

基于图双向选择注意力的公司任职预测算法

潘文韬 熊贇 朱扬勇

(复旦大学计算机科学技术学院上海市数据科学重点实验室 上海 200438)

摘要 基于员工与公司潜在的双向选择关系来预测未来员工的去向以及公司的人才引进情况,这些预测信息对于金融、招聘等从业人员在判断公司未来发展和寻找潜在求职者等工作具有指导意义。为了获得节点间的双向选择信息并强化节点信息以增强预测效果,在公司与员工及其相关数据构建成的异质图下利用自编码器和三层注意力机制来生成用于任职预测的双向选择向量及节点向量。根据在真实数据集上的实验,该方法在任职预测任务下的预测效果要优于现有方法,同时提高了预测的可解释性。

关键词 异质图 元路径 自编码器 注意力机制 深度神经网络 职业流动行为

中图分类号 TP181 TP3 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2024.06.007

EMPLOYMENT PREDICTION ALGORITHM BASED ON ATTENTION MECHANISM WITH BIDIRECTIONAL SELECTION GRAPH

Pan Wentao Xiong Yun Zhu Yangong

(Shanghai Key Laboratory of Data Science, School of Computer Science, Fudan University, Shanghai 200438, China)

Abstract Based on the potential bidirectional selection relationship between employees and companies, we can predict where the employees will go in the future and the prospective hiring situation of the company. These predictions are of great significance for practitioners in finance, recruitment and other industries to judge the future development of company, find potential candidates, etc. To obtain the bidirectional selection information and reinforce the vertex information to enhance the prediction effect, the companies, employees and their related data were used to form a heterogeneous information network (HIN), and the bidirectional selection embeddings and the node embeddings for employment prediction were generated by autoencoder and tri-attention mechanism. According to the experiments on real dataset, our model has a better effect on prediction compared with the existing methods. The interpretability of the prediction is also improved.

Keywords Heterogeneous information network Meta-path Autoencoder Attention mechanism Deep neural network Career mobility behavior

0 引言

在公司中的员工,尤其是那些具有重要地位的董事、监事、高管等,他们的职业流动行为会对公司的发展产生很大的影响。对于金融投资、招聘行业等从业人员,这些人员流动的预测信息是非常重要的。例如近期英特尔现任 CEO 的离职及 VMware CEO 的接任

就导致了英特尔的股价大涨。如果能够有效预测人员未来可能的职业流向,就可以对相关公司未来的发展情况做出一定的预测调整,或者发现一些潜在的求职者等。

为了预测公司与人员之间的任职关系,除了这两种实体,还有其他与他们相关的实体可被用于辅助预测任务,比如人员的毕业院校、公司的所属行业等。为了将这些实体统一建模到一幅图上,异质图^[1]是一个

被广泛运用于多种类型的实体和关系的构建方法。目前有研究采用链路预测的方法来预测异质图中类似公司与人员这样的两种不同实体之间是否存在链路。这些方法存在的问题没有考虑链路两端的实体之间可能存在双向选择关系,没有区分两端实体分别对另一端的单向选择。因此这些方法在公司任职预测的场景下具有很大的局限性。

因此,我们需要对公司任职预测这种存在双向选择情况的问题做更多的考虑。一方面我们需要考虑公司和人员在双向选择时对不同条件的重视程度,比如有的人喜欢符合自己专业的公司,有的人则更喜欢去一起工作过的人所在的公司;有的公司更喜欢招毕业于特定高校的学生,有的公司则更喜欢招内部员工推荐的人。另一方面我们还需要考虑公司和人员之间双向选择时可能存在的选择不平衡情况,因为在现实中很难确保公司与个人之间的选择权力是平等的。

本工作利用人员与公司之间的任职情况以及他们的其他基本信息来构建异质图,并基于他们之间可能存在的双向选择关系提出利用双向选择的基于图双向选择注意力的公司任职预测算法(BSGAEP),利用自编码器模型加上三层注意力机制——路径注意力、双向选择注意力和节点注意力,分别用于提取单向选择信息、提取双向选择信息、增强节点信息,生成用于预测的公司、人员向量、他们之间的双向选择向量。实验表明本文模型在针对这类问题时的效果可以达到目前最优水平,并提高可解释性。

