

多智能体协同的开放域多模态三维模型识别算法

李 铨¹, 马秋阳¹, 张 宁², 聂为之³

(1. 天津大学微电子学院, 天津 300072; 2. 中国人民大学信息资源管理学院, 北京 100872; 3. 天津大学电气自动化与信息工程学院, 天津 300072)

摘要: 为了解决开放域条件下三维模型无标签数据类别识别困难的问题, 本文提出了一种多智能体协同的开放域三维模型识别算法。首先, 构建多智能体系统, 模拟人类协作学习过程, 成员智能体分别处理不同模态的三维模型数据, 提取对应特征向量, 领导智能体通过特征融合网络整合多模态信息, 形成全局特征向量。通过奖励机制驱动智能体探索多模态特征空间, 并利用多模态信息的关联性进行自监督学习, 从而优化分类策略。其次, 在强化学习环境中设计了一种基于密度聚类的渐进式伪标签生成方法, 通过动态调整聚类参数, 为无标签数据迭代生成高质量伪标签, 缓解传统方法因标签缺失导致的性能瓶颈。实验结果表明, 本文方法在三维数据集 OS-MN40 上平均识别精度均值达到 65.6%, 将本文方法迁移至图像领域后, 在 CIFAR10 数据集上的分类准确率达到 95.6%, 为开放域三维模型识别研究提供了通用且高效的解决方案。

关键词: 新类发现; 开放域; 强化学习; 深度聚类; 多模态特征融合

中图分类号: TP 391.4 **文献标志码:** A

Recognition Algorithm for Multi-agent Collaborative Open-Domain Multimodal 3D Model

LI Qiang¹, MA Qiuyang¹, ZHANG Ning², NIE Weizhi³

(1. School of Microelectronics, Tianjin University, Tianjin 300072, China; 2. School of Information Resource Management, Renmin University of China, Beijing 100872, China; 3. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: To address the challenge of recognizing unlabeled 3D models in open-domain, this paper proposes a multi-agent collaborative algorithm for open-domain multimodal 3D model recognition. The algorithm employs a reinforcement learning framework to simulate human cognitive processes. Within this framework, a multi-agent system is utilized to extract and fuse multimodal information, which enables a comprehensive understanding of the feature space while leveraging the similarity of multimodal samples to enhance model training. Additionally, a progressive pseudo-label generation method is introduced in the reinforcement learning environment. It dynamically adjusts clustering constraints to generate reliable pseudo-labels for a subset of unlabeled data during training, mimicking human exploratory learning of unknown data. These mechanisms collectively update the network parameters based on environmental

基金项目: 国家自然科学基金(62272337, 62072232); 天津市自然科学基金(16JCZDJC31100); 企业档案多模态信息智能管理大模型关键技术研究及应用(2024-X-001)。

收稿日期: 2025-03-25; **修订日期:** 2025-04-25

feedback rewards, effectively controlling the extent of exploratory learning and ensuring accurate learning for unknown categories. Experimental results show that the average recognition accuracy of the method proposed in this paper on the three-dimensional dataset OS-MN40 reaches 65.6%. After transferring the method to the image domain, the classification accuracy on the CIFAR10 dataset reaches 95.6%, which provides a universal and efficient solution for the research of open-domain three-dimensional model recognition.

Key words: novel class discovery; open-domain; reinforcement learning; deep clustering; multimodal feature fusion

引 言

深度学习技术的持续发展已在数据分类和检索领域展现出超越人类水平的卓越性能。现有技术 在数据识别任务中的显著效果主要依赖于从封闭的已知样本集中提取可辨识信息,利用特征描述符实现高精度的数据识别。然而,现实世界是一个动态开放的复杂环境^[1],新类别对象持续涌现,这种动态性对于在封闭数据集上训练的网络模型可能会导致模型难以适应新的场景和任务要求。因此,如何使模型在面对动态变化的环境时具备自适应能力,同时高效地发现和学习新类别,成为开放域深度学习研究中的关键问题之一。

为了解决这一问题,新类发现(Novel class discovery)作为一项实际解决方案应运而生,其旨在解决模型在面对没见过的新类别时如何进行有效识别的问题。Han等^[2]首次在图像分类任务中明确定义了新类发现问题,并提出了解决方案:基于有标签数据集训练一个分类器模型,并将其用作新类别的特征提取器,随后利用该特征提取器的先验知识来减少无标签数据聚类的模糊性,并生成伪标签来训练分类器。这一基础框架为许多新类发现研究^[3-4]奠定了基础,即使用聚类方法^[5-7]为无标签数据生成伪标签。在这一基础上,Fini等^[8]使用Sinkhorn-Knopp算法来生成伪标签并将聚类伪标签与真实标签等价对待,通过单一的交叉熵损失同时作用于有标签和无标签数据集,提升了模型对新类别的适应能力。Wang等^[9]引入了知识蒸馏方法,分别用已知类和新类的特征向量构建了两个不相交的特征表示空间并计算其相似性以合成伪标签,通过自知识蒸馏过程,鼓励模型学习一致的特征表示,连接已知类和新类别的表示空间。尽管图像领域的新类发现研究已经取得了可以与有监督学习相媲美的性能,但模型性能随着无标签数据占比的提高而呈现出不断下降的趋势^[10]。二维图像模态单一,导致模型无法获取足够充分的信息以适应较高比例的无标签数据。随着无标签数据在数据集中的比例不断增加,单一模态的局限性变得愈加明显,尤其是在面对开放域的场景中,新类别往往需要通过更丰富的特征来进行有效识别。考虑到单一模态的局限性,Zhou等^[11]借助多模态信息来提升模型性能,其通过线性组合新类别的图像与文本特征信息,并使用量化的一致性分数作为权重来合成伪标签,显著提高了聚类精度。

近年来,开放域识别领域的研究通过与强化学习的融合取得了显著进展,有效提升了模型的性能表现。在具体应用方面,Nie等^[12]创新性地提出了一种多智能体协同学习框架,该框架通过整合语义智能体和视觉智能体的先验知识,共同指导诊断智能体的训练过程。这种协同机制使得诊断智能体能够通过持续探索和学习显著提高疾病分类任务中的准确性,特别是在处理标签缺失问题方面表现出色。另一方面,Patel等^[13]则从样本选择的角度出发,提出了一种基于强化学习的智能标注策略。该方法通过训练智能体主动选择信息量丰富的样本进行标注,从而显著降低了深度神经网络训练过程中对大规模标注数据的依赖,为降低数据标注成本提供了新的解决方案。

本文提出了一种多智能体协同的开放域多模态三维模型识别算法,其主要贡献如下:(1)构建了多智能体协作框架,模拟人类协同认知机制,通过成员智能体提取多模态特征,领导智能体动态融合全局

