

DOI:10.19651/j.cnki.emt.2108417

# 结合原型校准分布的小样本学习方法<sup>\*</sup>

黄友文 胡燕芳 魏国庆  
(江西理工大学信息工程学院 赣州 341000)

**摘要:**针对小样本学习中样本数量过少难以表述类别特征的问题,提出一种结合原型校准数据分布的小样本学习方法。首先,利用嵌入网络对图像进行预处理,将提取到的新类特征进行幂次变换。随后,通过相似度加权基类来表征新类样本的原型,充分利用已学过的基类知识来减小计算原型与实际原型的偏差。最后,以新类样本特征与其对应的原型构造均匀分布,根据样本数量改变均匀分布边界,使采样集中在置信度高的区域,生成大量的新类特征扩充训练分类器的支持集。在5-way 1-shot和5-way 5-shot设置中,该方法在miniImageNet数据集上的准确率分别为68.94%和84.75%,在CUB数据集上分别为81.75%和91.88%,均优于现有方法的最好结果。因此,所提方法能有效提高模型在小样本图像上的分类性能,获得更高的预测准确率。

**关键词:**小样本学习;图像分类;原型表征;均匀分布;数据生成

中图分类号:TP391.4 文献标识码:A 国家标准学科分类代码:510.4050

## Prototype-based calibration distribution for few-shot learning

Huang Youwen Hu Yanfang Wei Guoqing  
(School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China)

**Abstract:** Aiming at the problem that the number of samples in few-shot learning is too small to represent the characteristics of data categories, a few-shot learning method combining prototype calibration data distribution is proposed. First, the embedded network is used to preprocess the image to obtain new class features, and the extracted new class features are processed by power transformation. Then, the prototype of the new sample is characterized by the weighting of the similarity of the base class, and the learned knowledge of the base class is fully utilized to reduce the deviation between the calculated prototype and the actual prototype. Finally, we sample from the uniform distribution between the features of the new class instance and its prototype representation. It generates a large amount of feature data to expand the support set of the new class. At the same time, we propose a method to change the boundary of the uniform distribution according to the number of samples. As a result, the samples are concentrated in areas with high confidence. The accuracy of 5-way 1-shot and 5-way 5-shot of our method are 68.94% and 84.75% on the miniImageNet dataset, respectively, and the accuracy on the CUB dataset are 81.75% and 91.88%, respectively, which are better than the best results of existing methods. The experimental results show that our method can effectively improve the model's prediction accuracy in few-shot classification.

**Keywords:** few-shot learning; image classification; prototype characterization; uniform distribution; data generation

## 0 引言

深度学习在图像分类<sup>[1]</sup>、目标检测<sup>[2]</sup>、自然语言处理<sup>[3]</sup>等机器视觉任务中有着广泛的应用。这些方法通常使用大量带标记的数据集合进行训练,以达到模型的最佳性能。然而,在许多现实应用中,获取数据或注释数据的成本很高,无法创建庞大的训练数据集合。当数据量过少时,模型

往往会过度拟合于训练样本,而在新的类别上泛化性能下降。近年来,为减少深度网络对样本数据的依赖性,从少量训练样本中学习即小样本学习受到越来越多的关注。

与传统的机器学习不同,小样本学习的目标是模型从一组带丰富标记的基类别(base class)中学习,以适应一组只有少量标记数据的新类别(new class)。小样本学习方法可以分为3类:基于优化的方法、基于度量的方法和基于生

收稿日期:2021-11-22

\*基金项目:江西省教育厅科技项目(GJJ180443)资助

成的方法。基于优化的方法侧重于通过梯度下降快速调整模型参数来适应新任务。例如,未知模型元算法(model-agnostic meta-learning, MAML)<sup>[4]</sup>旨在学习参数的最优初始化,使模型面对不同任务时易于微调以适应新任务。元迁移学习算法(meta-transfer learning, MTL)<sup>[5]</sup>使用深度预训练网络进行迁移学习,重新训练少量参数,模型可以在不损失泛化特性的前提下迁移到新任务上。文献[6]在元迁移学习算法的基础上将训练过程中不同阶段的模型进行集成,以联合预测的方式提升结果的稳健性。基于度量学习的方法通过学习某种度量方式,以指示度量空间中样本的相似关系。例如,匹配网络(matching network)<sup>[7]</sup>通过学习一个距离度量来构建样本对之间的关系,根据得到的关系分数对未标记样本进行分类。原型网络(prototypical network)<sup>[8]</sup>将每类样本的平均特征视为该类原型,计算输入样本与类原型之间的欧氏距离并将样本点归类为最近的原型类别。文献[9]提出了基于余弦相似度的原型校正网络,从减小类内偏差和跨类偏差两方面对新类原型进行校正。基于生成的方法旨在增加训练样本数量,是一种传统的方法。例如,文献[10]利用数据增强的思想,通过改变图像姿态、光照和位置等信息来生成不同变化的新样本图像,实现训练数据的扩充。文献[11]将源类的数据特征变化迁移到新类中,通过共享不同类别的变化因素来丰富新类的特征。分布校准算法(distribution calibration, DC)<sup>[12]</sup>使用基类的统计数据对新类的特征分布进行校准,然后从新类分布中抽取足够数量的样本扩充训练数据。

