

受人脑中记忆机制启发的增量目标检测方法

商迪, 吕彦锋, 乔红

引用本文

商迪, 吕彦锋, 乔红. 受人脑中记忆机制启发的增量目标检测方法[J]. 计算机科学, 2023, 50(2): 267-274.

SHANG Di, LYU Yanfeng, QIAO Hong. [Incremental Object Detection Inspired by Memory Mechanisms in Brain](#) [J]. Computer Science, 2023, 50(2): 267-274.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于特征融合的小样本目标检测](#)

Few-shot Object Detection Based on Feature Fusion

计算机科学, 2023, 50(2): 209-213. <https://doi.org/10.11896/jsjcx.220500153>

[基于先验知识图谱的多代理被遮挡目标类别推理模型](#)

Novel Class Reasoning Model Towards Covered Area in Given Image Based on Informed Knowledge Graph Reasoning and Multi-agent Collaboration

计算机科学, 2023, 50(1): 243-252. <https://doi.org/10.11896/jsjcx.220700112>

[基于移位窗口金字塔Transformer的遥感图像目标检测](#)

SPT:Swin Pyramid Transformer for Object Detection of Remote Sensing

计算机科学, 2023, 50(1): 105-113. <https://doi.org/10.11896/jsjcx.211100208>

[面向深度卷积神经网络的小目标检测算法综述](#)

Small Object Detection Based on Deep Convolutional Neural Networks:A Review

计算机科学, 2022, 49(12): 205-218. <https://doi.org/10.11896/jsjcx.220500260>

[R-YOLOv5:自动切割的旋转的文本检测模型](#)

R-YOLOv5:Auto-cutting,Rotated Text Detection Model

计算机科学, 2022, 49(11A): 210900185-6. <https://doi.org/10.11896/jsjcx.210900185>

受人脑中记忆机制启发的增量目标检测方法

商迪 吕彦锋 乔红

中国科学院自动化研究所多模态人工智能系统全国重点实验室 北京 100190

中国科学院大学人工智能学院 北京 100049

中国科学院自动化研究所复杂系统管理与控制国家重点实验室 北京 100190

(shangdi2020@ia.ac.cn)

摘要 增量学习是缩小当前人工智能和人类智能间差距的关键技术,指智能体像人类一样从不稳定数据流中顺序学习多个任务,且不发生遗忘。目标检测是计算机视觉领域的核心任务之一,是计算机理解图像的基石。因此,增量目标检测问题具有重要的研究意义和实际意义。尽管增量学习在图像分类中取得了不错的成果,但基于目标检测的增量学习研究还处于初级阶段。这是因为目标检测相比图像分类更加复杂,它需要同时解决分类和边框回归的问题。不少研究者为解决此问题做了很多努力,但大多数工作都只关注如何保留已学习任务的性能,忽略了模型对新任务的快速适应能力,而这正是增量学习的关键要求。基于大脑的记忆机制,人类可以在学习中不断地提取知识以更好更快地学习新任务,不发生遗忘。受此启发,提出了一种融合编解码记忆重放机制的增量元学习方法。该方法对已学习样本的特征向量进行编码存储和解码重放,从而将不稳定数据流近似为动态稳定数据集,缓解了遗忘问题。同时,设计了一个双循环在线元学习策略,模型在内循环分别基于多批次新旧混合数据进行随机梯度更新,最后在外循环进行元学习,从而获得多任务间的共同结构,使模型具有良好的泛化性能,能够快速适应学习中遇到的新任务。在大型的公开数据集 PASCAL VOC 和 MS COCO 上设置了 3 种增量目标检测实验环境来评估所提算法。实验结果表明,所提算法与最先进的算法相比体现出了具有竞争力的性能,证明了其可以帮助模型更好地抵抗遗忘,具有更好的泛化性能。所提算法基于梯度更新,与模型无关,因此其可以与其他检测框架结合,具有强适应性。

关键词: 增量学习; 目标检测; 受脑启发; 元学习; 抵抗遗忘; 泛化性能

中图分类号 TP391

Incremental Object Detection Inspired by Memory Mechanisms in Brain

SHANG Di, LYU Yanfeng and QIAO Hong

State Key Laboratory of Multimodal Artificial Intelligence System, Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China
School of Artificial Intelligence, University of Chinese Academy of Sciences, Beijing 100049, China

State Key Laboratory of Complex System Management and Control, Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China

Abstract Incremental learning is key to bridging the enormous gap between artificial intelligence and human intelligence, meaning that agents can learn several tasks sequentially from a continuous stream of correlated data without forgetting, just as humans do. Object detection is one of the core tasks in the field of computer vision and the cornerstone of computer images understanding. Therefore, the incremental object detection has important research and practical significance. Although incremental learning has achieved good results in image classification, the research on incremental learning based on object detection is still in its infancy. This is because object detection is more complex than image classification, which needs to solve both classification and bounding box regression problems. Many researchers have made great efforts to solve this problem, but most of the work only focuses on how to retain previous learning, ignoring fast adaptability to new tasks, which is a critical requirement for incremental learning. Based on the memory mechanism of the brain, humans can constantly extract knowledge during learning, so as to learn new tasks better and faster without forgetting. Inspired by this, an incremental meta-learning method that integrates the codec memory replay mechanism is proposed. This method encodes, stores, decodes and replays the feature vectors of learned samples, so as to approximate the dynamic learning environment as a local stationary environment and avoid catastrophic forgetting. Besides, a double-loop online meta-learning strategy is designed, which can help model to extract common structures of tasks and improve generalization performance on new tasks encountered during learning. The model is respectively updated by SGD with multiple batches of old and new mixed data in the inner loop, and is meta-updated in the outer loop. We evaluate the proposed approach on three incremental object detection settings defined on PASCAL VOC and MS COCO datasets, where the proposed algo-

到稿日期:2022-09-22 返修日期:2022-10-28

基金项目:北京市自然科学基金(L211023);科技创新 2030-“新一代人工智能”重大项目(2020AAA0105900);国家自然科学基金(91948303)

This work was supported by the Natural Science Foundation of Beijing (L211023), National Key Research and Development Plan of China (2020AAA0105900) and National Natural Science Foundation of China(91948303).

