



# 计算机科学

COMPUTER SCIENCE

## 基于对称卷积块网络和原型校准的小样本学习方法

刘帅, 白雪飞, 高小方

引用本文

刘帅, 白雪飞, 高小方. 基于对称卷积块网络和原型校准的小样本学习方法[J]. 计算机科学, 2024, 51(11): 182-190.

LIU Shuai, BAI Xuefei, GAO Xiaofang. [Few-Shot Learning Method Based on Symmetric Convolutional Block Network and Prototype Calibration](#) [J]. Computer Science, 2024, 51(11): 182-190.

---

## 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)

### [面向文本识别的小样本阴影消除方法](#)

Few-shot Shadow Removal Method for Text Recognition

计算机科学, 2024, 51(9): 147-154. <https://doi.org/10.11896/jsjcx.230800003>

### [基于原型修正的小样本半监督语义图像翻译算法](#)

Few-shot Semi-supervised Semantic Image Translation Algorithm Based on Prototype Correction

计算机科学, 2024, 51(8): 224-231. <https://doi.org/10.11896/jsjcx.230500038>

### [任务感知的多尺度小样本SAR图像分类方法](#)

Task-aware Few-shot SAR Image Classification Method Based on Multi-scale Attention Mechanism

计算机科学, 2024, 51(8): 160-167. <https://doi.org/10.11896/jsjcx.230500171>

### [基于伪标签依赖增强与噪声干扰消减的小样本图像分类](#)

Few-shot Image Classification Based on Pseudo-label Dependence Enhancement and

Noise Interference Reduction

计算机科学, 2024, 51(8): 152-159. <https://doi.org/10.11896/jsjcx.230500066>

### [基于拉格朗日对偶的小样本学习隐私保护和公平性约束方法](#)

Lagrangian Dual-based Privacy Protection and Fairness Constrained Method for Few-shot Learning

计算机科学, 2024, 51(7): 405-412. <https://doi.org/10.11896/jsjcx.230500012>

# 基于对称卷积块网络和原型校准的小样本学习方法

刘帅 白雪飞 高小方

山西大学计算机与信息技术学院 太原 030006

(1669267672@qq.com)

**摘要** 针对基于原型网络的小样本学习模型泛化能力不足以及由少量样本得到的类原型不准确等问题,提出一种新的小样本学习方法。首先采用一个由双向卷积块注意力模块和残差块构成的对称网络 SCB-Net 对图像不同深度的特征进行自适应学习,从而提取到更具代表性的类别特征表示,以有效提高模型的泛化能力;其次提出了一种反欧氏标签传播原型校准算法 IELP-PC,利用伪标签策略扩充支持集样本;最后在支持集样本上采用反欧氏距离加权对类原型进行校准,进而提高模型的分类精度。在两个常用数据集 mini-ImageNet 和 tiered-ImageNet 上进行了实验,结果验证了所提方法的有效性,与基线模型相比,其在 5-way 1-shot 上分别提高了 6.44% 和 7.83%,在 5-way 5-shot 上分别提高了 2.68% 和 2.02%。

**关键词:** 原型网络;小样本学习;对称卷积块网络;原型校准;反欧氏距离

中图分类号 TP391

## Few-Shot Learning Method Based on Symmetric Convolutional Block Network and Prototype Calibration

LIU Shuai, BAI Xuefei and GAO Xiaofang

School of Computer and Information Technology, Shanxi University, Taiyuan 030006, China

**Abstract** To address the issues of poor generalization performance in few-shot learning models based on prototype networks and inaccurate class prototypes obtained from a small number of samples, a novel few-shot learning method is proposed in this paper. Firstly, a symmetric convolutional block network (SCB-Net) consisting of bidirectional convolutional block attention modules and residual blocks is used to adaptively learn the features at different depths of the image, so as to extract a more representative representation of the category features and effectively improve the generalization ability of the model. Secondly, an inverse Euclidean label propagation prototype calibration algorithm (IELP-PC) is introduced. It employs pseudo-labeling to augment the support set samples and subsequently calibrates the class prototypes using inverse Euclidean distance weighting for the support set samples, thereby improving the model's classification accuracy. Experiment results on two commonly used datasets mini-ImageNet and tiered-ImageNet demonstrate the effectiveness of the proposed method. Compared with the baseline model, the proposed method improves the 5-way 1-shot accuracy by 6.44% and 7.83%, and the 5-way 5-shot accuracy by 2.68% and 2.02%, respectively.

**Keywords** Prototype network, Few-shot learning, Symmetric convolutional block network, Prototype calibration, Inverse Euclidean distance

### 1 引言

近年来,随着人工智能技术的飞速发展,深度学习已经被广泛应用于图像识别、图像分割等多个领域<sup>[1]</sup>。在拥有大量标记数据的情况下,深度学习方法可以达到非常好的识别效果。然而,在现实世界中,图像数据分布非常不平衡<sup>[2]</sup>。有些类别的图像数据由于安全、隐私等原因获取困难,给传统的监督学习造成了极大的困扰。即使一些类别拥有丰富的图像数据,为这些数据进行标注也非常昂贵。在标记数据缺乏的

困境下,深度学习很难发挥出真正的实力<sup>[3]</sup>。而人类可以在很少的样本中进行学习,并将学习到的知识迁移到新的任务中。为了降低深度学习模型对标记数据的依赖,科研工作者受人类学习方式的启发,提出了小样本学习方法(Few-Shot Learning, FSL)<sup>[4-5]</sup>。

小样本学习首先从大量无关的、已标记的基类数据中获取先验知识,然后使用少量已标记的新类数据完成对未标记新类数据的分类<sup>[6]</sup>。小样本学习所面临的主要问题是标记样本不足,导致模型过拟合严重,泛化能力下降。目前用于解决

到稿日期:2023-09-04 返修日期:2023-12-28

基金项目:国家自然科学基金(61703252,62276161);山西省重点研发项目(202102150401013);山西省回国留学人员科研资助项目(2022-008)

This work was supported by the National Natural Science Foundation of China(61703252,62276161), Key Research and Development Program of Shanxi Province(202102150401013) and Research Project Supported by Shanxi Scholarship Council of China(2022-008).

