

基于元学习的图卷积网络少样本学习模型

刘鑫磊^{1,4}, 冯林^{1*}, 廖凌湘¹, 龚勋², 苏菡¹, 王俊³

(1. 四川师范大学计算机科学学院, 四川成都 610100; 2. 西南交通大学计算机与人工智能学院, 四川成都 611730;
3. 四川师范大学商学院, 四川成都 610100; 4. 资阳市公安局网络安全保卫支队, 四川资阳 641399)

摘要: 少样本学习是目前机器学习研究领域的热点和难点. 针对现有的少样本学习模型不能有效捕捉数据特征与数据标签之间的联系, 造成分类模型泛化能力弱的问题, 提出一种基于元学习的原型空间图卷积网络少样本学习模型 FSL-GCNPS (Few-Shot Learning of Graph Convolutional Network on Prototype Space). 首先, 利用卷积神经网络提取多任务数据的特征向量; 其次, 为了将特征向量映射到原型空间中, 根据元学习的训练策略得到特征向量的类原型表达; 然后, 通过类原型向量和类向量之间的嵌入表示, 构建图结构数据, 并进行图卷积网络训练、推理. 实验结果表明, 相较于经典少样本学习方法, FSL-GCNPS 模型拥有更好的分类准确率和分类稳定性. 同时, 在医学图像领域数据集上实验表明, FSL-GCNPS 具有很好的跨域适应性.

关键词: 元学习; 图卷积网络; 卷积神经网络; 少样本学习; 原型空间

基金项目: 国家自然科学基金(No.61876158, No.71971151); 四川省重点研发项目(No.23ZDYF1810)

中图分类号: TP181

文献标识码: A

文章编号: 0372-2112(2024)03-0885-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20220037

Few-Shot Learning on Graph Convolutional Network Based on Meta learning

LIU Xin-lei^{1,4}, FENG Lin^{1*}, LIAO Ling-xiang¹, GONG Xun², SU Han¹, WANG Jun³

(1. College of Computer Science, Sichuan Normal University, Chengdu, Sichuan 610100, China;

2. School of Computer and Artificial Intelligence, Southwest Jiao tong University, Chengdu, Sichuan 611730, China;

3. School of Business, Sichuan Normal University, Chengdu, Sichuan 610100, China;

4. Network Security Detachment, Ziyang Public Security Bureau, Ziyang, Sichuan 641399, China)

Abstract: Few shot learning is a hot and difficult problem in the field of machine learning. The existing few-shot learning model cannot effectively capture the relationships between data feature information and data label, thus causing the generalization ability of the resulting classifier would be weaker. A few-shot learning of graph convolutional network on prototype space, termed FSL-GCNPS, is developed. Firstly, the feature vectors are extracted on multi-task data by convolutional network. Secondly, in order to map the feature vectors into the prototype space, representation learning for the classes based on prototype network is proposed. Next, the graph is structured by combing the classes prototype vectors with class vectors. Then, FSL-GCNPS is trained using Meta learning. The experimental results show that FSL-GCNPS has better cross-domain adaptability in the medical image domain compared with the traditional deep learning models. Meanwhile, the FSL-GCNPS model has better classification accuracy and classification stability compared with the classical Few-shot learning algorithm.

Key words: meta learning; graph convolutional network; convolutional neural network; few-shot learning; prototype space

Foundation Item(s): National Natural Science Foundation of China (No.61876158, No.71971151); Key R&D Projects in Sichuan Province (No.23ZDYF1810)

1 引言

深度学习模型^[1]在大量有标注的数据分类应用中取得了突破性成功^[2-4]。但在一些应用场景中,如医学图像领域,大量标注需要专业医生完成,标注代价高、标注周期长。因此如何利用少量标注的数据建模,是当前机器学习领域研究的热点与难点。

少样本学习(Few-shot learning)^[5]具有从少量标注数据中获取知识并通过获得的知识来判别未知数据类别的能力。目前,元学习模型是少样本学习的主流方法,它主要分为四类。一是基于迁移学习的方法,该方法的主要思路是在一个具有充足数据量的源域数据集中预训练一个少样本学习模型,然后利用目标域数据集中的部分数据进行微调训练,使模型可以适应目标域的测试任务并提高模型的泛化能力。其中,余游等人^[6]提出的FSLSS是基于半监督的关系型分类模型,先通过源域数据集对关系型深度网络进行预训练,然后利用预训练的关系型网络获取目标域数据的伪标签,最后进行伪标签数据和真实数据的混合训练来提升模型的泛化能力;代磊超等人^[7]提出的Fast-FSL是基于添加随机噪声的模型,先通过核密度估计和图像滤波的方法向训练任务中加入多种类型的随机噪声,然后基于原型网络构建多个异构的基分类器,最后利用投票机制对基分类器进行融合来提高模型的分类精度。二是基于度量学习的方法,该类方法的通常由两部分组成:第一部分为特征提取器,旨在把数据嵌入到向量空间;第二部分为基于度量的分类器,用以计算数据样本之间的度量距离进行分类。如Vinyals等人^[8]提出的匹配网络(Matching Networks)是基于注意力机制的模型,在给定输入的情况下,利用注意力机制产生的联想记忆指定对应的实例并检索标签;Snell等人^[9]提出的原型网络(Prototypical Networks)基于不同的类别数据都存在一个数据原型点的基本假设,采用求取均值的方法将支持集数据嵌入到原型空间得到每个类别的原型表达,通过度量未知数据和原型点之间的欧式距离进行分类;Sung等人^[10]提出的关系型网络(Relation Network)定义了一个自适应计算已知类别数据和未知类别数据之间关系的网络,将数据的特征向量拼接后输入到关系网络中以计算关系得分的方式进行分类。三是基于贝叶斯理论的元学习方法,该类方法的目的是从训练任务中学习先验知识,然后基于贝叶斯理论利用先验知识对模型进行初始化操作,如Amit等人^[11]提出的基于泛化边界误差的元学习模型,针对观察训练任务的假设分布来学习新的任务分布,并通过可计算理论(Probably Approximately Correct, PAC)给出每个训练任务及总体的任务误差边界。四是基于基础学习与元学习器框架结合的方法,此类方法是在元学习

的基础之上与其他的学习方法相融合,以求获得更好的分类精度和模型泛化能力,如Finn等人^[12]提出的模型无关自适应模型(Model-Agnostic Meta-Learning, MAML),它由内循环和外循环两层循环构成,针对大量的训练任务,通过内循环的少量迭代训练来完成模型对不同训练任务的适应,然后外循环的梯度更新让模型拥有可以更好适应不同任务的初始化参数,增加模型的泛化能力;Zhang等人^[13]提出的基于任务对抗的元学习模型(MetaGAN),通过构建一个基于任务的对抗生成器,从已有的任务数据中生成大量的新任务数据进行训练,从数据生成的角度来解决少样本学习问题,Zhou等人^[14]提出的基于图元学习的少样本节点分类模型(Meta-GNN),通过构建基于元学习的图神经网络训练框架,在非欧式空间利用元学习的方法解决数据训练的问题;Kim等人^[15]提出的边标签图卷积网络(Edge-labeling Graph Neural Network, EGNN)在基于元学习的图神经网络的训练框架中,考虑通过学习预测数据标签的方式来显性的表达类内的相似性和类间的差异性,进而增强模型的分能能力。

上述模型在实际应用中存在两方面不足:(1)在源域与目标域特征分布差异大的情况下,会导致分类模型严重的过拟合,造成分类的准确率低;(2)传统的少样本学习算法都是通过大量任务数据的端到端训练,来迫使特征提取器把数据映射到更适合模型分类器进行判别的高维空间中,没有注意数据特征和数据标签之间的关系,无法建立数据特征和数据标签之间的联系并将数据特征中的信息传递到数据标签中进行分类。针对这些问题,本文采用多任务训练的元学习策略,提出了一种基于原型空间的图卷积网络少样本学习方法(Few-shot Learning of Graph Convolutional Network on Prototype Space, FSL-GCNPS)。

本文的主要贡献如下:

(1)提出了一种利用特征向量的类原型嵌入来生成图顶点集的方法,建立起数据特征和数据标签之间的联系。采用FSL-GCNPS模型中的特征提取网络提取出训练任务数据的特征向量,通过求取均值的方式得到训练任务支持集特征向量的类原型嵌入,增强模型的特征提取能力和泛化能力。

(2)提出了一种自适应的边更新函数来生成图边集的方法。采用FSL-GCNPS模型中的V2E网络(Vertex to Edge)对图顶点集中任意两点间的差向量进行自适应处理产生图顶点间的权重值,提升图卷积网络聚合节点信息的效率。

(3)根据半监督学习理论,引入辅助训练系数,利用无标签实例辅助训练有标签实例,以提升模型性能。

(4)根据FSL-GCNPS模型在医学图像少样本数据

集和少样本领域的经典数据集上的实验,分析模型的跨域适应性、分类准确率和分类稳定性,研究 FSL-GCNPS 的效度.

