



# 图神经网络七日打卡营

小斯妹 百度PGL团队成员



2020.11.25





# 昨晚课程内容的问题

飞桨



陈轻歌

1小时前

deepwalk相关问题

deepwalk论文中用的加速方法是层次的softmax，而不是用的负采样吧。。。

这两种加速方法，会影响最终模型的性能吗？

毕竟是讲论文，还是尊重一下作者在论文中的表述吧。。。

↑ 赞 ↓ 回复



Desmon 老师

1小时前

因为实际情况中，我们会选择用负采样的方式优化（可以看到后续的论文基本都是采用负采样的方法）。

所以我们选择讲解负采样这种方式，对于大家来说比较好理解，同时实现起来也方便一些。另外，我们在讲述游走模型时，其实关注点是放在如何游走上面哈~ 晚上我会跟大家说一下，我们是有选择的对论文内容进行筛选讲解。

↑ 赞 ↓ 回复 ← 删除

# 昨晚的作业

飞桨

AIStudio 红白黑 : <https://aistudio.baidu.com/aistudio/projectdetail/1265981?shared=1>



红白黑

图网络其木姆今有可当往七由老 小乃相生作山代码的详细注解 (该行解释 1下子联云 完具理解) 管注由  
路理解 Notebook 文件(5) <<

或者博

一、图基础及分类

图网络

1.1 什么是图?

今晚是

1.2 图具有的信息/属性

凸 1

1.3 图节点的概念补充--度、出度与入度

1.4 概念理解

1.5 图的基本分类



二、同构图与异构图

2.1 同构图基本定义

\*2.2 异构图的定义

\*2.3 异构图的补充概念(图元 (子图))

2.4 同构图与异构图的数学表示

/1260103

1 回复

1小时前

## 3.1 Node2Vec采样算法转换代码注解

1. 这部分代码，用于随机游走后得到的路径，然后对这些路径进行吸收学习，训练图结构

```
In [16]: %%writefile userdef_sample.py
import numpy as np

# 随机节点的获取
def node2vec_sample(succ, prev_succ, prev_node, p, q):
    """
    输入: succ - 当前节点的下一个相邻节点id列表 list (num_neighbors,)
          prev_succ - 前一个节点的下一个相邻节点id列表 list (num_neighbors,)
          prev_node - 前一个节点id int
          p - 控制回到上一节点的概率 float
          q - 控制偏向DFS还是BFS float
    输出: 下一个节点id int
    """

```

多看看课程讨论区

# 课程大纲

飞桨

## 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：游走类算法

- DeepWalk, node2vec, metapath2vec
- 实践：DeepWalk

## 第三课：图神经网络算法(一)

- GCN, GAT
- 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

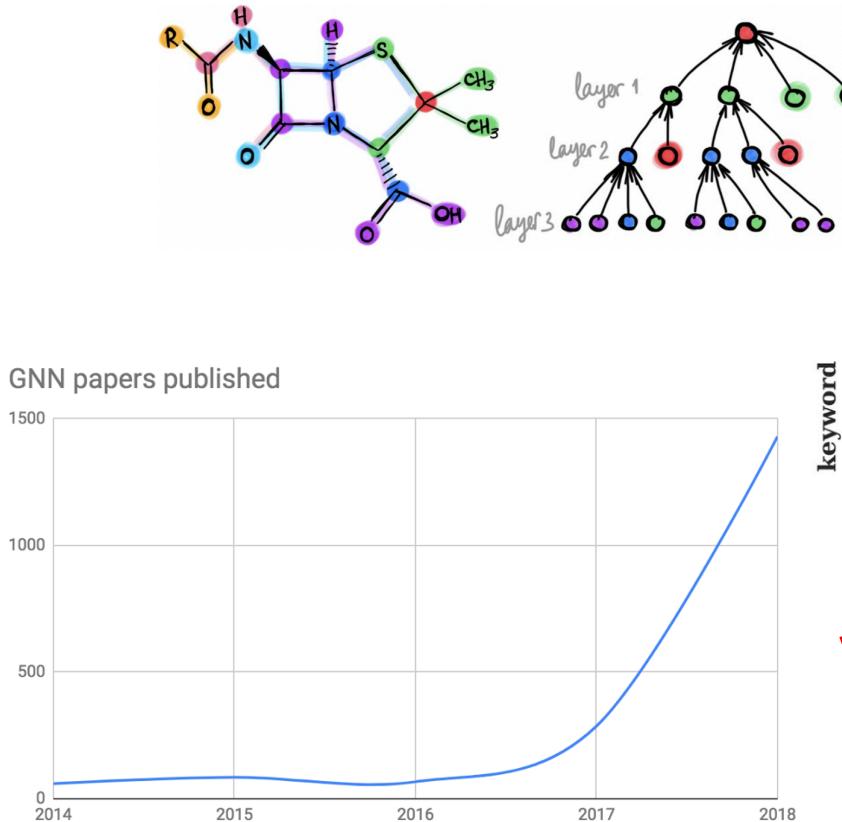
- ERNIE-Sage, UniMP
- 实践：有趣的应用

后续：新冠项目实战，带你助力疫情防控

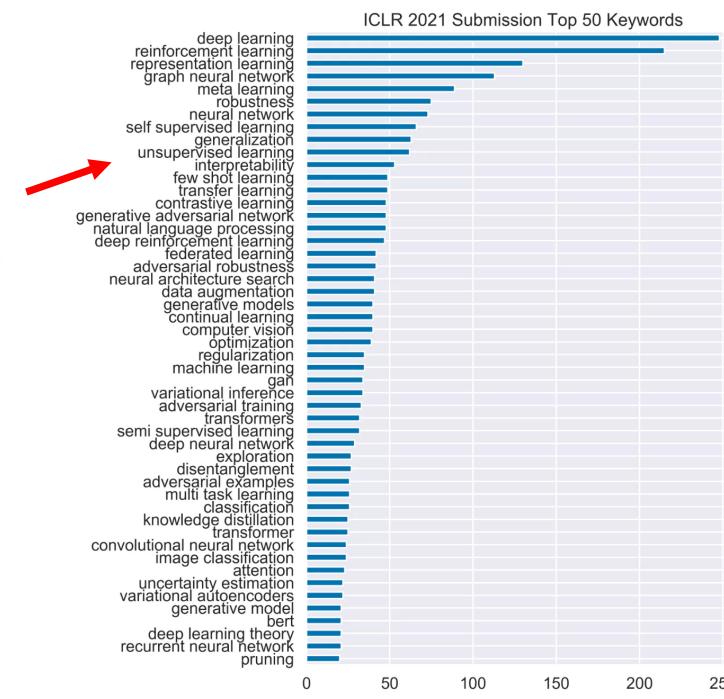
## 参考材料：

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

# 图神经网络的兴起：业界论文发表

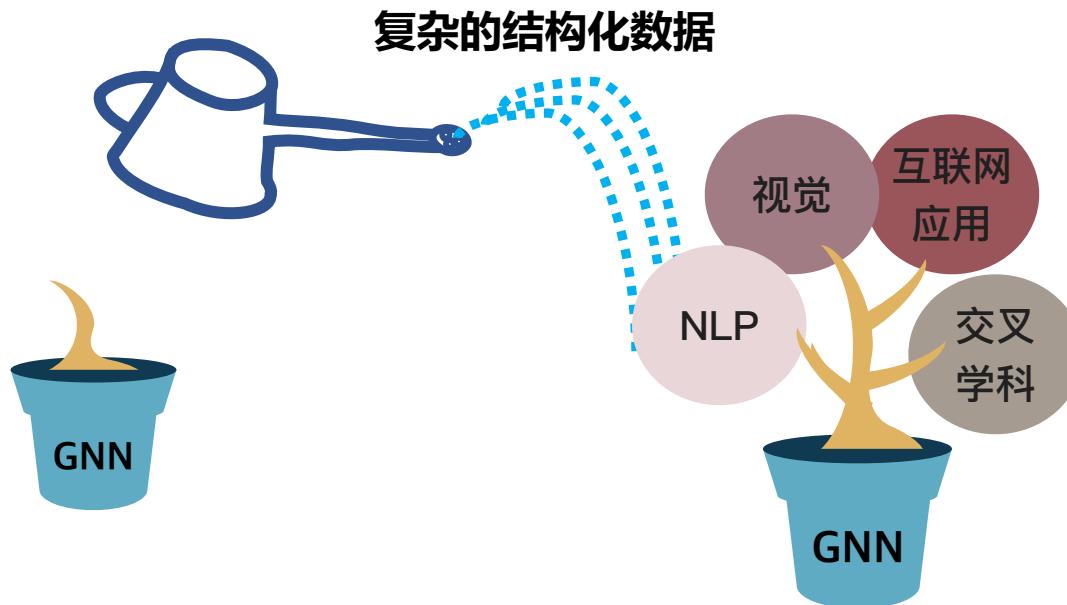


图神经网络发表论文数 (2014-2018)



ICLR 2021 提交Top50关键词

# 图神经网络的兴起：各领域的渗透

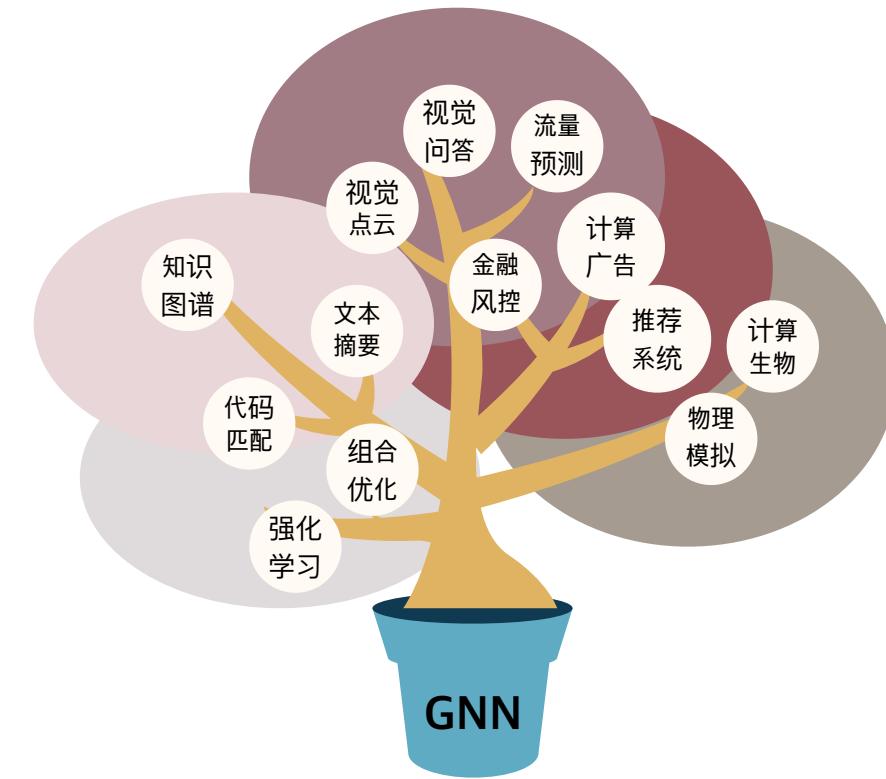


## 图网络结构雏形

- 涌现不同的图网络如GCN、GAT
- 提供了建模复杂结构的工具

## 图网络领域初探

- 在不同的领域引入复杂结构化信息，而信息增益带来收益
- 可迁移性，图网络可以统一不同领域的模型。



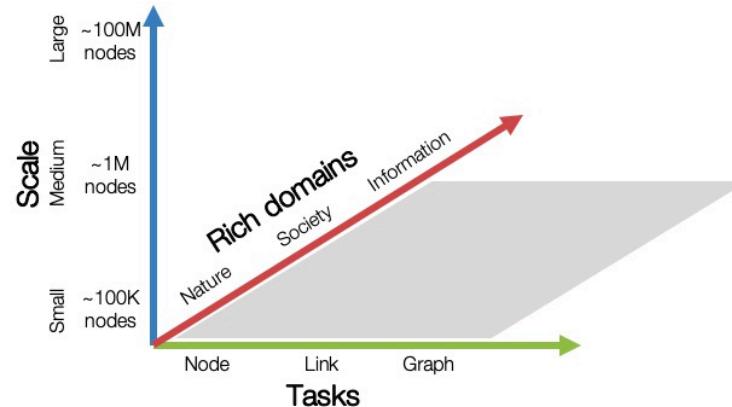
## 图网络应用爆炸

- 全新的解决方案：解决交叉学科的问题，生物计算、药物发现、粒子运动模拟
- 大量落地推荐系统、搜索广告、金融风控

# 图神经网络的兴起：权威榜单出现



- Jure Leskovec、Yoshua Bengio、Will Hamilton、Max Welling等学者提出



图神经网络领域目前最权威的评测榜单：

- 规模大：最大为10亿级
- 领域多：Nature/Society/Information
- 任务多：Node/Link/Graph

<https://ogb.stanford.edu/>

<https://github.com/graphdeeplearning/benchmarking-gnns>

## Benchmarking Graph Neural Networks

Vijay Prakash Dwivedi<sup>1\*</sup>  
vijaypr001@e.ntu.edu.sg

Chaitanya K. Joshi<sup>1\*</sup>  
chaitanya.joshi@ntu.edu.sg

Thomas Laurent<sup>2</sup>  
tlaurent@lmu.edu

Yoshua Bengio<sup>3,4</sup>  
yoshua.bengio@mila.quebec

Xavier Bresson<sup>1</sup>  
xbresson@ntu.edu.sg

<sup>1</sup> School of Computer Science and Engineering, Nanyang Technological University, Singapore

<sup>2</sup> Department of Mathematics, Loyola Marymount University

<sup>3</sup> Mila, University of Montréal

<sup>4</sup> CIFAR

<http://keg.cs.tsinghua.edu.cn/cogdl/leaderboard.html>

## Leaderboard

CogDL provides several downstream tasks including node classification (with or without node attributes), link prediction (with or without attributes, heterogeneous or not). These leaderboards maintain state-of-the-art results and benchmarks on these tasks.

