arXiv:2303.03933v1 [cs.LG] 6 Mar 2023

DEDGAT：用于检测金融风险的有向图注意力网络双重嵌入

Jiafu Wu*、Mufeng Yao*、Dong Wu、Mingmin Chi†复旦大学，中国上海

Baokun Wang†、Ruofan Wu、Xin Fu、Changhua Meng、Weiqiang Wang TiansuanLab、蚂蚁集团，中国上海

摘要

图表示在金融风控领域发挥着重要作用，其中用户之间的关系可以通过图的形式构建。在实际场景中，风控任务中的节点关系具有双向性，例如，商户既有收入行为，也有支出行为。为无向图设计的图神经网络通常通过注意力策略聚合具有判别性的节点或边表示，但应用于基于有向图构建的任务时，无法充分利用出度信息，从而导致方向偏差问题。为解决这一问题，我们提出了一种有向图注意力网络，称为DGAT，它将出度显式纳入注意力计算。除了方向性要求外，同一节点的输入表示和输出表示也可能不同，因此我们进一步提出了 DGAT 的双重嵌入，称为 DEDGAT。具体而言，DEDGAT为每个节点分配入度表示和出度表示，并分别使用这两种嵌入来计算入度节点和出度节点的注意力权重。在基准数据集上进行的实验表明，与无向GAT相比，DGAT和DEDGAT取得了更好的分类性能。此外，可视化结果表明，我们的方法能够充分利用入度和出度信息。

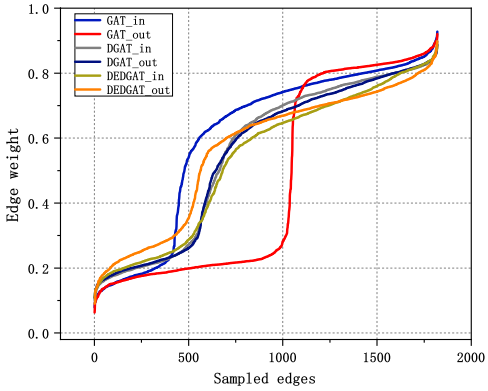

图1：在一个金融风险控制数据集上，采用我们提出的 DGAT 和 DEDGAT 方法以及图注意力网络，在有向图中得到的入度边权重与出度边权重的重要性分布。对于图注意力网络而言，出度边的重要性远低于入度边。这被称为方向偏差。我们的方法能够解决这一问题，并以平衡的方式聚合入度和出度表示。

CCS 概念

• **计算方法 → 机器学习**。

关键词

图注意力网络，金融风控，有向图，双重嵌入

1 引言

金融风控是互联网金融的核心，也是人工智能的主要应用领域之一 [2–5]。在风控场景中，实体之间通常存在各种关系，例如转账关系、设备关系、区域连接等。利用图结构对这些关系进行建模，有助于我们发现金融系统中的异常对象。

基于图的方法通常可分为浅层图方法和图神经网络（GNN）方法。以 DeepWalk [6], node2vec [7], LINE [8] 为代表的浅层方法只能学习图的浅层表示信息，因此分类性能有限。不同于浅层

与浅层方法相比，图神经网络可以通过监督方式自动学习图的高层特征，并利用节点和边的特征提升节点分类或边分类等下游任务的性能。图卷积网络（GCN） [13]使用卷积来聚合节点信息。GraphSage [1]使用邻居采样来聚合节点的邻域信息，从而使在大规模图数据上进行训练成为可能。图注意力网络（GAT） [12]根据加权注意力聚合各节点及其邻居节点的信息，广泛应用于图节点分类任务。尽管这些方法的表现优于浅层方法 [9], , 但其中大多数都是为无向图设计的，因此无法充分利用图的方向信息。DGCN [10] 通过引入一阶邻居和二阶邻居的概念来计算拉普拉斯矩阵，将图卷积从无向图扩展到有向图。MagNet [11]采用厄米磁拉普拉斯算子来解耦图的方向性。这些方法以传导式方式显式表示有向图，但没有充分考虑入度信息与出度信息之间的差异。

