

DOI:10.19651/j.cnki.emt.2106981

基于图神经网络的任务驱动元学习方法

李明 赵文仓 秦文谦

(青岛科技大学 自动化与电子工程学院 青岛 266061)

摘要: 为了解决传统分类模型泛化能力差的问题,提出了一种新的元学习方法。该方法首先引入动态特征提取模块使得分类模型能够挖掘外部的任务信息;其次,采用协同训练的方法解决由于任务驱动模块的引入而导致的计算量增大问题;最后,使用图神经网络作为分类模块充分利用样本之间的相关信息,达到进一步提高分类准确率的目的。与传统的元学习分类模型相比,该方法在 MiniImageNet 数据集上的准确率提高了 6.81%,在 CIFAR-FS 数据集上的准确率提高了 6.20%,实验结果表明,该方法可以有效解决传统元学习方法泛化能力差的问题。

关键词: 元学习;图神经网络;图像分类;小样本分类

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Task-driven meta-learning based on graph neural network

Li Ming Zhao Wencang Qin Wenqian

(College of Automation and Electronic Engineering, Qingdao University of Science & Technology, Qingdao 266061, China)

Abstract: In order to solve the issue of poor generalization ability of traditional classification models, an innovative meta-learning method was proposed. Firstly, a dynamic task-driven module was employed, which enabled the classification model to mine external task information. Secondly, a collaborative training method was adopted to overcome the increased complexity of calculation caused by the introduction of task-driven module. Finally, in order to exploit the relevant information between the samples, the graph neural network was used to be the classification module to achieve the purpose of further improving the classification accuracy. Compared with baselines, the accuracy of this method has increased by 6.81% and 6.20% on the MiniImageNet and CIFAR-FS datasets respectively. The experimental results show that the method can effectively improve the generalization ability of the classification model.

Keywords: meta-learning; graph neural networks; image classification; few-shot learning

0 引言

现存的元学习方法大致分为 3 类:基于参数优化的元学习方法,例如 MAML^[1]、TAML^[2]、AWGIM^[3],他们通过元学习的方式得到一个较好的初始化模型或者梯度下降的方向^[4],使得模型能够只利用较少的新样本,就能实现很好的效果,但是由于优化器选择的局限性,此方法通常得经过多次迭代更新才能获得最佳的学习率,这就导致模型面临新任务时学习过程缓慢;基于外部记忆的元学习方法,例如 MetaNet^[5]、MM-Net^[6],他们通过构建外部记忆来存储先验知识,以此来完成小样本的学习任务,但是由于学习网络得从头设计一种学习策略,故其工作效率比其他元学习方法略低;基于度量学习的元学习方法,例如 Prototypical Network^[7]、Relation Network^[8]、Matching Network^[9],他们首先将特征嵌入映射到统一的分类空间中,然后利用某

种度量方式^[10]比较支持集样本特征与查询集样本特征之间的距离,从而完成小样本的分类任务,但是当测试任务与训练任务之间的差别较大时,此方法效果不佳。

图神经网络^[11]和 TPN^[12]实质上是特殊的基于度量学习的元学习方法,与传统度量方式^[13]的不同点在于它将欧氏域数据映射到非欧氏域中,利用样本之间的关系构建图模型,并通过节点特征更新模块和边缘特征更新模块充分挖掘数据间的高阶信息,但上述方法的特征提取模块和当前的学习任务是独立的,没有考虑不同的分类任务之间特征嵌入的差别,这在一定程度上限制了模型的泛化能力。

为了克服上述元学习方法的弊端,本文方法改进了特征提取网络,即在原网络的基础上引入了可学习的动态任务驱动模块,它的作用是通过引入与当前任务相关的参数来更新特征嵌入,使每个任务都有自己不同的特征提取模块,从而提高分类模型的泛化能力。其次,为了克服由于训

