类别适应旧类别。PCR(proxy-based contrastive replay)(Lin等,2023)提出结合对比学习和代理学习的持续学习方法,提升了任务的表征能力。

2.2 基于正则化的方法

在持续学习中,记忆重放法通过保留旧任务的数据或生成伪样本等保留了过去知识,并与新任务数据一起训练,虽然能有效减少遗忘,但需要额外的存储空间和计算资源管理数据集,可能会导致隐私泄漏等问题。考虑到在一些持续学习场景中,不提供额外存储,或不允许存储额外数据,记忆重放法难以发挥作用。正则化方法通过添加额外的约束,鼓励模型保留之前学到的知识,通常利用参数的重要性加权减少对旧任务的遗忘。其优势在于不需存储原始数据,只需对模型参数进行调整,因此更节省内存且适合隐私敏感的场景。

在持续学习过程中,参数正则化方法的前提是认为模型是高度过参数化的。模型中对已学任务重要的参数不应被大幅度更新。通过限制这些关键参数的更新,可以有效缓解灾难性遗忘的现象。经典的关键参数的重要性估计通常将这些参数的重要性后验概率近似为一个高斯分布。该分布的均值由之前任务的参数决定,表示模型在旧任务中学到的最优参数。具体而言,假设有两个独立的数据集 D_A 和 D_B ,且有 $D = D_A \cup D_B$,根据监督学习的定义,模型的学习过程可视为求解后验分布 $p(\theta|D)$ 的过程。根据贝叶斯公式,该后验分布可以分解为对不同任务的条件概率,从而体现出模型对新旧任务的兼顾。具体为

$$\log p(\theta|D) = \log p(D_B|\theta) + \log p(\theta|D_A) - \log p(D_B) \quad (2)$$

在持续学习中,假设模型首先学习任务 A ,接着学习任务 B ,此时可以认为 $p(\theta|D_A)$ 是对任务 A 已

经学习到的后验概率。在进行新任务 B 的学习时,为最大化后验概率,上述问题可以转化为以下优化问题,即

$$\theta^* = \arg \max_{\theta} \log p(\theta|D) = \arg \min_{\theta} L_B(\theta) - \log p(\theta|D_A) \quad (3)$$

式中, $\log p(D_B|\theta)$ 表示参数 θ 对数据集 D_B 的条件概率,这实际上是 $L_B(\theta)$ 的相反数。因此,最大化后验概率等价于最小化 $L_B(\theta)$,即模型对新任务 B 的学习可以通过最小化损失函数来实现。而 $\log p(\theta|D_A)$ 则对应任务 A 训练后得到的参数分布,它反映了任务 A 对模型的约束和先验知识。

然而,在持续学习场景下,当模型开始训练任务 B 时,数据集 D_A 已不可见,这意味着模型无法直接获取 $\log p(\theta|D_A)$ 所包含的后验信息。如图8所示,这种情况导致了灾难性遗忘,即模型在训练新任务 B 时,可能会过度更新与任务 A 相关的参数,从而丢失之前学到的知识。为了缓解这一问题,参数正则化方法通过将任务 A 的后验信息近似保留为正则化项限制参数的更新。这类方法可以分为基于拉普拉斯近似、基于任务表示约束、基于贝叶斯正则以及基于知识蒸馏。接下来将对这几类方法进行介绍。




图8 正则化持续学习方法原理

Fig. 8 Principle of regularization-based continual learning

2.2.1 拉普拉斯近似

拉普拉斯近似技术将任务 A 的后验分布近似为一个高斯分布,从而对旧任务的重要参数施加约束。这种正则化方法通过在损失函数中加入对旧任务参数变化的惩罚项,在训练新任务时抑制与先前任务相关的参数过度更新,从而实现对新旧任务的平衡学习,降低灾难性遗忘的风险。EWC(elastic weight consolidation)(Kirkpatrick等,2017)直接利用了拉普拉斯近似算法近似之前任务后验 $\log p(\theta|D_A)$,该计算方法可以将问题转换为一个二

次正则问题,即

$$\theta^* = \arg \min_{\theta} L_B(\theta) - \frac{1}{2}(\theta - \theta_A^*)^2 f''(\theta_A^*) \quad (4)$$

EWC利用费雪信息矩阵估算参数的海森矩阵,代表了每个参数对旧任务的重要程度。在EWC基础上,SI(synaptic intelligence)(Zenke等,2017)采用了类似的想法,考虑损失函数变化的影响,认为函数变化可以表示为梯度的作用和。MAS(memory aware synapses)(Aljundi等,2018)通过对模型参数增加扰动近似计算参数重要性,同样定义了模型参数的重要性可以通过费雪矩阵对角的和来表示。RWalk(riemannian walk)(Chaudhry等,2018)基于黎曼流形,通过在模型的参数空间中进行随机漫步更新模型参数。在每次漫步中,模型会根据当前的参数值和训练数据计算出一个新的参数值,然后将其更新到模型中。NCCL(neuron calibration for continual learning)(Yin等,2021)提出一种基于神经元校准的方法缓解遗忘,将深度神经网络中的神经元建模为可校准的单元,并提出一种训练校准模型的学习框架。CPR(classifier-projection regularization)(Cha等,2020)通过在现有拉普拉斯近似正则化的持续学习方法中添加一个额外的正则化项,最大化分类器输出概率的熵,以促进宽局部最小值的出现,从而提高持续学习方法的性能。EFC(elastic feature consolidation)(Magistri等,2024)提出一种名为弹性特征巩固方法,通过引入经验特征矩阵来正则特征空间中与先前学习任务最相关方向的变化,并使用不对称原型重放损失平衡新任务数据和高斯原型,同时利用正则化指导分类器漂移补偿和更新原型,从而更好地学习新任务并减少遗忘。

2.2.2 任务表示约束

采用拉普拉斯近似方法构建二次正则项的难点在于如何估算参数重要性,这些方法通常伴随着较高的计算量。此外,一些学者并不采用拉普拉斯近似的二次正则项形式,而研究采用基于任务表示的正则化方法近似保留之前任务的后验信息。MER(meta-experience replay)(Riemer等,2019)结合演练法和元学习寻找模型中容易与不易被新任务梯度改变的参数。如图9所示,MUC(multi-classifier)(Liu等,2020a)整合多个辅助分类器以估计更有效的正则化约束,通过训练分类器差异损失增强了多分类器在处理分布外数据时的预测不一致性,同时在处

理分布内数据时保持一致性,使得辅助分类器能够为正则化之前学习的任务提供互补和鲁棒的信息。PCL(per-class continual learning)(Hu等,2021)在单类的类增量持续学习中,引入了一种整体正则化方法H-reg,使学习算法能够全面考虑每个类的特征。该方法通过参数传递进行初始化,确保不同模型的参数在相同的参数空间中,从而具有可比性。Inter-ContiNet(interval continual learning)(Wołczyk等,2022)通过在神经网络参数空间上施加区间约束控制遗忘。该方法将每个任务表示为参数空间中的超矩形,并确保新任务的超矩形被包含在之前任务的超矩形内,从而为模型的遗忘提供了界限。AdaB2N(adaptive balance of batch normalization)(Lyu等,2023)指出现有批归一化层(batch normalization, BN)在处理连续任务时存在近期偏差,并提出一种自适应平衡策略优化BN统计量,以提高模型在连续学习任务中的性能。




图9 多分类器正则化(Liu等,2020a)

Fig. 9 Multi-classifier continual learning(Liu et al., 2020a)

2.2.3 贝叶斯正则

贝叶斯正则方法的核心思想是利用贝叶斯框架更新模型参数,以便在学习新任务时保留先前任务的知识。贝叶斯正则方法通过在贝叶斯框架下正则化模型参数,有效地平衡了新旧任务的学习,以减少灾难性遗忘。OSLA(online structured laplace approximations)(Ritter等,2018)提出一种贝叶斯在线持续学习框架,递归地近似后验分布,以更新每个新任务的二次惩罚项,从而有效减少了灾难性遗忘。S-FSVI(sequential function-space variational inference)(Rudner等,2022)将持续学习视为顺序贝叶斯推断问题,通过顺序函数空间变分推断来解决在数据流中学习时的灾难性遗忘问题。该方法允许在训练过程中参数的广泛变化,同时通过更灵活的变分分布和更有效的正则化来适应新任务。TriRE(retain, revise & rewind)(Vijayan等,2023)受神经科

学启发,通过结合多种神经生理过程减少任务间的干扰,设计了3个阶段控制神经元保留、更新和主动遗忘。贝叶斯正则方法虽然在统计理论上具有坚实基础,但通常伴随着较高的计算成本和实现复杂性,需要精心调整超参数以实现最佳性能。

2.2.4 知识蒸馏

与记忆重放法中的知识蒸馏不同,基于知识蒸馏正则化法并不额外存储重放记忆,而选择利用存储的历史模型作为教师,并利用当前训练样本作为输入。在新任务训练的时候,用当前任务的样本输入历史模型获得伪标签,从而获得对过去知识的保持能力。采用该方法的知识蒸馏策略可以被视为是正则化的一种。LwF(learning without forgetting)(Li和Hoiem,2018)提出学习新的训练样本时,同时使用旧任务输出头的预测来计算蒸馏损失。LwM(learning without memorizing)(Dhar等,2019)提出注意蒸馏损失,并证明在添加新类时,惩罚分类器注意力图的变化有助于保留基类的信息。Zhao等人(2020)使用知识蒸馏维持旧类别内的区分度,提出权重对齐来纠正在全连接层中新类别的偏差权重。权重对齐通过将新类别的权重向量范数与旧类别对齐,确保模型对新旧类别公平分类。PODNet(pooled outputs distillation network)(Douillard等,2020)通过池化输出蒸馏损失约束模型的表征演化,从而减少对旧类别的遗忘。Lee等人(2021)在教师-学生框架中通过控制教师之间的相似性研究任务相似性对持续学习的影响,并在均值场极限下,通过控制教师的特征和读出相似性研究任务相似性对持续学习的影响。如图10所示,GeoDL(Simon等,2021)通过构建低维流形来嵌入旧模型和当前模型的特征,利用测地线流捕捉任务间的平滑变化,使特征沿测地线流投影并最小化响应间的差异。

2.3 基于动态结构的方法

由上述介绍可知,记忆重放法依赖存储旧任务的数据或生成旧任务的知识,存储和计算成本较高。正则法通过在损失函数中添加正则项,限制模型参数的更新幅度,却依赖正则项的选择和权衡,难以处理任务差异较大的情况。持续学习本质上是一种序列式的多任务学习,不同任务按照一定顺序学习,但评估却需要同时衡量多任务效果。因为任务知识存储于模型参数中,一种简单的方法是让不同任务的知识储存于不同的参数,这样可以最大程度避免新




图10 利用测地线流来捕捉任务间的平滑变化
(Simon等,2021)

Fig. 10 Capture smooth changes between tasks using geodesic path(Simon et al. , 2021)

任务的训练对旧任务的覆盖,从而造成灾难性遗忘。在此基础上,动态结构法通过逐步调整模型的结构来应对新任务和知识,根据输入数据的变化和新任务的需求,动态调整神经网络的架构或参数,添加或重新分配网络资源,以便学习新知识而不遗忘旧知识。动态结构法通过自动扩展网络、激活重要参数、冻结不相关的部分,确保模型能够适应新任务,同时避免灾难性遗忘,从而实现持续学习。

2.3.1 多专家与子网络结构

一些方法在构建模型时设计分块多专家模型,通过构建和管理一个由专家子模块组成的网络来适应连续到来的学习任务,这些专家子模块能够被动态地添加、调整或重用,以适应新的任务需求,同时尽可能地保留之前学习任务的记忆。这类方法的优势在于其灵活性和适应性,能够根据任务的变化灵活调整模型结构,减少对旧任务的遗忘,并且通过模块化设计提高计算资源的利用效率。Expert Gate(Aljundi等,2017)通过专家网络和门控自动编码器,在不存储先前数据的情况下处理新任务,自动选择相关先验任务辅助学习新任务,并在测试时选择合适模型。如图11所示,SEED(selection of experts for ensemble diversification)(Rypešć等,2024)在每个任务中只选择一个最优的专家进行更新,以减少遗忘并鼓励专家之间的多样性,同时引入了基于多变量高斯分布的专家选择方法,用于限制选定专家的表现型漂移。PICLE(probabilistic, library-based continual learning)(Valkov等,2024)构建了模块化的持续学习框架,通过概率模型评估不同模块组合的适

应度,以实现感知、少样本和潜在的迁移学习。MOSE(multi-level online sequential experts)(Yan等,2024)集成多级监督和反向自蒸馏,构建堆叠的子专家,通过在不同网络层级注入监督信号,利用反向自蒸馏在模型内部转移知识,从较浅的专家到最终的预测器,整合不同专家的知识。




