

图神经网络七日打卡营

小斯妹 百度PGL团队成员



2020.11.23

课程大纲

飞桨 PaddlePaddle



第一课：图学习初印象

- 图学习概述、入门路线
- 实践：环境搭建

第二课：图游走类算法

- DeepWalk, node2vec, metapath2vec
- 实践：DeepWalk, node2vec

第三课：图神经网络算法(一)

- GCN, GAT、消息传递
- 实践：GCN, GAT

第四课：图神经网络算法(二)

- 图采样、邻居聚合
- 实践：GraphSage

第五课：GNN 进阶

- ERNIESage, UniMP
- 实践：ERNIESage 代码讲解

后续：新冠项目实战，带你助力疫情防控

参考材料：


- 斯坦福CS224W课程：<http://cs224w.stanford.edu>
- 图学习库 PGL：<https://github.com/PaddlePaddle/PGL>

图学习入门路线

飞桨 PaddlePaddle


基础入门

基础概念
基本原理



经典算法复现

DeepWalk、GCN、GAT、GraphSage



前沿论文阅读

顶会论文



- 数学基础：
 - 高等数学
 - 线性代数
 - 概率与数理统计
- 编程基础：
 - Python : numpy
 - Paddle :
https://www.paddlepaddle.org.cn/documentation/docs/zh/beginners_guide/index_cn.html
- 机器学习基础：
 - 神经网络 (FC、BPNN)

- 理论：
 - 综述
 - Graph Neural Networks: A Review of Methods and Applications <https://arxiv.org/pdf/1812.08434.pdf>
 - A Comprehensive Survey on Graph Neural Networks <https://arxiv.org/abs/1901.00596>
 - 视频
 - 理论课：斯坦福 CS224W
- 动手实践：DeepWalk, node2vec, GCN, GAT, GraphSAGE (本次公开课实践内容)
- 进阶：经典论文
 - DeepWalk. "DeepWalk: Online Learning of Social Representations" <https://arxiv.org/pdf/1403.6652.pdf>
 - GCN. "Semi-supervised Classification with Graph Convolutional Networks" <https://arxiv.org/pdf/1609.02907.pdf>
 - GAT. "Graph Attention Networks" <https://arxiv.org/pdf/1710.10903.pdf>
 - GraphSAGE. "Inductive Representation Learning on Large Graphs" <https://arxiv.org/pdf/1706.02216.pdf>
 - <https://github.com/thunlp/GNNPapers>
- 前沿研究方向：
 - 针对 GNN 而言：图采样技术、邻居聚合、深度图卷积、图预训练

第一课 图学习初印象

小斯妹 百度PGL团队成员




2020.11.23





什么是图？

图论的开始



七桥问题



图(Graph)就是节点(Vertexes/Nodes)以及边(Edge)

$$G = (V, E)$$

注：一般情况下，我们认为图(graph)和网络(network)两种术语可交替使用。通常我们称为图。

实际的例子

图是一种统一描述复杂事物的语言。



社交网络

节点：人

边：人与人之间的各种联系，如父母关系、朋友关系、同事关系等等。



互联网

节点：网页


边：网页与网页之间的超链接关系

实际的例子

图是一种统一描述复杂事物的语言。




还有什么事物是可以用图来表示的呢？



推荐系统

节点：用户和商品

边：用户、商品之间的购买、点击等关系



化学分子


节点：原子

边：原子之间的相互作用力，也称为化学键


何为图学习？

- 语音、图像、文本具有整齐**规则**的数据结构


语音



图像




文本



数据对象：图


- 现实中的图是**不规则的**，难以直接建模




语法树



社交网络





人体骨骼




化学分子

图学习的优势


一般深度学习：难以处理不规则数据。



图学习：可以方便地处理不规则数据(图)，充分利用图结构信息。




地图




商品广告

图能做什么？——图学习的应用



节点级别任务——金融诈骗检测




节点分类任务

图模型

预测潜在的金融
诈骗分子


节点级别任务——目标检测

目标检测是自动驾驶中非常重要的一门技术。



节点级别任务——目标检测

从3D点云中利用图模型进行目标检测




边级别任务——推荐系统



新闻推荐

- 推荐系统是经典的**Link Prediction**任务



图级别任务——气味识别



月季





玫瑰

这个到底是啥花啊，
闻不出来，呜呜呜




图级别任务——气味识别






图学习是如何做的？

图游走类算法



假设序列最大长度为4.