练模型更加复杂,而导致的训练过程困难问题,本文在训练阶段利用辅助任务进行协同训练。最后,为了充分利用数据,本文用转导学习代替归纳学习,即将带有标签的训练集样本和不带标签的测试集样本都输入到网络中进行训练,然后再预测测试集中样本的标签,从而达到提高分类准确率的目的。

1 问题定义

本章主要介绍元学习问题的定义,要对其进行阐述,首先得从 N -way K -shot 问题着手:测试集的每一类中都只有 K 个样本的标签是已知的,且测试集中共含有 N 个类别,也就是说本文的任务是利用这 NK 个已知标签的样本,预测测试集中其他无标签样本的类别。元学习的特点是片段训练方式,为了模拟小样本分类中的 N -way K -shot 任务,每个片段都从样本标签全部已知的训练集中随机抽取 N 个类别,然后再从每个类别中随机抽取 K 个样本,这 NK 个有标签的样本组成某个元学习任务的支持集 $S = \{(x_i, y_i)\}_{i=1}^{NK}$ 。接下来,本文从每个类别剩下的样本中随机抽取 P 个样本模拟标签未知的测试集样本,这些未知标签的样本组成某个元学习任务的查询集 $Q = \{x_j\}_{j=1}^P$,重复以上步骤 M 次,便可以得到 M 个元学习任务,在这 M 个任务上训练任务驱动元的元学习模型,最后利用训练好的模型对测试集中无标签的样本进行分类^[14],某个 5-way 1-shot 学习任务,如图 1 所示,支持集中共含有 5 个已知标签的样本,查询集中含有 1 个待预测的样本。




图 1 基于图神经网络的任务驱动元学习方法的工作流程

接下来本文对图分类问题进行介绍,图结构由节点和边组成,本文将样本的特征和他们对应的标签级联后的向量看作节点 v (式(1)),将样本之间的相似度看作边,边上的权重组成的矩阵叫做邻接矩阵 A ,然后利用图神经网络不断更新节点特征和边缘特征(式(2)和(3)),使其充分挖掘样本之间的关系,最终得到样本与样本之间的相似度矩阵 B (将 A 逐行归一化后的矩阵)。

$$\begin{cases} v_i = (f(x_i), h(l_i)), \forall i = 1, \dots, NK \\ v_j = (f(x_j), K^{-1}1_K), \forall j = 1, \dots, P \end{cases} \quad (1)$$

式中: $f(\cdot)$ 表示特征提取网络;对于已知标签的支持集样本, $h(l)$ 表示标签的独热编码;对于未知标签的样本, $h(l)$ 表示均匀分布函数。

$$\Lambda_{i,j}^l = MLP_{\theta}(\text{abs}(V_i^l - V_j^l)) \quad (2)$$

式中: $\text{abs}(\cdot)$ 表示绝对差值函数; MLP 表示多层感知机; $\Lambda_{i,j}^l$ 表示第 l 层中矩阵 A 的第 i 行第 j 列元素; θ 表示一系

列可学习的训练参数。

$$V_i^{l+1} = G_c(V^l) = \rho\left(\sum_{B \in A} B V^l \theta_{B,i}^l\right) \quad (3)$$

式中: $\rho(\cdot)$ 表示激活函数 Leaky ReLU; d 表示节点特征向量的行数且 $i = d_1, \dots, d_{l+1}$ 。

2 方法

本章首先介绍了任务驱动特征提取器的构造方法和相应的网络架构;然后阐述了本文是如何在节点水平上实现图像分类的;最后本文引进了协同训练的方法对任务驱动特征提取模块和分类模块进行训练。本文方法的工作流程如图 1 所示,网络架构如图 2 所示,操作步骤如算法 1 所示。