通信作者:吕彦锋(yanfeng.lv@ia.ac.cn)

rithm performs favorably well against state-of-the-art methods. It proves that it can help the model to resist forgetting better and have better generalization performance on new tasks. The proposed algorithm is gradient-based and model-agnostic, so it has strong adaptability and can be applied on more complex detection frameworks.

Keywords Incremental learning, Object detection, Brain inspiration, Meta-learning, Resistance to forgetting, Generalization

1 引言

尽管人工智能近年来在分类、检测和跟踪等多种任务上的表现都优于人类,但这大部分归功于庞大稳定的数据集。当模型处理不稳定顺序数据流时,其在学习过程中会不断遇到新任务,如果直接使用新类别数据微调模型,模型在早期任务上的性能会急剧下降,这种现象被称为灾难性遗忘^[1]。因此,模型需要从头开始训练,学习所有任务,耗时耗力,这显然与人类连续地积累并应用知识的学习过程大不相同。因此,我们研究增量学习来解决这一问题。

基于计算机视觉任务的增量学习目前发展迅速,尤其是在分类任务上^[2]。相比之下,增量目标检测的研究仍处于初级阶段,这是因为与图像分类相比目标检测的任务目标和所用模型更加复杂,前者既要进行类别识别,还要进行预测框回归。增量目标检测(Incremental Object Detection, IOD)指当检测器连续接收新类别样本时,需要逐步识别和定位新对象,且不发生遗忘。目前,IOD领域已经取得阶段性成果,其中大多数方法只关注模型在学习过程中的抗遗忘能力,简单保留模型在已学习任务上的性能,如知识蒸馏^[3-5]和记忆重放^[6]等方法,忽略了模型在学习过程中的知识积累和迁移,没有持续提高模型对新任务的泛化能力。

得益于大脑中强大的记忆机制,人类可以连续快速学习新任务而不会忘记^[7]。其中,工作记忆提供了一个接口,用于将内在(大脑中短时记忆中的一些信息)和外部(来自外部世界的感知信息和短时记忆)信息联系起来^[8-9],快速处理当前任务。在此过程中,工作记忆不断重复旧信息,以在短期内激活和保存知识。同时,大脑将这些短时记忆抽象为模板信息,形成具有很强泛化能力和迁移能力^[10-11]的长时记忆。

受人脑中工作记忆和长时记忆的启发,本文提出了一种融合编解码记忆重放机制的增量元学习方法,该方法对已学习样本的特征向量进行编码压缩存储和解码重放,从而将增量学习过程中模型接收的不稳定数据流近似为动态稳定的数据集,缓解了灾难性遗忘问题。同时,算法为模型设计了一个双循环结构在线元学习策略,模型在内循环对由接收的新样本和回放的旧样本组成的多批次数据进行随机梯度下降,并在外循环基于不同批次的梯度更新进行参数元更新,获得一段时间内学习到的多任务间的共同结构。这种学习策略有助于模型在增量学习过程中不断提取和抽象同一任务族的模板信息,提高模型的泛化能力,快速适应遇到的新类。

最后,我们基于Fast RCNN^[12]目标检测框架实现了所提算法,并在通用数据集PASCAL VOC 2007^[13]和MS COCO 2014^[14]上设置了3类增量目标检测实验,它们分别是基于任务的、基于类的和在线的增量目标检测实验,并将所提算法与经典的和最先进的增量目标检测方法进行了比较。实验结果表明,所提算法在VOC和COCO的3个IOD设置中优于其他方法。此外,分别对比研究了所提算法在帮助模型抵抗

灾难性遗忘和提高泛化性方面的能力。实验结果表明,与其他方法相比,所提算法可以更好地帮助模型抵抗遗忘并泛化到新任务上。本文的主要贡献如下:

(1)本文工作侧重于研究同时帮助模型抵抗遗忘和提高泛化能力的增量目标检测算法。

(2)受人脑中记忆机制的启发,本文提出了一种融合编解码记忆重放机制的增量元学习方法,该方法可以帮助模型抵抗灾难性遗忘并更好地泛化到新任务上。

(3)本文在通用目标检测数据集PASCAL VOC 2007和MS COCO 2014上设置了3种IOD实验,结果表明所提算法使模型具有更好的抗遗忘能力,并且在增量学习期间更容易泛化到新任务上。

2 相关工作

2.1 增量目标检测

增量学习指模型不断从顺序接收的数据中学习新任务,且不遗忘旧任务。目前,增量学习方法广泛应用于各种人工智能任务,尤其是分类任务^[15-22]。增量目标检测比增量图像分类更复杂,也更具有挑战性。因为目标检测是多目标任务,需要同时完成分类和回归,而且使用的模型不是简单的单一模型,而是多个网络结构混合的模型。针对这一问题,Konstantin等^[3]将知识蒸馏思想应用于目标检测中,提出了平衡新旧类之间交互的损失函数和减少模型对旧类的响应差异的蒸馏函数。但是,LFwIOD不是端到端训练,它只更新最后的分类和回归层。Hao等^[4]基于LFwIOD提出了一种应用知识蒸馏思想的端到端IOD方法。Peng等^[23]则将知识蒸馏思想应用于更复杂的目标检测框架Faster RCNN来进行增量学习。Joseph等^[24]使用聚类方法帮助模型在开放世界中表现更好,同时避免灾难性遗忘。Zhang等^[25]提出了深度模型巩固的增量学习方法。该方法的核心想法是,首先使用标记数据为新类训练一个单独检测模型,然后使用公开可用的未标记辅助数据,通过一个双蒸馏训练目标合并新旧模型。与上述方法不同,Mano等^[6]使用更真实的在线学习训练协议来评估IOD方法。RODEO通过存储和重放图像特征向量来帮助模型在学习期间不发生遗忘。Joseph等^[26]虽然使用了元学习方法来约束未来模型的梯度变化方向,防止新任务的学习干扰旧任务的性能,但它忽略了模型泛化到新任务的能力或不对其进行研究。上述增量目标检测方法只关心如何帮助模型缓解灾难性遗忘问题,而忽略了模型需要在学习过程中积累知识、提高模型泛化能力这一增量学习中的关键问题。