2 理论基础

2.1 基于元学习策略的少样本学习概念

元学习模型是少样本学习的主流方法,它以任务 task 为基本单元,由多个 meta-training 任务训练一个分类模型 \mathcal{F} ,使 \mathcal{F} 可以快速适应到少样本的新任务上.下面,以元学习中的监督学习为例,用数学的形式化方法来阐述与本文相关的定义.

设 \mathcal{X} 为输入实例的特征空间, $p(\mathcal{T})$ 为任务 \mathcal{T} 的分布.

定义 1 meta-learning 任务集 一个 meta-learning 任务集 \mathcal{Q} 由多个 meta-training 任务 \mathcal{T}^{tr} 与多个 meta-test 任务 \mathcal{T}^{te} 组成,满足:

- ① $\mathcal{T}^{\text{tr}}, \mathcal{T}^{\text{te}} \sim p(\mathcal{T})$;
- ② $\mathcal{T}^{\text{tr}} \cup \mathcal{T}^{\text{te}} = \mathcal{D}, \mathcal{T}^{\text{tr}} \cap \mathcal{T}^{\text{te}} = \emptyset$;
- ③ $\forall \mathcal{T}_i, \mathcal{T}_k \in \mathcal{T}^{\text{tr}}, \mathcal{T}_i \neq \mathcal{T}_k$.

其中, $p(\mathcal{T})$ 为任务 \mathcal{T} 的分布.通常,一个任务与一个数据集相对应.设 $\forall \mathcal{T}_i \in \mathcal{T}^{\text{tr}}, \forall \mathcal{T}_j \in \mathcal{T}^{\text{te}}$, 分别有数据集 $\mathcal{D}_{\mathcal{T}_i}^{\text{tr}}, \mathcal{D}_{\mathcal{T}_j}^{\text{te}}$ 与之对应.

定义 2 meta-training 支持集与查询集 给定 meta-training 任务集 $\mathcal{T}^{\text{tr}}, \forall \mathcal{T}_i \in \mathcal{T}^{\text{tr}}$, 其对应的数据集为 $\mathcal{D}_{\mathcal{T}_i}^{\text{tr}}, \mathcal{D}_{\mathcal{T}_i}^{\text{te}}$ 覆盖的可见类 (seen classes) 集合 $\mathcal{S}^{\text{tr}} = \{c_i^{\text{tr}} | i = 1, 2, \dots, N_{\text{tr}}\}$, 称 $\mathcal{D}_i^{\text{tr}}$ 与 $\mathcal{D}_i^{\text{te}}$ 分别为 \mathcal{T}_i 的支持集与查询集,满足:

- ① $\mathcal{D}_i^{\text{tr}} = \{(x_i^{\text{tr}}, y_i^{\text{tr}}) \in \mathcal{X} \times \mathcal{S}^{\text{tr}}\}_{i=1}^m$;
- ② $\mathcal{D}_i^{\text{te}} = \{(x_i^{\text{te}}, y_i^{\text{te}}) \in \mathcal{X} \times \mathcal{S}^{\text{tr}}\}_{i=1}^n$;
- ③ $\{y_i^{\text{te}}\}_{i=1}^n \subseteq \{y_i^{\text{tr}}\}_{i=1}^m$;
- ④ $\mathcal{D}_i^{\text{tr}} \cup \mathcal{D}_i^{\text{te}} \in \mathcal{D}_{\mathcal{T}_i}^{\text{tr}}, \mathcal{D}_i^{\text{tr}} \cap \mathcal{D}_i^{\text{te}} = \emptyset$.

其中, \mathcal{X} 为输入实例的特征空间.

定义 3 meta-test 支持集与查询集 给定 meta-test 测试任务集 $\mathcal{T}^{\text{te}}, \forall \mathcal{T}_j \in \mathcal{T}^{\text{te}}$, 设其对应的数据集为 $\mathcal{D}_{\mathcal{T}_j}^{\text{te}}, \mathcal{D}_{\mathcal{T}_j}^{\text{tr}}$ 覆盖的可见类 (seen classes) 集合 $\mathcal{S}^{\text{te}} = \{c_j^{\text{te}} | j = 1, 2, \dots, N_{\text{te}}\}$, 未覆盖的未见类 (unseen classes) 集合 $\mathcal{U} = \{c_j^{\text{u}} | j = 1, 2, \dots, N_{\text{u}}\}$, 称 $\mathcal{D}_j^{\text{train}}$ 与 $\mathcal{D}_j^{\text{test}}$ 分别为 \mathcal{T}_j 的支持集与查询集,满足:

- ① $\mathcal{D}_j^{\text{train}} = \{(x_j^{\text{train}}, y_j^{\text{train}}) \in \mathcal{X} \times \mathcal{S}^{\text{te}}\}_{j=1}^h$;
- ② $\mathcal{D}_j^{\text{test}} = \{x_j^{\text{test}} \in \mathcal{X}\}_{j=1}^l$;
- ③ $\mathcal{D}_j^{\text{train}} \cup \mathcal{D}_j^{\text{test}} \in \mathcal{D}_{\mathcal{T}_j}^{\text{te}}, \mathcal{D}_j^{\text{train}} \cap \mathcal{D}_j^{\text{test}} = \emptyset$;
- ④ $\mathcal{S}^{\text{te}} \cap \mathcal{U} = \emptyset$.

定义 4 C-way K-shot 数据集 给定 meta-learning 任务集 \mathcal{Q} , 对任意的 $\mathcal{D} \in \mathcal{Q}$, 其支持集的可见类集合为 $\mathcal{S} = \{c_i^{\text{v}} | i = 1, 2, \dots, N_{\text{v}}\}, \forall y \in \mathcal{S}, \mathcal{A}(y)$ 为 y 对应的输入实例,

称 \mathcal{D} 为 C-way K-shot 数据集,满足:

- ① $|\mathcal{S}| = C$;
- ② $|\mathcal{A}(y)| = K$.

其中, $|\cdot|$ 为集合的势.

定义 5 C-way, K-shot 元学习 给定任务集合 $\mathcal{T} = \{\mathcal{T}^{\text{tr}}, \mathcal{T}^{\text{te}}\}$, 元学习通过两阶段的训练完成使模型适应任务分布 $p(\mathcal{T})$ 的目的.第一阶段利用 \mathcal{T}^{tr} 学习任务级分类函数 \mathcal{F}^* ; 第二阶段针对不同的 meta-test 任务, 利用支持集 $\mathcal{D}_j^{\text{train}}$ 学习样本级分类函数 $f^* = \mathcal{F}^*(\mathcal{S}_{\text{te}})$, 使 f^* 完成对查询集 $\mathcal{D}_j^{\text{test}}$ 的分类. 其学习过程如下:

①训练阶段: 定义一组学习分类函数 \mathcal{F} 及 \mathcal{F} 的损失函数 L , 在 $p(\mathcal{T})$ 上随机采样一个 meta-training 任务 $\mathcal{T}_i \in \mathcal{T}^{\text{tr}}$, 利用支持集 $\mathcal{D}_i^{\text{tr}}$, 生成样本级分类函数 $f_i = \mathcal{F}(\mathcal{D}_i^{\text{tr}})$, 并在查询集 $\mathcal{D}_i^{\text{te}}$ 上计算 f_i 的损失 l_i . 重复此采样和计算过程, 计算在 $p(\mathcal{T})$ 上随机采样 N 次所获得的训练任务集合上的损失函数 $L(\mathcal{F}) = \sum_i^N l_i$, 并通过 Adam、SGD、SVGD 等优化器最小化 $L(\mathcal{F})$, 生成任务级分类函数 $\mathcal{F}^* = \arg \min_{\mathcal{F}} L(\mathcal{F})$.