最近的研究中,文献[13]表明特征空间具有更低的维度,在样本特征上进行处理可以减少偏差的引入。随后,文献[14]在长尾数据分类中假定每个类别的特征相互独立且服从高斯分布,并利用头部数据中的类内方差来丰富尾部数据的特征表示。在文献[12]的研究中,同样假定数据服从高斯分布,利用两项相似基类特征的均值和方差对新类的特征分布进行校准。文献[15]中假定变换后的类特征服从高斯分布,采用最大后验估计法加权特征均值对新类原型进行迭代更新。可以发现,一方面,目前小样本原型研究中,主要选择已学过类别中的少量类别对新类数据特征进行调整,忽略了其余类别中有用的信息。另一方面,在小样本数据分布研究中,主要将相同类别的特征分布假定为高斯分布,针对其他分布类型对结果影响的研究较少。并且存在高斯分布方差计算量较大,运行时间较长的问题,同时不同数据集的方差还需要通过超参数进行调节。

针对以上算法中数据分布类型的问题,本文采用不同分布对新类的数据分布进行校准研究,通过比较发现,采用均匀分布可以获得更好的分类效果。进而在分布校准算法的基础上,提出一种结合原型校准分布的小样本学习方法。本文的主要贡献包括:1)与现有的小样本原型研究相比,所提方法能充分利用所有基类中的信息,通过相似度加权获取更加准确的新类原型表征。2)提出了一种新的数据校准

方法,利用新类样本和其原型构造均匀分布,并根据支持集样本数量改变均匀分布边界,从置信度高的区域中采样生成特征用于分类器的训练。3)所提模型在没有引入方差和学习参数的情况下,计算量极大减少,学习时间更短,在少量样本上的预测更加准确。

## 1 基于原型扩充的小样本学习

### 1.1 问题定义

在小样本学习中,数据可分为基类数据  $C_b$  和新类数据  $C_n$ ,基类与新类的类别不相交,关键挑战是通过基类数据训练模型后,模型能较好地适应只有少量带标签样本的新类数据。小样本学习通常采用元任务的方式进行训练和评估,构建元任务的最常见范式为 N-way K-shot 任务,即从新类中采样  $N$  个类别,每个类别抽取  $K$  个带标签图像作为训练样本,再从每类剩下的图像中抽取  $q$  个样本作为预测图像。少量带标签的数据集合称为支持集(support set),无标签的预测数据集合称为查询集(query set),模型在支持集上进行元训练适应当前任务,在查询集上进行元测试评估模型在当前任务上的适应能力和泛化能力。对于每个元任务  $T_i$ ,支持集  $S$  和查询集  $Q$  的定义如下所示:

$$S = \{(x_i, y_i)\}_{i=1}^{N \times K} \quad (1)$$

$$Q = \{(x_i, y_i)\}_{i=1}^{N \times q} \quad (2)$$

式中:  $x_i$  为数据的特征向量,  $y_i$  为数据的类别属性,  $N$  为每个任务中样本类别数量,  $K$  为支持集中每个类别的带标签图像数量,  $q$  为查询集中每个类别的无标签图像数量。模型通过从新类中采样多个任务的平均预测准确率,来评估小样本模型的分类性能。

### 1.2 算法框架

算法框架如图 1 所示,该算法主要由以下部分组成。首先,通过嵌入网络提取输入图像的特征向量,以元任务形式从新类中采样支持集和查询集并将特征进行幂次变换。其次,在新类的原型表征中,为了减小原型计算中引入的偏差,使用所有基类进行相似度加权来表示新类支持集样本的原型,图中椭圆表示不同类别的基类,五角星表示新类样本对应的原型。随后,以支持集样本特征与其原型表征构造均匀分布校准新类数据,并根据样本数量改变均匀分布的边界,从置信度高的分布区间中采样生成大量特征数据来扩充新类支持集,图中的小圆形表示生成的特征数据。最后,使用扩充后的支持集训练分类器,对新类查询集样本进行标签预测。

### 1.3 特征处理

随着卷积网络宽度和深度的增加,网络对图像信息的提取能更加充分。本文使用宽残差网络(WideResNet)对样本进行特征提取,WRN-28-10 是 28 层、宽因子为 10 的宽残差网络。在特征提取阶段,使用基类样本进行预训练,移除网络最后的 Softmax 层得到输入样本的特征提取器。获取基类和新类样本的特征如下所示:

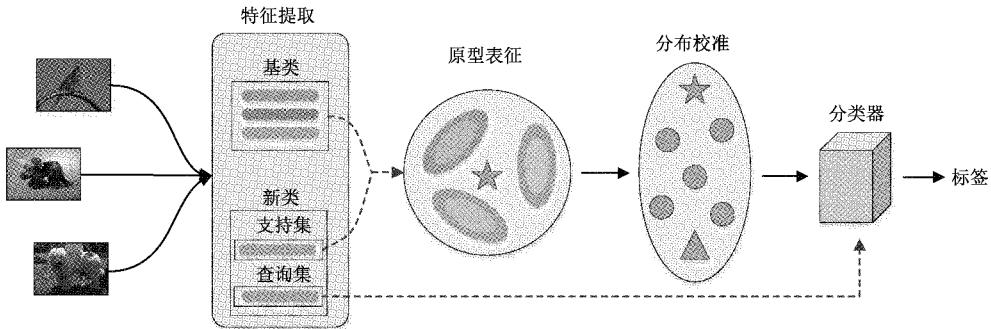


图1 小样本学习算法整体框架

$$x_b = f(\text{base}) \quad x_n = f(\text{new}) \quad (3)$$

式中:  $f(\cdot)$  表示为去除全连接层的特征提取器,  $\text{base}$  和  $\text{new}$  分别表示输入的基类和新类样本,  $x_b$  和  $x_n$  分别表示提取到的基类和新类特征。文献[15]在特征处理上的研究表明, 对特征向量进行幂次变换, 可以使特征更好的符合分布假设。受此启发, 所提模型在新类中抽取元任务后, 将任务中支持集和查询集的样本特征进行幂次变换。使用幂次变换的公式如下:

$$\tilde{x}_s = x_s^\lambda \quad \tilde{x}_q = x_q^\lambda \quad (4)$$

式中:  $x_s$  和  $x_q$  分别表示变换前支持集和查询集样本的特征,  $\tilde{x}_s$  和  $\tilde{x}_q$  分别表示变换后的支持集和查询集特征,  $\lambda$  是一个超参数。当  $\lambda$  设置为 1 时, 可以恢复原始特征。

#### 1.4 原型表征

在小样本学习中, 可以通过简单地平均样本特征来获得图像类别的基本原型。然而在数量过少的情况下, 计算的新类原型与实际原型会存在较大偏差。为了减小这种偏差, 文献[12]中利用最接近新类的前  $n$  项基类中的均值和方差来校准新类, 但这种方式也只将基类中相似类别特征进行简单平均, 忽略了相似程度的影响以及后续基类中的相似信息。文献[9]中利用查询集中样本进行反余弦距离加权来校正新类原型, 但查询集样本是模型未学习过且无标签的, 模型已学习过的基类信息没有得到合理利用。

为进一步减小新类原型与实际原型之间的偏差, 本文提出一种反欧氏距离加权的原型表征方法, 充分利用了所有已学过的基类信息, 来表征新类支持集中样本的原型。新类的原型表征如图 2 所示,  $u_i$  表示基类中不同类别的原型,  $p$  是新类支持集样本的原型表征,  $w_i$  表示不同基类与支持集样本的相似程度。

首先, 基类样本数量较为充足且相同类别内样本差异较小, 基类原型可以通过类别样本特征平均来计算。即基类中每个类别的原型用该类中所有样本的平均特征来表示, 基类原型如下:

$$u_i = \frac{\sum_{j=1}^{n_i} x_{ij}}{n_i} \quad (5)$$

式中:  $x_{ij}$  是基类中第  $i$  类的第  $j$  个样本的特征向量,  $n_i$  是

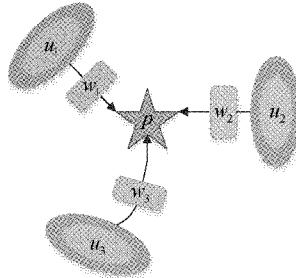


图2 原型表征过程

第  $i$  个类别中样本的总数。

随后, 利用与新类样本相似的基类对新类进行原型表征, 与支持集样本距离较小的基类在原型表征中将占有较大权重比例。具体而言, 采用欧氏距离对新类支持集样本与基类原型进行相似性度量, 再将相似度进行归一化得到权重系数, 相似度  $m_i$  和权重系数  $w_i$  分别如下:

$$m_i = \frac{1}{(u_i - \tilde{x})^2} \quad (6)$$

$$w_i = \frac{m_i}{\sum_{i=1}^n m_i} \quad (7)$$

式中:  $\tilde{x}$  为支持集样本的特征向量,  $u_i$  为基类中第  $i$  类样本的原型,  $m_i$  表示第  $i$  个基类的相似度,  $w_i$  表示第  $i$  个基类的权重系数,  $n$  为基类的总类别数量。

