

结合残差与自注意力机制的图卷积小样本图像分类网络

李凡, 贾东立, 姚昱旻, 涂俊

引用本文

李凡, 贾东立, 姚昱旻, 涂俊. 结合残差与自注意力机制的图卷积小样本图像分类网络[J]. 计算机科学, 2023, 50(6A): 220500104-5.

LI Fan, JIA Dongli, YAO Yumin, TU Jun. Graph Neural Network Few Shot Image Classification Network Based on Residual and Self-attention Mechanism [J]. Computer Science, 2023, 50(6A): 220500104-5.

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)

[基于可跟踪环签名的拜占庭容错共识算法](#)

Byzantine Fault Tolerant Consensus Algorithm Based on Traceable Ring Signature
计算机科学, 2023, 50(6A): 220300100-7. <https://doi.org/10.11896/jsjcx.220300100>

[基于改进Yolov4-tiny的轻量级目标检测算法](#)

Lightweight Target Detection Algorithm Based on Improved Yolov4-tiny
计算机科学, 2023, 50(6A): 220700006-7. <https://doi.org/10.11896/jsjcx.220700006>

[基于多尺度原型分层匹配的小样本分割方法](#)

Few-shot Segmentation Based on Multi-scale Prototype Hierarchical Matching
计算机科学, 2023, 50(6A): 220300275-7. <https://doi.org/10.11896/jsjcx.220300275>

[基于多图特征聚合的小样本学习方法](#)

Few-shot Learning Method Based on Multi-graph Feature Aggregation
计算机科学, 2023, 50(6A): 220400029-10. <https://doi.org/10.11896/jsjcx.220400029>

[基于增强AST的图神经网络函数级代码漏洞检测方法](#)

Function Level Code Vulnerability Detection Method of Graph Neural Network Based on Extended AST
计算机科学, 2023, 50(6): 283-290. <https://doi.org/10.11896/jsjcx.220600131>

结合残差与自注意力机制的图卷积小样本图像分类网络

李凡¹ 贾东立¹ 姚昱旻² 涂俊¹

¹ 河北工程大学信息与电气工程学院 河北 邯郸 056000

² 湖南省区块链技术创新中心 长沙 410000

(lifan539@163.com)

摘要 小样本学习的提出是为了解决深度学习中模型学习所需数据集规模小或者数据标注代价昂贵的问题,图像分类作为深度学习研究领域的重要研究内容,也存在训练数据不足的情况。研究人员针对图像分类模型缺乏训练数据的情况,提出了许多的解决方法,利用图神经网络进行小样本图像分类就是其中的一种。为了更好地发挥图神经网络在小样本学习领域中的作用,针对图神经网络中的卷积操作过程易受偶然因素影响,导致模型不稳定,使用残差网络对图神经网络进行改进,设计了残差图卷积网络,以提高图神经网络的稳定性。在残差图卷积网络的基础上,结合自注意力机制设计残差图自注意力机制,深入挖掘节点之间的关系,提高信息传播效率,从而提高分类模型的分类准确率。经过测试,改进后的残差图卷积网络训练效率得到提高,在5way-1shot任务中的分类准确率相比GNN模型提高了1.1%,在5way-5shot任务中比GNN模型提高了1.42%。在5way-1shot任务中,残差图自注意力网络的分类准确率比GNN模型提高了1.62%。

关键词: 小样本学习;图像分类;图神经网络;残差网络;自注意力机制

中图法分类号 TP391

Graph Neural Network Few Shot Image Classification Network Based on Residual and Self-attention Mechanism

LI Fan¹, JIA Dongli¹, YAO Yumin² and TU Jun¹

¹ School of Information and Electrical Engineering, Hebei University of Engineering, Handan, Hebei 056000, China

