

融合全局和局部特征的胶囊图神经网络

钱 榕^{1,2}, 张 茹², 张克君^{1,2}, 金 鑫¹, 葛诗靓², 江 晟^{3,4}

(1. 北京电子科技学院 研究生部, 北京 100070; 2. 西安电子科技大学 计算机科学与技术学院, 西安 710071;
3. 长光卫星技术有限公司, 长春 130000; 4. 中国科学院 长春光学精密机械与物理研究所, 长春 130033)

摘要: 针对胶囊图神经网络训练中得到的只有整体结构信息, 并且随着层数的增加, 节点的结构特征信息会丢失的问题, 本文提出融合全局和局部特征的胶囊图神经网络。首先, 改进了 Node2vec, 将节点的属性信息引入随机游走过程中, 从而在生成网络表示时综合考虑了网络结构和节点的属性; 然后, 将改进的 Node2vec 引入胶囊图神经网络, 设计了一个融合全局和局部特征的胶囊图神经网络。通过实验发现, 本文模型在训练时的收敛速度更快, 在图分类任务上的准确率有所提高。

关键词: 计算机应用技术; 网络表示学习; 复杂网络; 图神经网络

中图分类号: TP181 **文献标志码:** A **文章编号:** 1671-5497(2021)03-1048-07

DOI: 10.13229/j.cnki.jdxbgxb20200034

Capsule graph neural network based on global and local features fusion

QIAN Rong^{1,2}, ZHANG Ru², ZHANG Ke-jun^{1,2}, JIN Xin¹, GE Shi-liang², JIANG Sheng^{3,4}

(1. College of Graduate, Beijing Electronic Science and Technology Institute, Beijing 100070, China; 2. College of Computer Science and Technology, Xidian University, Xi'an 710071, China; 3. Chang Guang Satellite Technology Co., Ltd., Changchun 130000, China; 4. Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

Abstract: The overall structure information is obtained in the training of the capsule graph neural network, and as the layers increases, the structure feature information of the node will be lost. A capsule graph neural network that combines global and local features was proposed. First, the Node2vec is improved, and the attribute information of nodes is introduced into the random walk process, so that the network structure and the attributes of nodes are taken into account when the network representation is generated. Then, the improved Node2vec is introduced into the capsule graph neural network, and the capsule graph neural network is designed which fuses global and local characteristics. Experimental results show that the proposed capsule graph neural network has faster training convergence, and higher graph classification accuracy.

收稿日期: 2020-01-14.

基金项目: 国家重点研发计划项目(2018YFB1004101).

作者简介: 钱榕(1970-), 男, 副教授, 博士. 研究方向: 复杂网络, 数据挖掘, 云计算安全. E-mail: rqian@besti.edu.cn

通信作者: 江晟(1985-), 男, 副研究员, 博士. 研究方向: 视频检测, 人工智能, 多源融合.

E-mail: jiangsheng10@mails.jlu.edu.cn

Key words: computer application technology; network representation learning; complex network; graph neural network

0 引言

图神经网络(GNN)是卷积神经网络^[1]在图这种非欧数据集上的自然推广。它利用边的信息对节点信息进行聚合从而生成新的节点表示,能够对节点属性信息和结构信息进行端到端学习。Bruna等^[2]首次提出图上的基于频域和空域的卷积神经网络。Defferrard等^[3]提出了一种基于谱方法的卷积神经网络形式化表述,实现了局部化的卷积核。Kipf等^[4]提出了一种新的图卷积方法,使用谱图卷积的局部一阶近似来确定卷积结构。Hamilton等^[5]提出了一种新的思路,通过对一个节点的邻居节点的特征进行聚合来获得该节点的信息。基于图神经网络的方法在节点分类和预测上取得了很好的效果,这也给基于图神经网络的图表示学习提供了很大启发。Verma等^[6]提出一种通过使用WL-subtree图核的方式,在迭代中收集邻居节点的特性,并不断更新,在最后一次迭代中还原出所有的特征。然而在图的表示学习中,不仅要检测每个节点周围是否存在不同的结构,还要保持它们的详细属性,如位置、方向、连接等。Mallea等^[7]通过将数据集中的每个子图生成一个矩阵表示,再通过胶囊网络实现图分类。Zhu等^[8]提出一种在图卷积网络中引入胶囊网络,根据图卷积得到的节点嵌入生成高质量的图嵌入的神经网络框架——胶囊图神经网络。