最后, 通过加权所有基类原型来表示新类支持集中的样本原型, 如下所示:

$$p = \sum_{i=1}^n w_i \cdot u_i \quad (8)$$

式中:  $u_i$  表示基类中第  $i$  类的原型,  $w_i$  表示基类原型与新类支持集样本之间的相似度权重系数。新类的原型表征中包含了基类中所有的类型, 模型在基类中学过的知识得到了充分利用, 同时通过相似度加权后的原型表征  $p_k$  更接近新类的实际原型, 原型表征更加可靠。

#### 1.5 分布校准

在小样本学习中, 从新类中采样的评估任务只有少量带标签的样本, 难以正确的描述新类的数据分布特点。不同于常见的假定类别特征为高斯分布对新类特征进行校

准如文献[12,14-15],本文提出以新类样本与其原型表征的偏差构造均匀分布,并从中采样生成特征增加新类中可供分类器训练的样本数量。

新类样本在分布校准前后的分布情况如图 3 所示。校准前如图 3(a)所示,三角形表示新类支持集中不同类别的 3 个样本,由于单个样本易偏离类别中心,导致分类器不能正确划分类别。校准后如图 3(b)所示,五角星表示样本的原型表征,以新类样本特征(三角形)和其原型表征(五角星)构造均匀分布,圆形表示从分布中采样生成的新类样本特征,大量训练数据增强了模型对新类的辨别力。

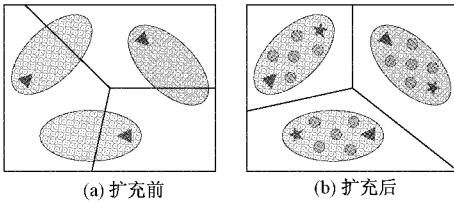


图 3 分布校准示意图

均匀分布边界的选取如图 4 所示,边界有 3 种选择:样本特征、原型表征、样本特征与其原型表征的平均值(虚线)。确定均匀分布的两个边界时,图中样本 1 分别采用原型表征和虚线所示的特征均值,图中样本 2 分别采用样本特征和原型表征,图中样本 3 分别采用样本特征和虚线所示的特征均值。当每个新类别只有单个样本时,生成数据中心易偏离类别原型,采用图中样本 1 确立的均匀分布边界可以使生成数据中心更接近类别原型,避免由单个样本造成的偏差。当每个类别有多个样本时,每个样本特征均采用图中样本 3 确立的均匀分布边界,可以使采样偏向于实际样本,提高采样数据的可靠性,同时多个样本构建的生成数据中心仍然可以不偏离实际原型。因此,根据小样本任务中支持集样本数量的不同,改变均匀分布的边界,可以使得采样集中在可信度较高的区域。

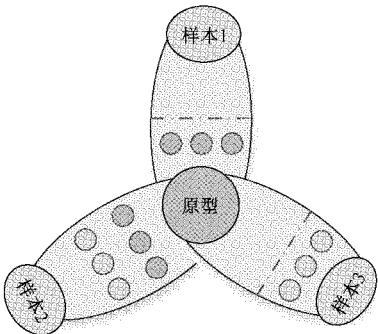


图 4 分布边界选择

为了便于描述,以新类支持集中的一个样本原型对为例构造均匀分布,从分布中采样生成一组带有标签的特征向量,如下所示:

$$D = \{(x', y) \mid x' \sim U(a, b)\} \quad (9)$$

式中:  $x'$  表示生成的特征样本,  $y$  表示生成样本的类别属

性,  $U$  表示均匀分布,  $a$  和  $b$  分别表示均匀分布的两个边界。其中,每个类别生成的特征样本数量设置为超参数。随后,将生成的特征样本加入支持集中,扩充后的支持集  $S_{new}$  如下:

$$S_{new} = S \cup \{D_i\}_{i=1}^{N \times K} \quad (10)$$

式中:  $S$  表示扩充前的新类支持集,  $D_i$  表示支持集中第  $i$  个图像对应校准分布的生成数据集合,  $N$  和  $K$  分别为一个 N-way K-shot 任务的  $N$  值和  $K$  值, 即一个元任务中的支持集图像数量。最后, 使用扩充后的支持集对分类器进行训练, 通过最小化新类支持集的交叉熵损失来训练分类器, 如下所示:

$$\phi = \operatorname{argmin}_{\phi} \sum_{t=1}^T L_t^{ce}(S_{new}; \phi) \quad (11)$$

式中:  $S_{new}$  表示扩充后的新类支持集,  $L_t^{ce}$  表示第  $t$  个元任务的交叉熵损失, 分类器模型由  $\phi$  表示。利用新类样本和其原型构造均匀分布, 同时根据支持集样本数量改变均匀分布边界, 采样置信度高的特征扩充新类支持集, 模型对新类的辨别能力增强, 且学习过程中避免了数据的方差计算, 模型学习时间更短。

