

## 基于持续事件知识网络的持续社会事件分类研究

张袁, 张胜杰, 刘利龙, 钱胜胜

### 引用本文

张袁, 张胜杰, 刘利龙, 钱胜胜. 基于持续事件知识网络的持续社会事件分类研究[J]. 计算机科学, 2025, 52(8): 268-276.

ZHANG Yuan, ZHANG Shengjie, LIU Lilong, QIAN Shengsheng. [Research on Continual Social Event Classification Based on Continual Event Knowledge Network](#) [J]. Computer Science, 2025, 52(8): 268-276.

---

### 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)

#### [基于带毒分类器的自监督后门攻击防御方法](#)

Self-supervised Backdoor Attack Defence Method Based on Poisoned Classifier

计算机科学, 2025, 52(4): 336-342. <https://doi.org/10.11896/jsjcx.240100005>

#### [基于多模态双协同Gather Transformer网络的虚假信息检测方法](#)

Multi-modal Dual Collaborative Gather Transformer Network for Fake News Detection

计算机科学, 2024, 51(12): 242-249. <https://doi.org/10.11896/jsjcx.231000057>

#### [基于异质图神经网络预训练的多标签文档分类研究](#)

Pre-training of Heterogeneous Graph Neural Networks for Multi-label Document Classification

计算机科学, 2024, 51(1): 143-149. <https://doi.org/10.11896/jsjcx.230600079>

#### [基于对偶变分多模态注意力网络的不完备社会事件分类方法](#)

Dual Variational Multi-modal Attention Network for Incomplete Social Event Classification

计算机科学, 2022, 49(9): 132-138. <https://doi.org/10.11896/jsjcx.220600022>

#### [多媒体社会事件分析综述](#)

Survey of Multimedia Social Events Analysis

计算机科学, 2021, 48(3): 97-112. <https://doi.org/10.11896/jsjcx.210200023>

# 基于持续事件知识网络的持续社会事件分类研究

张袁<sup>1</sup> 张胜杰<sup>1</sup> 刘利龙<sup>1</sup> 钱胜胜<sup>2</sup>

<sup>1</sup> 郑州大学河南先进技术研究院 郑州 450000

<sup>2</sup> 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

(1584462772@qq.com)

**摘要** 随着互联网的快速发展和社交媒体规模的不断扩大,社会事件分类(Social Event Classification, SEC)越来越受到人们的关注。现有的社会事件分类研究侧重于识别一组固定的社会事件。然而,在现实世界中,社交媒体上会不断出现新的社会事件,这就需要一种实用的 SEC 模型能够迅速适应社会事件不断发展的环境。因此,研究了一个新的关键问题,即持续社会事件分类(C-SEC),在持续收集的社会数据中会不断出现新事件;提出了一种新颖的持续事件知识网络(Continual Event Knowledge Network, CEKNet),用于持续学习持续事件知识,以实现具有持续增量事件的 C-SEC 分类。所提出的持续学习框架由两个部分组成:当前事件知识学习和过去事件知识重放。首先,进行当前事件知识学习,学习当前输入数据中新出现事件的分类。其次,设计了具有知识自蒸馏功能的过去事件知识重放,以巩固所学到的过去事件知识,防止灾难性遗忘。在真实世界的社会事件数据集上进行的综合实验表明,与先进的方法相比,为 C-SEC 而提出的 CEKNet 更具优势。

**关键词:** 社会事件分类;类递增持续学习;持续事件知识

**中图分类号** TP391

## Research on Continual Social Event Classification Based on Continual Event Knowledge Network

ZHANG Yuan<sup>1</sup>, ZHANG Shengjie<sup>1</sup>, LIU Lilong<sup>1</sup> and QIAN Shengsheng<sup>2</sup>

<sup>1</sup> Henan Institute of Advanced Technology, Zhengzhou University, Zhengzhou 450000, China

<sup>2</sup> State Key Laboratory of Multimodal Artificial Intelligence Systems, Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China

**Abstract** With the rapid development of the Internet and the burgeoning scale of social media, social event classification(SEC) has garnered increasing attention. The existing study of SEC focuses on recognizing a fixed set of social events. However, in real-world scenarios, new social events continually emerge on social media, which suggests the necessity for a practical SEC model that can swiftly adapt to the evolving environment with incremental social events. Therefore, this paper studies a new yet crucial problem defined as continual social event classification(C-SEC), where new events continually emerge in the sequentially collected social data. Accordingly, this paper proposes a novel continual event knowledge network(CEKNet) to continually learn continual event knowledge for C-SEC with continually incremental events. The proposed continual learning framework consists of two components: present event knowledge learning and past event knowledge replay. Firstly, it conducts present event knowledge learning to learn the classification of newly emerging events in the presently incoming data. Secondly, it designs past event knowledge replay with self-knowledge distillation to consolidate the learned knowledge of past events and prevent catastrophic forgetting. Comprehensive experiments on real-world social event datasets demonstrate the superiority of the proposed CEKNet for C-SEC compared with state-of-the-art methods.

**Keywords** Social event classification, Class-incremental continual learning, Continual event knowledge

## 1 引言

互联网和多媒体技术的快速发展带动了 Twitter, Facebook 和 Google 等社交媒体平台的繁荣。与此同时,社交媒体上的热门事件也会在转贴和评论等用户互动的推动下迅速

在全球范围内传播。由多种模态(如图像、视频和文本)组成的各种社会事件在互联网上不断发生,这意味着从海量社交媒体数据中自动挖掘社会事件并对其进行分类具有重要意义。因此,社会事件分类(Social Event Classification, SEC)近年来受到越来越多的关注<sup>[1-3]</sup>。SEC 不仅在多模态数据挖掘

到稿日期:2024-06-24 返修日期:2024-10-16

基金项目:国家重点研发计划(2023YFC3310700);国家自然科学基金(62276257)

This work was supported by the National Key Research and Development Program of China(2023YFC3310700) and National Natural Science Foundation of China(62276257).

通信作者:钱胜胜(shengsheng.qian@nlpr.ia.ac.cn)

和分析领域具有学术价值<sup>[4-5]</sup>,在舆论感知<sup>[6-7]</sup>、危机响应<sup>[8-9]</sup>和内容推荐系统<sup>[10-11]</sup>等应用中也具有实际意义。

现有的 SEC 研究侧重于一次性从训练数据中学习,并对属于固定社会事件集的数据进行分类<sup>[12-14]</sup>。然而,在现实世界中,在社交媒体上会不断出现新的社会事件。在这种动态环境中,静态分类模型不足以识别新出现的社会事件。此外,持续学习(Continual Learning, CL)的研究日益流行<sup>[15-17]</sup>,其目的是开发能够从新收集的训练数据中持续学习的机器学习系统。受此启发,本文提出了一个新的关键问题,名为“持续社会事件分类”(Continual Social Event Classification, CSEC)。C-SEC 要求分类模型从按时间顺序收集的一系列训练数据中学习,并对属于所有学习事件的社会数据进行分类。本文对 C-SEC 的定义遵循了类递增 CL 的定义<sup>[18-20]</sup>。特别是,为了减少重复训练成本并提高对新数据的响应速度,CL 模型不能访问全部历史训练数据。由于用户隐私政策的修改和用户发起的数据删除操作也会阻止访问某些历史数据,因此这种设置在 SEC 领域具有额外的实际意义。

在对新数据进行训练时,神经网络通常可以从当前数据中学习知识,但在获取新数据后,却很难保持已经学习过的概念,这被称为灾难性遗忘问题<sup>[21]</sup>。现有的 SEC 方法大多假设有一组固定的社会事件要进行分类,而缺乏从社会事件增量的连续训练数据中学习的机制。因此,将现有的 SEC 方法直接应用于 C-SEC 通常会遇到灾难性遗忘问题,导致在 CL 环境中的性能不理想。因此,要执行 C-SEC,必须应对挑战 1:如何从持续收集的数据中持续学习,同时防止对已学知识的灾难性遗忘?