1 相关工作

目前在任职预测领域的工作主要有: Xu 等^[2]提出利用动态职业流动图(Dynamic Job Transition Network),通过基于循环神经网络的深度序列预测模型,进行职业流动的动态图预测。但该工作的粒度较为宏观,不能精准到员工个体预测他的下一位雇主。Li 等^[3]提出基于上下文的长短期记忆网络的 NEMO 模型,根据员工的技能、毕业院校等信息,预测员工接下来的任职序列; Meng 等^[4]提出的 HCPNN 模型利用分层神经网络和嵌入注意力机制,预测员工的下一个雇主及雇佣时间。但是这两种方法都没有将员工、公司等相关实体和他们之间的关系构建成异质图^[1],不能有效发现人员和公司之间潜在的复杂关联。

异质图的概念在 PathSim^[1]中被首次提出。异质图可被用于将多种类型的节点和边建模在一幅图上。推荐是基于异质图的重要下游任务,即给定一个用户

和物品,去预测他们之间是否存在交互关系。近几年在这一领域的工作有: MCRec^[5]通过将节点向量和元路径向量结合后通过神经网络进行预测; NIREC^[6]通过随机游走生成的元路径进行交错结合后进行推荐。上述的推荐相关工作给本文提供了灵感,将推荐任务中的用户和物品替换为人员与公司,也可以预测他们之间的任职关系。但这些工作未考虑任职预测任务中人员与公司间的双向选择信息,不能对人员与公司之间相互的单向选择信息进行区分和融合。因此本工作将基于异质图,从图中提取出双向选择信息用于任职预测。

2 问题定义

首先我们需要对公司任职预测问题进行形式化定义。

异质图^[1,5]被定义为一个图 $G = (V, E, A, R)$, V 表示图中的所有节点的集合, E 表示图中的所有边的集合, A 表示图中节点的实体类型集合, R 表示图中边的关系类型集合,还有一个节点类型映射 $\phi: V \rightarrow A$, 将 V 中的每一个节点对应到 A 中的节点类型, 以及一个边类型映射 $\varphi: E \rightarrow R$, 将 E 中的每一个节点对应到 R 中的关系类型。

元路径是基于异质图的一个概念, 一条元路径 p 是形如 $A_1 \xrightarrow{R_1} A_2 \xrightarrow{R_2} \dots \xrightarrow{R_{n-1}} A_n$ 的路径, $A_1, A_2, \dots, A_n \in A$, $R_1, R_2, \dots, R_n \in R$ 。假设每两个类型的节点之间至多存在一种类型的边, 那么这条元路径可以被简化表示为 $p = \{A_1, A_2, \dots, A_n\}$ 。

元路径实例表示某一条元路径在异质图中的由实例节点组成的路径。对于一条长度为 l 的元路径实例 $\rho = \{v_1, v_2, \dots, v_l\}$, 如果满足 $\text{len}(\rho) = \text{len}(p)$, $v_1 \rightarrow A_1$, $v_2 \rightarrow A_2, \dots, v_l \rightarrow A_l$, 那么 ρ 就是属于元路径 p 的元路径实例。

本工作要解决的公司任职预测任务为: 给定一个公司任职关系图 G , 以及人员类型的节点 $v_x \rightarrow P$ 和公司类型的节点 $v_y \rightarrow C$, 且满足 $v_x, v_y \in V$, 节点类型 $P, C \in A$, 已知每个节点 $v_i \in V$ 的初始特征向量 \mathbf{E}_{v_i} , 求 v_c 和 v_p 之间存在任职关系的概率 \hat{r}_{v_x, v_y} 。