②测试阶段: 在 $p(\mathcal{T})$ 上随机采样一个 meta-test 任务 $\mathcal{T}_j \in \mathcal{T}^{\text{te}}$, 利用支持集 $\mathcal{D}_j^{\text{train}}$, 生成样本级分类函数 $f_i^* = \mathcal{F}^*(\mathcal{D}_j^{\text{train}})$, 然后使用测试任务查询集 $\mathcal{D}_j^{\text{test}}$ 完成对 f_i^* 的评估.

特别地, 在训练 \mathcal{F}^* 的过程中, 也可以把训练任务集再划分为训练任务集与验证任务集.

2.2 图卷积神经网络

图卷积神经网络 (Graph Convolutional Network, GCN) 按卷积定义差异分为两种: 一种是基于频谱的 GCN, 由 Bruna 等人^[16] 在 2014 年提出, 他们基于图谱理论从卷积定理出发, 站在图信号处理的角度引入自适应的滤波器来定义图卷积; 另一种则是基于空间的 GCN, 受消息传递机制的启发, 通过一个聚合函数从邻域聚合特征信息^[17]. 图卷积神经网络的诞生, 使得模型可以捕获实例之间相互依赖的关系^[18], 传递实例之间的信息, 给深度学习的各个领域注入了新的活力. 本文采用基于频谱的 GCN.

(a) 基于频谱的 GCN: 基于频谱的 GCN 将输入的图数据假设为无向图, 先将无向图的归一化拉普拉斯矩阵进行特征分解, 得到的特征向量构成了一个标准正交空间. 然后, 因为离散积分是一种内积形式, 而傅里叶变换就是时域信号与拉普拉斯算子特征函数的积分, 可以通过图上的拉普拉斯算子定义图上的傅里叶变换为 $F(x) = U^T x$, 利用图傅里叶变换将节点映射到标准的正交空间中, 在频域进行卷积操作. 基于频谱的图卷积公式矩阵计算的形式为有输入信号 x ,

$$\mathbf{x} * \text{GCN}(h) = \mathbf{U} \begin{pmatrix} \hat{h}(\lambda_1) & & \\ & \ddots & \\ & & \hat{h}(\lambda_n) \end{pmatrix} \mathbf{U} \mathbf{x} \quad (1)$$

即

$$\begin{aligned} \mathbf{x} * \text{GCN}(g) &= \mathbf{F}^{-1}(\mathbf{F}(\mathbf{x}) \odot \mathbf{F}(g)) \\ &= \mathbf{U}(\mathbf{U}^T \mathbf{x} \odot \mathbf{U}^T g) \end{aligned} \quad (2)$$

其中, \odot 表示哈达玛积, \mathbf{F} 表示傅里叶变换, \mathbf{U} 为归一化拉普拉斯矩阵的特征向量矩阵, h 为滤波器响应函数, \hat{h} 为响应函数 h 经傅里叶变换后的函数, λ 为归一化拉普拉斯矩阵的特征值. 基于 2.2 节式(1), Bruna 等人在 2014 年将 $\text{diag}(\hat{h}(\lambda_n))$ 定义为卷积核, 第一代的图卷积公式如式(3)所示, 有输入信号 \mathbf{x} ,

$$\mathbf{y}_{\text{output}} = \sigma(\mathbf{U} \mathbf{g}_\theta(\Lambda) \mathbf{U}^T \mathbf{x}) \quad (3)$$

其中, $\mathbf{g}_\theta(A)$ 为图卷积核. 但第一代的参数方法存在计算量大、没有空间局部性等弊端. 针对这些问题, Defferrard 等人^[19]在 2016 年将 $\hat{h}(\lambda_n)$ 改为 $\sum_{j=0}^K \alpha_j \lambda_n^j$, 并引入了

空间局部性. 利用特征分解的性质 $\mathbf{L}^k = \mathbf{U} \mathbf{A} \mathbf{U}^T$ 在新的图卷积核 $\sum_{j=0}^K \alpha_j \Lambda^j$ 基础上可以得到 $\mathbf{U} \sum_{j=0}^K \alpha_j \Lambda^j \mathbf{U}^T = \sum_{j=0}^K \mathbf{U} \alpha_j \Lambda^j \mathbf{U}^T = \sum_{j=0}^K \alpha_j \mathbf{L}^j$, 第二代的图卷积公式如式(4)所示, 有输入信号 x ,

$$\mathbf{y}_{\text{output}} = \sigma\left(\sum_{j=0}^K \alpha_j \mathbf{L}^j x\right) \quad (4)$$

其中, \mathbf{L} 为归一化拉普拉斯矩阵, K 为空间局部性的 K -hot 邻域数值. Defferrard 等人还利用切比雪夫不等式逼近图卷积核的方式证明了算法的计算复杂度较第一代大幅降低. 同年, Kipf 等人^[20]令 $K=1$, 使得每层图卷积只考虑直接邻域, 进一步简化图卷积公式为: 有输入信号 \mathbf{x} ,

$$\mathbf{y}_{\text{output}} = \sigma(\tilde{\mathbf{L}}_{\text{sym}} \mathbf{x} \mathbf{w}) \quad (5)$$

$$\tilde{\mathbf{L}}_{\text{sym}} = \tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}, \tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}, \tilde{\mathbf{D}} = \mathbf{D} + \mathbf{I}$$

其中, $\tilde{\mathbf{L}}_{\text{sym}}$ 为重归一化的拉普拉斯矩阵, \mathbf{A} 为图的邻接矩阵, \mathbf{D} 为图的度矩阵, \mathbf{I} 为单位阵.

(b) 基于空间的 GCN: 基于空间的 GCN 模仿传统的卷积神经网络中的卷积运算, 根据节点的空间关系引入自适应的图位移算子来定义图的卷积. 对于图位移算子而言, 将图中的节点与其邻居节点进行聚合, 通过任务数据的训练指导该算子进行学习, 从而完成对输入图信号的针对性变换操作, 得到该节点的新表示. 为了获得节点接收域的深度与广度信息, 通常将多个图卷积层叠加在一起. 图卷积算子定义如下:

$$h_i^{(l+1)} = \sigma\left(\sum_{j \in \mathcal{N}(i)} \frac{1}{c_{ij}} W^{(l)} h_j^{(l)}\right) \quad (6)$$

其中, $h_i^{(l+1)}$ 表示节点 i 在 $(l+1)$ 层的特征信息, c_{ij} 表示归一化因子, $W^{(l)}$ 表示节点的权重, $h_j^{(l)}$ 表示节点 j 在 l 层的特征信息.

3 FSL-GCNPS 模型结构

FSL-GCNPS 模型的结构如图 1 所示, 它由图顶点集生成网络、信息传递网络两部分构成. 其中图顶点集生成网络由特征提取网络和原型空间嵌入网络构成, 主要负责图顶点集的生成, 为利用 GCN 的“传播能力”提供基础; 信息传递网络由 V2E 网络和 GCN 构成, 主要负责图边集的生成和个节点间的信息传递, 并最终完成查询集数据的标签预测(如图 2 所示). 下面, 先对这两个部分的内容进行介绍, 然后对 FSL-GCNPS 模型的训练策略进行详细地阐述.

3.1 图顶点生成网络

(a) 特征提取网络: 特征提取网络由四个卷积层、两个最大池化层以及一个全连接层组成. 其中, 卷积层的卷积核大小为 3×3 , 扩充大小为 1, 激活函数为 ReLU; 池化层的池化核大小为 2×2 . 特征提取网络的主要目的是提取图像数据的特征, 把图像数据映射到高维空间中, 使得每一张图像都变成一个高维空间的向量节点. 在 FSL-GCNPS 模型进行端到端的训练时, 以 Adam 优化算法对特征提取网络的参数进行更新. 根据定义 2, 对于 $\forall x_i^r \in \mathcal{D}_i^r$, 有

$$\xi_i = g(x_i^r) \quad (7)$$

其中, ξ_i 为图像经过特征提取后的特征向量.