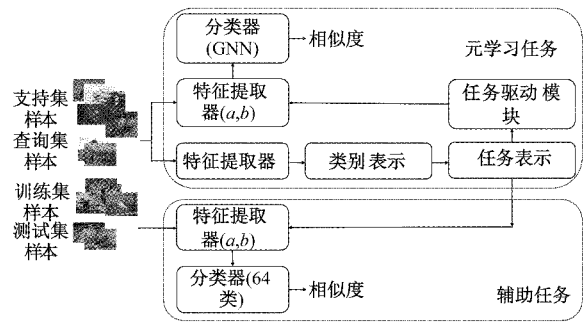


图 2 任务驱动元学习方法的网络架构可视化图

算法 1 任务驱动元学习方法的训练策略

输入: $S = \{(x_i, y_i)\}_{i=1}^{NK}$; $Q = \{x_j\}_{j=1}^P$

输出: 查询集样本的标签

对于 M 个元学习任务:

用式(4)计算 c_n , 其中 $n \in (1, N)$;

用式(5)计算 t_m , 其中 $m \in (1, M)$;

用式(6)、(7)计算 h_{l+1} ;

用式(1)将 $h(x_i), h(x_j)$ 与其标签级联, 其中 $i \in (1, N)$,

$j \in (1, P)$, 得到 $V = (v_1, \dots, v_{N+P})$;

对于层数 $l=1, \dots, L$:

用式(2)计算 A^l ;

用式(3)计算 V^{l+1} ;

用邻接矩阵 B 预测查询集样本的标签;

结束

结束

2.1 任务驱动特征提取模块

现存的元学习方法利用大量的分类任务训练特征提取器,并且默认为特征提取器提取到的样本特征与任务无关,即特征提取模块和当前的任务是独立的,这在一定程度上限制了分类模型的泛化能力。为了训练基于任务的特征提取器,本文在原有特征提取模块的基础上,引入了任务驱动模块,它的作用是通过生成与任务相关的参数 a 和 b , 改变

原始的特征向量使其与任务相关。本文通过在批规范层后面加入任务驱动模块来获得参数 a, b , 并将其作为放缩和平移系数来更新特征向量, 最后将任务驱动模块的输出(更新后的特征向量)与原始特征向量相结合获得与任务相关的可分类向量。

首先, 本文通过将原始特征向量的类别表示 c (式(4))取平均, 来获得任务表示 t (式(5)), 并以 t 为任务驱动模块的输入, 更新卷积块输出的样本特征向量。具体操作步骤为: 利用两个全连接残差网络 g, h 对任务表示 t 进行处理, 并以两个初始值为 0 的可学习参数 a_0, b_0 为权重, 经过放缩和平移获得参数 a, b (式(6))。然后, 将 a 作为放缩系数, b 作为平移系数, 来更新卷积层输出的特征向量 h (式(7))。

$$c_n = \sum_{i=1}^K x_i \quad (4)$$

式中: c_n 表示第 n 类样本的类别表示; x_i 表示第 i 个样本的初始特征向量。

$$t_m = \frac{1}{N} \sum_{n=1}^N c_n \quad (5)$$

式中: t_m 表示第 m 个任务的任务表示。

$$\begin{cases} a = a_0 g(t) + 1 \\ b = b_0 h(t) \end{cases} \quad (6)$$

$$h_{l+1} = a \times h_l + b \quad (7)$$

式中: h_l 表示第 l 层卷积层输出的特征表示。

本文的任务驱动特征提取模块以 ResNet-12 为基础, 它由 4 个残差块(Residual block)组成, 并且每个残差块都包含 4 个卷积块(Conv block), 其中 1 个卷积块用于提取原始特征向量, 包含 1 个卷积层和 1 个批规范层(batch normalization, BN), 其他 3 个卷积块用于提取与任务相关的特征向量, 都由 1 个卷积层、1 个批规范层和 1 个任务驱动模块(task-driven module, TDM)组成, 具体的网络架构如图 3(a)、(b)所示。为了避免过拟合现象, 增强模型的抗干扰能力, 本文引入了 L_2 正则器来约束 a_0, b_0 的取值, 使其为接近于 0 的数, 其具体的参数设置见第 3.2 节。任务驱动模块具体的网络架构如图 3(c)所示。