3 模型结构

图 1 展示了基于图双向选择注意力的公司任职预测模型的总体架构。本模型主要分为元路径向量的生成、单向选择向量的生成、双向选择向量的生成、节点

注意力机制、链路预测。接下来将针对这五个模块分别进行描述。

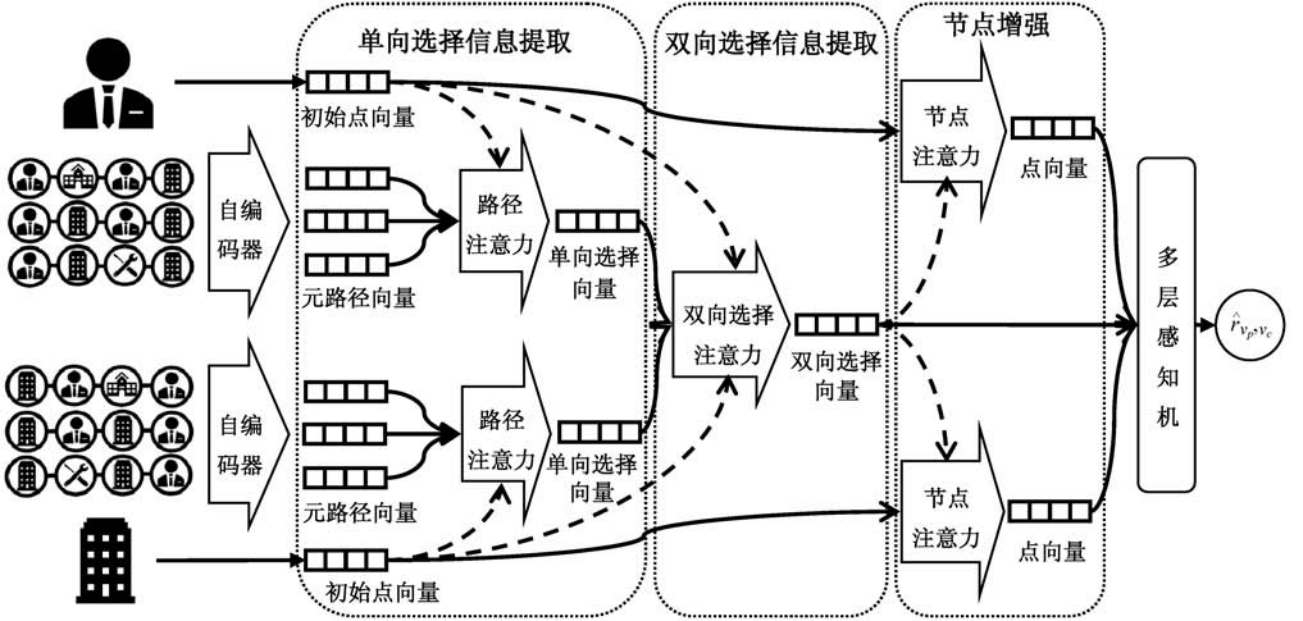


图1 基于图双向选择注意力的公司任职预测模型

3.1 元路径向量的生成

元路径向量的加入可以提升链路预测的效果^[5], 所以我们需要生成人员与公司之间的元路径的向量。元路径实例是由一个个节点连接而成的, 为了将元路径实例进行向量化, 可以简单地将路径所经过的所有节点向量进行拼接。但是, 这些拼接的向量存在两个问题^[7]:

- 1) 由于元路径所经过的节点数量较多, 其中可能会包含一些噪声信息或次要信息;
- 2) 不同元路径的长度可能不一样。这就意味着不通的元路径初始包含的向量维数是不一样的。

为了解决这些问题, 我们采用自编码器模型来将元路径实例转化为向量^[8]。

如图2所示, 本模型采用的元路径自编码器包含: 输入层、隐藏层和输出层。输入层与输出层都是元路径实例被压缩前的向量, 隐藏层为这条元路径实例的压缩后的向量, 会被作为结果取出。




图2 本模型采用的元路径自编码器模型

一条长度为 l 的元路径实例 $\rho = \{v_1, v_2, \dots, v_l\}$, 自编码器的输入层为元路径实例中的所有节点向量进行

拼接后所得到的向量, “ \oplus ”表示向量拼接操作:

$$L_{in}(\rho) = E_{v_1} \oplus E_{v_2} \oplus \dots \oplus E_{v_l} \quad (1)$$

隐藏层的公式为:

$$L_{hid}(\rho) = f_{\theta}(L_{in}(\rho)) = \sigma(WL_{in}(\rho) + b) \quad (2)$$

式中: $\theta = \{W, b\}$ 表示训练参数集合; W 为一个 $d' \times d$ 维的权重矩阵, d 和 d' 分别是输入层和隐藏层的维数; b 是偏移向量; $\sigma(\cdot)$ 表示 Sigmoid 激活函数。

输出层的公式为:

$$L_{out}(\rho) = g_{\theta'}(L_{hid}(\rho)) = \sigma(W'L_{hid}(\rho) + b') \quad (3)$$

式中: $\theta' = \{W', b'\}$ 表示参数集合, W' 表示一个 $d \times d'$ 维的权重矩阵且满足 $W' = W^T$, b' 是偏移向量。

θ 和 θ' 经过训练之后, 得到最优化的 θ^* 和 θ'^* :

$$\theta^*, \theta'^* = \arg \min_{\theta, \theta'} \frac{1}{n} \sum_{i=1}^n \|L_{in}(\rho_i) - L_{out}(\rho_i)\|^2 \quad (4)$$

