



基于自适应原型特征类矫正的小样本学习方法

赵红 钟杨清 金杰 邹林华

Few-shot Learning Based on Class Rectification via Adaptive Prototype Features

ZHAO Hong, ZHONG Yang-Qing, JIN Jie, ZOU Lin-Hua

在线阅读 View online: <https://doi.org/10.16383/j.aas.c240312>

您可能感兴趣的其他文章

基于特征变换和度量网络的小样本学习算法

Feature Transformation and Metric Networks for Few-shot Learning

自动化学报. 2024, 50(7): 1305–1314 <https://doi.org/10.16383/j.aas.c210903>

基于原型学习与深度特征融合的脑功能连接分类方法研究

Brain Functional Connection Classification Method Based on Prototype Learning and Deep Feature Fusion

自动化学报. 2022, 48(2): 504–514 <https://doi.org/10.16383/j.aas.c190747>

基于小样本学习的图像分类技术综述

Survey on Image Classification Technology Based on Small Sample Learning

自动化学报. 2021, 47(2): 297–315 <https://doi.org/10.16383/j.aas.c190720>

零样本学习研究进展

Research and Development on Zero-Shot Learning

自动化学报. 2020, 46(1): 1–23 <https://doi.org/10.16383/j.aas.c180429>

基于自适应噪声的最大熵进化强化学习方法

Adaptive Noise-based Evolutionary Reinforcement Learning With Maximum Entropy

自动化学报. 2023, 49(1): 54–66 <https://doi.org/10.16383/j.aas.c220103>

基于样本特征解码约束的GANs

A GANs Model Based on Sample Feature Decoding Constraint

自动化学报. 2022, 48(9): 2288–2300 <https://doi.org/10.16383/j.aas.c190496>

基于自适应原型特征类矫正的小样本学习方法

赵红^{1,2} 钟杨清^{1,2} 金杰^{1,2} 邹林华^{1,2}

摘要 针对小样本学习过程中样本数量不足导致的性能下降问题, 基于原型网络 (Prototype network, ProtoNet) 的小样本学习方法通过实现查询样本与支持样本原型特征间的距离度量, 从而达到很好的分类性能. 然而, 这种方法直接将支持集样本均值视为类原型, 在一定程度上加剧了对样本数量稀少情况下的敏感性. 针对此问题, 提出了基于自适应原型特征类矫正的小样本学习方法 (Few-shot learning based on class rectification via adaptive prototype features, CRAPF), 通过自适应生成原型特征来缓解方法对数据细微变化的过度响应, 并同步实现类边界的精细化调整. 首先, 使用卷积神经网络构建自适应原型特征生成模块, 该模块采用非线性映射获取更为稳健的原型特征, 有助于减弱异常值对原型构建的影响; 然后, 通过对原型生成过程的优化, 提升不同类间原型表示的区分度, 进而强化原型特征对类别表征的整体效能; 最后, 在 3 个广泛使用的基准数据集上的实验结果显示, 该方法提升了小样本学习任务的表现.

关键词 小样本学习, 原型网络, 原型特征, 类矫正

引用格式 赵红, 钟杨清, 金杰, 邹林华. 基于自适应原型特征类矫正的小样本学习方法. 自动化学报, 2025, 51(2): 475-484

DOI 10.16383/j.aas.c240312

CSTR 32138.14.j.aas.c240312

Few-shot Learning Based on Class Rectification via Adaptive Prototype Features

ZHAO Hong^{1,2} ZHONG Yang-Qing^{1,2} JIN Jie^{1,2} ZOU Lin-Hua^{1,2}

Abstract In response to the performance degradation issue from inadequate sample sizes during few-shot learning, prototypical network (ProtoNet)-based few-shot learning methods achieve commendable classification capabilities by measuring the distance metrics between query sample features and the prototype features of support samples. However, this method directly treats the mean of the support set samples as class prototypes, exacerbating sensitivity to scarcity of samples. To address this issue, we propose a few-shot learning method based on class rectification via adaptive prototype features (CRAPF). This method mitigates the model's over-responsiveness to minor data variations by adaptively generating prototype features and simultaneously achieves fine-tuned adjustments of class boundaries. First, we construct an adaptive prototype feature generation module using convolutional neural networks. This module leverages nonlinear mappings to obtain more robust prototype features, thereby mitigating the impact of outliers on prototype construction. Second, by optimizing the prototype generation process, we enhance the discriminability of prototype representations across different classes, thus strengthening the overall efficacy of prototype features in class representation. Finally, experiments conducted on three extensively utilized benchmark datasets reveal that this method significantly enhances the performance of few-shot learning tasks.

Key words Few-shot learning, prototype network (ProtoNet), prototypical feature, class rectification

Citation Zhao Hong, Zhong Yang-Qing, Jin Jie, Zou Lin-Hua. Few-shot learning based on class rectification via adaptive prototype features. *Acta Automatica Sinica*, 2025, 51(2): 475-484

在大量训练数据支撑下, 深度学习方法已在众多学科领域中, 呈现出显著的应用效果及优越性能^[1]. 但是在现实生活中的许多应用场景下, 大规模标注数据的采集常常难以实现或成本高昂, 构建相应的

大型训练集变得极其困难^[2-3]. 因此, 如何在面对有限标记数据资源时依然能够有效学习, 即小样本学习, 已成为人工智能领域至关重要的研究议题^[4-5]. 小样本学习因其突破数据局限性的独特优势而引起了广泛的关注与探索. 在小样本学习领域中, 基于度量学习的方法是一种核心方法论, 依据度量关注的核心要素差异, 可将其划分为基于个体样本特征的度量学习方法和基于类别原型特征的度量学习方法^[6]. 基于个体样本特征的度量学习方法依赖于预先设定的网络方法拥有强大的特征抽取能力, 进而确保方法能够在面对新类别时实现有效的泛化应用. 早期的基于个体样本特征的度量学习方法主要通过查询样本与支持样本特征间的距离进行量化

收稿日期 2024-06-03 录用日期 2024-08-29
Manuscript received June 3, 2024; accepted August 29, 2024
国家自然科学基金 (62376114) 资助
Supported by National Natural Science Foundation of China (62376114)

本文责任编辑 朱鹏飞

Recommended by Associate Editor ZHU Peng-Fei

1. 闽南师范大学计算机学院 漳州 363000 2. 闽南师范大学数据科学与智能应用福建省高校重点实验室 漳州 363000

1. School of Computer Science, Minnan Normal University, Zhangzhou 363000 2. Key Laboratory of Data Science and Intelligent Application, Minnan Normal University, Zhangzhou 363000

评估和对比分析, 以此指导查询样本的分类过程. 但由于各支持样本的个体差异和数量限制, 导致方法对未曾见过的新类别表达力有限. 针对这个问题, 基于类别原型特征的度量学习方法应运而生, 其关键在于通过学习类别的有效度量表示, 并利用类别原型作为各个类别的代表性向量基准. 具体地, 类别原型可通过整合多个支持样本特征嵌入并实施加权平均构建, 同时借助端到端的学习优化手段增强类原型特征表征效能. 最终, 通过计算查询样本与对应类别原型间的距离进行分类决策. 然而, 在数据稀缺的情况下, 单纯依赖平均值构造原型的方法可能加剧方法对样本数量不足状况的敏感性. 因此, 优化类别表征能力对确保精准分类的性能至关重要. 通过传统的原型网络 (Prototype network, ProtoNet)^[7] 提取特征并计算平均值, 可以获得固定原型, 如图 1(a) 所示, 其值可能偏向于异常值, 导致查询样本的错误分类. 解决这一问题可以提高基于度量方法的分类性能.