² Hunan Technology Innovation Center of Blockchain, Changsha 410000, China

Abstract Few shot learning is proposed to solve the problem of small size of data set required for model learning or high cost of data annotation in deep learning. Image classification has always been an important research content in the research field, and there may be insufficient annotation data. In view of the lack of image annotation data, researchers have put forward many solutions, one of which is to classify small sample images by using graph neural network. In order to better play the role of graph neural network in the field of small sample learning, aiming at the unstable situation of graph neural network convolution operation, residual graph convolution network is used to improve the graph neural network, and residual graph convolution network is designed to improve the stability of graph neural network. Based on the convolutional network of residual graph, the self-attention mechanism of residual graph is designed in combination with the self-attention mechanism, and the relationship between nodes is deeply mined to improve the efficiency of information transmission and improve the classification accuracy of the classification model. After testing, the training efficiency of the improved Res-GNN is improved. The classification accuracy in 5way-1shot task is 1.1% higher than that of GNN model, and 1.42% higher than that of GNN model in 5way-5shot task. In the 5way-1shot task, the classification accuracy of ResAT-GNN is 1.62% higher than that of GNN model.

Keywords Few shot learning, Image classification, Graph neural network, Residual network, Self-attention mechanism

1 引言

随着大数据时代的到来,深度学习作为数据处理的重要技术,在各个研究领域被广泛应用。在深度学习中,分类模型一般依靠大规模标注的数据集进行训练,以此完成模型的

泛化,使模型具有较好的分类效果。但是某些研究领域无法获取足够数量的样本数据,或者样本数据的标注代价过于昂贵。由于数据集规模较小,训练出的模型很容易存在过拟合等问题。研究人员通过小样本学习方法解决了分类模型在数据集规模较小情况下的训练问题。图像分类是计算机视觉的

基金项目:湖南省科技厅高新技术产业科技创新引领计划项目(2020GK2005)

This work was supported by the Science and Technology Innovation Leading Plan Project of High Tech Industry of Hunan Provincial Department of Science and Technology(2020GK2005).

通信作者:贾东立(jwdsli@163.com)

基础研究内容,在研究领域拥有重要的地位和研究意义。小样本图像分类问题的研究也受到了重视。研究人员主要从数据增强、迁移学习和元学习 3 个角度出发解决小样本学习问题。

数据增强是通过生成对抗网络等方式对数据集进行扩充^[1],也可以通过增强数据样本空间完成。迁移学习^[2]是利用源领域和目标领域的关联实现的,是一种通过对模型源领域上的数据集进行学习,并将学习到的知识、特征和参数迁移到目标领域的学习方法。

元学习是利用学会的知识在模型进行新任务时做出指导。其中基于度量学习的元学习是一种重要的方法。度量学习最根本的部分是进行相似度学习,在算法中,根据对度量的计算得出相似度。算法一般分为两步,首先是通过特征提取网络完成对样本数据的特征提取,然后将提取到的样本数据在度量空间中完成相似度比较。例如,Koch等^[3]提出的孪生网络通过两个完全相同的卷积网络完成对图像的特征提取,通过比较两个特征之间的欧氏距离来判断两种图像是否属于一个类别。匹配网络^[4]就是利用注意力机制对图像进行注意力得分计算,从而计算图像相似度。Cai等^[5]使用记忆匹配网络对标记图像的特征提取网络中的参数进行学习,以预测未标记图像特征提取网络中的参数。原型网络^[6]认为,每个类别在度量空间中都存在一个固定的原型点,将查询图像映射到度量空间中,通过计算度量空间中查询图像到原型点的距离,来计算相似度。关系网络^[7]是通过构建神经网络来计算输入样本之间的非线性距离,也就是相似度。

随着图神经网络的广泛应用,基于图神经网络的小样本学习方法也成为小样本学习的一个重要的研究方向。Garcia等^[8]使用特征提取网络,提取图像的特征向量作为图神经网络的节点,判断图神经网络的卷积操作,将有标签的节点信息传递到无标签的节点中,通过节点特征信息完成无标签节点的特征预测。Kim等^[9]则通过对边进行学习,判断图神经网络边两侧的节点是否属于同一类别,来完成图像类别的预测。对图神经网络小样本分类模型的改进一般从增强特征提取模块提取能力和加强图神经网络中节点信息的传播能力两方面出发。在增强特征提取模块提取能力方面,Liu等^[10]通过卷积注意力机制提取更具有表现力的特征,从而提高图节点信息传播能力。Wang等^[11]也通过注意力机制提取特征,提高图卷积操作的信息传播效率,提高模型分类能力;在提高图神经网络节点信息传播能力方面,Yang等^[12]提出了一种双图神经网络,使用点图和分布图分别提取样本之间和样本的分布之间的关系,通过循环传递将样本与样本之间分布的关系相融合,提升图神经网络性能。