元路径 p 包含实例集和 $S_p = \{\rho_1, \rho_2, \dots, \rho_n\}$, n 表示元路径 p 的实例 ρ_i 的数量。在完成自编码器的模型训练之后将全部 n 条元路径实例输入到模型中, 得到每一条元路径实例的向量表示 $E_{\rho_i} = L_{hid}(\rho_i)$ 之后, 我们直接对所有 $\rho_i \in S_p$ 的向量表示 E_{ρ_i} 求平均, 得到元路径 p 的向量表示:

$$E_p = \frac{1}{n} \sum_{i=1}^n E_{\rho_i} \quad (5)$$

3.2 单向选择信息提取

得到每一条元路径的向量后, 我们采用路径注意力机制^[5,9-11]来获得不同元路径的权重。

假定我们先从人员类型的节点 v_s 出发, 以公司类型节点 v_e 结束, 通过专家知识可以预先设定一个有意

义的元路径集合: $T_{v_x \rightarrow v_y} = \{p_1, p_2, \dots, p_n\}$ 。

在3.1节中我们已经得到每一条元路径的向量表示 E_{p_i} 。另外由于我们现在需要关心从 v_x 的角度出发对于不同元路径的重视程度,所以我们还需要关心 v_x 的向量 E_{v_x} 。元路径权重的计算过程如下:

$$\alpha'_{p_i, v_x} = \text{ReLU}(W_{v_x} E_{v_x} + W_{p_i} E_{p_i} + \mathbf{b}) \quad (6)$$

$$\alpha'_{p_i, v_x} = \text{ReLU}(\mathbf{w} \alpha'_{p_i, v_x} + \mathbf{b}) \quad (7)$$

$$\alpha_{p_i, v_x} = \frac{\exp(\alpha'_{p_i, v_x})}{\sum_{p_j \in T_{v_x \rightarrow v_y}} \exp(\alpha'_{p_j, v_x})} \quad (8)$$

式中: $\text{ReLU}(\cdot)$ 表示 ReLU 激活函数; W_{v_x} 和 W_{p_i} 分别表示 v_x 和 p_i 的权重矩阵; \mathbf{b} 表示偏移向量; \mathbf{w} 表示权重向量。式(8)采用了 Softmax 函数来最终得到元路径 p_i 对于节点 v_x 的权重 α_{p_i, v_x} 。

接下来我们就可以得到从 v_x 出发的角度考虑的单向选择向量为:

$$E_{v_x \rightarrow v_y} = \sum_{p_i \in T_{v_x \rightarrow v_y}} \alpha_{p_i, v_x} E_{p_i} \quad (9)$$

以此类推,我们通过同样的方法可以得到从节点 v_y 出发的角度考虑的单向选择向量: $E_{v_y \rightarrow v_x}$ 。

3.3 双向选择信息提取

由于双向选择中可能存在的平等性,我们还需要考虑两条单向选择的不同权重。我们通过第二层注意力:双向选择注意力来获得分别从人和公司出发的单向选择向量的权重。

在3.2节中我们已经得到 v_x 和 v_y 之间相互的单向选择向量: $E_{v_x \rightarrow v_y}$ 和 $E_{v_y \rightarrow v_x}$ 。由于现在已经到了双向选择阶段,需要对双方节点都进行考虑,所以需要在注意力中引入两端节点的向量: E_{v_x} 和 E_{v_y} 。

对于双向选择注意力,我们同样采用双层结构来实现:

$$\beta'_{v_x \rightarrow v_y} = \text{ReLU}(W_{v_x \rightarrow v_y}^{(1)} E_{v_x \rightarrow v_y} + W_{v_x}^{(1)} E_{v_x} + W_{v_y}^{(1)} E_{v_y} + \mathbf{b}^{(1)}) \quad (10)$$

式中: $W_{v_x \rightarrow v_y}^{(1)}$ 、 $W_{v_x}^{(1)}$ 和 $W_{v_y}^{(1)}$ 都是权重矩阵; $\mathbf{b}^{(1)}$ 是偏移向量。得到中间变量 $\beta'_{v_x \rightarrow v_y}$ 后,我们接着可以得到:

$$\beta_{v_x \rightarrow v_y} = \text{ReLU}(\mathbf{w}^{(1)} \beta'_{v_x \rightarrow v_y} + \mathbf{b}^{(1)}) \quad (11)$$

式中: $\mathbf{w}^{(1)}$ 是权重向量; $\mathbf{b}^{(1)}$ 是偏移量。得到下一层的中间变量 $\beta'_{v_x \rightarrow v_y}$ 后,我们接着还需要再经过一层 Softmax:

$$\beta_{v_x \rightarrow v_y} = \frac{\exp(\beta'_{v_x \rightarrow v_y})}{\exp(\beta'_{v_x \rightarrow v_y}) + \exp(\beta'_{v_y \rightarrow v_x})} \quad (12)$$