信息,并结合了强化学习奖惩机制优化分类策略;(2)设计了强化学习环境中基于密度聚类的渐进式标签生成方法,通过动态调整聚类参数,迭代生成高质量伪标签,有效缓解了开放域场景下高占比无标签数据导致的性能瓶颈;(3)利用了跨模态自监督学习,通过多模态特征间的相似性构建对比损失函数,增强了模型对复杂样本的鲁棒性。

1 本文算法

1.1 算法框架

本文探讨了开放域多模态三维模型识别算法,其基本架构如图1所示。受Nie等^[12]工作的启发,算法采用了多智能体协同的强化学习框架,将多模态数据的分类过程视为一个马尔可夫决策过程,通过多智能体协同整合三维模型多模态信息并利用奖惩机制进行训练,完成新类发现任务。在强化学习环境中,通过借鉴Fini等^[8]将聚类伪标签与真实标签同等对待的思想,结合人类认知过程中的知识迁移特性,利用模型先验知识,通过渐进地生成高可靠性的伪标签帮助智能体逐步掌握新类别的特征,使模型在应对未知数据时提高其适应性和鲁棒性。这种方法的核心思想是模拟人类在面对未知事物时的行为,通过不断试探和调整策略,逐渐从经验中学习,最终做出准确的判断和决策。

具体而言,将一个三维模型新类发现数据集定义为 D ,其中包括有标签数据集 D^l 和无标签数据集 D^u ,且有 $D^l \cap D^u = \emptyset$ 。智能体的核心任务是准确判定每个样本的类别归属。在进行新类发现任务之前,智能体会使用 D^l 进行预训练以获取先验知识,并在此基础上通过不断探索来发现无标签数据中的潜在特征。为此,构建了一个专门的环境来为智能体的行为提供反馈。下面对此框架的各个部分进行详细说明:

(1) 状态:数据集中的单个随机样本为 x_i ,一个批次中包含的样本数量为 n ,则状态 s_t 是训练过程中第 t 个批次包含所有样本,即 $s_t = \{x_1, x_2, \dots, x_n\}$ 。

(2) 智能体:本文使用了多智能体系统,假设本次任务中需要处理 m 种不同模态的信息,则需要构建 $m+1$ 个智能体,其中包括 m 个负责处理单一模态的成员智能体(G_1, G_2, \dots, G_m)和1个负责综合处理多模态信息的领导智能体 G 。成员智能体通过编码器提取样本各模态的特征向量,领导智能体则通过

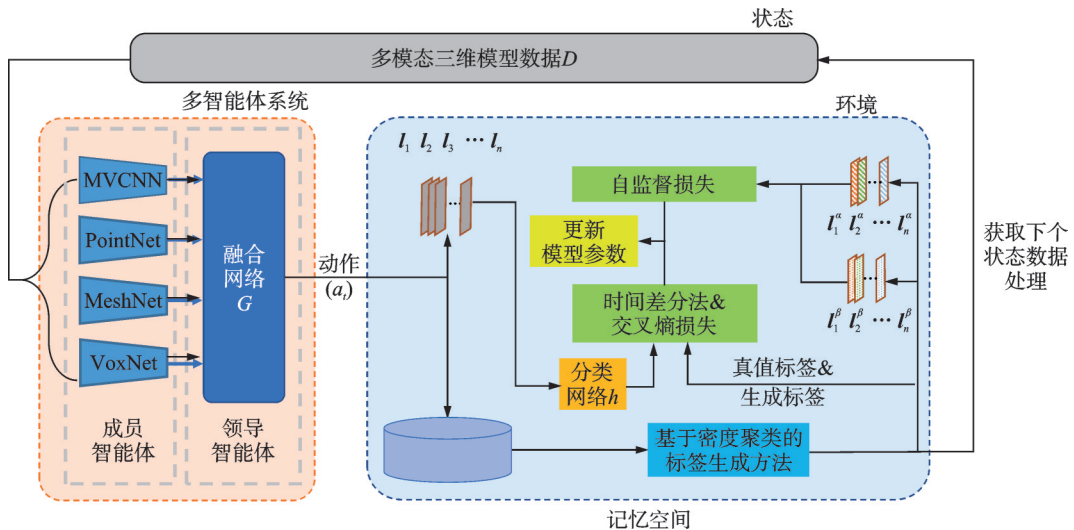


图1 多智能体协同的开放域多模态三维模型识别算法基本框架

Fig.1 Framework of multi-agent collaborative open-domain multimodal 3D model recognition algorithm

特征融合网络整合这些信息。

(3) 动作:智能体根据不同的状态采取相应的动作。领导智能体整合成员智能体提取的特征信息,生成全局特征向量 l_t 作为动作 a_t 输入环境,完成交互过程。

(4) 环境:环境 E 是与智能体交互的实体,负责根据智能体的行为提供后续状态和反馈。在本文中,环境将记录智能体的所有动作,并根据这些动作为无标签数据生成伪标签。环境的伪标签生成过程与智能体的分类策略形成闭环,推动模型自适应调整。在智能体与环境完成一次交互后,环境会根据当前的数据标注情况选择一批样本作为下一个状态 s_{t+1} , 详细的状态转移过程会在下一节阐述。

(5) 奖励:奖励 r_t 用于调整模型的参数,是环境对智能体动作的反馈。智能体的动作会将每个样本指向一个分类结果,将该分类结果与真值标签或生成的伪标签进行比较,如果一致,则 r_t 为 1, 若不一致或该样本没有任何标签则 r_t 为 0。在强化学习中,通常使用折扣因子 $\gamma \in [0, 1]$ 来表示未来奖励的重要性,于是状态 s_t 的累计期望奖励 V_t 可表示为 $V_t = \sum_{j=0}^{\infty} \gamma^j \cdot r_{t+j}$ 。

本文的目标是:基于上述定义,训练出能够解决三维模型新类发现问题的智能体。智能体的任务是在准确识别已知类别样本的同时,基于其获取的先验知识与环境反馈,进一步分类剩余无标签样本。在强化学习框架下,目标转换为最大化期望的累积奖励 $Q^*(s, a)$, 即在给定分类策略下,最大化在状态 s 中采取动作 a 所获得的期望奖励,可以表示为

$$Q^*(s, a) = \mathbb{E}[r_{t+1} + \gamma Q(s_{t+1}, a_{t+1})] = r_s^a + \gamma \sum_{s' \in S} P_{ss'}^a V(s') \quad (1)$$

$$V(s) = \sum_{a \in A} P_{sa} Q(s, a) \quad (2)$$

式中: r_{t+1} 为 $t+1$ 时刻的奖励值; r_s^a 为在状态 s 、动作 a 下的奖励值; $P_{ss'}^a$ 表示在状态 s 中采取动作 a 后, 转移到特定状态 s' 的概率; P_{sa} 表示在使用给定的分类策略时面对状态 s 采取特定动作 a 的概率; A 为动作集合。