2.2 元学习

元学习方法可以帮助模型快速泛化到具有少量样本的新任务上,包括基于优化的方法^[27-29]、黑盒适应方法^[30-31]和非参数方法^[32-33]。MAML^[27]作为一种与模型无关的元学习算法被广泛使用。MAML直接对模型参数 θ 进行优化,通过在满足

$P(T)$ 概率分布的任务集上最小化目标函数,来不断更新模型参数 θ' ,以获取任务集的通用表达。目标函数可以写成:

$$\min_{\theta} \sum_{T_i \sim P(T)} L_{T_i}(f_{\theta_i'}) = \sum_{T_i \sim P(T)} L_{T_i}(f_{\theta} - \beta \nabla_{\theta} L_{T_i}(f_{\theta})) \quad (1)$$

图 1 给出了 MAML 通过交替向 3 个最优解流形 W_{i-1} , W_{i-2} 和 W_i 移动获得的迭代序列,模型参数最终收敛到最小化平均平方距离的点。这表明 MAML 旨在优化模型参数,使模型学习同一任务域的任务函数的模板函数,以便可以基于尽可能少的梯度步骤快速泛化到新任务上^[27]。Reptile^[28] 忽略高阶导数部分从而简化了 MAML,并验证了它与 MAML 具有相同的效果。

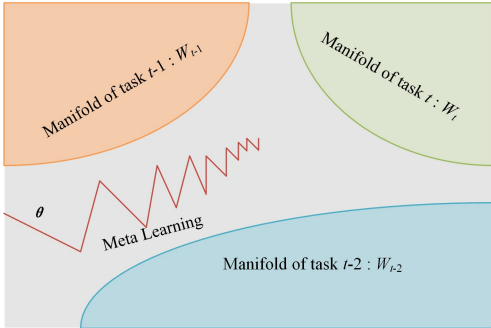


图 1 使用 MAML 算法的模型参数更新过程

Fig. 1 Model parameter updating process using MAML algorithm

3 本文方法

受人脑中记忆机制的启发,本文提出了一种融合编解码记忆重放机制的增量元学习方法。下面将详细介绍算法的具体步骤并证明它的有效性。虽然所提方法与模型无关,但我们使用经典的两阶段目标检测模型,即 Fast RCNN 来解释算法,并基于此进行验证实验。

算法 1 受人脑记忆机制启发的增量目标检测

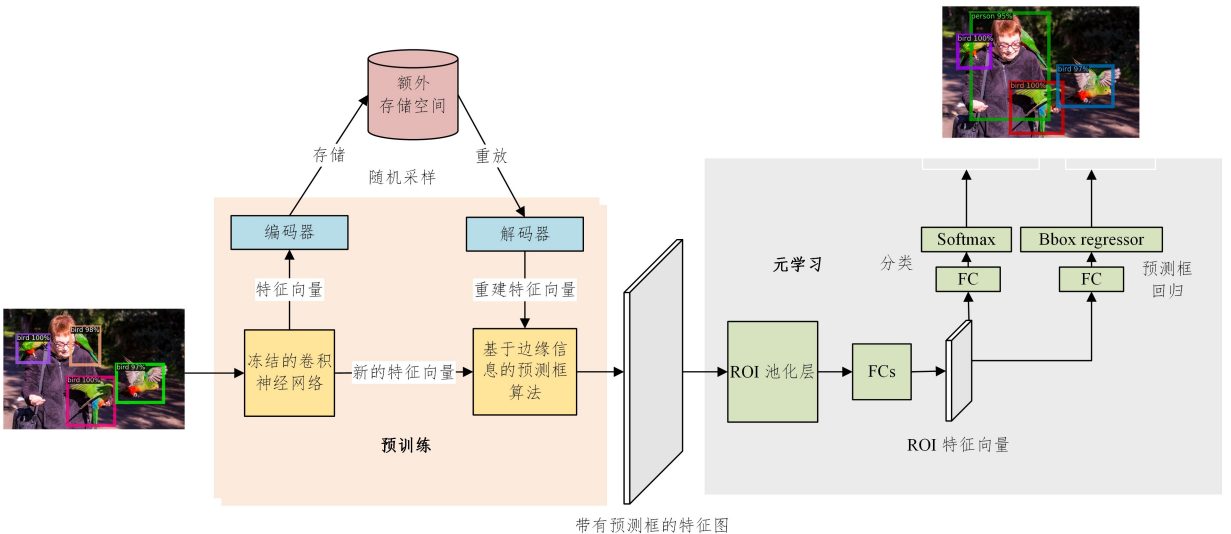
输入:模型参数 θ_0 ,任务 t 的流数据 D_t ,重放样本的数量 r_s ,额外存储空间 M ,注意力系数 s ,内循环学习率 β ,外循环学习率 γ
 输出:模型参数 θ

初始化:在基类上离线训练整个目标检测模型;在特征图上训练编解码器和解码器;使用来自基类的编码向量初始化重放缓冲区;获取基于边缘信息的预测框算法

1. for(x,y) in D_t do
2. $B = \text{sample}(r_s, M)$ 随机抽取样本
3. $B' = \text{Decoder}(B)$
4. for $i = 1, 2, \dots, r_s$ do
5. $x_i, y_i = B'[i]$
6. $\theta_i = \text{SGD}(x_i, y_i, \theta_{i-1}, \beta)$
7. end for
8. $\theta_{\text{end}} = \text{SGD}(x, y, \theta_{r_s}, s\beta)$
9. $\theta = \theta_0 + \gamma * (\theta_{\text{end}} - \theta_0)$
10. $M = M \cup F(x, y)$ 随机存储样本