2 相关工作

2.1 残差网络

网络层数的增加可以提高神经网络的拟合能力,但在实际应用中,神经网络的性能往往在层数增加时出现下降现象,即梯度消失和网络退化问题,而在图神经网络中,则会出现过平滑现象。梯度消失问题通过归一化和正则化操作得到了一定程度的缓解。而残差网络的出现,使神经网络在解决梯度

消失问题上取得了极大的进步^[13]。残差网络可以通过跨层连接,实现不同层的输入输出相连接,从而使网络退化问题得到缓解。从反向传播角度来看,错误信号可以直接通过残差网络传到低层,从而避免了网络中的梯度消失问题。

2.2 自注意力机制

在神经网络的输入中,输入向量之间可能会存在一定的关系,而一般的神经网络会忽略对其中的关系进行提取,造成一定程度的资源浪费。自注意力机制在基于 Transformer 自然语言处理中首先得到应用^[14]。在自然语言处理中,Transformer 注重捕捉句子中单词的联系,并且更加注重提取输入特征之间的联系和相关性。

2.3 图卷积网络

随着大数据时代的来临,非欧氏数据大量出现,规模飞速增长,如社交网络、药物分子结构和交通预测等。图的结构由节点和边构成。在图数据中,每个节点都有自己的特征,节点之间的联系构成了图的结构特征。卷积网络通过图片结构的平移不变性实现参数共享。对于图结构来说,图卷积网络在空间域中可以通过图卷积操作对邻居节点进行信息聚合,学习节点特征和整个图结构的特征^[15]。空域卷积的方法通过节点的连接关系定义卷积操作,频域中的卷积通过图的拉普拉斯矩阵中的特征值和特征向量来实现图卷积。

2.4 创新机制

将残差思想和自注意力机制与图神经网络相结合,以提升分类模型在小样本分类任务中的准确率和其他性能。

主要从两个方面出发:1)为增强图神经网络在节点更新过程中的稳定性,结合残差思想,在图神经网络的邻接矩阵更新过程中加入一定比例的上层邻接矩阵;2)为使图神经网络节点间拥有更强的信息传播能力,在图卷积操作后加入自注意力机制,充分挖掘输入信息之间的关系。

3 残差图自注意力网络

对图神经网络进行改进。如图 1 所示,在图神经网络节点更新过程中加入残差思想,在邻接矩阵更新时加入一定比例的上层邻接矩阵,以增强分类模型的稳定性。在图卷积网络的残差和图卷积操作后,加入自注意力机制对节点进行更新。将图神经网络加入残差思想改进的分类模型定义为残差图卷积网络(Res-GNN)。将图神经网络加入残差思想和自注意力机制改进的分类模型定义为残差图自注意力网络(ResAT-GNN)。




图 1 残差图自注意力网络节点更新过程

Fig. 1 Node update of ResAT-GNN

残差图自注意力网络如图 2 所示。构建节点个数为 5 的图神经网络。在小样本分类任务中,不同类别的 5 个样本数据通过卷积网络的卷积和池化操作进行特征提取,得到代表图像特征的 128 维向量与标签拼接,其中查询集样本初始标签置零,分别输入图神经网络的 5 个节点中,通过残差、卷积和自注意力机制等操作进行节点间的信息传递,

完成对查询图片类别的预测。

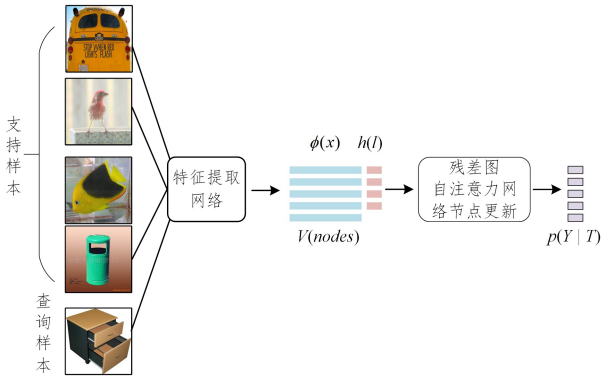


图2 残差图自注意力网络

Fig. 2 ResAT-GNN

3.1 残差图卷积操作

使用卷积网络作为特征提取网络,提取的图像特征向量作为图网络节点,节点特征之间的欧氏距离作为边,组成一个完全图。其计算如式(1)所示。

$$\varphi_{\theta}(\mathbf{x}_i^{(k)}, \mathbf{x}_j^{(k)}) = MLP_{\theta}(\text{abs}(\mathbf{x}_i^{(k)} - \mathbf{x}_j^{(k)})) \quad (1)$$