图 11 多专家结构协同预测(Rypešć等,2024)

Fig. 11 Co-predict using multi-expert structure
(Rypešć et al., 2024)

类似地,一些方法构建专用的子网络来适应新任务级保留对旧任务的记忆。与多专家结构不同的是,这类方法会将已有的复杂网络分割,将完整模型划分为多个子网络或模块,每个子网络负责处理特定的任务或任务集合以减轻新旧任务之间的干扰,从而降低灾难性遗忘的风险。这类方法的优势在于它们能够在原本模型结构的基础上,不牺牲先前学习任务性能来整合新任务,使得模型能够持续适应新的数据分布。CTrL(continual transfer learning)(Veniat等,2021)提出一种新的模块化神经网络架构和基于任务驱动的先验学习算法,该算法通过组合模块来解决任务,并通过数据驱动的先验来高效选择模块。WSN(winning subnetwork)(Kang等,2022)受彩票假设启发,认为在密集网络内存在竞争性的子网络,通过顺序学习并为每个任务选择最优子网络,同时尝试通过重用先前子网络的权重激活一小组权重。MIND(multi-task incremental network distillation)(Bonato等,2024)通过参数隔离技术将网络划分为多个子网络,每个子网络负责学习一个特定任务。MIND利用知识蒸馏机制,将每个新任务训练的新模型中的知识蒸馏到对应的子网络片段中,以此保留先前任务的知识。NICE(neurogenesis inspired contextual encoding)(Gurbuz等,2024)从海马体的神经发生中汲取灵感,通过将深度神经网络

中的神经元按照不同的成熟阶段进行分组,并在测试阶段无需额外信号即可推断出应使用哪些神经元。

尽管构建多个不重叠的专家或子网络能够减轻新旧任务之间的干扰,从而降低灾难性遗忘的风险,但多专家或多子网络间的知识互通存在挑战。此外,这类设计可能需要更复杂的网络管理和额外的计算资源来维护多个子网络,在网络结构调整和优化时可能面临较大挑战。

2.3.2 动态稀疏化掩膜方法

一些方法采用构建动态掩膜的方式进行不同任务的学习,这样可以在拥有同样模型的基础上,动态调整掩膜的分布,从而减少不同任务的知识干扰。Piggyback(Mallya等,2018)通过学习二进制掩码来选择性地屏蔽固定权重的基础网络,从而提高新任务的性能。Abati等人(2020)为每个卷积层配备了任务特定的门控模块,这些模块可以基于给定输入选择应用哪些过滤器,通过门控的执行模式识别和保护重要的过滤器,确保之前学习任务的模型性能不损失。CCLL(calibrating convolutional neural network for lifelong learning)(Singh等,2020)通过很少的校准参数对卷积神经网络(convolutional neural network, CNN)生成的激活图进行校准,使其与新任务相关。通过空间和通道校准模块对每个网络层产生的激活图进行校准,并仅对这些校准参数进行训练。CAT(continual learning with forgetting avoidance and knowledge transfer)(Ke等,2020)认为当任务相似且存在共享知识,因此构建了一个知识库来保存到目前为止所有任务学到的知识,并且所有任务都共享这个知识库,自动识别新任务与之前任务的相似性,对相似任务使用知识转移注意力选择性转移知识以学习新任务并实现反向知识转移,对不相似任务使用任务掩码防止遗忘。如图12所示,MEAT(meta-attention)(Xue等,2022)利用ViT(vision transformer)的架构特性,通过在多头自注意力模块中引入元注意力机制,动态地为新任务生成任务特定的自注意力模式。SPG(soft-masking of parameter-level gradient flow)(Konishi等,2023)通过在训练中基于每个参数对旧任务的重要性来软遮罩参数更新,允许每个任务使用完整的网络,而不是让每个任务独占网络的一部分,从而实现最大的知识迁移并减少容量使用。




图 12 ViT 结构中动态生成任务特定注意力(Xue 等,2022)
Fig. 12 Adaptive generate task-specific attention in ViT structure(Xue et al. , 2022)

另一种与动态掩膜相近的方法是构建参数路径,与直接构建动态掩膜方法不同的是,这类方法会从模型的前传反传角度设计模型稀疏化信息传递的方式,并避免路径重叠带来的知识混淆。Kumar 等人(2021)提出一种基于贝叶斯结构适应的持续学习框架,将结构学习能力融入到在线贝叶斯的简单而有效的框架中,通过学习每个任务的深度结构,支持任务间的转移,并在有监督和无监督的设置下都具有良好表现。NISPA(neuro-inspired stability- plasticity adaptation)(Gurbuz 和 Dovrolis, 2022)受神经科学启发,通过在稀疏网络中形成稳定路径来保留旧任务的知识,并利用连接重构来创建新的可塑路径以适应新任务。在每个任务训练过程中,NISPA 会周期性地选择候选稳定单元,并通过连接重构来创建新的路径。稳定单元的选择基于激活值的总和,而连接重构包括断开和生长连接,以减少不同任务间的干扰并促进知识迁移。

此外,还有一些方法直接从稀疏学习的角度学习如何对模型稀疏化,这类方法通常利用新旧任务之间同时存在共享和特有知识,并在此指导下控制模型的稀疏度和稀疏分布。SDMLP(sparse distributed multi-layer perception)(Bricken 等, 2023)基于稀疏分布式记忆的概念,提出一种改进的多层感知机模型,通过模仿生物学中的神经回路,引入了新的训练稀疏网络的方法。FPF(forgetting prioritized fine-tuning)(Zhao 等, 2023)发现神经网络在持续学习过程中只有少数参数模块对任务变化敏感,而大多数

参数可以跨任务共享。基于这一发现,通过微调敏感参数,有效减少了计算开销。

2.3.3 动态结构调整

一些学者设计了动态结构调整方法,该类方法认为持续学习中的骨干模型可以随着持续学习的过程发生改变,从结构构造方面减少新旧任务的冲突,抑制灾难性遗忘。动态结构调整方法主要包括模型扩展、模型剪枝以及神经结构搜索。其中,扩展方法通过引入可动态扩展的模型结构,缓解灾难性遗忘,适应不同任务;剪枝方法能去除冗余结构,提高模型效率;神经结构搜索则自动搜索最优的网络结构,提升模型性能。

模型扩展方法通过动态调整或扩展模型的结构来适应新的数据或任务。这通常包括引入新的特征、增加模型的节点或层次,或通过自适应算法根据性能变化调整模型的复杂度,确保模型能够持续捕捉数据中的模式和变化。这种方法的优势在于其灵活性和适应性,能够随着数据的不断更新调整模型,从而提高模型的鲁棒性和泛化能力,特别是在处理复杂和多变的任务时表现突出。DEN(dynamically expandable network)(Yoon 等, 2018)在每个任务到达时,仅使用必要数量的单元动态扩展网络容量,并通过单元拆分/复制和时间戳来有效防止语义漂移。Ostapenko 等人(2019)引入了具有神经可塑性的动态生成记忆框架,通过学习稀疏注意力掩码实现连接可塑性,并提出一种自适应网络扩展机制,以促进资源高效的持续学习。Model Zoo(Ramesh 和 Chaudhari, 2022)受到集成学习启发,将学习容量分散到多个模型上,在每个学习阶段添加一个新的多任务模型,该模型针对当前任务和一些过去的任务进行训练。在推理时,Model Zoo 通过选择在以往阶段表现不佳的任务进行重新训练,从而最大化从当前任务中学习到的信息。BEEF(bi-compatible energy-based expansion and fusion)(Wang 等, 2023a)通过能量基的扩展和融合框架,独立地训练各个模块,并在最终分类器中实现双向兼容性,显著提高了模型在普通和具有挑战性的增量学习环境中的性能。如图 13 所示,Zhu 等人(2022)提出一种自我维持的表示扩展方案,通过动态结构重组策略实现了循环扩展优化,得到结构不变的表示,通过组合使用保留的不变知识和新的监督减少相似类之间的特征混淆。尽管模型扩展方法通过引入可动态扩展的模型结构及扩

展审核机制能够缓解灾难性遗忘、适应不同任务,但也可能导致计算复杂度的显著增加,并且频繁的结构调整可能引发过拟合问题,影响模型的泛化性能,特别是在数据量大或模型复杂度提升过快的情况下。




图13 自我保持的结构扩展方法(Zhu等,2022)

Fig. 13 Self-sustaining structural expansion(Zhu et al. ,2022)

动态结构法中的模型剪枝方法是一种通过减少模型的复杂度提高学习效率的策略。随着新的数据不断进入,剪枝方法动态地移除模型中冗余或不再重要的节点和连接,以防止模型在持续学习过程中变得过于复杂,同时保持对新数据的适应性。Pack-Net(Mallya和Lazebnik,2018)通过迭代剪枝和微调不重要的权重学习新任务,但会产生二进制参数使用掩码,且性能会随着任务的增加而下降。UCB(uncertainty-guided continual learning with Bayesian neural networks)(Ebrahimi等,2020a)利用贝叶斯神经网络中的权重概率分布的不确定性指导学习过程,根据参数的不确定性动态调整学习率,使不确定的参数在学习新任务时可以更自由地更新,使用不确定性进行权重剪枝,并在剪枝后通过保存每个任务的二进制掩码来保持任务性能。DER(dynamically expandable representation)(Yan等,2021)通过新的特征提取器增加特征维度并利用辅助损失学习新类,同时基于通道级掩码的剪枝策略动态扩展表示,并使用平衡微调方法重新训练分类器。在持续学习场景中,剪枝方法可以有效控制模型的复杂度,防止随着时间和数据积累模型变得过于臃肿,从而降低计算和存储需求。剪枝还能减少模型过拟合,提高对新数据的泛化能力,使模型在不断变化的环境中保持高效运行。然而,剪枝可能会移除一些对

未来数据或任务有用的特征,从而影响模型对后续学习任务的适应性。

神经结构搜索(neural architecture search, NAS)是一种自动化调整神经网络结构的技术,旨在随着新数据的出现优化模型架构。它通过搜索算法动态选择最优的网络结构,使模型能够适应不同任务或数据分布的变化。在持续学习中随着任务的学习,神经结构搜索方法使用搜索算法动态探索不同的神经网络架构,选择最优结构处理新任务或数据。L2G(learn to grow)(Li等,2019)通过架构搜索来寻找每个顺序任务的最佳结构,并考虑了共享先前层的参数、引入新参数等选项,并引入了正则化项来优化模型结构和参数,以避免模型大小无限制增长。H2(helpful or harmful)(Jin和Kim,2022)将遗忘问题重新定义为任务关联问题,考虑结构分配策略中的任务干扰,并提出一种基于模型搜索的方法,以区分对旧任务有益和有害的信息,通过训练—剪枝—再训练的学习范式,使得特征提取器包含与任务相对应的不相交参数集,通过模型搜索框架和敏感度度量,发现对新任务损失敏感的关键参数,利用这些知识学习新任务。PGMA(parameter generation and model adaptation)(Hu等,2019)通过学习构建含共享参数和动态生成参数的模型,利用数据生成器生成重放数据约束训练,在测试时为实例动态生成参数,以解决顺序学习中的灾难性遗忘问题。神经结构搜索方法在持续学习中具有强大的自适应能力,能够根据数据的动态变化自动选择合适的网络结构,避免了手动调整的复杂性。它提高了模型在处理多样化任务时的表现,并能够在不同的环境下保持高效运作。尽管如此,神经结构搜索主要缺点是计算资源消耗巨大,因为搜索不同的结构需要大量的训练和评估。此外,自动生成的网络结构可能会过于复杂,不易解释或优化,特别是在处理高度动态或不稳定的数据时,搜索过程可能会过于频繁。

2.3.4 学习额外任务相关模块

上述动态结构方法核心在于将原本模型变得动态,例如采用子模块、动态结构搜索等方式。然而,在许多实际场景中,对原始模型的结构做出动态修改将带来大量的运算量,且要动态修改训练策略。因此,一些学者研究在不改变原始模型的基础上,额外增加任务相关可训练模块。该方法与上述可训练的重放记忆不同,不是基于数据做重放。ACL

(adversarial continual learning)(Ebrahimi 等, 2020b) 通过将任务特定和任务不变特征分解为不同的潜在空间表示, 结合架构增长和经验回放来避免遗忘, 同时使用对抗学习和正交性约束优化模型, 提高性能。AANets(adaptive aggregation networks)(Liu 等, 2021) 通过在每个残差级别构建两种类型的残块——稳定块和可塑性块, 来平衡学习旧类别和新类别的稳定性和可塑性, 并通过自适应聚合权重平衡二者, 采用双层优化程序更新网络参数和聚合权重, 以此缓解稳定性—可塑性困境。IRU (incremental rank updates)(Hyder 等, 2022) 将每层的网络权重表示为几个低秩矩阵的线性组合。为了更新新任务的网络, 冻结从先前任务学到的低秩因子, 为每层添加一个新的可训练的低秩因子, 并使用可学习的选取器权重将新旧因子结合起来。如图 14 所示, DyTox (dynamic token expansion)(Douillard 等, 2022) 使用共享的编码器层和解码器层, 并通过为每个任务学习特定的“任务标记”生成任务特定的嵌入。这种方法仅在每个任务中添加一个低维向量, 几乎不增加内存开销。




