

基于转导推理的小样本学习方法改进

付海涛, 金晨磊, 杨亚杰, 冯宇轩
(吉林农业大学 信息技术学院, 长春 130118)

摘要: 针对目前小样本图像分类推断置信度有待提高的问题, 提出一个新的结合元置信转导推理、数据混淆方法和按特征线性调制方法的模型。首先, 利用转导推理在训练过程中能学习到推断数据的性质, 可以有针对性地学习; 其次, 在网络结构中结合数据混淆方法, 加强对关键特征的提取, 提升模型的特征发现能力; 最后, 在转导推理框架中加入按特征线性调制变换以改进模型的小样本查询能力。在标准数据集 Mini-ImageNet 和 Tiered-ImageNet 上进行实验的结果表明, 该模型在这两个数据集上执行 5-way 1-shot 任务时准确率分别提升了 3.21, 3.36 个百分点, 在 5-way 5-shot 任务上准确率分别提升了 2.89, 1.89 个百分点。实验结果验证了该方法的有效性。

关键词: 小样本学习; 转导推理; 数据扰动; 按特征线性调制变换

中图分类号: TP39 **文献标志码:** A **文章编号:** 1671-5489(2024)06-1439-08

Transductive Inference Based Improvement for Few-Shot Learning

FU Haitao, JIN Chenlei, YANG Yajie, FENG Yuxuan

(College of Information Technology, Jilin Agricultural University, Changchun 130118, China)

Abstract: Aiming at the problem of the need to improve confidence level in few-shot image classification inference at present, we proposed a new model that combined meta-confidence transductive inference, data obfuscation method, and feature-wise linear modulation method. Firstly, by using transductive inference, the model could learn properties of inference data during training process, and achieve targeted learning. Secondly, combining data obfuscation methods in the network architecture to enhance the extraction of key features, and improve the feature discovery ability of the model. Finally, feature-wise linear modulation transformation was added to the transductive inference framework to improve the model's few-shot query capabilities. The results of experiments conducted on standard datasets Mini-ImageNet and Tiered-ImageNet show that the model improves accuracy by 3.21 and 3.36 percentage points respectively when performing 5-way 1-shot tasks on these two datasets, and by 2.89 and 1.89 percentage points respectively on 5-way 5-shot tasks. The experimental results validate the effectiveness of the proposed method.

Keywords: few-shot learning; transductive inference; data perturbation; feature-wise linear modulation transformation

当前神经网络的发展主要依靠大量标注样本的监督学习^[1]。在实际应用中, 数据标注是一项劳动密集型工作, 难以保证数据质量。当某类别的样本数量不足或类别分布不均衡时会影响深度神经

收稿日期: 2023-12-29.

第一作者简介: 付海涛(1976—), 男, 汉族, 硕士, 副教授, 从事深度学习和智能农业的研究, E-mail: fht@jlau.edu.cn. **通信作者简介:** 冯宇轩(1980—), 男, 汉族, 博士, 讲师, 从事自动规划和深度学习的研究, E-mail: fengyuxuan.cn@163.com.

基金项目: 吉林省环保厅一般项目(批准号: 吉环科学第 2023-18).

网络在该类别上的分类性能^[2]. 受人类强大学习能力的启发, 在样本不足或分布不均衡情况下有效学习的深度学习模型, 即为小样本学习^[3].

在小样本学习中, 常采用的数据增强^[4]、迁移学习^[5]和元学习等方法, 或是这些方法的组合. 数据增强是一种直观的解决方案, 通过上采样扩展数据集, 可增加数据量并平衡类别. 例如, 采用随机过采样和参数化过采样进行数据增强, 再结合元学习进行求解设计, 能在一定程度上改善小样本学习^[6]. 基于元学习的原型网络和孪生网络联合框架也取得了良好的结果^[7]. 在结合数据增强的小样本学习中, 除对训练数据进行增强外, 还有基于特征的数据增强方案. 假设同一类型的数据特征服从同一高斯分布, 可先基于该假设对支持集特征进行聚类, 再通过元学习对查询集特征进行分类, 最后在同分布特征中采样, 实现按特征的数据增强也实现了较好的性能^[8].

迁移学习通过将源领域数据中学习到的模型迁移到目标领域, 从而提高目标领域的学习性能. 其典型流程分为预训练和微调两个阶段. 预训练使用相对充足的源领域数据进行训练, 微调则利用目标领域数据对网络进行调整以适应特定任务. 如残差迁移网络(residual transfer networks, RTN)就是通过迁移源领域的特征学习提升模型在目标领域的泛化能力, 表现了良好的小样本学习效果^[9].