如图3所示。构建邻接矩阵(Adjacency Matrix),第 k 层的邻接矩阵 $\tilde{\mathbf{A}}^{(k)}$ 不仅使用节点进行构建,而且加入了一定比例的上层邻接矩阵,以缓解偶然因素造成的模型不稳定现象。

$$\tilde{\mathbf{A}}^{(k)} = \varphi_{\theta}(\mathbf{X}_i^{(k)}, \mathbf{X}_j^{(k)}) \quad (2)$$

$$\tilde{\mathbf{A}}^{(k)} = (1-a)\tilde{\mathbf{A}}^{(k)} + a\tilde{\mathbf{A}}^{(k-1)} \quad (3)$$

其中, a 为邻接矩阵更新时加入上层邻接矩阵的比例。




图3 残差邻接矩阵

Fig. 3 Residual adjacency matrix

图卷积操作是邻接矩阵 $\tilde{\mathbf{A}}^{(k)}$ 与对应的特征矢量相乘,通过加权处理和逐点非线性变换最终得到下一层特征表达的操作,表达式如式(4)所示:

$$\mathbf{H}^{k+1} = \sigma(\mathbf{D}^{-\frac{1}{2}} \tilde{\mathbf{A}}^{(k)} \mathbf{D}^{-\frac{1}{2}} \mathbf{H}^k \mathbf{W}^k) \quad (4)$$

其中, \mathbf{D} 为邻接矩阵进行归一化处理并引入自身的度; \mathbf{W} 为网络的权重; σ 为激活函数; $\tilde{\mathbf{A}}^{(k)}$ 为邻接矩阵; k 为图神经网络层数。

图卷积网络使用邻接矩阵对节点进行更新,再通过更新的节点信息计算邻接矩阵,完成节点间的信息传递。但是在对节点进行更新时,可能会受到偶然因素的影响,造成邻接矩阵计算出现偏差,从而影响信息传播的效果。残差图卷积网络通过在邻接矩阵计算并更新时,加入一定权重的上层邻接矩阵,来保证图卷积网络使用图卷积操作进行节点信息传递的稳定性。

将仅加入残差思想对图神经网络进行改进定义为残差图卷积网络。

3.2 图自注意力操作

残差图自注意力网络是在残差图卷积网络的基础上加入自注意力机制。如图4所示,图神经网络根据邻接矩阵和卷积操作进行节点特征更新,然后将更新节点输出到自注意力机制中继续进行信息传递操作。在改进的图自注意力网络中,节点特征信息由自注意力机制挖掘传递的过程分以下几步。

(1)将输入向量转化成嵌入向量 \mathbf{a} ,对于图神经网络中的每一个节点向量,分别与矩阵系数 $\mathbf{w}^q, \mathbf{w}^k, \mathbf{w}^v$ 相乘,得到 $\mathbf{q}, \mathbf{k}, \mathbf{v}$ 3个向量,被分别称为 Query, Key, Value。矩阵系数为随机初始化矩阵,在神经网络运算的过程中会不断地更新^[16]。计算过程如式(5)所示。

$$\mathbf{q}^i = \mathbf{w}^q \cdot \mathbf{a}^i \quad (5a)$$

$$\mathbf{k}^i = \mathbf{w}^k \cdot \mathbf{a}^i \quad (5b)$$

$$\mathbf{v}^i = \mathbf{w}^v \cdot \mathbf{a}^i \quad (5c)$$

其中, \mathbf{a}^i 为任意输入节点的向量; $\mathbf{w}^q, \mathbf{w}^k, \mathbf{w}^v$ 分别为对应的权重系数矩阵; \mathbf{v} 表示输入特征的向量, \mathbf{q}, \mathbf{k} 是用来计算 attention 权重的特征向量。