*这些作者对本研究的贡献相同，应视为共同第一作者。

†通讯作者（mmchi@fudan.edu.cn，yike.wbk@antgroup.com）。

在金融风控中，入度信息和出度信息之间的差异十分重要。例如，从银行账户 A 转账至账户 B，与从账户 B 转账至账户 A 所传递的信息有显著差异。此外，尽管 A 到 B 的转账是单向的，但这种转账关系意味着 A 与 B 之间存在双向的社会关系。因此，用于金融风控的图网络应明确区分入度信息和出度信息，并以平衡的方式充分聚合二者的信息。然而，如图 1 所示，图注意力网络（GAT）存在明显的方向偏向，其中出度权重远不如入度权重重要。这限制了其在金融风险控制任务中的表现。

为解决这一问题，我们提出了一种有向图注意力网络（称为 DGAT），在特征聚合过程中分别计算入度和出度信息。为了更好地区分有向图中的入度和出度表示，我们进一步提出了一种有向注意力网络的双重嵌入（称为 DEDGAT），以解决方向偏差问题。具体而言，将一个图节点分别划分为入度节点和出度节点，然后分别计算入度节点和出度节点的图表示。所提出的模型在三个金融风险控制数据集上取得了 SOTA 性能，并通过 GNNExplainer [14] 验证了其能够降低方向偏差。

2 提出的模型

如图 2(a) 所示，无向 GAT 只能聚合入度信息，导致出度信息不足。这引发了图 1 所示的方向偏差问题。为了显式利用图节点的有向信息，我们提出了一种有向图注意力网络（DGAT），分别计算入度注意力和出度注意力，如图 2(b) 所示。为了进一步区分入度信息和出度信息，我们基于 DGAT 提出了一种双重嵌入（称为 DEDGAT），以提取图节点不同方向的判别性特征，如图 2(c) 所示。

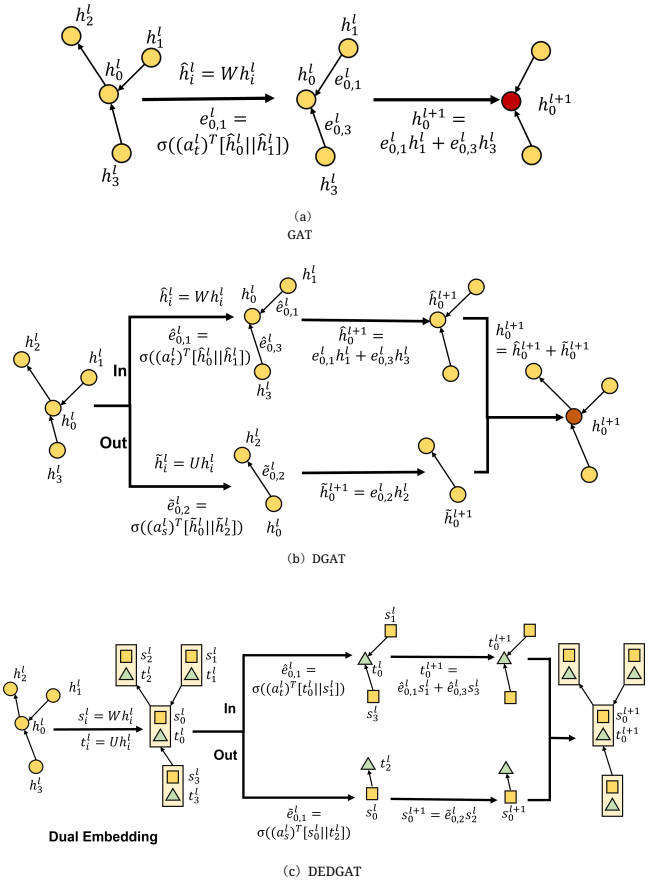

图 2：不同的聚合过程。（a）GAT 仅在一层中聚合入度特征。（b）DGAT 同时利用入度和出度特征。（c）DEDGAT 将节点划分为入度节点（三角形）和出度节点（正方形），并分别针对入度和出度特征表示计算两种不同的嵌入。