NODE CLASSIFICATION

LINK PREDICTION

GRAPH CLASSIFICATION



# 第三课 图神经网络算法(一)

小斯妹 百度PGL团队成员

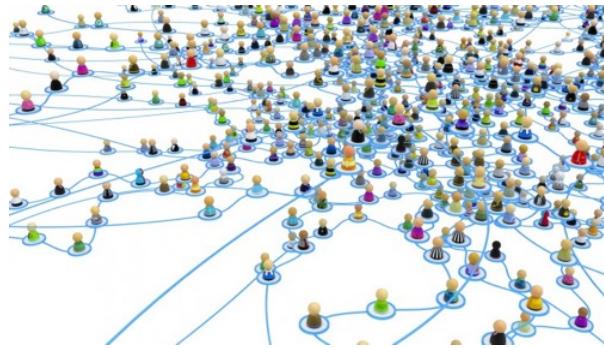


2020.11.25

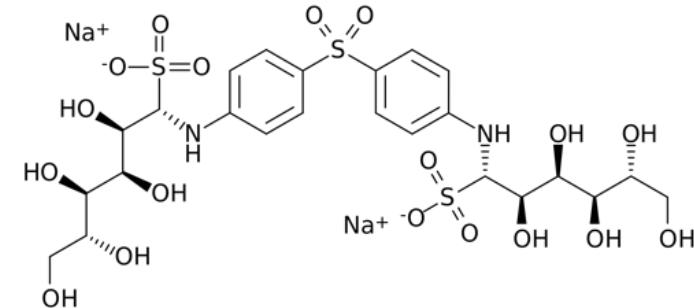


# 简单回顾

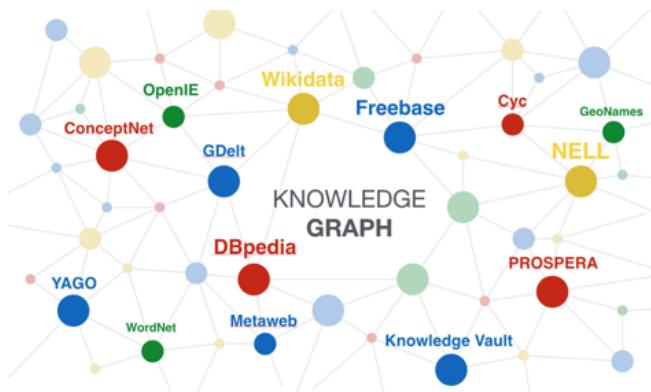
社交关系



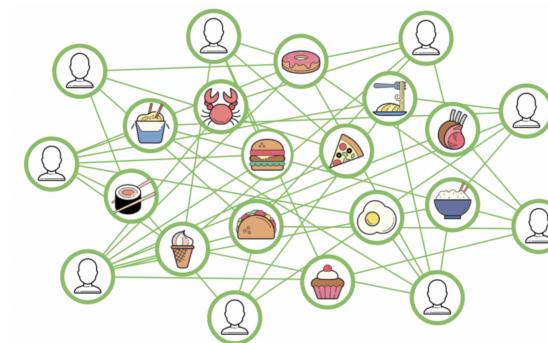
化学分子



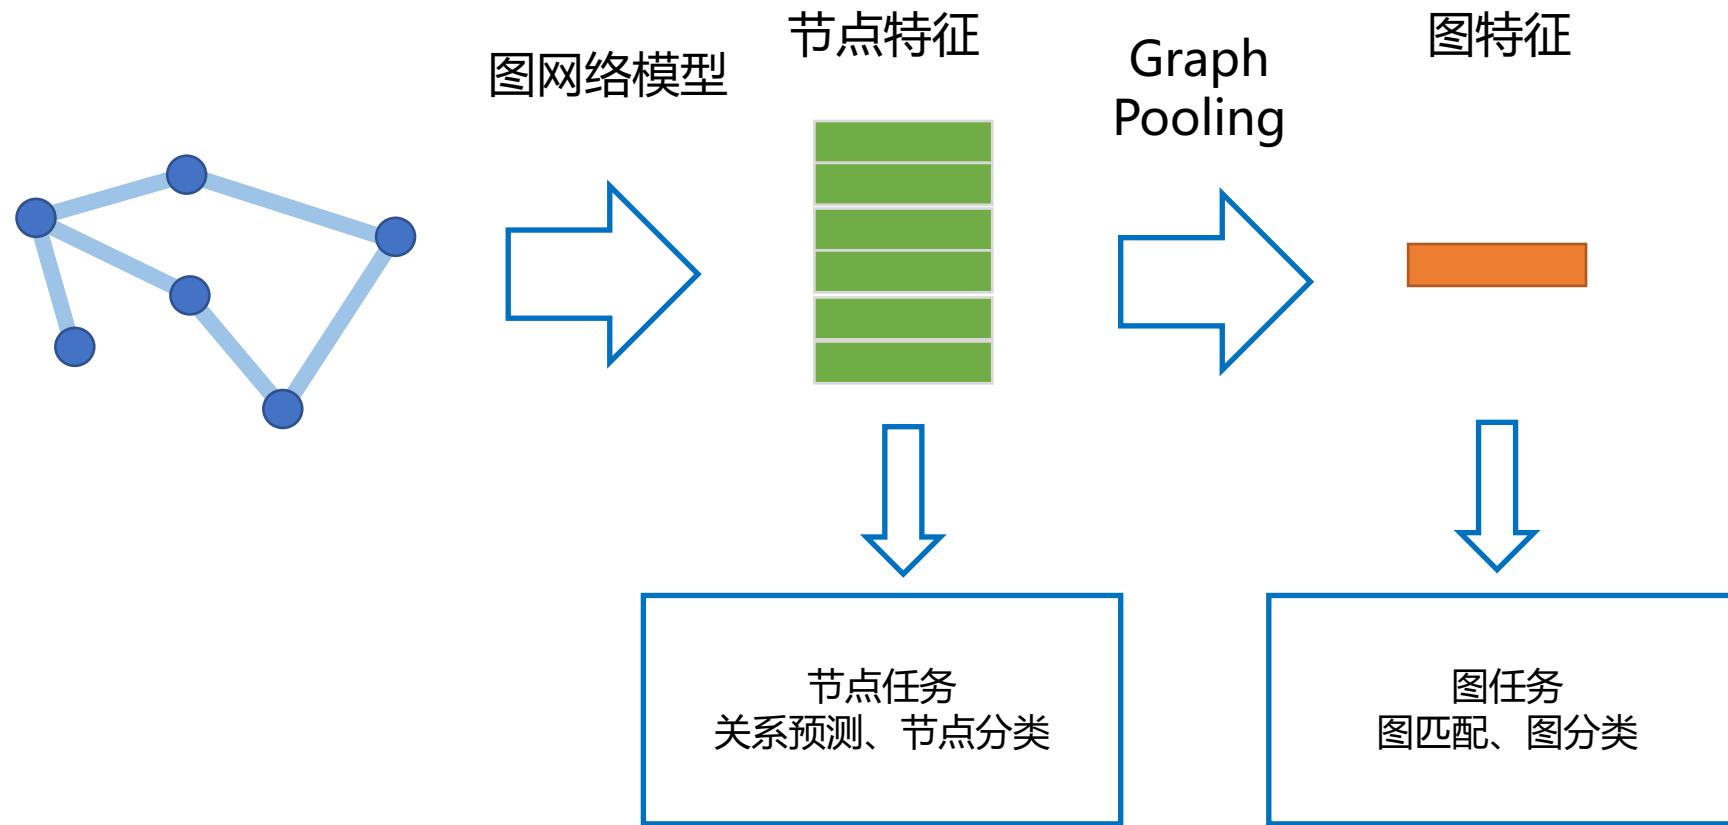
知识图谱



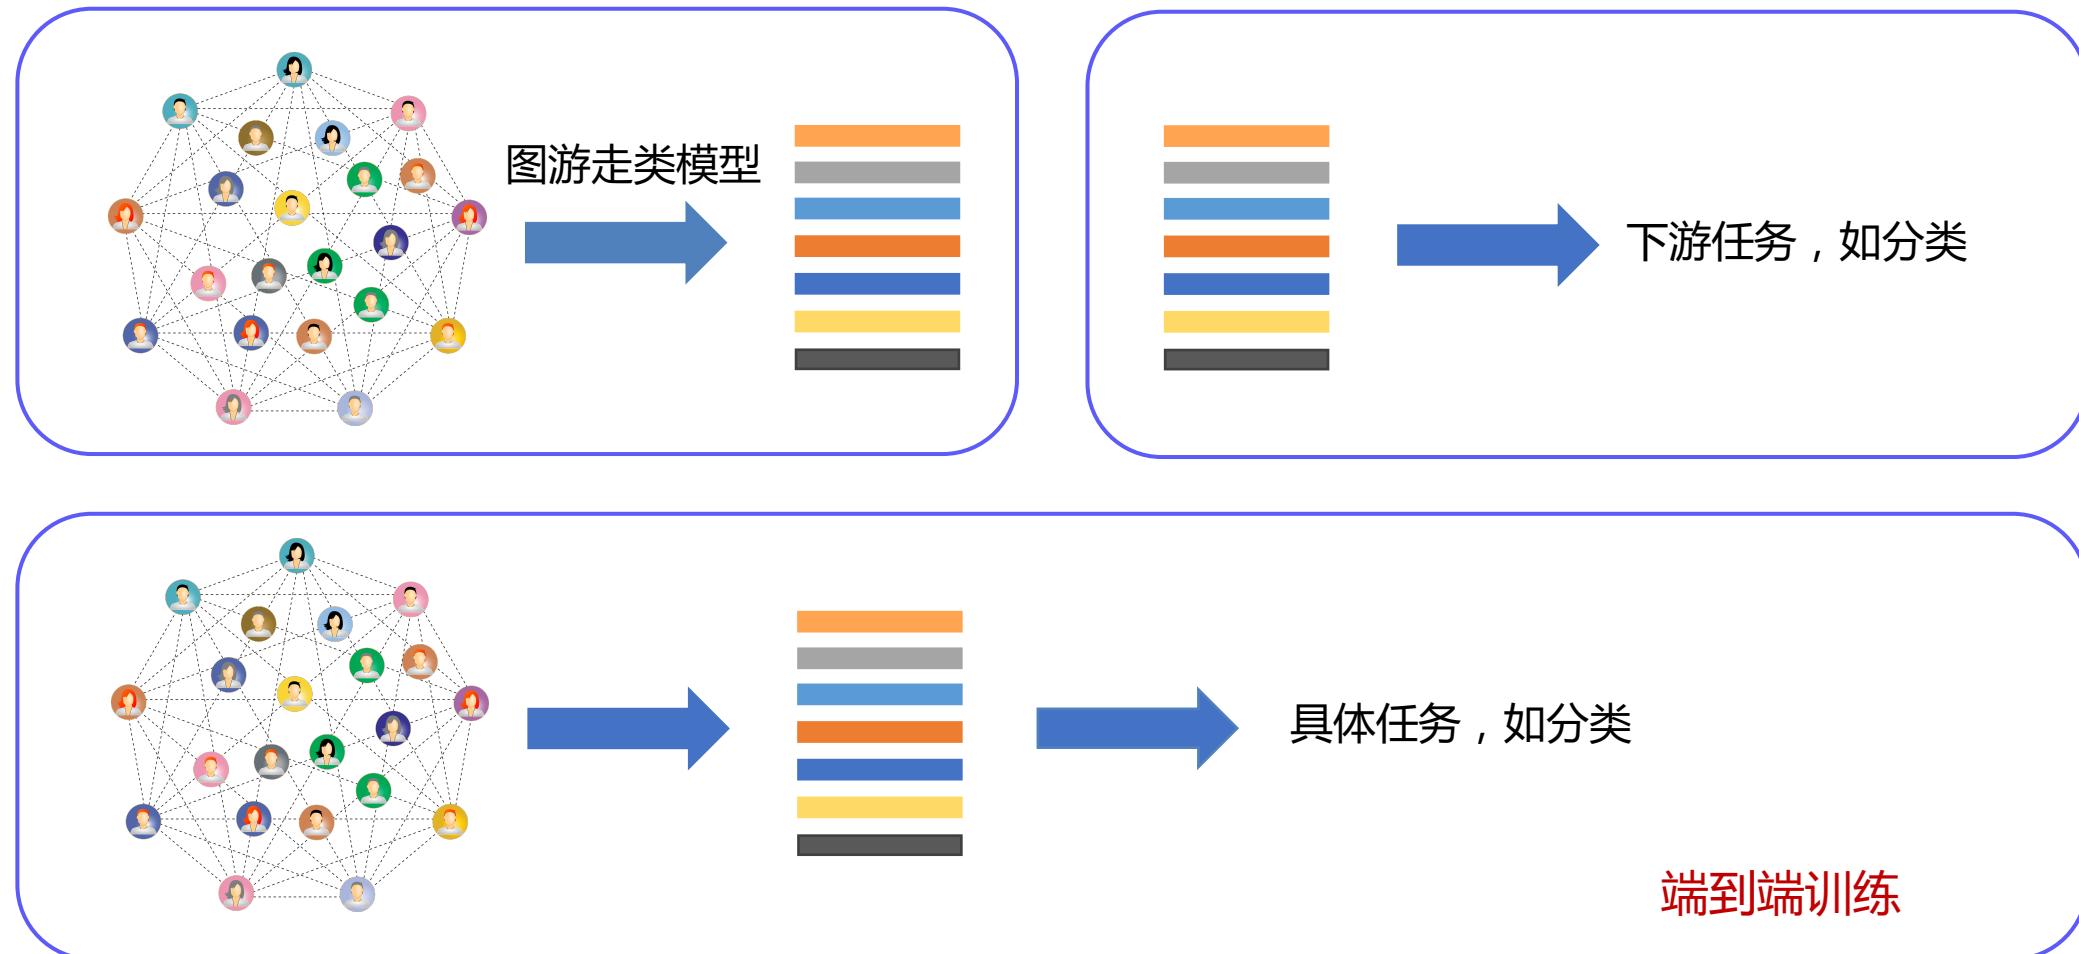
推荐系统



# 图网络的目的

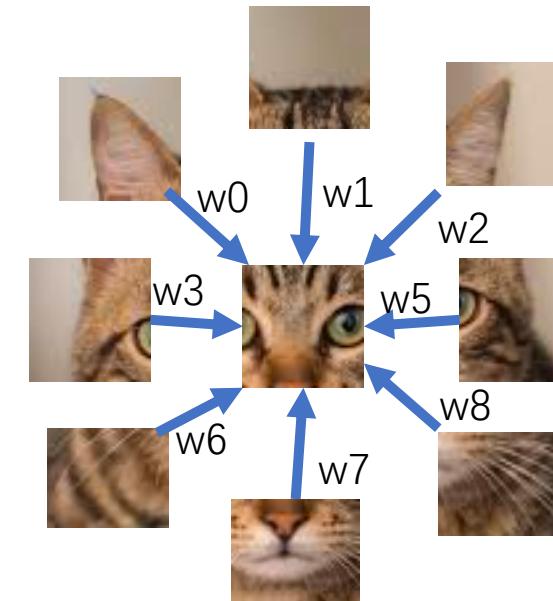
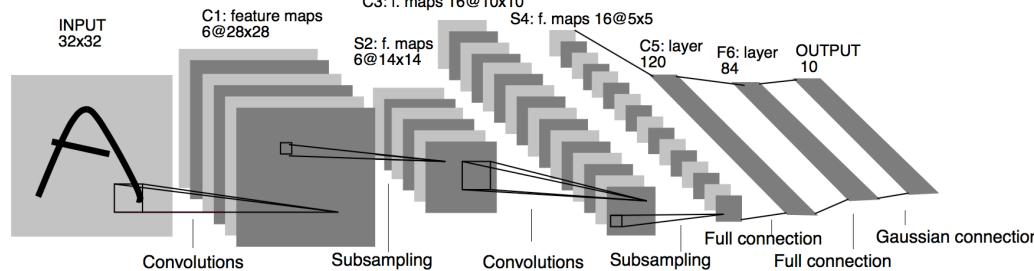


# 训练方式



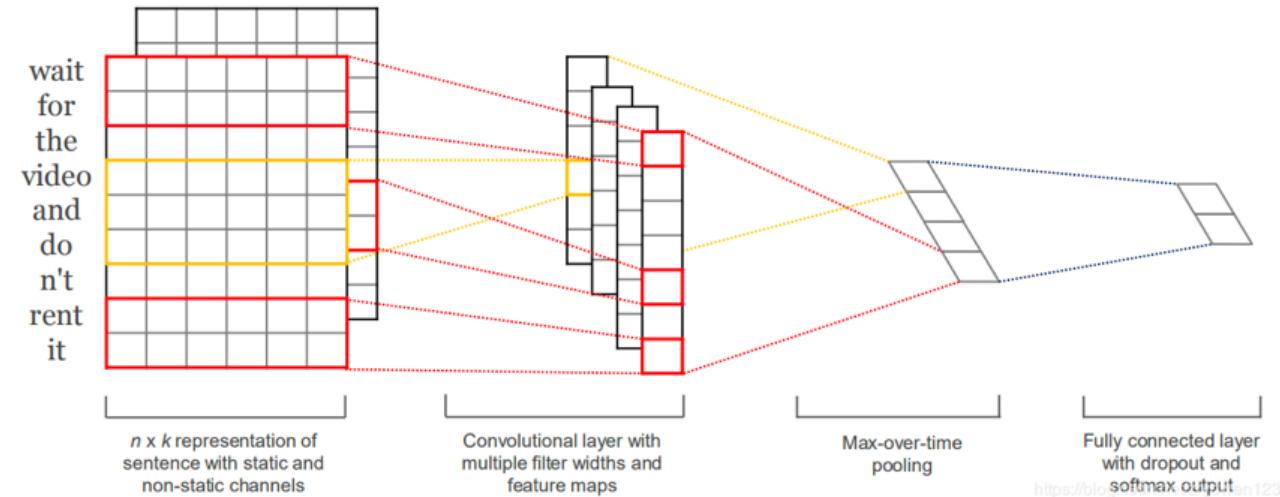
# 回顾DNN在文本以及图像的发展

## 图像上的卷积网络 2D-Convolution



# 回顾DNN在文本以及图像的发展

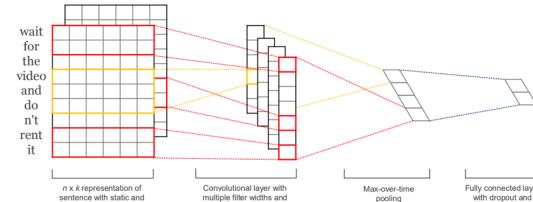
## 文本上的卷积网络 1D-Convolution



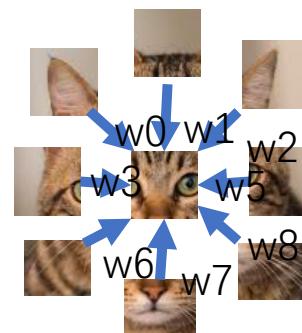
# 规则性数据

排列整齐的数据  
Grid-Like Data

文本

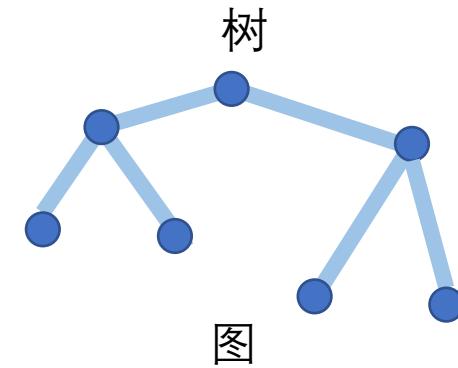


图像

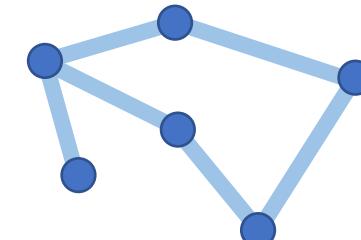


不规则数据

树

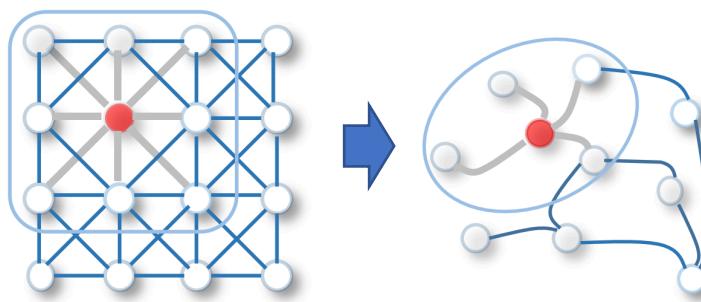


图

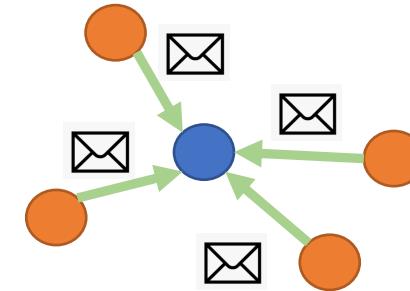


# 图卷积网络

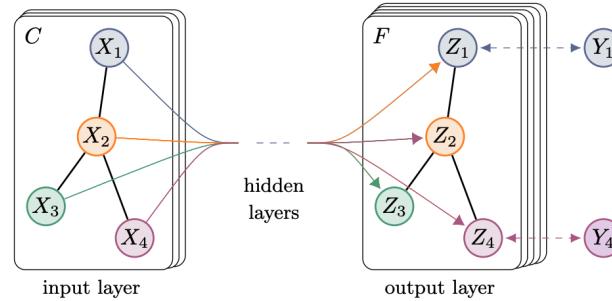
Graph Convolutional Network



如何从**图像卷积**，类比到**图结构卷积**



怎么用**消息传递**方式实现图卷积网络



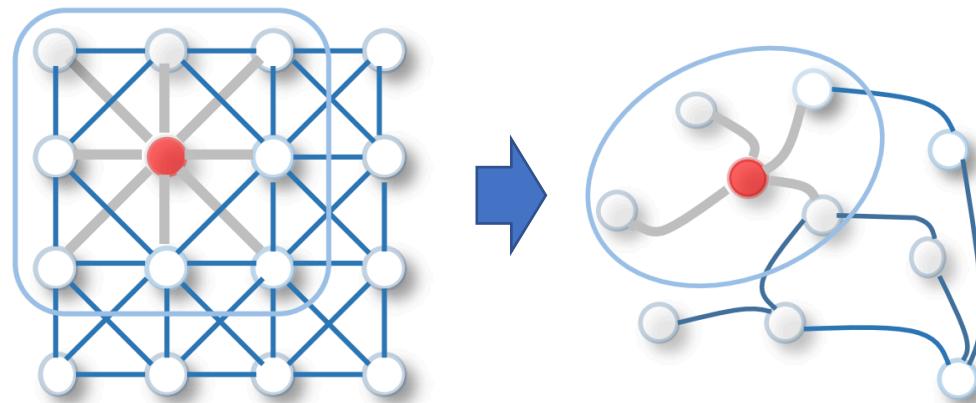
怎么用多层图网络完成**节点分类任务**

参考文献: SEMI-SUPERVISED CLASSIFICATION WITH GRAPH CONVOLUTIONAL NETWORKS (ICLR 2017)