(b) 原型空间嵌入: 根据 Bregman 散度理论及原型网络, 为了更好地在高维空间表示支持集类别, 使模型拥有更好的泛化性, 求取支持集每一个类别的原形表达 \mathbf{C}_k . 针对于每个支持集中的数据, 先利用特征提取网络将数据映射到高维空间中表示成若干个向量节点, 然后求取同类别向量节点的“均值”作为该类的原形表达. 根据 2.1 节的定义 2 和定义 4, 对于 $\forall x_i^r \in \mathcal{D}_i^r$, 有

$$\mathbf{C}_k = P(\xi_i) = \frac{1}{|K|} \sum_{i=1}^K \xi_i = \frac{1}{|K|} \sum_{(x_i^r, y_i^r) \in \mathcal{A} \times \mathcal{S}^r} g(x_i^r) \quad (8)$$

其中, k 为类原型点个数即标签数, $k \in \{1, 2, \dots, |S|\}$; K 为组成类原型点的向量节点个数即标签实例数,

$$K = |\mathcal{G}^{-1}(\mathbf{y})|.$$

同时, 为了奠定 GCN “传播能力”的基础, 以向量拼接的方式建立起数据和数据标签之间的隐式关系. 针对每个支持集中的训练数据, 先将类原型点所属类别标签用 one-hot 向量表示为

$$\mathbf{O}_k(\mathbf{C}_k) = [a_1 \quad \dots \quad a_k \quad \dots \quad a_{|S|}] \quad (9)$$

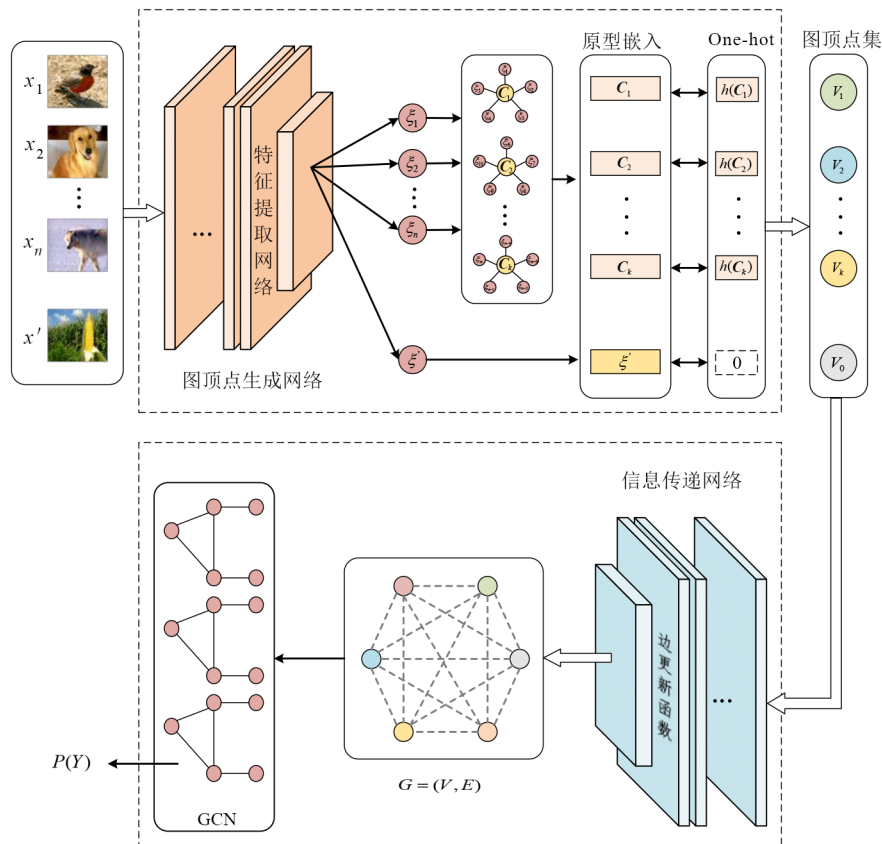


图 1 FSL-GCNPS模型描述




图 2 信息传递网络结构

其中, a_k 为 1, 其余位置均为 0, 然后将 one-hot 向量与对应类别的原型表达节点向量进行拼接, 拼接后的向量构成支持顶点集, 记为 V_s .

$$V_s = (C_k, \mathbf{O}_h(C_k)), k \in \{1, 2, \dots, |S|\} \quad (10)$$

针对每个查询集中所有的待标注数据, 为了达到支持集标签向量中的信息可以传播到查询集标签向量中的目的, 将查询集数据的标签向量全部设置为零向量, 并与其特征向量进行拼接, 拼接后的向量构成查询顶点集, 记为 V_q . 根据定义 2, 对于 $\forall x_j^{lc} \in \mathcal{D}_i^{lc}$, 有

$$V_q = (\xi_j, 0), \xi_j = g(x_j^{lc}) \quad (11)$$

其中, 0 为和 $\mathbf{O}_h(C_k)$ 相同维度的零向量. 支持顶点集和查询顶点集构成图顶点集, 记为 V .

$$V = V_s \cup V_q \quad (12)$$

图顶点集的构建策略见算法 1.

3.2 信息传递网络

(a) V2E 网络: 如何构建边更新函数是将图像数据转换成图结构数据过程中的难点问题, 边更新函数的构建质量直接影响 GCN“传播能力”的表达. 因此, 受 Relation Networks^[9]和 GNN^[21]的启发, 先利用差值函数计算图顶点集中任意两点之间的差异, 对于

算法1 图顶点集的构建策略输入:meta-training任务集 \mathcal{T}^r .输出:图顶点集 V .

1. 根据定义2,随机采样任务 $\mathcal{T}_i \in \mathcal{T}^r$,获得 \mathcal{T}_i 的支持集 \mathcal{D}_i^r 与查询集 \mathcal{D}_i^q ;
2. 取出 \mathcal{D}_i^r 中的图像实例集;
3. FOR $i=0$ TO $|\mathcal{A} \times \mathcal{S}^r|$
4. 根据式(7),对 $\forall x_i^r \in \mathcal{D}_i^r$ 得到 x_i^r 的特征向量 $\xi_i = g(x_i^r)$;
5. 根据式(8),对 ξ_i 求原型表达 $C_k = P(\xi_i)$;
6. END FOR
- 根据式(10),将 C_k 和对应类的one-hot编码 $O_h(C_k)$ 拼接得到支持顶点集 V_i ;
8. 取出 \mathcal{D}_i^q 中所有的图像实例集;
9. FOR $j=0$ TO $|\mathcal{A} \times \mathcal{S}^q|$
10. 根据式(7),对 $\forall x_j^q \in \mathcal{D}_i^q$ 得到 x_j^q 的特征向量 $\xi_j = g(x_j^q)$;
11. 根据式(11),将 ξ_j 和零向量拼接得到查询顶点集 V_j ;
12. END FOR
13. 根据式(12),得到图顶点集 $V = V_i \cup V_j$;
14. 输出图顶点集 V .

 $\forall (v_i, v_j) \in V$, 有

$$\begin{aligned} v' &= v_i - v_j \\ &= [a_1 - b_1 \quad a_2 - b_2 \quad \dots \quad a_n - b_n] \\ &= [C_1 \quad C_2 \quad \dots \quad C_n] \end{aligned} \quad (13)$$

其中, $v_i = [a_1 \quad a_2 \quad \dots \quad a_n]$, $v_j = [b_1 \quad b_2 \quad \dots \quad b_n]$.

同时,为了扩大图顶点之间的差异,采用平方函数对差异向量 v' 进行处理得到两点之间的度量向量 d_{ij}^E ,有

$$d_{ij}^E = \tau(v') = [C_1^2 \quad C_2^2 \quad \dots \quad C_n^2] \quad (14)$$

然后将 d_{ij}^E 输入到由卷积核为 1×1 的4个卷积层组成的V2E网络中,自适应的去构建图结构数据.

$$E_{ij} = \varphi(d_{ij}^E) \quad (15)$$

其中, φ 为V2E网络所构建出的边更新函数.