## 2 实验及结果分析

### 2.1 数据集和实验环境

实验采用 miniImageNet 和 CUB 两个小样本标准公用数据集对模型的性能进行验证。

miniImageNet 数据集是一个从 ImageNet 数据集抽取的子集, 广泛用于小样本学习的研究。数据集中包括各种对象, 共有 100 个不同的类别, 每个类有 600 个样本图像, 图像大小为  $84 \times 84 \times 3$ 。数据集分为 64 个基类、16 个验证类和 20 个新类。

CUB 是一个更细粒度的数据集, 不同粒度级别的数据集的特征空间可能具有不同的分布, 在 CUB 数据集上进行验证更便于展示方法的有效性和通用性。作为一个细粒度的小样本分类标准数据集, CUB 包含 200 种不同类别的鸟类, 共有 11 788 幅大小为  $84 \times 84 \times 3$  的图像。数据集分为 100 个基类、50 个验证类和 50 个新类。

实验平台的配置为 Intel Xeon 3014 处理器, 16 GB 内存、GTX2080Ti 显卡, 并使用 64 位操作系统 Ubuntu18.04 和 Pytorch 深度学习框架。

### 2.2 实验设置

实验在 miniImageNet 和 CUB 数据集上采用 5-way 1-shot 和 5-way 5-shot 设置测试模型的准确性。展示的结果是 600 项元任务的平均分类精度。

对于特征提取器, 采用 WideResNet 作为主干网络, 采用 Mangla 等<sup>[16]</sup>提出的特征提取方法对网络进行预训练。对于每个数据集, 使用基类训练特征提取器, 使用新类测试模型性能。其中, 为确保幂次变换输入有效, 特征提取器的倒数第 2 层使用 ReLU 激活函数进行提取, 保证特征值都是非负的。

在使用扩充后的新类支持集训练分类器时,分类器使用 sk-learn 库中的逻辑回归分类器(logistic regression, LR)和支持向量机(support vector machine, SVM)的默认设置实现。在所有数据集中使用相同的超参数值,每个类别生成的特征数量  $n$  取 40,幂次变换的指数  $\lambda$  取 0.7。

### 2.3 实验结果

#### 1) 实验结果对比分析

表 1 在 miniImageNet 和 CUB 数据集上的小样本分类精度

小样本学习方法	miniImageNet		CUB	
	1-shot	5-shot	1-shot	5-shot
基于度量	ProtoNet <sup>[8]</sup>	49.42±0.78	68.20±0.66	72.99±0.88
	Negative-Cosine <sup>[17]</sup>	62.33±0.82	80.94±0.59	72.66±0.85
	Centroid Alignment <sup>[18]</sup>	59.88±0.67	80.35±0.73	74.22±1.09
基于优化	MAML <sup>[4]</sup>	48.70±1.84	63.11±0.92	50.45±0.97
	MTL <sup>[5]</sup>	61.20±1.80	75.50±0.80	—
	E3BM <sup>[6]</sup>	63.80±0.40	80.3±0.10	—
	PT+MAP <sup>[15]</sup>	65.35±0.20	83.87±0.13	80.57±0.20
基于生成	Delta-Encoder <sup>[19]</sup>	59.9±n/a	69.7±n/a	69.8±n/a
	TriNet <sup>[20]</sup>	58.12±1.37	76.92±0.69	69.61±0.46
	MVT <sup>[11]</sup>	—	67.67±0.70	—
	DC <sup>[12]</sup>	68.57±0.55	82.88±0.42	79.56±0.87
本文方法(SVM)	本文方法(SVM)	68.68±0.34	84.09±0.42	81.53±0.32
	本文方法(LR)	68.94±0.42	84.75±0.36	81.75±0.43

从表 1 中可以看出,与基于优化、基于度量和基于生成的 3 类小样本学习方法相比,所提方法均取得了最好的分类结果。在 miniImageNet 数据集上,5-way 1-shot 设置下,所提模型分类准确率分别达到了 68.94%,比次优方法 DC<sup>[12]</sup> 分别提高了 0.37%,在 5-way 5-shot 设置下分类精度为 84.75%,比次优方法 PT + MAP<sup>[15]</sup> 分别提高了 0.88%。在 CUB 数据集上,5-way 1-shot 和 5-way 5-shot 设置下,所提模型分类准确率分别达到了 81.75% 和 91.88%,比次优方法 PT + MAP<sup>[15]</sup> 分别提高了 1.18% 和 0.73%。与采用高斯分布对新类进行分布校准的算法 DC<sup>[12]</sup> 和原型更新的算法 PT + MAP<sup>[15]</sup> 相比,本文提出的算法更能充分利用所有基类的特征信息,对新类的原型表征更加丰富和准确,从置信度高的均匀分布区域中采样生成特征数据,分类结果更加准确。验证了所提模型可以更好地处理数据量少的小样本分类任务。