图 14 ViT 中构建动态 Token 扩展(Douillard 等, 2022)

Fig. 14 Dynamic token expansion in ViT
(Douillard et al. , 2022)

2.4 方法小结

在传统持续训练方法中, 记忆重放法、正则化法和动态结构法是 3 种主要的方法。其中, 记忆重放法通过重温旧知识防止遗忘, 优点是简单直观, 能有效保留历史信息, 但缺点是可能导致对新知识的遗忘。正则化法通过引入正则项平衡新旧知识, 优点在于可以控制模型复杂度, 减少过拟合, 但可能会限制模型的学习能力。动态结构法则根据学习过程动态调整网络结构, 优点是能够灵活适应新任务, 但实现复杂且计算开销较大。这 3 种方法各有优势和劣势, 适用于不同的应用场景和需求。

随着持续学习研究的深入, 预训练模型逐渐成为一种重要的方法。预训练模型通过在大规模数据集上进行初步训练, 然后在特定任务上进行微调, 能够有效利用已有知识。这种方法不仅提高了模型的泛化能力, 还减轻了对大量标注数据的依赖。与传统持续训练方法相比, 预训练模型能够更好地应对知识的转移和积累问题, 尤其在面对多样化的任务时, 表现出更强的适应性。接下来, 将探讨预训练模型在持续学习中的应用及其优势。

3 基于预训练模型的方法

预训练模型(PTM)(张浩宇 等, 2022a) 是一类在大规模数据集上预先训练好的深度学习模型, 能够捕捉丰富的特征表示, 并在多种下游任务中展现出卓越的性能。随着深度学习的发展, 预训练模型已经成为自然语言处理、计算机视觉等领域的基石。近年来, 预训练模型的研究进展迅速, 从最初的语言模型如 BERT (bidirectional encoder representations from transformers), 到视觉领域的 Transformer 架构, 如 ViT, 再到多模态模型如 DALL-E 和 CLIP (contrastive language-image pretraining), 这些模型不断推动着人工智能的边界。研究者们还在探索如何使这些模型适应持续学习的设置, 即在不断接收新信息的同时, 减少对先前知识的遗忘, 这一领域的研究正在成为预训练模型应用的新前沿。

3.1 基于微调的方法

基于预训练模型的微调方法(fine-tuning) 是一种在预训练模型的基础上, 通过在特定任务或数据集上进行进一步训练来适应特定需求的技术。持续学习要求模型在面对新任务时能够在不遗忘旧任务的情况下适应新任务, 而微调通过在大规模通用数据中预训练的模型基础上进行进一步训练, 使其适应特定任务。具体而言, 通常会为预训练模型添加新任务相关的输出层, 并使用目标任务数据集进行小学习率的微调训练, 以提升模型在新任务上的表现。其优点在于能够高效利用预训练模型所学的知识, 减少从头训练的资源消耗, 且只需较少的特定数据。DLCFT (deep linear continual fine-tuning)(Shon 等, 2022) 通过利用预训练神经网络的线性化技术, 结合均方误差损失函数, 显著提升了参数正则化方法在持续学习中的有效性。这种方法不仅解决了传

统参数正则化方法在处理高维非线性神经网络时的挑战,而且还提供了一个理论框架,解释了为什么现有的基于Hessian的参数正则化方法在与交叉熵损失训练的神经网络中表现不佳。TwF(transfer without forgetting)(Boschini等,2022)通过维持一个固定的预训练模型副本,并使用基于知识蒸馏的层级损失项,连续地将源域中的知识传递给目标任务,从而解决了在持续学习过程中预训练知识被快速遗忘的问题。ConTraCon(continual transformer with convolutions)(Roy等,2023)基于Transformer架构,通过对多头自注意力层的Key、Query和Value进行重加权,使用卷积操作来适应新任务,从而使得每个新任务仅使用较少参数。FSA(first session adaptation)(Panos等,2023)提出仅在首次训练中适应预训练的神经网络主体,并在后续会话中固定它,然后面向新任务新增基于线性判别分析的输出头进行精确更新。SLCA(slow learner with classifier alignment)(Zhang等,2023a)通过降低表示层的学习率减缓过拟合问题,并引入了一种分类器对齐策略,通过模拟类别分布并调整分类层改善模型对新任务的适应性,同时保持对旧任务的记忆。TMC(tangent model composition)(Liu和Soatto,2023)通过在线性化预训练模型周围的切空间中独立微调的组件模型来实现,这些组件模型可以被添加、缩放或相减,以支持增量学习、集成或遗忘。在推理时,通过标量组合来组合这些模型,从而将集成的成本降低到单个模型的水平。Lee等人(2023)探讨了预训练模型在持续学习中的效果,发现并非所有持续学习算法都能平等地从预训练中受益,并提出一个简单的但有效的基线方法,该方法结合了最少正则化的记忆重放算法、ImageNet预训练的ResNet(residual network)模型,以及一个包含在线训练和离线训练两个阶段的训练流程,结果表明在开发和评估持续学习算法时,应考虑从预训练模型开始。如图15所示,Tan等人(2024)基于预训练模型增量地调整共享适配器和局部分类器,采用了从存储的原型中进行特征采样,并重新训练统一分类器的方法,可通过该方法估算旧任务原型的语义偏移,所提出的方法避免了模型扩展,并减少了对图像样本的依赖。TAIL(Liu等,2024b)旨在解决大型预训练模型在应用中数据稀缺和计算挑战问题,通过引入轻量级的适配器模块到预训练的决策模型中,并在持续模仿学习环境中比

较不同的高效适应技术,利用低秩适配器实现对新任务的快速适应,同时避免灾难性遗忘并保持持续学习中的适应性。然而,在持续学习场景中,微调方法也存在一些缺点,如可能会导致模型在新任务上过拟合,从而遗忘旧任务,且仍需较高的计算资源和超参数调节的精确性。因此,在持续学习任务中,微调往往需结合其他机制来减轻遗忘效应。




图15 预训练ViT中的动态适配器微调
(Tan等,2024)

Fig. 15 Dynamic adapter tuning in pretrained ViT
(Tan et al., 2024)

3.2 基于提示的方法

基于提示的方法通过在预训练模型中引入轻量级的可训练模块,即“提示”,来调整模型以适应新任务,而无需对整个模型进行大规模的微调。主要方式为在模型输入中添加提示,这些提示可以是学习到的参数或基于任务的元信息,目的是引导模型提取与新任务相关的特征表示。该方法能够以较小的计算成本实现模型的快速适应,同时保持预训练模型的通用特征提取能力。

一些方法直接通过维护一个提示集合应对新任务,从而减少对先前任务的遗忘。这类做法是在训练时为每个新任务生成或选择一个提示,并将这些提示存储在池中。在推理时,模型会使用这些提示处理新的输入实例,使得每个任务都有其专属的提示来辅助模型回忆和适应。如图16所示,L2P

(learning to prompt)(Wang 等, 2022e)基于预训练模型通过学习一个提示池存储持续学习中的新知识。具体来说,L2P将提示存储在一个键值共享的内存空间中,通过查询机制根据输入特征动态查找相关提示,这些提示被添加到输入嵌入中,指导预训练模型解决相应任务。DualPrompt(Wang 等, 2022d)在L2P的基础上通过学习两组不相交的提示空间G-Prompt和E-Prompt指导预训练模型学习任务,从而避免灾难性遗忘。具体来说,G-Prompt用于编码任务不变的指令,E-Prompt用于编码特定于任务的指令。在训练过程中,通过将G-Prompt和E-Prompt附加到预训练模型的不同位置,并使用一种可配置的提示函数将它们与嵌入特征相结合,从而使模型能够学习到任务相关的知识。在测试时,通过一个查询函数选择最匹配的E-Prompt,并将其与G-Prompt一起附加到预训练模型上进行预测。S-Prompts(Wang 等, 2022b)面向域增量学习中的灾难性遗忘问题,基于预训练的Transformer,为每个领域学习一组独立的提示,并将其添加到提示池中,同时使用K-Means算法存储每个领域的质心用于推理时的领域识别。这种方法的优点在于它提供了一种有效的外部记忆机制,允许模型在不同任务间进行快速切换和适应,同时通过实例特定的提示来增强模型对新任务的学习能力。然而,它的缺点包括随着任务数量增加,提示池可能会变得庞大,导致管理和选择合适提示的复杂性增加。此外,如何平衡提示的泛化性和任务特异性,以及如何有效地集成来自不同提示的信息,也是这种方法需要解决的挑战。




图 16 构建可训练共享提示池(Wang 等, 2022e)
Fig. 16 Construct trainable shared prompt pool
(Wang et al. , 2022e)

为了使得基于提示的持续学习方法表现更为稳定,一些方法在提示学习的基础上,引入一些优化、正则等策略改善提示的效果。PromptSRC(prompting with self-regulating constraints)(Khattak 等, 2023)

提出一种自我调节框架解决持续学习中提示学习过拟合问题,该框架通过3种方法引导提示优化特定任务和与任务无关的通用表示:1)通过最大化与冻结模型的相互一致性调节提示表示;2)在训练轨迹上使用提示的自集成来调节,以编码其互补优势;3)通过文本多样性进行调节,以缓解视觉分支的样本多样性不平衡问题。PGP(prompt gradient projection)(Qiao 等, 2024)通过结合提示调整和梯度投影减少遗忘,利用自我注意力机制在ViT中实现提示梯度的正交条件,并通过奇异值分解在输入空间和提示空间的元素和空间中求解条件方程,从而有效防止遗忘。LGCL(language guidance for prompt-based continual learning)(Khan 等, 2023)通过在任务级别和类别级别上引入语言指导,来增强基于提示的持续学习方法。在任务级别,LGCL鼓励模型将提示池中的可学习键映射到所有任务类别共享的语言表示中;在类别级别,它鼓励模型将视觉编码器的输出特征与相应类别的语言表示对齐。通过这种方式,LGCL能够在不需要额外可学习参数的情况下,提高持续学习方法的性能。EvoPrompt(evolutionary parameterized prompt memory)(Kurniawan 等, 2024)通过为预训练模型引入适应性和连续性的提示解决在测试期间选择不匹配和提示关联不当的问题。具体而言,EvoPrompt将连续的提示函数形式化为神经网络瓶颈,并将提示集合编码到网络权重中。通过建立一个由稳定参考提示记忆和灵活工作提示记忆组成的配对提示记忆系统,并在任务间融时融合两种记忆,实现了提示记忆的持续演化。CPrompt(consistent prompting)(Gao 等, 2024)通过让所有现有分类器参与提示训练来解决分类器不一致问题,并通过随机选择提示池中的提示训练当前任务的分类器,增强了模型对不同提示的适应能力,从而提高了预测的鲁棒性,并辅以多键机制提高提示选择的准确性。HiDe-Prompt(Wang 等, 2023c)通过理论分析,将持续学习目标分解为层次化组件,包括任务内预测、任务信息推断和任务自适应预测,通过构建特定任务的提示集合和利用未指导和指导表示的统计信息,显式优化这些层次化组件,引入对比正则化策略来协调它们。

此外,一些方法通过生成特定于实例或任务的提示来适应新任务,这些提示是动态创建的,而不是从预先定义的池中选择。例如使用元学习网络学习

如何根据输入实例的特征生成任务特定的提示,这些提示随后用于引导预训练模型提取与新任务相关的特征表示。APG(adaptive prompt generator)(Tang等,2023)认为预训练任务与未知未来任务之间存在较大差距,可能导致性能下降,因此提出将提示检索和提示学习过程统一到一个可学习的提示生成器中,通过优化整个提示过程减少任务间差距的负面影响。ConvPrompt(convolutional prompting)(Roy等,2024)通过在层级间共享嵌入上应用卷积操作生成任务特定的提示,从而在不同任务间实现知识迁移。此外,该方法利用大型语言模型评估任务间的相似性,并动态决定需要学习的提示数量,以优化参数效率。这种方法不仅减少了参数数量,还提高了模型在连续学习任务中的表现。提示生成的优点在于能够为每个任务生成定制化提示,提供更精细的控制和更好的适应性,减少了对预训练模型权重的干扰,有助于缓解灾难性遗忘问题。然而,生成有效提示的计算成本可能很高,需要额外的网络结构学习生成过程,且生成的提示可能需要复杂的优化策略确保其有效性。