# 图卷积网络

飞桨

Graph Convolutional Network

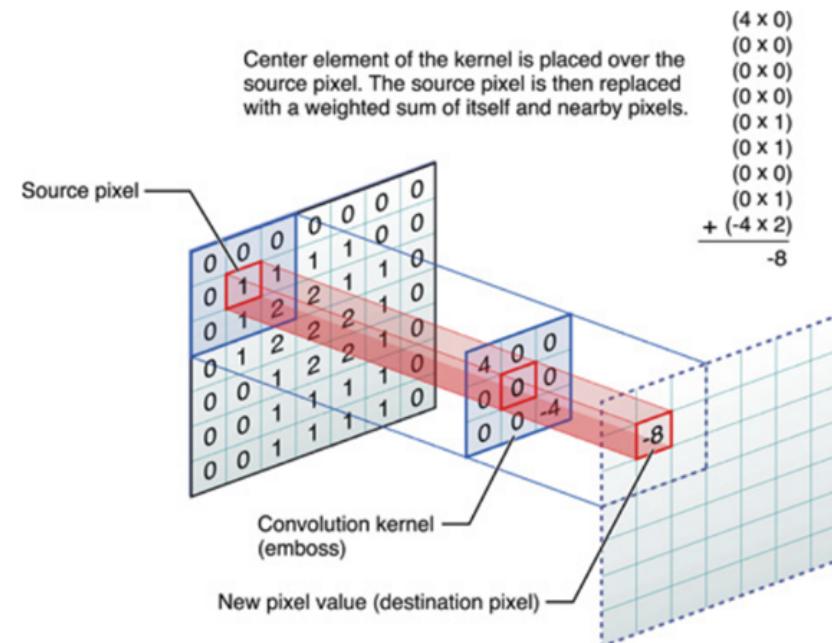
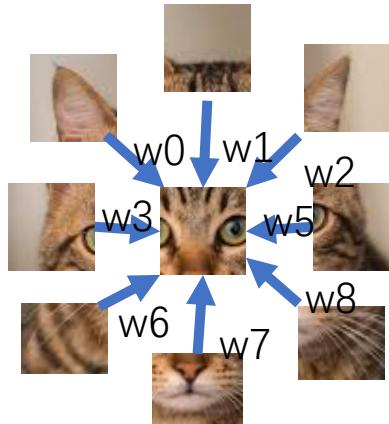


如何从**图像卷积**，类比到**图结构卷积**

# 图卷积网络

Graph Convolutional Network

## 图像上的卷积操作



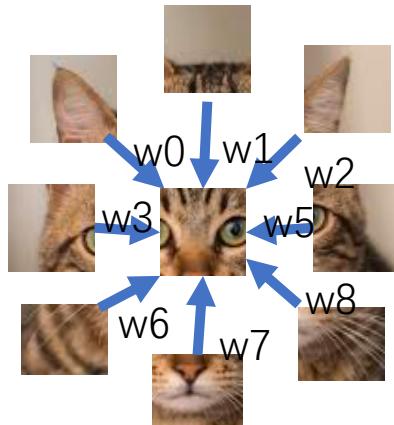
## 图像卷积

将一个**像素点**周围的**像素**按照不同的**权重叠加**起来。

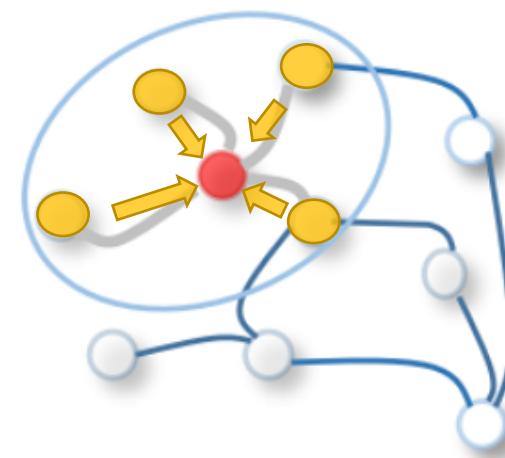
# 图卷积网络

Graph Convolutional Network

图像上的卷积操作



图结构上的卷积



图像卷积

将一个**像素点**周围的**像素**按照不同的**权重叠加**起来。

图结构卷积

将一个**节点**周围的**邻居**按照不同的**权重叠加**起来。

# 图卷积网络

Graph Convolutional Network

## 图卷积网络的计算公式

$$H^{(l+1)} = \sigma \left( \tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)} \right)$$

红框

是图卷积网络的核心公式

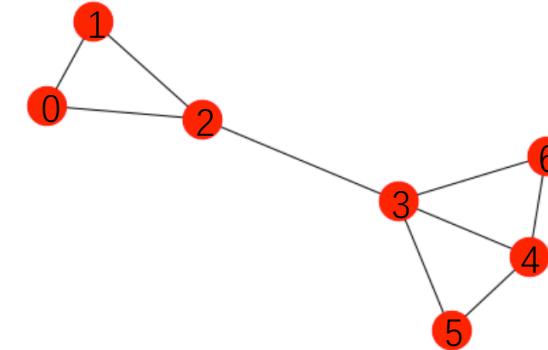
$\hat{A}$  邻接矩阵

$\hat{D}^{-\frac{1}{2}}$  与度矩阵相关

$H^{(l)}$  每一层的节点表示

1	1	1	0	0	0	0
1	1	1	0	0	0	0
1	1	1	1	0	0	0
0	0	1	1	1	1	1
0	0	0	1	1	1	1
0	0	0	1	1	1	0
0	0	0	1	1	0	1

邻接矩阵



# 图卷积网络

Graph Convolutional Network

## 图卷积网络的计算公式

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right)$$

红框

是图卷积网络的核心公式

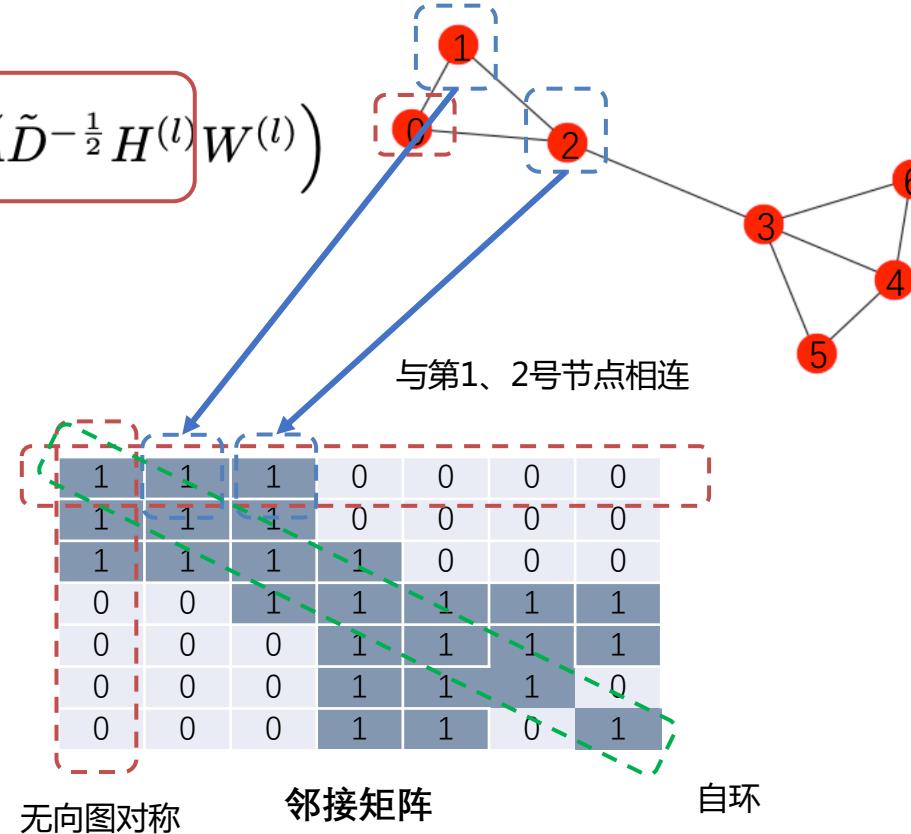
$\hat{A}$  邻接矩阵

$\hat{D}^{-\frac{1}{2}}$  与度矩阵相关

$H^{(l)}$  每一层的节点表示

第0个节点  
的链接

与第1、2号节点相连

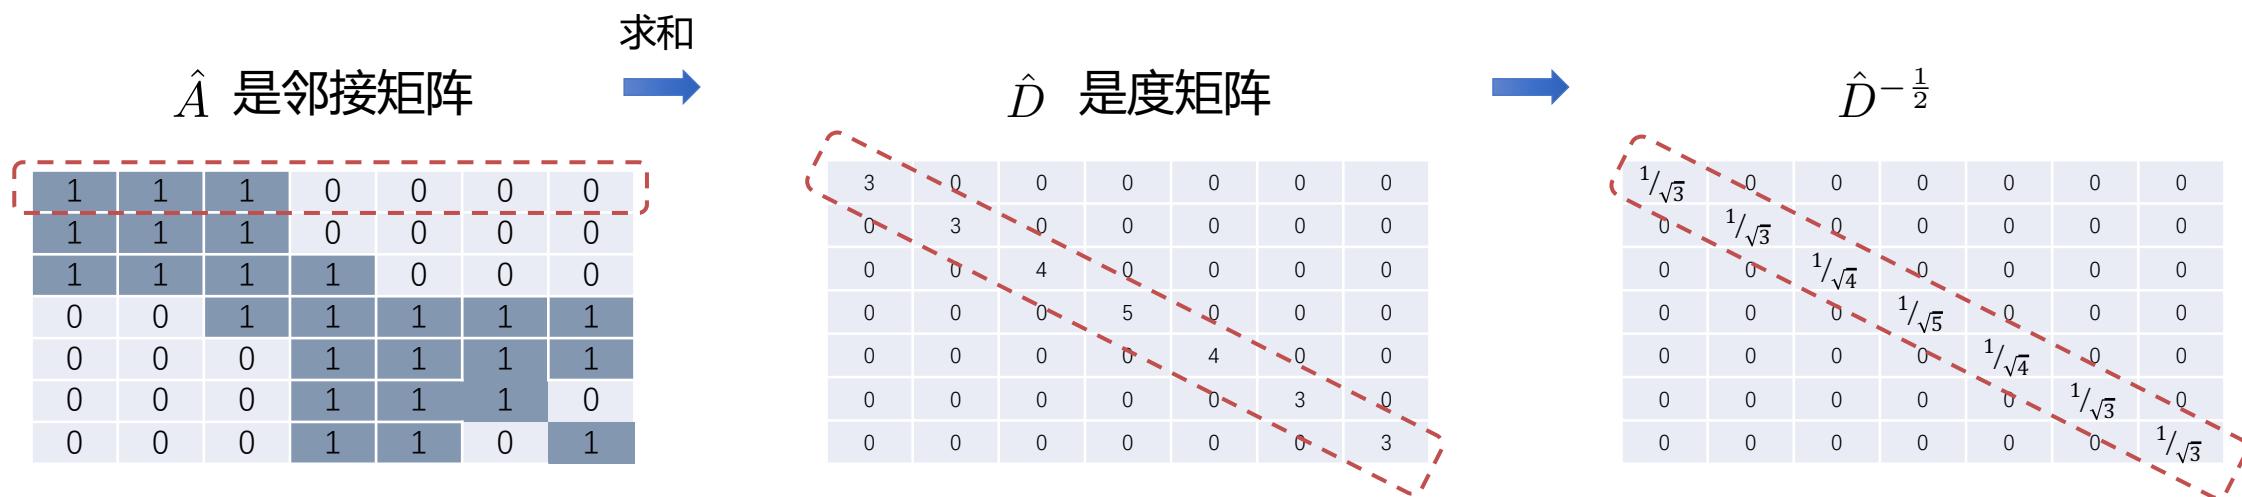
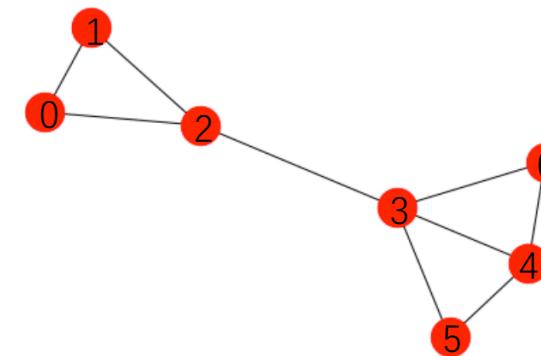


# 图卷积网络

Graph Convolutional Network

## 图卷积网络的计算公式

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right)$$



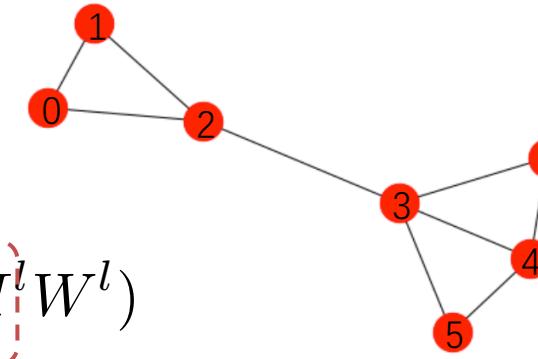
# 图卷积网络

Graph Convolutional Network

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right)$$

简化

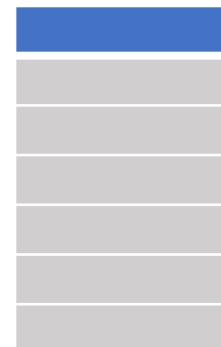
$$H^{(l+1)} = \sigma(\hat{A} H^l W^l)$$



$AH^{(l)}$  公式的物理含义是什么

$$H^{(l+1)}$$

第0节点表示

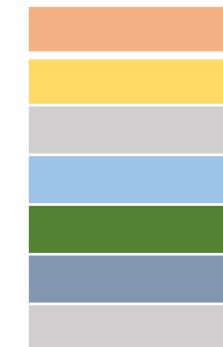


=

$$A$$

1	1	1	0	0	0	0
1	1	1	0	0	0	0
1	1	1	1	0	0	0
0	0	1	1	1	1	1
0	0	0	1	1	1	1
0	0	0	1	1	1	0
0	0	0	1	1	0	1

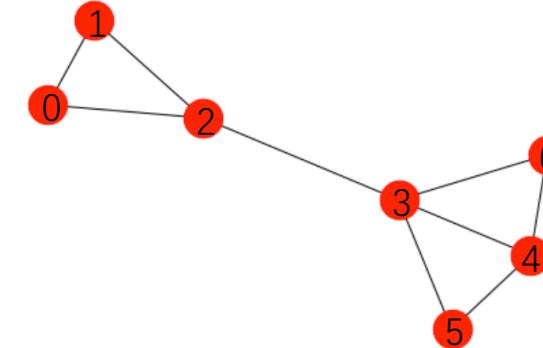
$$H^{(l)}$$



# 图卷积网络

Graph Convolutional Network

$AH^{(l)}$  公式的物理含义是什么



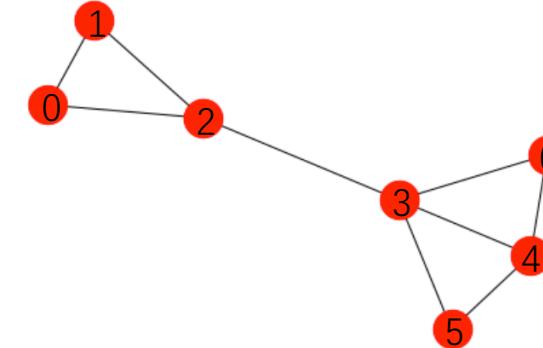
$$H^{(l+1)} = A H^{(l)}$$

第0节点表示

# 图卷积网络

Graph Convolutional Network

$AH^{(l)}$  公式的物理含义是什么



$$H^{(l+1)}$$

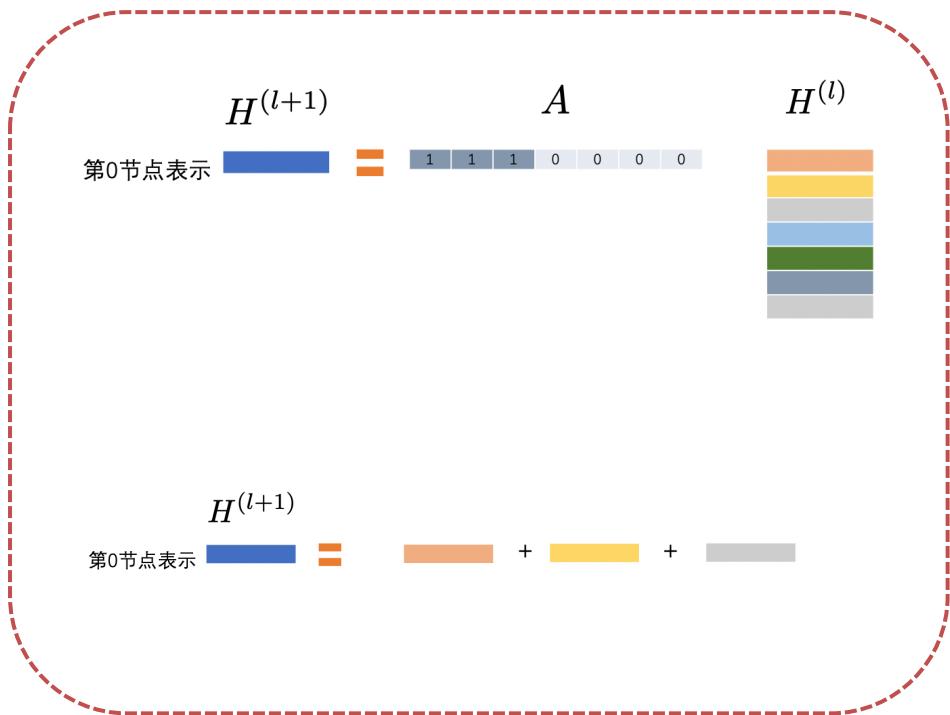
第0节点表示

$$\text{[blue bar]} = \text{[orange bar]} + \text{[yellow bar]} + \text{[grey bar]}$$