要找出一个最优的分类策略来解决新类发现问题,即找出 $V^*(s)$ 和 $Q^*(s, a)$ 的最大值,表达式为

$$V^*(s) = \max_a Q^*(s, a) \quad (3)$$

$$Q^*(s, a) = r_s^a + \gamma \sum_{s' \in S} P_{ss'}^a V^*(s') \quad (4)$$

式中 S 为状态集合。

由于转移概率分布 P 难以显式建模,实际应用中通过随机采样的方法来获取近似值。结合式(3)和式(4),有

$$\begin{aligned} Q(s, a) &\approx r_s^a + \gamma \max_{a'} Q(s', a') \approx (1 - \alpha) Q(s, a) + \alpha [r_s^a + \gamma \max_{a'} Q(s', a')] = \\ &Q(s, a) + \alpha [r_s^a + \gamma \max_{a'} Q(s', a') - Q(s, a)] = Q(s, a) + \alpha \delta_{TD} \end{aligned} \quad (5)$$

式中: s' 和 a' 分别代表特定状态和特定动作; α 为学习率, δ_{TD} 为时间差分。

通过使用时间差分(Temporal-difference, TD)算法^[14]来训练深度Q网络,根据一阶TD误差定义本方法中强化学习部分的损失函数 \mathcal{L}_{TD} 。对于 V_t 中的折扣因子 γ , 由于所有数据是独立同分布的,于是智能体只需关注当前的奖励,即 $\gamma = 0$ 。因此,TD损失函数可表示为

$$\mathcal{L}_{TD} = \frac{1}{2} (Q(s, a) - r_t)^2 \quad (6)$$

通过借鉴Nie等^[15]的工作,本算法设计了复合损失函数用于平衡模型的动态探索与稳定收敛。具体而言,除了使用 \mathcal{L}_{TD} 来最大化累积奖励外,还引入了交叉熵损失 \mathcal{L}_{CE} 用于确保已知类别与高置信度伪标签的分类准确性。此外,自监督对比损失 \mathcal{L}_{SS} 允许多智能体系统挖掘多模态特征间的内在关联性增强模型对噪声和模态缺失的鲁棒性。因此,最终的损失函数被定义为

$$\mathcal{L} = (1 - \lambda_1 - \lambda_2)\mathcal{L}_{TD} + \lambda_1\mathcal{L}_{CE} + \lambda_2\mathcal{L}_{SS} \quad (7)$$

式中: λ_1 和 λ_2 为超参数,用于调节各项损失函数对最终训练过程的影响; \mathcal{L}_{CE} 代表交叉熵损失; \mathcal{L}_{SS} 则是与自监督学习方法相关的损失函数。有关这些损失函数的具体实现将在后文中详细阐述。

1.2 基于密度聚类的标签生成方法

当面对未知对象时,经验丰富的个体可通过部分显著特征实现有效分类。受此认知机制启发,本文在强化学习环境中构建了基于密度聚类的标签生成方法,用于简化开放域场景下的三维模型识别难题,其基本流程如图2所示。该方法通过模拟人类学习机制,构建了动态约束调整框架。基于标注数据的预训练使模型具备基础特征识别能力。在此条件下,具有显著特征或结构简单的未标注样本,其特征向量在数学空间中的距离显著缩短。因此,本文选择密度聚类算法DBSCAN^[16]作为基础实现方法。

DBSCAN算法的核心参数包含邻域半径(eps)和最小邻域样本数(min_samples)。模型预训练后,通过对有标签样本进行聚类分析,在保证聚类精度的前提下获取两组聚类参数:一组为严格参数集,其采用最小可行eps与最大允许min_samples;另一组为宽松参数集,其采用最大允许eps与最小可行min_samples。在本方法实施过程中,首先采用严格参数集对无标签样本的特征向量进行聚类,剔除噪声点后为可靠聚类结果赋予伪标签,这类伪标签被称为固定伪标签。通过余弦退火策略动态调整参数,逐步增大eps同时减小min_samples,直至末次迭代采用宽松参数集。该机制促使前期噪声点逐步融入有效聚类,实现无标签样本向有标签样本的渐进式转化,在保证伪标签质量稳定性的前提下完成数据标注的自动化扩展。

对于在当次迭代中被判定为噪声点的样本,设置了动态探索机制。通过对强化学习中的 ϵ -greedy算法稍加改动,构建了渐进探索学习范式。具体而言,在训练初期设置较高初始探索概率 $\epsilon \in [0, 1]$,允许模型以该概率为噪声点样本随机分配不稳定的伪标签,这类伪标签被称为动态伪标签。随着迭代次数增加,按线性衰减规则降低探索概率,驱动学习过程从广泛探索向精准利用过渡。 ϵ 可表示为

$$\epsilon = \max \left\{ \epsilon_{\min}, 1 - \frac{(1 - \epsilon_{\min}) \cdot \text{step}}{\text{total}} \right\} \quad (8)$$

式中:total表示总训练迭代次数;step为当前已完成的训练迭代次数; ϵ_{\min} 为一个超参数,调整其值以确保即使在训练后期模型仍保持一定程度的探索能力。

为在高占比无标签样本的开放域场景下实现有效的三维模型识别,需平衡模型对已知类别知识保持、新类特征学习与未知类探索三者的关系。具体而言,环境在反馈下一状态时,会按照3:1的比例随机抽取无标签样本与有标签样本,确保模型在探索新类的同时巩固已知类别的判别能力。同时,保持抽取的无标签样本中拥有可靠伪标签样本的占比为 η 。

在具体实现中,环境内设置了一个记忆单元,用于存储每个训练周期的智能体动作和样本标签信息,包括有标签样本的真实标签和无标签样本的伪标签。其中要注意的是,由于应用 ϵ -greedy算法而获得的伪标签并不可靠,因此这部分伪标签只会在当前训练周期中使用而不会被存储。在每个训练周期

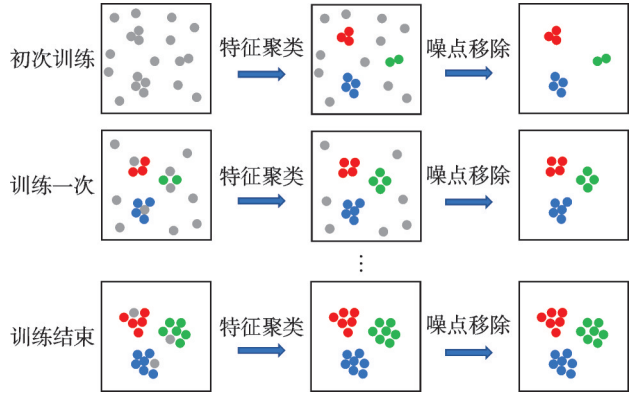


图2 基于密度聚类的标签生成方法具体流程

Fig.2 Process of density clustering strategy to generate pseudo-labels

结束时,本聚类方法会应用于记忆单元中的所有动作,并为非噪声样本赋予固定伪标签。这些标签一旦生成便被固定,即使在后续的训练中相应样本被识别为噪声点,标签也不会被清除。这一策略的目的是防止标签频繁变化对模型稳定性和学习过程的连续性产生不利影响。标签的固定可以确保模型在每轮训练过程中充分利用已生成的标签,减少不必要的干扰,并避免数据的重新标注,从而促进模型逐步收敛至更高的准确度。最后,清空记忆单元中的动作记录,开始新一轮训练。