3.3 方法小结

得益于大模型的发展,基于预训练模型实现更新是当前持续学习的重要方向之一。基于预训练模型的持续学习方法主要有两类通用做法。基于微调的方法是通过调整预训练模型的参数来适应特定任务的常用方法。全模型微调和局部参数高效微调是主要做法,能够使模型在特定任务上具有高度的适应性和强泛化能力。然而,微调需要高计算成本,且

可能导致灾难性遗忘,即模型在学习新任务时丧失对旧任务的知识。基于提示的方法通过设计特定的提示引导预训练模型完成任务,而不修改模型参数。它具有较高的效率和灵活性,避免了灾难性遗忘,并能通过简单调整提示适应不同任务。然而,提示学习在复杂任务中效果可能不如微调显著,且有效提示的设计难度较大,无法精准调整模型性能。未来,相关领域研究者可以结合微调与提示学习的优势,发展出混合方法,如在提示学习基础上结合高效微调。同时,自动提示生成、记忆增强、跨任务泛化等新方法有望提升大模型的知识保留与迁移能力,推动持续学习的发展。

4 持续学习的应用

如表 2 所示,持续学习在计算机视觉、自然语言处理以及多模态任务等领域已经涌现许多研究,本节将就代表性应用进行介绍。

4.1 计算机视觉中的应用

持续学习在计算机视觉领域已经发挥了重要作用,主要体现在识别和生成领域。其中,在识别领域,持续学习允许模型在引入新类别时不忘记之前学习的类别。例如,一个用于自动驾驶的视觉系统,可以在不断添加新类型交通标志或行人样本时,保持对旧类别(如汽车和行人)的准确识别能力。这种能力通过记忆重放或正则化方法实现,确保模型在面对新数据时不遗忘之前的信息。此外,在复杂环境中,持续学习可以帮助模型更好地理解场景中的

表 2 持续学习应用场景示例
Table 2 Examples application scenarios of continual learning

应用类型	代表性应用	主要挑战	常用方法	代表性工作
计算机视觉	持续图像分类	灾难性遗忘	传统持续训练、基于预训练模型	CPrompt(Gao等,2024)
	持续图像分割	背景偏移、前景偏移	实例级别重放	SimCS(Alfarra等,2024)
	持续目标检测	背景偏移、前景偏移	扩散模型生成式重放	SDDGR(Kim等,2024)
	持续图像生成	生成风格变化	模型分解适应风格	L ² DM(Sun等,2024)
自然语言处理	持续文本分类	灾难性遗忘	传统持续训练、基于预训练模型	Snapshot(Wang等,2023)
	持续信息抽取	实体和关系的变化	实体关系图结构重放	CREST(Le等,2024)
	持续对话生成	上下文风格变化	参数化任务风格	IDS(Wang等,2022)
多模态学习	持续视觉问答	模态鸿沟增大	多模态任务特定知识提取	VQACL(Zhang等,2023)
	持续视听理解	模态鸿沟增大	多模态蒸馏	CIGN(Mo等,2023)

各种元素。通过对新场景的学习,模型能够逐步增强对环境的理解,例如在智能家居系统中识别新的家具或设备。例如,RKT(relation guided knowledge transfer)(Ramakrishnan等,2020)在目标检测任务中首先通过一个提议选择机制,利用新类别的真实标注对象确定哪些知识应该从基础网络转移到新网络;然后引入一个基于关系引导的转移损失函数,旨在保持基础网络和新网络训练中选定提议之间的关系,以减少灾难性遗忘的影响。SDDGR(stable diffusion-based deep generative replay)(Kim等,2024a)在目标检测任务中利用基于扩散的生成模型和预训练的文本到图像扩散网络生成真实多样的合成图像,通过迭代细化策略提高图像质量,并采用L2知识蒸馏技术改善在合成图像中先前知识的保留。

在生成任务中(刘安安等,2024a),持续学习可以应用于生成对抗网络等模型。这些模型可以通过不断学习新样本生成高质量的图像。例如,一个艺术风格转换模型可以在接受新的艺术风格时,生成具有该风格的新图像,同时保持对已有风格的生成能力。例如,Hyper-LifelongGAN(Zhai等,2021)是一种用于图像条件生成的可扩展持续学习框架,它通过将传统的卷积滤波器分解为动态基础滤波器和跨任务共享的确定性权重矩阵来解决深度神经网络在遇到新任务时可能遗忘先前任务的问题。这种方法不仅减少了新任务所需的额外参数,还通过知识蒸馏技术保留了对先前任务的记忆,使得模型在适应新任务的同时,能够保持对之前任务的生成质量,有效解决了灾难性遗忘问题。L²DM(lifelong text-to-image diffusion model)(Sun等,2024)提出一种解决连续文本到图像生成任务的方法,通过设计任务感知记忆增强模块和弹性概念蒸馏模块来保护先前概念和个性化概念的知识,同时引入概念注意力艺术家模块和正交注意力艺术家模块来解决在生成多个用户特定概念时的语义忽视问题,从而能够在连续的文本提示下生成更高质量的图像。

4.2 自然语言处理中的应用

在自然语言处理(natural language processing, NLP)中,持续学习通过不断更新模型,使其能够灵活应对多样化的任务和动态变化的语言环境。例如,在文本分类任务中,持续学习提升了模型的分类能力,使其能够适应新出现的新闻主题和类别,从而确保准确的分类结果。在情感分析中,模型通过持

续学习能够识别新兴的用语和情感表达,及时捕捉社交媒体上的情感趋势。对于机器翻译,持续学习帮助系统不断优化翻译质量,以适应不同语言的特征和变化,提升翻译的准确性和流畅性。在对话系统中,持续学习增强了模型的交互能力,使其能够更好地理解用户的意图,优化回答策略,从而提高用户体验。在文本生成任务中,持续学习使模型能够生成更具创意和连贯性的文本,随着新写作风格和主题的引入,模型能够融入新元素,保持对已有风格的生成能力。IDS(incremental dialogue system)(Wang等,2019)在对话系统中引入了一个不确定性估计模块来评估对正确响应的信心。当系统对响应有高信心时,它会直接给出回应;如果信心不足,则会引入人工干预,并通过在线学习模块从人工干预中学习,以适应新用户需求。通过与用户持续的交互,系统能够不断更新自身,减少人工干预的需求,同时显著降低注释成本。PAGeR(prompt augmented generative replay)(Varshney等,2022)在持续意图检测任务中结合预训练语言模型的生成重放和监督对比学习,以便在不断引入新意图的同时,保持对先前意图的性能,而无需访问先前意图的数据。PAGeR存储每个意图的相关上下文作为提示,并利用这些存储的上下文(带有类别标签)生成特定于意图的表述,同时使用监督对比微调以提高生成质量。Snapshot(Wang等,2023b)在文本分类任务中构建轻量级快照,通过知识蒸馏将过去快照中的知识传递给当前模型,使模型在学习新任务的同时复习先前学到的知识,并设计了表示重校准以更好地处理类别增量设置。CREST(continual relation extraction via sequential multi-task learning)(Le等,2024)通过冻结BERT编码器、使用高斯混合模型生成数据以及提出一种专为持续文本信息提取设计的基于梯度的多目标优化框架,有效地平衡了新知识的获取与旧知识保留之间的矛盾。

4.3 多模态任务中的应用

在多模态任务中,如图像、文本和视频的数据处理,持续学习的方法尤为重要,因为现实世界的数据处理需求通常是复杂且多样化的,涉及多种数据模态而不仅仅是单一模态。这些多模态持续学习系统需要有效地整合和处理各种多模态数据流,同时保留先前获得的知识。这样做的好处包括提高模型对新任务的适应能力,减少对历史训练数据的依赖,从

而提高资源和时间效率,并且能够更好地模拟人类在处理现实世界复杂性时跨不同模态学习和整合信息的过程,最终提升整体的感知和认知能力。例如,智能助理或聊天机器人结合视觉(如用户面部表情和环境)和语言(如语音和文本输入)模态,可以提供更自然、更具适应性的交互体验。自动驾驶汽车整合视觉(摄像头图像)、雷达、激光雷达(光检测和测距)、传感器数据(如加速度计和陀螺仪)以及人类语言,可以实现更安全、更准确的驾驶决策。SCML (sequential cross-modal learning) (Song 和 Tan, 2021) 模仿人类大脑获取跨模态知识的认知机制,通过维护一个统一的模型捕获不同模态的共同知识,并以序贯的方式进行学习,使其能够根据不同模态的分布演化自适应调整,无需在多模态数据之间进行烦琐的对齐操作。此外,为了克服序贯学习中遇到的灾难性遗忘问题,SCML 还提出一种基于长短期记忆模型(long-short term memory, LSTM)的元学习方法,通过在新模态数据可用时对旧模型进行优化,以保持对新任务的良好性能同时保留先前任务的知识。VQACL (visual question answering continual learning) (Zhang 等, 2023b) 提出一种视觉问答持续学习方法,利用样本特定和样本不变特征学习对视觉问答(visual question answering, VQA)任务既有区分性又具有泛化性的表示。通过为视觉和文本输入分别提取这种表示,该方法能够明确地分离技能和概念。CIGN (class-incremental grouping network) (Mo 等, 2023) 通过学习音频—视觉类标记和音频—视觉分组,不断聚合类别感知特征,同时利用类标记蒸馏和持续分组来防止忘记先前任务中学习的参数,从而提高模型捕获区分性音频—视觉类别的能力。

5 持续学习的评价指标与基准测试

5.1 性能评价指标

在持续学习中,常用的评价指标主要衡量模型在新任务上的表现、灾难性遗忘的程度以及知识迁移能力等。以下是常见的几种评价指标及其计算式。

1) 平均精度(average accuracy)。平均精度用于衡量模型在所有任务上的整体表现。假设有 T 个任务, $a_{i,T}$ 表示在训练完所有任务后,模型在任务 i 上

的精度。平均精度定义为

$$A_T = \frac{1}{T} \sum_{i=1}^T a_{i,T} \quad (5)$$

2) 遗忘率(forgetting rate)。遗忘率衡量模型在新任务学习后,旧任务表现的下降程度。对每个任务 i , 其在训练完成后(即第 T 个任务训练后)精度为 $a_{i,T}$, 其初始精度为 $a_{i,i}$ 。遗忘率 F_T 定义为

$$F_T = \frac{1}{T-1} \sum_{i=1}^{T-1} (a_{i,i} - a_{i,T}) \quad (6)$$

该指标衡量了模型从最初在任务 i 上达到的精度与当前精度的差距。

3) 前向迁移(forward transfer)。前向迁移表示模型在学习新任务时,是否能从之前学习的任务中获益,表现为新任务初始精度的提高。假设在任务 t 训练前的精度为 $a_{i,t-1}$, 前向迁移定义为

$$FWT_t = a_{i,t-1} - a_i^b \quad (7)$$

式中, a_i^b 是模型在没有任何先前任务经验的情况下,直接测试任务 t 的初始精度。前向迁移即 $FWT_t > 0$, 说明学习先前任务对新任务有帮助。

4) 后向迁移(backward transfer, BWT)。后向迁移衡量学习新任务后,是否对旧任务精度有正面或负面影响。假设在学习任务 t ($t > 1$) 后,模型在之前任务 i 上的精度为 $a_{i,t}$, 则后向迁移定义为

$$BWT_t = \frac{1}{t-1} \sum_{i=1}^{t-1} (a_{i,t} - a_{i,i}) \quad (8)$$

后向迁移为正值时,说明学习新任务有助于提升旧任务的表现。

5) 记忆保留率(memory retention, MR)。记忆保留率衡量模型对旧任务的记忆保持程度。对于每个任务 i , 在学习新任务后其精度为 $a_{i,T}$, 则记忆保留率定义为

$$MR_T = \frac{1}{T} \sum_{i=1}^T \frac{a_{i,T}}{a_{i,i}} \quad (9)$$

该指标计算任务精度与其初始精度的比率,保留率越高,说明模型对旧任务的记忆越完整。

这些常见指标通过衡量模型在多个任务上的表现变化,评估其持续学习能力。平均精度评估整体性能,遗忘率反映知识遗忘情况,前向迁移和后向迁移分别评估知识的跨任务迁移效果,记忆保留率则关注模型保持旧知识的能力。这些指标帮助研究者识别和优化持续学习系统在应对灾难性遗忘和知识迁移时的效果。

5.2 基准数据集与测试协议

当前,持续学习的基准数据集一般基于通用图像分类数据集变换得到。变换的核心点在于构建持续多任务,根据构建方法不同,可以将基准数据集分为3类:基于拆分的数据集构建、基于变换的数据集构建以及基于组合的数据集构建。