3.1 增量目标检测器

由第 1 节介绍的人脑的记忆机制可知,模型通过一个个基于工作记忆的短时学习来抽象获取长时记忆信息,从而达到积累知识的目的。MAML 算法具有类似提取模板信息的作用,如第 2.2 节所述,MAML 算法通过元更新模型参数,来学习一组模型函数的函数,使其可以通过一个或少量梯度更新步骤快速泛化到新任务上。这样学习到的模型参数类似于大脑在学习一组相似任务时得到的模板信息。Reptile 算法可以达到与 MAML 算法近似的效果,而且计算步骤比后者更简单。根据 Reptile^[28] 的公式推导,当模型可微时,Reptile 算法才近似达到 MAML 算法的效果。由于 Fast RCNN 是双阶段目标检测框架,需要使用选择性搜索算法或其他方法为后面的目标检测提供候选区域,因此其不是端到端可微的,算法不可以对整个模型进行端到端的元更新。Tian 等^[34] 的研究表明,基于海量数据的良好学习嵌入模型可能比复杂的元学习算法更有效。因此,如图 2 所示,我们首先在同一任务域中的大部分数据上训练好特征提取层,并在增量学习期间对其进行冻结。同时,我们还使用预训练好的基于边缘信息的候选区域选取算法。它是一种无监督方法,可以生成与类别无关的候选集。基于边缘信息的候选区域选取算法有利于模型在未来可能遇到的类别信息未知的增量学习环境中更好地进行连续目标检测。



带有预测框的特征图

注:橙色区域的模型都经过预训练,且在学习过程中固定;灰色区域中的模型在学习期间进行元更新

图 2 算法的总体流程图(电子版为彩图)

Fig. 2 Overall flow chart of algorithm

但正如增量目标检测所定义的那样,模型需要处理增量随机数据流,并且无法知道未来学习任务的数量。这不符合 Reptile 算法需要在固定任务集的固定数据集划分的多个子任务集上进行元学习^[28]的要求,Reptile 算法无法直接使用。因此,我们使用经典的经验重放方法将连续不稳定数据流近似为一个动态稳定数据集。由于特征提取层在增量学习的过程中是冻结的,为了减小经验重放时使用的额外存储空间的大小,并且对已学习过的数据进行隐私保护,我们对输入图片的某层特征向量进行编码压缩存储和解码重放,详细步骤将在 3.2 节中叙述。

尽管对数据进行了重放,可以将数据流近似为稳定数据集,但是由于模型在增量目标检测环境中只能接收到当前样本数据,无法接触到已学习的样本,并对未学习的样本一无所知,因此我们依然无法像 Reptile 算法一样基于大任务集划分的多个子任务集进行元学习。

受到人脑中工作记忆的启发,依据增量目标检测的实际情况,我们提出了一个双循环结构的在线元学习策略,将宏观上基于多个任务集的元更新转化为微观上针对单个接收样本的在线元学习。详细步骤将在 3.3 节叙述,同时在 3.4 节将利用数学公式推导简单证明这种双循环结构学习策略在帮助模型抵抗遗忘的同时还可以获取任务间的共同结构,提高泛化能力。如图 2 所示,我们只对 Fast RCNN 中的由两个全连接层、线性分类器和回归器组成的多层感知器头进行元更新。

3.2 存储和回放

本节将详细描述融合编解码的记忆重放机制。根据 3.1 节所述,在连续学习过程中,模型使用冻结的预训练好的特征提取器,因此算法存储和重放样本的特征向量而不是原始图像来将不稳定数据流近似为动态稳定数据集。为了进一步节省存储空间并提高数据隐私的安全性,我们使用一组 Encoder 和 Decoder 来压缩特征向量,如图 2 所示。这个 ED 使用预训练好的特征提取器进行预训练。在模型存储遇到新样本时,新样本首先经过特征提取层,随后输出的特征向量被编码器压缩并被储存在额外存储空间中。等到模型需要重放样本时,样本特征向量将被解码器解码恢复,并参与到训练中。

如算法 1 的第 2 行和第 10 行所示,我们使用随机采样和水库采样法来抽取存储旧样本,此方法确保之前接收到的任何样本都有 $1/N$ 的概率(N 是模型学习的样本总数)成为缓冲区中特定元素并被等概率地重放,最大限度地将不稳定数据流近似为稳定数据集。

3.3 在线元更新

在连续学习中,模型在线连续接收数据样本,不可访问过去和未来的数据。因此,不同于 Reptile 算法将模型在多个任务集上进行反复训练后进行元更新,我们针对连续学习环境提出针对单个样本的双循环在线元学习策略。

对于内循环来说,如算法 1 第 2-8 行所示,我们随机从额外存储空间提取 r_s 个旧样本与接收的新样本混合,并基于多个 mini-batch 进行 SGD 更新。当 r_s 过大时,旧样本与新样本比例严重失衡,使得模型缺少对新样本的关注,导致模型在新任务上的训练效果较差,这也与人类实际学习过程中的注意力机制不符。为解决这一问题,如算法 1 第 8 行所示,我们引入注意力系数 s 来调节模型在新样本上的学习率,从而根据重放

样本数量调节模型对新样本的关注度。对于外循环来说,就是模型接收到的多个 batch 新数据,针对单个 batch 数据,如算法 1 第 9 行所示,我们基于模型在内循环构造的多个 mini-batch 上的参数更新,利用元学习率 γ 进行最后的元更新。

双循环在线元学习策略使得模型可以在连续学习环境中针对模型接收到的局部数据进行元更新,而不用获取数据的任务种类和数量等宏观信息。下面我们从数学的角度来证明此策略拥有抵抗遗忘和提高泛化性的能力。

3.4 连续性和迁移性证明

本节用数学公式简单证明了所提算法的编解码记忆重放机制和双循环在线元学习策略在增量学习过程中帮助模型抵抗遗忘的同时,还能提高其在新任务上的泛化能力。假设定义算法中的内循环是 mini-batch,外循环是 batch,算法的推导和证明是在 2 mini-batch 和 2 batch 的设置下进行的,以此类推。另外,根据上述对增量目标检测环境的描述,模型接收和回放的所有数据都是随机且任务无关的。我们使用 Reptile^[28]中的一些定义和公式来辅助推导证明。