胶囊网络更有效地保留了图的特征信息。胶囊图神经网络能够获取深层特征,但是使用图卷积网络训练得到的节点嵌入更多的是整体结构特征信息^[5]。而Node2vec是一种网络表示学习方法,它采用了随机游走和Skip-gram的学习方法,主要通过随机游走产生路径来模拟句子进行word2vec训练生成节点表示^[9]。它采用的是局部随机游走,生成的节点表示更关注节点的局部特征信息。因此,本文在胶囊图神经网络的基础上,提出了融合全局和局部特征的胶囊图神经网络(GLCapsGNN),具体工作如下:①提出了一个改进的Node2vec模型。Node2vec算法是基于网络结构的,在进行节点表示时没有考虑节点属性。本文将节点属性融入Node2vec的随机游走在

中,使网络表示效果略好于Node2vec,并使用改进后的模型提取图的局部结构特征。②设计了融合全局和局部特征的胶囊图神经网络模型。本文使用改进的Node2vec算法提取网络局部结构特征,结合图神经网络获取网络全局结构特征,充分融合网络结构的局部特征与全局特征,并利用胶囊网络实现分类。③在5个数据集上进行实验,实验结果表明,在图分类任务上引入了局部特征的胶囊图神经网络收敛速度更快,图分类准确率略高于胶囊图神经网络。

1 相关工作

1.1 网络表示学习

网络表示学习是指从网络数据中学习每个节点的向量表示,并将向量表示作为节点的特征应用于后续的网络应用任务。一般的网络表示学习算法可以分成两类:①基于网络结构的网络表示学习;②带有信息的网络结构的网络表示学习。在基于网络结构的网络表示学习算法中,DeepWalk^[10]、Node2vec、Struc2vec^[11]以及LINE^[12]是该领域主流的网络表示学习算法,它们在链路预测、引文文本分类等领域广泛应用。但是,上述网络表示学习算法仅考虑了局部游走,即网络局部结构信息。

1.2 图神经网络

卷积神经网络在处理图像数据时具有很强的特征抽取能力和整合能力,但是卷积神经网络所处理的数据都具有规则的网格结构,也就是排列很整齐的矩阵,是很典型的欧式结构。然而,现实生活和科学研究中有很多数据都不具备完整的矩阵结构,更多的是以一定的连接关系聚合在一起,如社交网络、通信网络、互联网络等。这些结构通过卷积神经网络处理起来是非常困难的。而图卷积网络是一类能够从图结构中学习的神经网络,类似于卷积神经网络,图卷积网络也采用共享权重,不过不同于卷积神经网络中每个卷积核的权重都是规则的矩阵,按照对应位置分配,图卷积中的权重通常是一个集合。

图卷积网络中的卷积操作是通过图拉普拉斯及其特征空间推导出的傅里叶变换来定义的^[13]。

图上的傅里叶变换中使用的拉普拉斯矩阵 $L = D - A$, L 为度矩阵 D 与邻接矩阵 A 的差。频域卷积的前提是无向图, 则 L 为对称矩阵, 因此可分解为:

$$L = UAU^T \quad (1)$$

式中: $U = (u_1, u_2, \dots, u_n)$; A 为包含特征值 $(\lambda_1, \lambda_2, \dots, \lambda_n)$ 的特征矩阵。

基于图的卷积公式为:

$$\hat{f}(t) = \sum_{n=1}^N f(n)u_t(n) \quad (2)$$

如果在整张图的 N 个节点上一起做卷积, 就可以得到整张图的卷积为:

$$\hat{f} = [\hat{f}(1), \hat{f}(2), \dots, \hat{f}(n)]^T = U^T f \quad (3)$$

1.3 胶囊图神经网络

胶囊网络可以很好地应对模糊性, 在胶囊网络里面, 细节的姿态信息(比如对象的准确位置、旋转、厚度、倾斜度、尺寸等)会在网络里被保存下

来^[14]。输入上微小的变化会带来输出上的小变化, 这就让胶囊网络能使用一个简单和统一的架构来应对不同的任务。胶囊网络有两个主要特性: ①基于层的压缩; ②动态路由。胶囊图神经网络是在图卷积网络中引入胶囊网络, 根据图卷积得到的节点嵌入生成高质量的图嵌入的神经网络框架。在这个框架中, 每个图用多维嵌入表示, 每个嵌入反映了图不同方面的特征。通过图卷积网络得到的节点特征组成胶囊, 用路由机制生成高级图胶囊以及分类胶囊。