2.1 有向图注意力网络（DGAT）

给定节点 i 在第 l 层的表示 $h^{(l)}_i$，其邻居 j_1、j_2、⋯ 的表示为 $h^{(l)}_{j_1}$、$h^{(l)}_{j_2}$、⋯，传播前的线性变换分别针对入度和出度表示为 $\hat{h}^{(l)}_i = W^{(l)} h^{(l)}_i$ 和 $\tilde{h}^{(l)}_i = U^{(l)} h^{(l)}_i$。随后，使用两个映射函数 F: $\hat{h} \in \mathbb{R}^{2d} \to \hat{e} \in \mathbb{R}^1$ 和 G: $\tilde{h} \in \mathbb{R}^{2d} \to \tilde{e} \in \mathbb{R}^1$，计算邻居的注意力权重如下：

$$\hat{e}^{(l)}_{i,j} = \sigma((a^{(l)}_t)^T [\hat{h}^{(l)}_i \| \hat{h}^{(l)}_j]), \tag{1}$$

$$\tilde{e}^{(l)}_{i,j} = \sigma((a^{(l)}_s)^T [\tilde{h}^{(l)}_i \| \tilde{h}^{(l)}_j]), \tag{2}$$

其中，$\|$ 表示拼接运算符，σ 表示softmax函数，而 $a^{(l)}_t$ 和 $a^{(l)}_s$ 分别表示内邻居和外邻居注意力机制的参数。对邻居的注意力权重进行softmax处理后，节点 i 在第 $l+1$ 层的表示由式3给出，其中，T (i)和S(i)分别表示.....的集合

内邻居和外部邻居。

$$\begin{aligned} h^{(l+1)}_i &= \hat{h}^{(l)}_i + \tilde{h}^{(l)}_i \\ &= \sum_{j \in \mathcal{T}(i)} \hat{e}^{(l)}_{i,j} \hat{h}^{(l)}_j + \sum_{j \in \mathcal{S}(i)} \tilde{e}^{(l)}_{i,j} \tilde{h}^{(l)}_j \\ &= \sum_{j \in \mathcal{T}(i)} \hat{e}^{(l)}_{i,j} W^{(l)} h^{(l)}_j + \sum_{j \in \mathcal{S}(i)} \tilde{e}^{(l)}_{i,j} U^{(l)} h^{(l)}_j . \end{aligned} \tag{3}$$

2.2 DGAT的双嵌入（DEDGAT）

DGAT 充分利用了入度和出度信息。然而，特征方向性仍未纳入考虑。我们认为，单一特征无法充分反映输入信息与输出信息之间的差异。因此，我们提出了一种具有双重嵌入的有向注意力模型 DEDGAT。如图 2(c) 所示，每个节点由两个表示 $t^{(l)}_i$ 和 $s^{(l)}_i$ 组成，分别用于提取入度和出度的节点特征。

在计算注意力之前，对于 $i = 1, 2, \cdots n$，定义了两个线性变换：$\hat{t}(l)_i = w(l)t(l)_i$和 $\hat{s}(l) = u(l)s(l)_i$。其中，$w(l)$ 和 $u(l)$ 是线性层的权重。其次，根据公式（4-5）计算入度和出度的注意力权重，其中 $a(l)_t$ 和 $a(l)_s$ 是内邻居和外邻居注意力机制的参数。

$$\hat{e}_{i,j}^{(l)} = \sigma((a_t^{(l)})^T[\hat{t}_i^{(l)}||\hat{s}_j^{(l)}]), \tag{4}$$

$$\tilde{e}_{i,j}^{(l)} = \sigma((a_s^{(l)})^T[\hat{s}_i^{(l)}||\hat{t}_j^{(l)}]). \tag{5}$$

然后，分别聚合入度和出度注意力的两个分支，为下一层生成两个表示。在最后一层 l，将入度表示 $t(l)_i$与出度表示 $s(l)_i$相加，生成节点 i 的表示。相加后的特征用于预测网络输出。

2.3 节点分类

我们在三个金融图数据集上使用两个 DEDGAT 层，并在其前接一个线性层来进行节点分类。给定最后一个 DEDGAT 层生成的嵌入 L，预测节点分类的结果如下：

$$\hat{y}_{i,c} = \text{softmax}_c(Vh_i^{(L)}), \tag{6}$$

其中，V 表示最后一个线性层。

3 实验

3.1 数据集

我们在三个有向图数据集上评估了所提出的方法。其中，Elliptic数据集[9] 用于从交易数据中检测洗钱行为，Ant数据集用于从转账记录中检测金融欺诈，DGraphFin数据集 [15] 用于从社交网络中检测金融欺诈。Ant数据集为自行收集，其余数据集均为开源数据集。每个数据集包含两类节点，其中0表示正常节点，1表示异常节点。在这些数据集上优化节点分类任务有助于我们检测金融风险。表1展示了三个数据集的统计信息。