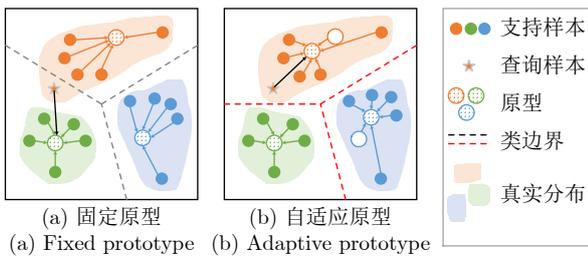


图 1 固定原型和自适应原型生成示例 (5 类 5 样本)
Fig.1 Examples of fixed prototype and adaptive prototype generation (5-way-5-shot)

针对上述问题, 本文提出一种改进的基于自适应原型特征类矫正的小样本学习方法 (Few-shot learning based on class rectification via adaptive prototype features, CRAPF), 该方法引入自适应原型特征以进行类矫正. 具体地, 设计一种卷积神经网络模块用于自适应生成和更新原型特征, 其机制借助于反向传播过程, 确保类别原型特征能够在训练迭代中, 逐步收敛至多数正常样本的中心, 并同时远离潜在的异常样本干扰. 这一动态自适应调整方法赋予了类别原型更高的稳定性与代表性. 如图 1(b) 所示的自适应原型, 当类别受到异常值影响导致分类性能下降时, 能够自动将原型从初始的示例位置 (以白色圆表示) 调整至较稳健的特征表示 (以网点圆表示), 从而提升方法的鲁棒性. 通过这种动态自适应调整原型特征的方式, 不仅实现了对类别边界的实时校正, 而且提炼出更具泛化能力的原型表示, 提升方法在面对未知类别时的泛化能力和适应性. 在 3 个广泛使用的基准小样本学习数据集

上进行了实验验证. 实验结果验证了本文提出的自适应原型特征类矫正的小样本学习方法的有效性. 本文的主要贡献有以下 3 点: 1) 构建了一种基于自适应原型特征的小样本学习框架, 利用卷积神经网络内在的隐含信息, 以自适应方式优化类别原型特征, 旨在构建更具区分性的原型表示; 2) 有效地缓解了采用简单平均法计算原型时因异常值造成的类别原型失真问题, 增强了方法对异常扰动的抵抗能力和对类别边界的精准矫正能力; 3) 本文的自适应原型特征类矫正的小样本学习方法具有高兼容性, 能够平滑地整合到其他小样本学习算法中, 共同提升整个方法的分类精度.

1 相关工作

本节介绍基于度量学习的小样本学习方法, 主要分为基于单个样本特征空间度量的小样本学习方法和基于原型特征度量的小样本学习方法.

1.1 基于单个样本特征度量的小样本学习方法

基于单个样本特征度量的小样本学习方法强调的是在高维特征空间中, 构建有效的距离或相似度度量函数. 这种方法通常依赖于学习一个特征提取器, 该提取器能够将样本映射至一个嵌入空间, 在此空间内, 同一类别内的样本彼此间距离尽可能接近, 而不同类别的样本间保持较大间隔^[8]. 例如, Li 等^[9] 运用一种基于局部描述符的度量方法, 结合 K 近邻搜索技术对深度局部描述符进行操作. Xu 等^[10] 从网络架构层面出发, 通过扩展卷积神经网络结构以增强对结构化特征的获取能力, 并明确引入特征位置编码以量化查询集和支持集样本特征间的空间关联性进行小样本学习. Huang 等^[11] 提出一种对齐网络方案, 该网络致力于重新配置支持集样本的空间特征以紧密匹配查询集中的样本特征, 借助精确的特征空间度量技术完成小样本学习任务. Xie 等^[12] 在小样本分类方面引入了深度布朗距离协方差方法, 通过衡量嵌入特征, 以量化两个随机变量间的相关性, 以及计算边缘特征矩阵的内积, 从而有效地学习图像表示.

不同于前面提到的特征嵌入度量方式, 部分研究工作聚焦于类表示度量. 例如, Luo 等^[13] 从支持集样本的局部特征中, 学习每个新类的一系列原型, 并基于对类别原型的相似性度量执行小样本学习任务. 与此同时, 也有研究者借助对比学习方法提升小样本学习方法的分类性能, 例如, Kwon 等^[14] 创新性地提出了基于特定类和未见类的双原型对比学习方法, 旨在增大类间距离和减小类内距离, 进而增强方法对未知类别的泛化能力. 同样借鉴对比学

习原理, Li 等^[15]提出了基于双视图的自监督对比学习方法, 通过学习可迁移的特征表示, 使方法能够更好地适应新的、不同的小样本学习任务。

1.2 基于原型特征度量的小样本学习方法

基于原型特征度量的小样本学习方法是通过建立每个类别的中心或原型实现分类. 原型通常是通过对每个类别内的样本特征采取某种聚合运算得出的, 如简单的算术平均或加权平均方法^[6]. 在原型网络的框架中, 方法在训练阶段学习如何计算类别原型, 并在测试阶段利用这些原型与新样本间的距离进行分类决策. 基于类原型的方法可分为基于固定原型方法和基于动态原型方法.

针对基于固定原型的方法, Snell 等^[7]在提出的原型网络中, 将每个类别的原型设定为支持样本特征嵌入的均值, 通过比较查询样本与这些原型间的距离完成分类任务. Sung 等^[16]在关系网络中, 进一步引入非线性分类器, 以衡量原型与查询实例之间的相似性程度. Hao 等^[17]借助关系矩阵有效实现了查询样本与原型之间的度量比对. Li 等^[18]采用局部信息的二阶协方差作为原型表示, 并基于分布一致性原则进行分类. 然而, 在小样本学习情境下, 由于数据稀缺性, 仅依赖支持集类别的固定原型往往会存在一定的偏差, 难以准确地刻画类别的本质特性.