这样我们就可以得到单向选择向量的权重 $\beta_{v_x \rightarrow v_y}$ 。另一个方向的 $\beta_{v_y \rightarrow v_x}$ 也可以用类似的方法得出。最后对它们进行加权求和,就可以得到双向选择向量:

$$E_{v_x \leftrightarrow v_y} = \beta_{v_x \rightarrow v_y} E_{v_x \rightarrow v_y} + \beta_{v_y \rightarrow v_x} E_{v_y \rightarrow v_x} \quad (13)$$

3.4 节点增强

在得到两个节点之间的双向选择向量之后,我们考虑到这个双向选择向量还有可能会对两个节点的初始向量起到注意力的作用,可能因为双向选择的特征导致节点向量中特征的重要程度不同。因此我们还需要再经过第三层注意力:节点注意力^[5]。

我们得到了双向选择向量 $E_{v_x \leftrightarrow v_y}$ 和两端节点的向量 E_{v_x} 和 E_{v_y} 。通过节点注意力可以得到:

$$\gamma_{v_x} = \text{ReLU}(W_{v_x}^{(1)} E_{v_x} + W_{v_x \leftrightarrow v_y}^{(1)} E_{v_x \leftrightarrow v_y} + \mathbf{b}^{(1)}) \quad (14)$$

式中: $W_{v_x}^{(1)}$ 和 $W_{v_x \leftrightarrow v_y}^{(1)}$ 表示权重矩阵; $\mathbf{b}^{(1)}$ 表示偏移向量。在得到两个节点的权重向量之后,我们可以将其分别乘入各自的初始向量中,“ \odot ”表示元素积:

$$\tilde{E}_{v_x} = \gamma_{v_x} \odot E_{v_x} \quad (15)$$

这样,我们就可以得到两个最终点向量 \tilde{E}_{v_x} 。 \tilde{E}_{v_y} 的计算方法类似。

3.5 任职预测

在得到两个节点的最终点向量 \tilde{E}_{v_x} 和 \tilde{E}_{v_y} 以及它们之间的双向选择向量 $E_{v_x \leftrightarrow v_y}$ 后,我们就可以进行链路预测了。我们对这三个向量进行拼接后得到输入向量:

$$\tilde{E}_{v_x, v_y} = \tilde{E}_{v_x} \oplus E_{v_x \leftrightarrow v_y} \oplus \tilde{E}_{v_y} \quad (16)$$

我们将这个向量输入到多层感知机^[2] (Multi-layer Perceptron, MLP) 中:

$$\hat{r}_{v_x, v_y} = \text{MLP}(\tilde{E}_{v_x, v_y}) \quad (17)$$

式中: \hat{r}_{v_x, v_y} 就是一个 $0 \sim 1$ 之间的预测结果。参考文献[12-13],我们会通过负采样来进行训练。损失函数为:

$$l_{v_x, v_y} = -\log \hat{r}_{v_x, v_y} - \mathbb{E}_{i \sim P_{v_x}^{\text{neg}}} [\log(1 - \hat{r}_{v_x, v_i})] - \mathbb{E}_{j \sim P_{v_y}^{\text{neg}}} [\log(1 - \hat{r}_{v_j, v_y})] \quad (18)$$

式中: $\log \hat{r}_{v_x, v_y}$ 表示正样本; $\mathbb{E}_{i \sim P_{v_x}^{\text{neg}}} [\log(1 - \hat{r}_{v_x, v_i})]$ 和 $\mathbb{E}_{j \sim P_{v_y}^{\text{neg}}} [\log(1 - \hat{r}_{v_j, v_y})]$ 表示负样本; $P_{v_x}^{\text{neg}}$ 和 $P_{v_y}^{\text{neg}}$ 分别表示从 v_x 节点和 v_y 节点出发的噪声分布。

4 实验分析

4.1 数据集

为了实验模型在任职预测任务中的预测效果,我们收集了中国上市公司数据集。它包含了中国上市公司的董监高任职情况、董监高的亲属关系、教育背景、其他机构任职情况、公司所属的行业。数据集规模如表1所示。

表 1 中国上市公司数据集规模

关系(X-Y)	#X	#Y	#X-Y
Person-Company	154 133	2 130	128 811
Person-Person	154 133	154 133	18 421
Person-University	154 133	2 688	88 212
Person-Institution	154 133	47 731	346 287
Company-Domain	2 130	74	2 130

该数据集收集自 CSMAR 数据库 (China Stock Market & Accounting Research Database), 是经济金融领域的研究型精准数据库, 借鉴 CRSP (Center for Research in Security Price, LLC)、Compustat 等权威数据库专业标准, 具有一定的权威性。

实验的任务是对数据集中的人员与公司之间的任职关系进行预测。本模型采用的元路径有 PCPC、PUPC、PIPC、PPC 和 PCDC。

4.2 对比方法

我们挑选了近几年在异质图的推荐和网络表示学习领域有代表性的方法来进行对比。对比方法和配置方法如下:

1) MRec^[5]: 基于异质图, 将元路径通过卷积神经网络来进行向量化后结合节点向量进行推荐的方法。将用户和商品换成人员和公司后, 计算他们之间存在任职关系的概率。

2) NEMO^[3]: 利用上下文的长短期记忆网络生成员工的技能、毕业院校等实体的向量, 预测员工接下来的任职序列。为了统一任务目标, 我们取每位员工任职序列中出现的公司作为正向预测结果。

3) HCPNN^[4]: 利用分层神经网络和嵌入注意力机制, 预测员工的下一个雇主及雇佣时间。同样将下一个雇主作为正向预测结果。

4) NRec^[6]: 目前最新的基于异质图的推荐算法, 通过随机游走出来的元路径进行交错融合后进行推荐。同样, 将原模型中的用户和商品对应到人员和公

司后, 计算任职概率。

4.3 实验结果

我们采用 AUC、F1-score 来作为评判指标^[14], 并采用验证集方法 (The Validation Set Approach), 参考文献 [15] 中的实验流程, 随机挑选 70% 的数据作为训练集, 剩余 30% 作为验证集, 并对随机挑选的 5 次数据依次进行训练, 最终得到的结果取平均值。

为了通过无监督的方式获得异质图上节点的初始向量, 并要求其包含结构和语义信息以得到最佳预测效果, 我们参考文献 [5] 的做法, 采用目前较为常用的 Metapath2vec^[16] 方法来获得异质图中节点的初始向量。

实验结果如表 2 所示。

表 2 各模型的实验结果对比

模型	F1-score	Precision	AUC
MRec	0.738	0.745	0.771
NEMO	0.653	0.650	0.692
HCPNN	0.631	0.625	0.680
NRec	0.742	0.748	0.779
BSGAEP	0.783	0.790	0.813

可以看到, 本文模型效果要优于其他模型的效果, 说明本文模型在任职预测这种存在双向选择场景的问题中具有较好的效果。

另外, 我们看到基于异质图的两种方法 MRec 和 NRec 的效果要好于未采用异质图的 NEMO 和 HCPNN, 这说明异质图的引入对于任职预测的效果有较大提升。

4.4 可解释性分析

在本文模型中, 路径注意力和双向选择注意力的权重可用于解释任职预测的结果。我们从实验数据中抽取了两个真实案例进行研究, 如图 3 所示。

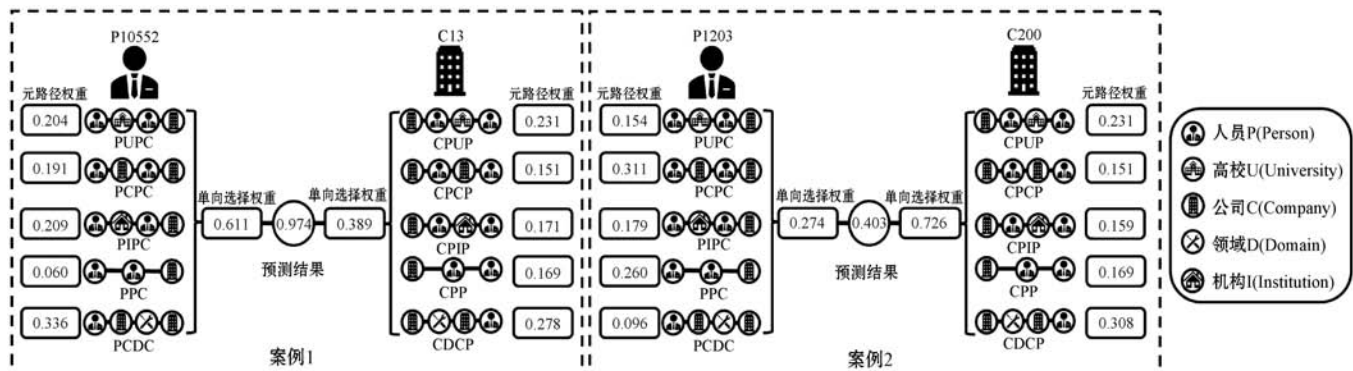


图 3 案例研究

在案例 1 中可以看到,P10552 人员和 C13 公司在 PUPC(CPUP)和 PCDC(CDCP)路径上的权重都比较高,说明 P10552 人员对于公司内是否有校友和公司的所属行业领域比较看重;而 C13 公司在招聘时也比较看重人员的毕业院校以及其曾经工作所在的行业领域。另外,该人员的单向选择权重更大,说明其在面对该公司时处于较为强势的地位。综合以上他们之间任职关系建立的概率更大。

