

doi:10.11920/xnmzdk.2025.03.011

基于协同注意力网络的人岗匹配方法研究

任书仪¹,李英玲^{1,2},蔡牧昕¹

(1. 西南民族大学计算机与人工智能学院,四川 成都 610225;

2. 西南民族大学计算机系统国家民委重点实验室,四川 成都 610225)

摘要:人岗匹配是通过计算求职者简历与招聘信息的匹配度,进而判断求职者是否适合招聘职位.现有的在线招聘平台通过对求职者与职位进行精准匹配,以实现自动的人岗匹配推荐.但是,已有方法大多聚焦于非结构化文本信息,仅依据求职者简历文本信息与职位发布文本信息来计算相似度,忽略了结构化数值信息以及历史招聘的经验(即历史成功招聘信息)的重要性,导致推荐的精度不够准确.因此,提出基于协同注意力神经网络的人岗匹配模型(CoAttenFit),通过结构化编码将简历的数值信息进行映射,利用协同注意力生成语义特征、使用图神经网络提取历史招聘特征,最后通过特征融合计算简历与职位的匹配度.提出的方法与当前具有代表性的8个基线方法进行比较,在准确率、精确度、召回率和F1值结果平均值上,比基线分别高出10%~27%、6%~27%、12%~20%、9%~17%.实验结果表明,提出的方法能够有效提高人岗匹配的准确率,从而降低资源和时间消耗.

关键词:人岗匹配;协同注意力;图神经网络;文本特征表示

中图分类号:TP315

文献标志码:A

文章编号:2095-4271(2025)03-0323-09

Research on collaborative attention neural network for person-job fit

REN Shuyi¹, LI Yingling^{1,2}, CAI Muxin¹

(1. School of Computer Science and Artificial Intelligence, Southwest Minzu University, Chengdu 610225, China;

2. State Ethnic Affairs Commission Key Laboratory for Computer Systems, Southwest Minzu University, Chengdu 610225, China)

Abstract: Person-job fit calculates the matching degree between a job seeker's CV and the job posting, and then determines whether the job seeker is suitable for the job posting. Existing online recruitment platforms achieve automatic job matching recommendation by accurately matching job seekers with jobs. However, most of the existing methods focus on unstructured text information, and calculate the similarity based only on the text information of the applicant's CV and the text information of the job posting, ignoring the importance of the structured numerical information and the historical recruiting experience (i. e., historical successful recruitment records), which results in the lack of accuracy of the recommendation. Therefore, a model on collaborative attention neural network was proposed for person-job fit (CoAttenFit), which mapped the numerical information of resumes through structured coding, generated semantic features with collaborative attention, extracted historical hiring features with graph neural networks, and finally calculated the matching degree between resumes and jobs through feature fusion. The method was compared with 8 current representative baseline methods and outperformed the baseline by 10%-27%, 6%-27%, 12%-20%, and 9%-17% in terms of accuracy, precision, recall, and F1 value, respectively. The experimental results illustrated that this method could effectively improve the accuracy of person-job matching, thus reducing resource and time consumption.

Keywords: person-job fit; collaborative attention; graph neural networks; text feature representation

收稿日期:2024-10-19

通信作者:李英玲(1984-),女,博士,副教授,研究方向:软件测试优化、智能软件工程.E-mail:liyiling@swun.edu.cn

基金项目:中央高校基本科研业务费专项资金优秀学生培养工程项目(2023NYXXS042)

由于在线招聘服务的出现,就业市场正在经历招聘实践的快速转变.人岗匹配是在线招聘的核心,即评估求职者与职位发布的匹配程度.由于其较高的实用价值,激发了越来越多的研究人员对人岗匹配研究的兴趣^[1-5].在这些研究中,一种典型的方法是将任务转换为有监督的文本匹配问题,其目的是根据职位发布和简历的文本内容计算匹配度.近年来,随着深度学习不同领域的广泛应用,端到端的神经网络被提出来理解语义表示以计算匹配度,包括基于 CNN 的模型^[6]、基于 RNN 的模型^[7]和结合 RNN 和 CNN 的模型^[8].尽管在人岗匹配方面取得了重大进展,现有方法仅聚焦于对目标简历和职位发布的文本语义信息进行建模,忽视了结构化数值信息和历史成功招聘经验的重要性.具体来说,简历和职位需求包括非结构化文本信息和结构化数值信息,其中非结构化信息是指没有固定格式的文本数据(例如简历自述和职位描述),结构化信息是指按照预定格式组织的数值数据(例如工作城市、工作年限).本文不仅考虑到非结构化文本的语义信息,也考虑到在简历和职位需求同等重要的结构化数值信息,能够提供更精确的匹配标准,提升匹配结果准确性.另一方面,历史成功的招聘记录可以说明哪些经历对于当前职位发布更重要,哪些能力要求更符合当前的简历,这些招聘人员的历史招聘经验,能够更好地支持人岗匹配.因此,本文对文本语义匹配和历史招聘经验进行建模,以提高人岗匹配的精度和准确率.