针对上述问题, 一些研究者提出了基于动态原型的方法, 这类方法侧重于根据查询样本与最相近原型之间的度量进行分类决策. 例如, Zhu 等^[19]利用高斯函数处理支持样本到查询样本的距离, 并通过温度函数对支持样本进行动态重加权, 以此生成针对特定查询样本的个性化原型. Allen 等^[20]采用一组代表支持类的聚类作为原型, 其中聚类的数量会随样本数量变化而调整. Liu 等^[21]提出一种基于余弦相似性的原型网络, 能够在少量样本中计算新类的基本原型, 并通过降低类内误差和跨类误差校准原型. 与上述方法相似, 本文通过基于距离的度量完成分类, 但所设计原型是由卷积神经网络动态构建出的自适应原型, 这一改进有助于减轻固定原型在面对异常值时可能引发的原型表述不准确问题.

2 CRAPF 方法

小样本分类任务常用的数据集可以分为训练集 D_{train} 、测试集 D_{test} 和验证集 D_{val} 3 个数据子集. 这 3 个数据集之间的类别是不相交的, $D_{\text{train}} \cap D_{\text{test}} = \emptyset$, $D_{\text{train}} \cap D_{\text{val}} = \emptyset$, $D_{\text{test}} \cap D_{\text{val}} = \emptyset$. 本文使用小样本元学习训练机制, 通过训练不同元学习任务并提取一般化的知识, 提高方法对未知任务的泛化能力.

每个元任务采用 N 类 K 样本小样本随机采样方法组成元任务数据集. 首先, 从 D_{train} 中随机抽取 N 个类, 每个类别随机选取 K 个样本形成一个支持集 $S = \{(x_i, y_i)\}_{i=1}^{N_s}$, $N_s = N \times K$. 然后, 从 D_{train} 中除了 N 类样本的其余部分随机选择一些样本形成查询集 $Q = \{(x_j, y_j)\}_{j=1}^{N_q}$. 其中, x_i 和 x_j 分别表示支持样本和查询样本, y_i 和 y_j 分别表示支持样本和查询样本的真实标签. S 和 Q 共享相同的标签空间, 但它们中的样本是不相交的, 即 $S \cap Q = \emptyset$. 小样本学习的目标是利用给定支持集 S 中包含的先验知识对未看到的查询样本 Q 进行分类, 即

$$\hat{y}_j = \arg \max_{n \in \{1, \dots, N\}} P(n | x_j, S) \quad (1)$$

式中, $P(n | x_j, S)$ 表示查询样本 x_j 被归为类 n 的概率, \hat{y}_j 表示预测的类别标签.

2.1 方法架构

本文提出一个基于自适应原型特征类矫正的小样本学习方法, 方法的总体架构 (在 5 类 5 样本的设置下) 如图 2 所示. CRAPF 由特征嵌入、自适应原型特征生成和小样本分类 3 个阶段组成. 首先, 将支持样本 x_i 和查询样本 x_j 嵌入网络中, 得到特征; 然后, 利用自适应原型特征模块生成自适应原型特征, 增强原型的表示能力和实现类边界的矫正; 接着, 计算查询样本和支持样本自适应原型特征的空间距离; 最后, 通过样本间空间距离获得相似度得分并并完成小样本分类.

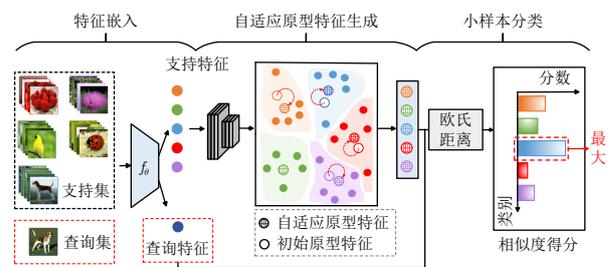


图 2 基于 5 类 5 样本的方法框架图

Fig. 2 Model framework based on 5-way-5-shot

2.2 特征嵌入

特征嵌入模块能够获取支持样本和查询样本的嵌入特征. 在特征空间中, 不同嵌入特征处于不同位置, 这些不同嵌入特征间的距离代表不同类别样本间的关系. 采用 6 层 ResNet12 作为嵌入网络, 可分为全连接层、全局池化和卷积层 3 个关键的子组件. 图像输入分辨率为 84×84 像素. 给定一个输入图像 x , 其嵌入特征是一个由 $c \times h \times w$ 组成的 3 维

张量:

$$\tilde{x} = f_{\theta}(x) \in \mathbf{R}^{c \times h \times w} \quad (2)$$

式中, $f_{\theta}(x)$ 为一个用于提取图像特征向量的嵌入式函数, 其中 θ 为卷积神经网络的可学习参数, c 为特征维度, h 和 w 为特征的高度和宽度. 设置主干网络的输出参数 $c = 640$, $h = w = 10$.

2.3 自适应原型特征生成

原型网络引入原型指代多个同类别样本嵌入特征在特征空间的核心点. 原型由同类嵌入特征的平均值构成. 具体地, 给定支持样本 x_i , 每个类别中支持样本的类原型 N_n 为

$$N_n = \frac{1}{|S_n|} \sum_{(x_i, y_i) \in S_n} f_{\theta}(x_i) \quad (3)$$

式中, S_n 表示类 n 中的支持样本集.

在为支持集样本 x_i 构造每类的原型后, 首先每个查询样本 x_j 都会遍历所有类别的原型 N_n , 并计算它们之间的欧氏距离; 然后, 根据距离对查询样本进行分类, 选取与查询样本最小距离原型; 最后, 将查询样本归类为这个最近原型代表的类别中, 查询样本 x_j 预测为第 n 类的概率表达式为

$$P(n | x_j) = \frac{\exp(-d(f_{\theta}(x_j), N_n))}{\sum_{n'=1}^N \exp(-d(f_{\theta}(x_j), N_{n'}))} \quad (4)$$

式中, $d(\cdot)$ 为距离度量函数, $P(n | x_j)$ 为将 x_j 预测为第 n 类的概率. 原型网络选择最大类别预测概率作为分类结果.

原型网络采用同类别样本嵌入特征的平均值方法构造 1 个类原型, 给予类原型中每个样本特征相同权重. 然而, 这种方法也加剧了类原型对异常节点的敏感性, 并不完全适用于实际数据^[22]. 传统类原型不具有代表性且不考虑每个独立样本对最终原型的贡献程度. 例如, 当同类样本中出现异常值的情况, 通过求平均获得的原型将偏离正常值而靠近异常值, 异常样本出现时应该赋予它更小的权重. 为了解决这个问题, 本文提出一种由卷积神经网络构建的自适应原型特征生成模块, 为每个查询样本生成特定的支持类别原型. 该方法可以缓解由平均计算得到的原型中由于异常值引起的原型表示不准确问题, 增强原型的鲁棒性, 同时矫正错误的类边界. 如图 3 所示, 自适应原型特征模块采用特征生成模块替代原始的求平均值获取原型的方式, 由 2 个卷积层、批归一化和 ReLU 激活函数组成. 自适应原型特征重新构建特征空间, 降低了异常样本特征对原型的影响, 提高了整体原型结构的稳定性.