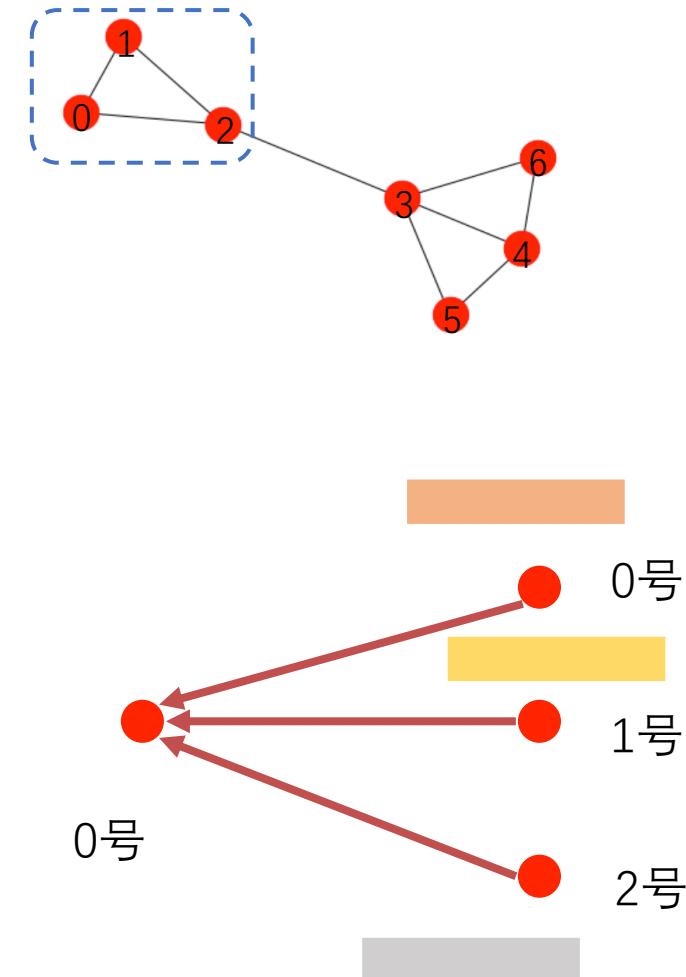
# 图卷积网络

Graph Convolutional Network

$AH^{(l)}$  公式的物理含义是什么

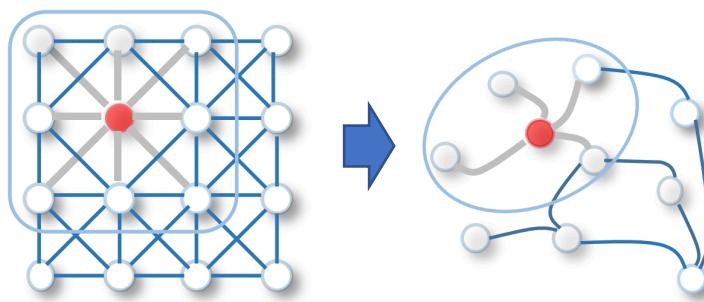


消息传递  
Message Passing

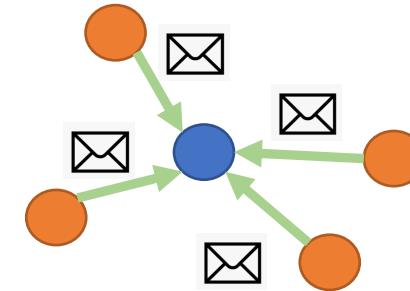


# 图卷积网络

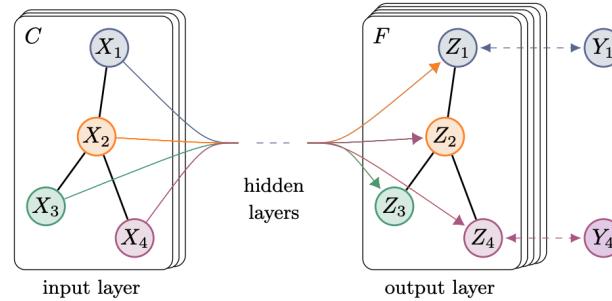
Graph Convolutional Network



如何从**图像卷积**，类比到**图结构卷积**



怎么用**消息传递**方式实现图卷积网络



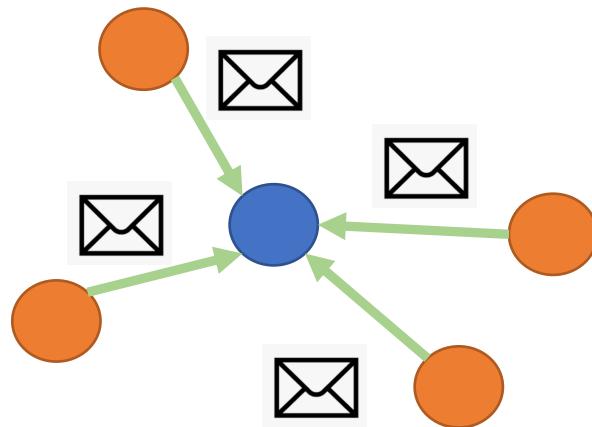
怎么用多层图网络完成**节点分类任务**

参考文献: SEMI-SUPERVISED CLASSIFICATION WITH GRAPH CONVOLUTIONAL NETWORKS (ICLR 2017)

# 图卷积网络

飞桨

Graph Convolutional Network

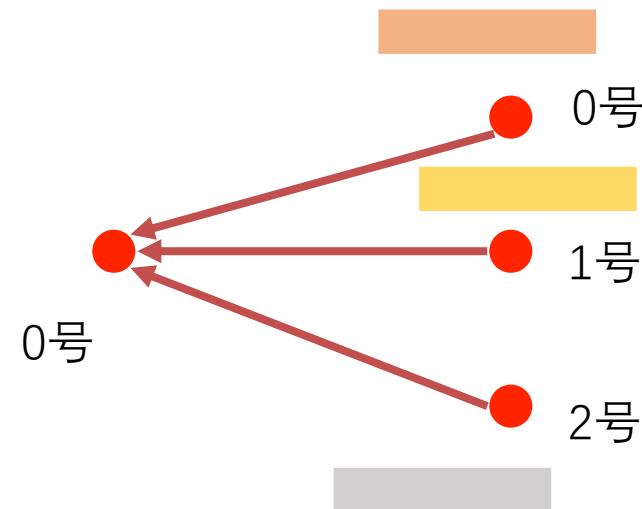


怎么用消息传递方式实现图卷积网络

# 图卷积网络

Graph Convolutional Network

消息传递  
Message Passing



## 发送Send

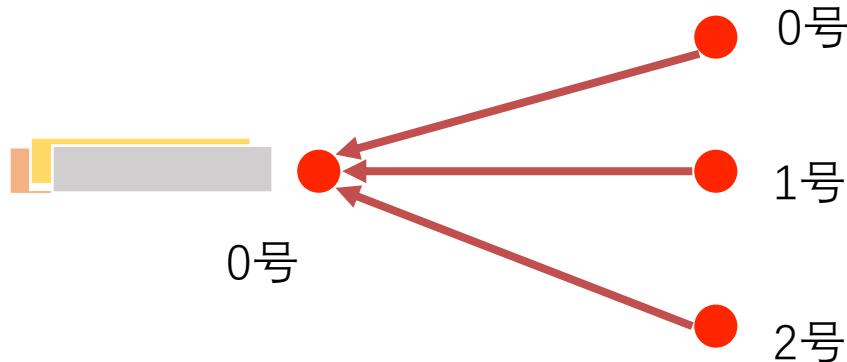
1. 边上的源节点，往目标节点发送特征



# 图卷积网络

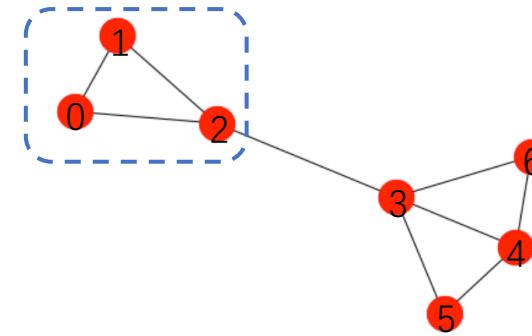
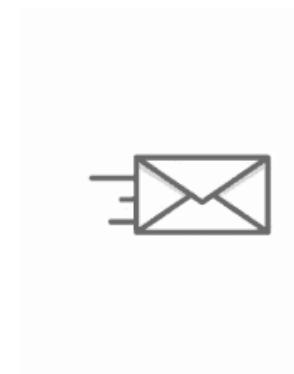
Graph Convolutional Network

消息传递  
Message Passing



## 接收Recv

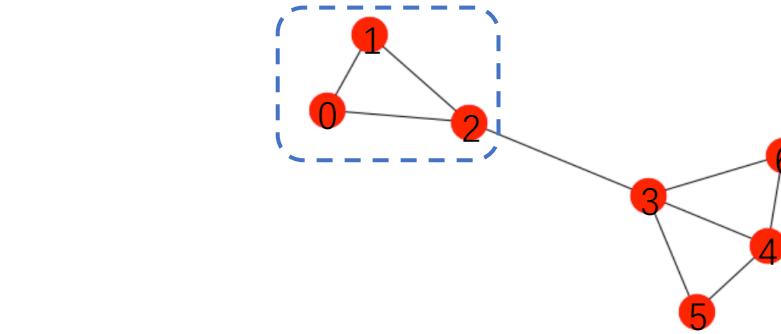
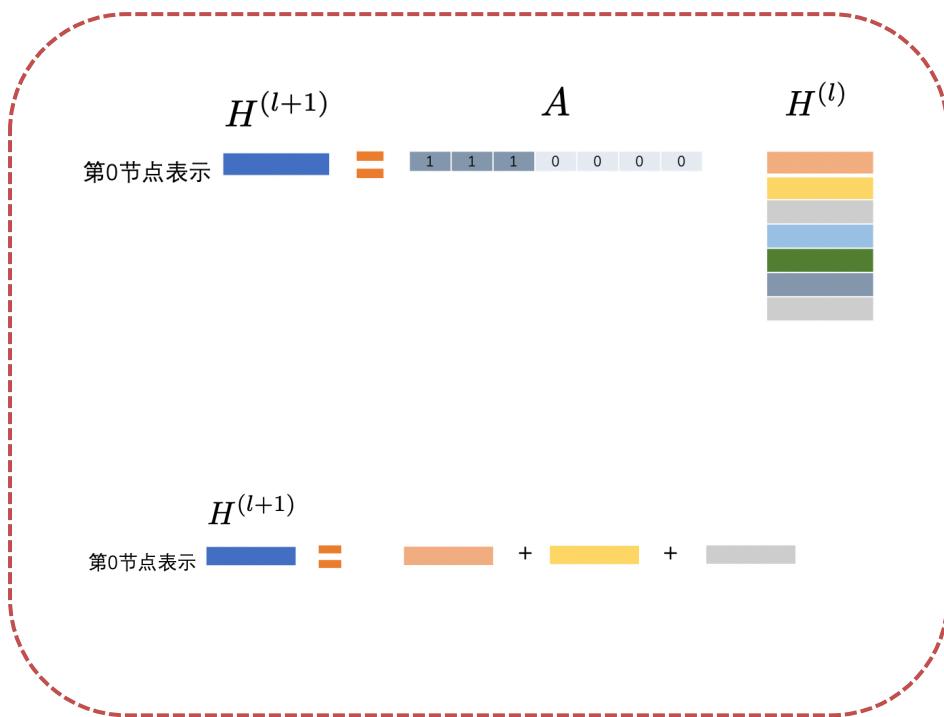
2. 目标节点对收到的特征进行聚合