受到推荐系统中基于图神经网络(即 GNN)方法^[9]成功的启发,本文引入 GNN 用于提取招聘人员的经验,提出基于协同注意力的人岗匹配(CoAttenFit)方法.具体分为三个阶段:首先获得相关简历和职位招聘的非结构化文本信息和结构化数值信息;然后分别对不同信息进行嵌入和结构化编码,使用 BERT 和 BiLSTM 进行语义特征表示,用 GNN 捕获当前项目节点和相关历史项目节点之间的关系以提取历史招聘特征;最后基于注意力和全连接网络计算简历与职位之间的匹配度.

本研究成果为人岗匹配任务提供了新颖视角,贡献如下:①充分考虑到结构化数值信息,将其进行结构化编码映射,提供更精确的匹配标准.②通过将图神经网络引入到人岗匹配任务中对招聘人员的经验

(即历史成功招聘记录)进行建模,提取更全面的人岗特征关系.③在大规模的真实数据集上评估了本文所提出的模型,大量的实验结果证明了模型的 CoAttenFit 有效性.

1 相关工作

1.1 招聘研究

人岗匹配度重点关注提高雇主技能与工作要求之间的匹配程度,是招聘分析的一项引人注目的任务.随着网络招聘大数据的开源,越来越多的招聘分析研究任务应运而生.Wang 等人^[10]研究随时间的趋势,招聘市场何时向用户提出适当的工作推荐.Cheng 等人^[11-12]研究公司概况,以深入了解公司的基本特征.Hoang 等人^[13]分析了技术招聘和非技术招聘在岗位要求上的差异.Xu 等人^[1]提出了一种基于大规模招聘数据分析的数据驱动方法,用于对工作技能的流行度进行建模.

早期的人岗匹配研究,将其视为推荐问题.Malinowski 等人^[5]认为求职者和工作之间的匹配需要是双边的,并应用两种不同的推荐系统来提高匹配程度.遵循这个想法,Lee 等人^[2]引入了一个全面的工作推荐系统,供求职者找到他们感兴趣的工作.Paparrizos^[3]首先将该推荐问题建模为监督机器学习问题,并使用朴素贝叶斯混合分类器对其进行建模.Zhang 等人^[4]在求职推荐系统中添加不同的协同过滤算法,并在招聘网站上使用.Zhang 等人^[14]将广义线性混合模型应用到职位推荐系统中.

最近的研究开始从另一个角度分析人岗匹配任务.Zhu 等人^[6]将该任务视为分类问题,并提出了一种基于卷积神经网络(CNN)的简历和职位发布之间的文本语义匹配的端到端模型.遵循这个想法,Qin 等人^[7]继续应用 BiLSTM 和 Attention 机制代替 CNN,并获得了更好的结果.基于该模型,Bian 等人^[8]添加了结构对应学习(SCL)算法来解决不同工作类别数据不平衡的问题.MV-coN^[15]将基于文本和关系的匹配模型整合为一种统一的职位简历匹配方法,其中关系图是基于类别和关键词信息建立的.He 等人^[16]提出了一种端到端的人员工作拟合模型 MUFFIN,设计了一个学习每个领域特征之间潜在相关性的模块和一个基于多头自注意力和残差连接来学习交互的模块.

Li 等人^[17]提出了一种深度学习模型,将所有特征划分到不同的域并分别学习特征表示。

然而,仅仅依靠文本信息获取多维特征可能不够可靠。与以前的工作不同,本文提出的 CoAttenFit 同时考虑到结构化数值信息和历史成功招聘信息来指导当前的招聘,这是丰富简历和职位发布功能必要且可靠的信息。

1.2 文本挖掘研究

一般来说,基于文本信息的人岗匹配研究可以归为文本挖掘任务,与自然语言处理(NLP)技术高度相关,如文本分类^[9]、文本相似度^[18]和阅读理解^[19]。近年来,由于深度学习的先进性能和灵活性,越来越多的研究人员尝试利用深度学习来解决文本挖掘问题。与依赖于有效人为设计的表示和输入特征(例如,单词 n-gram、解析树和词汇特征^[20])的传统方法相比,基于深度学习的方法可以学习有效的、无须特征工程的大规模纹理数据模型。在各种深度学习模型中,卷积神经网络(CNN)^[21]和循环神经网络(RNN)^[22]是两种具有代表性且广泛使用的架构,它们可以从不同的角度为 NLP 问题提供有效的方法。具体来说,CNN 有效地提取文本数据中的局部语义和层次关系。例如,作为该领域的代表作之一,Kalchbrenner 等人^[23]提出了一种用于句子建模的动态卷积神经网络(DCNN),该网络在多项文本分类任务中取得了不俗的表现。从那时起,基于 CNN 的方法在许多 NLP 任务上引起了更多关注。例如,He 等人^[24]使用 CNN 从多个粒度级别提取语义特征来测量句子的相似度。董等人^[25]引入了多列 CNN 来解答问题。

基于以上工作,本文引入 BERT+BiLSTM^[26],从文档结构的多个抽象级别学习文档表示,并且能够处理长格式文档。与 LSTM 和 GRU^[27]相比,BERT+BiLSTM 通过不同结构层次的信息学习到整个文档更全面的语义表示。

2 基于协同注意力网络的人岗匹配模型

本文提出基于协同注意力网络的人岗匹配模型(如图 1 所示),该模型一共分为 3 个阶段:基于属性特征的数据划分、基于协同注意力的多模型特征表示、基于特征融合的人岗匹配推荐。具体过程如下:1)将数据集分为文本信息和数值信息,并进行非结构化

和结构化处理。2)将处理好的数据分别利用协同注意力生成语义特征表示,GNN 提取历史招聘特征表示。3)融合语义特征和历史招聘特征,采用注意力机制和基于全连接网络的比较机制来衡量职位发布与简历之间的匹配程度。

2.1 基于属性特征的数据划分

该阶段进行数据清洗和划分。将简历和职位信息划分为两类,分别是非结构化文本信息(例如工作经验、职位描述)和结构化数值信息(例如工作城市、工作年限),划分标准为字段属性特征。对于结构化数值信息,设计不同的结构化编码规则,将其编码为数值类型,例如,将教育程度(初中、中专)转化为数值(200、300),接着使用标准分布对数值编码进行归一化。

2.2 基于协同注意力的多模型特征表示

2.2.1 基于 Bert+BiLSTM 和协同注意力的语义特征表示

语义特征表示旨在计算职位发布和简历之间的语义相似度。本文选择 Bert+BiLSTM,能从文档结构的多个抽象级别学习文档表示并处理长格式文档。

在用 Bert+BiLSTM 嵌入非结构化文本后,连接结构化数值信息,计算每个职位与简历之间的匹配度。为了捕获职位发布和简历之间的语义相似性,采用协同注意力神经网络来量化每个简历对特定职位要求的匹配贡献。使用基于注意力的关系得分 $m_{l,k}$ 来量化每个职位要求 W_k 对每个候选简历 E_l 的匹配贡献,计算如下:

$$f_{l,k} = v_1^T \tanh(W_1 h_{e,l} + U_1 h_{w,k}). \quad (1)$$

$$m_{l,k} = \frac{\exp(f_{l,k})}{\sum_{k=1}^c \exp(f_{l,k})}. \quad (2)$$

$$h_l^w = \sum_{k=1}^c m_{l,k} h_{w,k}. \quad (3)$$

其中 $W_1 \in \mathbb{R}^{d \times d}$, $U_1 \in \mathbb{R}^{d \times d}$, $v_1 \in \mathbb{R}^{d \times 1}$ 是可训练参数, $h_{e,l} \in \mathbb{R}^d$ 和 $h_{w,k} \in \mathbb{R}^d$ 是 Bert+BiLSTM 嵌入后的输出,可以分别作为职位发布中第 l 个能力需求和简历中第 k 个经验的语义特征表示, $h_l^w \in \mathbb{R}^d$ 是学习到的职位需求的语义特征表示, d 是向量的维度。与关系得分 $m_{l,k}$ 类似,利用关系得分 $n_{k,l}$ 来量化每个简历 E_l 对每个职位要求 W_k 的匹配贡献,学习到简历经验的语义特征表示 h_k^e 。

得到学习到的语义特征表示后,添加另一个注意力层来分别学习职位需求 h_l^W 的每个表示和简历经验 h_k^E 的每个表示的重要性,即计算每个需求表示 h_l^W 的重要性 p_l 来生成最终的职位语义向量 $H^W_{semantic}$,如式(4)~(6)所示:

$$c_l^W = v_p^T \tanh(W_3 h_l^W + b_3). \quad (4)$$

$$p_l = \frac{\exp(c_l^W)}{\sum_{l=1}^n \exp(c_l^W)}. \quad (5)$$

$$H^W_{semantic} = \sum_{l=1}^n p_l h_l^W. \quad (6)$$

其中 $v_p^T \in \mathbb{R}^{d \times 1}$, $W_3 \in \mathbb{R}^{d \times d}$, $b_3 \in \mathbb{R}^d$ 是可训练参数. $H^W_{semantic} \in \mathbb{R}^d$ 是获得的职位发布的语义向量. 同样地,计算每个简历 h_k^E 的重要性 o_k 来生成简历语义向量 $H^E_{semantic}$.

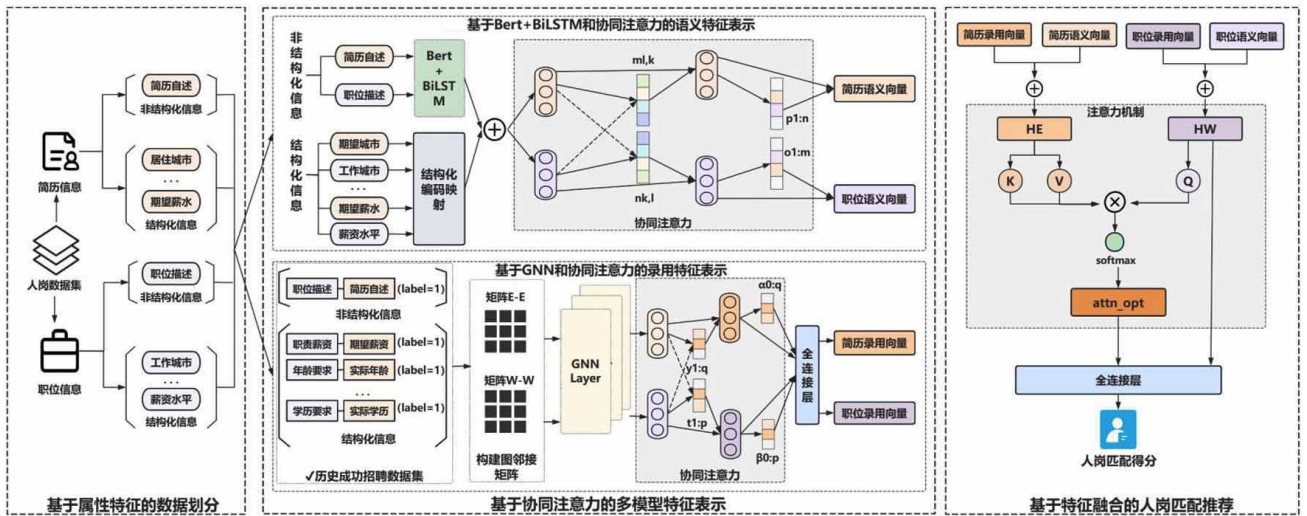


图 1 基于协同注意力的人岗匹配方法

Fig. 1 Collaborative attention neural network for person-job fit

2.2.2 基于 GNN 和协同注意力的历史招聘特征表示

本节对历史招聘人员的经验进行建模,利用历史招聘信息来指导当前的招聘.下面对构建图邻接矩阵、学习节点嵌入和招聘人员经验的建模细节进行说明.

①构建图邻接矩阵

对于每次招聘,构建两个无向图,分别命名为图 $W-W$ 和图 $E-E$.图 $W-W$ 中包含作为节点的历成功招聘职位发布和当前职位发布以及表示它们关系的边集.同样,图 $E-E$ 中包含历史成功招聘简历和当前简历作为节点以及它们关系的边集.

对于当前招募对 (W_c, E_c) , 构建图 $W-W$ 的第一步是查找与 W_c 相关的所有职位发布.搜索策略是找到一组招聘信息 W_r , 其中 $W_i \in W_r$ 满足条件 $(W_i, E_c, 1) \in A_s$. A_s 为历史成功招聘记录.搜索完成后,每个 $W_i \in W_r$ 都被标记为当前招聘信息 W_c 的相关招聘信息.第二步是计算边权重,为每个图构建邻接矩阵.考虑到 W_c 和相关职位发布 $[W_1, W_2 \dots W_q]$, 通过搜索策略

发现 W_c 为不同的单个节点,获得基于带有注意力机制的 BiLSTM 的表示,再使用余弦相似度函数,计算两个节点之间的相似度,用于构造邻接矩阵 L^W .

$$L^W[1][2] = \text{cosine}(\text{BiLSTM}(W_1), \text{BiLSTM}(W_2)). \quad (7)$$

其中 cosine 表示余弦相似度函数,计算图中每两个节点的边权重,这意味着构造的图是一个完全图.

②学习节点嵌入

构建图矩阵后,得到两个矩阵 L^W 和 L^E ,它们将图 $W-W$ 中的每个职位发布和图 $E-E$ 中的每个简历视为单个节点.节点表示通过 GNN 的更新函数学习如式(8)~(10)所示:

$$a_t^i = L_i([x_0^{t-1}, \dots, x_n^{t-1}]^T H^i + b^i). \quad (8)$$

$$\tilde{x}_t^i = \tanh(W_h^i a_t^i + M_h^i (r_t^i \odot x_t^{i-1})). \quad (9)$$

$$x_t^i = (1 - z_t^i) \odot x_t^{i-1} + z_t^i \odot \tilde{x}_t^i. \quad (10)$$

其中 $[x_0^i \dots x_n^i] \in \mathbb{R}^{d \times n}$ 为第 t 层当前标签图矩阵中的节点向量列表, $L_i \in \mathbb{R}^{1 \times n}$ 是对应于节点 i 的矩阵的第 i 行, $H^i, W_h^i, M_h^i \in \mathbb{R}^{d \times d}$ 和 $b^i \in \mathbb{R}^d$ 是要学习的参

数, $z' \in \mathbb{R}^d$ 和 $r' \in \mathbb{R}^d$ 分别是复位门和更新门, \odot 是逐元素乘法, $\sigma(\cdot)$ 是逻辑函数. 在这里构造了一个可训练的职位发布嵌入矩阵 $F^{GW} \in \mathbb{R}^{1 \times W \times d}$ 和简历嵌入矩阵 $F^{GE} \in \mathbb{R}^{1 \times E \times d}$, 节点的初始表示 (即 x^0) 是通过查找嵌入矩阵 H^{GW} 和 H^{GE} 获得的.

将两个矩阵输入各自的门控图神经网络后, 获得图 $W-W$ 和图 $E-E$ 中所有节点的表示, 分别表示为 x^W 和 x^E . 其中, x_0^W 和 x_0^E 分别表示输入的职位发布和简历的表示.

③ 招聘人员的经验建模

在获得图 $W-W$ 和图 $E-E$ 中的最终节点向量后, 进一步提取更多高级表示来对招聘人员的经验进行建模. 招聘人员清楚地知道自己成功通过的简历中, 哪些能力与本次招聘信息高度匹配, 以及招聘信息中的哪些要求与本次简历匹配度高, 本文将上面的两种招聘经验分别定义为关系 $W-E$ 和 $E-W$.

关系 $W-E$ 专注于增强候选人能力的建模. 首先, 应用 soft-attention 机制将职位发布 (即当前简历的历史成功招聘记录) 嵌入映射到图 $E-E$ 向量空间.

$$y_i = v_j^T \sigma(W_j x_i^W + c). \quad (11)$$

$$G_E = \sum_i y_i x_i^W. \quad (12)$$

其中 x_i^W 表示图 $W-W$ 中的每个节点向量, 参数 $v_j \in \mathbb{R}^{d \times 1}$ 和 $W_j \in \mathbb{R}^{d \times d}$ 表示可训练参数, $G_E \in \mathbb{R}^d$ 表示图 $E-E$ 向量空间中职位发布的表示, 它评估了招聘人员在过去成功招聘中所看重的杰出技能. 接着, 使用另一种注意力机制来估计每个职位发布与 G_E 之间的匹配程度.

$$f_t^E = v_\alpha^T \tanh(W_\alpha G_E + U_\alpha x_t^W). \quad (13)$$

$$\alpha_t = \frac{\exp(f_t^E)}{\sum_{i=0}^q \exp(f_i^E)}. \quad (14)$$

$$j^W = \sum_{i=0}^q \alpha_i x_i^W. \quad (15)$$

其中 $v_\alpha \in \mathbb{R}^{d \times 1}$, $W_\alpha \in \mathbb{R}^{d \times d}$ 和 $U_\alpha \in \mathbb{R}^{d \times d}$ 是训练过程中要学习的参数, 关注度 α 可以看作是职位发布中的要求与当前简历中的能力之间的匹配程度, j^W 表示关系 $W-E$ 的经验. 最后, 将图 $W-W$ 中的职位发布表示 x_0^W 与关系 $W-E$ 中的经验表示 j^W 连接起来, 并将输出视为职位的历史成功录用向量 H_{accept}^W .

$$H_{accept}^W = \tanh(W_w [x_0^W; j^W] + b_w). \quad (16)$$

与关系 $W-E$ 类似, $E-W$ 关系侧重于对招聘人员的个人偏好进行建模. 首先, 应用 soft-attention 机制将

简历的表示 (即当前职位发布的历史成功招聘记录) 嵌入映射到图 $W-W$ 向量空间. 其次, 使用另一种注意力机制来估计每份简历和 G_w 之间的匹配程度. 最后, 将图 $E-E$ 中 x_0^E 的简历表示与关系 $E-W$ 中 j^E 的经验表示连接起来, 并将输出视为当前简历的历史成功录用向量 H_{accept}^E .

2.3 基于特征融合的人岗匹配推荐

在得到语义向量 $H_{semantic}^W$, $H_{semantic}^E$ 和历史成功录用向量 H_{accept}^W , H_{accept}^E 后, 将语义和录用向量连接起来得到 H^W 和 H^E , 输入到注意力机制, 再应用基于全连接网络的比较机制来计算职位发布与简历之间的匹配度, 将全连接网络的输出 D 发送到逻辑函数中以获得预测标签 \tilde{y} .

$$attn_opt = \text{softmax} \left(\frac{\widehat{H}_W \widehat{H}_E^T}{\sqrt{d_k}} \right) H_E. \quad (17)$$

$$D = \tanh(W_d [H^W; attn_opt; H^W - attn_opt] + b_d). \quad (18)$$

$$\widehat{Y} = \sigma(W_y D + b_y). \quad (19)$$

其中 $W_d \in \mathbb{R}^{d \times 2 \times d}$, $b_d \in \mathbb{R}^d$, $W_y \in \mathbb{R}^{1 \times d \times 2}$, $b_y \in \mathbb{R}^1$ 是要学习的参数, $\tilde{Y} \in [0, 1]$ 为预测结果, $\sigma(\cdot)$ 是逻辑 sigmoid 函数. 本文为了优化模型, 采用整个训练数据的二元交叉熵损失作为总损失.

3 实验设置与结果分析

3.1 数据集准备和处理

本文在一个在线招聘公司提供的大型真实数据集上评估 CoAttenFit 模型. 数据集来源于中国在线招聘平台“智联招聘”, 并发布在参赛者众多的“天池”竞赛平台上. 为保护用户隐私, 所有涉及个人隐私的信息均已进行匿名化处理.

在该数据集中, 对于一个职位发布和一份简历的特定配对, 使用三个标签标记了两者的关系, 即“已浏览”“已投递”和“满意”. 标签“已浏览”表示用户是否在线浏览过该职位发布, 标签“已投递”表示用户是否已在线投递简历到该职位发布, 标签“满意”表示招聘人员是否认可该投递用户. 其中, “满意”是指求职者与公司就线下面试达成一致, 代表企业招聘人员对求职者简历的积极接收态度, 体现招聘人员的经验. 每个标签的值在 $\{0, 1\}$ 中选择, 1 表示是, 0 表示否. 本文

将“满意”的配对标记为成功,将那些标签为“已投递”但未标记为“满意”的配对标记为失败。

该数据集包含 4 465 份用户简历,269 534 个职位发布,总配对数为 6 971 621。其中标记为“满意”的有 31 696 对,标记为“已投递”的有 150 930 对,标记为“已浏览”的有 310 521 对。为了保证试验质量,将字数小于 15 的简历视为不完整的简历,将字数小于 50 的职位发布视为不完整的职位发布。删除那些不完整的简历和招聘信息,得到数据集统计信息见表 1。

表 1 数据集统计

Table 1 Statistics of the dataset

统计项	数量
职位发布数量	21 661
简历数量	2 437
成功匹配数量	12 112
失败匹配数量	38 354
每个职位文本平均字数	359
每个简历文本平均字数	53

从成功失败匹配数量来看,失败的记录远多于成功,这是典型的失衡情况。因此,随机选择一些失败记录,以保持与成功记录相同数量。最后将规范后的数据集分为文本信息和数值信息进行结构化和非结构化处理。

3.2 评价指标

本文参考相关文献,选取了常用的 4 个评价指标:准确率(Accuracy)、精准度(Precision)、召回率(Recall)和 F1。

1) 准确率

该评价指标是指分类模型正确预测的样本数量占总样本数量的比例。

2) 精确率

该评价指标是针对预测结果而言的,其含义是在被所有预测为正的样本中实际为正样本的概率。精确率代表对正样本结果的预测准确程度。

3) 召回率

该评价指标,也叫查全率,是覆盖面的度量。衡量了分类器对正例的识别能力。

4) F1 值

该评价指标是精确率(Precision)和召回率(Recall)的调和平均数。

3.3 基线方法

本文选择 8 个具代表性的监督模型作为基线方法,并将所提出模型 CoAttenFit 与这些基线方法进行比较,以验证模型的效果。

1) 基于深度学习的语义匹配模型 PJFNN^[6]: PJFNN 提出了一种二分卷积神经网络来有效学习简历和职位发布的联合表示。

2) 基于语言模型的匹配模型 BERT^[26]: BERT 是在语义相似度任务上进行微调的语言表示模型。将简历和职位发布看作两个序列,基于 $BERT_{BASE}$ 进行微调。

3) 基于序列处理与注意力的匹配模型 BPJFNN^[7]和 APJFNN^[7]: BPJFNN 是 APJFNN 的简化版本,它将简历和职位发布视为两个单独的序列,并应用 BiLSTM 来学习两个序列中每个单词的语义表示; APJFNN 将简历中的每条经历和职位发布中的每个要求视为一个序列,并应用基于 BPJFNN 的四种分层能力感知注意策略来学习职位要求 and 简历的词级语义表示。

4) 基于域适应与协同学习的匹配模型 SCLPJF^[8]和 MV-CoN^[15]: SCLPJF 利用 RNN 进行编码,对简历和职位发布表示之间的全局语义交互进行建模; MV-CoN 使用 GNN 来聚合每个节点的表示,提出协同教学机制,利用文本和关系降低训练数据中噪声的影响。

5) 基于自注意力的匹配模型 MUFFIN^[16]和 PJFFRIL^[17]: MUFFIN 提出了基于自注意力机制的多字段特征表示和交互学习模型,综合考虑了简历和职位的数值、类别和文本特征; PJFFRIL 将简历和职位信息分为多个域,利用多头自注意力机制学习简历和职位信息中的特征关联向量。利用特征交互模块促进域内和域外的特征交互,提取隐含的特征组合。

3.4 实验结果及分析

本章节首先将本文提出的方法从准确率、精确度、召回率和 F1 值 4 个方面,与基线方法在数据集上进行对比试验,验证 CoAttenFit 的性能;然后是消融实验,验证重要模块对方法性能的贡献。

3.4.1 对比实验

表 2 显示了 CoAttenFit 与 8 个基线方法的比较结果,表格中加粗的内容表示该类别的最佳性能。总体上来看,CoAttenFit 在所有评价指标上都取得了最好

的效果,达到了 85% 的 Accuracy、88% 的 Precision、85% 的 Recall 和 83% 的 F1.与 8 个基线方法相比 Accuracy 高出 10%~27%,Precision 高出 6%~27%,Recall 高出 12%~20%,F1 高出 9%~17%.与基线方法 PJFFRIL 相比,CoAttenFit 在 Accuracy, Precision, Recall 和 F1 上分别高出 10%、6%、15% 和 12%.这表明了本文提出的方法在人岗匹配方面的有效性.

与基于深度学习的语义匹配模型 PJFNN 比较,可以观察到 PJFNN 在四个指标上表现不佳,这是因为 PJFNN 使用卷积神经网络从长文档句子中获取语义特征,不足以捕获句子中的顺序信息.

将本文提出的模型与 BERT、APJFNN、BPJFNN、SCLPJF 和 MV-CoN 进行比较,结果表明本文的模型在四个指标上优于基线方法.这是因为这些方法只关注了当前职位和简历的文本信息,没有充分利用结构化数

值信息,忽略了简历和职位间数值化信息的关系.

值得注意的是,在基于自注意力的匹配模型 MUFFIN 和 PJFFRIL 中,利用了一些结构化信息,但未利用历史成功招聘信息.与上述基线不同的是,本文提出的方法同时使用结构化数值信息和历史成功招聘信息,提取更精确的语义信息和构建更全面的工作简历图,更加密集和可靠.

相较于所有基线方法,CoAttenFit 有两个主要优点:①CoAttenFit 不仅从文本语义信息中学习非结构化文本表示,而且考虑到结构化数值表示,提供更全面的匹配信息.②CoAttenFit 能够参考招聘人员的经验,通过引入 GNN,使用历史成功招聘经验来表示当前的简历和职位发布,利用注意力机制,有助于对招聘人员的偏好和候选人的能力进行建模.结果表明,本文的方法提高了“人岗匹配”任务的性能.

表 2 CoAttenFit 与基线方法结果统计

Table 2 Comparison of CoAttenFit and baseline performance

基线名称		Accuracy/%	Precision/%	Recall/%	F1/%
基于深度学习的语义匹配模型	PJFNN (2018)	0.69	0.69	0.70	0.69
基于语言模型的匹配模型	BERT (2018)	0.71	0.71	0.72	0.71
基于序列处理与注意力的匹配模型	BPJFNN (2018)	0.71	0.71	0.72	0.71
	APJFNN (2018)	0.74	0.74	0.75	0.74
基于域适应与协同学习的匹配模型	SCLPJF (2019)	0.71	0.71	0.72	0.72
	MV-CoN (2020)	0.75	0.77	0.71	0.74
基于自注意力的匹配模型	MUFFIN (2021)	0.74	0.80	0.73	0.70
	PJFFRIL (2023)	0.77	0.83	0.74	0.74
基于协同注意力的匹配模型	CoAttenFit	0.85	0.88	0.85	0.83

3.4.2 消融实验

为了验证 CoAttenFit 模型设计的有效性,本章节进行了消融实验.具体来说,本文创建了三个变体:①CoAttenFit (w/o GNN) 删除了录用招聘特征部分,仅使用语义信息特征部分,即无法获取图信息(即历史成功招聘信息).②CoAttenFit (w/o Attention) 删除了 GNN 部分的注意力.③CoAttenFit (w/o 数值) 删除了结构化数值信息.实验结果如表 3 所示,表格中加粗的数字表示该类别的最佳性能.

1) 总体来说,CoAttenFit 在 Accuracy, Precision, Recall 和 F1 指标上分别比 CoAttenFit (w/o GNN) 高出 14.8%、18.9%、16.4% 和 13.7%.结果证明了历史

成功招聘信息的重要性以及 GNN 模块的优越性.

2) CoAttenFit 在 Accuracy, Precision, Recall 和 F1 指标上分别比 CoAttenFit (w/o Attention) 高出 10.4%、14.3%、11.8% 和 7.8%.结果表明注意力策略可以更详细地捕获关键信息,并通过更好地估计匹配结果来提高性能.

3) CoAttenFit 在 Accuracy, Precision, Recall 和 F1 指标上分别比 CoAttenFit (w/o 数值) 高出 6.3%、10%、3.7% 和 2.5%.结果表明加入结构化数值能够提供精确的匹配标准,更详细地捕获关键信息,提升匹配结果准确性.

表 3 消融实验结果

Table 3 Performance of ablation experiment

实验名称	Accuracy/%	Precision/%	Recall/%	F1/%
CoAttenFit(w/o GNN)	0.74	0.74	0.73	0.73
CoAttenFit(w/o Attention)	0.77	0.77	0.76	0.77
CoAttenFit(w/o 数值)	0.80	0.80	0.82	0.81
CoAttenFit	0.85	0.88	0.85	0.83

4 总结

本文提出了一种基于协同注意力网络的人岗匹配方法 CoAttenFit, 不仅考虑上下文和结构化数值信息, 还利用历史成功招聘信息来计算职位发布和简历之间的匹配度. 具体来说, 给定目标简历职位对, 包括非结构化文本信息和结构化数值信息, CoAttenFit 首先基于 BERT+BiLSTM 生成语义特征表示, 同时基于图神经网络(GNN)生成历史招聘特征表示; 最后, 基于语义特征和历史招聘特征计算人岗匹配的匹配度. 为了验证所提出的 CoAttenFit 的性能, 在大规模招聘数据集上进行了广泛的实验, 与目前先进的基线相比, 结果验证了 CoAttenFit 的有效性.

未来, 计划结合更多的先验知识信息(例如知识图谱)来增强文本特征学习的能力. 另外, 设计更强大的图构建方法, 这可以减少对历史数据的依赖并包含更多语义信息.

参考文献

- [1] XU T, ZHU H S, ZHU C, et al. Measuring the popularity of job skills in recruitment market: A multi-criteria approach [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2018, 32(1): 2572-2579. DOI: <https://doi.org/10.1609/aaai.v32i1.11847>.
- [2] LEE D H, BRUSILOVSKY P. Fighting information overflow with personalized comprehensive information access: A proactive job recommender [C]//Third International Conference on Autonomic and Autonomous Systems(ICAS'07). Athens: IEEE, 2007: 21-21.
- [3] PAPARRIZOS I, CAMBAZOGLU B B, GIONIS A. Machine learned job recommendation [C]//Proceedings of the Fifth ACM Conference on Recommender Systems. Chicago Illinois: ACM, 2011: 325-328.
- [4] ZHANG Y Y, YANG C, NIU Z X. A research of job recommendation system based on collaborative filtering [C]//2014 Seventh International Symposium on Computational Intelligence and Design. Hangzhou: IEEE, 2014: 533-538.
- [5] MALINOWSKI J, KEIM T, WENDT O, et al. Matching people and jobs: A bilateral recommendation approach [C]//Proceedings of the 39th Annual Hawaii International Conference on System Sciences (HICSS'06). Kauai, HI: IEEE, 2006: 137c.
- [6] ZHU C, ZHU H S, XIONG H, et al. Person-job fit [J]. ACM Transactions on Management Information Systems, 2018, 9(3): 1-17.
- [7] QIN C, ZHU H S, XU T, et al. Enhancing person-job fit for talent recruitment: An ability-aware neural network approach [C]//The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. USA: ACM, 2018: 25-34.
- [8] BIAN S Q, ZHAO W X, SONG Y, et al. Domain adaptation for person-job fit with transferable deep global match network [C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). USA: ACL, 2019: 4809-4819.
- [9] YANG Y, PEDERSEN J O. A comparative study on feature selection in text categorization [C]//Icml, 1997: 35.
- [10] ZHU C, ZHU H S, XIONG H, et al. Recruitment market trend analysis with sequential latent variable models [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California: ACM, 2016: 383-392.
- [11] CHENG Y, XIE Y S, CHEN Z Z, et al. JobMiner: A real-time system for mining job-related patterns from social media [C]//Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Chicago Illinois: ACM, 2013: 1450-1453.
- [12] LIN H, ZHU H S, ZUO Y, et al. Collaborative company profiling: Insights from an employee's perspective [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2017, 31(1): 1417-1423.
- [13] HOANG P, MAHONEY T, JAVED F, et al. Large-scale occupational skills normalization for online recruitment [J]. AI Magazine, 2018, 39(1): 5-14.
- [14] ZHANG X X, ZHOU Y T, MA Y M, et al. GLMix: Generalized linear mixed models for large-scale response prediction [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco California: ACM, 2016: 363-372.
- [15] BIAN S Q, CHEN X, ZHAO W X, et al. Learning to match jobs with resumes from sparse interaction data using multi-view co-teaching network [C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. Virtual Event Ireland: ACM, 2020: 65-74.
- [16] HE M, SHEN D Y, WANG T, et al. Self-attentional multi-field features

- representation and interaction learning for person - job fit[J]. IEEE Transactions on Computational Social Systems, 2023, 10(1):255-268.
- [17] LI B, DING J, CHEN Z, et al. Multi-Domain Feature Representation, Multi-Dimensional Feature Interaction for Person-Job Fit[C]//SEKe. 2023:333-338.
- [18] SEVERYN A, MOSCHITTI A. Learning to rank short text pairs with convolutional deep neural networks[C]//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. Santiago: ACM, 2015:373-382.
- [19] BERANT J, SRIKUMAR V, CHEN P-C, et al. Modeling biological processes for reading comprehension[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar: ACL, 2014:1499-1510.
- [20] SIDA I W, CHRISTOPHER D. Manning. Baselines and Bigrams: Simple, Good Sentiment and Topic Classification[J]. Meeting of the Association for Computational Linguistics, 2012, 2:90-94.
- [21] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11):2278-2324.
- [22] ELMAN J. Finding structure in time[J]. Cognitive Science, 1990, 14(2):179-211.
- [23] KALCHBRENNER N, GREFFENSTETTE E, BLUNSON P. A convolutional neural network for modelling sentences[EB/OL]. arXiv preprint arXiv:1404.2188, 2014. <https://arxiv.org/abs/1404.2188v1>.
- [24] HE H, GIMPEL K, LIN J. Multi-perspective sentence similarity modeling with convolutional neural networks[C]//Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2015:1576-1586.
- [25] DONG L, WEI F R, ZHOU M, et al. Question answering over freebase with multi-column convolutional neural networks[C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Beijing: ACL, 2015:260-269.
- [26] KENTON J D M W C, TOUTANOVA L K. Bert: Pre-training of deep bidirectional transformers for language understanding[C]//Proceedings of naacL-HLT, 2019, 1:2.
- [27] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha: ACL, 2014:1724-1734.

(责任编辑:张阳,殷锋,付强,和力新,肖丽;英文编辑:周序林,郑玉才)