通信作者:白雪飞(baixuefei@sxu.edu.cn)

小样本学习问题的方法大致可以分为以下3类:基于元学习的方法、基于图神经网络的方法和基于度量学习的方法。

基于元学习的方法利用在大量先验任务中学习到的元知识促进模型在新任务中快速学习,可以较快地适应新的任务,但是这类方法容易忽略不同任务之间的差异,而且计算复杂度较高<sup>[7-9]</sup>。基于图神经网络的方法利用图数据结构将有标签的样本信息传递给无标签的查询样本,能够准确地提取样本之间的关系,但是存在节点过平滑和依赖图结构等问题<sup>[10-11]</sup>。

与前两种方法相比,基于度量学习的方法思想简单、适应性强,通过嵌入模块将样本投影到向量空间,然后根据度量模块计算的相似度得分进行分类,可以获得较好的分类性能<sup>[12-13]</sup>,经典的方法包括孪生网络(Siamese Network)<sup>[14]</sup>、匹配网络(Matching Network)<sup>[15]</sup>和原型网络(Prototypical Network)<sup>[16]</sup>等。其中,原型网络是一种使用广泛且效果较好的方法,每个类中样本的特征均值被作为该类的类原型,然后通过计算查询样本与类原型之间的欧氏距离进行分类,很多研究在此基础上进行改进和优化。

例如,元基线(Meta-baseline)<sup>[17]</sup>在原型网络的基础上将分类器训练和元训练相结合,通过计算查询图像和类原型之间的余弦相似度预测查询样本的类标签。Xin等<sup>[18]</sup>提出了一种Res-CBAMnet特征提取网络,利用卷积关注机制增强图像特征的代表性,提高模型的泛化性能。Liu等<sup>[19]</sup>提出了一种基于非对称卷积和注意力机制的小样本图像分类方法,用非对称的卷积块代替标准卷积核,并且采用SENet(Squeeze-and-Excitation Networks)注意力机制构建特征与通道的相关性,以提高模型的泛化能力。Chen等<sup>[20]</sup>提出了一种基于频域注意力的小样本图像分类方法,在网络中加入频域注意力模块,利用输入图像的空间域和频域特征来增强模型的泛化性能。Song等<sup>[21]</sup>使用多注意力机制来获取更多具有代表性的特征,并且融合查询样本特征来减小类原型偏差。Liu等<sup>[22]</sup>采用归一化原型网络来提高特征的可表示性,并且使用混合原型分类器修正单样本设置下的类原型。Liu等<sup>[23]</sup>提出了一种原型矫正算法BD-CSPN,采用标签传播对类原型进行

修正以减小类内偏差,使用特征偏移减小类间偏差。Yang等<sup>[24]</sup>提出了一种分布校准算法,选取与原始类原型欧氏距离较近的基类原型校准新类的原型和方差,然后在新类分布中充分采样来训练分类器。Huang等<sup>[25]</sup>在分布校准算法的基础上采用相似度加权基类表征新类原型,然后用新类原型和样本构造均匀分布的训练分类器。

上述方法在小样本学习中的泛化性能提升和类原型校准等方面取得了一定的进展,但是依然存在以下两个问题:1)在提取图像特征时,模型学习到的关键信息不够充分,同时容易受到噪声和无关信息的干扰,得到的特征代表性不强,导致模型的泛化性能不足;2)原型网络将每类样本的特征平均作为该类的类原型,而由少量样本计算得到的类原型与真实的类原型存在较大偏差,导致分类边界不准确,影响了模型的性能。

针对上述问题,本文提出了一种基于对称卷积块网络和原型校准的小样本学习方法,可以快速准确地对小样本图像进行分类,其框架如图1所示。本文的主要贡献如下:

1)设计了一个对称卷积块网络(Symmetric Convolutional Block Network, SCB-Net),用于提取图像特征,其将一个反向卷积块注意力模块(Reverse Convolutional Block Attention Module, RCBAM)与正向卷积块注意力模块(Convolutional Block Attention Module, CBAM)以对称方式嵌入在残差块中,能够自适应地关注不同深度特征的关键信息,提取到更具有代表性的图像类别特征,从而提高模型的泛化能力。

2)提出了一种反欧氏标签传播原型校准算法(Inverse Euclidean Label Propagation Prototype Calibration, IELPPC),在向量空间中筛选与类原型欧氏距离较近的查询集样本加入支持集中,然后对支持集中的样本进行反欧氏距离加权得到校准后的类原型,校准后的类原型在度量空间中更接近真实的类原型,使分类更加准确。

3)在常用的mini-ImageNet数据集和tiered-ImageNet数据集上进行了大量实验,可视化的实验结果和各项评价指标表明,与传统的基于度量学习的小样本方法相比,本文方法在小样本学习性能上有显著提升。

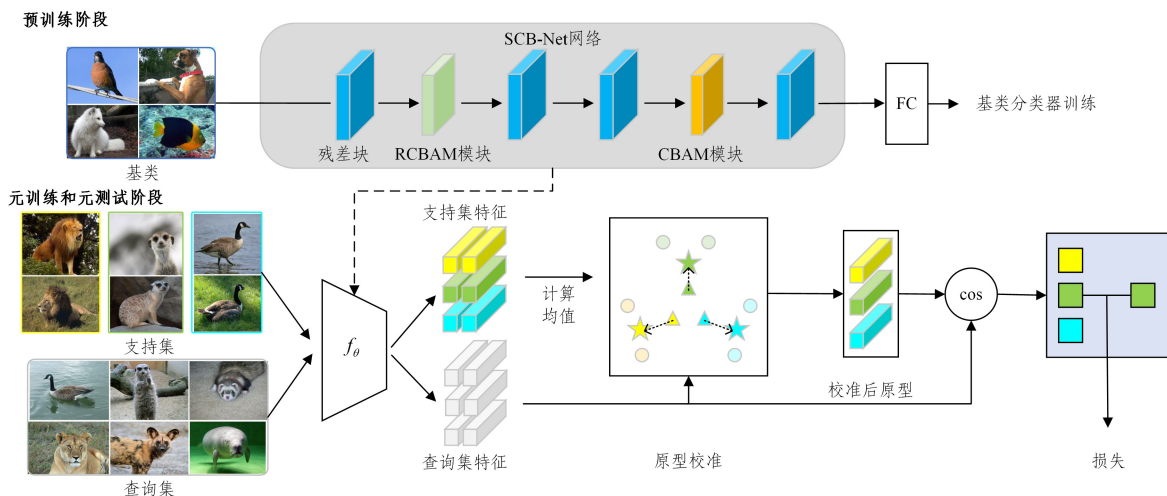


图1 基于对称卷积块网络和原型校准的小样本学习框架(电子版为彩图)

Fig. 1 Few-shot classification framework based on symmetric convolutional block network and prototype calibration

## 2 本文方法

### 2.1 问题定义

在小样本图像分类中,数据被分为基类数据  $C^{\text{base}} = \{(x_i, y_i)\}_{i=1}^{|C^{\text{base}}|}$  和新类数据  $C^{\text{novel}}$ .  $y_i$  为样本  $x_i$  的标签,  $y_i \in C^b, C^b$  和  $C^n$  分别表示基类和新类的标签集。基类数据和新类数据在类别上不相交,即  $C^b \cap C^n = \emptyset$ 。小样本学习通常采用元任务进行训练和测试,每个元任务中采用 N-way K-shot 范式,即从数据集中随机抽取  $N$  个类别,每个类别抽取  $K$  个带标签的样本用于训练,由这  $N \times K$  个样本组成的集合称为支持集,表示为  $C^{\text{support}} = \{(x_i^s, y_i^s)\}_{i=1}^{N \times K}$ ,从每类剩下的图像中抽取  $Q$  个不带标签的样本用于测试,由这  $N \times Q$  个样本组成的集合称为查询集,表示为  $C^{\text{query}} = \{(x_i^q, y_i^q)\}_{i=1}^{N \times Q}$ 。  $N$  通常取 5,  $K$  通常取 1 或 5。

