

# 基于图卷积网络的岗位匹配模型研究

孙庆英,周含,刘思妍,李家宏,席倩

(淮阴师范学院 计算机科学与技术学院,江苏 淮安 223300)

**摘要:**提出了一种基于图卷积网络(GCN)的岗位匹配模型,该模型首先对公司招聘信息和用户简历信息进行表示,进而利用图结构对用户简历和招聘需求信息进行建模,通过图卷积网络的传播与聚合操作,得到更能反映匹配关系的表示,最终实现招聘信息与简历信息的匹配.实验结果表明,所提的模型和基准模型相比,在  $F1$  值上提升了 3.3 个百分点,能有效提高招聘信息与用户简历信息的匹配性能.

**关键词:**图卷积网络;图结构;岗位匹配;自然语言处理

**中图分类号:**TP391

**文献标志码:**A

**文章编号:**1000-2367(2025)06-0093-08

岗位匹配任务是近年来人才招聘领域的研究热点之一,旨在利用人工智能技术,通过分析候选人的技能、经验和兴趣,以及工作岗位的要求和特征,从大量的候选人和岗位信息中,找到最佳的匹配结果.近年来,高校毕业生数量逐年增长,大量的求职者在寻找契合自身的岗位时,需要耗费大量的时间和精力.而企业在面对众多求职者时,想找到相契合的员工也如海底捞针一般.因此,快速高效的自动化岗位匹配能提高招聘效率和准确率,满足求职者和企业的需求.

1988 年, SALTON 等<sup>[1]</sup>提出了自动文本检索中的术语加权方法,为岗位匹配算法打下了算法基础.伴随着计算机网络的兴起,互联网招聘逐渐步入大众视野,出现了大量基于文本相似度算法来计算用户简历与岗位之间匹配度的工作<sup>[2-3]</sup>.比如, HEGGO 等<sup>[2]</sup>使用 TF-IDF 和 BM25 等公式计算用户的简历、用户搜索行为和岗位描述之间的相关性得分以对匹配结果进行排序.近期, ALSHAREF 等<sup>[3]</sup>探讨了在自动化简历筛选过程中使用文本相似性度量的效率.近年来,随着神经网络在多项任务上取得了不错的效果,很多研究者基于神经网络提出了多种岗位匹配的算法. LAVI 等<sup>[4]</sup>利用 BERT(bidirectional encoder representations from transformers)模型来构建职位描述和简历文本的嵌入表示.

无论是基于相似度的方法还是基于神经网络的岗位匹配模型,均未显式建模不同用户简历与岗位描述之间的关联关系,尤其是不同岗位对用户属性的共性要求(比如年龄,学历等),导致匹配策略缺乏跨岗位的适应性.

比如例 1 中有 3 个岗位描述和两个用户简历,定义一个匹配函数,  $f:U * J \rightarrow [0,1]$ ,  $f$  表示用户简历  $u(u \in U)$  与岗位描述  $j(j \in J)$  的匹配度,取值为 0 或 1,1 表示匹配,0 表示不匹配.

## [例 1] 不同的岗位和简历描述

岗位描述 1 要求本科及以上学历,财务管理、会计学等相关专业,2019 届应届毕业生优先.

岗位描述 2 要求 2017 年应届毕业生,大学本科及以上学历,土木工程相关专业毕业.

**收稿日期:**2025-02-20;**修回日期:**2025-04-03.

**基金项目:**国家自然科学基金(62006093);江苏高校“青蓝工程”优秀青年骨干教师资助项目(苏教师函[2022]29 号);教育部人文社会科学研究一般项目(24YJAZH113);江苏省大数据智能工程实验室开放课题(SDGC2158).

**作者简介(通信作者):**孙庆英(1982—),女,江苏淮安人,淮阴师范学院副教授,博士,研究方向为自然语言处理, E-mail: qingying.sun@foxmail.com.

**引用本文:**孙庆英,周含,刘思妍,等.基于图卷积网络的岗位匹配模型研究[J].河南师范大学学报(自然科学版),2025, 53(6):93-100.(Sun Qingying,Zhou Han,Liu Siyan,et al.Job matching model based on graph convolutional networks[J].Journal of Henan Normal University(Natural Science Edition),2025,53(6):93-100.DOI:10.16366/j.cnki.1000-2367.2025.02.20.0002.)

岗位描述 3 要求 2019 届毕业生,本科及以上学历,材料科学与工程(材料员岗位)、安全工程(安全员岗位)等相关专业.

用户简历 1 年龄 22 岁,本科学历,2019 年毕业,专业为会计学,期望的工作类型:会计.

用户简历 2 年龄 33 岁,本科学历,2008 年毕业,专业为小学教育,期望的工作类型:教育.