(b)GCN: Li和Xu等人在2018年的研究表明^[22,23], GCN模型在层数堆叠上存在阈值,当堆叠层数超过阈值,会造成严重的过平滑问题,导致模型分类能力急剧下降.为了避免这一问题,本文参考GNN^[21],使用两层的GCN模型.如图2所示,先将由图顶点集合 V 和图边集 E 构成的无向完全图输入到图卷积网络中,计算出图的重归一化拉普拉斯矩阵 \tilde{L}_{sym} ,并将 \tilde{L}_{sym} 和图顶点集中的点作为第一层的输入,经过GCN的聚合后输出更新后的点信息,记为

$$v^1 = \text{GCN}(v^0) = \sigma(\tilde{L}_{\text{sym}} v^0 w) \quad (16)$$

然后V2E网络以 v^1 输入更新无向完全图的权值,再次计算 \tilde{L}_{sym} ,将 \tilde{L}_{sym} 和 v^1 作为第二层的输入,经过

GCN的再次聚合后输出无标签数据的概率值,记为

$$P(Y) = \text{GCN}(v^1) = \sigma(\tilde{L}_{\text{sym}} v^1 w) \quad (17)$$

图边集的构建策略见算法2.

算法2 图边集的构建策略输入:图顶点集 V .输出:图边集 E .

1. FOR $i=0$ TO $|V|$
2. 从图顶点集中取出节点 v_i ;
3. FOR $j=0$ TO $|V|$
4. 从图顶点集中取出节点 v_j ;
5. 根据式(13),计算差异向量 $v' = v_i - v_j$;
6. 根据式(14),计算度量向量 $d_{ij}^E = \tau(v')$;
7. 根据式(15),计算边权重值 $E_{ij} = \varphi(d_{ij}^E)$;
8. $E \leftarrow E_{ij}$ /*将 v_i, v_j 形成的边 E_{ij} 放入图边集 E */;
9. END FOR
10. END FOR
11. 输出边集 E .

3.3 FSL-GCNPS的训练策略

根据以上讨论,FSL-GCNPS的训练首先在训练集中划分出训练任务集和测试任务集,然后将训练任务集中的任务数据输入到图顶点生成网络中生成图顶点集,再将图顶点作为输入并通过V2E网络构建图结构数据,最后利用GCN的推理能力判别出图结构数据中未知数据的类别,详见算法3.

算法3 FSL-GCNPS学习策略

输入:任务集 \mathcal{Q} 以及参数 C, K, λ /* C 代表分类种类, K 代表每一类的样本数, λ 为辅助训练系数;Times为训练次数.*/

输出:分类模型 Ω .

1. 根据定义2,从任务集 \mathcal{Q} 中划分出训练任务集 \mathcal{T}^r 和测试任务集 \mathcal{T}^q ;
2. 初始化模型中所有网络的参数;
3. IF Times > 0
4. 按照算法1的步骤得到图顶点集 V ;
5. IF $\lambda \neq 0$
6. 按照算法4的步骤得到辅助训练支持点集 V_i ;
7. $V = V + V_i$ /*将 V_i 并入图顶点集 V 中*/
8. END IF
9. 按照算法2的步骤得到图边集 E ;
10. 根据图 $G = (V, E)$,计算图的邻接矩阵 A ,度矩阵 D ,求取 \tilde{L}_{sym} ;
11. 将 $V, \tilde{L}_{\text{sym}}$ 输入到GCN中得到 X_{gn} 的分类概率矩阵 η ;
12. 根据分类概率矩阵 η 得出待分类样本的预测标签 Y ;
13. 根据定义5,计算损失 L ;
14. 利用梯度下降算法反传 Loss,调整模型参数;
15. END IF
16. 输出分类模型 Ω ,算法结束.

4 实验及结果分析

为了验证 FSL-GCNPS 模型的效果,实验分为三个部分:(1)与其它经典少样本学习算法的对比实验;(2)验证 FSL-GCNPS 在半监督学习以及辅助训练下的模型效果并分析辅助训练系数 λ 对 FSL-GCNPS 模型分类效果的影响;(3)在医学图像数据集 miniMedMNSIT 上验证 FSL-GCNPS 的跨域适应性.

实验数据集:实验 1、实验 2 选用少样本学习经典评估数据集 Omniglot 和 miniImageNet;实验 3 使用本课题组在 Yang 等人^[24]提出的 MedMNIST 数据集的基础上构

建的少样本医学图像数据集 miniMedMNIST. Omniglot 数据集包含来自 50 个不同字母的 1 623 个不同手写字符. 每一个字符都是由 20 个不同的人通过亚马逊的 Mechanical Turk 在线绘制的. miniImageNet 数据集包含动物、植物等在内的 100 个不同的常见类别,每个类别含有 600 张不同的图片,共计 60 000 张图片. 如图 3 所示,miniMedMNSIT 数据集包含医学病理图像、X 光片等多种不同领域的医疗图像,含有结肠癌、皮肤癌等在内的 7 种不同的疾病种类,每种疾病又按照医学标准分为若干等级的疾病类别,每个类别含有 100 张图片,共计 2 900 张不同的疾病病理图片.




图 3 miniMedMNIST 数据集

实验采用的硬件环境为 NVIDIA Tesla V100-SXM2 GPU 平台;软件环境为 Linux 系统、Python 编程语言、Pytorch 深度学习框架.

4.1 实验 1:与经典少样本学习算法的对比实验

实验 1 主要目的是评估 FSL-GCNPS 模型与其它经典少样本学习算法的性能. 为此,以分类准确率为标准给出了 FSL-GCNPS 模型与其它经典少样本学习算法的实验对比. 实验参数设置:如表 1 所示,针对于两个数据集,令 $C = 5, K = 1$ 或 5,学习率=0.000 3,分别设置成 5-way 1-shot 和 5-way 5-shot 两组实验.

表 1 实验 1 的模型参数

	数据集	批量大小	迭代次数	λ
5-way 1-shot	Omniglot	256	100 000	2
	miniImaeNet	64	60 000	5
5-way 5-shot	Omniglot	128	80 000	2
	miniImaeNet	32	80 000	1

实验方法如下:

Step1: 根据定义 1,把 miniImageNet 数据集划分为训练任务集(64 类)、验证任务集(16 类)、测试任务集(20 类);Omniglot 数据集划分为训练任务集(前 1 200 类)和测试任务集(后 423 类).

Step2: 根据定义 2,把训练任务集分为训练任务支

持集和训练任务查询集,按照算 3 的步骤训练模型得到分类函数 $\mathcal{F}_{\text{mini}}^*$ 和 $\mathcal{F}_{\text{ogt}}^*$.

Step3: 根据定义 2 和定义 5,把验证任务集分为验证任务支持集和验证任务查询集,按照算 3 的步骤去验证分类函数 $\mathcal{F}_{\text{mini}}^*$ 的有效性.

Step4: 根据定义 3,把测试任务集分为测试任务支持集和测查询集,按照算法 3 的步骤生成分类模型 f_{mini}^* 、 f_{ogt}^* ,并测试 f_{mini}^* 、 f_{ogt}^* 的识别准确率.

(1) Omniglot 数据集实验结果

将 FSL-GCNPS 模型在 Omniglot 数据集的识别率与 Matching Networks、Siamese Net、Prototypical Networks、Model-Agnostic Meta-learning、Relation Networks、FSLSS 以及 GNN 等模型作实验对比. 实验结果如表 2 所示,其中“*”表示辅助训练下的模型效果. 通过表 2 可也看出,针对于 Omniglot 数据集,FSL-GCNPS 模型在较有难度的 20-way 1-shot 的设定上达到了 99.38% 以上的分类准确率,比目前最好的 FSLSS 高了约 0.3 个百分点,证明了 FSL-GCNPS 在灰度图像领域拥有更好的分类能力. 同时,在其他的三种设定上也均达到了 99.7% 以上的分类准确率.

其中:分类准确率($A \pm B$)%中, A 代表多次测试的分类准确率的均值, B 代表标准差.