1)基于拆分的数据集将已有的分类数据集按照类别拆分为不同的任务。例如:Split MNIST 将经典的手写数字识别数据集 MNIST(modified national institute of standards and technology database)分成多个子任务。通常的做法是将 10 个类别分为 5 个二分类任务。每个任务都涉及两类数字的分类问题。Split CIFAR-10 和 Split CIFAR-100 是将 CIFAR-10(Canadian institute for advanced research 10-class dataset)和 CIFAR-100 数据集分成多个二分类或多分类任务的版本。CIFAR-10 包含 10 个类别,可以分为 5 个二分类任务,而 CIFAR-100 包含 100 个类别,通常分为 10 个 10 分类任务。Split TinyImagenet 是基于 TinyImageNet 的数据集,包含 200 个类别的图像,通常可分为 10 个 20 分类任务或 20 个 10 分类任务。

2)基于变换的数据集将已有的数据采用不同的方式变换成为一个新的数据集,每种变换被视为一个新任务。例如:Permuted MNIST 也是基于 MNIST 的变体。每个任务通过对 MNIST 数据图像的像素进行随机置换生成,因此每个任务的输入模式不同,但目标类别仍是 0~9 数字。Rotated MNIST 是通过将 MNIST 数据集中的图像进行旋转操作生成的持续学习任务集。每个任务中的图像会按固定角度旋转,例如任务 1 是 0° ,任务 2 是 15° ,直到达到 180° 。

3)基于组合的持续学习数据集将已有的不同分类数据集直接组合,每一个数据集代表一个任务。例如:Visual Domain Decathlon 是一个经典的组合数据集挑战,涉及 10 个视觉识别任务。每个任务都来自不同的数据集,数据集包括 CIFAR-100、ImageNet、SVHN、Omniglot、UCF-101、Aircraft 等,涵盖了物体、手写字符和自然场景等多种领域。VLCS 数据集包含来自 PASCAL VOC2007、LabelMe、Caltech 和 SUN 等不同数据源的数据,用于不同领域的图像分类任务,该数据集的数据来源多样,涵盖了不同场景、不同对象的图像,数据域差异较大。

5.3 代表性方法实验对比

为更直观地对比传统持续学习方法与基于预训练模型方法的效果差异,本文在 CIFAR-100 和 ImageNet-R 数据集上对一些具有代表性的工作进行了常见的最终精度 A_T 和遗忘度 F_T 结果对比,如表 3 所示。传统持续学习方法包括基于记忆重放和参数正则化的方法等。实验结果表明,基于预训练模型的方法在性能上已显著超越传统持续学习方法。其中,DER++(dark experience replay ++)(Buzzega 等,2020)在 CIFAR-100 数据集上表现出较好的结果,接近基于预训练模型的方法效果;在 ImageNet-R 数据集上,其性能接近早期的提示学习方法,但与较新的基于预训练模型的方法相比仍存在较大差距。EASE(expandable subspace ensemble)(Zhou 等,2024)展示了优异的性能。该方法通过为每个新任务训练轻量级适配器模块,创建任务特定的子空间,这些子空间跨越高维特征空间,使模型能够在不遗忘旧类别知识的同时,有效学习新类别。基于实验结果,本文建议在持续学习任务中,优先考虑采用基于预训练模型的方法,以获得更优的性能。

6 结语与展望

6.1 研究进展总结

持续学习是近年来人工智能领域的一个重要分支,它旨在赋予机器学习模型类似于人类大脑的持续学习能力,即在不断接收新信息的同时保留已有的知识。近年来,这一领域的研究已取得显著进展。研究者们提出多种策略来应对神经网络在序列学习任务中遇到的灾难性遗忘问题。这些策略可以分为传统持续训练和基于预训练模型的方法。传统持续训练的方法主要包括:记忆重放法,通过存储和回放旧任务的数据或梯度信息来辅助模型回忆和保持旧知识;正则化方法,通过限制模型在新任务上的参数更新来保留旧任务的知识;动态结构方法,通过动态利用和调整模型参数来减少对旧任务知识的干扰。此外,鉴于近年来预训练模型的发展,基于预训练模型的持续学习通过微调或提示学习的方式充分利用预训练模型中的知识。这些研究进展为构建能够持续进化和自我改进的智能系统提供了理论和技术基础。本文对这些方法进行了综述,提供了该领域技术的发展脉络。

表 3 传统持续训练与基于预训练模型方法效果对比
Table 3 Comparison of traditional continuous training and pre-trained model based methods

		/%			
方法类型	方法	CIFAR-100		ImageNet-R	
		A_T	F_T	A_T	F_T
传统持续训练的方法	Fine-Tuning	33.61	53.26	28.87	63.80
	iCaRL(Rebuffi 等, 2017)	66.00	5.33	—	—
	DER++(Buzzega 等, 2020)	83.94	14.55	66.73	20.67
	BiC(Wu 等, 2019)	66.11	35.24	52.14	36.70
	LwF(Li 等, 2018)	60.69	27.77	38.54	52.37
	EWC(Kirkpatrick 等, 2017)	47.01	33.27	35.00	56.16
基于预训练模型的方法	L2P(Wang 等, 2022)	84.16	5.14	65.57	6.81
	DualPrompt(Wang 等, 2022)	85.76	4.93	66.31	6.14
	CoDA-Prompt(Smith 等, 2023)	86.70	4.66	71.59	5.57
	EvoPrompt(Kurniawan 等, 2024)	87.78	4.28	73.60	5.24
	OVOR(Huang 等, 2024)	86.36	4.75	70.48	5.15
	CPrompt(Gao 等, 2024)	87.17	4.41	75.30	5.72
	EASE(Zhou 等, 2024)	88.11	4.47	76.04	5.88
	InfLoRA(Liang 和 Li, 2024)	86.93	5.03	75.53	6.10

注:“—”表示相关论文未提供对应结果。

6.2 仍然面临的挑战

尽管持续学习领域已经取得了一定的研究进展,但仍有许多挑战需要克服。本文根据已有经验,给出一些可能遇到的挑战:

- 1)资源受限条件下的持续学习。实际应用中,模型往往需要在移动设备或边缘计算环境中运行,这些环境的资源非常有限。如何在有限的计算资源和存储空间下实现有效的持续学习是一个关键问题。
- 2)任务差异较大时的持续学习。现有的持续学习方法大多对已有数据集进行拆分或转换,在转换后的数据集上进行效果评估。这种情况下,任务间存在较大的关联性。在真实场景下,很多任务之间没有明显关联时,将会面临更加严重的灾难性遗忘。当任务彼此之间高度相关时,模型可以从共享知识中获益,但任务之间的差异可能会导致干扰,致使模型在适应新任务时损害对旧任务的表现。如何在这些干扰中找到平衡,是一个关键问题。
- 3)缺乏监督情况下的持续学习。现有的大多数持续学习方法依赖于有监督的学习模式,而现实中

许多持续学习模型部署后更容易遭遇变化的环境,这种情况下难以获得大量标注数据。如何设计出在半监督、无监督或自监督情境下也能够持续学习的模型,甚至可以运行在测试时进行自动适应、自动发现的持续学习模型,是一个值得研究的问题。

4)数据不平衡下的持续学习。在许多实际应用中,数据是高度不平衡的,一些任务可能提供更多的数据,而另一些任务则可能数据稀少,甚至数据分布会随着时间不断变化。现有的持续学习方法忽略了这种可能的数据不平衡,默认所有任务的数据量相等。持续学习模型在这些动态变化中保持性能相对困难。

5)大模型预训练知识的充分利用与迁移。大模型在预训练阶段已经学到了大量通用知识,如何在持续学习过程中充分利用这些知识是一个关键问题。虽然大模型具有较强的泛化能力,但它们在面对具体任务时,仍可能无法高效迁移预训练知识。尤其是当新任务与预训练任务差异较大时,这种知识迁移的能力会受到限制。在微调过程中,大模型可能会遗忘掉其预训练阶段学到的通用知识。这种

灾难性遗忘可能会对模型的跨任务表现造成显著影响。提示设计复杂且难以推广到不同任务中,尤其是面对复杂任务时,如何高效设计提示并让模型长期保持性能是一个难点。

6.3 未来研究思路

本文建议持续学习领域的研究者可以从以下几个方向进一步研究:

1)资源受限与数据缺陷情况下的持续学习。持续学习在资源受限和数据缺陷的环境下面临诸多挑战。如何在计算能力有限的设备上进行有效的学习、如何应对小样本数据、甚至不完整或有噪声的数据是未来研究的重点。针对这些问题,研究者们可以探索更高效的模型压缩技术、低资源消耗的算法以及增量式数据学习方法,从而使模型在有限的硬件和数据支持下,仍能持续有效地提升性能。

2)探寻持续学习中可塑性和稳定性平衡的本质。研究者们可以致力于理解持续学习中可塑性和稳定性之间的平衡机制。未来的研究可以聚焦于设计新颖的记忆机制、优化知识重用策略,或引入正则化技术,以有效控制遗忘问题,实现更好的知识保留与更新。这涉及到对人类大脑中类似机制的深入研究,以及开发新的理论框架和算法,使机器学习模型能够更好地模拟人类的记忆和学习过程。

3)研究新的持续学习模型结构和训练模式。随着人工智能技术的进步,新的模型结构和训练模式有望为持续学习带来突破。例如,多智能体系统和分布式学习模式可以通过协作与并行计算,提升学习效率和扩展性。此外,基于图神经网络等前沿技术的结构也将帮助持续学习模型在复杂环境中更好地进行推理和决策。未来的研究方向可能还包括自适应模型的构建,使其能够根据环境或任务的变化进行动态调整。

4)大模型下持续学习如何有效利用预训练知识提升训练效果。大模型的预训练技术已经展示了其强大的知识存储与泛化能力,未来持续学习的一个重要方向是如何充分利用这些预训练知识,提高学习新任务的效率和效果。研究者可以设计新的技术手段,利用大模型帮助持续学习模型在新任务中更快适应,并减少对大量标注数据的依赖。此外,如何在持续学习的过程中,动态调整对预训练模型的依赖程度,避免其对模型的过度影响,也是未来的重要研究议题。

5)探索如何将持续学习应用于更具体的领域。持续学习的理论和技术已经在部分领域得到了验证,未来的研究将探索其在更多实际场景中的应用。例如,自主系统(如自动驾驶、无人机)和机器人技术中,模型需要在高度动态的环境中持续学习新技能和调整行为策略。通过将持续学习应用于这些领域,未来的人工智能系统可以在不间断学习的过程中不断自我优化,适应复杂的现实环境。此外,持续学习在医疗、金融、物流等行业的应用也值得深入探讨,以提升这些领域中的智能化水平和自动化能力。

通过这些研究方向的深入探索,持续学习领域有望实现新的技术突破,并在人工智能的多个子领域中发挥关键作用,推动智能系统向更加自主、适应性强和智能化的方向发展。

参考文献(References)

- Abati D, Tomczak J, Blankevoort T, Calderara S, Cucchiara R and Bejnordi B E. 2020. Conditional channel gated networks for task-aware continual learning//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 3930-3939 [DOI: 10.1109/cvpr42600.2020.00399]
- Ahn H, Kwak J, Lim S, Bang H, Kim H and Moon T. 2021. SS-IL: separated softmax for incremental learning//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 824-833 [DOI: 10.1109/iccv48922.2021.00088]
- Aljundi R, Babiloni F, Elhoseiny M, Rohrbach M and Tuytelaars T. 2018. Memory aware synapses: learning what (not) to forget//Proceedings of the 15th European Conference on Computer Vision - ECCV 2018. Munich, Germany: Springer: 144-161 [DOI: 10.1007/978-3-030-01219-9_9]
- Aljundi R, Belilovsky E, Tuytelaars, Charlin L, Caccia M, Lin M and Caccia L. 2019a. Online continual learning with maximal interfered retrieval//Proceedings of the 33rd Conference on Neural Information Processing Systems (NeurIPS 2019. Vancouver, Canada: Curran Associates Inc.: 1-15
- Aljundi R, Chakravarty P and Tuytelaars T. 2017. Expert gate: lifelong learning with a network of experts//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 7120-7129. [DOI: 10.1109/cvpr.2017.753]
- Aljundi R, Kelchtermans K and Tuytelaars T. 2019b. Task-free continual learning//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 11246-11255 [DOI: 10.1109/CVPR.2019.01151]
- Arani E, Sarfraz F and Zonooz B. 2022. Learning fast, learning slow: a