此外,现有的 CL 研究大多假设训练数据的顺序取决于数据收集的方式<sup>[22-24]</sup>。然而,在 C-SEC 中,社交媒体上的不同社会事件是按时间顺序自然发生的。因此,在 C-SEC 的实验环境中,本文假定不同的社会事件是按照真实世界的时间顺序连续出现的,从而与实际应用场景保持一致。为了有效地从时间上不断涌现的社会事件中学习,对顺序训练数据中固有的时序知识进行建模就成了一个重要问题。因此,要执行 C-SEC,必须应对挑战 2:如何在 C-SEC 的持续学习过程中对过去和现在社会事件的时序知识进行建模和学习?

为了应对 C-SEC 所面临的上述挑战,本文提出了一种新颖的持续事件知识网络(CEKNet),以便从连续收集的数据中不断学习时序事件知识并对动态 CL 环境中的增量社会事件进行分类。针对挑战 1,提出了一种过去事件知识重放方法,以便在从新输入的训练数据中学习时巩固所学到的过去事件知识。根据以往的 CL 研究<sup>[18-20]</sup>,保留了一个包含少量历史训练样本的存储器。与此不同的是,本文进一步提出了一种自适应置信度记忆更新,以存储少量当前训练样本的分类置信度,并在每个任务后进行自适应重新缩放。然后,通过知识自蒸馏,在内存中重放已学知识,以减轻对过去社会事件的灾难性遗忘。针对挑战 2,本文提出了一个由当前事件知识学习和过去事件知识重放组成的 CL 框架,以学习 C-SEC 的时间事件知识。对于新输入的数据,本文将事件分类器分为过去、现在和未来事件分类器。现在事件知识学习旨在学习新训练数据中的现在事件知识,并减少偏差,以防止过去和

未来分类器的退化。如前所述,过去事件知识重放的目的是巩固已经学到的过去事件知识。在真实世界的社会事件数据集上进行的综合实验表明,本文提出的方法在 C-SEC 方面明显优于目前最先进的方法。

总体而言,本文工作有以下几个贡献点:

1)研究了一项新颖实用的任务,即持续社会事件分类(C-SEC),在连续收集的社会数据中会不断出现新的社会事件。因此,本文提出了一种新颖的持续事件知识网络(CEKNet),用于从连续的训练数据中不断学习,并对增量社会事件进行分类。

2)为了克服 C-SEC 中的灾难性遗忘问题,本文提出了一种具有自适应置信度记忆更新和知识自蒸馏功能的过去事件知识重放方法,以便在从新输入的训练数据中学习时巩固所学到的过去事件知识。

3)为了在持续学习过程中对过去、现在和未来社会事件的时序知识进行全面建模,本文提出了一个由过去事件知识重放和现在事件知识学习组成的 CL 框架。

4)在 CrisisMMD<sup>[25]</sup>和 PHEME<sup>[26]</sup>等真实世界社会事件数据集上进行的大量实验表明,与 C-SEC 的先进方法相比,本文方法更具优势。

## 2 相关工作

### 2.1 社会事件分类

社会事件分类<sup>[27-30]</sup>旨在对社交媒体上的社会事件进行识别和分类。社会事件的识别也是推荐系统<sup>[31-32]</sup>、搜索引擎<sup>[33]</sup>和其他一些智能系统<sup>[34-35]</sup>的核心问题之一。随着近年来深度多模态学习的成功,研究人员开发了各种用于 SEC 的深度模型<sup>[12,14,36-38]</sup>。例如,Abavisani 等<sup>[12]</sup>提出了一种带有交叉注意模块的多模态融合方法,该模块可以在逐个样本的基础上过滤弱模态中的无信息成分和误导成分;Li 等<sup>[37]</sup>提出了一种多模态分类模型,并探讨了哪种类型的模态对灾难推文分类更有参考价值;Nguyen 等<sup>[39]</sup>提出了一种可解释的 SEC 模型,该模型集成了一个基于 GRU 的总结模块,以生成对分类结果的解释;最近,Qian 等<sup>[2]</sup>研究了开放世界的社会事件分类,其中未见事件可能会在测试中合并,并为 SEC 设计了一个开放世界分类器。然而,现有的 SEC 方法大多侧重于一次性从静态数据中学习,忽略了社交媒体中的动态变化。与此不同的是,本文提出了一个名为“持续社会事件分类(C-SEC)”的新问题,即要求模型从按时间顺序收集的连续训练数据中学习,并在学习过程中对增量社会事件进行分类。本文希望 C-SEC 的进展能进一步提升 SEC 模型的实用性并扩大其应用范围。

### 2.2 持续学习

近年来,针对缓解持续学习中固有的灾难性遗忘问题的方法逐渐引起广泛关注<sup>[15,17,21]</sup>,研究的目的是开发出一种既能适应输入数据分布变化,又能保留先前所学知识的模型。一般来说,持续学习方法可分为 4 类:正则化、任务新颖性偏差校正、网络扩展和重放。然而,前 3 类方法在长任务序列上可能会出现过度正则化或无约束参数增长的问题<sup>[40]</sup>。iCaRL<sup>[41]</sup>存储了一个示例子集,并在所学特征空间中选择最

佳近似类平均值。GEM<sup>[42]</sup>利用旧的训练数据,以明确的方式将梯度干扰降到最低。X-DER<sup>[22]</sup>对重放记忆进行修改,以接收有关过去数据的新信息,并为学习未见过的类别铺平道路。ESMER<sup>[20]</sup>采用了一种原则性机制来调节基于双记忆排演系统中的错误敏感性,该系统保留了对过去错误的记忆,并利用它来修改学习动态。TAMiL<sup>[18]</sup>包含任务注意模块,可从共同表征空间捕捉特定任务信息。与此不同的是,本文探讨了一个名为“持续社会事件分类”的新的实际问题,即在持续收集的训练社会数据中不断出现新的社会事件。此外,本文还提出了一种时序事件知识学习方法,为C-SEC所收集数据的时序特征建模,这在传统的CL任务中并不常见。

### 3 问题定义

本文提出了一个新的关键任务,名为“持续社会事件分类(C-SEC)”。对于按时间顺序收集的 $T$ 个任务的持续社会事件数据,连续收集的训练数据集为 $\mathfrak{S}=\{\mathcal{T}_1, \mathcal{T}_2, \dots, \mathcal{T}_t\}$ 。在第 $t$ 个任务期间,模型需要不断从训练数据 $T_t=\{x_t^i, y_t^i\}_{i=1}^{|\mathcal{T}_t|}$ 中学习。其中, $x_t^i=(p_t^i, v_t^i)$ 是第 $t$ 次训练的样本,包括帖子文本 $p_t^i$ 和附图 $v_t^i$ ,而 $y_t^i \in \mathcal{Y}_t$ 是社会事件标签。 $\mathcal{Y}_t$ 是 $\mathcal{T}_t$ 中出现的语义社会事件的集合,满足 $\mathcal{Y}_t \cap \mathcal{Y}_s = \emptyset, \forall t \neq s$ ,遵循类递增持续学习的设置<sup>[18-20]</sup>。在第 $t$ 个任务的测试中,模型需要对属于