#### 2) 学习时间对比分析

在前述的实验平台下对不同模型的学习时间进行对比分析,在两个数据集上,分别进行 5-way 1-shot 和 5-way 5-shot 实验,并展示模型一个元任务所需要的学习时间(s),实验结果如表 2 所示。

从表 2 中可以发现,算法 DC<sup>[12]</sup> 假定新类数据为高斯分布进行校准,由于方差计算量较大,模型学习时间较长,

所提方法和目前先进的小样本学习方法在两个数据集上的实验结果如表 1 所示。为更好地对模型性能进行评估,实验对比指标为随机抽取 600 项元任务的平均分类准确率,每项实验重复运行 5 次,其取高低值分别为 5 次运行结果中的最高和最低分类精度。本文选用了两种主流且简单的分类器,即 SVM 和 LR 分类器来证明所提方法的有效性。

表 2 不同模型的学习时间

模型	miniImageNet		CUB	
	1-shot	5-shot	1-shot	5-shot
DC <sup>[12]</sup>	5.83	20.62	5.12	18.64
本文方法	0.16	0.27	0.14	0.25

而本文提出的算法没有引入方差计算,极大减少了计算量,学习时间更短。

#### 3) 度量方式选择

为了分析原型表征中不同度量方式对所提方法产生的影响,在两个数据集上分别使用 5-way 1-shot 和 5-way 5-shot 设置进行实验。主要研究如下 4 种度量距离:余弦距离、切比雪夫距离、曼哈顿距离、欧氏距离,实验结果如表 3 所示。

表 3 不同度量的精度

度量方式	miniImageNet		CUB	
	1-shot	5-shot	1-shot	5-shot
余弦距离	68.25	84.73	80.97	91.86
切比雪夫距离	68.81	84.32	81.77	91.88
曼哈顿距离	68.84	84.73	81.66	91.87
欧氏距离	68.94	84.75	81.75	91.88

从表 3 中可以看出,4 种度量距离对于模型的分类精度有不同的影响。可以发现,在 1-shot 上的分类效果比 5-shot 上的效果差异更大,表明随着元任务中支持集数据量的增加,度量方式对原型表征的影响越小,即 5-shot 上结果差距较小。使用余弦距离作为基类与新类的相似度量,实验效果较差。切比雪夫距离和曼哈顿距离相较于余弦距离,分类准确率都有较大提升。在 CUB 数据集上使用欧氏距离进行度量,与切比雪夫距离性能相当,达到了最佳。在 miniImageNet 数据集上使用欧氏距离分类准确率也达到了最高值,表明使用欧氏距离对新类进行原型表征对提高模型的分类精度效果最好。

#### 4) 分布类型选择

在校准分布模块中,研究使用不同分布类型校准新类数据对实验结果的影响。在获得新类的原型表征后,分别使用卡方分布、泊松分布、指数分布和均匀分布对新类数据分布进行校准。在两个数据集上,分别进行 5-way 1-shot 和 5-way 5-shot 实验,实验结果如表 4 所示。

表 4 不同分布的精度

分布类型	miniImageNet		CUB	
	1-shot	5-shot	1-shot	5-shot
卡方分布	61.06	80.20	79.85	90.70
泊松分布	62.22	80.78	80.41	90.01
指数分布	68.11	84.15	81.43	91.74
均匀分布	68.94	84.75	81.75	91.88

从表 4 中可以看出,模型使用均匀分布对数据进行扩充的分类性能最佳。在两个数据集中,模型采用卡方分布和泊松分布的效果均较差。采用指数分布时,特征经过指数变换之后,可以增加不同类别之间的特征区分度,模型的分类准确率有较大提升。当使用均匀分布时,模型对新类样本和原型表征信息都有捕捉,采样生成的数据更接近新类的真实类别,更加有助于提升模型对新类的预测能力,使得分类精度达到最高值。

#### 5) 分布边界选择

在分布校准中,研究选取均匀分布边界对实验结果的影响。在两个数据集上分别进行 5-way 1-shot 和 5-way 5-shot 实验,主要研究 1.5 节中介绍的 3 种方式。(1)将均匀分布的两个边界分别设置为:支持集样本特征与其原型表征的平均值、原型表征,生成样本的采样区域靠近新类样本的原型表征;(2)将均匀分布的两个边界分别设置为:支持集样本特征、其原型表征;(3)将均匀分布的两个边界分别设置为:支持集样本特征、样本特征与其原型表征的平均值,生成样本的采样区域靠近新类样本的特征,实验结果如表 5 所示。