- general continual learning method based on complementary learning system//Proceedings of the 10th International Conference on Learning Representations. [s.l.]: ICLR: 1-22
- Bang J, Kim H, Yoo Y J, Ha J W and Choi J. 2021. Rainbow memory: continual learning with a memory of diverse samples//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 8214-8223 [DOI: 10.1109/cvpr46437.2021.00812]
- Bisaz R, Travaglia A and Alberini C M. 2014. The neurobiological bases of memory formation: from physiological conditions to psychopathology. *Psychopathology*, 47 (6) : 347-356 [DOI: 10.1159/000363702]
- Bonato J, Pelosin F, Sabetta L and Nicolosi A. 2024. MIND: multi-task incremental network distillation//Proceedings of the 38th AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI: 11105-11113 [DOI: 10.1609/aaai.v38i10.28987]
- Boschini M, Bonicelli L, Buzzega P, Porrello A and Calderara S. 2023. Class-incremental continual learning into the eXtended DER-verse. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(5): 5497-5512 [DOI: 10.1109/TPAMI.2022.3206549]
- Boschini M, Bonicelli L, Porrello A, Bellitto G, Pennisi M, Palazzo S, Spampinato C and Calderara S. 2022. Transfer without forgetting//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 692-709 [DOI: 10.1007/978-3-031-20050-2_40]
- Bricken T, Davies X, Singh D, Krotov D and Kreiman G. 2023. Sparse distributed memory is a continual learner//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda: ICLR: 1-57
- Buzzega P, Boschini M, Porrello A, Abati D and Calderara S. 2020. Dark experience for general continual learning: a strong, simple baseline//Proceedings of the 34th International Conference on Neural Information Processing System. Vancouver, Canada: Curran Associates Inc.: #1335
- Caccia L, Aljundi R, Asadi N, Tuytelaars T, Pineau J and Belilovsky E. 2022. New insights on reducing abrupt representation change in online continual learning//Proceedings of the 10th International Conference on Learning Representations. [s.l.]: ICLR: 1-27
- Castro F M, Marín-Jiménez M J, Guil N, Schmid, C and Alahari K. 2018. End-to-end incremental learning//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer: 241-257 [DOI: 10.1007/978-3-030-01258-8_15]
- Cha H, Lee J and Shin J. 2021. Co²L: contrastive continual learning//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 9496-9505 [DOI: 10.1109/iccv48922.2021.00938]
- Cha S, Hsu H, Hwang T, Calmon F P and Moon T. 2020. CPR: classifier-projection regularization for continual learning//Proceedings of the 37th International Conference on Machine Learning. Vienna, Austria: PMLR
- Chaudhry A, Dokania P K, Ajanthan T and Torr P H S. 2018. Riemannian walk for incremental learning: understanding forgetting and intransigence//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer: 556-572 [DOI: 10.1007/978-3-030-01252-6_33]
- Chaudhry A, Gordo A, Dokania P, Torr P and Lopez-Paz D. 2021. Using hindsight to anchor past knowledge in continual learning//Proceedings of the 35th AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 6993-7001 [DOI: 10.1609/aaai.v35i8.16861]
- Chaudhry A, Ranzato M, Rohrbach M and Elhoseiny M. 2019. Efficient lifelong learning with A-GEM//Proceedings of 2019 International Conference on Learning Representations. New Orleans, USA: ICLR: 1-20
- Churamani N, Kara O and Gunes H. 2023. Domain-incremental continual learning for mitigating bias in facial expression and action unit recognition. *IEEE Transactions on Affective Computing*, 14(4): 3191-3206 [DOI: 10.1109/TAFFC.2022.3181033]
- de Lange M, Aljundi R, Masana M, Parisot S, Jia X, Leonardis A, Slabaugh G and Tuytelaars T. 2022. A continual learning survey: defying forgetting in classification tasks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(7): 3366-3385 [DOI: 10.1109/tpami.2021.3057446]
- Derakhshani M M, Zhen X T, Shao L and Snoek C. 2021. Kernel continual learning//Proceedings of the 38th International Conference on Machine Learning. [s.l.]: PMLR: 2621-2631
- Dhar P, Singh R V, Peng K C, Wu Z Y and Chellappa R. 2019. Learning without memorizing//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 5133-5141 [DOI: 10.1109/cvpr.2019.00528]
- Douillard A, Cord M, Ollion C, Robert T and Valle E. 2020. PODNet: pooled outputs distillation for small-tasks incremental learning//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 86-102 [DOI: 10.1007/978-3-030-58565-5_6]
- Douillard A, Ramé A, Couairon G and Cord M. 2022. DyTox: transformers for continual learning with dynamic token expansion//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 9275-9285 [DOI: 10.1109/cvpr52688.2022.00907]
- Ebrahimi S, Elhoseiny M, Darrell T and Rohrbach M. 2020a. Uncertainty-guided continual learning with Bayesian neural networks//Proceedings of 2020 International Conference on Learning Representations. Addis Ababa, Ethiopia: ICLR: 1-16
- Ebrahimi S, Meier F, Calandra R, Darrell T and Rohrbach M. 2020b. Adversarial continual learning//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 386-402 [DOI: 10.1007/978-3-030-58621-8_23]
- Gao R and Liu W W. 2023. DDGR: Continual learning with deep

- diffusion-based generative replay//Proceedings of the 40th International Conference on Machine Learning. Honolulu, USA: PMLR: 10744-10763
- Gao Z X, Cen J and Chang X B. 2024. Consistent prompting for rehearsal-free continual learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 28463-28473 [DOI: 10.1109/CVPR52733.2024.02689]
- Garg P, Saluja R, Balasubramanian V N, Arora C, Subramanian A and Jawahar C V. 2022. Multi-domain incremental learning for semantic segmentation//Proceedings of 2022 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE: 2080-2090 [DOI: 10.1109/WACV51458.2022.00214]
- Gurbuz M B and Dovrolis C. 2022. NISPA: neuro-inspired stability-plasticity adaptation for continual learning in sparse networks//Proceedings of the 39th International Conference on Machine Learning. Baltimore, USA: PMLR: 8157-8174
- Gurbuz M B, Moorman J M and Dovrolis C. 2024. NICE: neurogenesis inspired contextual encoding for replay-free class incremental learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23659-23669 [DOI: 10.1109/CVPR52733.2024.02233]
- Han X, Zhang Z Y, Ding N, Gu Y X, Liu X, Huo Y Q, Qiu J Z, Yao Y, Zhang A, Zhang L, Han W T, Huang M L, Jin Q, Lan Y Y, Liu Y, Liu Z Y, Lu Z W, Qiu X P, Song R H, Tang J, Wen J R, Yuan J H, Zhao W X and Zhu J. 2021. Pre-trained models: past, present and future. *AI Open*, 2: 225-250 [DOI: 10.1016/j.aiopen.2021.08.002]
- Hao J, Ji K Y and Liu M R. 2023. Bilevel coreset selection in continual learning: a new formulation and algorithm//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: #2220 [DOI: 10.5555/3666122.3668342]
- Hayes T L, Kafle K, Shrestha R, Acharya M and Kanan C. 2020. REMIND your neural network to prevent catastrophic forgetting//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 466-483 [DOI: 10.1007/978-3-030-58598-3_28]
- He J, Mao R Y, Shao Z M and Zhu F Q. 2020. Incremental learning in online scenario//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 13923-13932 [DOI: 10.1109/cvpr42600.2020.01394]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Hinton G E and Plaut D C. 1987. Using fast weights to deblur old memories//Proceedings of the 9th Annual Conference of the Cognitive Science Society. Seattle, USA: Lawrence Erlbaum Associates, Inc.: 177-186
- Hu W P, Lin Z, Liu B, Tao C Y, Tao Z W, Ma J W, Zhao D Y and Yan R. 2019. Overcoming catastrophic forgetting for continual learning via model adaptation//Proceedings of 2019 International Conference on Learning Representations. New Orleans, USA: ICLR: 1-13
- Hu W P, Qin Q, Wang M Y, Ma J W and Liu B. 2021. Continual learning by using information of each class holistically//Proceedings of the 35th AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 7797-7805 [DOI: 10.1609/aaai.v35i9.16952]
- Huang W C, Chen C F and Hsu H. 2024. OVOR: OnePrompt with virtual outlier regularization for rehearsal-free class-incremental learning//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria: ICLR: 1-20[47]
- Hyder R, Shao K, Hou B, Markopoulos P, Prater-Bennette A and Asif M S. 2022. Incremental task learning with incremental rank updates//Proceedings of the European Conference on Computer Vision. Tel Aviv, Israel: ECVA: 566-582 [DOI: 10.1007/978-3-031-20050-2_33]
- Jeon M, Lee H, Seong Y and Kang M. 2023. Learning without prejudices: continual unbiased learning via benign and malignant forgetting//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda: ICLR: 1-18
- Jiang L Y, Zheng Y F, Chen C, Li G H and Zhang W J. 2023. Review of optimization methods for supervised deep learning. *Journal of Image and Graphics*, 28(4): 963-983 (江铃葵, 郑艺峰, 陈澈, 李国和, 张文杰. 2023. 有监督深度学习的优化方法研究综述. *中国图象图形学报*, 28(4): 963-983) [DOI: 10.11834/jig.211139]
- Jin H and Kim E. 2022. Helpful or harmful: inter-task association in continual learning//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 519-535 [DOI: 10.1007/978-3-031-20083-0_31]
- Jin X S, Sadhu A, Du J Y and Ren X. 2021. Gradient-based editing of memory examples for online task-free continual learning//Proceedings of the 35th International Conference on Neural Information Processing Systems. [s.l.]: Curran Associates Inc.: #2236 [DOI: 10.5555/3540261.3542497]
- Kang H, Mina R J L, Madjid S R H, Yoon J, Hasegawa-Johnson M, Hwang S J and Yoo C D. 2022. Forget-free continual learning with winning subnetworks//Proceedings of the 39th International Conference on Machine Learning. Baltimore, USA: PMLR: 10734-10750
- Ke Z X, Liu B and Huang X C. 2020. Continual learning of a mixed sequence of similar and dissimilar tasks//Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver, Canada: Curran Associates Inc.: #1553 [DOI: 10.5555/3495724.3497277]
- Kemker R and Kanan C. 2018. FearNet: brain-inspired model for incremental learning//Proceedings of the 6th International Conference on

- Learning Representations. Vancouver Canada: ICLR: 1-16
- Khan M G Z A, Naeem M F, Van Gool L, Stricker D, Tombari F and Afzal M Z. 2023. Introducing language guidance in prompt-based continual learning//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: IEEE: 11429-11439 [DOI: 10.1109/iccv51070.2023.01053]
- Khattak M U, Wasim S T, Naseer M, Khan S, Yang M H and Khan F S. 2023. Self-regulating prompts: foundational model adaptation without forgetting//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 15144-15154 [DOI: 10.1109/iccv51070.2023.01394]
- Koh H, Kim D, Ha J W and Choi J. 2022. Online continual learning on class incremental blurry task configuration with anytime inference//Proceedings of 2022 International Conference on Learning Representations. [s.l.]: ICLR: 1-21
- Kim C D, Jeong J and Kim G. 2020. Imbalanced continual learning with partitioning reservoir sampling//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 411-428 [DOI: 10.1007/978-3-030-58601-0_25]
- Kim J, Cho H, Kim J, Tiruneh Y Y and Baek S. 2024a. SDDGR: stable diffusion-based deep generative replay for class incremental object detection//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 28772-28781 [DOI: 10.1109/cvpr52733.2024.02718]
- Kim T, Park J and Han B. 2024b. Cross-class feature augmentation for class incremental learning//Proceedings of the 38th AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI: 13168-13176 [DOI: 10.1609/aaai.v38i12.29216]
- Kirkpatrick J, Pascanu R, Rabinowitz N, Veness J, Desjardins G, Rusu A A, Milan K, Quan J, Ramalho T, Grabska-Barwinska A, Hassabis D, Clopath C, Kumaran D and Hadsell R. 2017. Overcoming catastrophic forgetting in neural networks. Proceedings of the National Academy of Sciences, 114(13): 3521-3526 [DOI: 10.1073/pnas.1611835114]
- Konishi T, Kurokawa M, Ono C, Ke Z X, Kim G and Liu B. 2023. Parameter-level soft-masking for continual learning//Proceedings of the 40th International Conference on Machine Learning. Honolulu, USA: PMLR: 17492-17505
- Kumar A, Chatterjee S and Rai P. 2021. Bayesian structural adaptation for continual learning//Proceedings of the 38th International Conference on Machine Learning. [s.l.]: PMLR: 5850-5860
- Kurniawan M R, Song X, Ma Z H, He Y H, Gong Y H, Qi Y and Wei X. 2024. Evolving parameterized prompt memory for continual learning//Proceedings of the 38th AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI: 13301-13309 [DOI: 10.1609/aaai.v38i12.29231]
- Le T T, Nguyen M, Nguyen T T, Van L N and Nguyen T H. 2024. Continual relation extraction via sequential multi-task learning//Proceedings of the 38th AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI: 18444-18452 [DOI: 10.1609/aaai.v38i16.29805]
- Lee D, Jung S and Moon T. 2024. Continual learning in the presence of spurious correlations: analyses and a simple baseline//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria: ICLR: 1-24
- Lee K Y, Zhong Y Y and Wang Y X. 2023. Do pre-trained models benefit equally in continual learning?//Proceedings of 2023 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE: 6474-6482 [DOI: 10.1109/wacv56688.2023.00642]
- Lee S, Goldt S and Saxe A. 2021. Continual learning in the teacher-student setup: impact of task similarity//Proceedings of the 38th International Conference on Machine Learning. [s.l.]: PMLR: 6109-6119
- Li X L, Zhou Y B, Wu T F, Socher R and Xiong C M. 2019. Learn to grow: a continual structure learning framework for overcoming catastrophic forgetting//Proceedings of the 36th International Conference on Machine Learning. Long Beach, USA: PMLR: 3925-3934
- Li Z Z and Hoiem D. 2018. Learning without forgetting. IEEE Transactions on Pattern Analysis and Machine Intelligence, 40(12): 2935-2947 [DOI: 10.1109/TPAMI.2017.2773081]
- Liang Y S and Li W J. 2024. InfLoRA: interference-free low-rank adaptation for continual learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23638-23647 [DOI: 10.1109/cvpr52733.2024.02231]
- Lin H W, Zhang B Q, Feng S S, Li X T and Ye Y M. 2023. PCR: proxy-based contrastive replay for online class-incremental continual learning//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 24246-24255 [DOI: 10.1109/cvpr52729.2023.02322]
- Liu A A, Su Y T, Wang L J, Li B, Qian Z X, Zhang W M, Zhou L N, Zhang X P, Zhang Y D, Huang J W and Yu N H. 2024. Review on the progress of the AIGC visual content generation and traceability. Journal of Image and Graphics, 29(6): 1535-1554 (刘安安, 苏育挺, 王岚君, 李斌, 钱振兴, 张卫明, 周琳娜, 张新鹏, 张勇东, 黄继武, 俞能海. 2024. AIGC视觉内容生成与溯源研究进展. 中国图象图形学报, 29(6): 1535-1554) [DOI: 10.11834/jig.240003]
- Liu T Y and Soatto S. 2023. Tangent model composition for ensembling and continual fine-tuning//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 18630-18640 [DOI: 10.1109/iccv51070.2023.01712]
- Liu Y, Parisot S, Slabaugh G, Jia X, Leonardis A and Tuytelaars T. 2020a. More classifiers, less forgetting: a generic multi-classifier paradigm for incremental learning//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 699-716 [DOI: 10.1007/978-3-030-58574-7_42]
- Liu Y Y, Schiele B and Sun Q R. 2021. Adaptive aggregation networks