所有历史训练数据中出现的社会事件 $\bigcup_{i=1}^t \mathcal{Y}_i$ 的测试社会数据 $\tilde{\mathcal{T}}$ 进行分类。需要注意的是,在类递增持续学习中,任务标识符(或任务标签)在测试中是不可用的。因此,必须为所有过去的社会事件训练一个统一的模型。在学习第 $t$ 个任务时,模型只能访问第 $t$ 个训练集 $\mathcal{T}_t$ 和存储数据,其中存储数据保存了少量历史训练样本的信息。因此,C-SEC面临的一个主要挑战是:在学习第 $t$ 个任务时,如何防止遗忘从之前 $(t-1)$ 个任务中学到的知识。

### 4 方法描述

图1展示了持续事件知识网络(CEKNet)的优化过程,其中包括在连续社会事件分类(C-SEC)的第 $t$ 个任务中的当前事件知识学习和过去事件知识重放。具体来说,首先,将第 $t$ 个任务的训练社会数据 $x_t^i=(p_t^i, v_t^i)$ 和存储数据 $x_t^m=(p_t^m, v_t^m)$ 分别投射到多模态融合特征 $f_t^i$ 和 $f_t^m$ 中。接着,通过当前空间的交叉熵损失和过去-未来约束来学习当前事件知识,以防止过去和未来分类器的退化。然后,进行过去事件知识重放,利用知识自蒸馏来回顾过去的事件知识。最后,在第 $t$ 次训练结束时,通过蓄水池采样将 $\{(x_t^i, l(x_t^i), y_t^i)\}_{i=1}^{|\mathcal{T}_t|}$ 中的少量样本随机添加到内存 $\mathcal{M}$ 中。

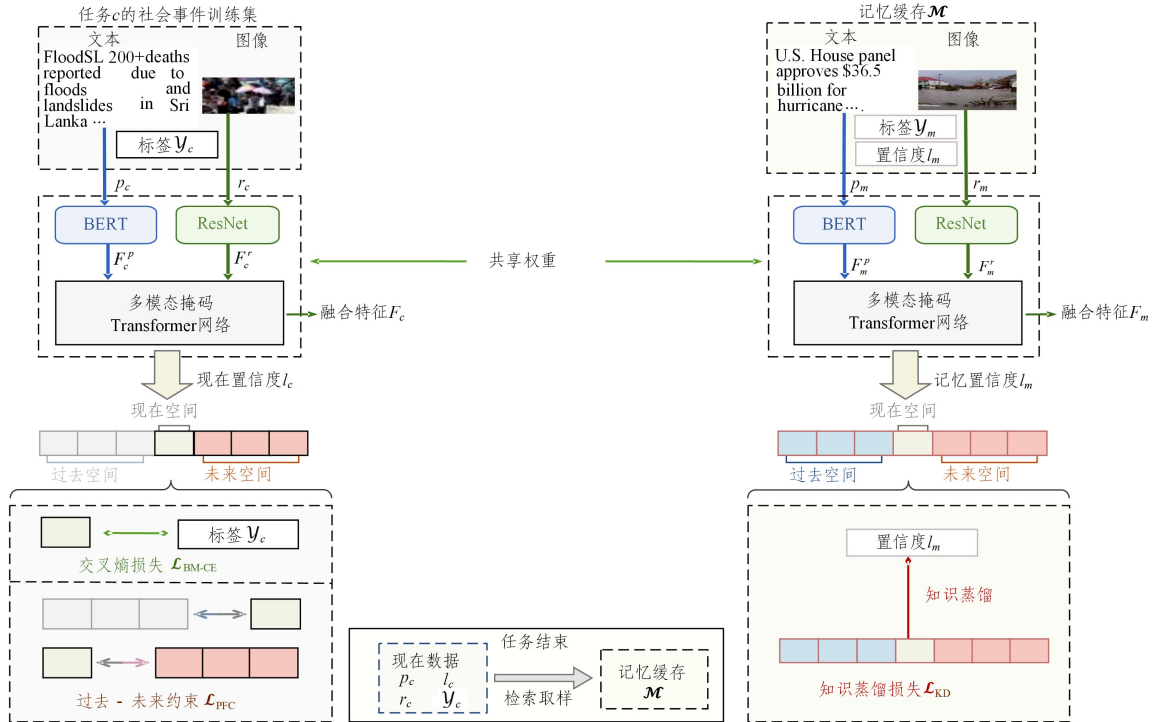


图1 CEKNet 模型

Fig.1 CEKNet model

#### 4.1 网络结构

##### 4.1.1 多模态掩码 Transformer 网络

由于本文方法侧重于对持续学习过程的改进,因此本文直接采用了最先进的SEC特征学习骨干网络,即多模态掩码Transformer网络(Multimodal Masked Transformer Network, MMTN)<sup>[2]</sup>。MMTN通过建模模态间关系和过滤冗余信息,将多模态社会数据融合并投射到高级特征空间中。对于训练

样本 $x_t^i=(p_t^i, v_t^i) \in \mathcal{T}_t$ ,首先利用预训练BERT<sup>[43]</sup>和预训练ResNet<sup>[44]</sup>提取文本特征 $F_{t,i}^p$ 和视觉特征 $F_{t,i}^r$ ,如式(1)所示:

$$\begin{aligned} F_{t,i}^p &= \text{BERT}(p_t^i) \in \mathbb{R}^{n_p \times 768} \\ F_{t,i}^r &= \sigma(\text{ResNet}(v_t^i)) \cdot W_r \in \mathbb{R}^{n_v \times 768} \end{aligned} \quad (1)$$

其中, $n_p$ 是 $p_t^i$ 中的单词数; $n_v=49$ 是图像区域数; $W_r \in \mathbb{R}^{2048 \times 768}$ 是可训练矩阵,用于将视觉特征投射到与文本特征相同的维度(因为 $\text{ResNet}(v_t^i) \in \mathbb{R}^{n_v \times 2048}$ ); $\sigma(\cdot)$ 是ReLU函数。

需要注意的是,预训练 BERT 和 ResNet 的参数保持不变,以避免在训练过程中出现过拟合。然后,采用 MMTN 对多模态特征进行有效融合,融合后的特征如下:

$$f_i = \text{MMTN}(F_{l,i}^v, F_{l,i}^v; \theta_1) \in \mathbb{R}^D \quad (2)$$

其中,  $\theta_1$  是 MMTN 的可训练参数,  $D$  是 MMTN 的输出维度。

#### 4.1.2 持续社会事件分类置信度的划分

在得到融合特征  $f_i$  后,采用线性分类器  $W(\cdot; \theta_2): \mathbb{R}^D \rightarrow \mathbb{R}^C$  将 MMTN 特征分为  $C$  个社会事件,如式(3)所示:

$$\ell(x_i') = W(f_i; \theta_2) \in \mathbb{R}^C \quad (3)$$

其中,  $\ell$  表示所有社会事件的分类置信度,  $\theta_2$  表示线性分类器的可训练参数。

当出现的类别(即本文中的社会事件)增加时,一些 CL 方法<sup>[45-46]</sup>会继续扩展分类器以保持  $C = |\bigcup_{i=1}^t \mathcal{Y}_i|$ 。与此不同的是,本文效仿其他研究<sup>[41]</sup>的做法,以满足  $C \geq |\bigcup_{i=1}^t \mathcal{Y}_i|$  的大输出维度初始化分类器。由于最后  $(C - |\bigcup_{i=1}^t \mathcal{Y}_i|)$  在本文实验中不会用于任何任务的测试,因此只需将  $C$  设置为  $|\bigcup_{i=1}^t \mathcal{Y}_i|$  即可。实际上,即使  $C$  不够大,分类器仍具备扩展能力。