表 1 为例 1 中 3 个岗位描述和两个用户简历的匹配度.从例 1 中 3 个岗位描述和要求中可以判断都需要本科以上的青年求职者,如果能将这种岗位需求和用户年龄、学历等属性之间的关系建模出来,将更有利于岗位匹配度的提高.

近年来,图神经网络(graph neural network,GNN)模型已经被证明能够用图来建模复杂关系,并实现全局优化<sup>[5-8]</sup>,其中,图卷积网络<sup>[8]</sup>(graph convolutional network,GCN)在很多自然语言处理任务中都非常有效.图卷积网络基于图上的特征传播与聚合将特征信息和图结构信息结合起来学习节点更好地表示,从而有效建模这些节点之间的关系.将图卷积网络用于岗位匹配任务存在 2 个难点:首先是如何表示岗位和用户简历来获得更高的语义相关性,其次是如何建模岗位和简历之间的全局关系来提高岗位匹配度.

本文提出了一种融合图卷积网络与预训练语言模型的岗位匹配模型(job matching model based on GCN,JMMGCN).该模型能有效捕获岗位描述以及用户简历之间的关系,一方面通过预训练语言模型来表示岗位描述和用户简历信息,另一方面通过图卷积网络来连接有相似学历、年龄等要求的岗位描述,建模了岗位描述和用户简历之间的全局关系.实验结果表明,本文提出的模型和基准模型相比能提高岗位匹配的准确率,说明预训练语言模型的强大文本表示能力,岗位描述和用户简历之间全局关系的建立能更好地理解岗位的要求,能够更准确地评估用户简历与公司岗位的适配程度.

## 1 相关工作

现有的岗位匹配推荐或简历匹配推荐的研究主要包括基于文本相似度的匹配算法、基于神经网络的匹配算法,以及基于图神经网络的岗位匹配推荐算法,下面分别介绍这些相关工作.

### 1.1 基于文本相似度的岗位匹配研究

在电子简历中包含了各种类型的文本信息,如姓名、学历、期望工作等.为了有效处理这些不同类型的数据,研究者们采用了多种机器学习技术.施元鹏等<sup>[9]</sup>研究了基于 doc2vec 模型的结构化文本数据处理方法,利用 doc2vec 算法来匹配简历与岗位之间的长文本信息.徐锦阳等<sup>[10]</sup>采用贝叶斯公式对求职者简历中的专业属性进行分类,提供更精确的职位推荐.近期,LAVI 等<sup>[4]</sup>专注于构建有效的文本信息嵌入,以解析简历中的嘈杂数据,实现了跨语言的文本信息匹配,进一步提升了匹配的准确性和效率.

### 1.2 基于神经网络的岗位匹配研究

神经网络在许多领域中的应用十分广泛.DENG 等<sup>[11]</sup>使用嵌入层来探索特征交互,并且合并从简历中提取的两个自动学习生成的特征来生成新的模型,该模型在有效性和精度上优于浅层模型.QIN 等<sup>[12]</sup>提出了一种基于端到端主题的能力感知岗位匹配神经网络框架,为拟合结果提供更好的可解释性,同时提出了一种基于递归神经网络的词级语义表示,用于工作要求和求职者体验.

### 1.3 基于图神经网络的应用研究

卷积神经网络(convolutional neural network,CNN)、循环神经网络(recurrent neural network,RNN)等模型在学习文本语义表示方面发挥了重要作用,但在建模信息的复杂关系方面明显存在不足.KIPF 等<sup>[8]</sup>提出了图神经网络,这是一种能够捕捉数据的复杂拓扑结构的网络,特别适合处理非欧几里得数据.在相关研究领域,图卷积网络已经显示出其强大的潜力.例如,YAO 等<sup>[13]</sup>提出了一种将图卷积网络应用于文本分

表 1 岗位匹配任务举例

Tab. 1 Example of job matching task		
岗位	简历	匹配度
岗位描述 1	用户简历 1	1
	用户简历 2	0
岗位描述 2	用户简历 1	0
	用户简历 2	0
岗位描述 3	用户简历 1	0
	用户简历 2	0

类任务的方法,这种方法基于词共现和文档词关系构建了文本图,为语料库学习一个文本图卷积网络,从而进行有效分类.此外,SCHLICHTKRULL 等<sup>[14]</sup>进一步提出了关系图卷积网络,并应用于知识图谱中知识库补全任务.LIU 等<sup>[15]</sup>有效地将异构、进化图上的归纳图学习与编码器-解码器图神经网络模型相结合,实现大规模个性化职位匹配.