- for class-incremental learning//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 2544-2553 [DOI: 10.1109/cvpr46437.2021.00257]
- Liu Y Y, Su Y T, Liu A A, Schiele B and Sun Q R. 2020b. Mnemonics training: multi-class incremental learning without forgetting//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 12242-12251 [DOI: 10.1109/cvpr42600.2020.01226]
- Liu Z X, Zhang J, Asadi K, Liu Y, Zhao D, Sabach S and Fakoor R. 2024b. TAIL: task-specific adapters for imitation learning with large pretrained models//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria: ICLR: 1-24
- Lopez-Paz D and Ranzato M. 2017. Gradient episodic memory for continual learning//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc.: 6470-6479
- Luo Y T, Zhao S Q, Wu H R and Lu Z W. 2024. Dual-enhanced coreset selection with class-wise collaboration for online blurry class incremental learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23995-24004. [DOI: 10.1109/cvpr52733.2024.02265]
- Lyu F, Wang S, Feng W, Ye Z H, Hu F Y and Wang S. 2021. Multi-domain multi-task rehearsal for lifelong learning//Proceedings of the 35th AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 8819-8827 [DOI: 10.1609/aaai.v35i10.17068]
- Lyu Y L, Wang L Y, Zhang X X, Sun Z C, Su H, Zhu J and Jing L P. 2023. Overcoming recency bias of normalization statistics in continual learning: balance and adaptation//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: #1108 [DOI: 10.5555/3666122.3667230]
- Magistri S, Trinci T, Soutif-Cormerais A, van de Weijer J and Bagdanov A D. 2024. Elastic feature consolidation for cold start exemplar-free incremental learning//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria: ICLR: 1-23
- Mai Z, Li R W, Jeong J, Quispe D, Kim H and Sanner S. 2022. Online continual learning in image classification: an empirical survey. *Neurocomputing*, 469: 28-51 [DOI: 10.1016/j.neucom.2021.10.021]
- Mallya A, Davis D and Lazebnik S. 2018. Piggyback: adapting a single network to multiple tasks by learning to mask weights//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer: 72-88 [DOI: 10.1007/978-3-030-01225-0_5]
- Mallya A and Lazebnik S. 2018. PackNet: adding multiple tasks to a single network by iterative pruning//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 7765-7773 [DOI: 10.1109/cvpr.2018.00810]
- Masana M, Liu X L, Twardowski B, Menta M, Bagdanov A D and van de Weijer J. 2023. Class-incremental learning: survey and performance evaluation on image classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45 (5): 5513-5533 [DOI: 10.1109/TPAMI.2022.3213473]
- McCloskey M and Cohen N J. 1989. Catastrophic interference in connectionist networks: the sequential learning problem. *Psychology of Learning and Motivation*, 24: 109-165 [DOI: 10.1016/S0079-7421(08)60536-8]
- Mermillod M, Bugaiska A and Bonin P. 2013. The stability-plasticity dilemma: investigating the continuum from catastrophic forgetting to age-limited learning effects. *Frontiers in Psychology*, 4: #504 [DOI: 10.3389/fpsyg.2013.00504]
- Mirza M J, Masana M, Possegger H and Bischof H. 2022. An efficient domain-incremental learning approach to drive in all weather conditions//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. New Orleans, USA: IEEE: 3000-3010 [DOI: 10.1109/CVPRW56347.2022.00339]
- Mo S T, Pian W and Tian Y P. 2023. Class-incremental grouping network for continual audio-visual learning//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 7754-7764 [DOI: 10.1109/iccv51070.2023.00716]
- Nguyen C V, Li Y Z, Bui T D and Turner R E. 2018. Variational continual learning//Proceedings of the 6th International Conference on Learning Representations. Vancouver Canada: ICLR: 1-18
- Ostapenko O, Puscas M, Klein T, Jahnichen P and Nabi M. 2019. Learning to remember: a synaptic plasticity driven framework for continual learning//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 11313-11321 [DOI: 10.1109/CVPR.2019.01158]
- Panos A, Kobe Y, Reino D O, Aljundi R and Turner R E. 2023. First session adaptation: a strong replay-free baseline for class-incremental learning//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 18774-18784 [DOI: 10.1109/iccv51070.2023.01725]
- Parisi G I, Kemker R, Part J L, Kanan C and Wermter S. 2019. Continual lifelong learning with neural networks: a review. *Neural Networks*, 113: 54-71 [DOI: 10.1016/j.neunet.2019.01.012]
- Pham Q, Liu C H, Sahoo D and Hoi S C H. 2021. Contextual transformation networks for online continual learning//Proceedings of 2021 International Conference on Learning Representations. Vienna, Austria: ICLR: 1-20
- Pourcel J, Vu N S and French R M. 2022. Online task-free continual learning with dynamic sparse distributed memory//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 739-756 [DOI: 10.1007/978-3-031-19806-9_42]
- Prabhu A, Torr P H S and Dokania P K. 2020. GDumb: a simple approach that questions our progress in continual learning//Proceedings of the 16th European Conference on Computer Vision. Glasgow, UK: Springer: 524-540 [DOI: 10.1007/978-3-030-

- 58536-5_31]
- Qiao J Y, Zhang Z Z, Tan X, Chen C W, Qu Y Y, Peng Y and Xie Y. 2024. Prompt gradient projection for continual learning//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria: ICLR: 1-22
- Qiu Z H, Xu Y, Meng F M, Li H L, Xu L F and Wu Q B. 2024. Dual-consistency model inversion for non-exemplar class incremental learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 24025-24035 [DOI: 10.1109/CVPR52733.2024.02268]
- Ramakrishnan K, Panda R, Fan Q F, Henning J, Oliva A and Feris R. 2020. Relationship matters: relation guided knowledge transfer for incremental learning of object detectors//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 1009-1018 [DOI: 10.1109/CVPRW50498.2020.00133]
- Ramesh R and Chaudhari P. 2022. Model zoo: a growing brain that learns continually//Proceedings of the 10th International Conference on Learning Representations. [s.l.]: ICLR: 1-27
- Reber P J. 2013. The neural basis of implicit learning and memory: a review of neuropsychological and neuroimaging research. *Neuropsychologia*, 51(10): 2026-2042 [DOI: 10.1016/j.neuropsychologia.2013.06.019]
- Rebuffi S A, Kolesnikov A, Sperl G and Lampert C H. 2017. iCaRL: incremental classifier and representation learning//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 5533-5542 [DOI: 10.1109/CVPR.2017.587]
- Riemer M, Cases I, Ajemian R, Liu M, Rish I, Tu Y H and Tesauro G. 2019. Learning to learn without forgetting by maximizing transfer and minimizing interference//Proceedings of 2019 International Conference on Learning Representations. New Orleans, USA: ICLR: 1-31
- Ritter H, Botev A and Barber D. 2018. Online structured Laplace approximations for overcoming catastrophic forgetting//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal, Canada: Curran Associates Inc.: 3742-3752 [DOI: 10.5555/3327144.3327290]
- Robins A. 1995. Catastrophic forgetting, rehearsal and pseudo-rehearsal. *Connection Science*, 7(2): 123-146 [DOI: 10.1080/09540099550039318]
- Rolnick D, Ahuja A, Schwarz J, Lillicrap T P and Wayne G. 2019. Experience replay for continual learning//Proceedings of the 33rd International Conference on Neural Information Processing Systems. Vancouver, Canada: Curran Associates Inc.: #32 [DOI: 10.5555/3454287.3454319]
- Roy A, Moulick R, Verma V K, Ghosh S and Das A. 2024. Convolutional prompting meets language models for continual learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23616-23626 [DOI: 10.1109/cvpr52733.2024.02229]
- Roy A, Verma V K, Voonna S, Ghosh K, Ghosh S and Das A. 2023. Exemplar-free continual transformer with convolutions//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 5874-5884 [DOI: 10.1109/iccv51070.2023.00542]
- Rudner T G J, Smith F B, Feng Q X, Teh Y W and Gal Y. 2022. Continual learning via sequential function-space variational inference//Proceedings of the 39th International Conference on Machine Learning. Baltimore, USA: PMLR: 18871-18887
- Rypešć G, Cygert S, Khan V, Trzciński T, Zieliński B and Twardowski B. 2024. Divide and not forget: ensemble of selectively trained experts in continual learning//Proceedings of the 12th International Conference on Learning Representations. Vienna, Austria: ICLR: 1-18
- Sarfraz F, Arani E and Zonooz B. 2023. Sparse coding in a dual memory system for lifelong learning//Proceedings of the 37th AAAI Conference on Artificial Intelligence. Washington, USA: AAAI: 9714-9722 [DOI: 10.1609/aaai.v37i8.26161]
- Schulz D J. 2006. Plasticity and stability in neuronal output via changes in intrinsic excitability: it's what's inside that counts. *Journal of Experimental Biology*, 209(24): 4821-4827 [DOI: 10.1242/jeb.02567]
- Seo M, Koh H, Jeung W, Lee M, Kim S, Lee H, Cho S, Choi S, Kim H and Choi J. 2024. Learning equi-angular representations for online continual learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23933-23942 [DOI: 10.1109/cvpr52733.2024.02259]
- Shi W X and Ye M. 2023. Prototype reminiscence and augmented asymmetric knowledge aggregation for non-exemplar class-incremental learning//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 1772-1781 [DOI: 10.1109/iccv51070.2023.00170]
- Shim D, Mai Z, Jeong J, Sanner S, Kim H and Jang J. 2021. Online class-incremental continual learning with adversarial Shapley value//Proceedings of the 35th AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 9630-9638 [DOI: 10.1609/aaai.v35i11.17159]
- Shin H, Lee J K, Kim J and Kim J. 2017. Continual learning with deep generative replay//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc.: 2994-3003 [DOI: 10.5555/3294996.3295059]
- Shon H, Lee J, Kim S H and Kim J. 2022. DLCFT: deep linear continual fine-tuning for general incremental learning//Proceedings of the 17th European Conference on Computer Vision — ECCV 2022. Tel Aviv, Israel: Springer: 513-529 [DOI: 10.1007/978-3-031-19827-4_30]
- Smith J S, Karlinsky L, Gutta V, Cascante-Bonilla P, Kim D, Arbelles