为便于讨论,如图 2 所示,本文将预测空间划分为以前学习到社会事件  $\bigcup_{i=1}^{t-1} \mathcal{Y}_i$  的过去空间、现在出现的社会事件  $\mathcal{Y}_t$  的现在空间和将来发生的事件的将来空间。为简单起见,将式(1)一式(3)中的计算合并,并将 CEKNet 的计算重写为:

$$\begin{aligned} \ell(x_i') &= [\ell_{\text{pa}}(x_i') \in \mathbb{R}^{|\bigcup_{i=1}^{t-1} \mathcal{Y}_i|}, \ell_{\text{pr}}(x_i') \in \mathbb{R}^{|\mathcal{Y}_t|}, \ell_{\text{fu}}(x_i') \in \mathbb{R}^{|\bigcup_{i=1}^t \mathcal{Y}_i|}] \\ &= \text{TEKNet}(x_i'; \theta) \in \mathbb{R}^C \end{aligned} \quad (4)$$

其中,  $[\cdot, \cdot, \cdot]$  表示沿预测维度的连接操作,  $\theta = \{W_r, \theta_1, \theta_2\}$  表示 CEKNet 的可训练参数。

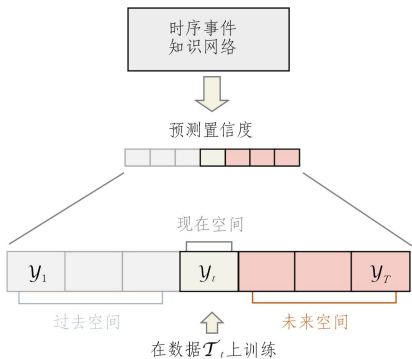


图 2 社会事件分类空间的划分

Fig. 2 Partition of social event classification space

## 4.2 当前事件知识学习

当前事件知识学习旨在学习如何对  $\mathcal{T}_t$  中新出现的社会事件进行分类。

### 4.2.1 减少过去和未来空间的偏差

最近的几项 CL 研究<sup>[22,47-48]</sup>关注到了新类别的偏差积累问题,强调了其对模型性能的不利影响。本文的目标是不断学习当前任务,以实现统一的分类器,因此必须抵消这种偏差积累。这一讨论可进一步划分为两个关键方面:首先,与过去类别相关的大多数错误都源于模型对新类别的盲目偏好,从而导致对过去类别的性能不达标;其次,未来的分类空间只接

收负样本,这可能会阻碍或减缓未来的学习。

### 4.2.2 防止过去和未来空间的惩罚

本文通过修改交叉熵损失在训练中的应用方式,来减轻过去和未来空间中的分类惩罚。对于  $\mathcal{T}_t$  中属于当前社会事件的训练样本,避免在所有置信度上计算 softmax 激活函数,而只对当前任务社会事件的得分进行建模,具体如下:

$$\mathcal{L}_{\text{BM-CE}} = \frac{1}{|\mathcal{T}_t|} \sum_{i=1}^{|\mathcal{T}_t|} \text{CE}(\text{softmax}(\ell_{\text{pr}}(x_i'), y_i')) \quad (5)$$

其中,  $\text{CE}(\cdot, \cdot)$  表示交叉熵损失,  $\ell_{\text{pr}}(x_i')$  是当前空间中的预测置信度。因此,过去和未来空间的预测置信度不会受到  $\mathcal{L}_{\text{BM-CE}}$  的影响。

### 4.2.3 限制过去和未来空间的激活

然而,在对属于所有社会事件的社会数据进行分类时,简单地去除过去和未来空间的惩罚会降低区分度。为了避免这个问题,本文提供了一个优化约束来限制过去和未来空间的激活。要求负样本事件的预测置信度低于保障阈值,即置信度  $\ell_{\text{gt}}(x_i') \triangleq \langle \text{one-hot}(y_i'), \ell(x_i') \rangle \in \mathbb{R}$  对应于基准类,其中  $\text{one-hot}(\cdot)$  表示将离散标签转换为 one-hot 编码向量,  $\langle \cdot, \cdot \rangle$  表示向量内积。这样就限制了过去和未来的最大置信度  $\ell_{\text{pa-max}}(x_i') = \max_j(\ell_{\text{pa}}(x_i'))_j$ ,  $\ell_{\text{fu-max}}(x_i') = \max_j(\ell_{\text{fu}}(x_i'))_j$  如下:

$$\begin{aligned} \mathcal{L}_{\text{DFC}} &= \frac{1}{|\mathcal{T}_t|} \sum_{i=1}^{|\mathcal{T}_t|} [\max(0, \ell_{\text{pa-max}}(x_i') - \ell_{\text{gt}}(x_i') + \alpha) + \\ &\quad \max(0, \ell_{\text{fu-max}}(x_i') - \ell_{\text{gt}}(x_i') + \alpha)] \end{aligned} \quad (6)$$

其中,  $\alpha$  是一个超参数,用于控制约束的严格程度。

## 4.3 过去事件知识回放

### 4.3.1 记忆缓存

在持续学习中,模型无法访问全部历史数据  $\bigcup_{i=1}^{t-1} \mathcal{T}_i$ , 但可以访问包含少量历史训练样本信息  $N^m$  的存储器。具体来说,本文设计了记忆缓存  $\mathcal{M} = \{x_i^m, \ell_i^m, y_i^m\}_{i=1}^{|\mathcal{M}|}$ 。其中,  $x_i^m = (p_i^m, v_i^m)$  包括第  $i$  批帖子文本和图片,  $\ell_i^m = \text{CEKNet}(x_i^m; \theta)$  是相应的预测置信度,  $y_i^m$  是基准标签。在完成第  $\mathcal{T}_t$  个任务的训练时,通过蓄水池采样策略<sup>[49]</sup>将  $\mathcal{T}_t$  中的  $N^m$  个样本添加到内存缓冲区,这样可以确保每个样本被提取的概率相等。

### 4.3.2 知识自蒸馏

为了抵御在适应新任务时遗忘过去所学知识的风险,并促进每个任务分类器聚合成一个统一而有内聚力的框架,开发了记忆样本的知识自蒸馏。对于每个记忆样本  $x_i^m = (p_i^m, v_i^m)$  和已记忆的置信度  $\ell_i^m$ , 会在持续的社会事件分类中重放存储  $\mathcal{M}$  中的基准标签,如式(7)所示:

$$\mathcal{L}_{\text{KD}} = \frac{1}{|\mathcal{M}|} \sum_{i=1}^{|\mathcal{M}|} \|\ell_i^m - \text{TEKNet}(x_i^m; \theta)\|_2^2 \quad (7)$$