## 2 基于图卷积网络的岗位匹配模型

本文旨在通过用户简历和公司发布的招聘信息实现用户简历和公司岗位是否匹配的预测.给定一个岗位描述  $e_i$ ,与其所对应的用户简历为  $u_i$ ,通过输入岗位描述  $e_i$ 、用户简历  $u_i$  进行匹配预测,预测结果为  $y$ (匹配为1,不匹配为0).目前已有的模型鲜有考虑基于用户简历  $u_i$  包含的属性(学历,年龄,工作经历等)信息和公司岗位描述  $e_i$  之间的联系来实现全局优化.

为了充分挖掘用户的学历、年龄、岗位描述等信息对岗位匹配任务的作用,本文提出了一个图卷积网络模型(JMMGCN)建模用户简历信息和公司岗位要求之间的需求关系实现岗位匹配的全局优化,模型如附录图 S1 所示.假设用户  $u_i$  对应某个岗位描述  $e_i$  的总体需求表示为  $\{a_i, b_i, c_i, d_i, e_i\}$ ,其中  $a_i$  为用户的学历信息,  $b_i$  为用户的年龄信息,  $c_i$  为用户期望的工作类型,  $d_i$  为岗位要求的学历信息.本文首先使用预训练语言模型来表示用户简历信息  $u_i$  及其岗位描述  $e_i$ ,并基于这些表示使用图卷积网络进行传播和聚合的迭代学习,基于用户简历,岗位描述构建社会连接,以获得具有相似学历或年龄的简历和岗位描述之间的连接关系,最后基于图卷积网络丰富的语义表示使用全连接层实现用户岗位匹配预测.

### 2.1 岗位描述和用户简历表示

本文主要基于 Transformer 结构的双向编码表示模型 BERT 来对用户简历以及公司招聘信息进行编码表示.公司招聘信息主要考虑岗位描述文档和公司要求的学历信息,用户简历主要考虑用户的年龄、学历和期望的工作类型信息.学历主要包括:中专,专科,本科,研究生,EMBA,博士.年龄划分为青年([18, 25)岁),中青年([25, 35)岁),中年([35, 55)岁)3个年龄段.用户期望的工作类型主要包含会计、教育、医疗、土木和销售等19个类别.为了便于后续信息处理,这里将公司对学历的要求信息也存放到用户简历信息中.

首先,以岗位描述信息为例,对公司招聘信息中的岗位描述  $e_i$  进行分词,然后将[CLS]标记、分词后的岗位描述,以及[SEP]标记拼接,生成输入序列  $\hat{x}$ .

其次,对于  $\hat{x}$  中的每个词  $\hat{x}_i$  通过将 token、segment 和 position embedding 相加,将其转换到向量空间,得到输入编码  $\mathbf{h}^i \in R^{(n+2) * h}$ ,其中  $h$  为隐藏层大小.

接着,使用  $L$  层堆叠的 TransformerBlock 来将输入编码投影为一系列上下文向量  $\mathbf{h}^i$ ,如式(1)所示:

$$\mathbf{h}^i = \text{TransformerBlock}(\mathbf{h}^{i-1}), \forall i \in [1, L]. \quad (1)$$

最终,使用 BERT 的输出  $H_p$  作为每个岗位描述  $e_i$  的表示,同样可以得到用户简历的 BERT 表示  $\{H_A, H_B, H_C, H_D\}$ .

### 2.2 岗位和用户简历之间的关系建模

在获得每个岗位描述及其用户简历的表示后,使用图卷积网络来建模岗位描述与用户简历之间的联系,如附录图 S1 需求背景连接部分所示.该图结构中,包含的结点有:岗位描述结点  $H_p$ ,用户学历结点  $H_A$ ,用户年龄段结点  $H_B$ ,用户期望工作类型结点  $H_C$ ,岗位要求学历结点  $H_D$ .假设结点总数为  $n$ ,使用一个  $n * n$  的邻接矩阵  $\mathbf{A}$  来表示其结构,其中  $\mathbf{A}_{ij} = 1$  表示节点  $i$  到节点  $j$  之间存在边.对于某一个岗位描述结点,将其与之匹配的用户简历信息中的学历、年龄、期望工作类型、岗位要求学历结点分别构建边,对所有样本都进行处理后,将完成一个包含岗位和简历之间关系的邻接矩阵  $\mathbf{A}$  的初始化操作.

接下来,使用图卷积操作对图神经网络中的结点进行迭代和更新,利用图结构进行信息传播,在  $l$  层的 GCN 中,将节点  $i$  在第  $l-1$  层的输入向量表示为  $\mathbf{h}_i^{(l-1)}$ ,输出向量表示为  $\mathbf{h}_i^{(l)}$ ,则一个图卷积操作可以表示为:  $\mathbf{h}_i^{(l)} = \sigma(\sum_{j=1}^n \mathbf{A}_{ij} \mathbf{w}^{(l)} \mathbf{h}_j^{(l-1)} + b^{(l)})$ ,其中  $\mathbf{w}^{(l)}$  是线性变换,  $b^{(l)}$  是偏置项,  $\sigma$  是非线性函数.在每次图卷积过程中,每个节点都会从图中的相邻节点收集和总结信息,通过图卷积操作,GCN 可以在多跳邻居之间传播信息,学习节点的表示.