图表示学习

下游任务：
节点分类等


下节课内容

图学习是如何做的？

图神经网络算法——消息传递



图学习算法分类




知识图谱也是典型的图。

图学习框架——PGL

Github: <https://github.com/PaddlePaddle/PGL>

API文档: <https://pgl.readthedocs.io/en/latest/>

应用场景	推荐系统	知识图谱	用户画像	金融风控	流量预测	智能地图	商业广告	Open Graph Benchmark
分布式	分布式图存储		分布式图采样		分布式训练		分布式预测	
内置模型	游走类模型			消息传递类模型			知识图谱类模型	
	DeepWalk、Node2Vec、Struc2Vec、LINE、GES、Metapath2Vec、Metapath2Vec++、Multi-Metapath2Vec++			GCN、GAT、GraphSage、SGC、DGI、STGCN、GIN、PinSage、GNN-Index、ERNIESage			TransE、TransR、RotatE	
	GATNE			Unsup GraphSAGE				
高效易用	易用的定制接口				性能优化			
	预定义图网络层	Message Passing API	Graph算子	Scatter-Gather	多进程子图采样	基于LodTensor消息聚合		
图引擎	支持边/节点特征		子图采样	随机游走		支持异构图		支持第三方图引擎
核心框架	飞桨 核心框架							



易用

支持异构图的Meta Path和Message Passing双机制

高效

基于LoD Tensor的并行消息聚合算法

规模

内置分布式图引擎，支持十亿节点、百亿边的巨图训练

丰富

涵盖Graph Neural Network和Graph Representation等前沿模型


1. 建图方便

```
# construct a graph
num_nodes = 4
edge_list = [(0,2), (2,1), (1,0), (3,2)]
g = graph.Graph(num_nodes=num_nodes, # 节点数
                edges=edge_list,      # 边列表
                node_feat=None,       # 节点特征, 可不写
                edge_feat=None)       # 边特征, 可不写
```


2. 采用Message Passing机制时，只需要Send/Recv实现图网络

```
# define message function
def send_func(src_feat, dst_feat, edge_feat):
    # In this tutorial, we return the feature vector of the source nodes.
    return src_feat['h']
```

```
# define reduce function
def recv_func(feats):
    # We sum the feature vector of the source nodes.
    return fluid.layers.sequence_pool(feats, pool_type='sum')
```




PGL——高效性




难点 节点获取的消息不定长
适配复杂的用户聚合函数

高效：业界首个并行消息聚合

主流框架的串行消息聚合




PGL并行消息聚合



PGL	复杂用户定义	LodTensor机制聚合	并行计算
	简单模型	Scatter-gather机制	并行计算
主流框架	复杂用户定义	Degree bucketing机制	串行计算

PGL——大规模

规模：PGL分布式解决方案——十亿节点、百亿边的巨图训练



- 满足超大规模节点 Embedding 需求
- Graph Embedding
- Graph Neural Network
- 解决数据 Feed 与训练速度差瓶颈
- 满足超大规模图分片存储需求

PGL——丰富性


丰富：预置多种主流的图学习模型

编号	模型	特点
1	DeepWalk	DFS随机游走的表示学习
2	node2vec	结合DFS及BFS的表示学习
3	L2NE	基于一阶、二阶邻居的表示学习
4	struc2vec	基于结构相似的表示学习
5	metapath2vec	基于元路径的表示学习
6	Multimetapath2vec++	自研：混合元路径的表示学习
7	GES	加入节点特征的图表示学习方法
8	GATNE	异构图的图表示学习
9	GAT	基于Attention的图卷积网络
10	GCN	图卷积网络
11	GIN	图同构网络
12	SGC	简化的图卷积网络
13	GaAN	引入门控 Attention 机制的图卷积网络
14	SAGPool	基于 self-attention 的图分类模型
15	STGCN	时空图卷积网络
16	GraphSAGE	基于邻居采样的大规模图卷积网络

编号	模型	特点
17	DeeperGCN	深层图卷积网络
18	GCNII	深层图卷积网络
19	APFNP	结合 GCN 和 PageRank 的传播模型
20	MixAggGNN	自研：基于混合聚合函数的图神经网络
21	GNN-Index	自研：结合语义索引技术的图神经网络
22	ERNIESage	自研：结合预训练语义模型的图神经网络
23	UniMP	自研：统一标签传递和图神经网络的统一模型
24	Distribute_DeepWalk	分布式随机游走
25	Distribute_GraphSAGE	分布式GraphSAGE
26	Distribute Pinsage	分布式Pinsage
27	Distribute_GIN	分布式GIN
28	Distribute_metapath2vec	分布式 metapath2vec
29	TransE	Translating Embedding
30	TransR	基于Relation空间的Translating Embedding
31	RotatE	基于Relational Rotation的Translating Embedding
32	BigBird	Sparse Transformer

PGL——百度落地应用举例

业务范围



PGL——基于GAT的网页反作弊项目

飞桨




网页作弊

- 内容作弊
- 框架作弊

是否作弊？

图分类

PGL——基于GAT的网页反作弊项目



1. ERNIESage: 落地百度内部多个应用，在COLING 2020 Text Graph-14 竞赛中获得第一；

Results					
#	User	Entries	Date of Last Entry	Team Name	MAP ▲
1	webbley	26	09/21/20	Baidu PGL	0.6033 (1)
2	alvysinger	31	06/25/20		0.5843 (2)
3	aisys	9	07/10/20		0.5233 (3)

2. UniMP: 10月份在图神经网络OGB榜单三大半监督节点分类数据集刷新 SOTA；

Leaderboard for [ogbn-products](#)

The classification accuracy on the test and validation sets. The higher, the better.
Package: >=1.1.1

Rank	Method	Test Accuracy	Validation Accuracy	Contact
1	UniMP	0.8256 ± 0.0031	0.9308 ± 0.0017	Yunsheng Shi (PGL team)

第五节课会进行详细解释

Leaderboard for [ogbn-arxiv](#)

The classification accuracy on the test and validation sets. The higher, the better.
Package: >=1.1.1

Rank	Method	Test Accuracy	Validation Accuracy	Contact
1	UniMP_large	0.7379 ± 0.0014	0.7475 ± 0.0008	Yunsheng Shi (PGL team)

Leaderboard for [ogbn-proteins](#)


The ROC-AUC score on the test and validation sets. The higher, the better.
Package: >=1.1.1

Rank	Method	Test ROC-AUC	Validation ROC-AUC	Contact
1	UniMP	0.8642 ± 0.0008	0.9175 ± 0.0006	Yunsheng Shi (PGL team)

AIStudio Notebook 案例

总结

图学习初印象



课后作业——跑通 PGL 的GCN 和 DeepWalk

Paddle 安装指引：详情可查看 PaddlePaddle 官网

```
pip install paddlepaddle==1.8.5 # -i https://pypi.tuna.tsinghua.edu.cn/simple/  
pip install pgl  
git clone --depth=1 https://github.com/PaddlePaddle/PGL  
cd PGL/examples/gcn  
python train.py
```

注意：

1. 如果在 pip 安装时遇到网络问题：
 - 使用清华源
 - <https://pypi.org/> 下载 whl包或者源码包安装
2. 如果中途安装中断：
 - 重新安装即可
3. 独立的 python 环境：conda

详细要求：在 AISTudio 课程后查看~

```
# 本地：推荐使用conda创建独立python环境  
conda create -n Paddle python=3.6 # 注意，3.8版本目前不支持~  
conda activate Paddle
```


第一课补充 简单的图基础

小斯妹 百度PGL团队成员





2020.11.23





图的分类

无向图 vs 有向图




无权图 vs 有权图




同构图 vs 异构图



同构图、异构图举例




同构图



异构图

图的度和邻居


无向图



$$G = (V, E)$$

$V = \{1, 2, 3, 4\}$
 $E = \{12, 21, 14, 41, 24, 42, 34, 43\}$

有向图



$V = \{1, 2, 3, 4\}$
 $E = \{14, 21, 42, 43\}$

节点4

度(degree)

邻居(neighbor)



degree = 3

neighbors = 1, 2, 3

degree = 3
indegree = 1
outdegree = 2

predecessor = 1
successor = 2, 3

图的表示——邻接矩阵




如果节点 i 和节点 j 之间有边： $A_{ij} = 1$
否则： $A_{ij} = 0$

$$A = \begin{pmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ 1 & 1 & 1 & 0 \end{pmatrix}$$

$$A = \begin{pmatrix} 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 \end{pmatrix}$$

无向图的邻接矩阵是对称矩阵。


图的表示——邻接表



- 对于稀疏 (sparse) 大 (large) 图而言非常友好。
- 允许我们快速获得给定节点的所有邻居。



1:
2: 3, 4
3: 2, 4
4: 5
5: 1, 2


图的表示——边集



(2,3)
(2,4)
(3,2)
(3,4)
(4,5)
(5,1)
(5,2)

结构特征、节点特征、边特征





PGL github

谢谢观看