需要注意的是,由于 CEKNet 在存储  $\ell_i^m$  之后会不断更新,因此存储的  $\ell_i^m$  并不等同于  $\text{TEKNet}(x_i^m; \theta)$ 。

### 4.3.3 缓存中置信度的自适应再缩放

在本方法中,对存储样本的置信度保持更新,可以防止模型在训练  $t$  个任务时丢失有价值的信息。当前输出置信度  $\ell(x_i^m) = \text{TEKNet}(x_i^m; \theta)$  包含当前网络有价值的规模信息。具体来说,将  $\ell_{\text{pr}}(x_i^m)$  表示为当前空间的预测置信度,并利用已保存在存储中的基准  $\ell_{\text{gt}}^m = \langle \text{one-hot}(y_i^m) \rangle$  对  $\ell_{\text{pr}}(x_i^m)$  的最大

值  $\ell_{\text{prmax}}(x_i^m) = \max_j(\ell_{\text{pr}}(x_i^m))_j$ ; 进行自适应再缩放,  $\ell_i^m$  大于所有存储的置信度, 如式(8)所示:

$$(\ell_i^m)_k \leftarrow (\ell_i^m)_k \cdot \min\left(\beta \frac{\ell_{\text{prmax}}^{\text{gt}}}{\ell_{\text{prmax}}}, 1\right) \quad (8)$$

$$k = \left| \bigcup_{j=1}^{t-1} \mathcal{Y}_j \right| + 1, \dots, \left| \bigcup_{j=1}^T \mathcal{Y}_j \right|$$

其中,  $\beta$  是控制衰减率的超参数。

#### 4.4 优化目标

总之, 本文 CEKNet 的总体优化目标如下:

$$\arg \min_{\theta} \mathcal{L}_{\text{overall}} \triangleq \mathcal{L}_{\text{BM-CE}} + \delta \mathcal{L}_{\text{PFC}} + \epsilon \mathcal{L}_{\text{KD}} \quad (9)$$

其中,  $\delta$  和  $\epsilon$  是平衡两个因素的权衡参数。

## 5 实验

### 5.1 数据集

表 1 列出了本文使用的 4 个数据集的统计数据。

表 1 数据集  
Table 1 Dataset

数据集	训练集	测试集	类别	任务类别
PHEME	6273	2089	7	[2, 2, 3]
CrisisMMD	16097	18126	7	[2, 2, 3]
CrisisMMD→PHEME	22370	20215	14	[2, 2, 2, 2, 2, 2, 2]
PHEME→CrisisMMD	22370	20215	14	[2, 2, 2, 2, 2, 2, 2]

PHEME<sup>[50-51]</sup> 是通过收集社交媒体上关于七大突发新闻的帖子而构建的, 这些新闻包括《查理周刊》枪击案、悉尼人质事件、弗格森骚乱、渥太华枪击案、德国之翼客机坠毁、普京失踪以及普林斯在多伦多的秘密表演。本文手动将 PHEME 分成 3 个任务, 分别包含 2, 2 和 3 个社会事件。所有社会事件均按实际时间顺序排列。

CrisisMMD<sup>[52]</sup> 是一个多模态危机事件数据集。它由带注释的图片-推文对组成。该数据集是在 2017 年的 7 次自然灾害中使用特定事件的关键词和标签(飓风伊尔玛、飓风哈维、飓风玛丽亚、墨西哥地震、加利福尼亚野火、伊拉克-伊朗地震和斯里兰卡洪水)收集的。本文手动将 CrisisMMD 分成 3 个任务, 分别包含 2, 2 和 3 个社会事件。所有社会事件均按实际时间顺序排列。

CrisisMMD→PHEME 是 CrisisMMD 和 PHEME 的组合, 其中持续社会事件分类的顺序是从 CrisisMMD 到 PHEM。CrisisMMD→PHEME 分为 7 个任务, 每个任务包含 2 个社会事件。

PHEME→CrisisMMD 是 CrisisMMD 和 PHEME 的组合, 其中持续社会事件分类的顺序是从 PHEME 到 CrisisMMD。PHEME→CrisisMMD 分为 7 个任务, 每个任务包含 2 个社会事件。

所有数据集按 7:1:2 的比例划分为训练集、验证集和测试集。

### 5.2 基准方法和评估指标

#### 5.2.1 基准方法

据知, 本文是第一篇研究持续社会事件分类的论文。因此, 本文采用了先进的社会事件分类模型 OWSEC<sup>[2]</sup> 作为所有比较过的持续学习(CL)方法(包括 CEKNet)的基线(第 4.1.1 节中有所描述), 以便进行公平的比较。所采用的持续

学习基准方法如下: 1) 增量分类器和表征学习(iCaRL)<sup>[41]</sup> 通过结合精心设计的 herding 缓冲区和最接近平均值的示例分类器, 有效地缓解了灾难性遗忘问题; 2) 梯度外显记忆持续学习(GEM)<sup>[42]</sup> 利用外显记忆来学习一组分布所共有的相关性子集, 通过提取任务间的共性特征, 从而增强模型的泛化能力; 3) Lipschitz-Driven Rehearsal (LIDER)<sup>[53]</sup> 在小数据池上进行重复优化, 提高了模型的准确性, 但不可避免地导致了决策边界紧密且不稳定; 4) 互补学习系统经验重放(CLS-ER)<sup>[54]</sup> 维护短期和长期语义记忆, 这些记忆与外显记忆相互作用, 以防止灾难性遗忘; 5) 基于代理的对比重放(PCR)<sup>[23]</sup> 以基于对比的方式, 用相应的代理替换锚的对比样本, 从而防止遗忘; 6) 基于错误敏感度调节的经验重放(ESMER)<sup>[20]</sup> 采用了一种原则性机制来调节基于双记忆重放系统的错误敏感度, 使模型更加精确地针对重要知识进行学习; 7) 持续学习中的任务特定注意模块(TAMIL)<sup>[18]</sup> 则包含了经验重演和自我调节的可扩展神经发生, 使模型具有更好的适应性和扩展性。此外, 本文还提供了两种方法, 分别作为持续学习的下限和上限: 1) 对最近的任务进行持续微调, 不进行重放来避免灾难性遗忘, 又称微调(Fine-Tuning, FT); 2) 对所有历史数据联合训练一个模型, 又称联合训练(Joint-Training, JT)。