采用图卷积操作通过将每个图转换为对应的邻接矩阵  $\mathbf{A}$  来实现建模岗位描述  $H_p$  与用户简历  $\{H_A, H_B, H_C, H_D\}$  之间的联系,其中  $\mathbf{A}_{ij} = 1$  表示  $H_p$  与用户简历之间存在连接.

在将 GCN 应用于岗位描述  $H_p$  及对应的用户简历  $\{H_A, H_B, H_C, H_D\}$  之后,得到了岗位描述  $H_p$  的隐藏表示  $\mathbf{H}'$ , 如式(2)所示:

$$\mathbf{H}' = \text{GCN}(H_p, H_A, H_B, H_C, H_D).$$

(2)

简而言之,GCN 层通过图卷积操作学习岗位描述与用户简历之间的连接,生成岗位描述基于用户简历的隐藏表示,该表示考虑了岗位描述与用户简历的关联,为后续的匹配检测任务提供了依据.

2.3 岗位匹配识别

给定一个岗位描述,对某一用户的简历进行岗位匹配返回一个二进制结果  $Y$ ,其结果  $Y = 0$ (不匹配) 或  $Y = 1$ (匹配),可以被视为一个单标签分类任务.形式上,给定输入向量  $\mathbf{H}'$ , 首先使用隐藏层来为每个岗位描述引导一组高级特征,如式(3)所示:

$$H_p^j = \sigma(\omega_p^{jh} \mathbf{H}' + b_p^{jh}).$$

(3)

然后,  $H_p^j$  被用作 softmax 输出层的输入,如式(4) 所示,其中,  $\omega_p^{jh}, b_p^{jh}, \omega_p^j$  和  $b_p^j$  是模型参数.

$$P_p^j = \text{softmax}(\omega_p^j H_p^j + b_p^j).$$

(4)

2.4 模型训练

本文的训练目标是最小化一组训练示例上的交叉熵损失值,将学习到的岗位描述文本表示作为特征,输入到分类模型中进行训练,交叉熵损失函数如式(5)所示.

$$J(\theta_y) = - \sum_{i=1}^N \sum_{j=1}^K y_i^j \lg y_i^j,$$

(5)

其中  $N$  表示训练样本的总数量,  $K$  表示匹配结果的标签类别数量,  $y_i^j$  表示测试集中第  $j$  个岗位匹配的真实标签(0 或 1),  $\hat{y}_i^j$  表示测试集中第  $j$  个岗位匹配的预测值(0 或 1). 通过最小化交叉熵损失函数,优化模型参数,使其更好地预测用户所适配的岗位,提高模型的准确性和泛化能力.

3 实验及分析

3.1 实验数据及评价指标

本文数据来源于阿里云和智联招聘携手举办的数据智能云上编程大赛中的脱敏数据集<sup>①</sup>,本数据集集中的数据为智联招聘网站提供的真实数据.本实验通过将上述数据集集中的用户简历数据集、公司招聘数据集和用户简历与公司招聘匹配数据集进行连接、组合与筛选形成本实验的数据集,一共包含 11 333 条样本数据,由 1 002 条用户简历信息、8 169 条公司招聘信息和 11 340 条简历与岗位的匹配信息组成.该文在 GitHub 上公开了本文使用的数据集<sup>②</sup>,数据集包含训练集和测试集,不同类别样本的分布如表 2 所示,训练集中随机选择 10%作为开发集.

从数据集中用户的年龄、学历类型分布的统计结果可以发现,大多数求职者的年龄在 25 至 35 岁之间,其中青年占 38%,中青年占 49%,超过 50%的用户拥有本科学历.

在实验结果的评价方面,根据岗位推荐的匹配结果,分别计算准确率、召回率、F1 值(准确率和召回率的调和平均数).

3.2 实验设置

本文的模型使用了 BERT 中文预训练模型[<https://huggingface.co/bert-base-chinese/tree/main>],通

表 2 数据集分布

Tab. 2 Distribution of instances in the datasets

岗位匹配	训练集	测试集
匹配/%	52.07	51.72
不匹配/%	47.93	48.28
总计	7 027	4 306

① 第二届阿里巴巴大数据智能云上编程大赛-智联招聘人岗智能匹配 <https://tianchi.aliyun.com/competition/entrance/231728/information>.