(2)计算分数值,自注意力机制中节点向量会有一个分数值,分数值决定了更新某个节点向量时,对其他邻居节点向量的关注程度。 \mathbf{q}, \mathbf{k} 用来计算两个输入节点向量之间的相关性,即 attention 的值,通常使用点乘的方式进行计算,如式(6)所示:

$$\alpha_{i,j} = (\mathbf{q}^i)^T \cdot \mathbf{k}^j \quad (6)$$

其中, $\alpha_{i,j}$ 为两输入向量之间的分数值,即 attention 的值,两个向量关联性较大时,分数值较大。

使用分数值归一化,即除以缩放系数 $\sqrt{d_k}$,使得结果处在较优位置,然后通过 softmax 操作,得到最终的分数值 $\alpha'_{i,j}$,如式(7)所示:

$$\alpha'_{i,j} = \text{softmax}\left(\frac{\alpha_{i,j}}{\sqrt{d_k}}\right) \quad (7)$$

(4)加权相乘,利用得到的每个输入向量的分数值 $\alpha'_{i,j}$ 和 \mathbf{v} 值,计算每个输入向量 \mathbf{a} 对应的 self-attention 层的输出向量 \mathbf{b} ,如式(8)所示:

$$\mathbf{b}^i = \sum_{j=1}^n \mathbf{v}_j \cdot \alpha'_{i,j} \quad (8)$$

即可输出每个输入向量的自注意力结果。




图4 图神经网络中的自注意力机制

Fig. 4 Self-attention mechanism in graph neural network

完全图经过 Res-GNN 卷积操作后,每个节点输出一个特征。输出的特征经过激活函数得到查询集图像属于每一类的概率。

4 实验分析

4.1 小样本学习问题评判标准

小样本图像分类评价指标一般被称为 N -way K -shot。

通常模型在训练阶段选择 C 个类别, 每个类别中选择 K 个样本, 作为支撑集数据。从 C 类剩余数据中随机选择一批数据作为预测样本数据。经过训练集样本数据训练后, 在测试任务中, 使用支持样本训练得到的模型, 对需要预测的查询集样本进行预测, 确定类别, 得到分类准确率。

在 5way-1shot 分类任务中, 需从数据集中选择 5 类样本, 每类随机抽取 2 例样本, 其中每类样本中的 1 例作为训练集, 剩余 1 例作为测试集。同样在 5way-5shot 任务中选择 5 类数据样本, 每类随机抽取 6 例样本, 其中每类样本中的 5 例作为训练集, 剩余 1 例作为测试集。

准确率和错误率是评价的重要指标。准确率的计算式如式(9)所示:

$$accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (9)$$

其中, FP 为负样本中被分类器错误预测为正样本的个数; TN 为正样本中被分类器正确预测为负样本的个数; FN 为负样本中被分类器正确预测为负样本的个数; TP 为正样本中被分类器正确预测为正样本的个数。

错误率的计算式如式(10)所示:

$$error = 1 - accuracy \quad (10)$$

4.2 Mini_ImageNet 数据集

Mini_ImageNet 数据集是 ImageNet 数据集的子集, 经常被用于小样本图像分类算法的测试。Mini_ImageNet 数据集共包含 100 类不同主体的图像, 每一类主体有 600 张图像, 统一处理每张图像的长宽为 84。将 100 类中的 20 类作为测试集, 16 类作为验证集, 64 类作为训练集。在 Mini_ImageNet 上进行了 5way-1shot 和 5way-5shot 的实验。

4.3 模型性能分析

将残差网络结合图神经网络改进的 Res-GNN 分类模型、在残差图卷积网络基础上结合自注意力机制改进的 ResAT-GNN 分类模型和图神经网络分类模型分别进行训练和测试。

如图 5 所示, 在 5way-1shot 任务中, Res-GNN 模型的测试误差率在 0~5 000 iteration, 下降速度比 GNN 模型快, 总体来说, 其下降曲线比 GNN 模型的下降曲线更平滑。2 个模型的训练误差率下降曲线总体上相差不大, 只是 GNN 曲线在 18 000 iteration 之后振荡较大。这说明残差思想在一定程度上提高了图神经网络模型的稳定性和分类能力。