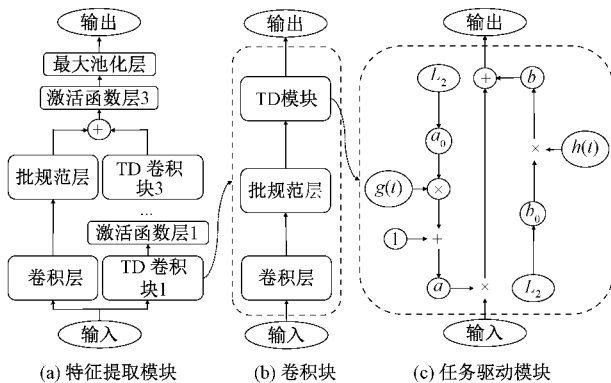


图 3 任务驱动特征提取模块的网络架构可视化图

2.2 分类模块

为了充分利用样本之间的关系, 提高分类准确率, 本文利用图神经网络(graph neural network, GNN)作为分类模块。本文首先将任务驱动特征提取模块的输出 h 与各自的类别标签级联起来, 将其看作节点, 记为: $V = (v_1, \dots, v_n)$, 其中, $n = N + P$ (N 为支持集中的类别数、 P 为查询集中样本点个数), 以节点作为图神经网络的输入, 并通过节点特征更新模块和边缘特征更新模块(网络结构如图 4 所示)来获得最终的邻接矩阵, 从而得到查询集样本和支持集类别之间的相似性。具体的操作步骤见第 1 章问题定义, 在此不再赘述。

边缘特征更新模块由 5 个全连接层组成, 其中前 4 个包含 1 个批规范化层、1 个激活函数层。节点特征更新模块由图卷积块(包含 1 个批规范层和 1 个激活函数层)和级联操作层组成, 其可视化图如图 4 所示。

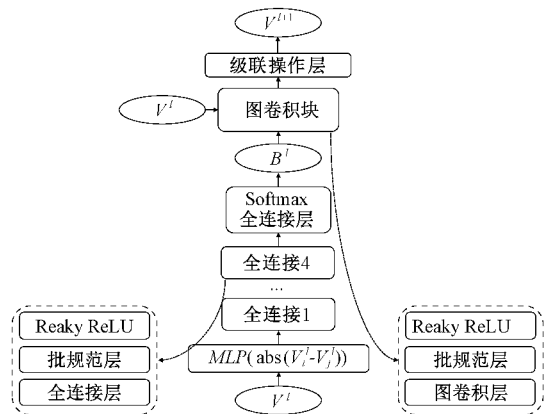


图 4 分类模块的网络架构可视化图

2.3 协同训练方法

为了减少任务驱动特征提取模块和分类模块的训练复杂度, 本文利用协同训练作为辅助任务来帮助小样本分类任务训练模型。辅助任务就是利用 MiniImageNet 和 CIFAR-FS 训练集中的样本训练一个 64 类的分类器, 且协同训练和小样本训练共用一个特征提取器。也就是说, 本文中, MiniImageNet 和 CIFAR-FS 的训练集有两个作用, 一是作为小样本分类任务的训练集(衍生出多个 5-way 1-shot 任务), 二是作为辅助任务的数据集。且辅助任务初始的训练集样本占数据集样本的 0.9, 剩下的 0.1 作为测试集样本, 本文将训练集样本所占的比例记为 P 。因为我们的最终目的是完成小样本分类任务, 所以当模型的能力随着训练次数的增加而逐渐变强时, 小样本分类任务的比重也应逐渐增加, 为了做到这一点本文将训练集样本所占的比例 P 以指数的形式退火(式(8))。由于增加了协同训练, 所以当利用损失来更新模型时, 损失来源于两部分: 小样本分类任务的损失和辅助任务的损失(式(9))。

$$P = 0.9 \left[\frac{t}{T} \right] \quad (8)$$

式中: t 表示迭代索引数(第 t 次训练); T 表示退火的迭代

间隔数(总的训练次数)。

$$Loss = L_m + L_c = - \sum_m y_m \log P(\hat{y}_m = y_m | T) - \sum_c y_c \log P(\hat{y}_c = y_c | T) \quad (9)$$