② <https://github.com/xhuguo/apt/releases/tag/item>.



过开发集上的准确率和宏观  $F1$  值来选择最佳模型,并采用提前停止策略以防止过拟合.使用 AdamW 优化算法更新模型参数,初始学习率设置为 0.000 01.为了进一步防止神经网络过度拟合,在模型中引入了 dropout 机制,dropout 率为 0.7.BERT 模型的输出维度为 768,而图卷积网络的隐藏层维度设置为 512.批处理大小设定为 32,整个训练过程中设定的训练周期(epoch)为 10,文本的最大字符长度为 125.此外,还设置了权重衰减(weight\_decay)为 0.000 001,以帮助控制模型复杂度并避免过拟合.

3.3 与基准系统的比较

在本小节中,将提出的图卷积网络岗位匹配模型(JMMGCN)与以下基准模型进行比较.

ChatGPT:是由 OpenAI 开发的对话模型<sup>[16]</sup>,基于 GPT(generative pre-trained transformer)架构.在本实验中,将用户简历信息和岗位要求的学历拼接,作为 ChatGPT 模型的输入与公司的岗位描述进行匹配.

MT5-base:是一个多语言的文本生成模型<sup>[17]</sup>.在本实验中,将岗位描述和用户简历信息拼接,作为 MT5-base 模型的输入进行岗位匹配的预测.

CNN:卷积神经网络<sup>[18]</sup>是一种深度学习模型,主要用于处理具有网格结构的数据.在本实验中将岗位描述和用户简历信息拼接,利用 CNN 来实现岗位匹配的二分类预测.

LSTM:长短期记忆网络<sup>[19]</sup>(long short-term memory, LSTM).在本实验中将岗位描述和用户简历信息拼接,作为 LSTM 模型的输入来进行岗位匹配的分类.

BERT:是一种基于 Transformer 的预训练模型<sup>[20]</sup>,将岗位描述和用户简历信息拼接后,使用 BERT 构建并训练模型,以对岗位匹配进行二分类预测.

JMMGCN:本文提出的图卷积网络岗位匹配模型.

表 3 为本文所提的 JMMGCN 模型和以上几种基准模型的实验对比结果,通过表 3 的实验结果可以发现:1)JMMGCN 模型的准确率和  $F1$  值都超过了其他几种模型,表明图卷积网络在建模岗位描述和用户简历关系方面的有效性;2)ChatGPT 模型和 MT5-base 模型的实验效果并不理想,说明大模型在岗位匹配任务上的泛化能力较弱,对该任务的语义理解能力还存在不足;3)CNN 模型的实验效果在几个对比模型中较低,说明通过 CNN 简单的拼接岗位描述和用户简历并不能得到更多有利的信息;4)LSTM 模型的实验结果相对 CNN 模型有所提升,说明 LSTM 在处理文本序列任务上的有效性;5)对比 BERT 和 JMMGCN 模型,两个模型都获得了较好的实验结果,也验证了 BERT 预训练模型的强大表示能力,基于 BERT 表示通过 GCN 构建的需求背景连接也更有利于岗位匹配的识别;6)所有模型的实验结果整体不高,说明岗位描述和用户简历之间的岗位匹配任务具有一定的复杂性,本文所提模型具有一定的有效性,但是对复杂关系建模的效果还有很大的提升空间.

表 3 和基准模型的比较  
Tab. 3 Comparison with the baseline models

模型	ChatGPT	MT5-base	CNN	LSTM	BERT	JMMGCN
准确率	0.500 7	0.502 0	0.517 2	0.525 8	0.563 6	<b>0.579 4</b>
召回率	0.500 7	0.501 9	<b>0.636 2</b>	0.581 0	0.564 9	0.578 8
$F1$ 值	0.489 0	0.502 0	0.545 6	0.552 0	0.563 9	<b>0.578 6</b>

3.4 不同影响因素分析

基于本文提出的 JMMGCN 模型,分析了不同的用户简历信息对模型性能的影响,定义了多种信息组合,构建不同数量的社会关系节点图来用于验证这些信息组合对求职者与职位之间的匹配程度的影响.这些组合涵盖了用户的个人信息(如年龄、学历、期望的工作类型)以及公司的职位要求(如岗位描述和要求的学历).以下是每个类型的简写表示:CD:表示公司岗位描述;UA:表示用户年龄;UD:表示用户学历;UJ:表示用户期望工作类型;CDeg:表示公司要求学历.

分别考虑了 2、3、4、5 个不同结点组合构建图,其中岗位描述结点(CD)为基础结点,每个组合中都必须包含,然后将剩下的 4 种结点 UA、UD、UJ、CDeg 与 CD 构成不同的组合,表 4 中列举了这些不同组合的实验结果.