2 融合全局和局部特征的胶囊图神经网络

本文提出的融合全局和局部特征的胶囊图神经网络, 其整体结构如图 1 所示, 主要包含 4 个部分。

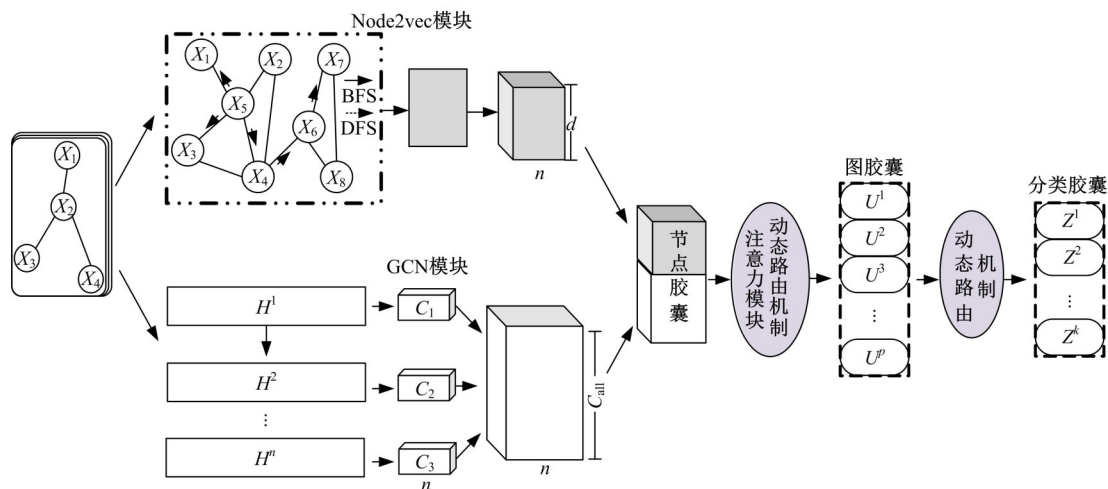


图 1 融合全局和局部特征的胶囊图神经网络

Fig. 1 Framework of capsule graph neural network based on global and local features fusion

(1) 节点的局部特征。通过在 Node2vec 的随机游走过程中增加节点的属性信息进行节点表示, 抽取图的局部特征。

(2) 节点的全局特征。本文使用图卷积网络抽取图的全局特征, 并将多个图卷积网络层抽取的多维节点特征进行合并以增加特征的维度。

(3) 高级胶囊。将节点的局部和全局特征进行融合, 得到初级的节点胶囊; 然后, 从节点的初级胶囊中抽取关于图更复杂、更高级的特征生成高级胶囊。

(4) 分类胶囊。分类胶囊是对高级胶囊进行分类, 胶囊的长度表示当前胶囊属于某个类别的概率。

2.1 节点的局部特征

本文通过改进网络表征学习中的 Node2vec 算法生成节点的局部特征。

Node2vec 是采用了随机游走和 Skip-gram 的学习方法, 主要通过随机游走产生路径来模拟句子进行 word2vec 训练生成节点嵌入。Node2vec 算法通过 p, q 来控制随机游走相邻节点转移的概率, 将宽度优先搜索和深度优先搜索引入随机游走序列的生成过程。

如图 2 所示, 当前节点为 v ; 随机游走的上一个节点为 t ; p 控制跳向上一个节点的邻居节点的概率, 也就是与 t 距离为 1 的节点 (x_1) ; q 控制跳向上一个节点的非邻居的概率, 即访问与 t 的距离




图 2 Node2vec 的随机游走

Fig. 2 Random walk procedure of nNode2vec

为 2 的节点概率(x_2, x_3)。具体的随机游走跳转概率值计算公式为:

$$\alpha_{pq}(t, x) = \begin{cases} 1/p, & \text{if } d_{tx} = 0 \\ 1, & \text{if } d_{tx} = 1 \\ 1/q, & \text{if } d_{tx} = 2 \end{cases} \quad (4)$$

式中: d_{tx} 为节点 t 与 x 之间的最短路径距离。

从式(4)可以看出,Node2vec 在随机选择路径时,只考虑了节点的 2-阶邻域节点,因而生成的节点表示更关注节点的局部特征信息。

本文对 Node2vec 进行改进,根据 p, q 计算节点的转移概率时,加入了节点的度属性,使得 p, q 的值在随机游走过程中是动态变化的。具体实现方式为:

$$p = p(1 + D(a)/D(b)) \quad (5)$$

$$q = q(1 + D(b)/D(a)) \quad (6)$$

式中: $D(\cdot)$ 为节点的度运算; a 为节点 t 和 x 中度比较大的节点; b 为 t 和 x 中度比较小的节点。

通过在随机游走的过程中增加节点的度属性,将节点的属性信息引入随机游走的过程中,可以使得生成的网络表示更准确,在不同的网络结构上表现更好。

2.2 节点的全局特征

节点的全局特征是通过图卷积网络实现的,图卷积网络在进行节点信息的聚合变换后,可以在整个网络上对其进行发散,因而生成的节点表示更注意节点的全局特征。本文使用的图卷积网络是文献[4]提出的,并将多个图卷积网络层中抽取的节点特征进行连接,如图 3 所示。在这部分中,输入是节点的属性,如果没有节点属性,可以使用节点的度作为输入,本文抽取全局特征使用的图卷积网络的过程可以表示为:

$$f(H^l, A) = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H^{l-1} W^l) \quad (7)$$

式中: $W_{ij}^l \in R^{d \times d'}$ 为 l 层与 $l+1$ 层之间从通道 i 到 j 的参数; $H^l \in R^{N \times d'}$, $H^0 = X$, $\hat{A} = A + I$, $\hat{D} = \sum_j \hat{A}_{ij}$ 。

图卷积网络每层的输出为 $[H^1, H^2, \dots, H^n]$, 本文设置每层图卷积网络的输入通道与输出通道相同,然后把得到的输出进行连接,得到了节点的全局特征信息。

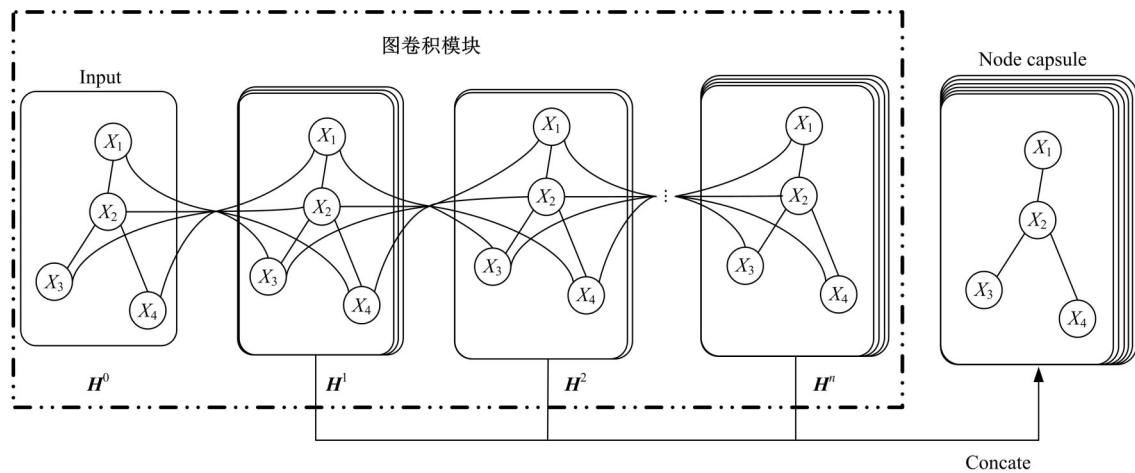


图 3 图卷积模块

Fig. 3 Module of graph convolutional network

2.3 高级胶囊

高级胶囊是图级别的,每个图被建模为多个图形胶囊,不同的图胶囊从不同方面反映图形的特征。将图的局部特征信息和全局特征信息组合得到初级节点胶囊。利用初级节点胶囊生成高级

胶囊需要经过 3 个步骤:①注意力机制,是通过节点归一化方法在每个通道上生成注意力值并应用到初级节点胶囊上,得到了归一化的初级胶囊;②保持节点的位置信息,是将归一化初级胶囊中最后一个通道提取出来作为每个通道的位置信息并

进行组合;③路由选择机制,是应用在胶囊相邻层之间的权重更新,用来将节点胶囊捕获到的高级特征传播到合适的图胶囊上。

注意力机制是通过一个两层的全连接神经网络实现的,如图 4 所示。输入 H 为初级节点胶囊, $H \in R^{n \times d \times c_{all}}$, 将 H 展开成 $Y \in R^{n \times d \times c_{all}}$, 然后使用全连接神经网络进行训练,神经网络的输入层大小为 $d \times c_{all}$, 输出层大小为 c_{all} 。全连接网络层的输出为 $Z \in R^{n \times c_{all}}$, 然后应用基于节点的归一化方法对 Z 按行求值作为最终的注意力值,并应用到原始的节点胶囊上得到收缩后的节点胶囊 U 。




图 4 注意力模块

Fig. 4 Attention module

随着图卷积网络的加深,抽取出来的节点特征包含了更多位置信息。一般情况下,图卷积最后一层得到的节点嵌入可以很好地对整个图进行分类和排序,因而本文使用最高层的图卷积网络得到的嵌入来表示每个节点的位置信息,如下所示:

$$v_{(n,i)j} = [u_{(n,i)}^T W_{ij}^n // u_{(n,c_{all})}^T W_j^p] \quad (8)$$

式中: i, j 为通道; n 为节点; v 为节点在节点通道与图通道之间选择的结果; W^n 和 W^p 分别为最高通道和其他通道对应的转移矩阵; u 为经过注意力模块得到的归一化节点胶囊。

最后,再通过路由选择机制生成高级胶囊。

2.4 分类胶囊

分类胶囊是通过高级胶囊对图进行分类,通过路由选择机制生成分类胶囊 $C, C \in R^{k \times d}$, 其中, k 为分类胶囊的个数,本文使用文献[14]提出的边界损失函数作为分类损失函数,如下所示:

$$Loss_c = \sum_k \{ T_k \max(0, m^+ - \|c_k\|)^2 + \lambda(1 - T_k) \max(0, \|c_k\| - m^-)^2 \} \quad (9)$$

式中: k 为分类; T_k 为分类的指示函数(k 类存在为 1,不存在为 0); m^+ 为上界,惩罚假阳性,即预测 k 类存在但真实不存在; m^- 为下界,惩罚假阴性,即预测 k 类不存在但真实存在; λ 为比例系数,用来调整两者比重。

在损失函数中的正则损失部分使用对抗网络中常用到的重建损失,如图 5 所示。它接受正确分类胶囊的输出作为输入,重建输入的子图大小,在本网络中重建了初级节点胶囊,损失函数为重建图像与输入图像之间的欧式距离。




图 5 重建损失

Fig. 5 Reconstruction losses

解码器强制胶囊学习对重建原始图像有用的特征,重建图像越接近,输入越好。在分类之后,除了分类正确的那个胶囊之外,其他的分类胶囊都被屏蔽,然后使用两层全连接神经网络重建输入信息,公式如下:

$$Loss_r = \frac{\sum_i MP_i (d_i - m_i)^2}{\sum_i MP_i} + \frac{\sum_i (1 - MP_i) (d_i - m_i)^2}{\sum_i (1 - MP)_i} \quad (10)$$

式中: m_i 为输入图中带有属性 i 的节点数量; d_i 为对应的解码值,当输入图中包含属性 i , 则 $MP_i = 1$, 否则为 0。

3 实验

3.1 实验环境和数据

本文实验环境是基于 Ubuntu16.04 系统,内存为 8 GB 的 CPU 环境,编程语言为 Python3.6,实验框架为 Pytorch。

本文对比了融合全局和局部特征的胶囊图神经网络与其他算法的性能,参与对比的算法有基于核的算法 Weisfeiler-Lehman(WL)^[15]和 GK 算法^[16],它们首先根据核定义将图分解为子组件,然后以基于特征的方式构建图的嵌入;还有基于深度学习的算法 AWE、DGCNN 和文献[8]提出的胶囊图神经网络(CapsGNN),AWE是通过网络表示学习算法学习图的表示,然后应用基于核的机器学习方法进行图形分类^[17]。DGCNN通过多层 GNN 生成节点嵌入,并结合从所有层提取

的特征,再根据从最后一层提取的嵌入信息对节点进行排序^[18]。

本文在5个数据集上对改进模型进行验证,采用10倍交叉验证的方式对实验数据进行划分。实验数据如表1所示,其中,D&D、ENZYMES属于生物结构数据集,有节点标签;COLLAB、IMDB-B、IMDB-M是社交网络数据集,没有节点标签。

3.2 实验结果及分析

本文实验参数设置与CapsGNN完全相同。表2和表3为相同条件下进行实验得出的对比结

表1 数据集详细信息

Table 1 Dataset details

数据集	类	数据大小	标签	平均节点数	平均边个数
COLLAB	3	5000	无	74.49	4914.99
IMDB-B	2	1000	无	19.77	193.06
IMDB-M	3	1500	无	13	131.87
D&D	2	1178	有	284.31	715.65
ENZYMES	6	600	有	32.46	63.14

果。从表2和表3中可以看出,GLCapsGNN在其中3个数据集上的分类效果更好,说明增加节点的局部结构特征之后网络的分类准确率有所提升。

表2 对比实验准确率

Table 2 Accuracy of comparative

算法	COLLAB	IMDB-B	IMDB-M	D&D	ENZYMES
WL	79.02±1.77	73.40±4.63	49.33±4.75	79.78±0.36	52.22±1.26
GK	72.84±0.28	65.87±0.98	43.89±0.38	78.45±0.26	32.70±1.20
AWE	73.93±1.94	74.45±5.83	51.54±3.61	71.51±4.02	35.77±5.93
DGCNN	73.76±0.49	70.03±0.86	47.83±0.85	79.37±0.94	51.00±7.29
CapsGNN	79.62±0.91	73.10±4.83	50.27±2.65	75.38±4.17	54.67±5.67
GLCapsGNN	77.88±4.19	75.62±5.38	63.12±2.26	74.88±3.42	58.43±4.25

表3 对比实验的计算代价

Table 3 Compute cost of comparative

算法	COLLAB		IMDB-B		IMDB-M		D&D		ENZYMES	
	时间/s	内存/%	时间/s	内存/%	时间/s	内存/%	时间/s	内存/%	时间/s	内存/%
CapsGNN	0.5463	63	0.1608	59	0.1574	57	6.1603	87	2.2738	71
GLCapsGNN	0.5792	61	0.1945	59	0.1753	58	6.6494	89	2.3452	72

本文在实验中对不同图网络提取局部特征时,改进的Node2vec算法的参数设置不同,以IMDB-M数据集为例,参数设置如下:特征向量维度为20;随机游走数量为10;随机游走长度为10;序列窗口大小为10;随机游走概率参数 $p=1$, $q=2$ 。

图6为胶囊图神经网络和本文融合全局和局

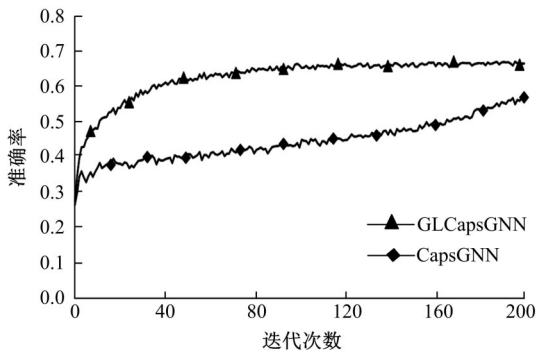


图6 两种模型在IMDB-M数据集上的准确率对比曲线

Fig. 6 Accuracy comparison curve of two models on IMDB-M dataset

部特征的胶囊图神经网络在IMDB-M数据集上图分类的准确率。通过对比实验发现,改进后的模型在测试集上的准确率提升了约8%,并且收敛速度更快,曲线收敛更平滑。

4 结束语

本文对Node2vec算法进行改进,将节点的内容属性融入到随机游走过程中,使随机游走变成一个动态过程。在进行网络表示时,Node2vec更注重节点的局部特征,图卷积网络偏向图的全局特征。本文将改进的Node2vec引入胶囊图神经网络中,提出了融合全局和局部特征的胶囊图神经网络。通过实验表明,引入局部特征信息可以提高分类准确率,增加的Node2vec可以从不同方向丰富图的特征信息,在后续抽取图的抽象特征可以发挥作用,能够更好地表示图。从实验结果也可以看出,在分类对比实验中,5个数据集有3个分类准确率最高。

参考文献:

- [1] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks[J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [2] Bruna J, Zaremba W, Szlam A, et al. Spectral networks and locally connected networks on graphs[J/OL]. [2019-01-02]. <https://arxiv.org/pdf/1312.6203.pdf>
- [3] Defferrard M, Bresson X, Vandergheynst P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//*Advances in Neural Information Processing Systems*, San Francisco, 2016: 3844-3852.
- [4] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[J/OL]. [2020-01-04]. <https://arxiv.org/pdf/1609.02907.pdf>
- [5] Hamilton W, Ying Z, Leskovec J. Inductive representation learning on large graphs[C]//*Proceedings of the 31st International Conference on Neural Information Processing*, San Francisco, 2017:1025-1035.
- [6] Verma S, Zhang Z L. Graph capsule convolutional neural networks[J/OL]. [2020-01-02]. <https://arxiv.org/pdf/1805.08090.pdf>
- [7] Mallea M D G, Meltzer P, Bentley P J. Capsule neural networks for graph classification using explicit tensorial graph representations[J/OL]. [2020-01-04]. <https://arxiv.org/pdf/1902.08399v1.pdf>
- [8] Zhu Z, Peng G, Chen Y, et al. A convolutional neural network based on a capsule network with strong generalization for bearing fault diagnosis[J]. *Neurocomputing*, 2019, 323: 62-75.
- [9] Grover A, Leskovec J. Node2vec: scalable feature learning for networks[C]//*Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, 2016: 855-864.
- [10] Perozzi B, Al-Rfou R, Skiena S. Deepwalk: online learning of social representations[C]//*Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, 2014:701-710.
- [11] Ribeiro L F R, Saverese P H P, Figueiredo D R. Struc2vec: learning node representations from structural identity[C]//*Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, 2017:385-394.
- [12] Tang J, Qu M, Wang M, et al. LINE: large-scale information network embedding[C]//*Proceedings of the 24th International Conference on World Wide Web*, Piscataway, 2015:1067-1077.
- [13] Henaff M, Bruna J, LeCun Y. Deep convolutional networks on graph-structured data[J/OL]. [2019-01-06]. <https://arxiv.org/pdf/1506.05163.pdf>
- [14] Sabour S, Frosst N, Hinton G E. Dynamic routing between capsules[J/OL]. [2020-01-08]. <https://arxiv.org/pdf/1710.09829.pdf>
- [15] Shervashidze N, Schweitzer P, van Leeuwen E J, et al. Weisfeiler-lehman graph kernels[J]. *Journal of Machine Learning Research*, 2011, 1(3):2539-2561.
- [16] Rezaee B. A cluster validity index for fuzzy clustering[J]. *Fuzzy Sets and Systems*, 2010, 161(23):3014-3025.
- [17] Wang H, Fan W, Yu P S, et al. Mining concept-drifting data streams using ensemble classifiers[C]//*Proceedings of the 9th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, 2003:226-235.
- [18] Wang Y, Sun Y, Liu Z, et al. Dynamic graph CNN for learning on point clouds[J]. *ACM Transactions on Graphics*, 2019, 38(5):1-12.