在环境内设置了多层感知机来将智能体的动作进一步处理为概率向量 $\hat{y} \in \mathbf{R}^c$, 其中 c 代表数据集中的类别总数。基于此,交叉熵损失函数可表达为

$$\mathcal{L}_{CE} = \sum_{i=1}^n [-u_i \cdot y_i^1 \log \hat{y}_i + (u_i - 1) \cdot y_i^p \log \hat{y}_i] \quad (9)$$

式中:当 $x_i \in D^1$ 时, $u_i = 1$, 反之, $u_i = 0$; y_i^1 表示有标签样本的真实标签; y_i^p 为无标签样本的伪标签。

1.3 多智能体系统

受人类协同认知机制的启发,本文提出了一种多智能体协同的跨模态学习范式。认知科学研究表明,群体智能通过分布式知识整合能够显著提升新类识别能力,其中各成员从异构视角进行特征解析,领导者通过信息融合形成全局决策。这种协作模式与多模态学习具有内在一致性,即数据蕴含的互补信息可通过系统化融合提升表征完备性。如图3所示,本文构建的多智能体协同系统通过结构化分工有效实现了对三维模型多模态信息的处理与融合。

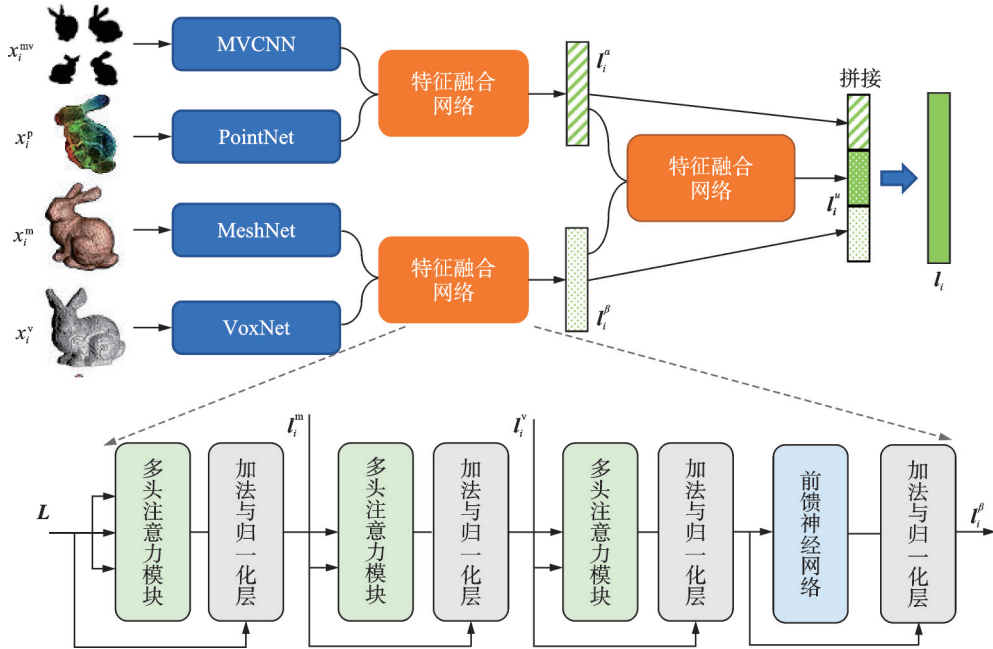


图3 多智能体特征融合网络

Fig.3 Multi-agent feature fusion network

对于一个给定的三维模型样本 x_i , 其有多种模态表达, 本文选取了多视图、点云、网格和体素4种模态, 分别表示为 x_i^{mv} 、 x_i^p 、 x_i^m 和 x_i^v 。成员智能体会独立分析相关模态并生成对应的特征向量。每个成员智能体由对应模态的经典特征提取网络构成, 对于多视图、点云、网格和体素数据, 分别使用 MVCNN^[17]、PointNet^[18]、MeshNet^[19] 和 VoxNet^[20] 提取对应模态的局部特征向量 I_i^{mv} 、 I_i^p 、 I_i^m 和 I_i^v 。随

后,领导智能体通过数个特征融合网络分步融合局部特征信息,每个特征融合网络的结构基本一致,如图3所示,其由多头自注意力层、前馈神经网络层以及归一化层构成。多头注意力模块负责捕捉不同模态特征间的关联信息,前馈神经网络层对融合后的特征进行非线性变换,归一化层则用于稳定训练过程,确保特征尺度一致。其中, L 表示由Liu等^[21]的方法计算得来的标签嵌入向量,其包含了所有类别的关键词信息,在特征融合过程中, L 为特征融合提供了类别先验知识,引导特征融合方向,使融合后的特征向量更具判别性。

将成员智能体提取的多模态信息两两分组,若有模态缺失,则以零向量替代。若需融合的特征向量超过两个,则添加对应数量的多头注意力层以实现多模态信息的动态加权整合。然后,使用注意力机制融合这两组特征向量,得到两个中间特征向量 l_i^α 和 l_i^β ,随后再次应用注意力机制融合 l_i^α 和 l_i^β ,得到融合特征向量 l_i^μ ,最后将 l_i^α 、 l_i^β 与 l_i^μ 拼接在一起作为全局特征向量 l_i 输出给多层感知机进行分类。

由于在特征融合过程中产生的中间特征向量对应的是同一样本,因此它们之间具有较高的相似性,可以对这两个中间特征向量采用自监督学习方法,进一步帮助模型进行训练。基于此,自监督损失函数 \mathcal{L}_{SS} 可表达为

$$\mathcal{L}_{SS} = -\frac{1}{n} \sum_{i=1}^n \log \frac{e^{\cos(l_i^\alpha, l_i^\beta)/\tau}}{\sum_{j=1}^n e^{\cos(l_i^\alpha, l_i^j)/\tau}} \quad (10)$$