# 图卷积网络

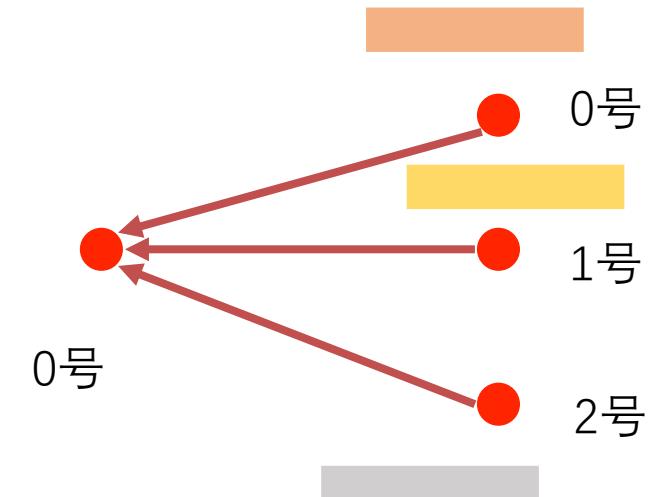
Graph Convolutional Network

$AH^{(l)}$  公式的物理含义是什么



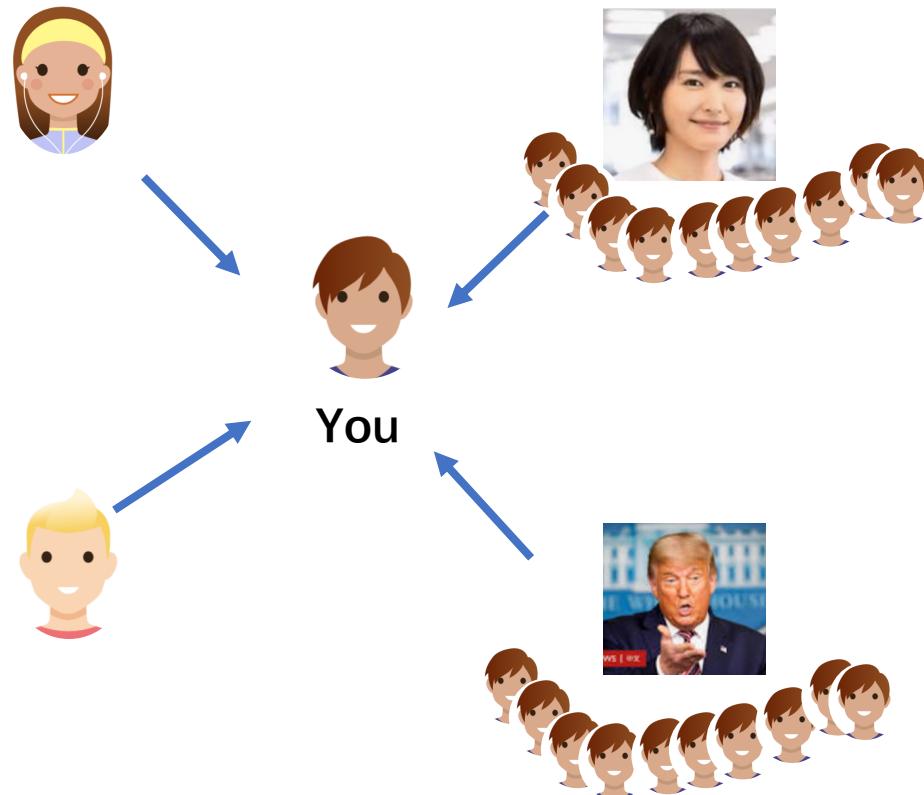
消息传递  
Message Passing

发送SEND 源节点发送特征给目标节点  
接收RECV 目标节点接收特征并统计



# 图卷积网络

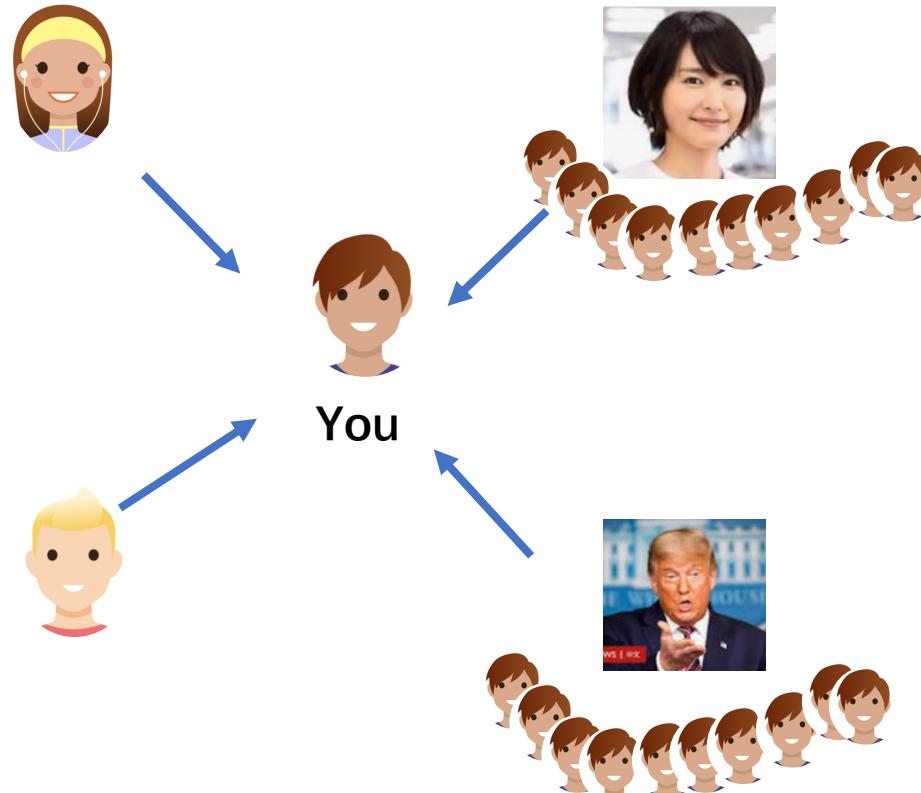
$AH^{(l)}$  将邻居的特征接收、聚合



是否所有的人对自己的评价都是有用的？

# 图卷积网络

$AH^{(l)}$  将邻居的特征接收、聚合

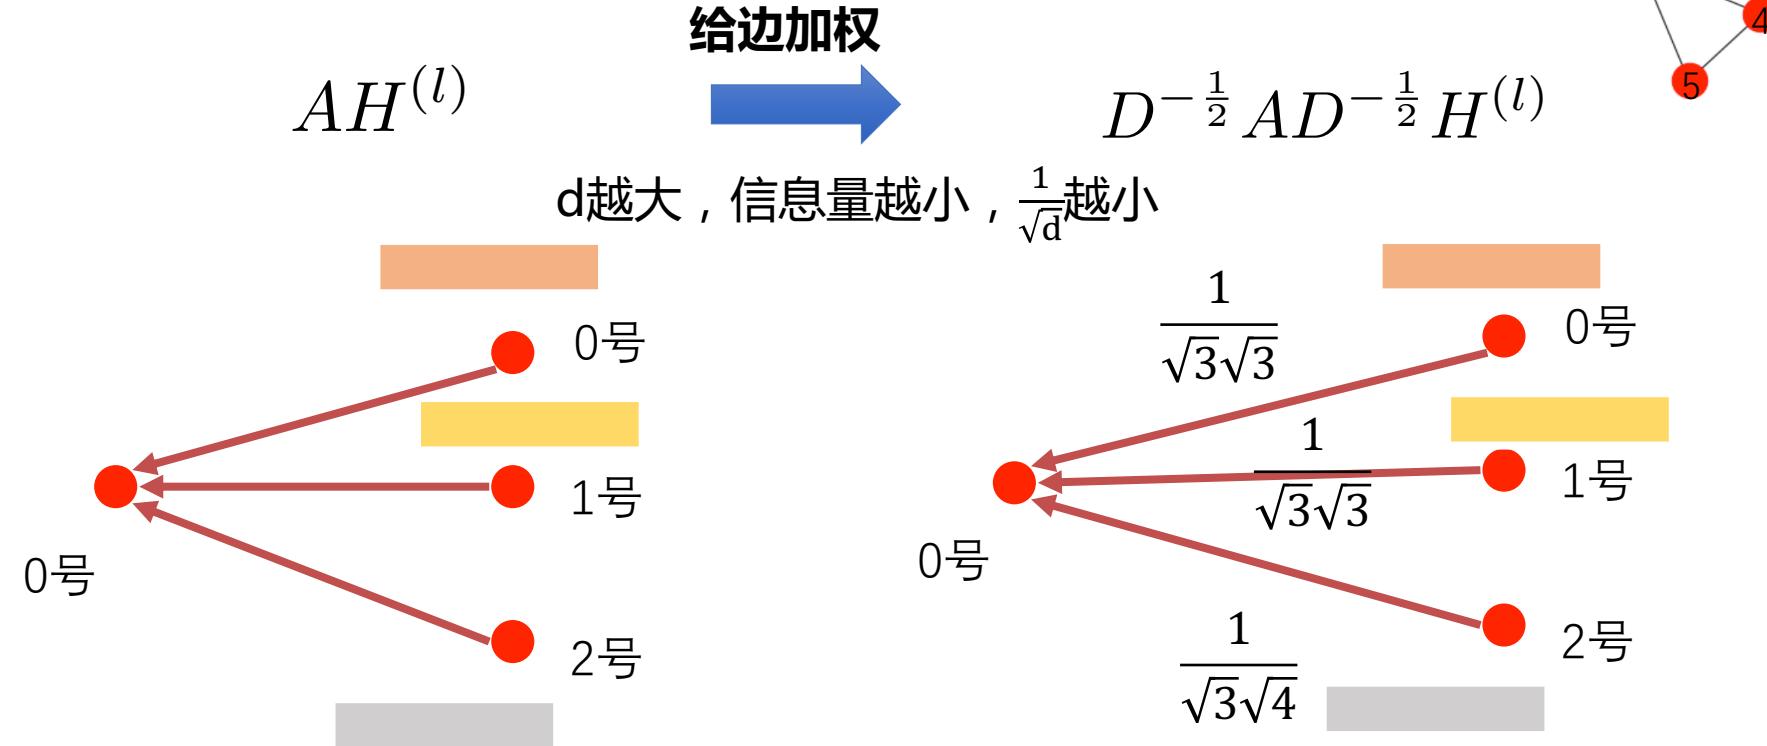


是否所有的人对自己的评价都是有用的？

如何衡量邻居的重要性 度

# 图卷积网络

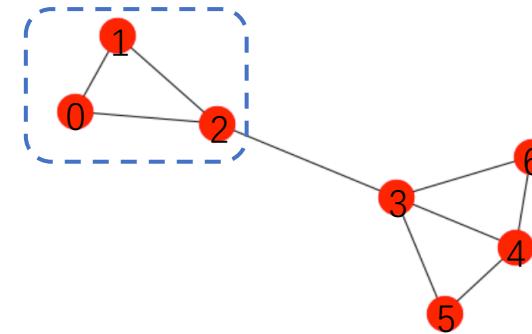
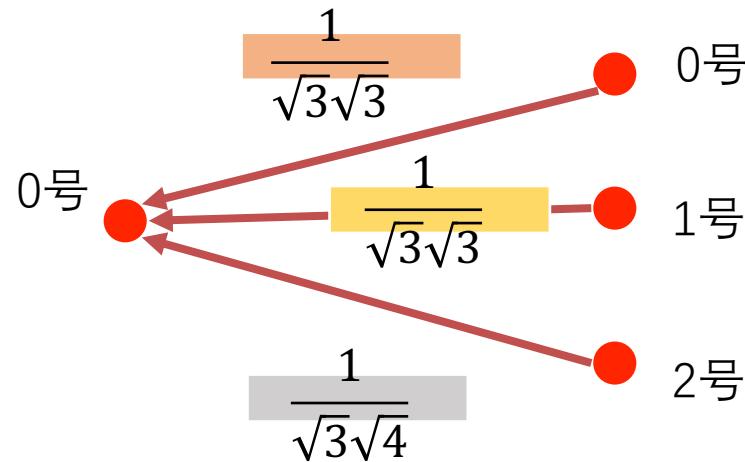
Graph Convolutional Network



# 图卷积网络

Graph Convolutional Network

$$D^{-\frac{1}{2}} A D^{-\frac{1}{2}} H^{(l)}$$



在PGL中Message Passing实现

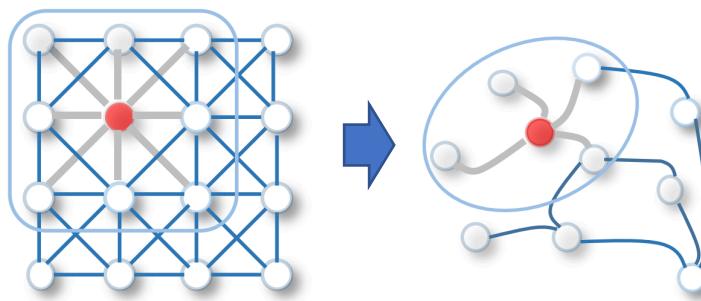
```
from paddle.fluid.layers import sequence_pool as pool

# 发送函数，从发送源src到发送目标点dst
def send(src_feat, dst_feat, edge_feat):
    return src_feat["norm"] * dst_feat["norm"] * src_feat["h"]

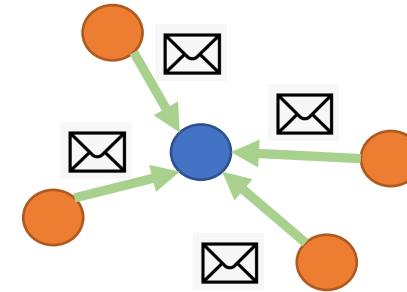
# 接收函数，从发送源src到发送目标点dst
def recv(message):
    return pool(message, "sum")
```

# 图卷积网络

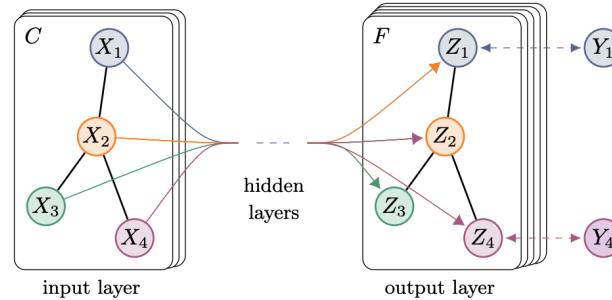
Graph Convolutional Network



如何从**图像卷积**，类比到**图结构卷积**



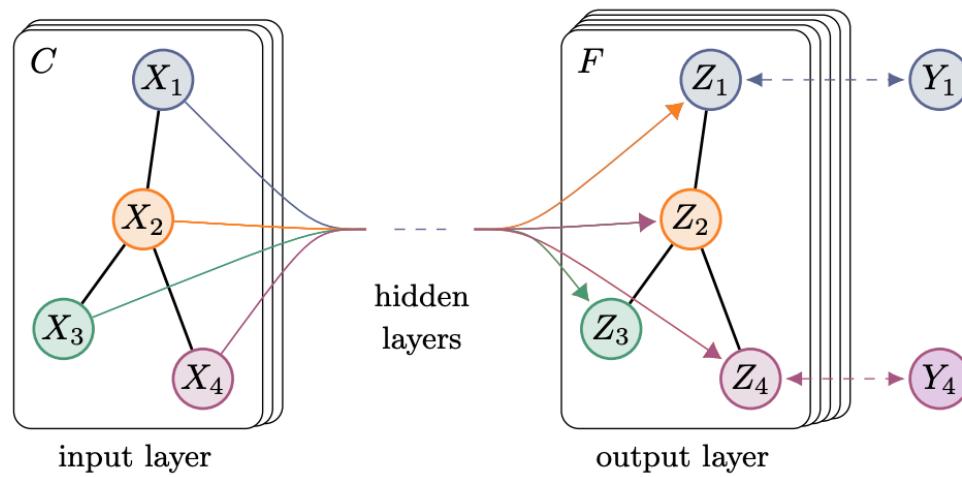
怎么用**消息传递**方式实现图卷积网络



怎么用多层图网络完成**节点分类任务**

# 图卷积网络

Graph Convolutional Network



怎么用多层图网络完成**节点分类任务**

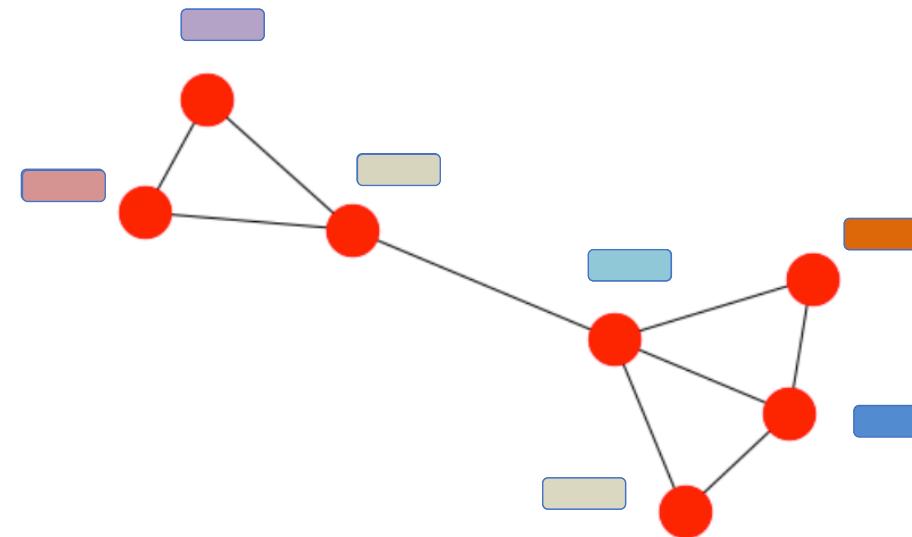
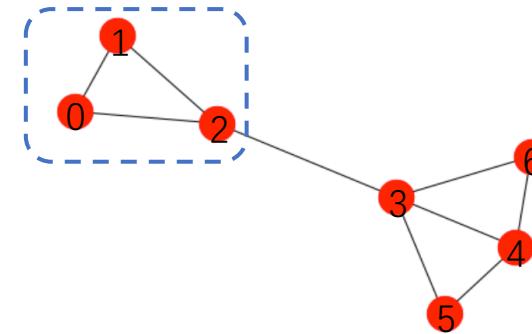
# 图卷积网络

Graph Convolutional Network

GCN算法全流程

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right)$$

第一步： $\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)}$  节点间进行特征传递

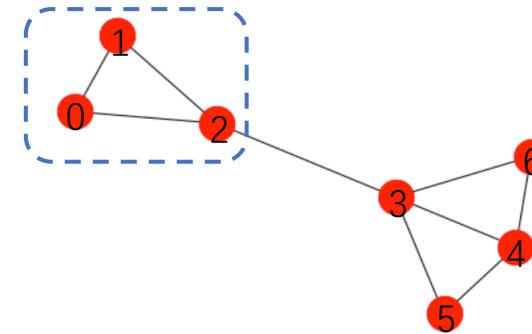


# 图卷积网络

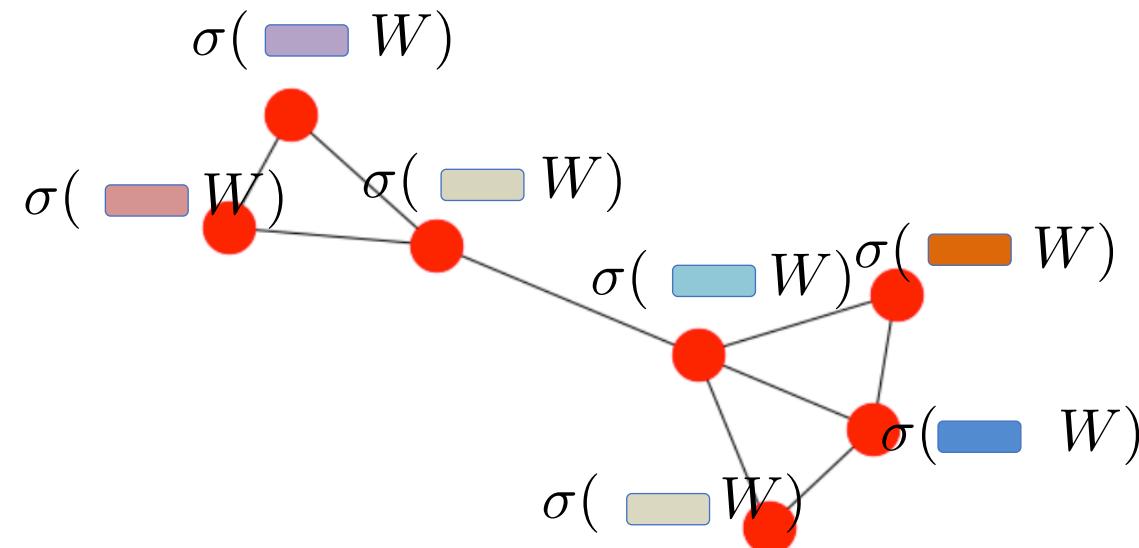
Graph Convolutional Network

GCN算法全流程

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}}\tilde{A}\tilde{D}^{-\frac{1}{2}}H^{(l)}W^{(l)}\right)$$



第二步：对每一个节点过一层DNN



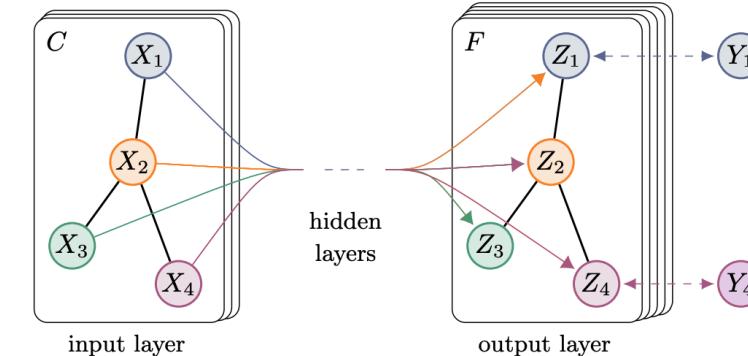
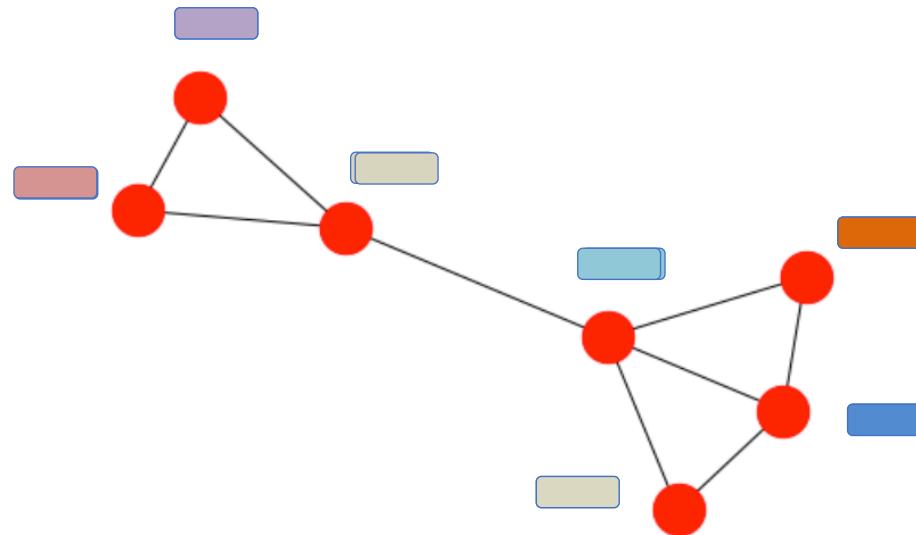
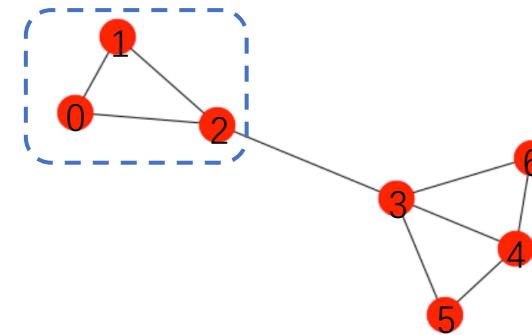
# 图卷积网络

Graph Convolutional Network

GCN算法全流程

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right)$$

重复L次，步骤1和步骤2，实现多层图卷积网络



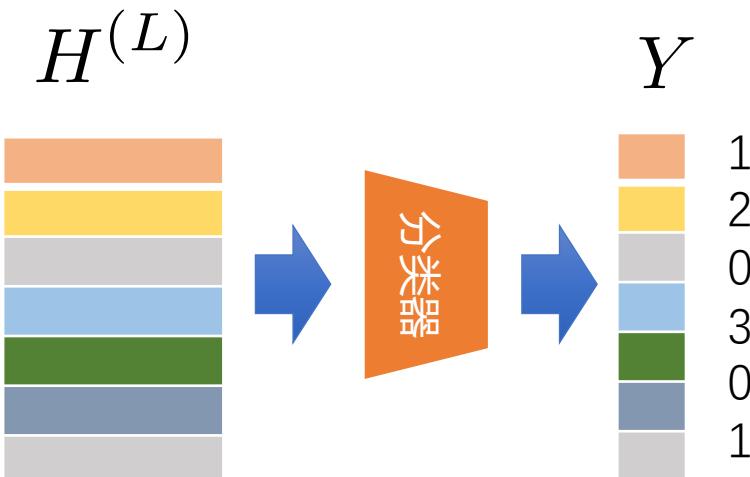
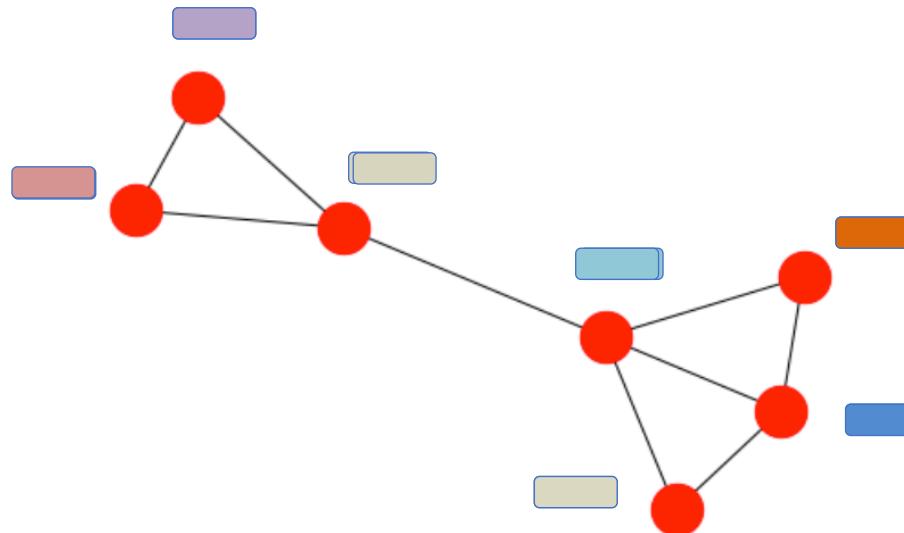
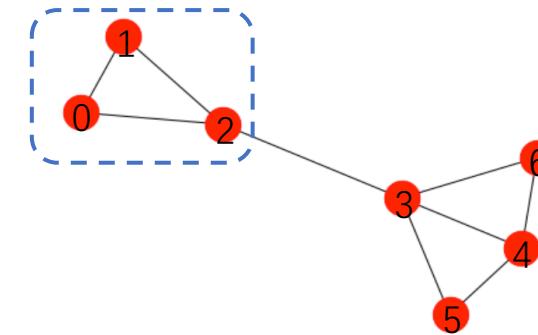
# 图卷积网络