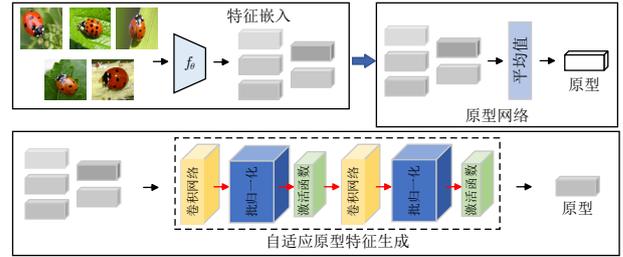


图 3 自适应原型特征生成模块

Fig.3 Adaptive prototype features generation module

类 n 中的支持样本生成的自适应原型特征 P_n 生成表达式为

$$P_n = g_{\varphi}(f_{\theta}(x_i), \dots, f_{\theta}(x_{|n|})) \quad (5)$$

式中, $g_{\varphi}(\cdot)$ 为自适应原型特征生成模块, φ 为可学习参数, $|n|$ 为类 n 的支持样本数.

2.4 小样本分类

在元任务中, 查询样本的分类可通过度量其在特征空间中与自适应原型特征的距离实现. 使用欧氏距离度量函数计算原型和查询样本之间的关系得分

$$r_{nj} = d(f_{\theta}(x_j), P_n) \quad (6)$$

式中, r_{nj} 为关系得分, 得分越高, 表示距离越远, 相似度越小. 利用获取的关系得分, 可通过 softmax 函数获取查询样本 x_j 借助自适应原型特征预测为第 n 类的概率, 即

$$P_1(n | x_j) = \frac{\exp(-r_{nj})}{\sum_{n'=1}^N \exp(-r_{n'j})} \quad (7)$$

最终的交叉熵损失函数为

$$\text{Loss} = -\frac{1}{N} \sum_{n=1}^N y_{nj} \ln P_1(n | x_j) \quad (8)$$

式中, y_{nj} 为查询样本 x_j 分类结果标签, 若 x_j 属于第 n 类, $y_{nj} = 1$, 否则, $y_{nj} = 0$.

2.5 方法分析与讨论

自适应原型特征生成方法可以增强传统原型网络的稳定性, 具有以下 3 个特点: 1) 自适应原型可以提高方法对数据知识与类别信息的学习效果, 可以缓解由平均计算得到的原型中由于异常值引起的原型表示不准确问题; 2) 自适应原型方法可以生成更具判别性原型并重构特征空间, 矫正方法的错误类边界问题和增强网络的健壮性; 3) 在不增加时间复杂度的情况下, 自适应原型改善了传统原型网络的分类性能.

3 实验设置

3.1 实验数据集

本文实验采用 MiniImageNet^[23]、CIFAR-FS^[24] 和 FC100^[25] 3 个广泛应用于小样本图像分类的实验数据集, 表 1 为 3 个数据集的基本信息, 图 4 展示了 3 个数据集的部分代表性图像.

表 1 数据集基本信息
Table 1 Basic information of datasets

数据集	样本数量	训练/验证/测试类别数量	图片尺寸 (像素)
MiniImageNet	60000	64/16/20	84 × 84
CIFAR-FS	60000	64/16/20	32 × 32
FC100	60000	60/20/20	32 × 32



图 4 数据集部分代表性图像

Fig. 4 Representative images in the datasets

1) MiniImageNet 数据集广泛应用于小样本图像分类任务, 是 ImageNet^[26] 数据集的一个子集. 包含 100 个类别, 每个类别有 600 幅 84×84 像素图像, 共包含 60 000 幅彩色图像. 按照 Ravi 等^[27] 的划分方式, 将其划分为 64 个训练类、16 个验证类和 20 个测试类.

2) CIFAR-FS 数据集是基于 CIFAR-100^[28] 数据集随机采样构建的小样本数据集. 包含 100 个类别, 每个类别有 600 幅 32×32 像素图像, 共包含 60 000 幅图像. 采用与文献 [29] 相同的设置, 将该数据集划分为 64 个训练类、16 个验证类和 20 个测试类.

3) FC100 数据集是从 CIFAR-100 数据集中随机采样构建的小样本数据集. 包含 100 个类别, 每个类别有 600 幅 32×32 像素图像, 共包含 60 000 幅图像. 根据广泛使用的划分方式, 将其划分为 60 个训练类、20 个验证类和 20 个测试类.

3.2 实验设置

本文实验采用元学习训练机制进行小样本学习, 在进行元学习训练前, 先对方法进行常规分类预训练学习, 以提升特征的代表能力. 方法在 MiniImageNet、CIFAR-FS 和 FC100 数据集上进

行预训练, 批次大小均设置为 64, 初始学习率设置为 0.05, 学习率的衰减因子为 0.1. 优化器使用随机梯度下降, 动量设置为 0.9 进行优化.

为了公平比较, 本文实验采用文献 [11] 的 ResNet12 和 ResNet18 作为主干网络进行小样本学习. 与常用的方法相同, 使用 ResNet12 作为主干网络时, 图像分辨率设置为 84×84 像素; 使用 ResNet18 作为主干网络时, 图像分辨率设置为 224×224 像素. ResNet12 网络由 4 个残差块组成, 4 个残差块的卷积层通道数分别为 64、160、320、640. 每个残差块有 3 个卷积层, 每个卷积层由 1 个 BatchNorm 批归一化层、1 个 3×3 的卷积核和 1 个 ReLU 激活函数组成. 为获得更多的卷积特征, 在除最后一个块之外的每个块后面使用 2×2 最大池化层, 对特征图进行下采样. ResNet18 具有相似的结构, 但它的 4 个残差块的卷积层通道数分别为 64、128、256、512. 本文使用 Adam 作为优化器训练本文方法, 利用预训练的网络初始化特征提取器, 初始学习率 α 设置为 0.001, 并在整个训练过程中保持不变. 在训练或测试阶段, 每个类别的查询样本数设置为 15 个. 在测试阶段, 从测试数据集中随机对 1000 个任务进行测试, 以所有设置下的平均精度作为最终评价指标.

3.3 对比方法

与 CRAPF 进行实验对比的 13 种方法如下:

1) 文献 [30] 提出将元学习范式与深度度量学习和转换推理相结合的用于小样本学习的情景自适应度量方法 (Transductive episodic-wise adaptive metric, TEAM).

2) 文献 [31] 提出一种转导元学习方法 (Transductive conditional neural adaptive processes, TransCNAPS), 将基于正则马氏距离的软 k -聚类与先进的自适应特征提取器相结合, 以提高未标记数据的分类精度.

3) 文献 [32] 提出一种匹配识别网络 (Match them up network, MTUNet), 联合来自主干方法的视觉表示和基于自注意力可解释模块的小样本图像分类方法.

4) 文献 [33] 提出一种改进的原型网络 (Improved prototypical networks, IPN), 并利用注意力相似方法和距离缩放方法探索类分布信息.

5) 文献 [25] 提出一种自适应度量方法 (Task dependent adaptive metric, TADAM), 将学习者的条件转化为任务样本集, 学习一个任务相关的度量空间.