从表 5 中可以发现,3 种分布边界均比现有方法实现了更好的性能。在 5-way 1-shot 的设置下,即每个任务的

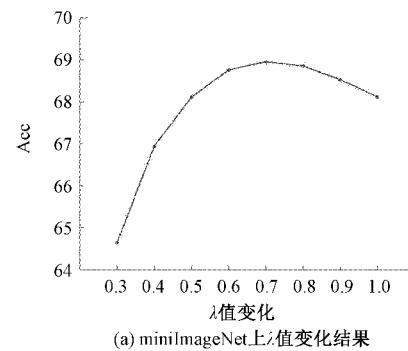
表 5 不同分布边界的精度

边界 a	边界 b	miniImageNet		CUB	
		1-shot	5-shot	1-shot	5-shot
原型表征	二者均值	68.94	84.36	81.75	91.67
样本特征	原型表征	68.50	84.66	81.66	91.81
样本特征	二者均值	67.51	84.75	81.56	91.88

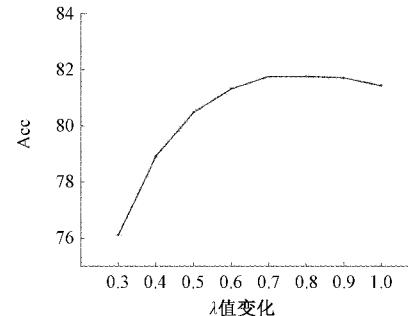
支持集中每类样本仅有 1 个样本时,均匀分布的采样区域越靠近原型表征,生成的样本可信度越高,模型性能越好。当分布边界为二者均值和原型表征时,1-shot 准确率达到了最高值。在 5-way 5-shot 的设置下,每个任务中支持集的每类样本有 5 个样本,采样区域越靠近支持集样本,生成数据的可信度越高。当分布边界为支持集样本和二者均值时,5-shot 准确率达到了最高值。通过分析可知,当每个类别只有 1 个样本时,对接近该样本区域采样会导致生成样本的整体中心偏离实际原型,但当有多个样本时,生成数据的中心仍然可以不偏离,并且可以增加样本数据的可靠性。因此,根据样本数量对分布边界进行调整可以进一步提高小样本图像的分类准确率,所提方法在 1-shot 上采用第 1 组分布边界,在 5-shot 上采用第 3 组分布边界达到了最佳的分类结果。

#### 6) 超参数选择

为了研究超参数对实验的影响程度,实验在两个数据集上,5-way 1-shot 设置下进行,实验结果如图 5 所示。通过在一定范围内改变超参数数值,观察精度的变化,选择对应于最高预测性能的峰值。对于特征转换的超参数,在 miniImageNet 上的变化结果如图 5(a)所示,在 CUB 上的



(a) miniImageNet 上  $\lambda$  值变化结果



(b) CUB 上  $\lambda$  值变化结果

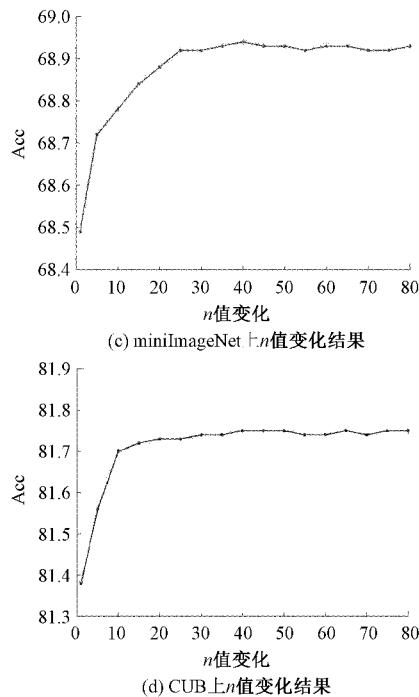


图 5 超参数变化结果

变化结果如图 5(b)所示。在两个数据集上的变化曲线基本相似,分类精度呈现先升高后降低的变化,两条曲线在相同的  $\lambda = 0.7$  处出现峰值,之后精度开始降低。对于生成样本数量的超参数  $n$ ,分别从数值 1 开始,以等差为 5 的取值进行实验。在 miniImageNet 上的变化结果如图 5(c)所示,当  $n < 5$  时,分类精度上升较快,之后上升幅度减小,当  $n > 40$  后,分类精度基本趋于稳定。在 CUB 上的变化结果如图 5(d)所示,当  $n < 10$  时,分类精度上升幅度较大,之后上升较为缓慢,当  $n > 40$  后,分类精度趋于稳定。可以看到,随着生成样本数量的增加,分类准确率均呈现先上升后稳定的状。因此,所提模型选取超参数组  $\lambda = 0.7, n = 40$  可以获得最佳分类性能。