Graph Convolutional Network

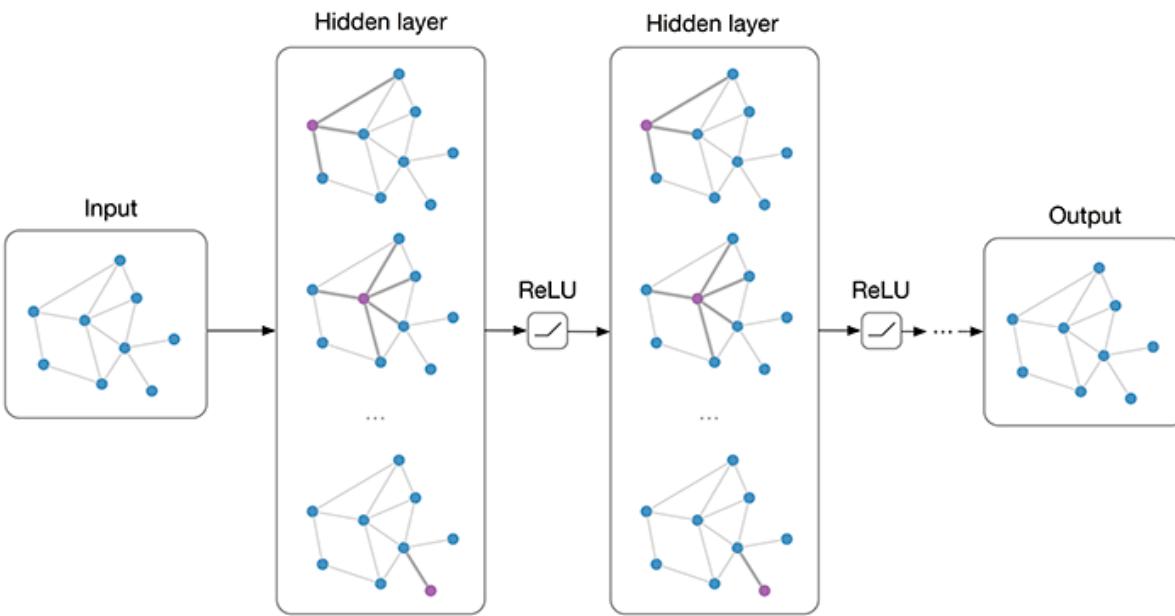
GCN算法全流程

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right)$$

获取的最终表示  $H^{(L)}$  作为最终节点表示

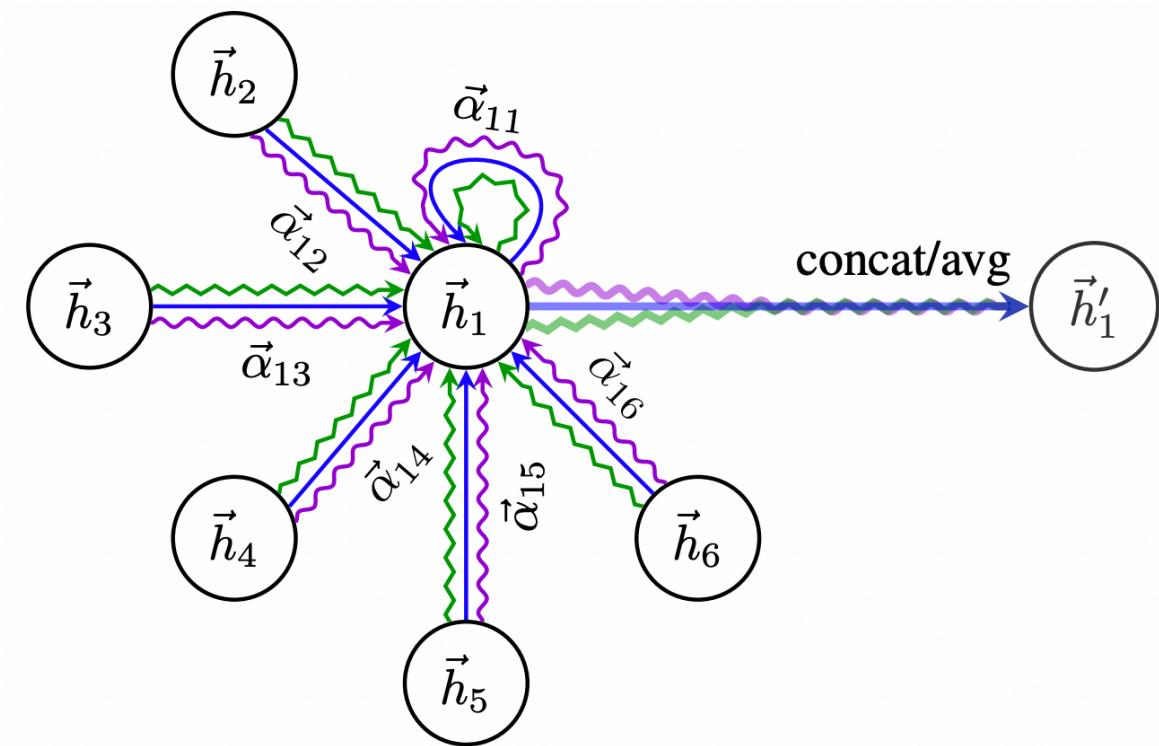


# 图卷积网络多种形式



图卷积网络 ( GCN )

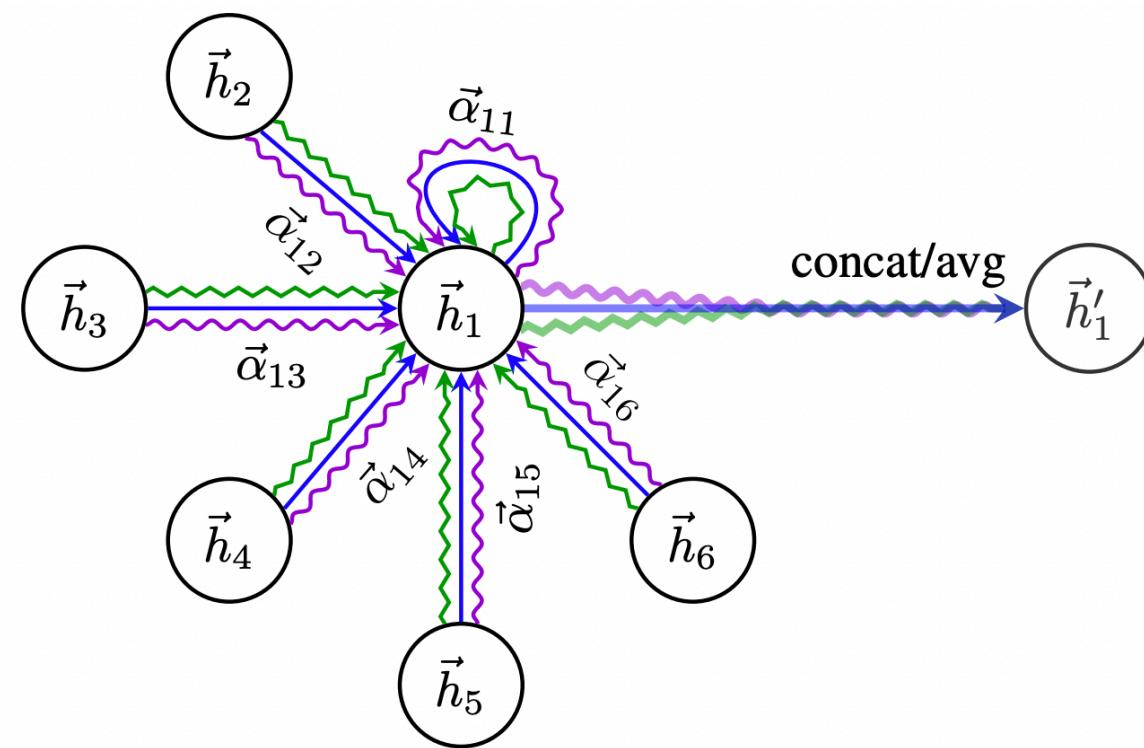
Kipf, Thomas N and Welling, Max  
Semi-Supervised Classification with Graph Convolutional Networks  
ICLR 2017



图注意力网络 ( GAT )

Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò and Yoshua Bengio  
Graph Attention Networks,  
ICLR 2018

# 图卷积网络多种形式



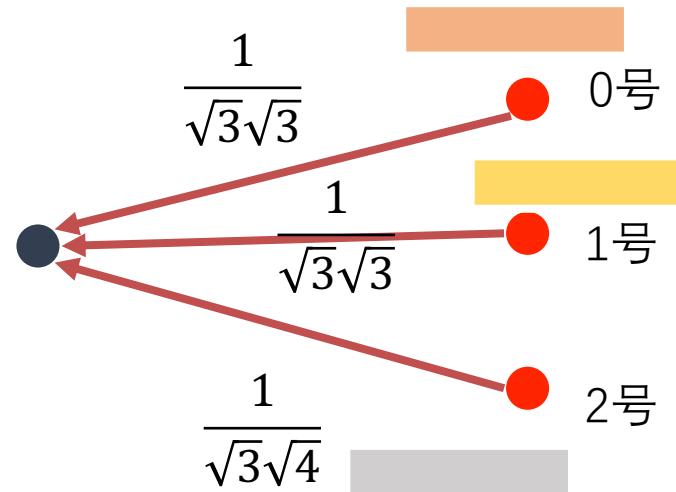
图注意力网络 ( GAT )

Petar Veličković, Guillem Cucurull, Arantxa Casanova, Adriana Romero, Pietro Liò and Yoshua Bengio  
Graph Attention Networks,  
ICLR 2018

# 图注意力网络

Graph Attention Network

$$D^{-\frac{1}{2}} A D^{-\frac{1}{2}} H^{(l)}$$

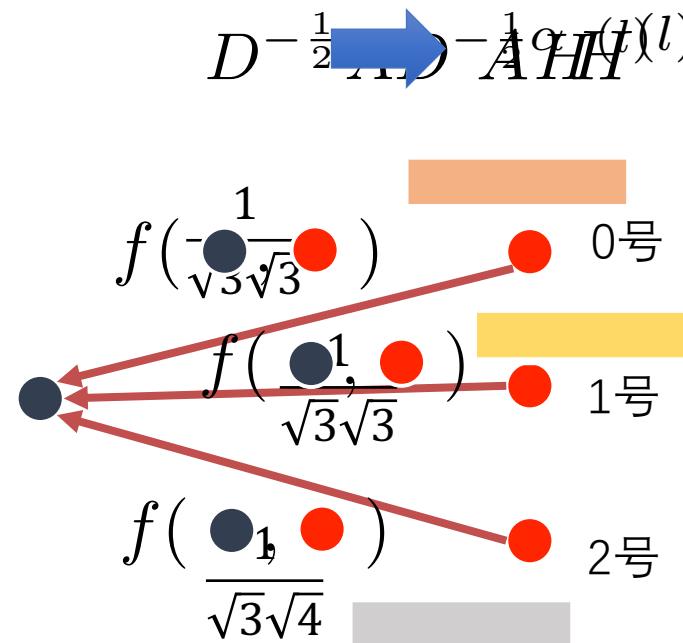


GCN中边的权重：

- 与节点的度相关
- 不可学习

# 图注意力网络

Graph Attention Network



GCN中边的权重：

- 与节点的度相关
- 不可学习



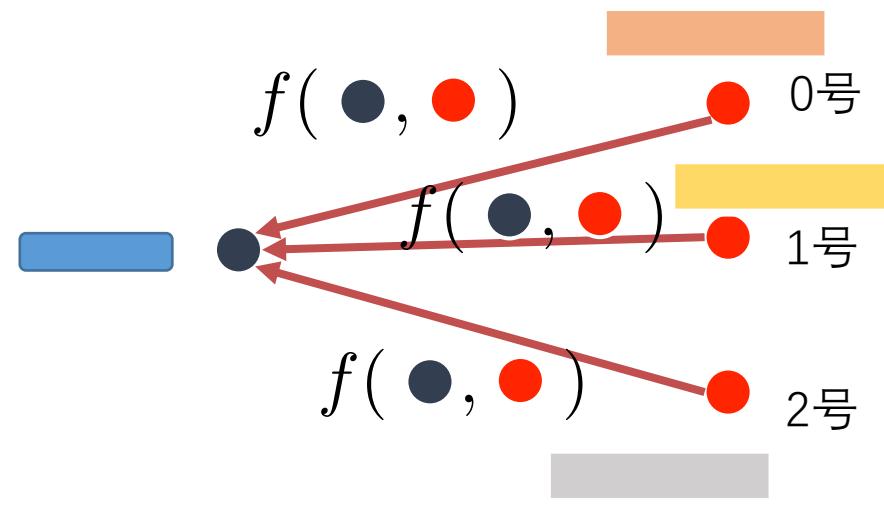
GAT中的边权重

$$f(\bullet, \bullet)$$

- 权重变成节点间的函数
- 权重与两个节点相关性有关
- 可学习

# 图注意力网络

Graph Attention Network



attention计算方法

$$\alpha_{ij} = \frac{\exp \left( \text{LeakyReLU} \left( \vec{\mathbf{a}}^T [\mathbf{W}\vec{h}_i \| \mathbf{W}\vec{h}_j] \right) \right)}{\sum_{k \in \mathcal{N}_i} \exp \left( \text{LeakyReLU} \left( \vec{\mathbf{a}}^T [\mathbf{W}\vec{h}_i \| \mathbf{W}\vec{h}_k] \right) \right)}$$

特征聚合计算方法

$$\vec{h}'_i = \sigma \left( \sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}\vec{h}_j \right)$$

# 图注意力网络

飞桨

Graph Attention Network

attention计算方法

$$\alpha_{ij} = \frac{\exp \left( \text{LeakyReLU} \left( \vec{a}^T [\mathbf{W}\vec{h}_i \| \mathbf{W}\vec{h}_j] \right) \right)}{\sum_{k \in \mathcal{N}_i} \exp \left( \text{LeakyReLU} \left( \vec{a}^T [\mathbf{W}\vec{h}_i \| \mathbf{W}\vec{h}_k] \right) \right)}$$

特征聚合计算方法

$$\vec{h}'_i = \sigma \left( \sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}\vec{h}_j \right)$$

单头GAT消息传递在PGL中Message Passing实现

```
from paddle.fluid.layers import sequence_pool as pool
from paddle.fluid.layers import sequence_softmax as edge_softmax
import paddle.fluid.layers as L
...
# 发送函数，从发送源src到发送目标点dst
def send(src_feat, dst_feat, edge_feat):
    src_weight = L.fc(src_feat["h"], size=1, name="a1_weight")
    dst_weight = L.fc(dst_feat["h"], size=1, name="a2_weight")
    weight = L.leaky_relu(src_weight + dst_weight, alpha=0.2)
    # 计算每一条边的源节点以及目标节点相关性
    return {"weight": weight, "h": src_feat["h"]}

# 接收函数，从发送源src到发送目标点dst
def recv(message):
    # 对相关性进行softmax 归一化
    alpha = edge_softmax(message["weight"])
    hidden = pool(alpha * message["h"], "sum")
    return hidden
```

# 图注意力网络

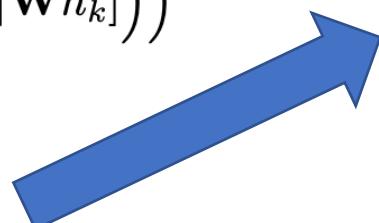
Graph Attention Network

attention计算方法

$$\alpha_{ij} = \frac{\exp \left( \text{LeakyReLU} \left( \vec{a}^T [\mathbf{W}\vec{h}_i \| \mathbf{W}\vec{h}_j] \right) \right)}{\sum_{k \in \mathcal{N}_i} \exp \left( \text{LeakyReLU} \left( \vec{a}^T [\mathbf{W}\vec{h}_i \| \mathbf{W}\vec{h}_k] \right) \right)}$$

特征聚合并计算方法

$$\vec{h}'_i = \sigma \left( \sum_{j \in \mathcal{N}_i} \alpha_{ij} \mathbf{W}\vec{h}_j \right)$$



多头 Attention 特征聚合方法

$$\vec{h}'_i = \left\| \sum_{k=1}^K \sigma \left( \sum_{j \in \mathcal{N}_i} \alpha_{ij}^k \mathbf{W}^k \vec{h}_j \right) \right\|$$

```
for head_no in range(n_heads):
    # 请完成单头的GAT的代码
    single_output = single_head_gat(graph_wrapper,
        node_feature,
        hidden_size,
        name="head_%s" % (head_no) )
    heads_output.append(single_output)
```