在案例 2 中,P1203 人员和 C200 公司之间的任职概率不高,原因是 P1203 在 PCPC 路径上的权重比较高,说明其找工作比较倾向于找有前同事在的公司;但 C200 可能更看重 CPUC、CDCP 这两条分别反映校友人脉和就业领域的路径。说明他们在求职和招聘时的偏好有所不同。另外,C200 的单向选择权重更高,说明假如这个人员会来这家公司应聘,公司的选择相比人员的选择会更加重要。

另外,我们也观察了部分案例的节点注意力权重,但由于节点向量的每一维无法用自然语言进行解释,我们无法利用其来提升预测的可解释性。

4.5 三层注意力对比实验

为了验证本文模型中各部件的必要性,我们还进行了消融实验,对比方法如下:

- 1) BSGAEP:完整的基于图双向选择注意力的公司任职预测模型。
- 2) BSGAEP-pa:将完整模型的路径注意力机制去除,将元路径向量的加权平均替换为直接平均。
- 3) BSGAEP-bsa:将完整模型的双向选择注意力机制去除,将两条单向选择向量的加权平均替换为直接平均。
- 4) BSGAEP-va:将完整模型的节点注意力机制去除,直接将节点的初始向量加入学习。

消融实验的结果如图 4 所示。通过实验结果可以看出,缺少路径注意力对模型效果的影响最大,说明分别对人员和公司计算不同路径的权重是有必要的;双向选择注意力对模型的影响虽略小于路径注意力,但也说明该数据集中公司与员工的选择权力还是有所差别;节点注意力的影响最小,但对模型还是能起到一定的提升作用。

综合上文所述的案例研究以及消融实验,我们可以用表 3 对三层注意力的加入原因和提升效果进行总结。

表 3 三层注意力的加入原因及提升效果

注意力机制	加入原因		提升效果	
	提取双向选择信息	增强节点信息	预测效果	可解释性
路径注意力	√		√	√
双向选择注意力	√		√	√
节点注意力		√	√	

在三层注意力中,路径注意力和双向选择注意力都是为了增强人员和公司之间的双向选择信息,其中路径注意力是通过增强单向选择信息来间接增强双向选择信息,而节点注意力是为了增强节点信息。最终实验结果表明,三种注意力都有利于提升模型的预测效果,但只有路径注意力和双向选择注意力对预测的可解释性的提升起到了作用。

5 结 语

本文充分利用了公司任职关系中存在双向选择关系的特点,利用路径注意力来计算不同元路径分别在人员与公司眼中的重要程度;再考虑到双向选择不平等情况,加入双向选择注意力;最后再利用节点注意力进一步提升节点向量在预测中的作用。一开始采用自编码器对元路径向量进行压缩,也可以起到去除噪声和统一向量维数的目的。实验结果证明,利用异质图进行建模可以有效提升任职预测的效果,自编码器和三层注意力的加入对模型预测的准确度有所提升。另外,路径注意力和双向选择注意力的加入对于任职预测的可解释性也有较好的提升作用。

参 考 文 献

- [1] Sun Y Z, Han J W, Yan X F, et al. PathSim: Meta path-based top-k similarity search in heterogeneous information networks[J]. Proceedings of the VLDB Endowment,2011,4 (11):992 - 1003.
- [2] Xu H, Yu Z W, Yang J Y, et al. Dynamic talent flow analysis with deep sequence prediction modeling [J]. IEEE Transactions on Knowledge and Data Engineering,2018,31 (10):1926 - 1939.
- [3] Li L Y, Jing H, Tong H, et al. Nemo: Next career move prediction with contextual embedding[C]//26th International Conference on World Wide Web Companion,2017:505 - 513.