式中: τ 为温度参数,在本方法中设置 $\tau=2$; $\cos(x, y)$ 表示向量 x 和 y 的余弦相似度。

综上所述,本文研究方法的详细训练流程如算法1所示。

算法1 基于强化学习的多模态信息融合新类发现网络算法

输入:三维模型多视图数据 x_i^{mv} ,点云数据 x_i^{pc} ,网格数据 x_i^m ,体素数据 x_i^v

输出:全局特征向量 l_i ,模型预测结果 \hat{y}

- (1) 随机初始化模型参数
- (2) 使用有标签数据预训练模型,并通过1.2节方法获取聚类参数组
- (3) 清空动作缓存空间 M_1 ,并将有标签数据的所有标签存储至标签缓存空间 M_2
- (4) for $i=1, 2, \dots, N$ do
- (5) while not done do
- (6) 从环境获取状态 s_t
- (7) 智能体面对 s_t 作出动作 a_t
- (8) 环境接收 a_t 并根据 M_2 中数据反馈奖励 r_t ,同时将 a_t 存储至动作缓存空间 M_1
- (9) 环境通过探索为无标签数据生成仅本轮训练使用的伪标签
- (10) 根据式(7)计算损失函数
- (11) 反向传播并更新智能体参数
- (12) end while
- (13) 对 M_1 使用1.2节方法为部分无标签数据生成伪标签并存储至标签缓存空间 M_2
- (14) 清空 M_1
- (15) end for

2 实验与评估

2.1 数据集

为了验证所提方法的有效性,本节使用三维模型数据集OS-MN40^[22]和OS-MN40-Miss^[22]进行了

验证实验。此外,为了评估所提出框架在跨领域泛化能力方面的表现,使用二维图片数据集 CIFAR-10^[23]进行了迁移实验。OS-MN40是一个开放域三维物体检索数据集,大多数样本选自 ModelNet40^[24],共涵盖40个类别,其中包括8个类别的2 822个有标签样本,另外32个类别的8 527个无标签样本。OS-MN40-Miss是OS-MN40的另一个版本,采用了随机丢弃任意模态的方式构成,丢弃的概率为0.4,该数据集旨在模拟模态缺失问题。CIFAR-10是计算机视觉领域广泛使用的数据集,共10个类别,每个类别包含6 000张图像。数据集中有50 000张训练图像和10 000张测试图像,在实验过程中选取了其中5个类别作为有标签数据集,剩余5个类别作为无标签数据集。

2.2 实验设置与评价标准

在数据处理方面,按照如下方法对数据集中的数据进行处理。对于三维模型的多模态数据,多视图图像的尺寸调整为224像素×224像素×3像素,点云数据由1 024个点的三维坐标表示,体素数据的尺寸为32像素×32像素×32像素,网格数据由500个三角面片构成。为了确保各模态特征向量维度的一致性,在每个特征提取网络的分支后添加了一个全连接层,使得每个分支输出的特征向量维度固定为512。对于迁移实验中的二维图像,通过采用数据增强技术为每张图像生成两种不同的表示作为图像的伪多模态信息。增强方法包括随机裁剪并调整大小、水平翻转、颜色抖动和灰度化,这些操作会根据设定的概率随机应用,使用经典网络ResNet-18^[25]作为特征提取器。

在训练设置方面,网络参数的优化采用了带有0.000 1权重衰减的Adam优化器。初始学习率设置为0.001,并随着迭代次数的增加线性衰减,所有模型的初始参数通过随机初始化。实验硬件平台包括两块NVIDIA 1080Ti GPU、32 GB内存,以及Intel Xeon E5-2609 V4,1.70 GHz,8核处理器。所有实验均在PyTorch平台上进行。

在评估指标方面,主要评估所提方法在分类与检索任务上的性能。对于分类任务,使用了分类精度来进行评估。对于检索任务,使用了精确率-召回率曲线(Precision-recall curve, PR curve)、最近邻(Nearest neighbor, NN)、平均精度均值(mean Average precision, mAP)、归一化折损累计增益(Normalized discounted cumulative gain, NDCG)和平均归一化修正检索秩(Average normalized modified retrieval rank, ANMRR)。对于所有的数值型指标,除ANMRR值与检索性能负相关外,其余指标均是检索性能正相关。

2.3 对比实验

为了评估本研究方法在检索任务中的表现,选择了一些典型的方法进行对比。这些方法中既包含对于三维模型新类发现算法的研究,也包含对于二维图像新类发现算法的研究。对于专注于二维图像的方法,在实验过程中会将其特征提取器调整为MVCNN网络^[17]以适应三维模型的数据输入,对于专注于三维模型的方法,不对其进行任何算法上的调整。所有对比方法均在与本文方法相同的实验设置下进行,实验结果如表1所示。由于不同方法使用了不同的模态,因此在表中同时列出了各方法所使用的模态情况。实验结果表明,采用4种模态的模型在性能上显著优于仅使用部分模态的模型。使用部分模态的模型在mAP、NN、NDCG和ANMRR指标上的平均值分别为0.381 6、0.836 5、0.545 3和0.624 9,而使用4种模态的模型在这4个指标上的平均值为0.553 5、0.891 3、0.661 6和0.476 2。此外,二维图像新类发现方法在迁移至三维模型新类发现问题后,其整体表现显著落后于专注于三维模型的方法,这可能是由于现有的二维新类别发现方法受限于图像信息的单一性,无法充分利用多模态特征,从而导致其在无标签数据占比较高时难以取得理想性能。这进一步凸显了针对多模态数据研究新类发现方法的重要性。通过对图4中不同模态的PR曲线进一步分析可以发现,不同模态对模型性能的贡献存在差异。例如,点云数据在检索任务中表现最优,其次是多视图表示,而网格和体素模态的性能相