### 2.2 模型框架

本文提出的基于对称卷积块网络和原型校准的小样本学习方法有两个训练阶段和一个测试阶段,具体流程如下。

#### 2.2.1 预训练阶段

预训练阶段的任务是使用所有基类数据训练一个基类分类器。首先初始化一个分类器,该分类器由一个特征提取网络和一个全连接(Fully Connected, FC)层组成。采用本文提出的 SCB-Net 网络提取特征后使用由一个全连接层组成的线性分类器进行分类,训练分类器的损失采用标准交叉熵损失。

#### 2.2.2 元训练阶段

在基类数据中构建  $T$  个 N-way K-shot 任务。将训练好的基类分类器去掉最后的 FC 层,得到参数化的 SCB-Net 网络,并将其作为特征编码器  $f_\theta$ 。在每个元任务中,使用特征编码器对支持集样本和查询集样本进行特征提取。通过式(1)计算支持集中每类样本的特征平均值,将其作为该类的类原型。

$$p_n = \frac{1}{|C_n^{\text{support}}|} \sum_{i=1}^{|C_n^{\text{support}}|} f_\theta(x_{n,i}^s) \quad (1)$$

其中,  $p_n, x_{n,i}^s$  和  $|C_n^{\text{support}}|$  分别表示支持集第  $n$  类的类原型、支持集第  $n$  类的第  $i$  个样本和支持集第  $n$  类的样本数量。

在特征空间中筛选与类原型欧氏距离较近的查询集样本特征,并为这些样本分配对应类的伪标签,将它们加入支持集中,然后对支持集中的样本特征进行加权求和得到校准后的类原型。在图 1 的原型校准模块中,不同浅颜色的圆形表示标有伪标签的查询集样本特征,黄色、青色和绿色的三角形表示每个类的原始类原型,标有对应颜色的五角星表示校准后的类原型。最后采用式(2)对查询集中每个样本的类标签进行预测。

$$g(y_i = n | x_i^q) = \frac{\exp(\tau \cdot \cos(f_\theta(x_i^q), p_n'))}{\sum_{n=1}^N \exp(\tau \cdot \cos(f_\theta(x_i^q), p_n'))} \quad (2)$$

其中,  $g(\cdot)$  为概率分布函数;  $\cos(\cdot, \cdot)$  为余弦相似度函数;  $\cos(a, b) = a \cdot b / \|a\| \|b\|$ ;  $x_i^q$  表示查询集中的第  $i$  个样本;  $p_n'$  表示校准后第  $n$  类的类原型;  $\tau$  为可学习参数,用来缩放余弦相似度。

每个元任务的损失函数为:

$$L^{\text{meta}} = -\frac{1}{N \times Q} \sum_{i=1}^{N \times Q} \sum_{n=1}^N y_{in} \log(g_{in}) \quad (3)$$

其中,  $g_{in} = g(y_i = n | x_i^q)$ ;  $y_{in}$  为指示函数,若  $y_i = n$ ,则  $y_{in} = 1$ ,否则为 0。

通过最小化所有元任务的平均损失更新模型参数  $\theta$ ,如式(4)所示:

$$\theta = \arg \min_{\theta} \frac{1}{T} \sum_{t=1}^T L_t^{\text{meta}} \quad (4)$$

#### 2.2.3 元测试阶段

在新类数据中构建 N-way K-shot 任务。元测试与元训练的分类过程相同,首先由式(1)计算得到每个类的类原型,然后在原型校准模块中对新类的类原型进行校准,最后由式(2)计算查询集样本特征和校准后类原型的余弦相似度得到查询集样本的标签。

### 2.3 对称卷积块网络(SCB-Net)

在传统的小样本学习方法中,由于训练样本较少,模型容易过拟合,导致其在特征提取过程中忽略了不同深度特征以及不同维度的关键信息。同时,模型还会受到图像噪声等干扰信息的影响,得到的图像特征代表性不强,从而导致泛化能力较差。为了提高模型的泛化能力,本文首先提出了一个 SCB-Net 特征提取网络,如图 2 所示。该网络采用残差网络结构,共有 4 个残差块,其中每个残差块由 3 个卷积层、3 个批归一化层以及 1 个最大池化层组成,具体结构如图 2 虚线框部分所示。此外,为了增强网络对不同深度图像特征的信息提取能力,在卷积块注意力模块 CBAM 基础上,本文提出了一个反向卷积块注意力模块 RCBAM,并将这两个模块以对称的形式嵌入在 SCB-Net 网络中。

如图 3 所示, CBAM 模块是由通道注意力模块和空间注意力模块组成的顺序结构,首先对每个通道的特征进行重要性加权,然后对空间维度的特征进行关注。本文提出的 RCBAM 模块将空间注意力模块放置在通道注意力模块之前,首先在空间维度上对特征进行关注,然后在通道维度上对空间位置的特征进行重要性加权,如图 4 所示。

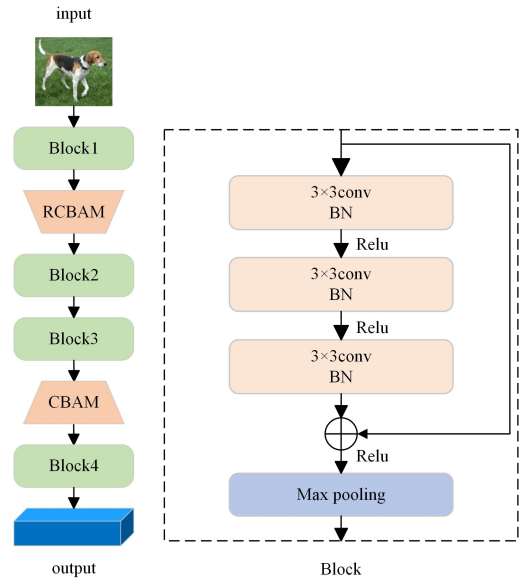


图 2 SCB-Net 网络结构图

Fig. 2 Structure diagram of SCB-Net




图 3 正向卷积块注意力模块

Fig. 3 Forward convolution block attention module




图 4 反向卷积块注意力模块

Fig. 4 Reverse convolutional block attention module

图像经过每个残差块后,其输出特征图的尺寸和通道数会发生变化,在空间和通道两个维度上信息的重要程度也会随之改变。浅层网络输出的特征图尺寸较大并且通道数较少,在空间维度上所蕴含的信息比通道维度上的信息更加丰富。随着网络的加深,输出的特征图通道数增加,并且尺寸减小,此时特征图在通道维度上所蕴含的信息比空间维度上的信息更重要。因此,根据不同深度特征的不同维度信息的重要程度,本文在第一个残差块后插入 RCBAM 模块,该模块先后从空间和通道两个维度计算浅层特征的权重,关键信息获得的权重较大,噪声及背景信息获得的权重就较小。将权重与特征相乘后,关键特征被增强,而噪声和无关背景信息会被抑制。在第三个残差块后插入 CBAM 模块,该模块先后从通道和空间两个维度对深层特征的信息进行自适应加权,进一步降低了噪声和其他无关信息的干扰。RCBAM 模块和 CBAM 模块的互补使得 SCB-Net 网络能够自适应提取到图像不同深度特征的关键信息,得到的图像特征代表性更强,从而提高模型的泛化能力。