i, k 和 j, l 分别代表 batch 和 mini-batch 的序号。 g_{ij}^k 和 H_{ij}^k 指在 SGD 过程中点 kl 计算的关于 ij 的梯度值和海森矩阵, \bar{g}_{ij} 和 \bar{H}_{ij} 表示在初始点的梯度和海森矩阵。如果 $k = i$ 和 $l = j$, 则 $g_{ij}^k = g_{ij}$, $H_{ij}^k = H_{ij}$ 。其中, $g_{ij}^k = \frac{\partial L(\theta_{ij})}{\partial \theta_{kl}}$, $\bar{g}_{ij} = \frac{\partial L(\theta_{ij})}{\partial \theta_{00}}$, $H_{ij}^k = \frac{\partial^2 L(\theta_{ij})}{\partial^2 \theta_{kl}}$, $\bar{H}_{ij} = \frac{\partial^2 L(\theta_{ij})}{\partial^2 \theta_{00}}$ 。

$$\theta_{ij+1} = \theta_{ij} - \alpha g_{ij} \quad (2)$$

$$\theta_{i+10} = \theta_{i0} + \beta(\theta_{i2} - \theta_{i0}) \quad (3)$$

假设经过 2 mini-batches 和 2 batches 的数据训练后,参数的梯度为 g_{MRIOD} , $\theta_{20} = \theta_{00} + g_{\text{MRIOD}}$ 。之后通过式(2)、式(3)得到:

$$g_{\text{MRIOD}} = -\alpha\beta(g_{00} + g_{01} + g_{10} + g_{11}) \quad (4)$$

g_{ij} 先泰勒展开,再代入等式(2), $g_{ij} = \bar{g}_{ij} + O(\alpha)$, 获得如下公式:

$$\begin{aligned} g_{ij} &= \bar{g}_{ij} + \bar{H}_{ij}(\theta_{ij} - \theta_{00}) + O(\|\theta_{ij} - \theta_{00}\|^2) \\ &= \bar{g}_{ij} - \alpha \bar{H}_{ij} \sum_{s=0}^{j-1} \bar{g}_{is} + O(\alpha^2) \end{aligned} \quad (5)$$

基于式(5)获得如下公式:

$$g_{00} + g_{01} = \bar{g}_{00} + \bar{g}_{01} - \alpha \bar{H}_{01} \bar{g}_{00} + O(\alpha^2) \quad (6)$$

对 g_{10} 进行泰勒展开,代入式(2)、式(3)得到:

$$g_{10} = \bar{g}_{10} + \bar{H}_{10}(\theta_{10} - \theta_{00}) + O(\alpha^2) \quad (7)$$

$$= \bar{g}_{10} - \alpha\beta \bar{H}_{10} \bar{g}_{00} - \alpha\beta \bar{H}_{10} \bar{g}_{01} + O(\alpha^2) \quad (8)$$

基于 θ_{10} 对 g_{11} 进行泰勒展开:

$$g_{11} = \bar{g}_{11} - \alpha \bar{H}_{11}^{10} \bar{g}_{10} + O(\alpha^2) \quad (9)$$

采用泰勒展开式,发现可以转换 Hessian 表达式为:

$$\bar{H}_{11}^{10} = \bar{H}_{11} + O(\alpha) \quad (10)$$

基于 θ_{00} 对 g_{10}^{10} 进行泰勒展开:

$$\bar{g}_{10}^{10} = \bar{g}_{11} + \bar{H}_{11}(\theta_{10} - \theta_{00}) + O(\alpha^2) \quad (11)$$

$$= \bar{g}_{11} - \alpha\beta \bar{H}_{11} \bar{g}_{00} - \alpha\beta \bar{H}_{11} \bar{g}_{01} + O(\alpha^2) \quad (12)$$

然后,将方程(8)和方程(6)代入方程(5),得:

$$g_{11} = \bar{g}_{11} - \alpha\beta \bar{H}_{11} \bar{g}_{00} - \alpha\beta \bar{H}_{11} \bar{g}_{01} - \alpha \bar{H}_{11} \bar{g}_{10} + O(\alpha^2) \quad (13)$$

如果样本和顺序是随机的,则以下等式成立:

$$\mathbb{E}[\bar{\mathbf{H}}_{ij} \bar{\mathbf{g}}_{kl}] = \mathbb{E}[\bar{\mathbf{H}}_{kl} \bar{\mathbf{g}}_{ij}] = \frac{1}{2} \mathbb{E}\left[\frac{\partial}{\partial \theta_{00}} (\bar{\mathbf{g}}_0 \cdot \bar{\mathbf{g}}_1)\right] \quad (14)$$

然后,将方程(6)、方程(8)、方程(13)和代入方程(4), β 为常数。如果 $\beta=1$,我们得到以下结果:

$$\mathbb{E}[\mathbf{g}_{\text{MRIOD}}] = \mathbb{E}\left[-\alpha\beta \left(\sum_{i=1}^B \sum_{j=1}^b \bar{\mathbf{g}}_{ij} - \alpha Z\right)\right] \quad (15)$$

$$Z = \sum_{i=0}^1 \sum_{j=0}^1 \sum_{k=0}^{i-1} \sum_{l=0}^{j-1} \bar{\mathbf{H}}_{kl} \bar{\mathbf{g}}_{ij}$$

如果 batch 和 mini-batch 的数量是 B 和 b , 我们可推得如下参数方程。

$$\begin{aligned} \theta &= \arg \min_{\theta} \mathbb{E}_{(x,y) \sim M} \left[2 \sum_{i=1}^B \sum_{j=1}^b [L(x_{ij}, y_{ij}) - Q] \right] \\ Q &= \sum_{k=1}^{i-1} \sum_{l=1}^{j-1} \alpha \frac{\partial L(x_{ij}, y_{ij})}{\partial \theta} \cdot \frac{\partial L(x_{kl}, y_{kl})}{\partial \theta} \end{aligned} \quad (16)$$

如等式(16)所示, $L(x_{ij}, y_{ij})$ 表示模型在所有已学习数据的损失, Q 是模型在不同样本上获得的梯度之间的内积,若此内积大于零,则表示样本间发生迁移。这表明本文算法既可以使 θ 接近“联合训练”的最小值,帮助模型抵抗遗忘,还可以增强样本间的迁移,提高模型泛化能力。

4 实验和分析

本节在两个通用的目标检测数据集上设置了3种增量目标检测实验,来评估所提算法的性能。此外,我们还分析了所有方法的抗遗忘和泛化能力。下面将介绍一些实验细节和结果并对其进行分析。