表1：金融风控数据集

-	Elliptic	Ant	DGraphFin
节点	203,769	1,296,486	3,700,550
边	234,355	1,785,844	4,300,999
带标签的节点	203,769	1,296,486	1,225,601
特征	93	59	17
类别	2	2	2

3.2 基线与参数设置

我们选取 GAT[12], GCN[13],GraphSage[1],DGCN[10],MagNet[11] 方法进行比较。其中，GAT 、 GCN 和 GraphSage 是基础图模型，DGCN 和 MagNet 是专为有向图设计的最新图模型。

为确保比较公开透明，我们提供了表2，展示实验中使用的各个图神经网络模型的网络参数。

表 2：网络参数数量

	Elliptic	Ant	DGraphFin
GCN	98,306	63,490	20,482
GAT	113,696	78,880	35,872
SAGE	98,818	64,002	20,094
DGCN	620,82	57,730	52,354
MagNet	134,917	121,861	89,842
DGAT	57,892	40,484	89,160
DEDGAT	114,756	79,940	88,200

3.3 实现

我们使用 AGL [16], , 这是一个可扩展、具备容错能力的集成系统，支持图神经网络的完整训练与推理，用于训练我们的网络。AGL 系统由三个部分组成，分别是 GraphFlat、GraphTrainer 和 GraphInfer。GraphFlat 是一种基于消息传递的高效分布式生成器，可生成 K 跳邻域，其中包含目标节点的完整信息子图。GraphTrainer 集成了流水线、剪枝和边划分模块，以减少输入/输出开销，并优化图神经网络模型训练期间的浮点计算。GraphInfer 是一个分布式推理模块，它将 K 层图神经网络模型拆分为 K 个切片，并基于 MapReduce 执行 K 次消息传递。上述三种计算逻辑构建于分布式文件系统、CPU集群和 MapReduce计算框架之上。我们的 AGL 系统基于成熟的基础设施实现，可在 14 小时内完成在包含数十亿个节点和数千亿条边的有向图上训练一个 2 层图注意力网络。

3.4 分类性能

表 3 展示了各方法在节点分类任务上的实验结果。我们的 DEDGAT 有效提升了分类性能，在全部三个数据集上均取得了最佳结果。

表 3：节点分类性能（曲线下面积）

	Elliptic	Ant	DGraphFin
GCN	91.09±0.28	85.18±0.57	70.78±0.23
GAT	95.06±0.45	97.43±0.24	76.24±0.81
SAGE	95.79±0.33	97.49±0.19	77.61±0.18
DGCN	94.48±0.60	94.71±0.85	79.58±0.15
MagNet	92.84±1.01	91.95±0.20	79.71±0.27
DGAT	95.79±0.43	97.92±0.31	80.72±0.11
DEDGAT	**96.18±0.23**	**98.16±0.09**	**81.37±0.06**

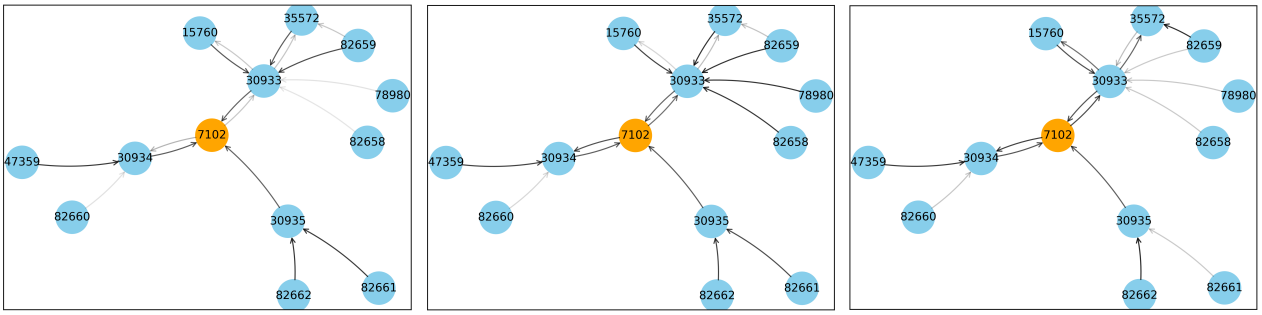

(a) 图注意力网络　(b) DGAT　(c) DEDGAT

图 3：GNNExplainer 对目标节点 7102 的解释结果比较。图注意力网络忽略了四条出度边 (7102 →30934)、(7102 → 30933)、(30933 → 1576) 和(30933 → 35572)；DGAT 则利用了两条出度边(7102 → 30934) 和(7102 → 30933)；DEDGAT 则利用了图注意力网络忽略的全部四条边。