6) 文献 [34] 提出子图相似性度量方法 (Subgraph similarity refiner, SSR), 使相似图收敛于由图像标签引起的目标相似图。

7) 文献 [35] 提出一种多距离度量网络 (Multi-distance metric network, MDM-Net), 通过使用多输出嵌入网络, 将样本映射到不同特征空间。

8) 文献 [36] 提出一种学习嵌入的 Shot-Free 方法用于小样本学习, 可以在高维空间中学习原型和方法参数。

9) 文献 [37] 提出一种基于深度推土机距离 (Deep earth mover's distance, DeepEMD) 的小样本学习方法, 可计算图像表示之间的结构距离, 进行图像区域最优匹配。

10) 文献 [38] 提出一种动态子空间网络 (Dynamic subspace network, DSN), 利用子空间方法构建动态分类器, 设计了一个新的小样本学习框架。

11) 文献 [39] 提出多任务学习 (Multi-task learning, MTL) 与基于梯度的元学习算法, 共享相同的优化公式, 进行小样本学习。

12) 文献 [40] 提出判别空间度量网络 (Discriminant space metric network, DSMNet), 利用样本的几何结构, 增强嵌入空间的判别能力, 可有效解决小样本分类问题。

13) 文献 [41] 提出一种 SimpleShot 的小样本学习方法, 通过简单的特征转换可获得较高的小样本分类精度。

4 实验结果与分析

4.1 消融实验

本节分析自适应原型和预训练模块 (Adaptive prototype and pre-training module, APre) 在所提方法中的作用。实验在 MiniImageNet、CIFAR-FS 和 FC100 数据集上进行, 均使用 5 类 5 样本设置, 并保持其他参数设置不变, 以确保实验的公平性, 实验结果如图 5 所示。

由图 5 可知: 1) 在 5 类 5 样本设置下, 使用自适应原型和预训练模块后的方法整体分类精度在 3 个数据集上都显示了良好的性能, 验证了自适应原型和预训练模块的有效性和泛化性; 2) 与未使用 APre 的方法相比, CRAPF 的分类精度在 3 个数据集上均提升了 3% 以上。这验证了加入预训练和自适应原型能够起到促进作用, 提升不同类别间原型表示的区分度, 进而增强方法的分类能力。

4.2 不同 N 类 K 样本设置的性能比较

为验证 CRAPF 的有效性, 使用 5 类 5 样本、

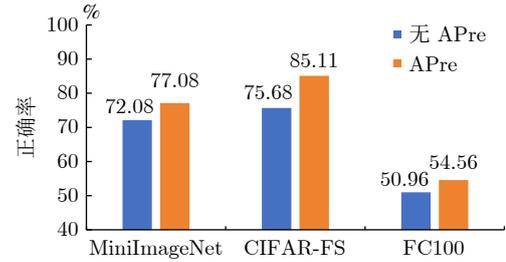


图 5 在不同数据集上自适应原型和预训练模块的性能比较

Fig. 5 Performance comparison of adaptive prototype and pre-training module on different datasets

5 类 10 样本和 10 类 5 样本 3 种设置, 在 CIFAR-FS 和 FC100 数据集上进行小样本任务测试。将 CRAPF 与基线方法 ProtoNet 进行比较, 比较结果见图 6。

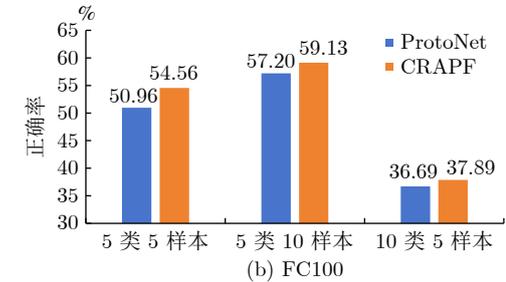
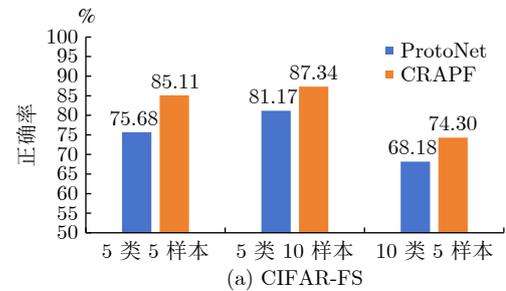


图 6 应用不同 N 类 K 样本设置的性能比较
Fig. 6 Performance comparison using different N -way- K -shot settings

在 CIFAR-FS 数据集上, CRAPF 的性能在所有分类设置下均优于 ProtoNet。尤其是在 5 类 5 样本设置下, CRAPF 的平均分类精度为 85.11%, 比 ProtoNet 提高了 9.43%。在 5 类 10 样本设置下, 也提高了 6.17%。在 FC100 数据集上, CRAPF 的性能优于 ProtoNet, 性能的提高相较 CIFAR-FS 数据集, 整体有较大提升。例如在 5 类 5 样本设置下提升了 3.6%。这些结果表明, 即使是在更具有挑战性的小样本设置下, CRAPF 相比于基线方法, 仍然能取得较高性能。这是因为 CRAPF 有其独特的自

适应原型特征表示, 获取的原型特征更为稳健, 可以减弱在原型构建过程中产生异常值的影响。

4.3 应用不同网络的实验结果

为验证 CRAPF 的有效性, 分别使用 ResNet12 和 ResNet18 作为嵌入网络. 表 2 展示了在 MiniImageNet、CIFAR-FS 和 FC100 数据集上应用不同主干网络的实验结果. 除嵌入模块更换主干网络以外, 其他实验均采用相同的 5 类 5 样本设置. 由表 2 可以看出, CRAPF 在所有数据集的 5 类 5 样本设置下相对基线方法 ProtoNet 都获得了更优越的分类性能. 此外, 还可以观察到分类精度不会随着主干网络的深度增加而增加. 例如, 在 MiniImageNet 数据集上使用主干网络 ResNet18 时. 在使用 ResNet12 时, CRAPF 的分类精度为 77.08%; 在使用 ResNet18 时, 分类精度下降为 74.40%, 原因可能是网络参数的增加导致了过拟合, 从而降低了分类的准确度.

表 2 应用不同网络的实验结果 (%)
Table 2 Experimental results using different networks (%)

网络	数据集	ProtoNet	CRAPF
ResNet12	MiniImageNet	72.08	77.08
	CIFAR-FS	75.68	85.11
	FC100	50.96	54.56
ResNet18	MiniImageNet	73.68	74.40
	CIFAR-FS	72.83	84.93
	FC100	47.50	53.33

然而, 除 MiniImageNet 数据集外, 随着网络层数的加深, CRAPF 的分类性能相较于 ProtoNet 下降速度较慢. 例如, CRAPF 在 CIFAR-FS 和 FC100 数据集上, 从 ResNet12 到 ResNet18 仅下降了 0.18% 和 1.23%, 但是基线模型却分别下降了 2.85% 和 3.46%. 这表明 CRAPF 具有较好的稳定性, 其生成的原型也更为稳健, 在不同深度的主干网络下仍然具备较好的性能.