图 5 5way-1shot 任务中 5 层 Res-GNN 与 GNN 模型误差率下降曲线

Fig. 5 Decline curve of 5-layers Res-GNN and GNN model error rate in 5way-1shot task

模型与 GNN 模型在 20 000 iteration 之后的实验数据。2 条曲线的测试误差率在趋近收敛时均出现了不同程度的振荡, 但总体上 ResAT-GNN 模型的测试误差率比 GNN 模型的要小, 而 ResAT-GNN 模型的训练误差率明显高于 GNN 模型。这说明自注意力机制在传递节点信息时减缓了模型训练误差率的下降速度, 但是模型最终分类准确率得到提高, 分类能力得到加强。




图 6 5way-1shot 任务中 5 层 ResAT-GNN 与 GNN 模型部分误差率下降曲线

Fig. 6 Partial decline curve of 5-layers ResAT-GNN and GNN model error rate in 5way-1shot task

如图 7 所示, 在 5way-5shot 任务中, 对 5 层图神经网络的实验数据进行分析。




图 7 5way-5shot 任务中 5 层 ResAT-GNN, Res-GNN 与 GNN 模型误差率下降曲线

Fig. 7 Error rate decline curve of ResAT-GNN, Res-GNN and GNN models in 5way-5shot task

在相同迭代次数时 Res-GNN 的测试错误率要低于 ResAT-GNN 和 GNN 模型。从 3 个分类模型的测试错误率下降曲线平滑程度来看, GNN 模型的测试误差率下降曲线在 8 000 iteration 后出现一定程度的振荡, 模型的稳定性受到影响, Res-GNN 和 ResAT-GNN 模型的测试误差率下降曲线相对较为平滑。

ResAT-GNN 的训练误差率曲线在迭代中后期要略高于 Res-GNN 曲线, 这种现象在 5way-1shot 任务中出现过, 但不同的是 ResAT-GNN 测试错误率曲线没有低于 Res-GNN 曲线。这可能是由于在 5way-5shot 任务中节点本身信息较多, 加入了自注意力机制后, 分类模型过于关注节点间的关系, 使得模型性能下降。在 3 个模型的训练误差率曲线中, Res-GNN 模型曲线下降过程相比其余两条较为平滑, 说明了残差思想在一定程度上可以提高模型的稳定性。

在 5way-5shot 任务中, 加入残差思想有利于模型稳定性的提升, 而且在一定程度上有利于提高模型分类效率和分类能力。

总体上, 在 5way-5shot 任务与 5way-1shot 任务中, 通过

如图 6 所示, 在 5way-1shot 任务中, 截取 ResAT-GNN

引入残差思想改进的 Res-GNN 模型稳定性和训练效率均得到提高。在 5way-1shot 任务中,加入自注意力机制改进的 ResAT-GNN 模型分类能力得到提高。

4.4 分类准确率对比实验

由表 1 中的实验数据可知,Mini-ImageNet 数据集上,5way-1shot 和 5way-5shot 任务中,结合了残差网络和注意力网络的残差图自注意力网络的分类准确率相比其他分类模型有所提高。

表 1 分类算法准确率对比

Table 1 Accuracy comparison of classification algorithms

Algorithm	5ways-1shot	5ways-5shot
MAML ^[16]	48.70±1.84	63.11±0.92
Prototypical Network ^[6]	49.42±0.78	68.20±0.66
Matching Network ^[4]	43.56±0.84	55.31±0.73
GNN ^[8]	50.33±0.36	66.41±0.63
Relation Network ^[7]	50.44±0.82	65.32±0.70
Res-GNN	51.43±0.59	67.83±0.57
ResAT-GNN	51.95±0.62	66.11±0.67

Res-GNN 的邻接矩阵是结合神经网络当前更新的节点计算得出的邻接矩阵和上次更新节点使用的邻接矩阵加权得出的,相比在更新节点基础上直接计算邻接矩阵,使用经过残差思想改进的邻接矩阵减小了不稳定因素对模型的影响,使得分类模型的稳定性得到增强,分类性能也得到一定程度的提升。因此 Res-GNN 模型分类准确率在 5way-1shot 任务中相比 GNN 模型提高了 1.1%,在 5way-5shot 任务中相比 GNN 模型分类准确率提高了 1.42%。