图 4 消融实验结果

- [4] Meng Q X, Zhu H S, Xiao K L, et al. A hierarchical career-path-aware neural network for job mobility prediction [C]//25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2019:14–24.
- [5] Hu B, Shi C, Zhao W X, et al. Leveraging meta-path based context for top-N recommendation with a neural co-attention model[C]//24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018:1531–1540.
- [6] Jin J R, Qin J R, Fang Y C, et al. An efficient neighborhood-based interaction model for recommendation on heterogeneous graph[C]//26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2020:75–84.
- [7] Ng A. Sparse autoencoder[EB/OL]. [2021–03–15]. https://nlp.stanford.edu/%7Esocherr/sparseAutoencoder_2011new.pdf.
- [8] Ji H Y, Shi C, Wang B. Attention based meta path fusion for heterogeneous information network embedding[C]//Pacific Rim International Conference on Artificial Intelligence, 2018:348–360.
- [9] Hao Y C, Zhang Y Z, Liu K, et al. An end-to-end model for question answering over knowledge base with cross-attention combining global knowledge[C]//55th Annual Meeting of the Association for Computational Linguistics, 2017:221–231.
- [10] Koren Y, Bell R. Advances in collaborative filtering[M]//Recommender Systems Handbook. Spring, 2015:77–118.
- [11] Shi C, Hu B, Zhao W X, et al. Heterogeneous information network embedding for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 31(2):357–370.
- [12] Wang X, Ji H Y, Shi C, et al. Heterogeneous graph attention network[C]//The World Wide Web Conference, 2019:2022–2032.
- [13] Tang J, Qu M, Wang M Z, et al. Line: Large-scale information network embedding[C]//24th International Conference on World Wide Web, 2015:1067–1077.
- [14] Zhou X H, McClish D K, Obuchowski N A. Statistical methods in diagnostic medicine[M]. John Wiley & Sons, 2009.
- [15] 王晓萍, 郭梦洁, 岳婧雯. 基于关系图谱的人岗关系研究[J]. 大数据, 2020, 6(6):129–139.
- [16] Dong Y X, Chawla N V, Swami A. Metapath2vec: Scalable representation learning for heterogeneous networks[C]//23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2017:135–144.
- 方法[J]. 计算机技术与发展, 2016, 26(12):132–136.
- [40] 林闯. 计算机网络与计算机系统的性能评价[M]. 北京:清华大学出版社, 2001.
- [41] 林闯. 随机 Petri 网和系统性能评价[M]. 2 版. 北京:清华大学出版社, 2005.
- [42] Boukredera D, Adel-Aissanou K. Modeling and performance analysis of cognitive radio networks using stochastic timed colored petri nets[J]. Wireless Personal Communications, 2020, 112(3):1659–1687.
- [43] Sallhammar K, Helvik B E, Knapskog S J. Towards a stochastic model for integrated security and dependability evaluation[C]//1st International Conference on Availability, Reliability and Security, 2006:168.
- [44] 何新贵. 模糊 Petri 网[J]. 计算机学报, 1994, 17(12):946–950.
- [45] 李季, 朱小勇. 模糊 Petri 网及其在 Web 服务信任评估中的应用[J]. 计算机应用研究, 2010, 27(2):573–576.
- [46] 王元卓, 林闯, 程学旗, 等. 基于随机博弈模型的网络攻防量化分析方法[J]. 计算机学报, 2010, 33(9):1748–1762.
- [47] Yu M, Liu C, Qiu X L, et al. Modeling and analysis of information theft trojan based on stochastic game nets[C]//2nd International Conference on Information Science and Control Engineering, 2015:318–322.
- [48] Yu M, Liu C, Qiu X L, et al. Modelling and analysis of phishing attack using stochastic game nets[C]//International Conference on Cyberspace Technology, 2013:300–305.
- [49] Talukder S, Sakib I, Hossen F, et al. Attacks and defenses in mobile IP: Modeling with stochastic game Petri net[C]//International Conference on Current Trends in Computer, Electrical, Electronics and Communication, 2017:18–23.
- [50] Wang Y Z, Yu M, Li J Y, et al. Stochastic game net and applications in security analysis for enterprise network[J]. International Journal of Information Security, 2012, 11(1):41–52.
- [51] 龙毅宏, 潘丹, 张海松, 等. 基于模糊 Petri 网的信任评估[J]. 信息安全与通信保密, 2008(3):58–61.
- [52] Liu J, Zhang B C, Zeng H R, et al. The BeiHang keystroke dynamics systems, databases and baselines[J]. Neurocomputing, 2014, 144:271–281.
- [53] Shen C, Chen Y F, Guan X H, et al. Pattern-growth based mining mouse-interaction behavior for an active user authentication system[J]. IEEE Transactions on Dependable and Secure Computing, 2020, 17(2):335–349.
- [54] Mondal S, Bours P. A study on continuous authentication using a combination of keystroke and mouse biometrics[J]. Neurocomputing, 2017, 230:1–22.
- [55] Yu Y, Xia C H, Li S Y, et al. Trust type based trust bootstrapping model of computer network collaborative defense[J]. China Communications, 2015, 12(12):133–146.