4.4 可视化分析

本节使用 GradCAM (Gradient-weighted class activation mapping)^[42] 方法对 CRAPF 进行可视化分析. 原始图像帆船、狗和鸟均是从 MiniImageNet 数据集中随机采样得到, 可视化结果如图 7 所示.

图 7(a) 为原始图像, 图 7(b) 为基线方法原型网络所提取的特征图, 图 7(c) 为 CRAPF 提取的特

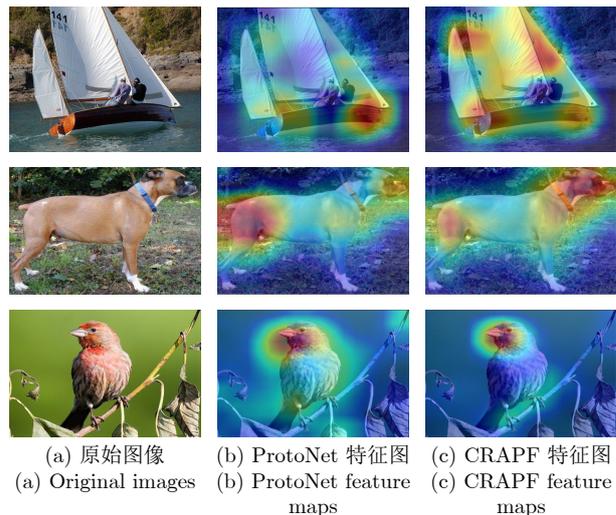


图 7 CRAPF 的可视化对比
Fig.7 Visual comparison of CRAPF

征图. 由图 7 可以看出: 1) 传统以均值计算原型特征的原型网络提取的特征, 对图像分类起到重要作用, 但不够准确. 将支持集样本均值视为类原型的做法在一定程度上加剧了样本稀缺情况下方法对异常样本的敏感性, 容易获得偏离正确类别的类原型. 如图 7(b) 所示, 狗类的关注点应该在头部, 但基线方法关注的是臀部; 鸟类虽然关注到对分类起重要作用的头部, 但也关注到了其他影响因素, 如树枝等. 相比之下, CRAPF 加入自适应原型特征生成模块后, 缓解了方法对数据细微变化的过度响应, 同时矫正了类边界, 可以关注到对分类有用的判别性原型特征, 如图 7(c) 所示, 从而增加分类的精确度, 促进小样本学习. 2) CRAPF 能强化原型特征对类别表征的整体效能. 如图 7(b) 所示, 基线方法对帆船虽然能获得正确的原型特征, 但其整体类别表征不够充分. 而 CRAPF 通过对原型生成过程的优化, 可以进一步强化原型特征对类别表征的整体效能, 如图 7(c) 所示, 通过对原型生成过程的优化, 得到一个更具表征能力的类原型. 验证了 CRAPF 可以提高类间原型表示的识别度, 进一步增强了原型的表征能力, 从而提升小样本分类性能.

4.5 MiniImageNet 数据集上的对比实验结果

为了评估 CRAPF 的有效性, 在 MiniImageNet 数据集上与相关小样本学习方法进行性能比较, 实验结果如表 3 所示. 表 3 中大部分方法的实验结果都源自参考文献的公开数据, 其中“*”标注的方法结果是根据论文提供的代码运行得到, 数字加粗表示准确率最高的结果.

实验分别在 5 类 1 样本和 5 类 5 样本 2 种小样本设置下进行, 并在 95% 置信区间内计算小样本平

表 3 MiniImageNet 数据集上的对比实验结果 (%)
Table 3 Comparative experimental results on the MiniImageNet dataset (%)

方法	网络	5 类 1 样本	5 类 5 样本
TEAM	ResNet18	60.07	75.90
TransCNAPS	ResNet18	55.60	73.10
MTUNet	ResNet18	58.13	75.02
IPN	ResNet10	56.18	74.60
ProtoNet*	ResNet12	53.42	72.08
TADAM	ResNet12	58.50	76.70
SSR	ResNet12	68.10	76.90
MDM-Net	ResNet12	59.88	76.60
CRAPF*	ResNet12	59.38	77.08

均分类准确率. 将 CRAPF 与当下流行的多种小样本学习方法进行比较. 由表 3 可以看出, CRAPF 可以在 5 类 5 样本设置下取得较好结果. 例如, 在 5 类 5 样本设置下, CRAPF 准确率达到 77.08%, 分别比 ProtoNet、SSR、MDM-Net 和 TADAM 提高了 5.00%、0.18%、0.48% 和 0.38%, 这表明 CRAPF 具有良好的性能. 然而, CRAPF 的优越性不能在 5 类 1 样本设置下得到充分验证, 这是因为 5 类 1 样本的设置只有 1 个图像表示 1 类, 本身具有挑战性; 另一个关键原因是, CRAPF 主要作用是原型的生成, 而 1 个样本生成的原型表示没有多样本生成的原型表示能力好. 但是, 在 5 类 1 样本设置下与基线方法 ProtoNet 方法相比, CRAPF 的性能提高了 5.96%, 这说明即使是在样本稀缺的 5 类 1 样本设置下, CRAPF 也能在一定程度上强化原型特征对类别表征的整体效能, 进而获得具有竞争力的小样本分类效果.

4.6 CIFAR-FS 数据集上的对比实验结果

表 4 展示了 CRAPF 在 CIFAR-FS 数据集上的对比实验结果以及与各种方法的性能比较. 实验设置与在 MiniImageNet 数据集上相同.

由表 4 可以看出, CRAPF 与其他方法相比, 始终显示出较好性能. 例如, 在 5 类 1 样本和 5 类 5 样本设置下实现了 72.34% 和 85.11% 的分类精度. 与 ProtoNet 相比, CRAPF 在 5 类 1 样本设置下准确率提高了 15.48%, 在 5 类 5 样本设置下准确率提高了 9.43%. 对更深网络 ResNet18, CRAPF 依旧显示出较好的分类精度, 在 5 类 1 样本和 5 类 5 样本设置下, 分别比 MTUNet 提高了 4.91% 和 2.30%. 这表明在自适应原型的引导下, 相比于利用更深网络提取出的深度特征的方法, CRAPF 在使用较浅网络情况下, 也能实现原型生成过程的优化, 进一步验证了该方法的简单和有效性.

表 4 CIFAR-FS 数据集上的对比实验结果 (%)
Table 4 Comparative experimental results on the CIFAR-FS dataset (%)

方法	网络	5 类 1 样本	5 类 5 样本
ProtoNet*	ResNet12	56.86	75.68
Shot-Free	ResNet12	69.20	84.70
TEAM	ResNet12	70.40	80.30
DeepEMD	ResNet12	46.50	63.20
DSN	ResNet12	72.30	85.10
MTL	ResNet12	69.50	84.10
DSMNet	ResNet12	60.66	79.26
MTUNet	ResNet18	67.43	82.81
CRAPF*	ResNet12	72.34	85.11

4.7 FC100 数据集上的对比实验结果

在 FC100 数据集上的对比实验结果如表 5 所示. 文献 [43] 提出的 Baseline2020 为小样本基线模型. 在 5 类 1 样本和 5 类 5 样本设置下 CRAPF 分类准确率分别达到了 40.44% 和 54.56%. 与使用 ResNet10 作为主干网络的 SimpleShot 方法相比, CRAPF 在 5 类 1 样本设置下提高了 0.31%, 在 5 类 5 样本设置下提高了 0.93%. 在 5 类 1 样本设置下, CRAPF 与基线方法 ProtoNet 相比, 平均分类准确性提高了 2.94%, 在 5 类 5 样本设置下, 平均分类准确性提高了 3.60%. 这表明 CRAPF 对比基线方法有很大的提升, 验证了 CRAPF 能有效缓解平均计算得到的原型表示不准确问题, 在一定程度上降低了方法对异常数据的敏感程度, 有助于构建更稳健的原型特征. 此外, 在 FC100 数据集上的实验结果明显不如在 MiniImageNet 和 CIFAR-FS 数据集上的实验结果, 这是因为 FC100 数据集不是按照类别, 而是按照超类别进行划分的, 在小样本情景下增加了分类的复杂度与困难度. 但是, 在几乎所有方法性能都下降的前提下, CRAPF 仍然表现出较好结果, 说明自适应生成原型特征的方法具有很强的泛化性, 即使面对更加复杂的数据集, 也能优化原型生成过程, 提升不同类别间原型表示的区分度, 进而提高更具有挑战性的小样本情景下的分类效果.

表 5 FC100 数据集上的对比实验结果 (%)
Table 5 Comparative experimental results on the FC100 dataset (%)

方法	网络	5 类 1 样本	5 类 5 样本
ProtoNet*	ResNet12	37.50	50.96
SimpleShot	ResNet10	40.13	53.63
Baseline2020	ResNet12	36.82	49.72
TADAM	ResNet12	40.10	56.10
CRAPF*	ResNet12	40.44	54.56

5 结束语

针对原型特征表示单一且不充分等问题, 提出一种简单有效的基于自适应原型特征表示的小样本学习方法. 在原型网络的基础上, CRAPF 通过卷积神经网络自适应学习类原型特征, 使得原型特征的表达程度最大化, 从而增强原型的表征能力. 具体而言, 通过使用卷积神经网络构建自适应原型特征生成模块, 动态生成与类别适应的原型特征, 更好地捕捉类别之间的差异性, 最大化类间原型的识别能力, 进而提升分类性能. 实验结果在 MiniImageNet、CIFAR-FS 和 FC100 基准数据集上展现出良好的性能. 本文从增强原型特征表示能力的角度提高了方法性能, 未来研究将探讨不同视角的特征表示方法, 从而进一步提升原型表示的能力, 并根据这些视角设计有效的特征融合方法, 以提升小样本学习方法的泛化能力.

References

- Jiang H, Diao Z, Shi T, Zhou Y, Wang F, Hu W, et al. A review of deep learning-based multiple-lesion recognition from medical images: Classification, detection and segmentation. *Computers in Biology and Medicine*, 2023, **157**: Article No. 106726
- Zhao Kai-Lin, Jin Xiao-Long, Wang Yuan-Zhuo. Survey on few-shot learning. *Journal of Software*, 2021, **32**(2): 349–369 (赵凯琳, 靳小龙, 王元卓. 小样本学习研究综述. *软件学报*, 2021, **32**(2): 349–369)
- Zhao Yi-Ming, Wang Pei-Jin, Diao Wen-Hui, Sun Xian, Deng Bo. Few-shot SAR aircraft image classification method based on channel attention mechanism. *Journal of Nanjing University (Natural Science)*, 2024, **60**(3): 464–476 (赵一铭, 王佩瑾, 刁文辉, 孙显, 邓波. 基于通道注意力机制的小样本 SAR 飞机图像分类方法. *南京大学学报 (自然科学版)*, 2024, **60**(3): 464–476)
- Li F F, Fergus R, Perona P. A Bayesian approach to unsupervised one-shot learning of object categories. In: Proceedings of the IEEE International Conference on Computer Vision. Nice, Franc: IEEE, 2003. 1134–1141
- Liu Ying, Lei Yan-Bo, Fan Jiu-Lun, Wang Fu-Ping, Gong Yan-Chao, Tian Qi. Survey on image classification technology based on small sample learning. *Acta Automatica Sinica*, 2021, **47**(2): 297–315 (刘颖, 雷研博, 范九伦, 王富平, 公衍超, 田奇. 基于小样本学习的图像分类技术综述. *自动化学报*, 2021, **47**(2): 297–315)
- Li X, Yang X, Ma Z, Xue J. Deep metric learning for few-shot image classification: A review of recent developments. *Pattern Recognition*, 2023, **138**: Article No. 109381
- Snell J, Swersky K, Zemel R. Prototypical networks for few-shot learning. In: Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: 2017. 4077–4087
- Qiang W, Li J, Su B, Fu J, Xiong H, Wen J. Meta attention-generation network for cross-granularity few-shot learning. *IEEE International Journal of Computer Vision*, 2023, **131**(5): 1211–1233
- Li W, Wang L, Xu J, Huo J, Gao Y, Luo J. Revisiting local descriptor based image-to-class measure for few-shot learning. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE, 2019. 7260–7268
- Xu W, Xu Y, Wang H, Tu Z. Attentional constellation nets for few-shot learning. In: Proceedings of the International Conference on Learning Representations. Vienna, Austria: ICLR, 2021. 1–12
- Huang H, Zhang J, Yu L, Zhang J, Wu Q, Xu C. TOAN: Target-oriented alignment network for fine-grained image categorization with few labeled samples. *IEEE Transactions on Circuits and Systems for Video Technology*, 2021, **32**(2): 853–866
- Xie J, Long F, Lv J, Wang Q, Li P. Joint distribution matters: Deep Brownian distance covariance for few-shot classification. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE, 2022. 7972–7981
- Luo X, Wei L, Wen L, Yang J, Xie L, Xu Z, et al. Rectifying the shortcut learning of background for few-shot learning. In: Proceedings of the 35th International Conference on Neural Information Processing Systems. Virtual Event: 2021. 13073–13085
- Kwon H, Jeong S, Kim S, Sohn K. Dual prototypical contrastive learning for few-shot semantic segmentation. arXiv preprint arXiv: 2111.04982, 2021.
- Li J, Liu G. Few-shot image classification via contrastive self-supervised learning. arXiv preprint arXiv: 2008.09942, 2020.
- Sung F, Yang Y, Zhang L, Xiang T, Torr P H, Hospedales T M. Learning to compare: Relation network for few-shot learning. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE, 2018. 1199–1208
- Hao F, He F, Cheng J, Wang L, Cao J, Tao D. Collect and select: Semantic alignment metric learning for few-shot learning. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul, South Korea: IEEE, 2019. 8460–8469
- Li W, Xu J, Huo J, Wang L, Gao Y, Luo J. Distribution consistency based covariance metric networks for few-shot learning. In: Proceedings of the AAAI Conference on Artificial Intelligence. Honolulu, USA: 2019. 8642–8649
- Zhu W, Li W, Liao H, Luo J. Temperature network for few-shot learning with distribution-aware large margin metric. *Pattern Recognition*, 2021, **112**: Article No. 109381
- Allen K, Shelhamer E, Shin H, Tenenbaum J B. Infinite mixture prototypes for few-shot learning. In: Proceedings of the International Conference on Machine Learning. Long Beach, USA: ICML, 2019. 232–241
- Liu J, Song L, Qin Y. Prototype rectification for few-shot learning. In: Proceedings of the European Conference Computer Vision. Glasgow, UK: Springer, 2020. 741–756
- Li X, Li Y, Zheng Y, Zhu R, Ma Z, Xue J, et al. ReNAP: Relation network with adaptive prototypical learning for few-shot classification. *Neurocomputing*, 2023, **520**: 356–364
- Vinyals O, Blundell C, Lillicrap T, Kavukcuoglu K, Wierstra D. Matching networks for one shot learning. In: Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona, Spain: 2016. 3637–3645
- Bertinetto L, Henriques J, Torr P, Vedaldi A. Meta-learning with differentiable closed-form solvers. In: Proceedings of the International Conference on Learning Representations. New Orleans, USA: ICLR, 2019. 1–13
- Oreshkin B, Rodríguez Loópez P, Lacoste A. TADAM: Task dependent adaptive metric for improved few-shot learning. In: Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal, Canada: 2018. 719–729
- Russakovsky O, Deng J, Su H, Krause J, Satheesh S, Ma S, et al. ImageNet large scale visual recognition challenge. *International Journal of Computer Vision*, 2015, **115**: 211–252
- Ravi S, Larochelle H. Optimization as a model for few-shot learning. In: Proceedings of the International Conference on Learning Representations. San Juan, Puerto Rico: ICLR, 2016. 1–11