### 3 结 论

本文提出了一种结合原型校准分布的小样本图像分类算法。该方法利用基类特征进行反距离加权以表示新类支持集样本,获取更加准确的新类原型表征。随后从新类样本特征和其原型表征的均匀分布中采样,并根据样本数量改变均匀分布的边界,从置信度较高的区域生成大量数据扩充新类支持集,提升分类器对新类图像的预测性能。在小样本标准数据集 miniImageNet 和 CUB 上的实验结果表明,相比于现有方法,所提模型实现了最佳的分类性能,验证了算法的有效性。在未来的研究中,可以利用自适应策略来选取生成样本的采样区间,进一步提高小样本图像的预测准确率。

### 参考文献

[1] 刘浩然,刘秀清,王春乐.基于随机森林和超像素的极

化 SAR 图像分类[J].国外电子测量技术,2021,40(9): 29-35.

- [2] 李睿康,焦新泉,陈建军.样本重采样小目标检测算法的改进[J].电子测量技术,2021,44(13): 41-47.
- [3] 王光,李鸿宁,邱云飞,等.基于图卷积记忆网络的方面级情感分类[J].中文信息学报,2021,35(8): 98-106.
- [4] FINN C, ABBEEL P, LEVINE S. Model-agnostic meta-learning for fast adaptation of deep networks [C]. Proceedings of the 34th International Conference on Machine Learning August 6-11, 2017, Sydney, Australia, PMLR, 2017: 1126-1135.
- [5] SUN Q R, LIU Y Y, CHUA T, et al. Meta-transfer learning for few-shot learning [C]. Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019, Long Beach, USA, New York: IEEE, 2019: 403-412.
- [6] LIU Y Y, SCHIELE B, SUN Q. An ensemble of epoch-wise empirical bayes for few-shot learning[C]. Proceedings of the 16th European Conference on Computer Vision, August. 23-28, 2020, Glasgow, UK, Cham: Springer, 2020: 404-421.
- [7] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]. Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June. 23, 2018, Salt Lake City, USA, New York: IEEE Press, 2018: 1199-1208.
- [8] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems, December, 4-9, 2017, Long Beach, USA, New York: Curran Associates, 2017: 4080-4090.
- [9] LIU J, SONG L, QIN Y. Prototype rectification for few-shot learning[C]. Computer Vision-ECCV 2020: 16th European Conference, Glasgow, UK, August 23-28, 2020, Springer, 2020: 741-756.
- [10] WANG Y X, GIRSHICK R, HEBERT M, et al. Low-shot learning from imaginary data [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7278-7286.
- [11] PARK S J, HAN S, BAEK J, et al. Meta variance transfer: Learning to augment from the others[C]. International Conference on Machine Learning, PMLR, 2020: 7510-7520.
- [12] YANG S, LIU L, XU M. Free lunch for few-shot learning: Distribution calibration[C]. In 2021 International Conference on Learning Representations(ICLR), 2021.

- [13] XIAN Y, LORENZ T, SCHIELE B, et al. Feature generating networks for zero-shot learning [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 5542-5551.
- [14] LIU J, SUN Y, HAN C, et al. Deep representation learning on long-tailed data: A learnable embedding augmentation perspective [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 2970-2979.
- [15] HU Y, GRIPON V, PATEUX S. Leveraging the feature distribution in transfer-based few-shot learning [C]. International Conference on Artificial Neural Networks, Springer, Cham, 2021: 487-499.
- [16] MANGLA P, KUMARI N, SINHA A, et al. Charting the right manifold: Manifold mixup for few-shot learning [C]. Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2020: 2218-2227.
- [17] LIU B, CAO Y, LIN Y T, et al. Negative margin matters: Understanding margin in few-shot classification[C]. Proceedings of the 16th European Conference on Computer Vision (ECCV), Glasgow, UK, 2020: 438-455.
- [18] AFRASIYABI A, LALONDA J O, CHRISTIAN G. Associative alignment for few-shot image classification[C]. Proceedings of the European Conference on Computer Vision, Springer, Cham, 2020: 18-35.
- [19] SCHWARTZ E, KARLINSKY L, SHTOK J, et al. Delta-encoder: An effective sample synthesis method for few-shot object recognition[C]. Proceedings of the 32nd International Conference on Neural Information Processing Systems, 2018: 2850-2860.
- [20] CHEN Z, FU Y, ZHANG Y, et al. Multi-level semantic feature augmentation for one-shot learning [J]. IEEE Transactions on Image Processing, 2019, 28 (9): 4594-4605.

### 作者简介

黄友文,博士,副教授,主要研究方向为计算机视觉。

E-mail: ywhuang@jxust.edu.cn

胡燕芳,硕士研究生,主要研究方向为计算机视觉、小样本学习。

E-mail: Oreash@163.com

魏国庆,硕士研究生,主要研究方向为机器学习。

E-mail: a203597244@163.com