表 2 Omniglot 数据集下与其他少样本学习方法的分类准确率对比

Model	5-way		20-way	
	1-shot	5-shot	1-shot	5-shot
Matching Networks ^[8]	98.1%	98.9%	93.8%	98.5
Siamese Net ^[25]	98.4%	99.6%	95%	98.6%
Prototypical Networks ^[9]	98.8%	99.7%	96.0%	98.9%
MAML ^[12]	(98.7±0.4)%	(99.9±0.1)%	(95.8±0.3)%	(98.9±0.2)%
Relation Networks ^[10]	(99.6±0.2)%	(99.8±0.1)%	(97.6±0.2)%	(99.1±0.1)%
GNN ^[21]	99.2%	99.7%	97.4%	99.0%
FSLSS ^[6]	(99.8±0.2)%	(99.9±0.1)%	(99.1±0.2)%	(99.6±0.1)%
Fast-FSL ^[7]	(99.40)%	(99.75)%	(96.37)%	(99.08)%
本文 FSL-GCNPS	(99.4±0.3)%	(99.8±0.2)%	(96±0.5)%	(99.2±0.3)%
本文 FSL-GCNPS*	(99.8±0.2)%	(99.88±0.12)%	(99.38±0.12)%	(99.7±0.2)%

(2) miniImageNet 数据集实验结果

将 FSL-GCNPS 模型在 miniImageNet 数据集的识别率与 Matching Networks、Prototypical Networks、Model Agnostic Meat-learner、Relation Networks、FSLSS 以及 GNN 等模型做实验对比。

实验结果如表 3 所示,其中“*”表示辅助训练下的模型效果。从表 3 可以看出, FSL-GCNPS 模型分类准确率达到 (54.43±0.59)%,比 GNN 的分类准确率提高了 4.1%,且超过了其它经典的少样本学习算法;在 5-way 5-shot 的设定下,比 GNN 的分类准确率提高了 5.36%,也均超过了 FSLSS、Fast-FSL 等其它经典的少样本学习算法。

表 3 miniImageNet 数据集下与其他少样本学习方法的分类准确率对比

Model	5-way	
	1-shot	5-shot
Matching Networks ^[8]	(45.56±0.84)%	(55.31±0.73)%
Prototypical Networks ^[9]	(49.42±0.78)%	(68.20±0.66)%
MAML ^[12]	(48.70±1.84)%	(63.10±0.92)%
Relation Networks ^[10]	(50.44±0.82)%	(65.32±0.70)%
GNN ^[21]	(50.33±0.36)%	(66.41±0.63)%
FSLSS ^[6]	(53.85±0.81)%	(71.50±0.69)%
Fast-FSL ^[7]	(51.19±0.17)%	(70.87±0.03)%
本文 FSL-GCNPS	(51.87±1.23)%	(68.59±1.31)%
本文 FSL-GCNPS*	(54.43±0.59)%	(71.77±0.82)%

实验 1 的结果说明图顶点生成网络中的原型空间嵌入优化了数据的特征表达,增进了模型的泛化能力。同时,信息传递网络中的 V2E 网络通过自适应构建边的方法,使得图节点之间边的质量得到了保证,进一步提升了 GCN 的“传播能力”,增进了模型分类准确率。

4.2 实验 2: FSL-GCNPS 在半监督学习下的效果

半监督学习 (Semi-Supervised Learning, SSL)^[26] 是深度学习领域研究的重点问题,是监督学习与无监督

学习相结合的一种学习方法。

半监督分类可以在无标签实例的帮助下训练有标签实例,弥补有标签实例不足的缺陷,在无标签实例的帮助下获得更好的泛化能力,提升模型的性能。受半监督分类的启发,本文提出辅助训练的方式,如算法 4 所示,在训练任务 \mathcal{T}_i 所对应的数据集 \mathcal{D}_i^r 中,针对所有类别,取每一类别的 λ 个图像实例去除标签信息后加入训练任务的辅助支持集 \mathcal{D}_i^s 中,即

$$\mathcal{D}_i^s = \{(x_i^s, y_i^s) \in \lambda \times \mathcal{S}\}_{i=1}^c \quad (18)$$

其中, $\mathcal{D}_i^s \cap (\mathcal{D}_i^r \cup \mathcal{D}_i^e) = \emptyset$ 。通过图顶点生成网络构建图辅助支持点集 V_λ ,利用 V_λ 辅助训练 V_s ,以增进模型的泛化能力。

算法 4 图辅助支持点集的构建策略

输入:辅助训练参数 λ ,数据集 \mathcal{D}_i^r

输出:图辅助支持点集 V_λ

1. 根据式(18),构建辅助训练任务支持集 \mathcal{D}_i^s ;
2. 取出 \mathcal{D}_i^s 中的图像实例集;
3. FOR $i = 0$ TO $|\lambda \times \mathcal{S}|$
4. 根据式(7),得到 x_i 的特征向量 $\xi_i = g(x_i)$;
5. END FOR
6. 根据 3.1 节式(11),将 ξ_i 和零向量拼接去除标签信息得到图辅助支持点集 V_λ ;
7. 输出图辅助支持点集 V_λ 。

实验 2 的主要目的分为以下三点:

①验证 FSL-GCNPS 在半监督学习下的相较于前人研究成果的效果;

②验证无标签实例辅助训练后的模型效果;

③分析辅助训练系数对 FSL-GCNPS 分类准确率和稳定性的影响。

实验参数的设定:

①半监督学习对比实验遵循文献[19]的设定,针对 5-way 5-shot 实验采用训练任务集中的支持集数据

20% 被标记、40% 被标记以及 100% 被标记的设置方式对数据进行预处理;

②辅助训练及辅助训练系数的分析实验在实验 2 的基础上,令 λ 分别等于 0、1、2、3、4、5、6;其他实验参数和实验步骤均遵循实验 2 的设定.

(1)半监督学习对比实验

实验结果如表 4 和表 5 所示,FSL-GCNPS 在半监督下的训练效果有所提升,其中“**”表示只用有标签数据进行训练,“***”表示半监督训练.通过表 4 可以看出,针对于 Omniglot 数据集,在数据 20% 被标记的情况下,准确率提升了 0.3%,在数据 40% 被标记的情况下,准确率提升了约 0.2%;通过表 5 可以看出,针对于 mini-ImageNet 数据集,FSL-GCNPS 在半监督下的训练效果有所提升,在数据 20% 被标记和数据 40% 被标记的情况下,都准确率提升了约 2%;同时,相较于 GNN,FSL-GCNPS 在两个数据集的在四种情况下都有所提升.不难看出,基于半监督学习的训练方式有利于模型性能的提升,可以有效增进 FSL-GCNPS 的泛化能力.

表 4 Omniglot 数据集下半监督训练的分类准确率对比

Model	5-way 5-shot		
	20% 被标记	40% 被标记	100% 被标记
GNN**	99.18%	99.59%	99.71%
GNN***	99.59%	99.63%	99.71%
FSL-GCNPS**	(99.40±0.30)%	(99.72±0.08)%	(99.80±0.20)%
FSL-GCNPS***	(99.78±0.12)%	(99.89±0.11)%	(99.80±0.20)%

表 5 miniImageNet 数据集下半监督训练的分类准确率对比

Model	5-way 5-shot		
	20% 被标记	40% 被标记	100% 被标记
GNN**	(50.33±0.36)%	(58.91±0.42)%	(66.41±0.63)%
GNN***	(52.45±0.88)%	(58.76±0.86)%	(66.41±0.63)%
FSL-GCNPS**	(51.87±1.23)%	(58.88±0.42)%	(68.59±1.31)%
FSL-GCNPS***	(54.22±0.63)%	(60.83±0.87)%	(68.59±1.31)%

(2)辅助训练

实验结果如表 6 和表 7 所示,FSL-GCNPS 在辅助训练下的模型分类准确率和稳定性都有所提升.通过表 6 可以看出,针对于 Omniglot 数据集:在 5-way 1-shot 设定下,当 $\lambda=2$ 时,模型分类准确率提升了 0.43%,方差降低了 0.23%;在 5-way 5-shot 设定下,当 $\lambda=3$ 时,模型分类准确率达到 99.88%,方差降低了 0.08%.通过表 7 可以看出,针对于 miniImageNet 数据集:在 5-way 1-shot 设定下,当 $\lambda=5$ 时,模型分类准确率提升了 2.56%,方差降低了 0.64%;在 5-way 5-shot 设定下,当 $\lambda=2$ 时,模型分类准确率达到 71.77%,方差降低了 0.49%;在未列出的 Omniglot 数据集的 20-way 的两种设置下,辅助训练的方式也使得模型分类准确率和稳定性有所提升.说明在加入辅助训练数据后,图顶点生成网络生

成了表达能力更强的图顶点,有助于 FSL-GNNPS 分类准确率的进一步提升.