作业部分代码

`num_nodes * feature_size -> num_heads * num_nodes * hidden_size`

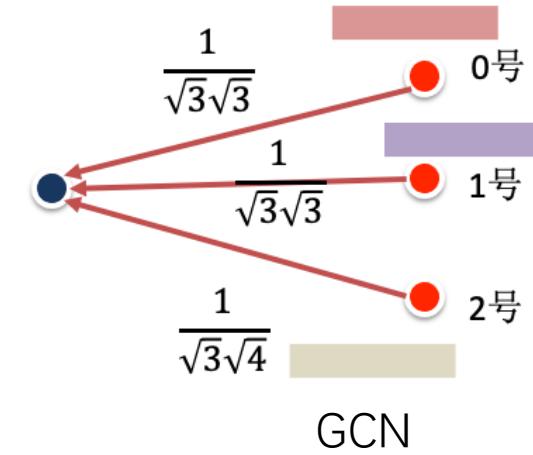
# Message Passing

GCN、GAT都是基于邻居聚合的模型

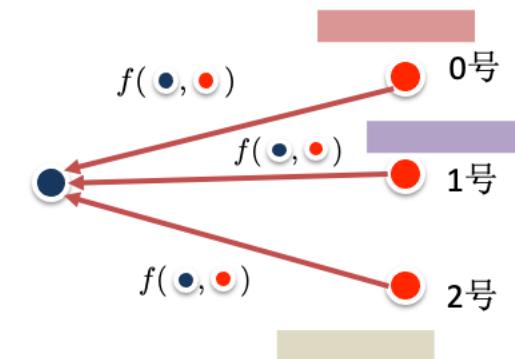
称为 Spatial (空间) GNN

大部分的Spatial GNN都可以用  
Message Passing实现

- 消息的发送
- 消息的接收



GCN



GAT

# Message Passing

基于消息传递的 Graph Neural Network 的通用公式

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

多层MLP

F可以是聚合函数  
通常是Mean/Max/Sum

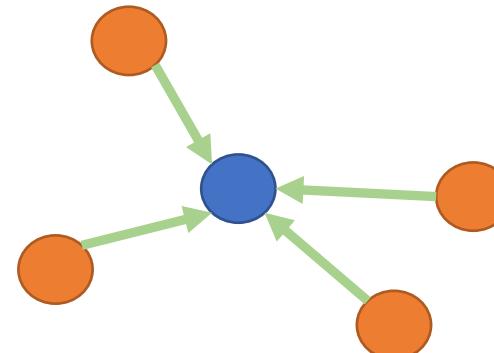
邻居消息发送

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

## Message Passing流程

1. 邻居的发送信息
2. F可以看作是目标接收信息的方式

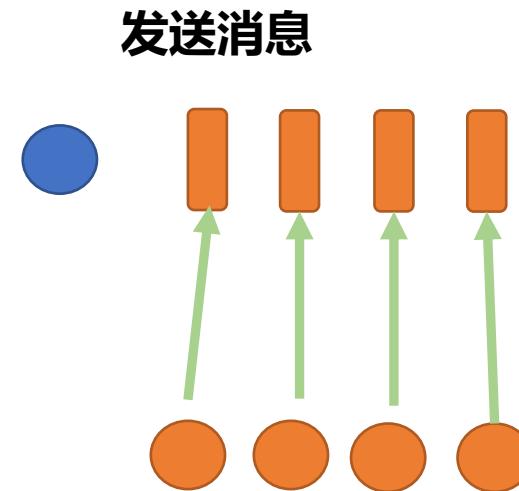


# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

## Message Passing流程

1. 邻居的发送信息
2. F可以看作是目标接收信息的方式

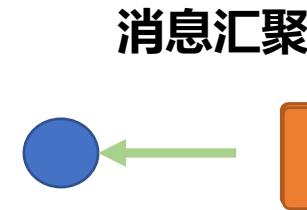


# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

## Message Passing流程

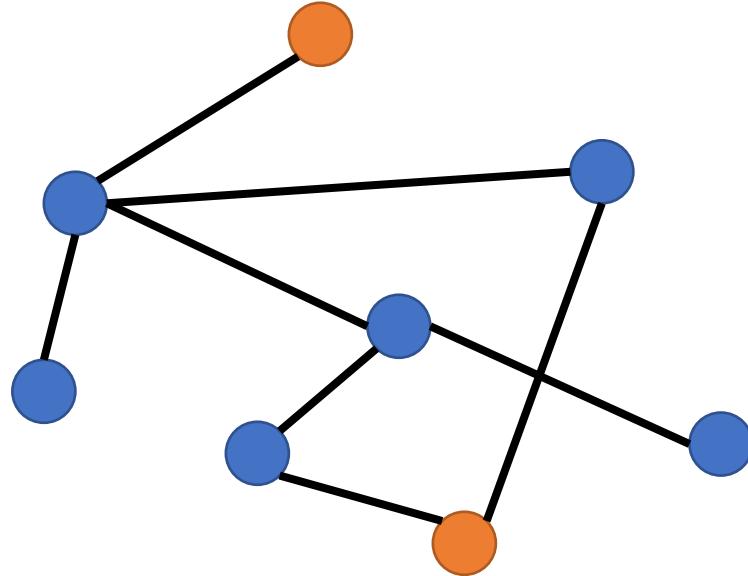
1. 邻居的发送信息
2. F可以看作是目标接收信息的方式



GCN:  $F = \text{基于度的加权求和}$   
GAT:  $F = \text{基于 Attention 的 加权求和}$

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

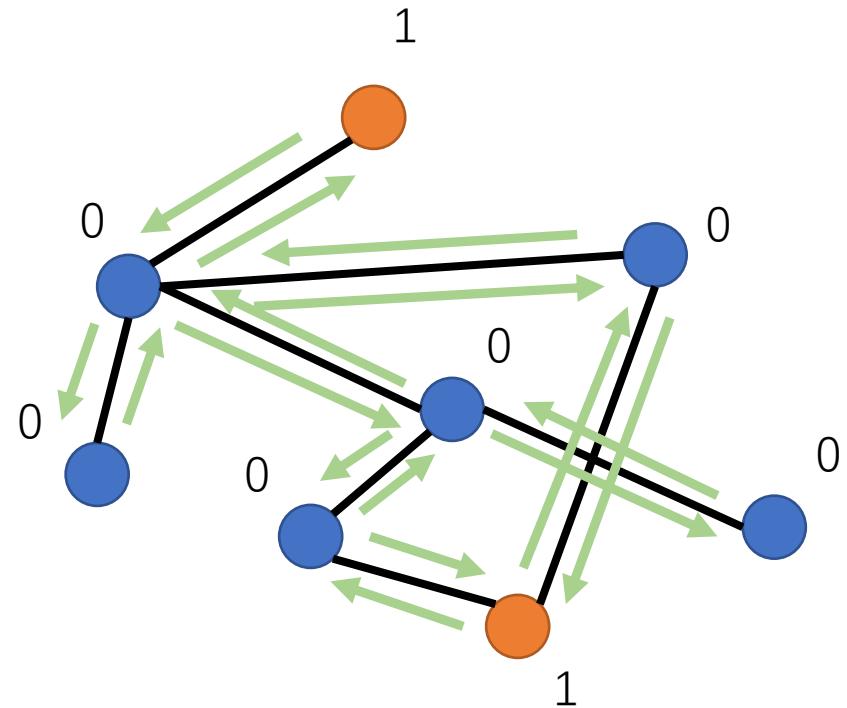


用Message Passing的范式解决问题

1. 哪些点的邻居存在橙色点（包括自己）
2. 每个节点附近平均有多少个橙色点（包括自己）
3. 哪些点的半径为2范围内存在橙色点（包括自己）

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

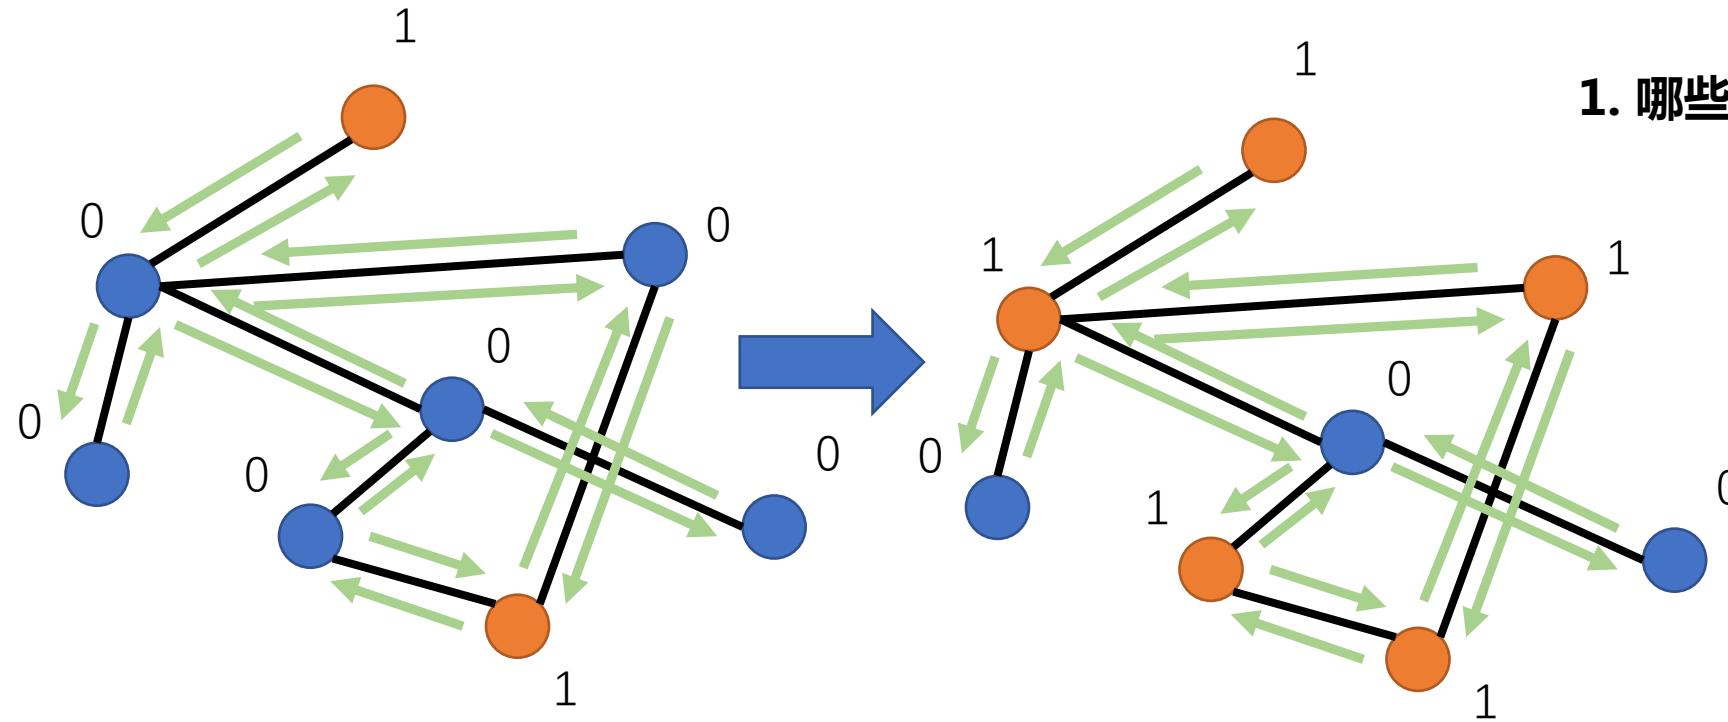


1. 哪些点的邻居存在橙色点（包括自己）

$\mathcal{F}$  为求Max

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$



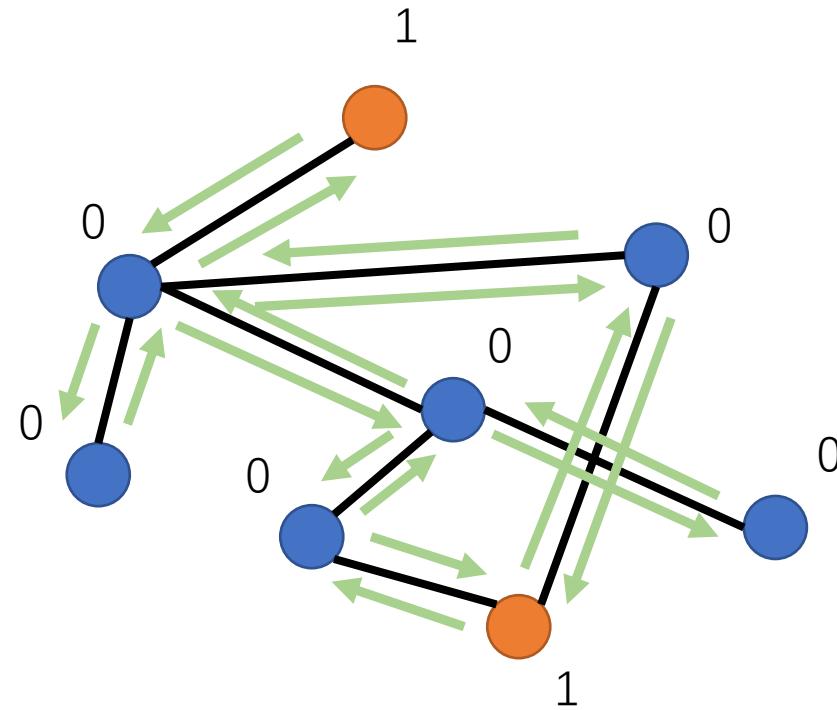
1. 哪些点的邻居存在橙色点（包括自己）

$\mathcal{F}$  为求Max

邻居节点有1的有5个

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

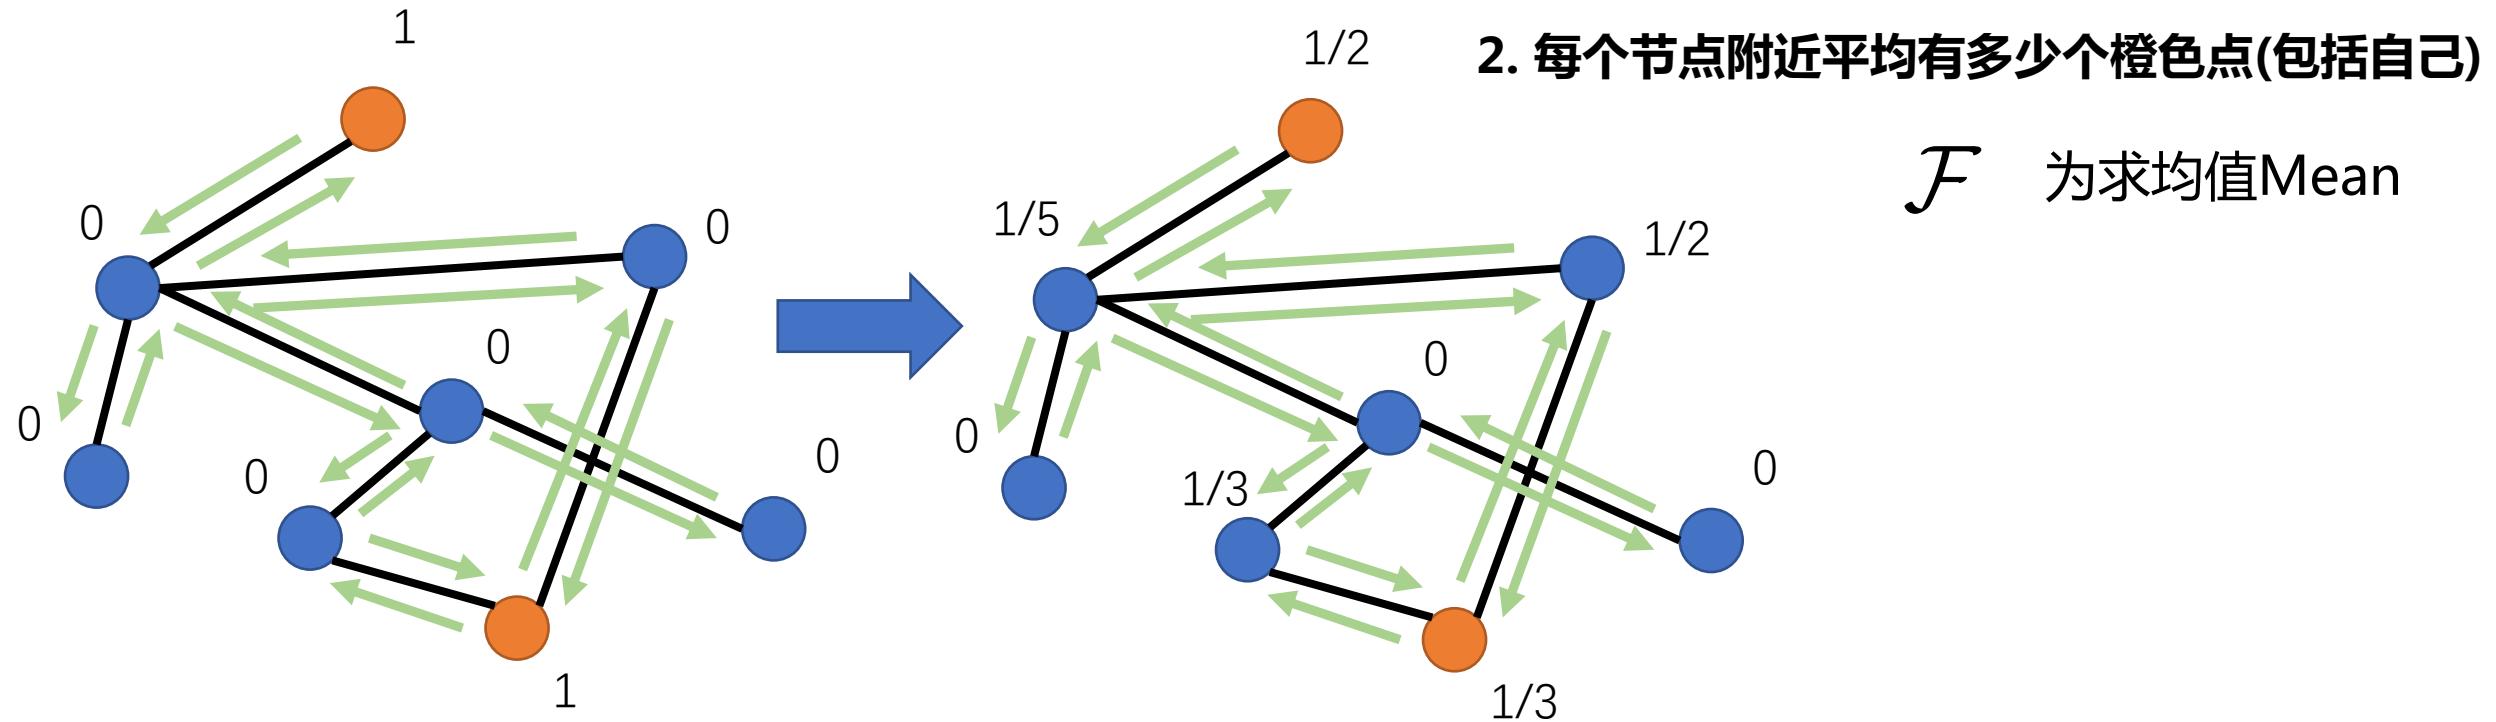


2. 每个节点附近**平均**有多少个橙色点(包括自己)