元学习, 尤其是度量学习, 则是一类通过自动学习知识解决相似性分类问题的方法. 度量学习通过计算待分类样本与已知样本之间的相似度, 在度量空间内完成分类推断^[10]. 典型方法有 Koch 等^[11]提出的基于孪生网络的单样本学习方法, 以及 Vinyals 等^[12]提出的匹配网络, 都是利用相似度度量实现小样本分类. 原型网络通过比较类别原型之间的距离进行分类^[13], 而关系网络则通过神经网络输出相似度得分^[14]进行分类.

基于以上小样本学习技术, 为扩展深度神经网络的知识学习能力, 本文采用基于元学习的转导推理方法, 对小样本学习进行改进. 首先, 引入区域混淆, 通过将输入图像划分为多个区域, 按区域进行随机排列, 增强模型在少量数据中进行特征学习的能力, 改进小样本学习效果; 其次, 设计骨干网络中的按特征线性调制变换(feature-wise linear modulation, FiLM), 通过对神经网络中间特征进行仿射变换, 训练提高转导推理结果的置信度, 从而提升小样本学习性能.

1 预备知识

1.1 小样本学习问题

在小样本学习任务中, 为解决在样本数据量小的情况下对新类别进行准确分类的问题, 通常使用基类数据集 D_{base} 训练模型, 并使模型能泛化到新类 D_{novel} 图像数据上完成分类, 基类数据集与新类数据集相互独立, $D_{\text{base}} \cap D_{\text{novel}} = \emptyset$. 在小样本学习的图像分类问题中, 每个元任务由支持集和查询集组成, 其中: 支持集为 $S = \{\{x_{i,s}\}_{s=1}^K, y_i\}_{i=1}^N$, 支持集中类别数为 N , 每种类别包含 K 个标记样本; 查询集为 $Q = \{\{x_{i,q}\}_{q=1}^{Q_1}, y_i\}_{i=1}^N$, 查询集和支持集来自同分布的 N 个类别, 每个类别中包含 $|Q|$ 个测试样本. 小样本学习也称为 N -way K -shot 分类问题.

1.2 转导推理

通过对已有的训练用例进行表征学习, 并据此进行推断是常见的监督学习范式, 属于归纳推理^[15]. 转导推理与归纳推理同属监督学习, 其核心概念在于使用已知的训练样本学习对测试样本的推断^[16]. 在模型的训练阶段引入训练集和测试集, 以实现对这两个数据集的充分利用. 相对于归纳推理有一定的推断和迁移的性能提升, 当数据改变时训练要重新进行. 转导推理常见的方法主要包括转导支持向量机(trans-support vector machine, TSVM)和标签传播算法(label propagation algorithm, LPA). 转导支持向量机假设数据集合与其对应的标签集合之间存在特定的几何关系, 与支持向量机相同也致力于寻找具有分类能力的超平面. 标签传播算法是在已知部分数据的情况下, 根据数据之间的特征相似性推断数据集中缺失标签的机器学习方法, 算法包含了特征传播和标签传播两部分. 它们的目的是通过有标记与无标记的数据进行综合考虑, 从而提升识别效果. 在该过程中, 利用有标签的数据确定支持向量, 而未标记的数据被用来描述数据的分布情况, 以提高分类效果.

转导推理通过学习的方式使模型对输入数据进行转换、分类、标注、生成等处理, 同时利用神经

网络对多个任务进行权值调节, 使目标函数达到最优. 在计算机视觉、图像分类、自然语言处理和生物信息学等领域应用广泛.

1.3 元置信转导网络模型

元置信转导(meta-confidence transduction, MCT)^[17]网络在解决小样本问题上, 先利用转导推理得到查询样本的置信度加权平均值, 再通过得到的值对查询样本的类别原型进行更新. 但在现实问题中, 查询样本可能来自一个未知的分布领域, 这样通过转导推理得到的值可能不可靠, 导致预测错误. 为解决该问题, 引入了元学习方法, 先利用元学习中的距离度量给未标记的每个类的查询样本分配置信度得分, 再对获得置信度的原网络进行更新, 从而提高模型对未知分布查询样本的转导推理能力.