3.5 可视化结果

当图注意力网络 [12] 应用于无向图时，节点只聚合来自入度方向的信息。在有向图中，边 E_{ij} 表示节点 i 的出度边和节点 j 的入度边。图注意力网络基于方向对称性隐式地利用出度信息。在有向图的方向性语境中，隐式融合出度信息的图注意力网络类方法无法很好地泛化到有向图的识别场景。然而，我们的方法明确地将出度信息和入度信息分开计算，并在 DEDGAT 中引入双重嵌入，以突出这种分离思路。离散建模旨在缓解图注意力网络中存在的入度偏差。

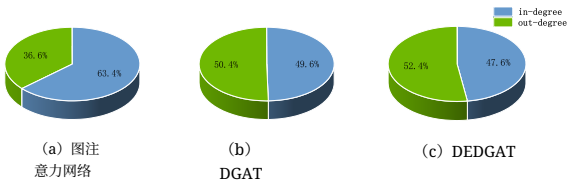

（a）图注意力网络　（b）DGAT　（c）DEDGAT

图 4：重要性分数大于 0.5 时入度边权重和出度边权重的占比。图注意力网络的入度边权重占比是出度边权重占比的 1.73 倍，而所提出的 DGAT 和 DEDGAT 中两个方向的边权重占比几乎相同。

GNNExplainer [14]是一种图解释器，可输出图模型中每条边的重要性分数。为了验证我们引入的方向性的有效性，我们使用 GNNExplainer 对三种方法——图注意力网络、DGAT 和 DEDGAT——的聚合过程进行可视化。如图 3 所示（边颜色越深，重要性越高）：图注意力网络未充分利用四条出度边（7102 → 30934）、（7102 → 30933）、（ 30933 → 1576）和（ 30933 → 35572）；相比之下，我们的 DGAT 利用了两条出度边（7102 → 30934）和（ 7102 → 30933 ）；DEDGAT 更进一步，利用了图注意力网络所忽略的全部四条边。

我们遍历Ant数据集，为 S_{in} 和 S_{out}提供全局统计结果（图1），其中 S_{in} 和 S_{out} 定义如下：

$$\begin{aligned} S_{in} &= \left\{ w_{ij} \in S \middle| k(i) > k(j) \right\}, \\ S_{out} &= \left\{ w_{ij} \in S \middle| k(i) < k(j) \right\}, \end{aligned} \tag{7}$$

其中，k（i）表示从节点i到中心风险节点的跳数。S定义为 $S = \left\{ w_{ij} \middle| I \right.$（$i$，$j$）$= 1\}$，其中$w_{ij}$来自GNNExplainer，即 $w_{ij} = GNNExplr\left(E_{ij}\right)$，$E_{ij} \in G$（$E$，$V$）。此处，$I$（$i$，$j$）是指示函数

$$I(i,j) = \begin{cases} 1, A_{ij} = 1 \wedge A_{ji} = 1, \\ 0, A_{ij} = 0 \vee A_{ji} = 0, \end{cases} \tag{8}$$

其中，A是有向图G的邻接矩阵。

如图 1 所示，图注意力网络过度依赖入度信息，却未能充分利用出度边；得益于 DGAT 和 DEDGAT 分别计算入度和出度，入边和出边都被赋予了近似的权重。我们将阈值 λ 设为 0.5，并统计权重大于该阈值的入度边和出度边（这些边在图卷积中很重要）。统计结果如图 4 所示：图注意力网络呈现出明显的入度信息偏差，而 DGAT 和 DEGAT 则使入度信息和出度信息保持平衡。