ResAT-GNN 在每层的图卷积操作后,图网络中每个输入节点通过带反馈的自注意力机制,也就是通过自身节点在内的全连接节点的加权,进行信息传递更新,从而提高信息传递效率。在 5way-1shot 任务中,其分类准确率比 GNN 模型提高了 1.62%。

结束语 为了使图神经网络在小样本图像分类算法中发挥更大的作用,通过加入残差邻接矩阵,提高了分类模型的稳定性和训练效率,并在一定程度上提高了模型的分类能力。在残差图卷积网络的基础上加入自注意力机制,挖掘节点之间的相关信息,在节点间进行更有效的信息传播,使得分类模型获得更好的分类能力。经过测试,改进的 Res-GNN 模型分类准确率在 5way-1shot 任务中相比 GNN 模型提高了 1.1%,在 5way-5shot 任务中相比 GNN 模型提高了 1.42%;而 ResAT-GNN 模型在 5way-1shot 任务中的分类准确率相比 GNN 模型提高了 1.62%。

参考文献

[1] SHI Y X, AN K, LI Y S. Few-shot Communication Jamming Recognition Technology Based on Data Augmentation[J]. Radio Communications Technology, 2022, 48(1): 25-31.

[2] ZHU K F, WANG G J, LIU Y J. Radar Target Recognition Algorithm Based on Data Augmentation and WACGAN with a Limited Training Data[J]. Acta Electronica Sinica, 2020, 48(6): 1124-1131.

[3] KOCH G, ZEMEL R, SALAKHUTDINOV R. Siamese neural networks for one-shot image recognition[C]// Proceedings of 32nd International Conference on Machine Learning. Lille, France; International Machine Learning Society, 2015.

[4] VINYALS O, BLUNDELL C, LILICRAP T, et al. Matching networks for one shot learning[C]// 30th Conference on Neural Information Processing Systems(NIPS 2016). Barcelona, Spain; NIPS Foundation, 2016; 1-9.

[5] CAI Q, PAN Y, YAO T, et al. Memory Matching Networks for One-Shot Image Recognition[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA; IEEE, 2018; 4080-4088.

[6] SNELL J, SWERSKY K, ZEMEL R S. Prototypical networks for few-shot learning[C]// 31st Conference on Neural Information Processing Systems(NIPS 2017). Long Beach, CA, USA; NIPS Foundation, 2017; 1-11.

[7] 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. Salt Lake City, UT, USA; IEEE, 2018; 1199-1208.

[8] GARCIA V, BRUNA J. Few-shot learning with graph neural networks[C]// Proceedings of the International Conference on Learning Representations. Vancouver, BC, Canada, 2018.

[9] KIM J, KIM T, KIM S, et al. Edge-Labeling Graph Neural Network for Few-Shot Learning[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, CA, USA; IEEE, 2019; 11-20.

[10] LIU Y, CHE X. Few-shot Image Classification Algorithm Based on Graph Network Optimization and Label Propagation[J]. Signal Processing, 2022, 38(1): 202-210.

[11] WANG X R, ZHANG H. Relation Network Based on Attention Mechanism and Graph Convolution for Few-Shot Learning[J]. Computer Engineering and Applications, 2021, 57(19): 164-170.

[12] YANG L, LI L, ZHANG Z, et al. DPGN; Distribution Propagation Graph Network for Few-Shot Learning[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA; IEEE, 2020; 13387-13396.

[13] LIU Z X, ZHU C J, HUANG J, et al. Image Super-resolution by Residual Attention Network with Multi-skip Connection[J]. Computer Science, 2021, 48(11): 258-267.

[14] YANG Q, ZHANG Y W, ZHU L, et al. Text Sentiment Analysis Based on Fusion of Attention Mechanism and BiGRU[J]. Computer Science, 2021, 48(11): 307-311.

[15] LIU H C, WANG L. Graph Classification Model Based on Capsule Deep Graph Convolutional Neural Network[J]. Computer Science, 2020, 47(9): 219-225.

[16] 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. 2017.



LI Fan, born in 1998, postgraduate. His main research interest is intelligent information processing.



JIA Dongli, born in 1972, Ph. D, associate professor, graduate supervisor. His main research interest is intelligent information processing.