#### 5.2.2 评估指标

在第  $t$  个任务中, 模型在属于社会事件  $\mathcal{Y}_t$  的  $\mathcal{T}_t$  上进行训练, 并在属于所有历史训练数据中出现的社会事件  $\bigcup_{i=1}^t \mathcal{Y}_i$  的  $\tilde{\mathcal{T}}_t$  上进行测试。对于第  $t$  个任务,  $a_t$  是准确率得分,  $f_t$  是  $F_1$  分数,  $a_i^t (i \leq t)$  是社会事件  $\mathcal{Y}_i$  的准确率得分。根据以前的持续学习工作<sup>[55-56]</sup>, 用平均准确率(AA)和平均  $F_1$  (AF1) 来评估模型性能:

$$AA = \frac{1}{T} \sum_{t=1}^T a_t \quad (10)$$

$$AF1 = \frac{1}{T} \sum_{t=1}^T f_t$$

其中,  $T$  表示任务总数。本文还沿用了之前工作<sup>[22, 41, 45]</sup> 中采用的最终遗忘 (FF)<sup>[57]</sup> 指标:

$$FF = \frac{1}{T-1} \sum_{i=1}^{T-1} k_i \quad (11)$$

where  $k_i = \max_{t \in \{1, \dots, T-1\}} a_i^t - a_i^T$

其中, FF 的取值范围为  $[-100, 100]$ , 用于测量平均精度下降, 即通过训练观察到的特定任务性能的最大差异。

### 5.3 实现细节

本文的代码使用 PyTorch<sup>[58]</sup> 实现, 所有模型都在一个 RTX 3090 GPU 上训练。采用 Adam optimizer<sup>[59]</sup> 进行优化, 初始学习率为  $0.8 \times 10^{-4}$ 。所有数据集的批量大小设置为 256。所有数据集的内存大小设为  $N^m = 100$ 。在 CrisisMMD, PHEME 的情况下, 损失的权衡系数分别为  $\delta = 0.3, \epsilon = 0.3$ ; 在 CrisisMMD→PHEME 和 PHEME→CrisisMMD 的情况下, 损失的权衡系数分别为  $\delta = 0.3, \epsilon = 0.3$ 。本文实验中, 随机抽取 5 个种子, 计算平均结果作为最终结果。

### 5.4 实验结果分析

#### 5.4.1 定量分析

表 2 和图 3 是 CEKNet 和其他比较方法在 C-SEC 的 4

个数据集上的实验结果。根据这些结果,可得出以下结论:

1)如图3所示,当有更多任务到达时,基线方法的准确率明显下降。此外,表2中下限FT的性能远低于上限JT,这表明非持续学习方法无法有效解决C-SEC问题。这些结果共同表明,所提出的持续社会事件分类(即C-SEC)并不是社会事件分类领域的一个小问题。

2)如表2所列,在C-SEC的所有数据集上,本文提出的CEKNet相比所有基线方法都有明显的优势。与第二好的结果相比,CEKNet在CrisisMMD, PHEME, CrisisMMD → PHEME和PHEME → CrisisMMD上的AA分别提高了

1.43个百分点、2.18个百分点、0.54个百分点和0.55个百分点。对于AF1和FF,CEKNet也取得了最佳结果。如图3所示,在所有数据集上,CEKNet在所有任务中都取得了最高的准确率。这些结果表明,所提出的CEKNet可以更好地克服持续学习中的灾难性遗忘问题,实现精确的C-SEC。

3)如表2所列,在最具挑战性的由7个任务组成的CrisisMMD → PHEME和PHEME → CrisisMMD上,基线方法存在严重的灾难性遗忘,导致性能下降。然而,CEKNet可以有效地学习过去、现在和未来的知识,通过持续学习过程获得最佳AA,AF1和FF分数。

表2 不同方法在4个数据集上的实验结果

Table 2 Results of different methods on four datasets

methods	CrisisMMD			PHEME			CrisisMMD → PHEME			PHEME → CrisisMMD		
	AA [↑]	AF1 [↑]	FF [↓]	AA [↑]	AF1 [↑]	FF [↓]	AA [↑]	AF1 [↑]	FF [↓]	AA [↑]	AF1 [↑]	FF [↓]
JT	97.82	97.67	—	98.10	98.45	—	96.49	96.50	—	98.61	98.56	—
FT	57.02	47.16	76.70	54.91	47.83	57.07	35.09	26.66	100.00	40.81	26.48	98.05
GEM <sup>[42]</sup>	89.06	89.69	3.22	84.71	84.90	10.71	86.93	83.51	10.64	78.09	72.74	36.97
iCaRL <sup>[41]</sup>	87.87	90.14	9.45	74.92	71.70	30.20	78.93	73.55	14.72	67.16	69.69	32.08
LiDER <sup>[53]</sup>	91.50	90.13	3.22	84.95	83.66	<u>3.10</u>	81.96	75.59	19.44	60.35	59.31	36.62
X-DER <sup>[22]</sup>	<u>91.80</u>	<u>91.39</u>	<u>2.80</u>	85.19	88.32	5.77	87.80	82.96	12.11	<u>80.89</u>	<u>78.31</u>	<u>15.86</u>
CLS-ER <sup>[54]</sup>	90.42	86.75	4.18	77.10	73.36	15.15	86.40	79.12	9.60	73.54	63.89	24.7
PCR <sup>[23]</sup>	87.93	83.82	4.78	<u>86.28</u>	<u>86.30</u>	3.84	82.99	78.69	<u>5.37</u>	79.66	73.25	38.02
ESMER <sup>[20]</sup>	90.88	90.74	8.69	75.82	74.48	31.62	<u>87.95</u>	<u>83.66</u>	7.26	78.57	63.72	69.55
TAMiL <sup>[18]</sup>	86.61	74.79	18.28	77.60	77.13	18.30	66.53	54.48	29.15	59.37	52.96	65.56
CEKNet	<b>93.23</b>	<b>95.09</b>	<b>1.84</b>	<b>88.46</b>	<b>90.58</b>	<b>2.14</b>	<b>88.49</b>	<b>87.07</b>	<b>2.00</b>	<b>81.44</b>	<b>81.20</b>	<b>4.83</b>




图3 不同方法在各项任务上的准确率

Fig. 3 Accuracy of different methods on various tasks throughout the entire continual learning process

#### 5.4.2 消融实验

提出的CEKNet包含多个部分,本节将通过消融实验来验证不同部分的有效性,变体包括:

- 1) w/o  $\mathcal{L}_{\text{BM-CE}}$ :对过去和未来空间进行惩罚的变体。
- 2) w/o  $\mathcal{L}_{\text{PFC}}$ :不限制过去和未来空间激活的变体。
- 3) w/o  $\mathcal{L}_{\text{KD}}$ :没有知识蒸馏损失的变体。

表3列出了对PHEME和CrisisMMD → PHEME的消融实验结果,可以得出以下结论:

1)当去除所有损失项中的任何一项或存储更新策略时,本文方法的性能都会下降,这表明每个部分都对最终结果有贡献。

2)在两个数据集上,不包含 $\mathcal{L}_{\text{BM-CE}}$ 的变体的表现明显不如CEKNet,这表明从当前训练数据中学习是C-SEC的基石。不包含 $\mathcal{L}_{\text{PFC}}$ 的变体在两个数据集上的过去和未来空间偏差

得分较低,这表明本文提出的过去和未来空间激活约束可以限制模型专注于当前任务,并学习具有区分性的分类器。

3)不包含 $\mathcal{L}_{\text{KD}}$ 的变体在PHEME和CrisisMMD → PHEME上的AA分别下降了21.88%和49.08%,这表明失去对过去事件知识的重放使C-SEC模型遭受了严重的灾难性遗忘。

表3 CEKNet变体在PHEME和CrisisMMD → PHEME数据集上的实验结果

Table 3 Experimental results of the CEKNet variants on PHEME and CrisisMMD → PHEME datasets