$\mathcal{F}$  为求均值Mean

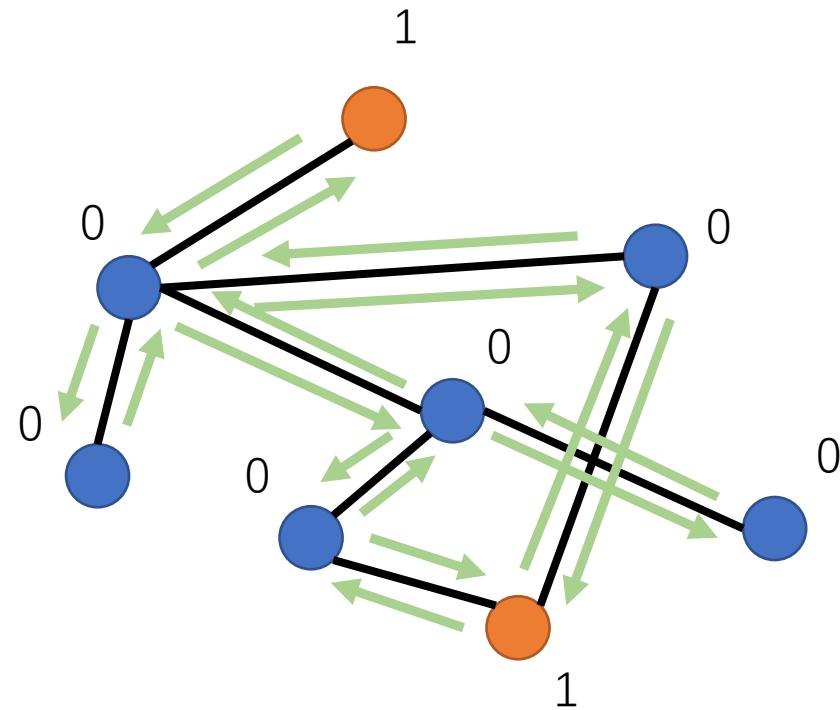
# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$



# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

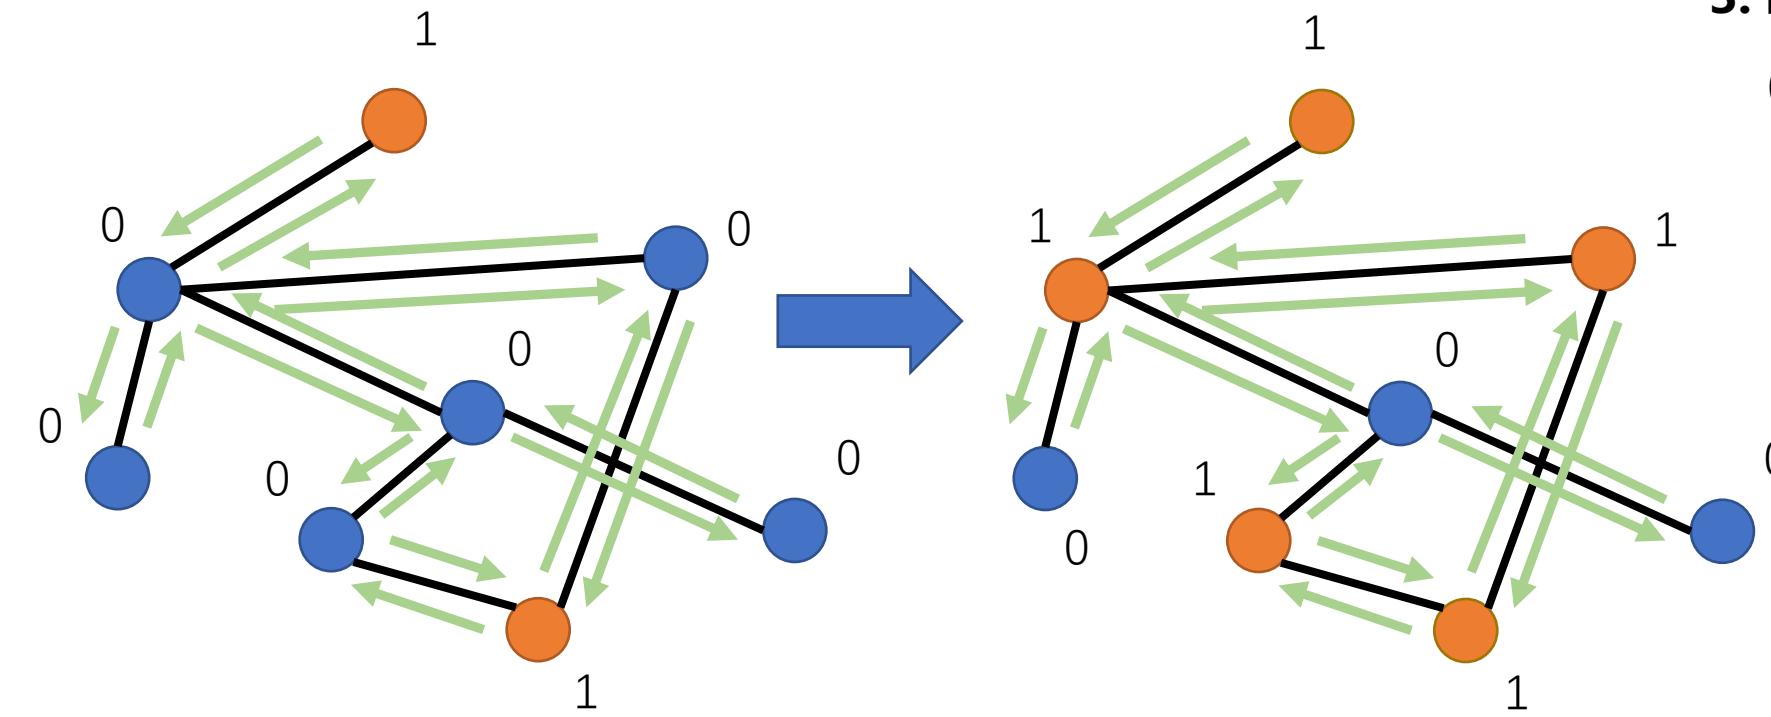


3. 哪些点的半径为2范围内存在橙色点(包括自身)

$\mathcal{F}$  为求Max

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$



3. 哪些点的半径为2范围内存在橙色点  
(包括自身)

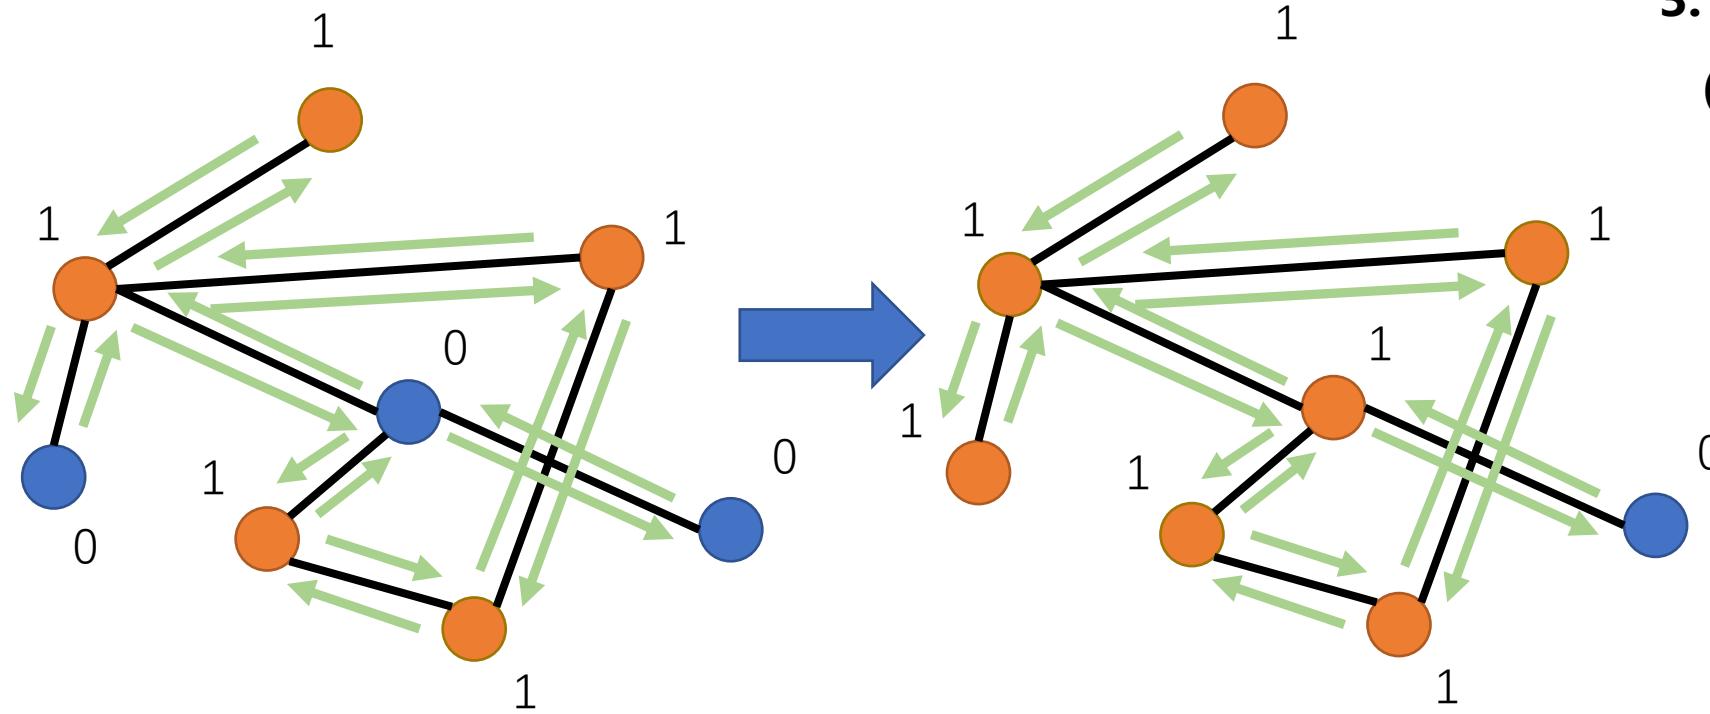
$\mathcal{F}$  为求Max

第一次迭代

1. 一阶邻居有橙色点

# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$



3. 哪些点的半径为2范围内存在橙色点  
(包括自身)

$\mathcal{F}$  为求Max

第一次迭代

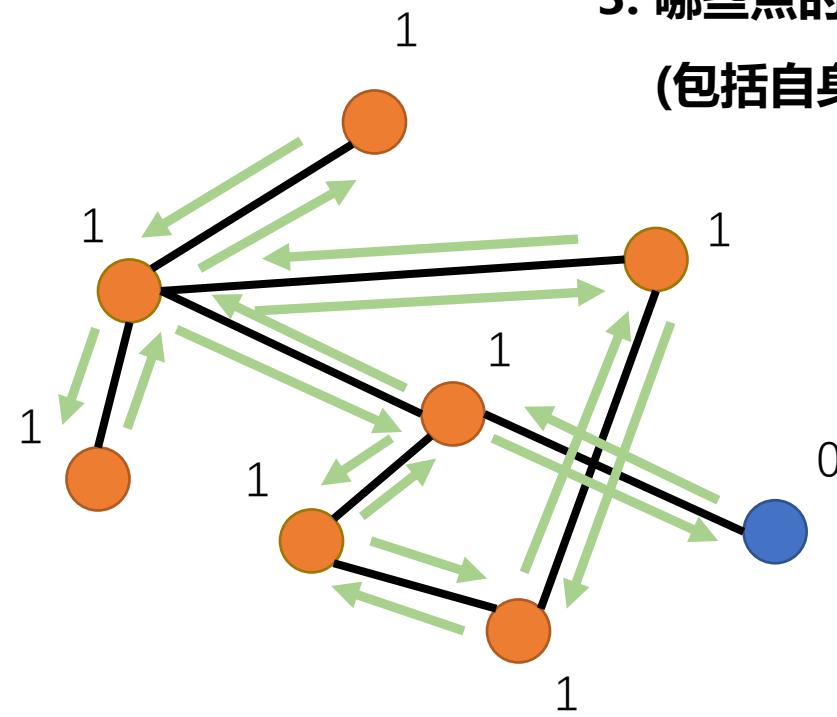
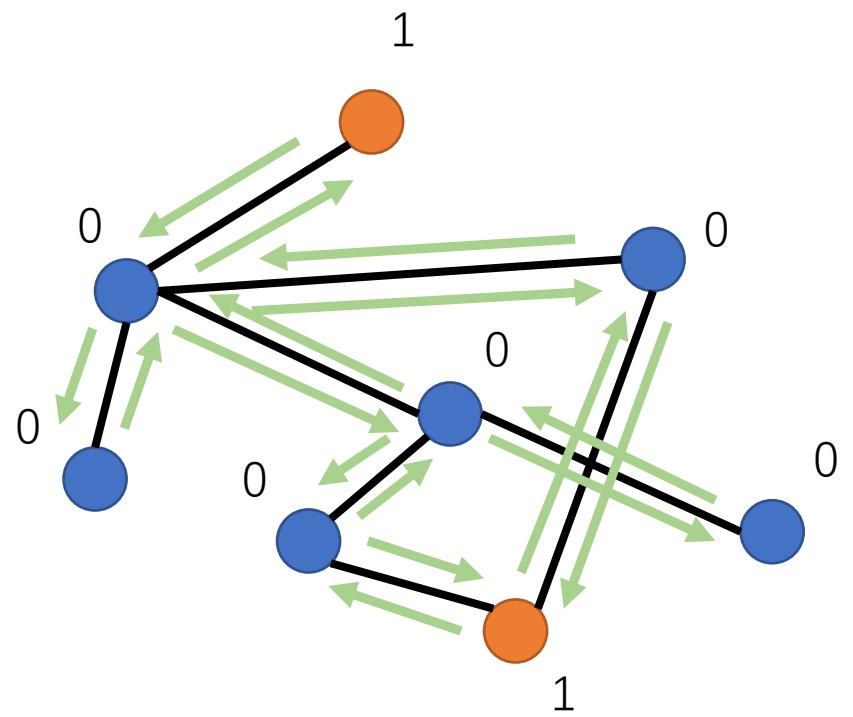
1. 一阶邻居有橙色点

第二次迭代

2. 二阶邻居有橙色点

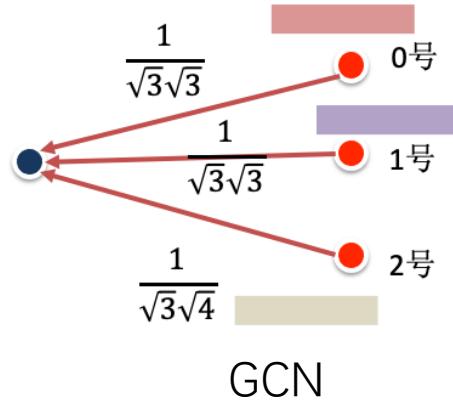
# Message Passing

$$h_l^{(t)}(v) = f(h_l^{(t-1)}, \mathcal{F}\{h_l^{(t-1)}(u) | u \in N(v)\})$$

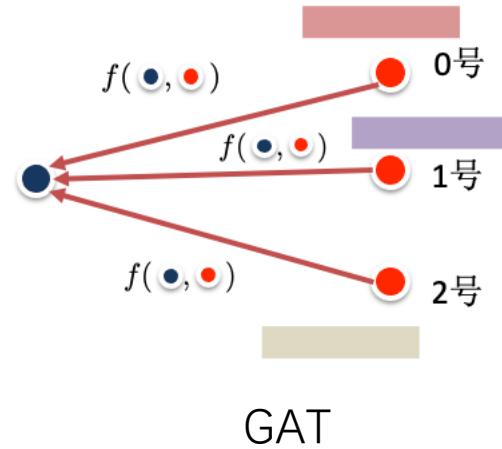


3. 哪些点的半径为2范围内存在橙色点  
(包括自身)

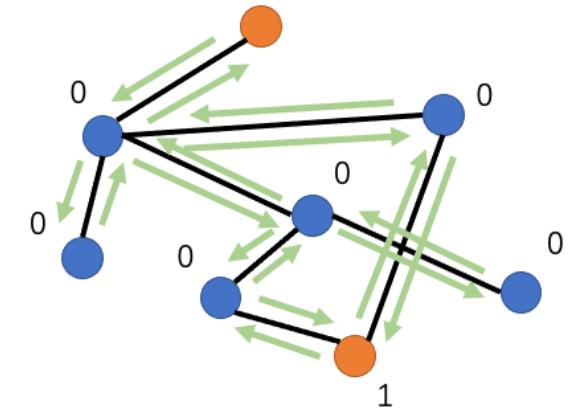
## 1. GCN算法介绍



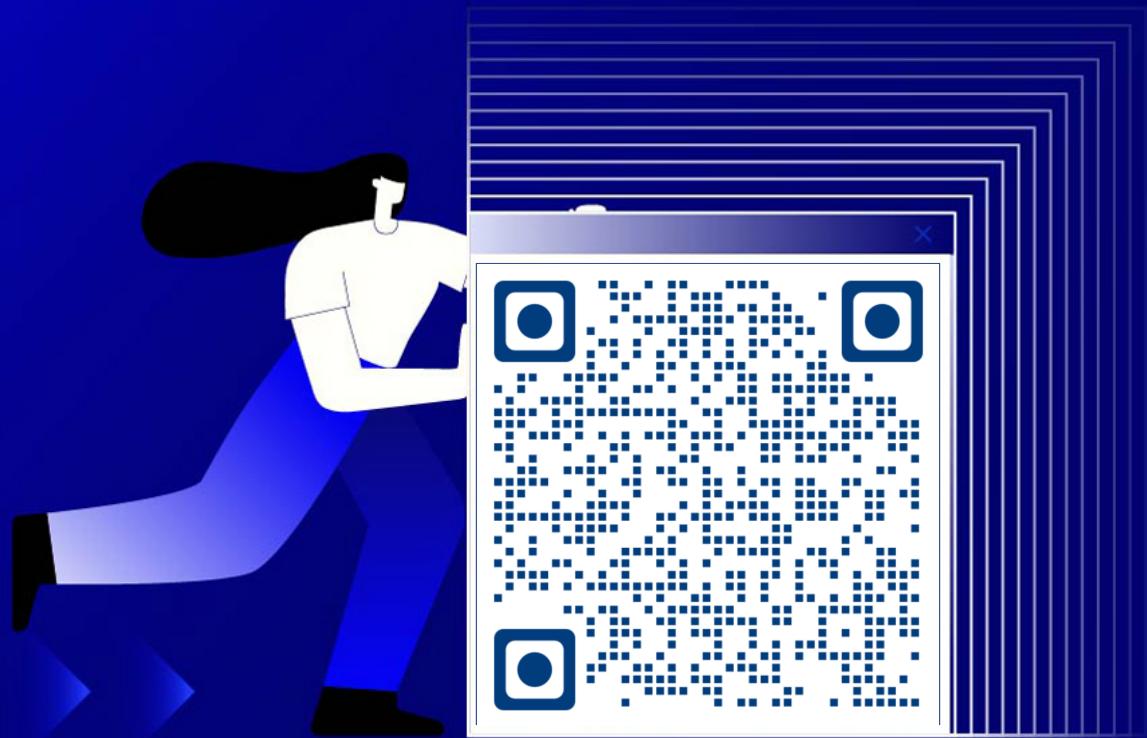
## 2. GAT算法介绍



## 3. Message Passing 消息传递算法



实现 GAT 模型的消息传递接口



PGL github

谢谢观看