4 结论

本文提出了一种有向图注意力网络（简称 DGAT），用于显式计算有向图的入度和出度表示，以解决方向偏差问题，例如图注意力网络（GAT） [12]的权重重要性分布，如图 2(a) 所示。为更好地区分有向图的入度和出度节点表示，我们将每个节点拆分为入度节点和出度节点。本文进一步提出了 DGAT 模型的双重嵌入（简称 DEDGAT），分别计算入度和出度对应的节点表示。DGAT 和 DEDGAT 均能有效解决 GAT 的方向偏差问题。此外，DEDGAT 在三个金融风险控制数据集上取得了最佳表现。GNNExplainer [14] 生成的可视化结果表明，方向性对于金融风险控制任务至关重要。

参考文献

[1] Hamilton, William L、Ying, Rex 和 Leskovec, Jure。大型图上的归纳式表示学习。。《第31届神经信息处理系统国际会议论文集》，1025–1035，2017年。[2] Yang, Bo。基于风险关联和机器学习构建物流金融安全风险本体模型。。《安全科学》。第123卷，页码104437，2020年。[3] Ma, Xiaomeng 和 Lv, Shuliang。机器学习驱动的互联网金融信用风险预测。。《神经计算与应用》。第31卷，页码8359–8367，2019年。[4] Aziz, Saqib 和 Dowling, Michael。用于风险管理的机器学习与人工智能。。《颠覆金融》，页码33–50，2019年。[5] Li, Nan、Liang, Xun、Li, Xinli、Wang, Chao 和 Wu, Desheng Dash。利用机器学习和情感分析研究网络环境与金融风险。。《人类与生态风险评估》。第15卷，页码227–252，2009年。[6] Perozzi, Bryan、Al-Rfou, Rami 和 Skiena, Steven。*DeepWalk*：社会表示的在线学习。。《第20届ACM SIGKDD知识发现与数据挖掘国际会议论文集》，页码701–710，2014年。[7] Grover, Aditya 和 Leskovec, Jure。*node2vec*：网络的可扩展特征学习。。《第22届ACM SIGKDD知识发现与数据挖掘国际会议论文集》，页码855–864，2016年。[8] Tang, Jian、Qu, Meng、Wang, Mingzhe、Zhang, Ming、Yan, Jun 和 Mei, Qiaozhu。*LINE*：大规模信息网络嵌入。。《第24届万维网国际会议论文集》，页码1067–1077，2015年。[9] Weber, Mark、Domeniconi, Giacomo、Chen, Jie、Weidele, Daniel Karl I、Bellei, Claudio、Robinson, Tom 和 Leiserson, Charles E。反洗钱比特币洗钱：利用图卷积网络开展金融取证的实验。。arXiv 预印本 arXiv:1908.02591，2019年。[10] Ma, Yi and Hao, Jianye and Yang, Yaodong and Li, Han and Jin, Junqi and Chen, Guangyong。面向有向图的基于谱的图卷积网络。。arXiv 预印本 arXiv:1907.08990，2019年。[11] Zhang, Xitong and He, Yixuan and Brugnone, Nathan and Perlmutter, Michael and Hirn, Matthew。*Magnet*：一种面向有向图的神经网络。。《神经信息处理系统进展》，第34卷，第27003–27015页，2021年。[12] Veličković, Petar and Cucurull, Guillem and Casanova, Arantxa a nd Romero, Adriana and Lio, Pietro and Bengio, Yoshua。图注意力网络。。arXiv 预印本 arXiv:1710.10903，2017年。[13] Kipf, Thomas N and Welling, Max。利用图卷积网络进行半监督分类。。arXiv 预印本 arXiv:1609.02907，2016年。[14] Ying, Zhitao and Bourgeois, Dylan and You, Jiaxuan and Zitnik, Marinka and Leskovec, Jure。*GNNExplainer*：为图神经网络生成解释。。《神经信息处理系统进展》，第32卷，2019年。[15] Huang, Xuanwen and Yang, Yang and Wang, Yang and Wang, Chunping and Zhang, Zhisheng and Xu, Jiarong and Chen, Lei and Vazirgiannis, Michalis。*DGraph*：用于图异常检测的大规模金融数据集。。第36届神经信息处理系统大会数据集与基准赛道，2022年。[16] Zhang, Dalong and Huang, Xin and Liu, Ziqi and Zhou, Jun and Hu, Zhiyang and Song, Xianzheng and Ge, Zhibang and Wang, Lin and Zhang, Zhiqiang and Qi, Yuan。*AGL*：面向工业级图机器学习的可扩展系统。。VLDB基金会会议录，第3125–3137页，2020年。