空间注意力模块能够对关键特征的空间位置信息进行学习,如图 5 所示。空间注意力机制首先对输入的特征图进行通道上的平均池化和最大池化;然后在通道上进行合并,再经过一个卷积层得到只有一个通道的特征;最后使用 Sigmoid 函数为特征图分配权重。该过程如式(5)所示:

$$M_s(\mathbf{F}) = \sigma(\text{conv}^{7 \times 7}([\text{AvgPool}(\mathbf{F}); \text{MaxPool}(\mathbf{F})])) \\ = \sigma(\text{conv}^{7 \times 7}([\mathbf{F}_{\text{avg}}^s; \mathbf{F}_{\text{max}}^s])) \quad (5)$$

其中,  $\mathbf{F}$  为输入特征,  $\text{conv}^{7 \times 7}$  表示卷积核为  $7 \times 7$  的卷积层,  $\sigma(\cdot, \cdot)$  为 Sigmoid 激活函数。




图 5 空间注意力模块

Fig. 5 Spatial attention module

通道注意力机制首先在空间维度上对特征进行压缩,同时对特征进行最大池化和平均池化操作,如图 6 所示。平均池化和最大池化可以增强特征图中的空间信息,将得到的特征图输入到共享网络中,压缩输入特征图的空间维度,逐个元素求和合并,生成通道注意力图。该过程如式(6)所示:

$$M_c(\mathbf{F}) = \sigma(\text{MLP}(\text{AvgPool}(\mathbf{F})) + \text{MLP}(\text{MaxPool}(\mathbf{F}))) \\ = \sigma(W_1(W_0(\mathbf{F}_{\text{avg}}^c)) + W_1(W_0(\mathbf{F}_{\text{max}}^c))) \quad (6)$$




图 6 通道注意力模块

Fig. 6 Channel attention module

输入一幅图像,经过第一个残差块后,得到一个浅层特征图  $\mathbf{F}_1 \in \mathbb{R}^{C \times H \times W}$ 。然后 RCBAM 模块推导出特征图  $\mathbf{F}_1$  的空间注意力图  $M_s(\mathbf{F}_1) \in \mathbb{R}^{1 \times H \times W}$ ,并将  $\mathbf{F}_1$  与其空间注意力图相乘得到  $\mathbf{F}_1'$ ,将其输入通道注意力模块得到通道注意力图  $M_c(\mathbf{F}_1') \in \mathbb{R}^{C \times 1 \times 1}$ 。最后将  $\mathbf{F}_1'$  与其通道注意力图相乘得到  $\mathbf{F}_1''$ 。过程如下:

$$\mathbf{F}_1' = M_s(\mathbf{F}_1) \otimes \mathbf{F}_1 \quad (7)$$

$$\mathbf{F}_1'' = M_c(\mathbf{F}_1') \otimes \mathbf{F}_1' \quad (8)$$

其中,  $\otimes$  表示逐元素相乘。接下来,将  $\mathbf{F}_1''$  依次通过后面的残差块,在经过第三个残差块后输出特征图  $\mathbf{F}_3$ 。CBAM 模块依次推导出特征图  $\mathbf{F}_3$  的通道注意力图  $M_c(\mathbf{F}_3) \in \mathbb{R}^{C \times 1 \times 1}$  和空间注意力图  $M_s(\mathbf{F}_3') \in \mathbb{R}^{1 \times H \times W}$ ,经过顺序相乘后得到  $\mathbf{F}_3''$ 。其过程如下:

$$\mathbf{F}_3' = M_c(\mathbf{F}_3) \otimes \mathbf{F}_3 \quad (9)$$

$$\mathbf{F}_3'' = M_s(\mathbf{F}_3') \otimes \mathbf{F}_3' \quad (10)$$

最后,将  $\mathbf{F}_3''$  输入第四个残差块,得到最终的图像特征。

## 2.4 反欧氏标签传播原型校准算法 (IELP-PC)

在原型网络中,类原型表示每个类的簇中心,样本点都聚集在类原型周围。测试过程中,查找距离查询样本最近的类原型,并对其进行分类。一些基于原型网络的方法通过对支持集样本的特征进行平均来获得类原型,然而,真实的类原型是通过同一类中的大量样本特征计算均值得到的。支持集中的样本非常少,无法代表整个类的分布,计算得到的类原型与真实的类原型存在显著偏差。模型使用偏差较大的类原型容易产生误分类,从而导致分类性能下降。

为了提高模型的性能,本文提出了一种反欧氏标签传播原型校准算法 IELP-PC,伪代码如算法 1 所示,该算法通过引入查询集样本增加样本数量,并采用伪标签策略为查询集样本添加标签,然后将其加入到具有相同标签的支持集中。但是查询样本也有可能被错误标记,从而对原型校准产生干扰。因此,本文只选择将与类原型欧氏距离最近的前  $k$  个查询样本加入到支持集中,并且对支持集中的样本采用反欧氏距离加权计算,得到类原型。在特征空间中,同一类的样本与其类原型更加接近,而且与类原型距离越近的样本相似度

越大。为了提高类原型的准确性,需要增强距离较近的样本对原型校准的影响,同时也需要保留距离相对较远的样本对原型校准的作用。反欧氏相似度能够对欧氏距离较近的样本赋予很大的权重,而且能够捕捉较远样本与类原型之间的相似性。相对于余弦相似度,反欧氏相似度的取值范围更广,加权更加灵活,校准后的类原型更加准确,能够显著提高模型的分性能。IELP-PC算法的具体过程如下:

1) 计算每个查询集样本与原始类原型的欧氏距离,如式(11)所示:

$$D = \{d_i | d_i = \sqrt{(f_\theta(\mathbf{x}_i^q) - \mathbf{p}_n)^2}, \mathbf{x}_i^q \in C^{\text{query}}\} \quad (11)$$

其中,  $\mathbf{x}_i^q$  表示查询集  $C^{\text{query}}$  中的第  $i$  个样本,  $\mathbf{p}_n$  表示第  $n$  类的类原型。

2) 在查询集中筛选与类原型欧氏距离最近的前  $k$  个样本,并为这些样本赋予伪标签,如式(12)所示:

$$C_n^{\text{pseudo}} = \{\mathbf{x}_i^q | i \in \text{topk\_indices}(D)\} \quad (12)$$

其中,  $\text{topk\_indices}(\cdot)$  表示返回集合中最小的前  $k$  个元素的索引,  $C_n^{\text{pseudo}}$  表示被标记伪标签的查询样本集合。

3) 将标记有伪标签的查询集样本与支持集样本合并在一起,如式(13)所示:

$$C_n^{\text{support}} = C_n^{\text{support}} + C_n^{\text{pseudo}} \quad (13)$$

其中,  $C_n^{\text{support}}$  表示合并后支持集中第  $n$  类的样本集合,  $C_n^{\text{support}}$  为合并前支持集中第  $n$  类的样本集合。

4) 将支持集样本与类原型之间欧氏距离平方的倒数,即反欧氏距离作为相似性度量,计算每个支持集样本与类原型之间的相似度,如式(14)所示:

$$u_i = \frac{1}{(f_\theta(\mathbf{x}_{n,i}^s) - \mathbf{p}_n)^2 + \alpha} \quad (14)$$