- A, Panda R, Feris R and Kira Z. 2023. CODA-prompt: continual decomposed attention-based prompting for rehearsal-free continual learning//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 11909-11919 [DOI: 10.1109/CVPR52729.2023.01146]
- Simon C, Koniusz P and Harandi M. 2021. On learning the geodesic path for incremental learning//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 1591-1600 [DOI: 10.1109/CVPR46437.2021.00164]
- Singh P, Verma V K, Mazumder P, Carin L and Rai P. 2020. Calibrating CNNs for lifelong learning//Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver, Canada: Curran Associates Inc.: #1307 [DOI: 10.5555/3495724.3497031]
- Song G and Tan X Y. 2021. Real-world cross-modal retrieval via sequential learning. *IEEE Transactions on Multimedia*, 2021, 23: 1708-1721 [DOI: 10.1109/TMM.2020.3002177]
- Sun G, Liang W Q, Dong J H, Li J, Ding Z M and Cong Y. 2024. Create your world: lifelong text-to-image diffusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 46(9): 6454-6470 [DOI: 10.1109/TPAMI.2024.3382753]
- Sun S Y, Calandriello D, Hu H Y, Li A and Titsias M. 2022b. Information-theoretic online memory selection for continual learning//Proceedings of the 10th International Conference on Learning Representations. [s.l.]: ICLR: 1-25
- Sun W J, Li Q Y, Zhang J, Wang W and Geng Y A. 2023a. Decoupling learning and remembering: a Bilevel Memory framework with knowledge projection for task-incremental learning//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 20186-20195 [DOI: 10.1109/CVPR52729.2023.01933]
- Sun Z C, Mu Y D and Hua G. 2023b. Regularizing second-order influences for continual learning//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 20166-20175 [DOI: 10.1109/cvpr52729.2023.01931]
- Tan Y W, Zhou Q H, Xiang X, Wang K, Wu Y C and Li Y B. 2024. Semantically-shifted incremental adapter-tuning is a continual ViT-transformer//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23252-23262 [DOI: 10.1109/CVPR52733.2024.02194]
- Tang Y M, Peng Y X and Zheng W S. 2023. When prompt-based incremental learning does not meet strong pretraining//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: IEEE: 1706-1716 [DOI: 10.1109/ICCV51070.2023.00164]
- Valkov L, Srivastava A, Chaudhuri S and Sutton C. 2024. A probabilistic framework for modular continual learning//Proceedings of the 12th International Conference on Learning Representations. [s.l.]: ICLR: 1-26
- Varshney V, Patidar M, Kumar R, Vig L and Shroff G. 2022. Prompt augmented generative replay via supervised contrastive learning for lifelong intent detection//Findings of the Association for Computational Linguistics: NAACL 2022. Seattle, USA: Association for Computational Linguistics: 1113-1127 [DOI: 10.18653/v1/2022.findings-naacl.84]
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser Ł and Polosukhin I. 2017. Attention is all you need//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc.: 6000-6010 [DOI: 10.5555/3295222.3295349]
- Veniat T, Denoyer L and Ranzato M. 2021. Efficient continual learning with modular networks and task-driven priors//Proceedings of 2021 International Conference on Learning Representations. Vienna, Austria: ICLR: 1-30
- Vijayan P, Bhat P, Zonooz B and Arani E. 2023. TriRE: a multi-mechanism learning paradigm for continual knowledge retention and promotion//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: #3226 [DOI: 10.5555/3666122.3669348]
- Wang F Y, Zhou D W, Liu L, Ye H J, Bian Y T, Zhan D C and Zhao P. 2023a. Beef: bi-compatible class-incremental learning via energy-based expansion and fusion//Proceedings of the 11th International Conference on Learning Representations. Kigali, Rwanda: ICLR: 1-25
- Wang J, Dong D J, Shou L D, Chen K and Chen G. 2023b. Effective continual learning for text classification with lightweight snapshots//Proceedings of the 37th AAAI Conference on Artificial Intelligence. Washington, USA: AAAI: 10122-10130 [DOI: 10.1609/aaai.v37i8.26206]
- Wang L Y, Xie J Y, Zhang X X, Huang M Y, Su H and Zhu J. 2023c. Hierarchical decomposition of prompt-based continual learning: rethinking obscured sub-optimality//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: #3022 [DOI: 10.5555/3666122.3669144]
- Wang L Y, Zhang X X, Yang K, Yu L H, Li C X, Hong L Q, Zhang S F, Li Z G, Zhong Y and Zhu J. 2022a. Memory replay with data compression for continual learning//Proceedings of the 10th International Conference on Learning Representations. [s.l.]: ICLR: 1-25
- Wang W K, Zhang J J, Li Q, Hwang M Y, Zong C Q and Li Z F. 2019. Incremental learning from scratch for task-oriented dialogue systems//Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics. Florence, Italy: Association for Computational Linguistics: 3710-3720 [DOI: 10.18653/v1/p19-1361]
- Wang Y B, Huang Z W and Hong X P. 2022b. S-prompts learning with pre-trained transformers: an Occam's razor for domain incremental

- learning//Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: #411 [DOI: 10.5555/3600270.3600681]
- Wang Z, Liu L, Duan Y Q and Tao D C. 2022c. Continual learning through retrieval and imagination//Proceedings of 2022 AAAI Conference on Artificial Intelligence. [s.l.]: AAAI: 8594-8602 [DOI: 10.1609/aaai.v36i8.20837]
- Wang Z F, Zhang Z Z, Ebrahimi S, Sun R X, Zhang H, Lee C Y, Ren X Q, Su G L, Perot V, Dy J and Pfister T. 2022d. Dualprompt: complementary prompting for rehearsal-free continual learning//Proceedings of the 17th European Conference on Computer Vision. Tel Aviv, Israel: Springer: 631-648 [DOI: 10.1007/978-3-031-19809-0_36]
- Wang Z F, Zhang Z Z, Lee C Y, Zhang H, Sun R X, Ren X Q, Su G L, Perot V, Dy J and Pfister T. 2022e. Learning to prompt for continual learning//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 139-149 [DOI: 10.1109/cvpr52688.2022.00024]
- Wołczyk M, Piczak K, Wójcik B, Pustelnik L, Morawiecki P, Tabor J, Trzcinski T and Spurek P. 2022. Continual learning with guarantees via weight interval constraints//Proceedings of the 39th International Conference on Machine Learning. Baltimore, USA: PMLR: 23897-23911
- Wu Y, Chen Y P, Wang L J, Ye Y C, Liu Z C, Guo Y D and Fu Y. 2019. Large scale incremental learning//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 374-382 [DOI: 10.1109/CVPR.2019.00046]
- Xue M Q, Zhang H F, Song J and Song M L. 2022. Meta-attention for ViT-backed continual learning//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 150-159 [DOI: 10.1109/cvpr52688.2022.00025]
- Yan H W, Wang L Y, Ma K S and Zhong Y. 2024. Orchestrate latent expertise: advancing online continual learning with multi-level supervision and reverse self-distillation//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23670-23680 [DOI: 10.1109/cvpr52733.2024.02234]
- Yan Q S, Gong D, Liu Y H, van den Hengel A and Shi J Q. 2022. Learning Bayesian sparse networks with full experience replay for continual learning//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 109-118 [DOI: 10.1109/CVPR52688.2022.00021]
- Yan S P, Xie J W and He X M. 2021. DER: dynamically expandable representation for class incremental learning//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 3013-3022 [DOI: 10.1109/CVPR46437.2021.00303]
- Yang E N, Shen L, Wang Z Y, Liu T L and Guo G B. 2023. An efficient dataset condensation plugin and its application to continual learning//Proceedings of the 37th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: 2957 [DOI: 10.5555/3666122.3669079]
- Ye F and Bors A G. 2024. Online task-free continual generative and discriminative learning via dynamic cluster memory//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 26202-26212 [DOI: 10.1109/cvpr52733.2024.02476]
- Yin H Y, Yang P and Li P. 2021. Mitigating forgetting in online continual learning with neuron calibration//Proceedings of the 35th International Conference on Neural Information Processing Systems. [s. l.]: Curran Associates Inc.: #785 [DOI: 10.5555/3540261.3541046]
- Yoon J, Yang E, Lee J and Hwang S J. 2018. Lifelong learning with dynamically expandable networks//Proceedings of the 6th International Conference on Learning Representations. Vancouver Canada: ICLR: 1-11
- Zenke F, Poole B and Ganguli S. 2017. Continual learning through synaptic intelligence//Proceedings of the 34th International Conference on Machine Learning. Sydney, Australia: JMLR: 3987-3995 [DOI: 10.5555/3305890.3306093]
- Zhai M Y, Chen L and Mori G. 2021. Hyper-LifelongGAN: scalable lifelong learning for image conditioned generation//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 2246-2255 [DOI: 10.1109/cvpr46437.2021.00228]
- Zhang G W, Wang L Y, Kang G L, Chen L and Wei Y C. 2023a. SLCA: slow learner with classifier alignment for continual learning on a pre-trained model//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. Paris, France: IEEE: 19091-19101 [DOI: 10.1109/ICCV51070.2023.01754]
- Zhang H Y, Wang T B, Li M Z, Zhao Z, Pu S L and Wu F. 2022. Comprehensive review of visual-language-oriented multimodal pre-training methods. *Journal of Image and Graphics*, 27(9): 2652-2682 (张浩宇, 王天保, 李孟择, 赵洲, 浦世亮, 吴飞. 2022. 视觉语言多模态预训练综述. *中国图象图形学报*, 27(9): 2652-2682) [DOI: 10.11834/jig.220173]
- Zhang J T, Zhang J, Ghosh S, Li D W, Tasci S, Heck L Zhang H M and Jay Kuo C C. 2020. Class-incremental learning via deep model consolidation//Proceedings of 2020 IEEE Winter Conference on Applications of Computer Vision (WACV). Snowmass, USA: IEEE: 1120-1129 [DOI: 10.1109/WACV45572.2020.9093365]
- Zhang X, Zhang F F and Xu C S. 2023b. VQACL: a novel visual question answering continual learning setting//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 19102-19112 [DOI: 10.1109/cvpr52729.2023.01831]

- Zhang Y Q, Pfahringer B, Frank E, Bifet A, Lim N J S and Jia Y Z. 2022. Repeated augmented rehearsal: a simple but strong baseline for online continual learning//Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans, USA: Curran Associates Inc.: #1074 [DOI: 10.5555/3600270.3601344]
- Zhao B W, Xiao X, Gan G J, Zhang B and Xia S T. 2020. Maintaining discrimination and fairness in class incremental learning//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 13205-13214 [DOI: 10.1109/CVPR42600.2020.01322]
- Zhao H Y, Zhou T Y, Long G D, Jiang J and Zhang C Q. 2023. Does continual learning equally forget all parameters?//Proceedings of the 40th International Conference on Machine Learning. Honolulu, USA: JMLR: 42280-42303 [DOI: 10.5555/3618408.3620187]
- Zhou D W, Wang F Y, Ye H J and Zhan D C. 2023. Deep learning for class-incremental learning: a survey. Chinese Journal of Computers, 46(8): 1577-1605 (周大蔚, 汪福运, 叶翰嘉, 詹德川. 2023. 基于深度学习的类别增量学习算法综述. 计算机学报, 46(8): 1577-1605) [DOI: 10.11897/SP.J.1016.2023.01577]
- Zhou D W, Sun H L, Ye H J and Zhan D C. 2024. Expandable subspace ensemble for pre-trained model-based class-incremental learning//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 23554-23564 [DOI: 10.1109/cvpr52733.2024.02223]
- Zhu F, Zhang X Y and Liu C L. 2023. Class incremental learning: a review and performance evaluation. Acta Automatica Sinica, 49(3): 635-660 (朱飞, 张煦尧, 刘成林. 2023. 类别增量学习研究进展和性能评价. 自动化学报, 49(3): 635-660) [DOI: 10.16383/j.aas.c220588]
- Zhu K, Zhai W, Cao Y, Luo J B and Zha Z J. 2022. Self-sustaining representation expansion for non-exemplar class-incremental learning//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 9286-9295 [DOI: 10.1109/CVPR52688.2022.00908]

作者简介

吕凡,男,博士后,主要研究方向为持续学习。

E-mail: fan.lyu@cripac.ia.ac.cn

胡伏原,通信作者,男,教授,主要研究方向为持续学习与计算机视觉。E-mail: fuyuanhu@usts.edu.cn

王亮,男,研究员,主要研究方向为多模态学习。

E-mail: wangliang@nlpr.ia.ac.cn

李玺,男,教授,主要研究方向为计算机视觉、模式识别和深度学习。E-mail: xilizju@zju.edu.cn

郑伟诗,男,教授,主要研究方向为计算机视觉和多模态学习。E-mail: wszheng@ieee.org

张彰,男,副研究员,主要研究方向为计算机视觉和自动驾驶。E-mail: zzhang@nlpr.ia.ac.cn

周涛,男,教授,主要研究方向为医疗影像和大数据分析。

E-mail: zhoutaonxmu@126.com