表 6 Omniglot 数据集下 FSL-GCNPS 辅助训练的分类准确率

λ	5-way	
	1-shot	5-shot
0	(99.40±0.30)%	(99.80±0.20)%
1	(99.80±0.20)%	(99.84±0.12)%
2	(99.83±0.07)%	(99.88±0.12)%
3	(99.74±0.10)%	(99.78±0.02)%
4	(99.78±0.12)%	(99.74±0.03)%
5	(99.68±0.08)%	(99.76±0.09)%

表 7 miniImageNet 数据集下 FSL-GCNPS 辅助训练的分类准确率

λ	5-way	
	1-shot	5-shot
0	(51.87±1.23)%	(68.59±1.31)%
1	(52.00±0.86)%	(71.77±0.82)%
2	(52.10±0.77)%	(69.88±0.53)%
3	(53.56±0.78)%	(68.98±0.63)%
4	(54.22±0.63)%	(67.89±0.62)%
5	(54.43±0.59)%	(66.65±0.25)%

(3)辅助训练系数的分析

实验结果如图 4~7 所示.通过图 4 和图 5 可以看出,随着辅助训练系数的增加,FSL-GCNPS 的分类准确率先上升后下降,针对于 miniImageNet 数据集,在 5-way 1-shot 设定下,当 $\lambda=4$ 时,模型分类准确率达到最高,然后开始下降,在 5-way 5-shot 设定下,当 $\lambda=1$ 时,模型分类准确率达到最高,然后开始下降,针对于 Omniglot 数据集,在 5-way 1-shot 和 5-way 5-shot 两种设定下,当 $\lambda=2$ 时模型分类准确率达到最高值, λ 的值大于 2 时,分类准确率开始慢慢下降.同时,通过图 6 和图 7 可以




图 4 miniImageNet 数据集下辅助训练系数对模型分类准确率的影响

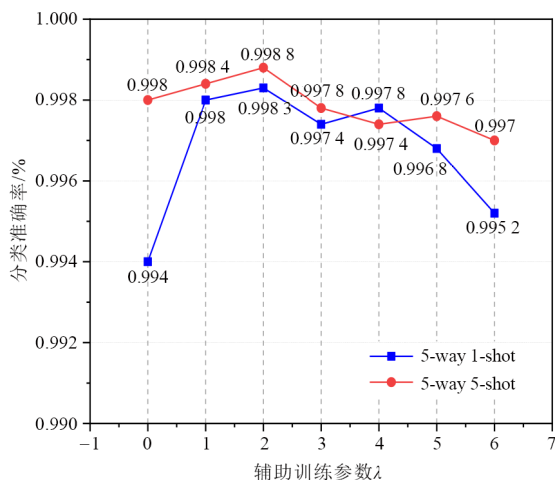


图5 Omniglot数据集下辅助训练系数对模型分类准确率的影响

看出,随着 λ 值的增加,模型分类结果的方差在不断地减小,FSL-GCNPS的分类稳定性得到了提升.实验结果充分说明了 λ 值对模型能力的表达有很大的影响, λ 值太小,辅助训练对模型分类准确率和分类稳定性的增益效果并不明显, λ 值太大,虽然增进了模型分类稳定性,但是对模型分类效果却起到了抑制作用.所以,在模型训练过程中要针对 λ 值对分类准确率和分类稳定性的不同影响,权衡后选取一个合适的 λ 值.




图6 miniImageNet数据集下辅助训练系数对模型分类稳定性的影响

4.3 实验3: miniMedMNIST数据集实验结果

深度学习方法面世以来,其在医疗领域取得了长足的应用和发展.大量的深度学习研究人员利用深度模型完成对医学图像的分类以减轻医生的工作量和工作压力^[27-29].但深度模型的训练需要大量的有标注的数据,而医学数据的标注通常由医生完成,导致深度模型在减轻医生分类工作压力的同时增加了医生标注工作的压力.所以,本文利用miniMedMNIST数据集探究少样本学习在医疗领域的可行性,测试FSL-GCNPS在

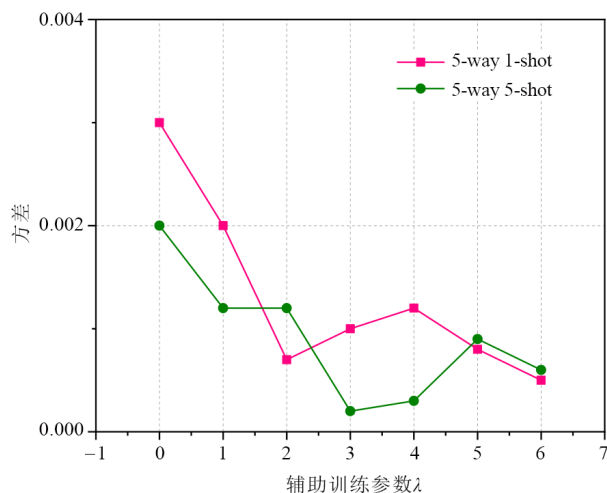


图7 Omniglot数据集下辅助训练系数对模型分类稳定性的影响

医疗数据集上的分类准确率和跨域适应性.

实验方法:将miniMedMNIST数据集划分为两个不相交的训练任务数据集和测试任务数据集,在训练任务上学习推理能力并在测试任务上测试,利用分类准确率作为评判标准来探究少样本学习方法在医学图像数据上的可行性.实验参数的设定:针对于5-way 1-shot和5-way 5-shot两组实验,batch size =64,迭代次数=60 000,学习率=0.000 3,辅助训练系数 $\lambda=0$.

Step1:根据定义1,把miniMedMNIST数据集划分为训练任务集(前21类)和测试任务集(后8类).

Step2:根据定义2,把训练任务集分为训练任务支持集和训练任务查询集,按照算法3的步骤训练模型得到分类函数 \mathcal{F}_{med}^* .

Step3:根据定义3,把测试任务集分为测试任务支持集和测试任务查询集,按照算法3的步骤生成分类模型 f_{med}^* ,并测试 f_{med}^* 的分类准确率.

实验结果如表1所示.从表8可以看出,在5-way 1-shot设定下,FSL-GCNPS模型分类准确率为85.6%,在OCTMNIST上为分类最优值,在其他两个疾病种类上FSL-GCNPS的分类准确率也超过了大部分的深度学习算法;Relation Networks在OCT-MNIST上的表现略优于深度学习算法.在5-way 5-shot设定下,FSL-GCNPS模型分类准确率为92.7%,与其他深度学习算法比较,在OCT-MNIST中提升了16.9%,在Breast-MNIST中提升了4.9%,在Pneumonia-MNIST提升了0.9%;Relation Networks也有不错的分类表现,达到了80.8%的分类准确率.由此可知,将少样本学习策略应用于医学图像数据集上是可行的.同时,相较于传统的深度学习算法和少样本学习算法,FSL-GCNPS模型在医学图像领域拥有更好的分类准确率及跨域适应性.

表 8 miniMedMNIST数据集下少样本学习算法在与其他深度学习方法分类准确率对比

Deep learning	Breast-MNIST	OCT-MNIST	Pneumonia-MNIST
ResNet-18(28) ^[30]	85.9%	75.8%	84.3%
ResNet-18(224) ^[30]	87.8%	75.2%	86.1%
ResNet-50(28) ^[30]	85.3%	74.5%	85.7%
ResNet-50(224) ^[30]	83.3%	75.0%	89.6%
Auto-sklearn ^[31]	80.8%	59.5%	86.5%
Auto-Keras ^[32]	80.1%	73.6%	91.8%
Few-shot learning	5-way		
	1-shot		5-shot
Relation Networks ^[10]	76.2%		80.8%
MAML ^[12]	59.8%		69.7%
FSL-GCNPS	85.6%		92.7%

5 总结

近年来,少样本学习得到了机器学习研究工作者的广泛关注.其可以通过少量标注数据的学习建立起分类准确率较高的模型.本文对基于元学习的图卷积网络少样本学习算法进行研究,提出了FSL-GCNPS少样本学习算法,取得了如下研究成果:

(1)在图像分类中引入基于元学习的度量方法,利用类原型向量和类向量构建图顶点集,自适应地求取图顶点集中两节点间的边值权重,解决了将图像数据转换为图结构数据生成的问题;

(2)用图卷积神经网络来传递标签信息,推理待标注数据的类别,解决了传统少样本学习模型没有考虑数据分布和数据结构信息的问题;

(3)基于半监督学习分类理论,提出辅助训练方式,提升了FSL-GCNPS的模型性能.