表1 各算法在 OS-MN40 和 OS-MN40-Miss 数据集上的性能比较

Table 1 Comparison of evaluation results on OS-MN40 and OS-MN40-Miss datasets

数据集	方法	多视图	点云	网格	体素	mAP	NN	NDCG	ANMRR
OS-MN40	KCL ^[26]	✓	×	×	×	0.335 6	0.810 4	0.505 7	0.672 5
	MCL ^[27]	✓	×	×	×	0.348 9	0.822 5	0.518 9	0.663 4
	DTC ^[2]	✓	×	×	×	0.362 4	0.836 2	0.530 1	0.654 1
	UNO ^[8]	✓	×	×	×	0.375 2	0.849 7	0.543 0	0.645 3
	CMS ^[28]	✓	×	×	×	0.382 2	0.852 4	0.545 1	0.641 1
	AGCD ^[29]	✓	×	×	×	0.413 5	0.843 3	0.563 9	0.612 4
	TT_VODKA ^[22]	✓	×	×	✓	0.329 3	0.809 4	0.501 7	0.651 9
	CU_MM ^[22]	✓	✓	×	×	0.408 3	0.867 7	0.577 3	0.583 6
	MM_AI_SoCSE_KLETech ^[22]	✓	✓	×	×	0.415 2	0.864 6	0.580 8	0.575 0
	NUC_AICV ^[22]	✓	✓	✓	✓	0.418 3	0.863 5	0.566 0	0.575 0
	Ome_Candy ^[22]	✓	×	×	×	0.445 0	0.808 3	0.586 9	0.550 0
HCMUS ^[22]	✓	✓	✓	✓	0.586 1	0.924 0	0.701 8	0.430 8	
本文方法	✓	✓	✓	✓	0.656 0	0.886 5	0.717 1	0.364 8	
OS-MN40-Miss	HCMUS ^[22]	✓	✓	✓	✓	0.287 3	0.788 5	0.463 2	0.678 9
	TT_VODKA ^[22]	✓	×	×	✓	0.297 6	0.782 3	0.471 0	0.680 9
	MM_AI_SoCSE_KLETech ^[22]	✓	✓	×	×	0.389 3	0.832 3	0.548 9	0.593 7
	本文方法	✓	✓	✓	✓	0.438 5	0.866 7	0.593 7	0.554 2

对较差。这可能是因为点云数据能够更直接地反映三维模型的几何结构,而多视图表示则能够提供丰富的视角信息。网格和体素模态虽然也能提供一定的几何信息,但在特征提取和表示上可能不如点云和多视图数据有效。

对于 OS-MN40-Miss 数据集,缺失的模态特征被零向量替代,这与其他一些方法使用零或随机数的做法类似。总体来看,本文方法在 4 个评价指标上均优于其他方法,但当模态随机缺失时,模型在检索任务上的性能下降约 20%。具体来说,模态缺失会导致模型在处理无标签数据时面临更多的不确定性。例如,当某一模态缺失时,模型可能无法充分利用该模态的信息来进行有效的特征提取和分类,从而影响整体性能。此外,模态缺失还可能导致模型在生成伪标签时的准确性下降,进一步影响模型的训练和优化。

具体而言,在 OS-MN40 数据集上,本文方法的 mAP、NN、NDCG 和 ANMRR 指标分别达到 0.656、0.886 5、0.717 1 和 0.364 8,整体优于其他算法。例如,相比性能较好的 HCMUS 方法^[22],本文方法的 mAP 高出 0.07, NDCG 高出 0.015, ANMRR 低了 0.066,表明多智能体协同能显著提升检索精度和稳定性。在 OS-MN40-Miss 数据集上,尽管模态随机缺失,本文方法仍取得 0.438 5 的 mAP,优于 MM_AI_SoCSE_KLETech 和 TT_VODKA 等方法^[22],凸显了多智能体系统在模态缺失时的鲁棒性。进一步分析发现,多智能体协同使各模态优势互补,融合获取更加丰富特征的信息,提升模型对复杂样




图4 本文方法中不同模态数据的 PR 曲线
Fig.4 PR curves of different modalities in the proposed method

本的理解和识别。此外,多智能体系统通过分工与协作,模拟人类学习过程,高效探索多模态特征空间,优化模型识别策略。实验表明,本文方法在开放域三维模型识别任务中具有显著优势,为该领域研究提供了有效的解决方案和创新思路。

2.4 消融实验

为了深入探讨各个组件对本文模型训练性能的影响,在 OS-MN40 数据集上进行了消融实验,在不同训练周期下对模型的 mAP 指标进行了评估。实验结果如表 2 所示,评估的组件包括自监督模块、基于强化学习的 TD 算法以及基于密度聚类的标签生成方法。

表 2 在 OS-MN40 数据集上不同训练周期下使用不同组件的 mAP 性能评估

Table 2 Evaluation of mAP metric for different components at different epoch counts on OS-MN40 dataset

组件模块				训练周期				
交叉熵	TD 算法	自监督	标签生成	5	10	20	30	40
✓	×	×	×	0.341 3	0.339 6	0.342 2	0.340 8	0.341 3
✓	×	×	✓	0.554 9	0.588 6	0.593 6	0.596 2	0.554 9
✓	✓	×	×	0.341 4	0.342 3	0.344 3	0.342 5	0.341 4
✓	✓	×	✓	0.598 7	0.635 4	0.640 9	0.642 3	0.598 7
✓	×	✓	×	0.361 3	0.376 4	0.369 6	0.380 2	0.361 3
✓	×	✓	✓	0.561 8	0.610 2	0.618 8	0.620 3	0.561 8
✓	✓	✓	×	0.364 5	0.378 2	0.380 1	0.379 9	0.364 5
✓	✓	✓	✓	0.607 2	0.648 8	0.656 0	0.656 0	0.607 2

根据表 2 中的数据,可以得出以下结论:

(1) 在强化学习环境中构建的基于密度聚类的标签生成方法是本研究的核心组件。可靠的伪标签能够有效提高模型的性能,显著提升无标签数据的处理能力。

(2) 强化学习框架的使用有效提高了模型的训练效果。对于检索任务而言,自监督模块的加入带来了约 3% 的提升,TD 算法的加入贡献了约 5% 的提升。当自监督模块和 TD 算法结合使用时,模型的性能得到了进一步提升,综合提升幅度达到 6%,这证明了强化学习框架中环境的反馈对于训练过程的积极作用。

为了能够更加全面地评估模型性能,分别在有监督与新类发现设定下对模型的分分类准确率进行了观察,结果如表 3 所示。实验结果表明,本文方法可以有效完成有监督学习任务,但多个功能模块的加入可能导致算法在有监督条件下出现过拟合现象。在新类发现设定下,引入自监督损失和强化学习损失后,分类准确率提升了约 2%,验证了在开放域条件下结合自监督学习与强化学习的有效性。

2.5 可视化实验

图 5 展示了所提方法在 OS-MN40 数据集上训练时不同训练周期下特征空间的变化情况。在进行可视化分析时,首先使用主成分分析(Principal component analysis, PCA)^[30]将所有无标签数据的全局特征向量 l_i 从 512 维降低至 128 维,然后利用 t-SNE^[31]将处理后的特征向量投影到二维空间,便于观察数据的分布情况。

表 3 模型的分分类准确率评估

Table 3 Evaluation of classification accuracy of the proposed model

损失函数	数据集	
	OS-MN40	ModelNet40
\mathcal{L}_{CE}	0.752	0.986
$\mathcal{L}_{CE} + \mathcal{L}_{TD}$	0.769	0.979
$\mathcal{L}_{CE} + \mathcal{L}_{SS}$	0.763	0.935
$\mathcal{L}_{CE} + \mathcal{L}_{TD} + \mathcal{L}_{SS}$	0.773	0.926