- 28 Krizhevsky A. Learning Multiple Layers of Features From Tiny Images [Master thesis], Toronto University, Canada, 2009.
- 29 Bertinetto L, Henriques J F, Valmadre J, Torr P H S, Vedaldi A. Learning feed-forward one-shot learners. In: Proceedings of the 30th International Conference on Neural Information Processing Systems. Barcelona, Spain: 2016. 523–531
- 30 Qiao L, Shi Y, Li J, Wang Y, Huang T, Tian Y. Transductive episodic-wise adaptive metric for few-shot learning. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul, South Korea: IEEE, 2019. 3603–3612
- 31 Bateni P, Barber J, van de meent J W, Wood F. Enhancing few-shot image classification with unlabelled examples. In: Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, USA: IEEE, 2022. 2796–2805
- 32 Wang B, Li L, Verma M, Nakashima Y, Kawasaki R, Nagahara H. Match them up: Visually explainable few-shot image classification. *Applied Intelligence*, 2023, **53**: 10956–10977
- 33 Ji Z, Chai X, Yu Y, Pang Y, Zhang Z. Improved prototypical networks for few-shot learning. *Pattern Recognition Letters*, 2020, **140**: 81–87
- 34 Shen X, Xiao Y, Hu S X, Sbai O, Aubry M. Re-ranking for image retrieval and transductive few-shot classification. In: Proceedings of the 35th International Conference on Neural Information Processing Systems. Virtual Event: 2021. 25932–25943
- 35 Gao F, Cai L, Yang Z, Song S, Wu C. Multi-distance metric network for few-shot learning. *International Journal of Machine Learning and Cybernetics*, 2022, **13**(9): 2495–2506
- 36 Ravichandran A, Bhotika R, Soatto S. Few-shot learning with embedded class models and shot-free meta training. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Seoul, South Korea: IEEE, 2019. 331–339
- 37 Zhang C, Cai Y, Lin G, Shen C. DeepEMD: Few-shot image classification with differentiable earth mover's distance and structured classifiers. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2020. 12203–12213
- 38 Simon C, Koniusz P, Nock R, Harandi M. Adaptive subspaces for few-shot learning. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE, 2020. 4136–4145
- 39 Wang H, Zhao H, Li B. Bridging multi-task learning and meta-learning: Towards efficient training and effective adaptation. In: Proceedings of the International Conference on Machine Learning. Vienna, Austria: ICML, 2021. 10991–11002
- 40 Yan L, Li F, Zhang L, Zheng X. Discriminant space metric network for few-shot image classification. *Applied Intelligence*, 2023, **53**: 17444–17459
- 41 Wang Y, Chao W L, Weinberger K Q, Maaten L. SimpleShot: Revisiting nearest-neighbor classification for few-shot learning. arXiv preprint arXiv: 1911.04623, 2019.
- 42 Ramprasaath R, Michael C, Abhishek D, Ramakrishna V, Devi P, Dhruv B. Grad-CAM: Visual explanations from deep networks via gradient-based localization. In: Proceedings of the IEEE/CVF International Conference on Computer Vision. Venice, Italy: IEEE, 2017. 618–626
- 43 Dhillon G S, Chaudhari P, Ravichandran A, Soatto S. A baseline for few-shot image classification. In: Proceedings of the

International Conference on Learning Representations. Addis Ababa, Ethiopia: ICLR, 2020. 1–12



赵红 闽南师范大学计算机学院教授。2019年获得天津大学博士学位。主要研究方向为粒计算, 小样本学习和分层分类。本文通信作者。

E-mail: hongzhaocn@163.com

(**ZHAO Hong** Professor at the School of Computer Science, Min-

nan Normal University. She received her Ph.D. degree from Tianjin University in 2019. Her research interest covers granular computing, few-shot learning, and hierarchical classification. Corresponding author of this paper.)



钟杨清 闽南师范大学计算机学院硕士研究生。主要研究方向为小样本学习。E-mail: yangqingzhong0@163.com

(**ZHONG Yang-Qing** Master student at the School of Computer Science, Minnan Normal University. Her main research interest is few-shot

learning.)



金杰 闽南师范大学计算机学院硕士研究生。主要研究方向为小样本学习, 分层分类。

E-mail: kimjee@126.com

(**JIN Jie** Master student at the School of Computer Science, Min-

nan Normal University. His research interest covers few-shot learning and hierarchical classification.)



邹林华 闽南师范大学计算机学院硕士研究生。主要研究方向为小样本学习, 分层分类。

E-mail: zlh1836065471@163.com

(**ZOU Lin-Hua** Master student at the School of Computer Science, Minnan Normal University. His re-

search interest covers few-shot learning and hierarchical classification.)