4.1 数据集和评测指标

所有的实验都是在 PASCAL VOC 2007^[13] 和 MS COCO 2014^[14] 上进行的。PASCAL VOC 2007 包含 20 个类别的 9963 个图像和 24640 个标签,其中一半为训练集和验证集,其余用于测试。MS COCO 2014 包含来自 80 个不同类别的 83000 张图像,验证集中有 41000 张图像。由于它的测试集不可用,我们使用整个验证集作为测试集。

我们使用 0.5 IoU 阈值(mAP@50)的平均精度作为两个数据集的主要评估指标。

4.2 训练方式和对比对象

为了验证所提算法在增量目标检测上的优越性,我们基于两个数据集设置3种增量目标检测实验,即基于任务、基于类和在线增量目标检测。

正如 3.1 节所述,模型首先将一部分类别划分为基类,并用其对模型进行初始化。对于基于任务的增量目标检测,模型初始化后逐步学习多个任务,每个任务包含多个类别^[3],这显然比学习识别一个类别更复杂。基于类的增量目标检测遵循 MetaIOD^[26] 中的设置,模型一次学习一个类。对于上述设置中的所有实验,在基类初始化之后,模型一次提供包含单个

新任务或类的所有数据,这些数据允许循环使用。但对于在线 IOD 实验,我们遵循 RODEO^[6] 的设置,模型一次在线接收一个数据,且每个数据样本只能观察一次。

我们根据不同方法的特点为不同的 IOD 实验选择对比对象。例如,ORE 不能在线 IOD 实验中运行,因此其不能作为这个实验的对比对象。RODEO^[6] 和 SLDA+Stream-Regress^[6] 只能应用于在线设置^[6]。所有实验的对比对象都包括上限和下限,上限是在离线设置中一次性使用整个数据集对模型进行训练,下限是在增量学习环境中只对检测模型进行微调,不使用任何增量目标检测算法,它将遭受严重的灾难性遗忘。ILwFOD^[3], RODEO^[6] 和 SLDA+Stream-Regress 使用带有候选框算法和 ResNet50 主干的 Fast RCNN 架构。SLDA+Stream-Regress 是 SLDA 与流回归模型相结合的模型。Faster ILOD^[23], ORE^[24], DMC^[25] 和 MetaIOD^[26] 均基于 Faster RCNN 模型进行实验验证。

在学习了每个新的类/任务后,每个模型都在测试数据上进行评估。然而,由于 COCO 比 VOC 大得多,评估需要更长的时间,我们每训练 10 个新类别就评估一次模型。

4.3 实现细节

我们使用 Product Quantizer 进行编解码,该方法的优点是较小的编码表达了非常多的编码,从而节省了存储空间。我们使用数据集的基类数据(VOC 和 COCO 分别为 1-10 和 1-40)训练编码器和解码器。对于 VOC,我们使用内存中的所有特征图来训练编码器和解码器。对于 COCO,我们从每张图像的完整特征图中下采样 30 个随机位置来训练 Encoder 和 Decoder。为了使实验公平,我们将存储旧样本的额外存储空间限制为 510 MB,这是 ILwFOD 和 RODEO 所需的内存量。所有模型都使用相同的网络初始化过程,所有模型都使用随机梯度下降进行优化,更多细节可以在补充材料中找到。

4.4 实验结果

4.4.1 基于任务的增量目标检测

在基于任务的 IOD 中,我们在 VOC 和 COCO 上分别选择 10 和 40 个类作为基类,并将其余类分组为单个新任务。如表 1 和表 2 所列,本文方法在 VOC 和 COCO 上增量学习的新任务的 mAP 明显优于其他方法。同时,相比表 1 中其他方法新任务中每个类别的 AP 参差不齐、性能表现不均衡,本文方法在新任务上每个类别的表现都处于前列,性能均衡,更符合实际意义上的增量学习。由表 1 可以发现,基类的 mAP 仅略低于 MetaIOD,但新任务中几乎所有类的 mAP 都远高于其他方法,这表明本文方法可以在增量学习过程中提高模型对新任务的泛化能力。

表 1 VOC 上基于任务的增量目标检测的精度对比

Table 1 Class AP and overall mAP of task-based incremental object detection on VOC

(单位:%)

方法	基类	Table	Dog	Horse	Bike	Person	Plant	Sheep	Sofa	Train	Tv	mAP
Fine tune*	14.7	57.6	57.1	72.6	67.5	73.9	33.5	53.4	61.1	66.5	57.0	37.3
ILwFOD*	63.2	59.7	72.7	73.5	73.2	63.9	29.5	63.4	61.6	69.3	62.2	63.1
Faster ILOD*	69.8	36.7	70.9	66.8	67.6	66.1	24.7	63.1	48.1	57.1	43.6	62.2
ORE*	60.4	56.1	70.4	80.2	72.3	81.8	42.7	71.6	68.1	77.0	67.7	64.6
DMC*	65.9	61.5	67.7	67.5	52.2	74.0	37.8	63.0	55.5	65.3	72.4	63.8
MetaIOD*	68.4	60.1	66.4	76.0	72.6	74.6	39.7	64.0	60.2	68.5	60.5	66.3
MRIOD	67.0	60.6	81.2	82.4	76.1	73.3	36.6	66.2	65.6	73.9	69.2	67.7
Offline*	74.7	71.9	83.0	85.4	81.5	82.7	49.4	74.4	75.1	79.6	73.6	75.2

注:*表示我们使用具有相同实验设置的数据^[26]。我们的方法使用 $\gamma=0.8, r_s=8, s=2$

表 2 COCO 上基于任务的增量目标检测的精度对比
Table 2 AP, mAP and AP75 of task-based incremental object detection on COCO


方法	AP	mAP	AP ⁷⁵
ILwFOD*	21.3	37.4	—
Faster ILOD*	20.6	40.1	—
MetaIOD*	23.8	40.5	24.4
MRIOD	27.6	42.8	25.3
Offline*	31.5	50.9	33.5

注: * 表示我们使用具有相同实验设置的数据[26]。
我们的方法使用 $\gamma=0.8, r_s=4, s=3$

这些结果表明,所提方法在基于任务的增量目标检测实验中具有 SOTA 性能,同时具有很好的抵抗遗忘和迁移泛化的能力,而且新任务的单个类别性能表现均衡,这表明本文方法可以更好地增量学习复杂任务。