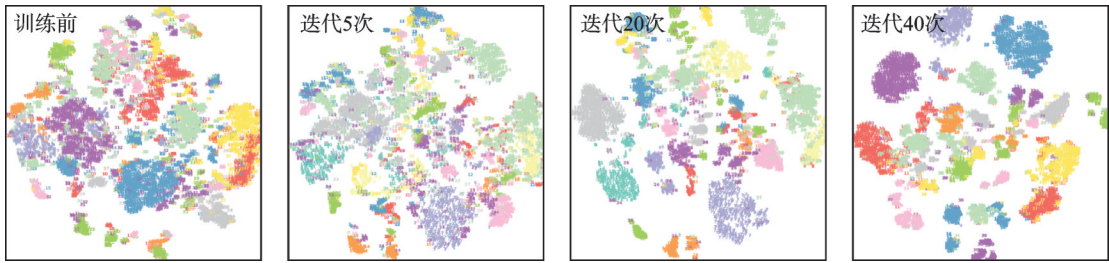


图5 OS-MN40数据集无标签数据的T-SNE可视化实验

Fig.5 T-SNE visualization of unlabeled samples on OS-MN40 dataset

从图5中可以看出,在使用有标签数据集预训练模型后,尽管对于部分较为复杂的样本而言,不同类别样本的特征向量在特征空间中仍然聚类在一起导致难以分辨,但还是有一部分无标签数据的特征向量因具有较高的相似度而较为聚集,这表明模型已经能够初步分辨出部分无标签数据。经过5次训练迭代后,不同类别数据之间的区分度已经相对提高。这一现象验证了基于密度聚类的标签生成方法的有效性,在训练过程中逐步放宽约束条件可以在保证聚类准确性的同时减少噪声点的数量。进一步观察发现,经过40个训练周期后,无标签数据集中不同类别的样本变得更加可区分,而同类别样本的特征向量也更加聚集。这表明本文方法能够有效提高模型在开放域新类发现问题中的表现。

为了评估本文方法在开放域场景中的性能,随机从查询数据集中选取了5个三维模型,并可视化了每个样本的前10个检索结果。如图6所示,其中错误的检索结果通过红色虚线方框标出。可以发现,瓶子和椅子的检索结果较为优秀,台灯和收音机的检索效果则比较一般,而杯子的检索表现是所有类别中最差的。结合不同类别数据在数据集中的占比,可以发现表现较好的类别在数据集中的样本数量相对较多,更能够从训练中受益。花瓶与杯子在几何形状上的相似度较高,同时花瓶在训练数据中的




图6 本文方法在OS-MN40数据集检索结果的可视化

Fig.6 Visualization of retrieval examples using the proposed method on OS-MN40 dataset

占比是杯子的9倍,这表明当训练数据有限时,本文方法在检索任务中面临挑战,难以取得有效的竞争力。

2.6 迁移实验

前述实验结果充分证明了本文方法在开放域多模态三维模型识别问题中的有效性,尤其是在处理开放域环境下无标签数据时具有优异表现。为了进一步验证该方法的通用性和潜力,本节通过将三维模型的新类发现方法迁移到二维图像领域并与现有的典型方法进行对比实验来评估该方法在不同数据模式下的适应性,得到了不同方法在有标签数据、无标签数据以及整个数据集上的分类准确性,如表4所示。

由于二维图像本身不具备三维模型的多模态特性,为适配本研究算法,为二维图像生成了伪多模态数据,即通过数据增强方法(如随机裁剪、水平翻转和颜色抖动等)为每张原始图像生成两种差异化增强版本,将其作为伪多模态数据分别输入到两个独立的成员智能体中。模拟三维场景中

多模态数据的特征差异,领导智能体调整为仅使用一个特征融合网络,通过多头自注意力层动态加权融合伪模态特征,进而保留算法框架的一致性。通过对比各方法的性能表现,发现本文方法在准确率上优于其他方法。结果表明,本文方法不仅能够处理三维模型中的新类发现问题,而且成功地将其扩展到二维图像领域,并在该领域取得了优异的性能。由此证明,本文方法的网络架构在不同领域开放域环境中的应用具有广泛的潜力。

3 结束语

本文提出了一种多智能体协同的开放域多模态三维模型识别算法。算法通过构建多智能体系统模拟人类协作学习过程,结合奖励机制驱动智能体探索多模态特征空间,并利用自监督学习优化分类策略。同时,在强化学习环境中设计了一种基于密度聚类的渐进式标签生成方法,通过动态调整聚类参数迭代生成高质量伪标签,有效地缓解了标签缺失导致的性能瓶颈。这些策略的应用使得模型的训练范式更加贴近人类的学习过程,从而构建了更为智能化的模型。在多个数据集上的广泛实验验证了该方法的有效性和可迁移性。本文所提算法能够适应不同的数据模态和任务类型,尤其是在处理复杂和未见过类别时,能够有效地进行知识迁移与融合,为未来在其他复杂任务中应用该框架,尤其是在跨模态和开放域问题上的拓展提供了有力的支持。

参考文献:

- [1] 章秦,刘紫琪,张晓林,等.基于深度学习的开放域识别研究综述[J/OL].计算机学报,1-37[2025-01-15].<https://affgc1d129f57bb244a4h9vv6wcucqk0n6quxfgy.eds.tju.edu.cn/kcms/detail/11.1826.TP.20250115.1150.002.html>.
ZHANG Qin, LIU Ziqi, ZHANG Xiaolin, et al. Deep learning based open set recognition: A survey [J/OL]. Chinese Journal of Computers, 1-37[2025-01-15]. <https://affgc1d129f57bb244a4h9vv6wcucqk0n6quxfgy.eds.tju.edu.cn/kcms/detail/11.1826.TP.20250115.1150.002.html>.
- [2] HAN K, VEDALDI A, ZISSERMAN A. Learning to discover novel visual categories *via* deep transfer clustering[C]//

表4 在CIFAR-10数据集上的模型分类准确性评估

Table 4 Evaluation of classification accuracy on CIFAR-10 dataset

方法	分类准确率		
	有标签数据	无标签数据	全部数据
DTC ^[2]	0.539	0.395	0.476
UNO ^[8]	0.916	0.693	0.805
ORCA ^[32]	0.882	0.904	0.897
MM ^[33]	0.932	0.914	0.923
PromptCAL ^[28]	0.948	0.943	0.946
CMS ^[29]	0.942	0.935	0.938
AGCD ^[34]	0.953	0.947	0.950
CPT ^[35]	0.956	0.952	0.954
本文方法	0.961	0.952	0.956

- Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, Korea: IEEE, 2019: 8400-8408.
- [3] LIU Y, CAI Y, JIA Q, et al. Novel class discovery for ultra-fine-grained visual categorization[C]//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2024: 17679-17688.
- [4] LIU J, WANG Y, ZHANG T, et al. Open-world semi-supervised novel class discovery[EB/OL]. (2023-05-22). <https://arxiv.org/abs/2305.13095>.
- [5] 谢云轩, 陈松灿. 分布式稀疏软大间隔聚类[J]. 数据采集与处理, 2024, 39(2): 376-384.
XIE Yunxuan, CHEN Songcan. Distributed sparse soft large margin clustering[J]. Journal of Data Acquisition and Processing, 2024, 39(2): 376-384.
- [6] 柳菁, 邱紫滢, 郭茂祖, 等. 基于 Tukey 规则与初始中心点优化的 K-means 聚类改进算法[J]. 数据采集与处理, 2023, 38(3): 643-651.
LIU Jing, QIU Ziyang, GUO Maozu, et al. Improved K-means clustering algorithm based on Tukey rule and initial center point optimization[J]. Journal of Data Acquisition and Processing, 2023, 38(3): 643-651.
- [7] 董永峰, 邓亚哈, 董瑶, 等. 基于深度学习的聚类综述[J]. 计算机应用, 2022, 42(4): 1021-1028.
DONG Yongfeng, DENG Yahan, DONG Yao, et al. Survey of clustering based on deep learning[J]. Journal of Computer Applications, 2022, 42(4): 1021-1028.
- [8] FINI E, SANGINETO E, LATHUILIÈRE S, et al. A unified objective for novel class discovery[C]//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision (ICCV). Montreal, QC, Canada: IEEE, 2021: 9264-9272.
- [9] WANG Y, CHEN Z, YANG D, et al. Self-cooperation knowledge distillation for novel class discovery[EB/OL]. (2024-07-02). <https://arxiv.org/abs/2407.01930>.
- [10] ZHU F, MA S, CHENG Z, et al. Open-world machine learning: A review and new outlooks[EB/OL]. (2024-03-01). <https://arxiv.org/pdf/2403.01759>.
- [11] ZHOU J, LIU Y, CHEN Q. Novel class discovery in chest X-rays via paired images and text[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(7): 7650-7658.
- [12] NIE W, ZHANG C, SONG D, et al. Deep reinforcement learning framework for thoracic diseases classification via prior knowledge guidance[J]. Computerized Medical Imaging and Graphics, 2023, 108: 102277.
- [13] PATEL U, PATEL V. Active learning-based hyperspectral image classification: A reinforcement learning approach[J]. The Journal of Supercomputing, 2024, 80(2): 2461-2486.
- [14] WATKINS C. Learning from delayed rewards[D]. London: King's College, 1989.
- [15] NIE W, LIANG Q, WANG Y, et al. MMFN: Multimodal information fusion networks for 3D model classification and retrieval[J]. ACM Transactions on Multimedia Computing, Communications, and Applications, 2020, 16(4): 1-22.
- [16] ESTER M, KRIEGER H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]//Proceedings of the Second International Conference on Knowledge Discovery and Data Mining. Portland, Oregon: ACM, 1996: 226-231.
- [17] SU H, MAJI S, KALOGERAKIS E, et al. Multi-view convolutional neural networks for 3D shape recognition[C]//Proceedings of 2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015: 945-953.
- [18] CHARLES R Q, HAO S, MO K, et al. PointNet: Deep learning on point sets for 3D classification and segmentation[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 77-85.
- [19] FENG Y, FENG Y, YOU H, et al. MeshNet: Mesh neural network for 3D shape representation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 8279-8286.
- [20] MATURANA D, SCHERER S. VoxNet: A 3D convolutional neural network for real-time object recognition[C]//Proceedings of 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Hamburg, Germany: IEEE, 2015: 922-928.
- [21] LIU S, ZHANG L, YANG X, et al. Query2label: A simple transformer way to multi-label classification[EB/OL]. (2021-07-22). <https://arxiv.org/abs/2107.10834>.

- [22] FENG Y, GAO Y, ZHAO X, et al. SHREC'22 track: Open-set 3D object retrieval[J]. *Computers & Graphics*, 2022, 107: 231-240.
- [23] KRIZHEVSKY A. Learning multiple layers of features from tiny images[M]//*Handbook of Systemic Autoimmune Diseases*. [S.l.]: [s.n.], 2009.
- [24] WU Z, SONG S, KHOSLA A, et al. 3D ShapeNets: A deep representation for volumetric shapes[C]//*Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Boston, MA, USA: IEEE, 2015: 1912-1920.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//*Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [26] HSU Y C, LV Z, KIRA Z. Learning to cluster in order to transfer across domains and tasks[EB/OL]. (2017-11-28). <https://arxiv.org/abs/1711.10125>.
- [27] HSU Y C, LV Z, SCHLOSSER J, et al. Multi-class classification without multi-class labels[EB/OL]. (2019-01-02). <https://arxiv.org/abs/1901.00544>.
- [28] ZHANG S, KHAN S, SHEN Z, et al. PromptCAL: Contrastive affinity learning via auxiliary prompts for generalized novel category discovery[C]//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Vancouver, BC, Canada: IEEE, 2023: 3479-3488.
- [29] CHOI S, KANG D, CHO M. Contrastive mean-shift learning for generalized category discovery[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA, USA: IEEE, 2024: 23094-23104.
- [30] ABDI H, WILLIAMS L J. Principal component analysis[J]. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2010, 2(4): 433-459.
- [31] MURPHY K, SCHÖLKOPF B, VAN DER MAATEN L. Accelerating t-SNE using tree-based algorithms[J]. *Journal of Machine Learning Research*, 2014, 15(1): 3221-3245.
- [32] CAO K, BRBIC M, LESKOVEC J. Open-world semi-supervised learning[C]//*Proceedings of International Conference on Learning Representations (ICLR)*. [S.l.]: SNAP, 2022.
- [33] CHI H, LIU F, HAN B, et al. Meta discovery: Learning to discover novel classes given very limited data[C]//*Proceedings of the 10th International Conference on Learning Representations*. [S.l.]: [s.n.], 2022.
- [34] MA S, ZHU F, ZHONG Z, et al. Active generalized category discovery[C]//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Seattle, WA, USA: IEEE, 2024: 16890-16900.
- [35] YANG M, YIN J, GU Y, et al. Consistent prompt tuning for generalized category discovery[J]. *International Journal of Computer Vision*, 2025, 133(7): 4014-4041.

作者简介:



李镛(1974-),男,教授,研究方向:深度学习与机器视觉, E-mail: liqiang@tju.edu.cn。



马秋阳(1995-),男,硕士研究生,研究方向:深度学习与机器视觉。



张宁(1977-),女,副教授,研究方向:电子文件管理、档案管理信息化、信息分析。



聂为之(1987-),通信作者,男,教授,研究方向:计算机视觉、多媒体信息分析, E-mail: weizhinie@tju.edu.cn。

(编辑:张黄群)