其中,  $\mathbf{x}_{n,i}^s \in C_n^{\text{support}}$  表示合并后支持集第  $n$  类中的第  $i$  个样本;  $\mathbf{p}_n$  表示第  $n$  类的类原型;  $u_i$  为查询集样本与类原型之间的相似度;  $\alpha$  是一个小正数,为了避免分母为 0,通常取 0.1。

5) 通过相似度归一化计算支持集第  $n$  类的每个样本的权重系数。

$$\omega_i = \frac{u_i}{\sum_{i=1}^{|C_n^{\text{support}}|} u_i} \quad (15)$$

其中,  $|C_n^{\text{support}}|$  表示合并后支持集中第  $n$  类的样本总数,  $\omega_i$  为每个样本的权重。

6) 对支持集第  $n$  类的样本进行加权求和,得到校准后的类原型。

$$\mathbf{p}_n' = \sum_{i=1}^{|C_n^{\text{support}}|} \omega_i f_\theta(\mathbf{x}_{n,i}^s) \quad (16)$$

其中,  $\mathbf{p}_n'$  表示校准后第  $n$  类的类原型。

**算法 1** 反欧氏标签传播原型校准(IELP-PC)算法

输入: 支持集数据  $C^{\text{support}} = \{(\mathbf{x}_i^s, \mathbf{y}_i^s)\}_{i=1}^{N \times K}$ , 查询集数据  $C^{\text{query}} = \{(\mathbf{x}_i^q, \mathbf{y}_i^q)\}_{i=1}^{N \times Q}$

输出: 校准后的类原型  $\mathbf{p}_n'$

1. 通过式(1)计算支持集每个类的类原型  $\mathbf{p}_n$ ;
2. for  $n \leftarrow 1$  to  $N$  do
3. 计算查询集样本与类原型  $\mathbf{p}_n$  之间的欧氏距离,如式(11)所示;
4. 筛选与类原型  $\mathbf{p}_n$  最近的前  $k$  个查询集样本并赋予该类的伪标签,

如式(12)所示;

5. 将支持集样本与标有该类伪标签的查询集样本合并,如式(13)所示;
6. 计算合并后支持集第  $n$  类每个样本与类原型  $\mathbf{p}_n$  的相似度,如式(14)所示;
7. 计算支持集第  $n$  类中每个样本的权重系数,如式(15)所示;
8. 对第  $n$  类的样本进行加权求和得到校准后的类原型  $\mathbf{p}_n'$ ,如式(16)所示;
9. end for

### 3 实验内容与结果分析

为了验证本文提出的小样本学习方法及各模块的有效性和可行性,在两个常用的小样本学习数据集 mini-ImageNet 和 tiered-ImageNet 上进行实验,对不同方法的分类性能进行比较,同时也对本文模型的超参数、复杂度进行分析。

#### 3.1 数据集及评价指标

本文实验中采用的两个数据集 mini-ImageNet 和 tiered-ImageNet 是小样本研究中通用的基准数据集,均为 ImageNet 数据集中抽取的子集,具体描述如表 1 所列。其中,mini-ImageNet 有 100 个类,其中 64 个类用于训练,16 个类用于验证,20 个类用于测试。每个类有 600 张图像,一共有 60 000 张图像。tiered-ImageNet 是 ImageNet 的一个更大的子集,有 34 个大类,包含 608 个小类,其中训练集有 20 个大类(351 个小类),验证集有 6 个大类(97 个小类),测试集有 8 个大类(160 个小类)。每个小类平均有 1 281 张图像,每张图像大小为  $224 \times 224$ 。

本文使用 top-1 精度作为衡量方法性能的评价指标,在 mini-ImageNet 和 tiered-ImageNet 数据集上采用 5-way 1-shot 和 5-way 5-shot 设置对各模型的性能进行了测试。实验展示的结果为 800 个元任务的平均分类精度。

表 1 数据集描述

Table 1 Descriptions of datasets

Dataset	Number of pictures	Number of classes	Number of training, validation, and test set classes
mini-ImageNet	60 000	100	64/16/20
tiered-ImageNet	779 165	34(608)	20/6/8(351/97/160)

#### 3.2 实验设置

实验平台的配置为 64 位操作系统 Ubuntu18.04, Nvidia A100 显卡,显卡内存为 40GB,编程语言为 Python,深度学习框架采用 Pytorch。

本文将 SCB-Net 作为特征提取网络,采用 Meta-baseline 作为实验的基线框架。在预训练阶段,首先初始化一个基类分类器,使用数据集中的训练集作为基类数据训练分类器,用 SCB-Net 网络对图像进行特征提取,然后使用一个全连接层对图像进行分类,在单个 GPU 上对分类器进行训练,损失函数为标准交叉熵损失。其中, batch 大小为 128, 训练 100 个 epoch。元训练阶段,在训练集上生成 800 个元任务。在 5-way 1-shot 设置中,每个元任务在训练集中随机抽取 5 个类,每个类随机抽取一幅图像作为支持样本,则支持集有 5 幅

图像;从每类剩下的图像中选取 15 幅作为查询样本,查询集有 75 幅图像。在 5-way 5-shot 设置中,每个元任务在训练集中随机抽取 5 个类,每个类随机抽取 5 幅图像作为支持样本,则支持集有 25 幅图像;从每类剩下的图像中选取 15 幅作为查询样本,查询集有 75 幅图像。训练 20 个 epoch,一个 epoch 有 200 个 batch,一个 batch 中有 4 个元任务,损失函数为预测结果和真实标签的交叉熵损失。选取与类原型欧氏距离最近的查询样本,其数量在 1-shot 设置中取 15,在 5-shot 设置中取 20,余弦缩放参数  $\tau$  初始化为 10。元测试阶段,在测试集上生成 800 个元任务,每个元任务随机抽取 5 个类,每个类随机抽取 1 或 5 个样本组成支持集,支持集样本数量为 5 或 25;再从每类剩下的样本中随机抽取 15 个组成查询集,查询集样本数量为 75。将 800 个元任务的平均测试精度作为最终结果。

### 3.3 对比实验

首先通过实验比较分析本文方法与其他经典的小样本学习方法的分类性能,如表 2 和表 3 所列,为了公平地进行比较,其他对比方法的实验结果均来自提出该方法的文献。根据测试过程的不同设置,小样本学习方法可以分为归纳式和直推式,其中归纳式表示对查询集中单个样本进行预测,而直推式是对整个查询集样本进行预测。本文在测试过程中对整个查询集样本进行预测,属于直推式。表 2 和表 3 中分界线以上为归纳式方法,以下为直推式方法,可以看出,与基线模型 Meta-Baseline 相比,本文方法在 mini-ImageNet 数据集上 5-way 1-shot 设置中精度提升了 6.44%,5-way 5-shot 设置中精度提升了 2.68%,在 tiered-ImageNet 上精度分别提升了 6.83%和 0.82%。与同类型中次优方法 BD-CSPN 相比,在 mini-ImageNet 数据集上 5-way 1-shot 设置中精度提升了 3.67%,5-way 5-shot 设置中精度提升了 2.71%,在 tiered-ImageNet 上精度分别提升了 0.28%和 0.06%。由此可见,本文提出的基于对称卷积块网络和原型校准的小样本学习方法与归纳式小样本学习方法以及同类型的直推式方法相比,在两个数据集的 1-shot 和 5-shot 性能上均达到了最优。1-shot,5-shot 的提升较小,这是因为随着样本数的增多,通过均值计算得到的类原型与真实的类原型非常接近,同时也说明了本文方法在样本量较少的情况下更有优势。