式中: L_m 表示元学习任务的损失; L_c 表示辅助任务的损失; y 为样本的真实标签; \hat{y} 为样本的预测标签; m 为元学习任务查询集中未知标签样本的个数; n 为辅助任务测试集中未知标签样本的个数。

3 实 验

本章首先介绍了实验所用的数据集 MiniImageNet 和 CIFAR-FS, 然后说明了实验过程中的参数设置, 接下来, 展示了各种对比方法以及本文方法的小样本分类准确率, 最后通过消融实验证明了图神经网络作为分类模块的优越性、任务驱动特征提取模块的有效性和先进性、协同训练方法的必要性以及转导学习方法对准确率的提升作用。

3.1 数据集

MiniImageNet: 这个数据集来自 ImageNet 数据集, 共包含 100 类别, 每个类别 600 张图像, 合计 60 000 张图像, 每幅图像的尺寸统一为 84×84 。本文选择 64 个类别作为训练集, 16 个类别作为验证集, 20 个类别作为测试集^[15]。

CIFAR-FS: 这个数据集全称为 CIFAR100 Few-Shots 数据集, 是从 CIFAR 100 数据集中选择了 60 000 张图像构成的, 共 100 个类别, 每个类别有 600 张图像。每幅图像的尺寸都为 32×32 ^[16]。本文选择 64 个类别作为训练集, 16 个类别作为验证集, 20 个类别作为测试集^[17]。

3.2 参数设置

为了模拟小样本分类任务, 本章将支持集中 N 的值设置为 5, K 的值设置为 1 和 5, 并且设置查询集中样本的个数为 15。当没有采用协同训练方法时, 本章将 MiniImageNet 和 CIFAR-FS 训练时每个批次(batch)中片段的数量分别设置为 30 000 和 20 000, 测试时每个批次(batch)中片段的数量设置为 30 000。在采用协同训练的情况下, 由于辅助任务的加入, 网络的训练难度大大降低, 所以本章将 MiniImageNet 和 CIFAR-FS 训练时每个批次(batch)中片段的数量分别设置为 20 000 和 10 000, 测试时每个批次(batch)中片段的数量设置为 20 000。并且将训练和测试时的批次数量(batch size)分别设置为 4 和 8。本文使用随机梯度下降法优化模型, 并将优化算法的动量设置为 0.9, 初始学习率设置为 0.1, 并且每隔 2 000 个片段学习率下降到 0.006, 0.001 2, 0.002 4 等。每个辅助任务都是从训练集中随机的抽取 64 个样本, 并且协同训练学习率下降频率与小样本分类任务中的学习率下降频率保持一致。关于网络架构, 本文将 ResNet block 的滤波器数目设置为 64、128、256、512, 卷积核的尺寸设置为 3×3 , 最大池化的尺寸设置为 2×2 , 并且为了避免过拟合, 将每一层中正则器的权重在 0.01 处进行交叉验证, 此外, 将任务驱动特征提取

模块的网络深度设置为 3, 具体原因见 3.4 节。本文的实验均在两台 NVIDIA GTX 1080Ti GPUs 上进行, 并用 Pytorch 语言在 Ubuntu 16.04 环境下编写, 本文中对比方法的设置与原论文一致。

3.3 实验结果

本文在 MiniImageNet 和 CIFAR-FS 数据集上, 分别做了多组 5-way 1-shot 和 5-way 5-shot 实验, 实验结果如表 1、2 所示。本文将基于参数优化的元学习方法 MAML、基于度量学习的元学习方法 Matching Network、Prototypical Network、GNN 以及转导传播网络 TPN 作为对比方法。并且为了进一步提高分类准确率, 本文将各种对比方法分别做了转导学习设置下的实验(T 表示转导学习设置, I 表示归纳学习设置)。