4.4.2 基于类的增量目标检测

在基于类的 IOD 中,选择了 15 个类作为 VOC 的




注:对于 MRIOD,本文中 $r_s=8, \gamma=0.8$ 和 $s=2$

图 3 模型逐步学习 5 个新类的过程

Fig. 3 Process of model learns five new classes incrementally

4.4.3 在线增量目标检测

与上面的批处理学习相比,模型在在线增量目标检测设置中学习更多的新任务,一次只接收一个样本,这更现实且更难。在在线 IOD 实验中,只使用 ILwFOD^[3], RODEO^[6] 和



注:对于 VOC 上的 MRIOD,本文中 $r_s=12, \gamma=0.8$ 和 $s=2$; 对于 COCO 上的 MRIOD,本文中 $r_s=4, \gamma=0.8$ 和 $s=2$

图 4 本文模型在 VOC 和 COCO 上在线增量学习 10 和 40 个新类的过程

Fig. 4 Process of model learns 10 and 40 new classes online incrementally on VOC and COCO

如图 4(a) 所示,本文方法远远优于 IFwIOD 和 SLDA+Stream-Regress,并且比 RODEO^[2] 的性能略好,在 VOC 中其 MAP 比 RODEO^[2] 高 1.6% (RODEO^[2] 为 65.0% 和 MRIOD 为 66.6%)。如图 4(b) 所示,本文方法优于所有其他方法。如图 4(c) 和图 4(d) 所示,虽然在 VOC 上本文方法和 RODEO 的性能比较接近,但是可以发现本文方法在基类的 mAP 和

基类,然后模型逐步学习多个类别。与上述实验相比,本实验学习了更多的新任务,模型更容易忘记最初学习的任务。图 3(a) 给出了模型每学习完新类后的 mAP。如图 3(a) 所示,在本文算法连续学习了 5 个新类后,性能优于其他方法,这验证了本文方法在基于类的 IOD 中具有更好的增量目标检测能力。同时,从图 3(a) 可以看出,本文方法在增量学习时准确率是平稳的,而其他方法则有明显下降趋势。为了进一步研究本文算法的优越性,分别记录了模型在增量学习过程中基类的性能和模型首次学习新类时的 AP,如图 3(b) 和图 3(c) 所示。如图 3(b) 所示,与在其他学习过程中基类 mAP 持续下降的方法相比,本文方法稳定地保持了模型在基类上的性能,这表明本文方法比其他方法更能抵抗灾难性遗忘。如图 3(c) 所示,与其他方法相比,本文方法可以更好地泛化到新类上,这有力地证明了本文方法在学习过程中可以提高模型对新任务的泛化能力。

SLDA+Stream-Regress^[6] 作为比较方法,因为其他方法无法在此设置下运行。模型在 VOC 和 COCO 中分别学习 10 和 40 个新任务。图 4(a) 和图 4(b) 给出了增量学习期间所有学习任务的 mAP。

新类的 AP 变化方面具有更好的性能,这表明本文方法具有更好的抗遗忘和泛化能力。

4.4.4 MRIOD 的消融实验

为了研究本文方法,我们对控制元更新学习率的权重因子 γ 和 s 进行敏感性分析,结果如表 3 所列。从表中可以看到,与 γ 相比,随着 s 的增加, mAP 下降得更快,这表明 γ 对

最终结果的影响小于 s 。

表3 不同 γ 和 s 的结果

Table 3 Results with different γ and s

$\gamma \setminus s$	2	4
0.1	63.1	63.5
0.3	65.4	65.1
0.5	66.1	64.6
0.8	66.6	64.9

注:在 VOC 的在线 IOD 中, $rs=12$

结束语 现有的增量目标检测方法大多只注重缓解增量学习中的灾难性遗忘问题,简单保留旧任务的性能,并不通过积累知识来获得模板信息,不能在抵抗遗忘的同时更好更快地学习新任务。这与人类的学习过程非常不一致。人类可以不断地对学习的任务进行提取和抽象,以获取同一任务族中的模板信息。因此,受人脑中记忆机制的启发,我们提出了一种融合编解码记忆重放机制的增量元学习方法,其灵感来自工作记忆工作机理和长时记忆形成过程,该方法对已学习样本的特征向量进行编码存储和解码重放,将不稳定数据流近似为动态稳定数据集,从而缓解了灾难性遗忘问题。同时,设计了一个双循环学习策略,使模型参数基于多批次随机梯度更新进行元学习,从而获得多任务间的共同结构,使模型具有良好的泛化性能,能够快速适应学习中遇到的新类。我们针对 FastRCNN 的特点将算法应用于其上,并在两个基准数据集上的 3 个不同的增量目标检测实验中验证算法的优越性,结果显示所提算法优于目前最先进的方法。此外,我们还研究了某些特定参数对算法中实验效果的敏感性。虽然我们在这项工作中只使用 Fast RCNN 作为基础模型,但由于所提算法针对梯度更新提供学习策略,因此算法与模型无关。未来,我们可以将算法扩展到更复杂的目标检测器上,例如单阶段检测器^[35-37]和更复杂的任务,如动作识别^[38]、对象计数^[39]和实例分割^[40]等。