表 2 mini-ImageNet 数据集上的图像分类准确率

Table 2 Classification accuracy on mini-ImageNet dataset

		(%)	
Algorithm	Backbone	1-shot	5-shot
Matching Net <sup>[15]</sup>	ConvNet-4	43.56±0.84	55.31±0.73
MAML <sup>[8]</sup>	ConvNet-4	48.70±1.84	63.11±0.92
Prototypical Net <sup>[16]</sup>	ConvNet-4	56.13±0.45	75.70±0.33
LEO <sup>[26]</sup>	WRN-28-10	61.76±0.08	77.59±0.12
E3BM <sup>[27]</sup>	ResNet-12	63.80±0.40	80.10±0.30
TADAM <sup>[28]</sup>	ResNet-12	58.50±0.30	76.70±0.30
CTM <sup>[29]</sup>	ResNet-18	62.05±0.55	78.63±0.06
Meta-Baseline <sup>[17]</sup>	ResNet-12	63.17±0.23	79.26±0.17
TPN <sup>[30]</sup>	ConvNet-4	55.51±0.86	69.86±0.65
CAN+T <sup>[31]</sup>	ResNet-12	67.19±0.55	80.64±0.35
PRFDC <sup>[32]</sup>	ResNet-12	63.92±0.53	80.41±0.33
BD-CSPN <sup>[23]</sup>	ResNet-12	65.94	79.23
Our Method	SCB-Net	<b>69.61±0.30</b>	<b>81.94±0.55</b>

注:“±”前面的数值表示准确率,“±”后面的数值表示 95%的置信区间的置信度;加粗数值为最优值。

表 3 tiered-ImageNet 数据集上的分类准确率

Table 3 Classification accuracy on tiered-ImageNet dataset

		(%)	
Algorithm	Backbone	1-shot	5-shot
MAML <sup>[8]</sup>	ConvNet-4	51.67±1.81	70.30±1.75
Prototypical Net <sup>[16]</sup>	ConvNet-4	59.11±0.52	75.30±0.42
LEO <sup>[26]</sup>	WRN-28-10	66.33±0.55	81.44±0.09
E3BM <sup>[27]</sup>	ResNet-12	71.20±0.40	85.30±0.30
CTM <sup>[29]</sup>	ResNet-18	64.78±0.11	81.05±0.52
Meta-Baseline <sup>[17]</sup>	ResNet-12	68.62±0.27	83.74±0.18
TPN <sup>[30]</sup>	ConvNet-4	59.91±0.94	73.30±0.75
CAN+T <sup>[31]</sup>	ResNet-12	73.21±0.58	84.93±0.38
PRFDC <sup>[32]</sup>	ResNet-12	64.44±0.45	83.30±0.37
BD-CSPN <sup>[23]</sup>	ResNet-12	76.17	85.70
Our Method	SCB-Net	<b>76.45±0.85</b>	<b>85.76±0.56</b>

注:“±”前面的数值表示准确率,“±”后面的数值表示 95%的置信区间的置信度;加粗数值为最优值。

### 3.4 消融实验

为了验证本文提出的 SCB-Net 网络中各模块的作用,在 SCB-Net 网络不同的残差块后加入 RCBAM 模块或 CBAM 模块,然后在 mini-ImageNet 数据集的 5-way 1-shot 和 5-way 5-shot 设置下测试其性能,结果如表 4 所列。为了方便表示,表中第一列的数字和字母表示在残差块之间加入模块的位置,数字表示 4 个残差块,“R”表示 RCBAM 模块,“C”表示 CBAM 模块,如“1-R-2-3-4”表示在第一个残差块后加入 RCBAM 模块。由表中前四行结果可以看出,在网络浅层加入 RCBAM 模块要比加入 CBAM 模块的效果好,而在深层加入 CBAM 模块要比加入 RCBAM 模块的效果更好,这也证明了 RCBAM 模块更适合对浅层网络特征进行关注,而 CBAM 模块更适合对深层网络特征进行关注。从表中后四行实验结果可以看出,单纯地在全部残差块后加入 RCBAM 模块或者 CBAM 模块不如在第一个残差块和第三个残差块后分别加入 RCBAM 和 CBAM 模块的效果好,这说明了最后一个网络结构,即本文所采用的 SCB-Net 网络的对称结构的合理性和有效性,而且其更加轻量化。

表 4 mini-ImageNet 数据集上采用不同网络结构的消融实验结果

Table 4 Results of ablation experiments with different network structures on mini-ImageNet dataset

		(%)	
Location of CBAM/RCBAM modules in the network		1-shot	5-shot
1-R-2-3-4		63.21±0.28	78.98±0.30
1-C-2-3-4		63.13±0.28	78.95±0.22
1-2-3-R-4		63.38±0.28	79.33±0.31
1-2-3-C-4		63.79±0.30	79.41±0.26
1-C-2-C-3-C-4-C		63.86±0.30	79.24±0.22
1-R-2-R-3-R-4-R		64.02±0.26	79.12±0.22
1-R-2-R-3-C-4-C		64.05±0.28	79.26±0.19
1-R-2-3-C-4		<b>64.09±0.28</b>	<b>79.53±0.22</b>

注:“±”前面的数值表示准确率,“±”后面的数值表示 95%的置信区间的置信度;加粗数值为最优值。

此外,为了验证本文提出的 SCB-Net 网络和 IELP-PC 算法的有效性,本文在 mini-ImageNet 和 tiered-ImageNet 数据

集的 5-way 1-shot 和 5-way 5-shot 设置下进行了消融实验, 结果如表 5 和表 6 所列。使用 SCB-Net 网络后, 模型在 mini-ImageNet 数据集的 1-shot 和 5-shot 性能上比基线模型 Meta-Baseline 分别提升了 0.92% 和 0.27%, 在 tiered-ImageNet 数据集的 1-shot 和 5-shot 性能上比基线模型 Meta-Baseline 分别提升了 1.18% 和 0.11%, 说明本文提出的 SCB-Net 网络可以提升 Meta-Baseline 的小样本学习性能。使用 IELP-PC 算法后, 模型比 Meta-Baseline 在 mini-ImageNet 数据集上的 1-shot 和 5-shot 分别提升了 5.57% 和 1.52%, tiered-ImageNet 数据集的 1-shot 和 5-shot 分别提升了 6.4% 和 0.74%, 说明使用 IELP-PC 算法得到的类原型更加接近真实的类原型。从表中也能看出, 同时使用 SCB-Net 网络和 IELP-PC 算法的性能比单独使用其中一项的性能要高, 也进一步说明本文提出的 SCB-Net 网络和 IELP-PC 算法在模型框架中是相互促进、相辅相成的。

表 5 mini-ImageNet 数据集上的消融实验结果

Table 5 Results of ablation experiments on mini-ImageNet dataset (%)

SCB-Net	IELP-PC	1-shot	5-shot
×	×	63.17±0.23	79.26±0.17
√	×	64.09±0.28	79.53±0.22
×	√	68.74±0.30	80.78±0.56
√	√	<b>69.61±0.30</b>	<b>81.94±0.55</b>

注:“±”前面的数值表示准确率,“±”后面的数值表示 95% 的置信区间的置信度;加粗数值为最优值。

表 6 tiered-ImageNet 数据集上的消融实验结果



Table 6 Results of ablation experiments on tiered-ImageNet dataset (%)

SCB-Net	IELP-PC	1-shot	5-shot
×	×	68.62±0.27	83.74±0.18
√	×	69.80±0.86	83.85±0.58
×	√	75.02±0.86	84.48±0.59
√	√	<b>76.45±0.85</b>	<b>85.76±0.56</b>

注:“±”前面的数值表示准确率,“±”后面的数值表示 95% 的置信区间的置信度;加粗数值为最优值。

### 3.5 超参数分析

在原型校准模块中,为了减少误分类查询集样本的干扰, 本文只选取与类原型欧氏距离最近的前  $k$  个查询集样本, 将其加入到支持集中参与原型校准。在元测试时, 一个 epoch 包括 4 个元任务, 每个元任务在测试集中随机抽取 5 个类, 每个类随机抽取 15 个样本组成查询集, 那么在一个元任务中, 对每个类原型校准可用的查询集样本共有 75 个。为了分析  $k$  值对实验结果的影响, 本文在 mini-ImageNet 和 tiered-ImageNet 数据集上进行实验, 在 5-way 1-shot 和 5-way 5-shot 设置下, 图 7(a) 为在 mini-ImageNet 上的实验结果, 图 7(b) 为在 tiered-ImageNet 上的实验结果。从图中可以看出, 两个数据集上的曲线非常相似, 随着  $k$  值的不断增加, 模型性能不断提升。当  $k$  增加至 15 时, 1-shot 分类性能达到最大值, 当  $k$  增加至 20 时, 5-shot 分类性能达到最大值。然后, 随着  $k$  的不断增大, 性能缓慢降低。因此, 在实验中, 对于两个数据集的 1-shot 和 5-shot 设置,  $k$  值分别设置为 15 和 20, 可以获得最佳的分类性能。

(a) mini-ImageNet 上  $k$  值变化结果(b) tiered-ImageNet 上  $k$  值变化结果图 7  $k$  值变化结果Fig. 7 Impact of  $k$  on experimnt results

### 3.6 复杂度分析

本文实验还对基线模型和文中所提模型的复杂度进行了分析, 在 mini-ImageNet 数据集上进行了 5-way 1-shot 实验, 并且对比了模型的参数总量、分类准确率和运行一个元任务所需要的时间, 如表 7 所列。由于本文在 SCB-Net 网络中引入了 CBAM 模块和 RCBAM 模块, 参数量比基线模型 Meta-Baseline 增加了  $0.1 \times 10^6$ , 运行一个元任务所需时间仅增加了 0.019 s, 在性能上却有 6.44% 的显著提升。由此可见, 本文模型在增加少量参数和时间复杂度的基础上, 可以获得较大的性能提升。

表 7 模型复杂度分析

Table 7 Analysis of model complexity

Algorithm	Backbone	Parameter total	Accuracy/%	Time/s
Meta-Baseline <sup>[17]</sup>	ResNet-12	$8.0 \times 10^6$	63.17±0.23	0.033
Our Method	SCB-Net	$8.1 \times 10^6$	69.61±0.30	0.052

### 3.7 可视化实验

本文提出的 SCB-Net 网络结合了反向和正向卷积块注意力模块, 能够对图像中的关键信息进行重点关注。为了验证其有效性, 将其与使用基线模型 Meta-Baseline 训练的 ResNet-12 网络进行对比。在 mini-ImageNet 和 tiered-ImageNet 两个数据集中分别随机抽取 4 张实验图像, 使用 Grad-CAM<sup>[33]</sup> 对两个特征提取网络所关注的区域分别进行可视化, 如图 8 所示, 所得到的类激活图中颜色越红表明关注度越高。分析图 8 可以看出, 本文提出的 SCB-Net 网络所关注的区域更加集中并且准确覆盖了目标物体, 对于背景区域的关注较少。即使图像中的目标物体很小而且环境很复杂, 本文所提出的网络也能够准确地关注到目标物体所在区域。由此可见, 本文所提出的 SCB-Net 网络可以提取到更具有代表性的特征, 提高模型的泛化性能。

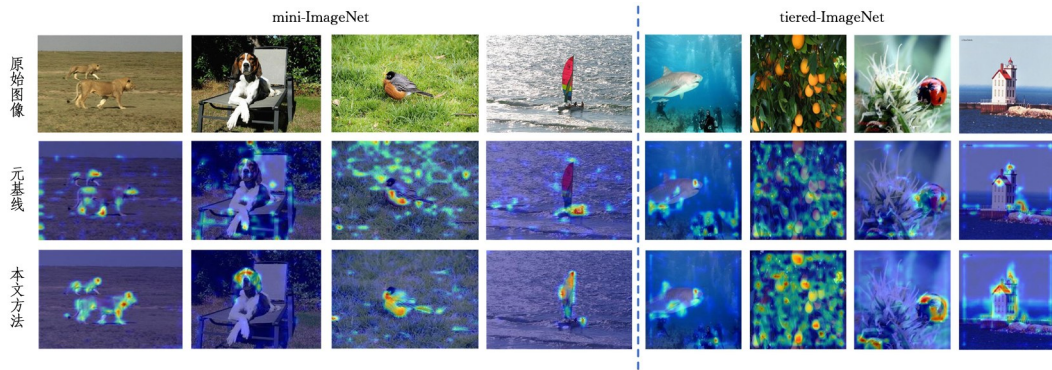



图8 特征可视化图(电子版为彩图)

Fig.8 Feature visualization diagram

最后,为了验证本文所提出的 IELP-PC 算法的有效性,分别在 mini-ImageNet 数据集和 tiered-ImageNet 数据集上的 5-way 5-shot 设置下随机抽取一个元任务,然后使用 t-SNE 将这个元任务中不同类的样本特征和原型降至 2 维,对其原型校准结果进行可视化展示。如图 9 所示,图中不同颜色的样本点表示不同的类。在同一个类中,‘★’表示真实的类原型,‘▲’表示原始的类原型,‘◆’表示校准后的类原型,‘×’表示支持集样本,‘●’表示查询集样本。图 9(a)和 9(b)分别为这两个数据集上的一个元任务的原型校准可视化图,从图中可以看出,经过校准后的类原型相比原始类原型距离真实的类原型更加接近,这证明了本文提出的 IELP-PC 算法能够得到更加准确的类原型,从而提高了整个模型的性能。



(a) mini-ImageNet 上原型校准可视化图

(b) tiered-ImageNet 上原型校准可视化图

图9 原型与特征的 t-SNE 可视化结果

Fig.9 t-SNE visualization results of prototypes and features

**结束语** 小样本学习对于解决数据缺乏以及标记成本昂贵的问题具有极其重要的意义。原型网络是解决小样本问题常用的一种方法,其难点在于如何提高模型的泛化能力和得到准确的类原型。针对基于原型网络的小样本学习模型泛化能力差以及原型与真实原型偏差较大的问题,本文提出了一种基于对称卷积块网络和原型校准的小样本学习方法。该方法首先使用对称卷积块网络 SCB-Net 获取更具有代表性的图像特征,其次采用反欧氏标签传播原型校准算法 IELP-PC 得到更加准确的类原型,提高了模型的性能。在两个常用数据集 mini-ImageNet 和 tiered-ImageNet 上进行了大量实验,结果验证了本文方法的有效性和可行性。

本文方法虽然在一定程度上提高了小样本学习的性能,但是引入的查询样本数量有限,性能的提升空间也比较有限。下一步的工作重点是加入基类数据改进原型校准算法,在

基类图像中选取与新类原型高度相似的局部特征对原型进行进一步校准。

## 参考文献

- [1] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Communications of the ACM, 2017, 60(6): 84-90.
- [2] YANG Y, XU Z. Rethinking the value of labels for improving class-imbalanced learning [J]. Advances in neural information processing systems, 2020, 33: 19290-19301.
- [3] GE Y Z, LIU H, WANG Y, et al. Survey on deep learning image recognition in dilemma of small samples [J]. Journal of Software, 2021, 33(1): 193-210.
- [4] ANKOWSKI N, DUCH W, GRA, BCZEWSKI K. Meta-Learning in Computational Intelligence [M]. Berlin, Heidelberg: Springer, 2011: 97-115.
- [5] LI F F, FERGUS R, PERONA P. One-shot learning of object categories [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(4): 594-611.
- [6] WANG Y Q, YAO Q M, KWOK J T, et al. Generalizing from a few examples: A survey on few-shot learning [J]. ACM Computing Surveys, 2020, 53(3): 1-34.
- [7] LI X X, LIU Z Y, WU J J, et al. Total relation network with attention for few-shot image classification [J]. Chinese Journal of Computers, 2023, 46(2): 371-384.
- [8] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C] // International Conference on Machine Learning. PMLR, 2017: 1126-1135.
- [9] HE Y, ZANG C, ZENG P, et al. Convolutional shrinkage neural networks based model-agnostic meta-learning for few-shot learning [J]. Neural Processing Letters, 2023, 55(1): 505-518.
- [10] KIM J, KIM T, KIM S, et al. Edge-labeling graph neural network for few-shot learning [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11-20.
- [11] YU T, HE S, SONG Y Z, et al. Hybrid graph neural networks for few-shot learning [C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2022: 3179-3187.
- [12] AN S B, GUO Y Q, BAI Y, et al. Survey of few-shot image clas-

- sification research [J]. *Journal of Frontiers of Computer Science and Technology*, 2023, 17(3): 511-532.
- [13] ANTONELLI S, AVOLA D, CINQUE L, et al. Few-shot object detection: A survey [J]. *ACM Computing Surveys*, 2022, 54(11s): 1-37.
- [14] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition [C] // *ICML Deep Learning Workshop*, 2015.
- [15] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching networks for one shot learning [C] // *Proceedings of the 30th International Conference on Neural Information Processing Systems*, 2016: 3637-3645.
- [16] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning [C] // *Advances in Neural Information Processing Systems*, 2017: 4077-4087.
- [17] CHEN Y, LIU Z, XU H, et al. Meta-baseline: Exploring simple meta-learning for few-shot learning [C] // *Proceedings of the IEEE/CVF international conference on computer vision*, 2021: 9062-9071.
- [18] XIN S, LIU H. Few-shot Classification based on CBAM and prototype network [C] // *2022 4th International Conference on Data-driven Optimization of Complex Systems (DOCS)*. IEEE, 2022: 1-6.
- [19] LIU Y, ZHANG H, YANG Y. Few-Shot Image Classification Based on Asymmetric Convolution and Attention Mechanism [C] // *2022 4th International Conference on Natural Language Processing (ICNLP)*. IEEE, 2022: 217-222.
- [20] CHEN Z, LIN H, QIANG Z, et al. Image Classification with Frequency Channel Attention under the Few-Shot Condition [C] // *2022 IEEE 8th International Conference on Computer and Communications (ICCC)*. IEEE, 2022: 1958-1963.
- [21] SONG J, ZHU Z, LI B, et al. Few-shot Learning based on Multi-Attention and Prototype Correction [C] // *2022 8th International Symposium on System Security, Safety, and Reliability (ISSSR)*. IEEE, 2022: 83-84.
- [22] LIU D, BAI L, YU T, et al. Learning a Good Representation for Metric-based Few-shot Classification [C] // *2023 15th International Conference on Computer Research and Development (ICCRD)*. IEEE, 2023: 187-192.
- [23] LIU J, SONG L, QIN Y. Prototype rectification for few-shot learning [C] // *Computer Vision-ECCV 2020: 16th European Conference*. Springer International Publishing, 2020: 741-756.
- [24] YANG S, LIU L, XU M. Free lunch for few-shot learning: Distribution calibration [J]. *arXiv:2101.06395*, 2021.
- [25] HUANG Y W, HU Y F, WEI G Q. Prototype-based calibration distribution for few-shot learning [J]. *Electronic Measurement Technology*, 2022, 45(5): 132-139.
- [26] RUSU A A, RAO D, SYGNOWSKI J, et al. Meta-learning with latent embedding optimization [J]. *arXiv:1807.05960*, 2018.
- [27] LIU Y, SCHIELE B, SUN Q. An ensemble of epoch-wise empirical bayes for few-shot learning [C] // *Computer Vision-ECCV 2020: 16th European Conference*. Springer International Publishing, 2020: 404-421.
- [28] ORESHKIN B, RODRÍGUEZ LÓPEZ P, LACOSTE A. Tadam: Task dependent adaptive metric for improved few-shot learning [J]. *Advances in Neural Information Processing Systems*, 2018, 31: 719-729.
- [29] LI H, EIGEN D, DODGE S, et al. Finding task-relevant features for few-shot learning by category traversal [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019: 1-10.
- [30] LIU Y, LEE J, PARK M, et al. Learning to propagate labels: Transductive propagation network for few-shot learning [J]. *arXiv:1805.10002*, 2018.
- [31] HOU R, CHANG H, MA B, et al. Cross attention network for few-shot classification [J]. *Advances in Neural Information Processing Systems*, 2019, 32: 4003-4014.
- [32] LV J, ZENG M Y, DONG B S. Prototype rectification few-shot classification model with dual-path co-operation [J]. *Journal of Frontiers of Computer Science and Technology*, 2024, 18(3): 693-706.
- [33] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: Visual explanations from deep networks via gradient-based localization [C] // *Proceedings of the IEEE International Conference on Computer Vision*, 2017: 618-626.



**LIU Shuai**, born in 1996, postgraduate, is a student member of CCF (No. P2838G). His main research interests include machine learning and few-shot learning.



**BAI Xuefei**, born in 1980, Ph.D, associate professor, is a member of CCF (No. 22413M). Her main research interests include image processing and machine learning.

(责任编辑:何杨)