如表 1 所示, 本文的方法在 MiniImageNet 数据集上, 与基于参数优化的元学习方法 MAML 相比, 准确率在 5-way 1-shot 和 5-way 5-shot 设置下提升了 10.94% (48.70% VS 59.64%) 和 10.05% (66.19% VS 76.24%)。与基于度量学习的元学习方法相比, 本文方法的准确率在 5-way 1-shot 和 5-way 5-shot 设置下都获得了较大地提升, 且提升了 6.91% (66.41% VS 73.32%)。且同样在转导学习的设置下, 本文的方法与 TPN 相比, 准确率在 5-way 1-shot 和 5-way 5-shot 设置下提升了 6.81% (69.43% VS 76.24%)。

表 1 MiniImageNet 数据集上的小样本分类准确率

		%	
方法		5-way 1-shot	5-way 5-shot
MatchingNet	I	(43.56±0.84)	(55.31±0.73)
MatchingNet	T	(44.20±0.00)	(57.00±0.00)
MAML	I	(48.70±1.84)	(63.11±0.92)
MAML	T	(50.83±0.00)	(66.19±0.00)
PrototypicalNet	I	(46.61±0.78)	(65.77±0.70)
PrototypicalNet	T	(49.42±0.78)	(68.20±0.66)
GNN	I	(50.33±0.36)	(66.41±0.63)
GNN	T	(52.78±0.00)	(66.42±0.00)
TPN	T	(53.75±0.00)	(69.43±0.00)
本文方法	I	(59.64±0.63)	(73.32±0.84)
本文方法	T	(62.75±0.43)	(76.24±0.41)

如表 2 所示, 本文的方法在 CIFAR-FS 数据上, 与基于参数优化的元学习方法 MAML 相比, 准确率在 5-way 1-shot 和 5-way 5-shot 设置下提升了 9.51% (58.90% VS 68.41%) 和 11.80% (73.40% VS 85.20%)。与基于度量学习的元学习方法相比, 本文方法的准确率提升了 6.51% (61.90% VS 68.41%)。本文的方法与 TPN 相比, 在 5-way 1-shot 和 5-way 5-shot 设置下, 准确率提升了 6.20% (65.60% VS 71.80%)。

表 2 CIFAR-FS 数据集上的小样本分类准确率 %

方法		5-way 1-shot	5-way 5-shot
MatchingNet	I	—	—
MatchingNet	T		
MAML	I	(58.90±1.90)	(71.50±1.12)
MAML	T	(60.10±0.81)	(73.40±0.74)
PrototypicalNet	I	(55.50±0.70)	(72.00±0.60)
PrototypicalNet	T	(56.70±0.99)	(72.90±0.77)
GNN	I	(61.90±0.00)	(75.30±0.00)
GNN	T	(63.40±0.83)	(77.50±0.10)
TPN	T	(65.60±0.11)	(78.30±0.30)
本文方法	I	(68.41±0.36)	(83.54±0.84)
本文方法	T	(71.80±0.70)	(85.20±0.68)

此外,如表 1、2 所示,由于转导学习能够将无标签的样本充分利用起来,故各种对比方法的准确率都有不同程度的提升。在 MiniImageNet 数据集上,对比方法的准确率至少提升了 0.01% (66.41% VS 66.42%),在 CIFAR-FS 数据集上,对比方法的准确率至少提升了 0.90% (72.00% VS 72.90%)。且本文的方法在加入转导学习后,在 MiniImageNet 和 CIFAR-FS 数据集上准确率至少提升了 1.66% (83.54% VS 85.20%)。