在小样本学习任务中, 即使对模型进行了元学习, 但由于数据的稀缺问题, 模型置信度本质上还是不可靠的. 为输出更可靠的置信度, 可以强制模型输出一致性的预测, 同时扰动模型或数据. 数据扰动共有两个置信度, 一个置信度来自原始图像, 另一个是对原始图像进行水平翻转后的图像. 采用这种方法可以在不损失信息的前提下, 对数据施加一定的干扰, 从而得到训练与测试中的扰动置信度. 模型中的扰动则是通过伪随机过程决定是否删除某些网络模块带来的.

2 基于 MCT 的小样本方法

2.1 区域混淆

人类有小样本学习和细粒度学习的能力, 如在仅获取少量局部区域样本的条件下, 就能区分更有代表性的样本特征, 从而实现分类和识别任务. 例如旅游爱好者能通过少量图像的区域特征对景点进行分类. 相比于自然语言处理, 在监督学习条件下对比乱序前后的句子可以使模型注意到区分度高的词, 在视觉领域, 将图的局部区域扰乱前后的数据采用同一个标签, 端到端地训练网络也可以使模型在分类任务中更好地聚焦在关键分类区域上. 即先把输入图像划分为多个局部区域部分, 再利用区域融合算法(region confusion mechanism, RCM)^[18]对局部区域进行打乱. 通过加强对细节特征的学习充分利用小样本的数据.

RCM 扰乱图像局部区域的空间分布如图 1 所示. 首先将图像 I 切分为 $N \times N$ 个子区域, 用 $R_{i,j}$ 标记每个区域, 其中 i, j 分别表示图像块在原图中的行列位置, i 和 j 的取值范围为 $[0, N)$. 对局部区域的空间分布进行打乱, 其实就是为 R 的第 j 行生成一个随机向量 q_j , 而第 i 个元素的值为 $q_{j,i} = i + r$, r 的取值范围为 $[-b, b]$, 且符合均匀分布 $U(-b, b)$, $0 \leq b < N$, 其中 b 是一个可调整的参数. 在第 j 行通过对 q_j 进行排序获得新区域的排列 σ_j^{row} , 数量关系要满足:

$$|\sigma_j^{row}(i) - i| < 2b, \quad \forall i \in \{1, 2, \dots, M\}, \tag{1}$$

也可以用上述关系进行验证.



图 1 区域混淆算法

Fig. 1 Region confusion algorithm

同理, 在行向量和列向量上做完该操作后即可得到一个新的“破坏”后的图像. 对区域逐列地应用变换 σ_i^{col} :

$$|\sigma_i^{col}(j) - j| < 2b, \quad \forall j \in \{1, 2, \dots, M\}. \tag{2}$$

原图中 (i, j) 区域被重构后新的坐标位置为

$$\sigma(i, j) = (\sigma_i^{row}(i), \sigma_i^{col}(j)). \tag{3}$$

该方法对原始图像的区域分布进行重构后, 对不同类别之间提取细微差别的能力得到了提高, 解

决了数据来自未知分布时,置信度预测不可靠的问题.

2.2 按特征的线性调制变换

按特征的线性调制变换(FiLM)方法^[19]来自于视觉问答,使用该结构在神经网络的中间表示数据上进行仿射变换,该模式可在视觉问答实践中按条件进行选择特征.即通过条件信息的特征仿射变换影响神经网络的计算,小样本学习中支持集/查询集的学习模式与视觉问答模式相仿,所以在小样本学习模型上可引入这类变换方法.该方法通过学习两个任意的函数 f 和 h 改进特征学习,这两个函数也可以通过神经网络分支实现,它们共享参数便于更好地学习,本文将这两个网络作为一个网络,类似于孪生网络的设计.最终通过可学习参数 $\gamma_{i,c}$ 和 $\beta_{i,c}$ 影响网络:

$$\gamma_{i,c} = f_c(x_i), \tag{4}$$

$$\beta_{i,c} = h_c(x_i), \tag{5}$$

其中下标表示第 i 个输入的第 c 个特征. $\gamma_{i,c}$ 和 $\beta_{i,c}$ 用来调节神经网络中的激活 $F_{i,c}$, 然而调节特征图仅需两个参数,计算效率较高,在图像风格化、视觉回答和语言识别领域表现优异.本文将其在查询集与支持集的相似性比较上:

$$\text{FiLM}(F_{i,c} | \gamma_{i,c}, \beta_{i,c}) = \gamma_{i,c} F_{i,c} + \beta_{i,c}. \tag{6}$$

一个卷积神经网络结构上的单一 FiLM 层如图 2 所示,在 MCT 主干网络中进行 FiLM 变换,可以自适应地调整特征图, γ 和 β 的不同组合能实现多种方式对特征的调整,其中 \odot 表示 Hadamard 乘积,是一种常用的矩阵计算方法.将两个行、列数相同的矩阵 A 和 B 对应位置元素相乘后的结果放入矩阵 C 中的对应位置,可得到 Hadamard 乘积 $C: C(i, j) = A(i, j) \odot B(i, j)$, 其中 i 和 j 表示行列.