仿真实验表明,FSL-GCNPS在医学图像领域较深度学习算法有更好的跨域适应性;在少样本经典评估数据集上较其他经典的少样本学习算法拥有更好的分类准确率和分类稳定性.下一步的工作将考虑如何构建更具表达能力的图结构数据,以期待进一步增进模型的泛化能力.

参考文献

- [1] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [2] 李峰,詹邦成,辛蕾,等.基于新型联合感知矩阵的压缩学习目标识别技术[J].电子学报,2021,49(11):2108-2116.
LI F, ZHAN B C, XIN L, et al. Target recognition technology based on a new joint sensing matrix for compressed learning[J]. Acta Electronica Sinica, 2021, 49(11): 2108-2116. (in Chinese)
- [3] 史先进,曹爽,张重生,等.基于锚点的字符级甲骨图像

自动标注算法研究[J].电子学报,2021,49(10):2020-2031.

SHI X J, CAO S, ZHANG C S, et al. Research on automatic annotation algorithm for character-level oracle-bone images based on anchor points[J]. Acta Electronica Sinica, 2021, 49(10): 2020-2031. (in Chinese)

- [4] 谢佳龙,张波涛,吕强.一种基于双流融合3D卷积神经网络的动态头势识别方法[J].电子学报,2021,49(07):1363-1369.

XIE J L, ZHANG B T, LÜ Q. A dynamic head gesture recognition method based on 3D convolutional two-stream network fusion[J]. Acta Electronica Sinica, 2021, 49(7): 1363-1369. (in Chinese)

- [5] LI F F, ROBERT F, PIETRO P. A Bayesian approach to unsupervised one-shot learning of object categories[C]// Proceedings of the Ninth IEEE International Conference on Computer Vision. Sydney: IEEE, 2003: 1134-1141.

- [6] 余游,冯林,王格格,等.一种基于伪标签的半监督少样本学习模型[J].电子学报,2019,47(11):2284-2291.

YU Y, FENG L, WANG G G, et al. A few-shot learning model based on semi-supervised with pseudo label[J]. Acta Electronica Sinica, 2019, 47(11): 2284-2291. (in Chinese)

- [7] 代磊超,冯林,尚兴林,等.基于深度网络的快速少样本学习算法[J].模式识别与人工智能,2021,34(10):941-956.

DAI L C, FENG L, SHANG X L, et al. Fast few-shot learning algorithm based on deep network[J]. Pattern Recognition and Artificial Intelligence, 2021, 34(10): 941-956. (in Chinese)

- [8] 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. New York: ACM, 2016: 3637-

- 3645.
- [9] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: ACM, 2017: 4080-4090.
- [10] 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. Washington: IEEE, 2018: 1199-1208.
- [11] AMIT R, MEIR R. Meta-learning by adjusting priors based on extended PAC-Bayes theory[C]//Proceedings of the 35th International Conference on Machine Learning. Stockholm: IEEE, 2018: 205-214.
- [12] 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. New York: ACM, 2017: 1126-1135.
- [13] ZHANG R, CHE T, GHARAMANI Z, et al. MetaGAN: An adversarial approach to few-shot learning[J]. *NeurIPS*, 2018, 2(8): 1.
- [14] ZHOU F, CAO C, ZHANG K, et al. Meta-GNN: On few-shot node classification in graph meta-learning[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. New York: ACM, 2019: 2357-2360.
- [15] 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. Piscataway: IEEE, 2019: 11-20.
- [16] BRUNA J, ZAREMBA W, SZLAM A, et al. Spectral networks and deep locally connected networks on graphs[C]//Proceedings of the 2nd International Conference on Learning Representations. Banff: ICLR, 2014: 1-14.
- [17] GILMER J, SCHOENHOLZ S S, RILEY P F, et al. Neural message passing for quantum chemistry[C]//Proceedings of the 34th International Conference on Machine Learning. Sydney: ACM, 2017: 1263-1272.
- [18] AKELLA P N, CONNORS T J, KELLY J, et al. Creation and maintenance of social relationship network graphs: US7539697[P]. 2009-05-26.
- [19] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. New York: ACM, 2016: 3844-3852.
- [20] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks[C]//Proceedings of the 5th International Conference on Learning Representations. Toulon: ICLR, 2017: 1-14.
- [21] GARCIA V, BRUNA J. Few-shot learning with graph neural networks[C]//Proceedings of the 6th International Conference on Learning Representations. Vancouver: ICLR, 2018: 1-13.
- [22] LI Q, HAN Z, WU X M. Deeper insights into graph convolutional networks for semi-supervised learning[C]//Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans: ACM, 2018: 3538-3545.
- [23] XU K, LI C, TIAN Y, et al. Representation learning on graphs with jumping knowledge networks[C]//Proceedings of the 35th International Conference on Machine Learning. Stockholm: IEEE, 2018: 5453-5462.
- [24] YANG J, SHI R, NI B. Medmnist classification decathlon: A light-weight automl benchmark for medical image analysis[C]//Proceedings of the 18th International Symposium on Biomedical Imaging. Nice: IEEE, 2021: 191-195.
- [25] GREGORY K, RICHARD, RUSLAN S. Siamese neural networks for one-shot image recognition[C]//Proceedings of the International Conference on Machine Learning Deep Learning workshop. Lille: ICLR, 2015: 1-30.
- [26] ZHU X. Semi-supervised learning literature survey[J]. *World*, 2005, 10: 1-38.
- [27] CAMPANELLA G, HANNA M G, GENESLAW L, et al. Clinical-grade computational pathology using weakly supervised deep learning on whole slide images[J]. *Nature Medicine*, 2019, 25(8): 1301-1309.
- [28] NOORBAKSH J, FARAHMAND S, NAMBURI S, et al. Deep learning-based cross-classifications reveal conserved spatial behaviors within tumor histological images [J]. *Nature Communications*, 2020, 11(1): 1-14.
- [29] KATHER J N, KRISAM J, CHAROENTONG P, et al. Predicting survival from colorectal cancer histology slides using deep learning: A retrospective multicenter study[J]. *PLoS Medicine*, 2019, 16(1): e1002730.
- [30] 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. Las Vegas: IEEE, 2016: 770-778.
- [31] FEURER M, KLEIN A, EGGENSPERGER K, et al. Auto-sklearn: Efficient and robust automated machine learning[J]. *Automated Machine Learning*, 2019, 11: 113-134.

- [32] JIN H, SONG Q, HU X. Auto-keras: An efficient neural architecture search system[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage: ACM, 2019: 1946-1956.

作者简介



刘鑫磊 男,1994年出生于吉林省长春市。2022年毕业于四川师范大学计算机科学学院软件工程专业。现为四川省资阳市公安局网安支队民警。主要研究方向为机器学习、少样本学习。

E-mail: 1178101948@qq.com



冯林 男,1972年出生于四川省巴中市。现为四川师范大学计算机科学学院博士,教授,研究生导师。主要研究方向为机器学习、数据挖掘。

E-mail: fenglin@sicnu.edu.cn



廖凌湘 男,1994年出生于福建省南平市。2022年毕业于四川师范大学计算机科学学院计算机科学与技术专业。现为四川航天职业技术学院硕士研究生、助教。

E-mail: liao199411@163.com

龚勋 男,1980年生。现为西南交通大学人工智能学院博士、教授、博士生导师。主要研究方向为人工智能、计算机视觉及图像处理。

E-mail: xgong@swjtu.edu.cn

苏菡 女,1979年出生于四川省阿坝藏族自治州。现为四川师范大学计算机科学学院博士、教授、硕士生导师。主要研究方向为模式识别、图像处理。

E-mail: suhan@sicnu.edu.cn

王俊 男,1984年生。现为四川师范大学商学院博士、副教授、硕士生导师。主要研究方向为复杂景区系统建模分析、不确定多属性决策理论与方法。

E-mail: wangjun.sicnu@qq.com