3.4 消融实验

1) 特征提取网络层数对分类准确率的影响

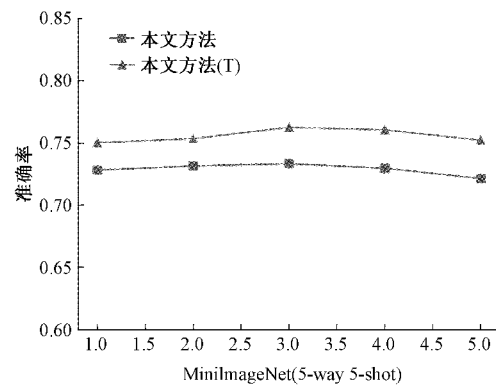
为了探究任务驱动特征提取模块的网络层数(网络深度)对分类准确率的影响,本章做了网络层数(层数=1,2,3,4,5)与分类准确率之间的消融实验,结果如图 5 所示。其中,图 5(a)、(b)分别表示本文方法(加转导学习和不加转导学习)在 MiniImageNet 数据集上 5-way 1-shot 和 5-way 5-shot 设置下的分类准确率;图 5(c)、(d)分别表示本文方法(加转导学习和不加转导学习)在 CIFAR-FS 数据集上 5-way 1-shot 和 5-way 5-shot 设置下的分类准确率。如图 5(a)~(d)所示,无论加不加转导学习,最高的分类准确率均在层数为 3 时取得,这是因为,随着网络层数的不断增加(大于 3),提取到的特征更加抽象,从而与原始特征的相关性越来越低,故模型分类准确率有所下降,本文将任务驱动特征提取模块的网络层数设为 3。

2) 分类模型中各个模块对分类准确率的影响


为了证明分类模型中各个模块的作用,本章通过改变各个模块,观察分类准确率的变化,其可视化图如图 6 所示。其中,图 6(a)、(b)分别表示在 MiniImageNet 数据集和 CIFAR-FS 数据集上各个模块的变化对分类准确率的影响。首先在原型网络(基于余弦距离)的基础上将度量方式从欧氏域映射到非欧氏域,准确率在两个数据集上都有不同程度地提升,从而证明了图神经网络分类模块的先进性。然后,在特征提取模块中引入了任务驱动模块(task-driven, TD),准确率不但没有提升反而有所下降,这是由




(a) MiniImageNet(5-way 1-shot)分类准确率



(b) MiniImageNet(5-way 5-shot)分类准确率



(c) CIFAR-FS(5-way 1-shot)分类准确率



(d) CIFAR-FS(5-way 5-shot)分类准确率

图 5 不同特征提取网络层数下的分类准确率

于任务驱动模块的加入,额外增加了计算量。为了缓解这

一现象,本文引入了协同训练(collaborative training, CT)的方法。

如图 6(a)、(b)所示,由于辅助任务的加入,在 MiniImageNet 数据集上 5-way 1-shot 和 5-way 5-shot 设置下准确率分别提升了 9.51% (50.13% VS 59.64%) 和 8.08% (65.24% VS 73.32%);在 CIFAR-FS 数据集上 5-way 1-shot 和 5-way 5-shot 设置下准确率分别提升了 8.28% (60.13% VS 68.41%) 和 8.52% (75.02% VS 83.54%),由此证明了协同训练方法的必要性。转导学习方法确实能提升分类准确率,在 5-way 1-shot 和 5-way 5-shot 设置下准确率提升了 3.11% (59.64% VS 62.75%) 和 1.66% (83.54% VS 85.20%)。