参考文献

- [1] MICHAEL M, NEAL J C. Catastrophic interference in connectionist networks: The sequential learning problem[M] // Psychology of Learning and Motivation. Academic Press, 1989: 109-165.
- [2] RAIH H, DUSHYANT R, ANDREI A R, et al. Embracing change: Continual learning in deep neural networks [J]. Trends in Cognitive Sciences, 2020, 24(12): 1028-1040.
- [3] KONSTANTIN S, CORDELIA S, KARTEEK A. Incremental learning of object detectors without catastrophic forgetting [C] // IEEE International Conference on Computer Vision, 2017: 3420-3429.
- [4] HAO Y, FU Y W, JIANG Y G, et al. An end-to-end architecture for class-incremental object detection with knowledge distillation [C] // IEEE International Conference on Multimedia and Expo, 2019: 1-6.
- [5] CHEN L, YU C Y, CHEN L C. A new knowledge distillation for incremental object detection [C] // International Joint Conference on Neural Networks, 2019: 1-7.
- [6] MANO A, TYLER L H, CHRISTOPHER K. RODEO: replay for online object detection [C] // British Machine Vision Conference, 2020.
- [7] ALAN B. Working memory [J]. Science, 1992, 255: 556-559.
- [8] ALAN B. The episodic buffer: a new component of working memory? [J]. Trends in Cognitive Sciences, 2000, 4(11): 417-423.
- [9] PATRICIA S, GOLDMAN R. Regional and cellular fractionation of working memory [J]. Proceedings of the National Academy of Sciences of the United States of America, 1996, 93(24): 13473-13480.
- [10] CHARLE H, SARAH M, GORDON D B. Memory for familiar and unfamiliar words: Evidence for a long-term memory contribution to short-term memory span [J]. Journal of Memory and Language, 1991, 30(6): 685-701.
- [11] PHILIP G, VINCENT F C, SAMUEL S, et al. The long and the short of long-term memory — a molecular framework [J]. Nature, 1986, 322(6078): 419-422.
- [12] ROSS G. Fast r-cnn [C] // IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [13] MARK E, AE S M, LUC V G, et al. The pascal visual object classes challenge: A retrospective [J]. International Journal of Computer Vision, 2015, 111(1): 98-136.
- [14] TSUN Y L, MICHAEL M, SERGE B, et al. Microsoft COCO: Common Objects in Context [C] // European Conference on Computer Vision, Berlin: Springer, 2014: 740-755.
- [15] DAVUD L, MARC A R. Gradient episodic memory for continual learning [C] // Advances in Neural Information Processing Systems. Curran Associates, Inc, 2017: 6470-6479.
- [16] SYLVESTRE A R, ALEXANDER K, GEORG S, et al. icarl: Incremental classifier and representation learning [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5533-5542.
- [17] DUSHYANT R, FRANCESCO V, ANDREI A R, et al. Continual unsupervised representation learning [C] // Advances in Neural Information Processing Systems. Curran Associates, Inc, 2019: 7645-7655.
- [18] ARSLAN C, ALBERT G, PUNEET K D, et al. Using hindsight to anchor past knowledge in continual learning [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 6993-7001.
- [19] JAMES K, RAZYAN P, NEIL R, et al. Overcoming catastrophic forgetting in neural networks [J]. Proceedings of the National Academy of Sciences of the United States of America, 2017, 114(13): 3521-3526.
- [20] PRAVENDRA S, VINAY K V, PRATIK M, et al. Calibrating cnns for lifelong learning [C] // Advances in Neural Information Processing Systems. Curran Associates, Inc, 2020: 15579-15590.
- [21] JAEHONG Y, SAEHOON K, EUNHO Y, et al. Scalable and order-robust continual learning with additive parameter decomposition [C] // International Conference on Learning Representations, 2020.

- [22] EKIN D C, BARRET Z, DANDELION M, et al. AutoAugment: Learning Augmentation Policies from Data[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:113-123.
- [23] PENG C, ZHAO K, BRIAN C L. Faster ilod: Incremental learning for object detectors based on faster rnn [J]. Pattern Recognition Letters, 2020, 140: 109-115.
- [24] JOSEPH K J J, SALMAN K, FAHAD S K, et al. Towards open world object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 5830-5840.
- [25] ZHANG J T, ZHANG T, SHALINI G, et al. Class-incremental learning via deep model consolidation [C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. 2020.
- [26] JOSEPH K, JATHUSHAN R, SALMAN K, et al. Incremental object detection via meta-learning [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021, 44 (22): 9209-9216.
- [27] CHELSEA F, PIETER A, SERGEY L. Model agnostic meta-learning for fast adaptation of deep networks[C]// Proceedings of the 34rd International Conference on Machine Learning. 2017:1126-1135.
- [28] ALEX N, JOSHUA A, JOHN S. On first-order meta-learning algorithms [J]. arXiv:1803.02999, 2018.
- [29] ANDREI A R, DUSHYANT R, JAKUB S, et al. Meta-learning with latent embedding optimization[C]// International Conference on Learning Representations. 2019.
- [30] ADAM S, SERGEY B, MATTHEW B, et al. Meta-learning with memory-augmented neural networks[C]// Proceedings of The 33rd International Conference on Machine Learning. 2016: 20-22.
- [31] MISHRA N, ROHANINEJAD M, CHEN X, et al. Meta-learning with temporal convolutions [J]. arXiv:1707.03141, 2017.
- [32] JAKE S, KEVIN S, RICHARD Z. Prototypical networks for few-shot learning[C]// Advances in Neural Information Processing Systems. Curran Associates, Inc, 2017.
- [33] FLOOD S, YONGXIN Y, LI Z, et al. Learning to compare: Relation network for few-shot learning [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018.
- [34] TIAN Y L, WANG Y, DILIP K, et al. Rethinking few-shot image classification: A good embedding is all you need? [C]// European Conference on Computer Vision. Berlin: Springer, 2020:266-282.
- [35] WANG T C, RAO M A, HISHAM C, et al. Learning rich features at high-speed for single-shot object detection[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019.
- [36] NIE J, RAO M A, HISHAM C, et al. Enriched feature guided refinement network for object detection[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019.
- [37] PANG Y W, WANG T C, RAO M A, et al. Efficient featured image pyramid network for single shot detector[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019.
- [38] FAHAD S K, XU J L, JOOST V D W, et al. Recognizing actions through action-specific person detection [J]. IEEE Transactions on Image Processing, 2015, 24(11): 4422-4432.
- [39] JIALE C, HISHAM C, RAO M A, et al. D2det: Towards high quality object detection and instance segmentation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020.
- [40] HISHAM C, SUN G L, FAHAD S K, et al. Object counting and instance segmentation with image-level supervision[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019.



SHANG Di, born in 1998, postgraduate, is a student member of China Computer Federation. Her main research interests include computer vision, incremental learning and few shot learning.



LYU Yanfeng, born in 1985, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include robot vision, brain-like computing, and incremental learning.

(责任编辑:喻黎)