变体	PHEME			CrisisMMD → PHEME		
	AA	AF1	FF	AA	AF1	FF
w/o $\mathcal{L}_{\text{BM-CE}}$	56.08	28.00	10.35	25.29	35.56	14.95
w/o $\mathcal{L}_{\text{PFC}}$	66.96	55.95	60.62	78.36	69.82	15.19
w/o $\mathcal{L}_{\text{KD}}$	66.58	56.55	58.72	39.41	28.72	47.89
CEKNet	<b>88.46</b>	<b>90.58</b>	<b>2.14</b>	<b>88.49</b>	<b>87.07</b>	<b>2.00</b>

### 5.4.3 采样策略分析

以前的方法<sup>[18,22]</sup>认为,在存储中随机保留一些样本有助于保持模型在过去类别上的性能。本小节将研究不同的随机抽样策略。如图4所示,不同的采样策略在ESMER<sup>[20]</sup>,XDER<sup>[22]</sup>和LiDER<sup>[53]</sup>上的表现并不稳定。例如,ESMER<sup>[20]</sup>和LiDER<sup>[53]</sup>在Distance采样、Entropy采样和Herding采样方面的表现均不理想。然而,CEKNet在4种采样策略上都优于这3种方法。这些结果进一步证明了CEKNet在不同采样策略下的有效性和鲁棒性。




图4 不同采样策略结果

Fig. 4 Result of different sampling strategies

**结束语** 本文首次探索了持续社会事件分类(CSEC),并提出了一种持续事件知识网络(CEKNet),用于从连续收集的数据中持续学习时序事件知识。为了克服C-SEC中的灾难性遗忘问题,本文提出了一种具有自适应置信度记忆更新和知识自蒸馏功能的过去事件知识重放方法,以便在从新输入的训练数据中学习时巩固所学到的过去事件知识。为了在持续学习过程中对过去、现在和未来社会事件的时间知识进行全面建模,本文提出了一个由过去事件知识重放和当前事件知识学习组成的CL框架。在真实世界社会事件数据集上进行的大量实验表明,所提出的CEKNet在C-SEC方面明显优于目前先进的方法。未来,将研究本方法在更多真实世界应用中的可移植性。

### 参考文献

[1] AFYOUNI I, AL AGHBARI Z, RAZACK R A. Multi-feature, multi-modal, and multi-source social event detection: A comprehensive survey[J]. *Information Fusion*, 2022, 79: 279-308.

[2] QIAN S, CHEN H, XUE D, et al. Open-world social event classification[C]// *Proceedings of the ACM Web Conference 2023*. 2023: 1562-1571.

[3] ZHOU H, YIN H, ZHENG H, et al. A survey on multi-modal social event detection[J]. *Knowledge-Based Systems*, 2020, 195: 105695.

[4] CHANDRASEKARAN G, NGUYEN T N, HEMANTH D J. Multimodal sentimental analysis for social media applications: A comprehensive review[J]. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 2021, 11(5): e1415.

[5] CHEN M, CHEN S C, SHYU M L, et al. Semantic event detection via multimodal data mining[J]. *IEEE Signal Processing Magazine*, 2006, 23(2): 38-46.

[6] HAN X, WANG J, ZHANG M, et al. Using social media to mine and analyze public opinion related to COVID-19 in China[J]. *International Journal of Environmental Research and Public Health*, 2020, 17(8): 2788.

[7] XIA H, AN W, LI J, et al. Outlier knowledge management for extreme public health events: Understanding public opinions about COVID-19 based on microblog data[J]. *Socio-Economic Planning Sciences*, 2022, 80: 100941.

[8] JIN Y, LIU B F, AUSTIN L L. Examining the role of social media in effective crisis management: The effects of crisis origin, information form, and source on publics' crisis responses[J]. *Communication Research*, 2014, 41(1): 74-94.

[9] ZADE H, SHAH K, RANGARAJAN V, et al. From situational awareness to actionability: Towards improving the utility of social media data for crisis response[J]. *Proceedings of the ACM on Human-Computer Interaction*, 2018, 2(CSCW): 1-18.

[10] CACCIA L, ALJUNDI R, ASADI N, et al. New insights on reducing abrupt representation change in online continual learning[J]. *arXiv:2104.05025*, 2021.

[11] MACEDO A Q, MARINHO L B, SANTOS R L T. Context-aware event recommendation in event-based social networks[C]// *Proceedings of the 9th ACM Conference on Recommender Systems*. 2015: 123-130.

[12] ABAVISANI M, WU L, HU S, et al. Multimodal categorization of crisis events in social media[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020: 14679-14689.

[13] KIELA D, BHOOSHAN S, FIROOZ H, et al. Supervised multimodal bitransformers for classifying images and text[J]. *arXiv:1909.02950*, 2019.

[14] OFLI F, ALAM F, IMRAN M. Analysis of social media data using multimodal deep learning for disaster response[J]. *arXiv:2004.11838*, 2020.

[15] DE LANGE M, ALJUNDI R, MASANA M, et al. A continual learning survey: Defying forgetting in classification tasks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 44(7): 3366-3385.

[16] LESORT T, LOMONACO V, STOIAN A, et al. Continual learning for robotics: Definition, framework, learning strategies, opportunities and challenges[J]. *Information Fusion*, 2020, 58: 52-68.

[17] MAI Z, LI R, JEONG J, et al. Online continual learning in image classification: An empirical survey[J]. *Neurocomputing*, 2022, 469: 28-51.

[18] BHAT P, ZONOOZ B, ARANI E. Task-aware information routing from common representation space in lifelong learning[J]. *arXiv:2302.11346*, 2023.

[19] JIN X, LIN B Y, ROSTAMI M, et al. Learn continually, generalize rapidly: Lifelong knowledge accumulation for few-shot learning[J]. *arXiv:2104.08808*, 2021.

[20] SARFRAZ F, ARANI E, ZONOOZ B. Error sensitivity modulation based experience replay: Mitigating abrupt representation drift in continual learning[J]. *arXiv:2302.11344*, 2023.

[21] ROBINS A. Catastrophic forgetting, rehearsal and pseudorehearsal[J]. *Connection Science*, 1995, 7(2): 123-146.