2.3 整体模型设计

本文对原始的 MCT 网络结构进行优化,以提高模型的泛华能力和分类性能,改进的 MCT 网络结构如图 3 所示.在支持集输入阶段,采用区域混淆算法对图像的区域进行打乱,以增强数据的多样性和模型的泛化能力.在数据扰动后,引入 FiLM 变换,根据输入数据的特征动态调整网络的权重.为更好地使网络模型理解并区分不同的特征,提高分类的准确性,利用距离度量进行学习.在查询集输入阶段,采用与支持集相同的网络结构进行特征提取,以确保特征的一致性.为提高模型在处理新

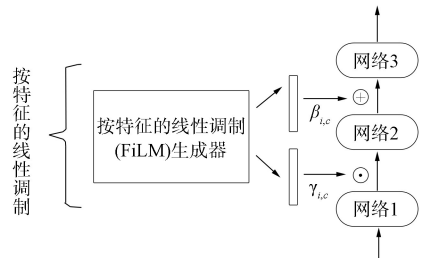


图 2 按特征的线性调制层

Fig. 2 Feature-wise linear modulation layer

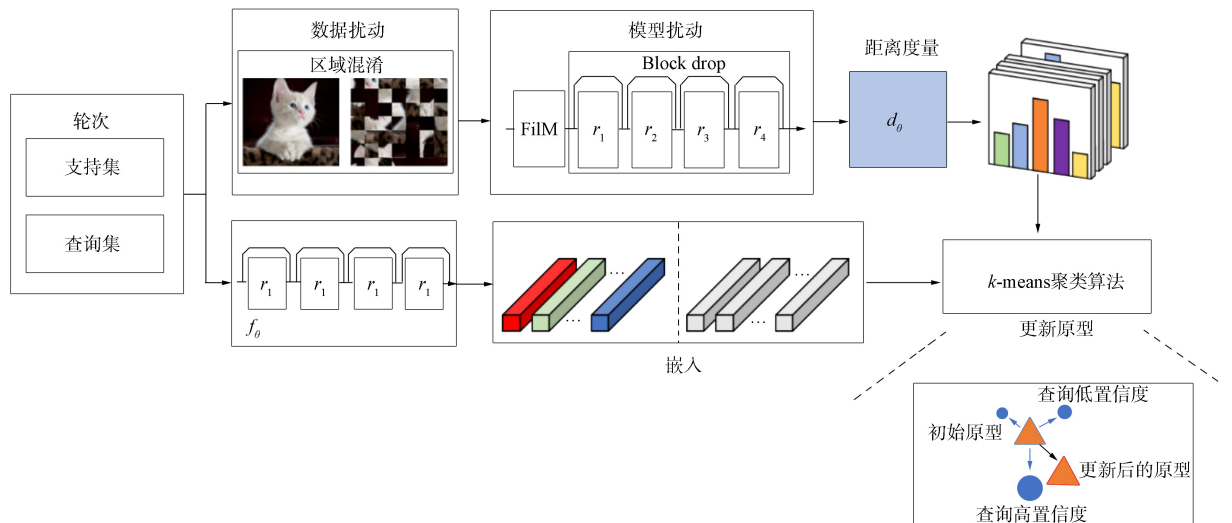


图 3 改进的 MCT 网络结构

Fig. 3 Structure of improved MCT networks

数据时能快速准确地进行分类, 提取到的特征进行特征嵌入, 最终与支持集数据的特征进行 k -means 聚类度量.

2.4 算法流程

基于 MCT 方法的小样本学习网络算法流程如下.

为捕捉数据的不确定性, 数据经过区域扰动后把原有图像划分为多个区域后进行重构, 重构后的数据经过模型扰动后进行 FiLM 变换, 通过对中间特征应用条件信息的仿射变换影响转导推理的置信度.

对查询样本进行元学习, 能产生一个可以提高性能的距离度量值 d_θ , 其中 θ 表示距离度量关系由可学习的参数 θ 决定. 设 $a_1, a_2 \in \mathbb{R}$, 使用欧氏距离定义有归一化的按实例度量缩放 g_θ^I 和成对度量缩放 g_θ^P , 分别表示为

$$d_\theta^I(a_1, a_2) = \left\| \frac{a_1}{\|a_1\|_2} - \frac{a_2}{\|a_2\|_2} \right\|_2^2, \tag{7}$$

$$d_\theta^P(a_1, a_2) = \left\| \frac{a_1}{\|a_1\|_2} - \frac{a_2}{\|a_2\|_2} \right\|_2^2. \tag{8}$$

为得到最优距离函数 $g_\theta \in \{g_\theta^I, g_\theta^P\}$, 计算查询样本概率后, 优化距离函数 g_θ 中 θ 的值, 使 $d_\theta \in \{d_\theta^I, d_\theta^P\}$ 的损失尽量小, 其中 d_θ^I 为按实例度量缩放的距离度量值, d_θ^P 为按成对度量缩放的距离度量值.

$L_i^\tau(\theta, \phi)$ 是一个期望损失函数, 在元学习过程中用于优化模型参数, 并在所有任务上取平均值, 其中 τ 表示任务索引或任务分布, θ 为定义自适应距离度量参数, ϕ 表示模型参数. 在元学习中, 通常需要在多个任务上训练模型, 每个任务 τ 可能包含不同的数据分布或不同的类别. I 表示损失函数的类型或实例, L_I 表示在特定任务 τ 上对每个实例进行预测时的损失, \mathcal{D} 表示集合的大小, 用来对所有样本的损失进行平均. $L_i^\tau(\theta, \phi)$ 定义为

$$L_i^\tau(\theta, \phi) = \frac{1}{|\mathcal{D}|} \sum_{(\tilde{x}, \tilde{y}) \in \mathcal{D}} -\log p(\tilde{y} | \tilde{x}, s; \theta, \phi) = \frac{1}{|\mathcal{D}|} \sum_{(\tilde{x}, \tilde{y}) \in \mathcal{D}} [d_\phi(f_\theta(\tilde{x}), P_c^{(T)}) + \sum_{c'=1}^C \exp\{-d_\phi(f_\theta(\tilde{x}), P_{c'}^{(T)})\}], \tag{9}$$

其中: $-\log p(\tilde{y} | \tilde{x}, s; \theta, \phi)$ 表示 Softmax 归一化项; (\tilde{x}, \tilde{y}) 表示输入样本及其对应标签; $(\tilde{y} | \tilde{x}, s; \theta, \phi)$ 表示给定输入 \tilde{x} 和支持集 s 时, 模型预测样本 \tilde{x} 属于类别 \tilde{y} 的概率, 此概率通过 Softmax 函数计算得到; 距离项 $d_\phi(f_\theta(\tilde{x}), P_c^{(T)})$ 是模型预测的嵌入 $f_\theta(\tilde{x})$ 与类别原型 $P_c^{(T)}$ 之间的距离, 该距离度量是通过参数 θ 学习的, 可以是欧氏距离; $\exp\{-d_\phi(f_\theta(\tilde{x}), P_{c'}^{(T)})\}$ 是模型对类别 c' 预测概率的指数部分, d_ϕ 是通过参数 ϕ 学习的距离度量函数, $f_\theta(\tilde{x})$ 是模型的嵌入函数, 将输入 \tilde{x} 映射到嵌入空间中, $P_c^{(T)}$ 是类别 c 的原型, 是在第 T 步更新后的类别中心.

在此基础上, 使用 Soft k -means 算法描述转导推理得到置信度加权平均值后对原始网络进行更新的主要过程. Soft k -means 和 Hard k -means 这两种算法, 前者得到一个置信度, 类似于概率; 后者得到 0 和 1, 0 表示不属于该类别, 1 表示属于该类别.

定义一个包含支持集 S 和查询集 Q 的集, 并将 S_c 定义为类 c 的支持集, Q_x 为所有查询样本的集合, 其中 $Q_x = \{X_1, X_2, \dots, X_{c \times m}\}$. 计算每个类 $c = \{1, 2, \dots, C\}$ 的初始原型 $P_c^{(0)} = \frac{1}{|S_c|} \sum_{x \in S_c} f_\theta(x)$; 以 t 值为基础, 计算样本 x 的置信度, 即属于类 c 的概率 $p_c^{(t-1)}(\tilde{x})$,

$$q_c^{(t-1)}(\tilde{x}) = \frac{\exp\{-d(f_\theta(\tilde{x}), P_c^{(t-1)})\}}{\sum_{c'=1}^C \exp\{-d(f_\theta(\tilde{x}), P_{c'}^{(t-1)})\}}, \tag{10}$$

其中 $t = \{1, 2, \dots, T\}$, $x \in Q_x$, $d(\cdot, \cdot)$ 表示欧氏距离, $P^{(t-1)}$ 表示第 $(t-1)$ 步需要更新的原型网络. 基

于所有样本 x 的置信度(概率)更新类 c 的原型. 网络的具体训练过程如下.

算法 1 利用区域混淆和 FiLM 变换改进后的 MCT 网络算法.

1) BEGIN

输入: $\theta_0, G_0, J_0, \mathcal{D}_{\text{train}}, N_{\text{episode}}$ (任务量);

输出: θ, G, J ;

2) $\theta, G, J \leftarrow \theta_0, G_0, J_0$ // 模型参数初始化;

3) FOR x FROM 1 to N_{episode} DO

4) 从 $\mathcal{D}_{\text{train}}$ 中随机采样一个任务 $\delta^{(x)} = \{S^{(x)}, Q^{(x)}\}$;

5) $\theta \leftarrow \sigma(\delta^{(x)})$ // 函数 $\sigma(\cdot)$ 是将参数进行区域混淆, 按式(3)描述过程得到区域混淆重构后的新坐标;

6) $\theta' \leftarrow \text{FiLM}(\theta | \gamma_{i,c}, \beta_{i,c})$ // FiLM 变换, 按式(6)完成;

7) $G \leftarrow$ 式(7) // 按式(7)得到按实例度量缩放的距离度量值

$G \leftarrow$ 式(8) // 按式(8)得到按成对度量缩放的距离度量值

8) $G' \leftarrow \varphi(G)$ // 用函数 $\varphi(\cdot)$ 对距离函数进行优化, 使 d_θ 损失最小;

9) END FOR

10) $J_0 \leftarrow 0$ // 初始化网络原型;

11) $J \leftarrow J_0 +$ 式(10) // 使用 Soft k -means 算法更新原型;

12) θ, G, J // 更新网络参数;

13) END.

3 实验

3.1 小样本学习问题的评判标准

小样本学习中 5-way 1-shot 分类任务表示在数据集中包含 5 个类别, 每个类别中的 1 个样本作为训练样本. 小样本学习是指在实验中, 只给模型提供较少的样本(1 个或几个), 检验模型能否正确地推广到新的类别上. 同样在 5-way 5-shot 任务中选择 5 类数据样本, 并在每个类别中随机抽取 5 个训练样本, 模型需要从这些训练样本中学习如何识别这 5 个类别, 当进行分类任务时, 模型能正确地完成分类.

分类准确率(ACC)是衡量小样本学习分类模型性能的重要指标, 主要是通过计算模型正确分类的图像数量 n_R 与总预测图像数量 n 的比值得到, 公式为

$$\text{ACC} = n_R / n. \quad (11)$$

3.2 实验及参数配置

本文在数据集 Mini-ImageNet 和 Tiered-ImageNet 上对比并验证了本文方法. 激活函数使用 Hardswish^[20], 与 ReLU, Sigmoid 和 Tanh 激活函数不同, 该激活函数在本文问题中具有计算效率的优势. Mini-ImageNet: 该数据集由数据集 ImageNet 的一个子集组成, 常被用于小样本图像分类算法中. 数据集 Mini-ImageNet 包含 100 个类, 每个类有 600 张图像, 共有 60 000 张数据集 ImageNet 的图像, 并且每张图像的处理长宽为 84. 本文从 100 个类别中选取 20 个类别进行测试, 16 个用于检验, 剩余的 64 个用于训练. Tiered-ImageNet: 该数据集同样也是基于数据集 ImageNet, 但它采用了一种不同的分层采用方法, 可以更好地模拟实际应用场景中的数据分布和类别之间的关系, 与数据集 Mini-ImageNet 相比包含了更广泛的类别. 本文从 20 个上层类别中选择 351 个类别样本进行训练; 6 个不同类别的上层类别中选择 97 个类别样本进行验证; 8 个不同类别的上层类别中选择 160 个类别样本进行测试.

3.3 实验结果和分析

对数据集图像结构进行全局破坏重构, 并将 FiLM 变换结合主干网络 ResNet-12 改进的 MCT 网络模型进行训练和测试. 本文在数据集上分别进行了 5-way 1-shot 和 5-way 5-shot 的两种实验, 目的是与原有的 MCT 算法和其他同类型的小样本图像分类算法公平对比. 在实验中以数据集

Mini-ImageNet 的 500 次测试的平均精度作为最终结果, 以数据集 Tiered-ImageNet 的 800 次测试的平均精度作为最终结果. 除图像处理部分和 FiLM 变换外, 其余 MCT 的原有参数保持不变.

基于数据集 Mini-ImageNet 和 Tiered-ImageNet, 各小样本分类模型在 5-way 1-shot 和 5-way 5-shot 任务上进行实验. 实验结果列于表 1, 包括 TPN^[21], DPGN^[22], MetaOptNet^[23], MCT^[17] (* 表示原 MCT 网络在同一设置下的复现) 及本文的改进结果.

表 1 各模型实验结果对比

Table 1 Comparison of experimental results of each model

网络模型	骨干网络	Mini-ImageNet 准确率/%		Tiered-ImageNet 准确率/%	
		1-shot	5-shot	1-shot	5-shot
TPN	ResNet-12	52.82±0.63	71.34±0.45	54.92±0.15	69.78±0.74
DPGN	ResNet-12	66.79±0.73	68.27±64	69.33±0.45	69.78±0.65
MetaOptNet-SVM	ResNet-12	57.10±0.46	73.22±0.75	62.89±0.51	73.97±0.40
MCT(pair) (*)	ResNet-12	75.41±0.84	84.31±0.44	78.27±0.87	86.12±0.49
本文(pair)	ResNet-12	77.85±0.32	86.12±0.78	79.89±0.31	87.66±0.22
MCT(instance) (*)	ResNet-12	76.53±0.83	85.09±0.43	80.22±0.95	87.12±0.34
本文(instance)	ResNet-12	79.74±0.85	88.45±0.12	83.11±0.65	89.01±0.21

由表 1 可见, 改进后的本文(instance)模型在数据集 Mini-ImageNet 上的学习精度分别达到了 (79.74±0.85)%, (88.45±0.12)%; 在数据集 Tiered-ImageNet 上的学习精度分别达到了 (83.11±0.65)%, (89.01±0.21)%. 实验结果表明, 打乱图像区域分布和 FiLM 变换的方法对解决 MCT 网络在小样本图像分类问题上性能较好.

3.4 消融实验

为进一步验证改进后的 MCT 网络模型的性能, 在数据集 Mini-ImageNet 上进行 5-way 1-shot 和 5-way 5-shot 的实验. 将原 MCT 网络同一设置下的复现结果作为基线, 分别测试进行数据扰动(Sr)和 FiLM 变化后的数据, 实验结果列于表 2. 表 2 的实验结果进一步验证了改进后的 MCT 网络模型的有效性, 优于原网络模型, 取得了良好的效果.

表 2 消融实验结果

Table 2 Results of ablation experiment

网络模型	骨干网络	准确率/%	
		1-shot	5-shot
MCT(pair)	ResNet-12	75.41±0.84	84.31±0.44
本文(pair-Sr)	ResNet-12	76.58±0.21	85.74±0.32
本文(pair-FiLM)	ResNet-12	76.32±0.45	85.54±0.43
MCT(instance)	ResNet-12	76.53±0.83	85.09±0.43
本文(instance-Sr)	ResNet-12	78.01±0.31	87.53±0.37
本文(instance-FiLM)	ResNet-12	78.23±0.75	87.01±0.86

综上所述, 为提高 MCT 网络在小样本图像分类问题中的准确性, 基于该网络模型, 通过区域混淆机制, 使神经网络能根据区域的图像细节信息实现分类, 降低对图像全局结构的依赖性. 利用 FiLM 变换使网络更适用于支持/查询的学习模式, 有效改进了当数据来自未知分布时置信度不可靠的问题. 通过在经典数据集上的实试验结果表明, 改进后的本文(instance-FiLM)网络模型相比原模型在 5-way 1-shot 任务中的分类准确率提高了 3.21, 3.36 个百分点, 在 5-way 5-shot 任务中相比原模型提高了 2.89, 1.89 个百分点.

参 考 文 献

[1] BENGIO Y, LECUN Y, HINTON G. Deep Learning for AI [J]. Communications of the ACM, 2021, 64(7): 58-65.
 [2] LI Y D, HAO Z B, LEI H. Survey of Convolutional Neural Network [J]. Journal of Computer Applications, 2016, 36(9): 2508-2515.

- [3] HU X, CHEN S. A Survey of Few-Shot Learning Based on Machine Learning [J]. *Intelligent Computer and Applications*, 2021(7): 191-195.
- [4] 朱晓慧, 钱丽萍, 傅伟. 图像数据增强技术研究综述 [J]. *软件导报*, 2021, 20(5): 230-236. (ZHU X H, QIAN L P, FU W. Overview of Research on Image Data Enhancement Technology [J]. *Software Guide*, 2021, 20(5): 230-236.)
- [5] PAN S J, YANG Q. A Survey on Transfer Learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 22(10): 1345-1359.
- [6] OCHAL M, PATACCHIOLA M, STORKEY A J, et al. Few-Shot Learning with Class Imbalance [J]. *IEEE Transactions on Artificial Intelligence*, 2021, 4: 1348-1358.
- [7] YAN J, FENG K Y, ZHAO H Y, et al. Siamese-Prototypical Network with Data Augmentation Pre-training for Few-Shot Medical Image Classification [C]//2022 2nd International Conference on Frontiers of Electronics, Information and Computation Technologies (ICFEICT). Piscataway, NJ: IEEE, 2022: 387-391.
- [8] ZHANG X, HUANG W G, WANG R, et al. Multi-stage Distribution Correction: A Promising Data Augmentation Method for Few-Shot Fault Diagnosis [J]. *Engineering Application of Artificial Intelligence*, 2023, 123: 106477-1-106477-16.
- [9] LONG M S, ZHU H, WANG J M, et al. Unsupervised Domain Adaptation with Residual Transfer Networks [J]. *Advances in Neural Information Processing Systems*, 2016, 29: 22-24.
- [10] SHEN Y Y, YAN Y, WANG H Z. Recent Advances on Supervised Distance Metric Learning Algorithms [J]. *Acta Automatica Sinica*, 2014, 40(12): 2673-2686.
- [11] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese Neural Networks for One-Shot Image Recognition [C]//Proceedings of the 32nd International Conference on Machine Learning. [S.l.]: JMLR, 2015: 1-8.
- [12] VINYALS O, BLUNDELL C, LILLICRAP T, et al. Matching Networks for One Shot Learning [C]//Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2016: 3630-3638.
- [13] SNELL J, SWERSKY K, ZEMEL R S. Prototypical Networks for Few-Shot Learning [C]//Proceeding of the 31st International Conference on Neural Information Processing Systems. New York: ACM, 2017: 4080-4090.
- [14] SUNG F, YANG Y, ZHANG L, et al. Learning to Compare: Relation Network for Few-Shot Learning [C]//2018 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE Computer Society, 2018: 1199-1208.
- [15] KITSON N K, CONSTANTINOU A C, GUO Z G, et al. A Survey of Bayesian Network Structure Learning [J]. *Artificial Intelligence Review*, 2023, 56(8): 8721-8814.
- [16] BOUSQUET O. Transductive Learning: Motivation, Models, Algorithms [J]. *Journal of Machine Learning Research*, 2002, 2002(14): 135-168.
- [17] KYE S M, LEE H, KIM H, et al. Transductive Few-Shot Learning with Meta-Learned Confidence [J]. *Journal of Machine Learning Research*, 2020, 1(2): 1-3.
- [18] CHEN Y, BAI Y L, ZHANG W, et al. Destruction and Construction Learning for Fine-Grained Image Recognition [C]//Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2019: 5157-5166.
- [19] PEREZ E, STRUB F, DE VRIES H, et al. FiLM: Visual Reasoning with a General Conditioning Layer [C]//Proceedings of the Thirty-Second AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2018: 3942-3951.
- [20] RAMACHANDRAN P, ZOPH B, LE Q V. Searching for Activation Functions [EB/OL]. (2017-10-16) [2023-02-15]. <https://arxiv.org/abs/1710.05941>.
- [21] LIU Y B, LEE J, PARK M, et al. Learning to Propagate Labels: Transductive Propagation Network for Few-Shot Learning [EB/OL]. (2018-03-25)[2023-03-10]. <https://arxiv.org/abs/1805.10002>.
- [22] YANG L, LI L L, ZHANG Z L, et al. DPGN: Distribution Propagation Graph Network for Few-Shot Learning [C]//2020 IEEE/CVF Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2020: 13387-13396.
- [23] LEE K, MAJI S, RAVICHANDRAN A, et al. Meta-Learning with Differentiable Convex Optimization [C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2019: 10657-10665.