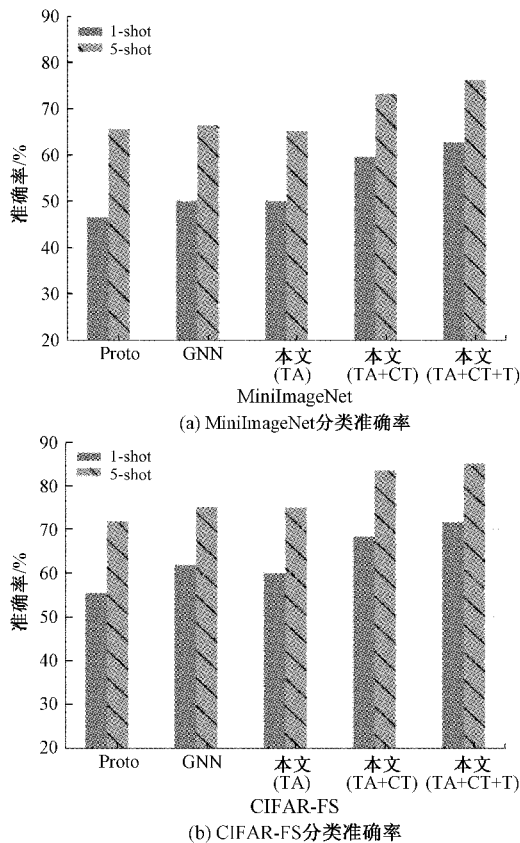


图 6 不同网络结构下的分类准确率

4 结 论

本文在传统特征提取网络的基础上引入了任务驱动模块,它能有效地提取与任务相关的信息,并更新网络模型,使模型的泛化能力大大提高。针对额外增加的计算量,本文通过协同训练生成辅助任务,帮助小样本分类任务训练分类模型,实验结果表明此方法有效地提高了分类效率。最终的分类模块,本文将度量方式从欧氏域映射到非欧氏域,目的是通过形成图模型来充分利用样本之间的相关信息。为了克服小样本分类任务中标记样本匮乏的弊端,本

文用转导学习代替归纳学习,达到将无标记样本充分利用起来的目的。在 MiniImageNet 和 CIFAR-FS 数据集上的实验结果表明本文的任务驱动元学习方法优于对比方法。在接下来的工作中,会将此方法扩展到零样本分类以及文本和视频分类的领域上去。

参考文献

- [1] 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.
- [2] JAMAL M A, QI G J. Task agnostic meta-learning for few-shot learning[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 11719-11727.
- [3] GUO Y, CHEUNG N M. Attentive weights generation for few shot learning via information maximization [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 13499-13508.
- [4] 王建华,冉煜琨. 基于深度神经网络和模糊规则的文本分类方法[J]. 电子测量技术, 2021, 44(10): 75-81.
- [5] MUNKHDALAI T, YU H. Meta networks [C]. International Conference on Machine Learning (PMLR), 2017: 2554-2563.
- [6] CAI Q, PAN Y, YAO T, et al. Memory matching networks for one-shot image recognition [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4080-4088.
- [7] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]. Proceedings of the 31st International Conference on Neural Information Processing Systems, 2017: 4080-4090.
- [8] SUNG F, YANG Y, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 1199-1208.
- [9] VINYALS O, BLUNDELL C, LILICRAP T, et al. Matching networks for one shot learning [C]. Proceedings of the 30th International Conference on Neural Information Processing Systems, 2016: 3637-3645.
- [10] 周嫣然,罗毛欣,赵博. 基于多分辨率特征提取网络的图像相似度学习[J]. 国外电子测量技术, 2021, 40(5): 27-32.
- [11] HU Z, DONG Y, WANG K, et al. Gpt-gnn: Generative pre-training of graph neural networks[C]. Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining,

- 2020; 1857-1867.
- [12] WANG Y, YAO Q, KWOK J T, et al. Generalizing from a few examples: A survey on few-shot learning[J]. ACM Computing Surveys (CSUR), 2020, 53(3): 1-34.
- [13] SHANTHAKUMAR S, SHAKILA S, SUNETH P, et al. Environmental sound classification using deep learning[J]. Instrumentation, 2020, 7(3): 15-22.
- [14] GIDARIS S, KOMODAKIS N. Generating classification weights with gnn denoising autoencoders for few-shot learning[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 21-30.
- [15] SUN Q, LIU Y, CHUA T S, et al. Meta-transfer learning for few-shot learning[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 403-412.
- [16] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [17] GIDARIS S, BURSUC A, KOMODAKIS N, et al. Boosting few-shot visual learning with self-supervision[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 8059-8068.

作者简介

李明, 硕士研究生, 主要研究方向为模式识别与智能系统。

E-mail: Lconalm529@163.com

赵文仓, 教授, 主要研究方向为模式识别与智能系统。

E-mail: 2810832145@qq.com

秦文谦, 硕士研究生, 主要研究方向为模式识别与智能系统。

E-mail: 732598684@qq.com