表 4 JMMGCN 模型中不同结点组合构建图的结果比较

Tab. 4 Comparison of different node combinations in constructing graphs in JMMGCN

结点数	结点组合	准确率	召回率	F1 值
2	UA+CD	0.578 0	0.577 6	0.577 9
	UD+CD	0.567 6	0.578 6	0.567 2
	UJ+CD	0.578 0	0.575 7	0.577 0
	CDeg+CD	0.571 3	0.567 1	0.569 7
	平均值	0.574 4	0.574 9	0.573 6
3	UA+UD+CD	0.577 1	0.575 5	0.576 4
	UA+UJ+CD	0.580 8	0.579 9	0.578 0
	UA+CDeg+CD	0.564 8	0.569 4	0.564 7
	UD+UJ+CD	0.573 2	0.574 8	0.573 1
	UD+CDeg+CD	0.577 8	0.576 3	0.574 7
	UJ+CDeg+CD	0.577 1	0.580 0	0.576 4
	平均值	0.574 7	0.576 1	0.573 4
4	UA+UD+UJ+CD	0.574 3	0.574 9	0.573 8
	UA+UD+CDeg+CD	0.568 3	0.547 9	0.573 8
	UA+UJ+CDeg+CD	0.570 8	0.571 4	0.568 9
	UD+UJ+CDeg+CD	0.572 9	0.570 3	0.570 6
	平均值	0.571 6	0.572 2	0.571 8
5	UA+UD+UJ+CDeg+CD	0.579 4	0.578 8	0.578 6

从表 4 的实验结果可以观察到：

(1)在不同的结点组合构建图神经网络下,JMMGCN 算法的准确率和 F1 值有所变化.这表明不同结点组合对于算法的预测能力产生了影响.例如,UA+UJ+CD 组合显示出相对较高的准确率和 F1 值,这表明建模用户年龄、期望工作类型和岗位描述信息之间的关系在岗位匹配时提供了更加精确的用户需求信息,能帮助更好地对接岗位需求.

(2)尽管学历信息对匹配质量的影响较小,但它仍然是关键因素,因为许多岗位有基本的学历要求.综合考虑用户的年龄、学历和期望工作类型时,模型的性能得到显著提升,表明多维度的用户信息能够提供更全面的上下文,从而提高匹配的准确性和有效性.

(3)当公司要求的学历与用户的学历信息结合时,模型的性能都相对比较高,说明这两种信息的建模能够显著增强匹配质量.总的来说,全面考虑用户的各项属性与公司要求能够最佳地提高匹配的准确性.

3.5 样例分析

从测试集中抽取部分样例分析图卷积网络在岗位匹配任务中的作用.表 5 列举了一些被 CNN 模型预测错误但被 JMMGCN 模型预测正确的例子.对于这些例子,JMMGCN 模型能构建岗位描述和用户学历、年龄、期望的工作类型等信息之间的关系,比如例 2 和例 3 的岗位描述和中青年、本科这两个结点都建立了连接,例 3 和例 4 的岗位描述都和用户期望的工作类型“教育/培训”建立了连接,通过这些连接,可以获得一些信息,比如中青年人青睐的岗位有哪些共性,教育/培训类的工作都有哪些不同的岗位要求等,这些共性的信息对岗位匹配的预测有一定的帮助作用.

4 结 论

本文提出了一种基于图卷积网络的招聘信息与简历信息的匹配模型,充分利用了文本特征和图结构信息,通过在真实数据集上的实验验证,本文提出的模型在招聘信息与简历信息匹配任务上取得了优异的性能,相较于基准方法,具有更高的匹配准确度,可为人才招聘领域提供新的思路和方法.未来可以进一步优化

模型,提升匹配效果,探索更多的文本表示方法和关系建模技术,以应对更复杂的匹配场景.

表 5 测试集中 CNN 预测错误但 JMMGCN 预测正确的部分样例

Tab. 5 Examples drawn from the test set with job matching labels that are incorrectly inferred by CNN but correctly predicted by the JMMGCN model

序号	用户简历	岗位描述	标准答案	CNN	JMMGCN
例 2	期望岗位:建筑/房地产; 学历:大专;年龄:中青年; 公司要求最低学历:本科	具有造价工程师执业资格,能胜任建筑项目管理工作, 了解土木机工程造价,具有较强沟通协调能力.	不匹配	匹配	不匹配
例 3	期望岗位:教育/培训; 学历:本科;年龄:中青年; 公司要求最低学历:本科	负责宝能汽车金融公司区域销售工作,做好客户车辆咨 询相关服务工作,提升客户满意度保持良好客户关系.	匹配	不匹配	匹配
例 4	期望岗位:教育/培训; 学历:大专;年龄:青年; 公司要求最低学历:大专	对待培训工作认真负责,熟悉掌握一二三年级语文、数 学、英语功课,对孩子耐心,有一定教育经验,能够与学 生与家长进行良好沟通.	匹配	不匹配	匹配

附录见电子版(DOI:10.16366/j.cnki.1000-2367.2025.02.20.0002).

参 考 文 献

[1] SALTON G, BUCKLEY C. Term-weighting approaches in automatic text retrieval[J]. Information Processing & Management, 1988, 24(5): 513-523.

[2] HEGGO I A, ABDELBAKI N. Behaviorally-based textual similarity engine for matching job-seekers with jobs[C]//The International Conference on Advanced Machine Learning Technologies and Applications(AMLTA2018). Cham: Springer, 2018: 564-574.

[3] ALSHAREF A, NASSOUR H, Sharma J. Exploring the efficiency of text-similarity measures in automated resume screening for recruitment[C]//INDIACom. New Delhi: IEEE, 2023: 36-42.

[4] LAVI D, MEDENTSIY V, GRAUS D. conSultantBERT: fine-tuned Siamese sentence-BERT for matching jobs and job seekers[EB/OL]. [2025-02-10]. <https://arxiv.org/abs/2109.06501>.

[5] 胥桂仙, 刘兰寅, 张廷, 等. 基于预训练模型和图神经网络的藏文文本分类研究[J]. 东北师大学报(自然科学版), 2023, 55(1): 52-64.

XU G X, LIU L Y, ZHANG T, et al. Tibetan text classification based on pre-trained model and graph neural network[J]. Journal of North-east Normal University(Natural Science Edition), 2023, 55(1): 52-64.

[6] DIAO Z L, WANG X, ZHANG D F, et al. Dynamic spatial-temporal graph convolutional neural networks for traffic forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 890-897.

[7] ZHANG X, ZHANG L H, ZHOU D Y. Sentiment analysis on streaming user reviews via dual-channel dynamic graph neural network [C]//Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing. Singapore, Stroudsburg: ACL, 2023: 7208-7220.

[8] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks[EB/OL]. [2025-02-10]. <https://arxiv.org/abs/1609.02907>.

[9] 施元鹏, 单剑峰. 基于文本相似度的简历匹配推荐算法研究[J]. 计算机仿真, 2022, 39(4): 441-444.

SHI Y P, SHAN J F. Research on resume matching recommendation algorithm based on text similarity[J]. Computer Simulation, 2022, 39(4): 441-444.

[10] 徐锦阳, 张高煜, 王曼曦, 等. 招聘网站职位与简历的双向匹配相似度算法[J]. 信息技术, 2016, 40(8): 43-46.

XU J Y, ZHANG G Y, WANG M X, et al. Bi-directional matching similarity algorithm for positions and resumes of recruitment website [J]. Information Technology, 2016, 40(8): 43-46.

[11] DENG Y, LEI H, LI X Y, et al. An improved deep neural network model for job matching[C]//2018 International Conference on Artificial Intelligence and Big Data(ICAIBD). Chengdu: IEEE, 2018: 106-112.

[12] QIN C, ZHU H S, XU T, et al. An enhanced neural network approach to person-job fit in talent recruitment[J]. ACM Transactions on Information Systems, 2020, 38(2): 1-33.

[13] YAO L, MAO C S, LUO Y. Graph convolutional networks for text classification[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 7370-7377.

[14] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks[C]//The Semantic

Web,Cham:Springer,2018:593-607.

[15] LIU P,WEI H C,HOU X C,et al.LinkSAGE:optimizing job matching using graph neural networks[EB/OL].[2025-02-10].https://arxiv.org/abs/2402.13430.

[16] BROWN T B,MANN B,RYDER N,et al.Language models are few-shot learners[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems.[S.l.]:ACM,2020:1877-1901.

[17] XUE L T,CONSTANT N,ROBERTS A,et al.MT5:a massively multilingual pre-trained text-to-text transformer[EB/OL].[2025-02-10].https://arxiv.org/abs/2010.11934.

[18] LECUN Y,BENGIO Y,HINTON G.Deep learning[J].Nature,2015,521(7553):436-444.

[19] GRAVES A.Long short-term memory[M]//Supervised Sequence Labelling with Recurrent Neural Networks.Berlin:Springer,2012:37-45.

[20] DEVLIN J,CHANG M W,LEE K,et al.BERT:pre-training of deep bidirectional transformers for language understanding[EB/OL].[2025-02-10].https://arxiv.org/abs/1810.04805.

Job matching model based on graph convolutional networks

Sun Qingying, Zhou Han, Liu Siyan, Li Jiahong, Xi Qian

(School of Computer Science and Technology, Huaiyin Normal University, Huaian 223300, China)

**Abstract:** We propose a job matching model based on Graph Convolutional Networks(GCN). The model firstly represents company job postings and user resumes, then models user resumes and job requirements using the graph structure in GCN. By leveraging graph convolutional network propagation and aggregation operations, a representation that better reflects the matching relationship is obtained, ultimately achieving the matching of job postings and resumes. Experimental results show that the model proposed in this paper improves the *F1* score by 3.3 percentage points compared with the baseline model, effectively enhancing the matching performance between job postings and user resumes.

**Keywords:** graph convolutional networks; graph structure; job matching; natural language processing

[责任编辑 陈留院 杨浦]

(上转第 7 页)

Phase-frequency synchronization of the nonlinear coupled neuron oscillators system

Liu Weiqing, Lin Jinghong

(School of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China)

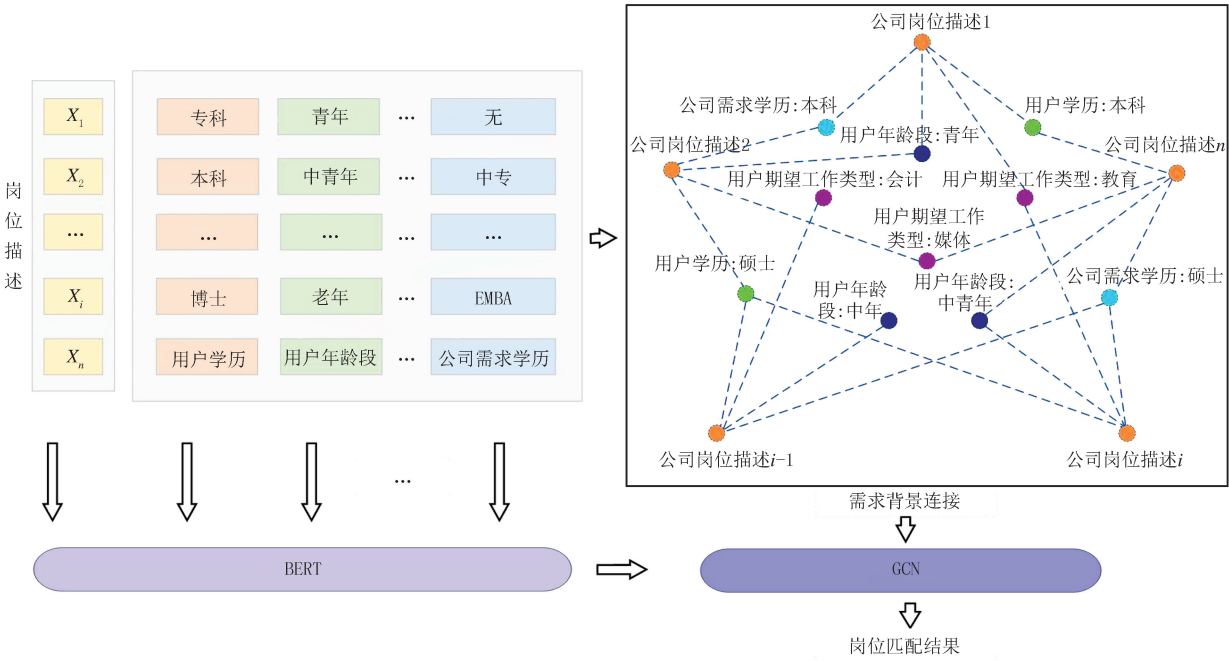
**Abstract:** Phase-frequency synchronization, as one kind of the cross frequency couplings, reflects the interaction between neurons of different frequencies, that is, the dynamic association between frequency and phase. This phenomenon is widely observed in the brain. It is considered to be a key mechanism for coordinating different brain regions and integrating information processing at multiple time scales, helping the brain to handle different complex tasks. The phase-frequency synchronization phenomenon in the two interconnected structures was observed through the nonlinear coupled Poincaré model, and the influence of the intensity of coupling between neurons of different frequencies on the phase-frequency coupling was determined through spectral analysis. Theoretical analysis was conducted to further explore the influence of the phase of low-frequency oscillations on high-frequency oscillations and its regulatory mechanism. This study can not only enrich the study of neuronal synchronization dynamics behavior, but also help to understand the functional coordination mechanism between different brain regions and provide a new perspective for the modeling and optimization of neural networks.

**Keywords:** neuron; cross-frequency coupling; phase-frequency synchronization; phase locking; spectral analysis; Poincaré model

[责任编辑 杨浦 刘洋]



附 录



图S1 基于图卷积网络的岗位匹配模型整体结构

Fig.S1 Overall structure of JMMGCN