[22] BOSCHINI M, BONICELLI L, BUZZEGA P, et al. Class-incre-

- mental continual learning into the extended der-verse[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 45(5):5497-5512.
- [23] LIN H, ZHANG B, FENG S, et al. PCR: Proxy-based contrastive replay for online class-incremental continual learning[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2023:24246-24255.
- [24] ZHOU D W, WANG Q W, YE H J, et al. A model or 603 exemplars: Towards memory-efficient class-incremental learning[J]. *arXiv:2205.13218*, 2022.
- [25] ALAM F, OFLI F, IMRAN M. Crisismmd: Multimodal twitter datasets from natural disasters[C]// *Proceedings of the International AAAI Conference on Web and Social Media*. 2018.
- [26] KOCHKINA E, LIAKATA M, ZUBIAGA A. All-in-one: Multi-task learning for rumour verification [J]. *arXiv:1806.03713*, 2018.
- [27] LEE K, PALSETIA D, NARAYANAN R, et al. Twitter trending topic classification [C] // *2011 IEEE 11th International Conference on Data Mining Workshops*. IEEE, 2011:251-258.
- [28] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality [C]// *Advances in Neural Information Processing Systems*. 2013.
- [29] PARILLA-FERRER B E, FERNANDEZ P L, BALLENA J T. Automatic classification of disaster-related tweets[C]// *International Conference on Innovative Engineering Technologies(ICI-ET)*. 2014.
- [30] SRIRAM B, FUHRY D, DEMIR E, et al. Short text classification in twitter to improve information filtering[C]// *Proceedings of the 33rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2010:841-842.
- [31] QIAO Z, ZHANG P, ZHOU C, et al. Event recommendation in event-based social networks[C]// *Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence*. AAAI, 2014:3130-3131.
- [32] TANG J, TANG J, LIU H. Recommendation in social media: recent advances and new frontiers[C]// *Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2014.
- [33] TSOU M H, YANG J A, LUSHER D, et al. Mapping social activities and concepts with social media(Twitter) and web search engines(Yahoo and Bing): a case study in 2012 US Presidential Election[J]. *Cartography and Geographic Information Science*, 2013, 40(4):337-348.
- [34] ALSAEDI N, BURNAP P, RANA O. Can we predict a riot? Disruptive event detection using Twitter[J]. *ACM Transactions on Internet Technology*, 2017, 17(2):1-26.
- [35] ZHANG W, QI G, PAN G, et al. City-scale social event detection and evaluation with taxi traces[J]. *ACM Transactions on Intelligent Systems and Technology*, 2015, 6(3):1-20.
- [36] KELLY S, ZHANG X, AHMAD K. Mining multimodal information on social media for increased situational awareness[C]// *Proceedings of the 14th International Conference on Information Systems for Crisis Response and Management*. 2017.
- [37] LI X, DOINA C. Improving disaster-related tweet classification with a multimodal approach[C]// *Proceedings of the 17th International Conference on Information Systems for Crisis Response and Management*. 2020.
- [38] MOUZANNAR H, RIZK Y, AWAD M. Damage Identification in Social Media Posts using Multimodal Deep Learning [C] // *The 15th International Conference on Information Systems for Crisis Response and Management(ISCRA M)*. 2018.
- [39] NGUYEN T H, RUDRA K. Towards an interpretable approach to classify and summarize crisis events from microblogs [C] // *Proceedings of the ACM Web Conference*. 2022:3641-3650.
- [40] HADSELL R, RAO D, RUSU A A, et al. Embracing change: Continual learning in deep neural networks[J]. *Trends in Cognitive Sciences*, 2020, 24(12):1028-1040.
- [41] REBUFFI S A, KOLESNIKOV A, SPERL G, et al. ICARL: Incremental classifier and representation learning [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017:2001-2010.
- [42] LOPEZ-PAZ D, RANZATO M A. Gradient episodic memory for continual learning [C] // *Advances in Neural Information Processing Systems*. 2017.
- [43] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding. [J]. *arXiv:1810.04805*, 2018.
- [44] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016:770-778.
- [45] HOU S, PAN X, LOY C C, et al. Learning a unified classifier incrementally via rebalancing [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019:831-839.
- [46] LI Z, HOIEM D. Learning without forgetting [ J ]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 40(12):2935-2947.
- [47] CACCIA L, ALJUNDI R, ASADI N, et al. New insights on reducing abrupt representation change in online continual learning [J]. *arXiv:2104.05025*, 2021.
- [48] MITTAL S, GALESSO S, BROX T. Essentials for class incremental learning [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021:3513-3522.
- [49] VITTER J S. Random sampling with a reservoir [J]. *ACM Transactions on Mathematical Software*, 1985, 11(1):37-57.
- [50] KOCHKINA E, LIAKATA M, ZUBIAGA A. All-in-one: Multi-task learning for rumour verification [J]. *arXiv:1806.03713*, 2018.
- [51] ZUBIAGA A, LIAKATA M, PROCTER R, et al. Analysing how people orient to and spread rumours in social media by looking at conversational threads [J]. *PLoS One*, 2016, 11(3):e0150989.
- [52] ALAM F, OFLI F, IMRAN M. Crisismmd: Multimodal twitter datasets from natural disasters[C]// *Proceedings of the International AAAI Conference on Web and Social Media*. 2018.
- [53] BONICELLI L, BOSCHINI M, PORRELLO A, et al. On the ef-

fectiveness of lipschitz-driven rehearsal in continual learning[J]. Advances in Neural Information Processing Systems, 2022, 35: 31886-31901.

- [54] ARANI E, SARFRAZ F, ZONOOZ B. Learning fast, learning slow: A general continual learning method based on complementary learning system[J]. arXiv:2201.12604, 2022.
- [55] CHA S, CHO S, HWANG D, et al. Rebalancing batch normalization for exemplar-based class-incremental learning[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023:20127-20136.
- [56] VILLA A, ALCÁZAR J L, ALFARRA M, et al. Pivot: Prompting for video continual learning[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2023:24214-24223.
- [57] CHAUDHRY A, DOKANIA P K, AJANTHAN T, et al. Riemannian walk for incremental learning: Understanding forgetting and intransigence[C]// Proceedings of the European Conference on Computer vision(ECCV). 2018:532-547.
- [58] PASZKE A, GROSS S, MASSA F, et al. Pytorch: An imperative style, high-performance deep learning library[C]// Proceedings

of the 33rd International Conference on Neural Information Processing Systems. Red Hook, NY: Curran Associates Inc., 2019: 8026-8037.

- [59] KINGMA D P. Adam: A method for stochastic optimization[J]. arXiv:1412.6980, 2014.



**ZHANG Yuan**, born in 2001, postgraduate. His main research interests include natural language processing and continual learning.



**QIAN Shengsheng**, born in 1991, Ph.D., professor. His main research interests include data mining and multimedia content analysis.

(责任编辑:柯颖)

## CCF 计算艺术分会 2025 年执行委员增选申请报名

CCF 计算艺术分会(Computational Art, 简称 CA)成立于 2021 年,作为一个涉及音乐、美术、设计等多种艺术形式与计算机学科的交叉领域,是学科融合的集成创新。CCF 计算艺术分会将聚焦于人工智能技术对音乐、美术、设计、影视、动画、戏剧、戏曲、广播电视等多种艺术学科的和谐共融的发展,团结、联合、组织艺术与科技领域的专业人才,促进学术交流和产学研合作,加快艺术科技的产业化。

为了进一步增强分会的影响力,促进计算艺术交叉领域的交流与合作,分会现开放 2025 年执行委员增选工作,欢迎各位专业人士加入 CCF 计算艺术分会。

执委申请条件:

(1)专委会执行委员由本领域内有一定学术成就和影响力的专业人士担任,且必须是 CCF 专业会员。执行委员以个人身份参与专委会的工作。执行委员构成应考虑地区分布和企业委员的比例,来自同一单位的执行委员数不超过执行委员总数的 10%。与应用或产业关系密切的专委会,须吸收一定数量的来自企业的人士作为执行委员。

(2)专委委员可申请专委会执行委员资格,申请人须填写专委会执行委员申请表,并得到 2 位以上该专委会在任执行委员推荐,方可成为专委会执行委员正式候选人。执行委员增补须候选人到场,由常务委员会会议投票选举产生。

(以上增选规则选自《专业委员会条例》)

CCF 计算艺术分会 2025 年度工作会议将于 2025 年 9 月 23 日-25 日在济南举办,执行委员申请人需参会并进行竞选演讲,竞选结果根据 CCF 要求投票产生。

请有意愿加入分会的专业人士填写申请表,须在 2025 年 8 月 29 日 24 点前提交至 [computationalart@163.com](mailto:computationalart@163.com),逾期申请无效。

参选请扫码下载报名表:

