



基于采样的 图神经网络高效训练

罗意

2021-11-19

目录

CONTENTS

1 基于采样的图神经网络训练方法

2 采样邻域节点的方法

3 分层采样节点的方法

4 基于子图样本的方法

1

CONTENTS


1.1 图神经网络在大规模应用中的问题

1.2 基于采样的图神经网络训练方法



图神经网络GNN

◆ 图神经网络与节点分类



◆ 图神经网络的一般方式

1. 聚合节点邻域特征
2. 变换




数据集趋势

发布时间	数据集	节点数	连接数	特征维度	标签种类
2008	Cora	2708	5429	1433	7
	Citeseer	3327	4732	3703	6
	Pubmed	19717	44338	500	3
2017	Reddit	232965	11606919	602	41
2020	Yelp	716847	6977410	300	100
	ogbn-products	2449029	61859140	100	47
	ogbn-papers100M	111059956	1615685872	-	172

Weihua Hu, et al, "Open Graph Benchmark: Datasets for Machine Learning on Graphs," NeurIPS 2020



GNN大规模应用中的问题



- ◆ 多层卷积时计算量指数级增长引发的**难扩展**问题
- ◆ 全量训练 (full-batch) 收敛慢产生的**低效**问题



采样方法

◆ 采样

在聚合前仅选择部分节点作为全部节点的估计，以有限的精度损失，提升GNN的扩展性和学习效率。


1. 扩展性：限制多层卷积涉及的节点规模，减小计算量
2. 学习效率：支持小批量（mini-batch）训练，加快参数更新

◆ 对采样方法的要求

1. 提出采样策略
2. 证明以该策略采样，估计量是无偏的
3. 减小以该策略采样时估计量的方差



在大规模图中基于采样训练GNN




◆ 基于采样训练GNN

1. 采样部分节点作为整体的估计
2. 聚合节点邻域特征
3. 变换




基于采样训练GNN的方法分类



- ◆ 采样邻域节点的方法 (node-wise)
- ◆ 分层采样节点的方法 (layer-wise)
- ◆ 基于子图样本的方法 (subgraph-based)



基于采样训练GNN方法的发展



时间	类型	方法	无偏性	有效性	解决问题	产生问题
2017	Node	GraphSAGE	否	否	扩展、效率	邻域爆炸
2018	Node	PinSAGE	否	否	邻域爆炸	启发式
2018	Layer	FastGCN	否	是	邻域爆炸	稀疏连接
2018	Node	VR-GCN	是	是	邻域爆炸	高内存
2018	Layer	AS-GCN	是	是	稀疏连接	采样复杂
2019	Subgraph	Cluster-GCN	否	否	邻域爆炸	引入偏差
2019	Subgraph	GraphSAINT	是	是	偏差、方差	-

2


CONTENTS

采样邻域节点的方法




GraphSAGE/PinSAGE

◆ GraphSAGE : 邻域爆炸



◆ PinSAGE : 寻求相关性更强的1-hop邻居



W. L. Hamilton, R. Ying, and J. Leskovec, "Inductive representation learning on large graphs," NIPS, 2017



R. Ying, R. He, et al, "Graph convolutional neural networks for web-scale recommender systems," SIGKDD, 2018



◆ 采样方法


感受野内每次只采样自己和1个邻居，邻域线性扩大

(对比GraphSAGE采样25&10)







◆ 方差控制



被采样邻居



未采样邻居



估计

聚合

3


CONTENTS

分层采样节点的方法



FastGCN

◆ 采样方法



估计量

$$h^{(l+1)}(v) = \sigma(E_p[\hat{A}(v, u)h^{(l)}(u)W^{(l)}])$$

引入重要性采样

$$h^{(l+1)}(v) = \sigma(E_q[\hat{A}(v, u)h^{(l)}(u)W^{(l)} \cdot \frac{p(u)}{q(u)}])$$

理论最优的q

$$q^* \propto \sqrt{E_v[\hat{A}(v, u)^2] \cdot |h^{(l)}(u)W^{(l)}| \cdot p(u)}$$

简言之：邻居越多越重要


$$\hat{q} \propto \sqrt{E_v[\hat{A}(v, u)^2]} = \|\hat{A}(:, u)\|^2$$



重要性采样的重要性

◆ 重要性采样降方差后，效果比均匀采样更好

数据集为Cora, Pubmed, Reddit





◆ 按条件采样节点

解决稀疏连接问题

◆ 方差控制

最优采样分布

$$q^*(u_j) = \frac{p(u_j|v_i)|h^{(l)}(u_j)|}{\sum_{j=1}^N p(u_j|v_i)|h^{(l)}(u_j)|}$$

方差

$$\text{Var}_q(\hat{\mu}_q(v_i)) = \frac{1}{n} \mathbb{E}_{q(u_j)} \left[\frac{(p(u_j|v_i)|h^{(l)}(u_j)| - \mu_q(v_i)q(u_j))^2}{q^2(u_j)} \right].$$

引入可学习的线性变换 W ，假装 $h(u_i) = Wx_i$

一举两得：

1. 可用于指导采样
2. 方差项作为正则项进行优化

4

CONTENTS


基于子图样本的方法



Cluster-GCN


◆ Motivation

1. 图网络中存在按社群聚集现象
2. 一批被采样的节点间连接数越多，其表示的学习应越充分
3. 所以跨社群的采样得不偿失





Cluster-GCN



$$A = \bar{A} + \Delta = \begin{bmatrix} A_{11} & \cdots & A_{1c} \\ \vdots & \ddots & \vdots \\ A_{c1} & \cdots & A_{cc} \end{bmatrix}$$


$$\bar{A} = \begin{bmatrix} A_{11} & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & A_{cc} \end{bmatrix}, \Delta = \begin{bmatrix} 0 & \cdots & A_{1c} \\ \vdots & \ddots & \vdots \\ A_{c1} & \cdots & 0 \end{bmatrix}$$

◆ 步骤

1. 使用社群发现算法划分图为c个cluster
2. 每个batch采样若干个cluster，拼成子图（包括cluster间的连接）
3. 在子图上使用GCN



GraphSAINT



◆ 三个采样器（无偏、有效）

1. 以邻接矩阵所在列的2范数（FastGCN）为概率采样节点，组成子图
2. 以两 endpoint 度的倒数和为概率采样边，组成子图
3. 随机游走，路径形成子图




谢谢

敬请批评指正！



基于采样训练GNN方法的发展



时间	类型	方法	无偏性	有效性	解决问题	产生问题
2017	Node	GraphSAGE	否	否	扩展、效率	邻域爆炸
2018	Node	PinSAGE	否	否	邻域爆炸	启发式
2018	Layer	FastGCN	否	是	邻域爆炸	稀疏连接
2018	Node	VR-GCN	是	是	邻域爆炸	高内存
2018	Layer	AS-GCN	是	是	稀疏连接	采样复杂
2019	Subgraph	Cluster-GCN	否	否	邻域爆炸	引入偏差
2019	Subgraph	GraphSAINT	是	是	偏差、方差	-