

融合键值表示与改进注意力机制的人岗匹配模型

啜子涵¹ 薛霞²
CHUO Zihan XUE Xia

摘要

人岗匹配 (person-job fit, PJF) 是在线招聘的核心, 用于智能匹配岗位与简历。大多数现有的 PJF 方法都将此任务看作是工作描述和简历中自由文本之间的匹配, 但忽略了半结构化多元属性的贡献, 导致预测失败。基于此, 文章提出了一种全面探索 PJF 中半结构化多元属性间复杂关系的模型 SIFT, 旨在有效匹配职位和简历。首先, 将每个属性的键和值以及来源都嵌入到相同的语义空间中; 随后, 使用 MSF 模块进行有效的特征融合, 并结合 Transformer 模型和 Talking-Heads Attention 以提升模型的鲁棒性和泛化能力; 最后, 使用匹配聚合层来预测匹配程度。该研究在真实数据集 (智联招聘数据集) 上验证了 SIFT 的有效性。实验结果表明, SIFT 模型在 AUC、准确性和 F_1 分数方面总体改进分别为 3.51%、3.72% 和 0.71%。

关键词

人岗匹配; 自然语言处理; 深度学习

doi: 10.3969/j.issn.1672-9528.2026.02.041

0 引言

近年来, 求职人数不断增长, 新兴招聘平台层出不穷, 海量的岗位与简历信息在网络上呈现爆炸式增长。求职者希

望通过智能手段找到与自身职业发展契合的岗位, 而招聘方则致力于筛选出与岗位要求高度匹配的人才。然而, 传统依赖人工筛选简历的方式, 不仅效率低、耗时费力, 而且容易受到主观偏见的影响, 严重制约了人力资源管理的智能化发展。因此, 如何从简历中精准挖掘求职者的能力, 并与岗位需求进行高效匹配, 成为亟待解决的关键问题, 即人岗匹配 (person-job fit, PJF) 任务。

1. 太原师范学院 山西晋中 030600
2. 运城学院 山西运城 044000
- [基金项目] 山西省基础 Research 计划资助项目 (202203021212174)

[6] HASAN M M, PANDEY A, RAJ A A B.UAV classification from micro-doppler signature-based time frequency images using SVM[C]// 2022 International Conference on Augmented Intelligence and Sustainable Systems (ICAISS). Piscataway: IEEE, 2022: 1225-1230.

[7] 陈翔, 汪连栋, 许雄, 等. 基于 Raw I/Q 和深度学习的射频指纹识别方法综述 [J]. 雷达学报, 2023, 12(1): 214-234.

[8] 刘鸿达, 孙旭辉, 李沂滨, 等. 基于卷积神经网络的图像分类深度学习模型综述 [J]. 计算机工程与应用, 2025, 61(11): 1-21.

[9] 俞宁宁, 毛盛健, 周成伟, 等. DroneRFa: 用于侦测低空无人机的大规模无人机射频信号数据集 [J]. 电子与信息学报, 2024, 46(4): 1147-1156.

[10] 李超群, 王金明. 基于短时傅里叶变换的无人机射频指纹分类识别 [J]. 通信技术, 2022, 55(9): 1202-1207.

[11] 程晓静, 牛慧莹. 基于时频图像的无人机信号检测识别算法研究 [J]. 信息技术, 2022(4): 170-174.

[12] 孟彩茹, 宋京, 孙明扬. 基于改进 CNN 与 SVM 的手势识

别研究 [J]. 现代电子技术, 2020, 43(22): 128-131.

[13] 李州, 汪繁荣. 基于 CNN-SVM 的变压器故障诊断方法 [J]. 现代电子技术, 2025, 48(6): 73-77.

【作者简介】

陈恩泽 (2004—), 男, 湖南常德人, 本科, 研究方向: 深度学习、信号处理。

罗保诚 (2004—), 男, 湖南怀化人, 本科, 研究方向: 信号处理、软件无线电。

黄琴 (2004—), 女, 湖南邵阳人, 本科, 研究方向: 深度学习。

李广选 (2001—), 男, 山东烟台人, 硕士研究生, 研究方向: 反无人信号侦测。

李立 (1983—), 女, 湖北武汉人, 本科, 职员, 研究方向: 数据分析处理。

(收稿日期: 2025-09-10 修回日期: 2026-02-03)

随着人工智能和自然语言处理（natural language processing, NLP）技术的快速发展，基于深度学习的自动化人岗匹配系统应运而生。自然语言处理通过对文本语义的建模和理解，能够挖掘简历与职位描述中的深层信息，为企业招聘决策提供智能支持。近年来，基于预训练语言模型（如 BERT）的文本匹配方法在多个 NLP 任务中取得了突破性成果，也被广泛引入到人岗匹配领域。

然而，当前主流的人岗匹配方法仍存在诸多不足。首先，它们多将匹配建模视为一个纯粹的文本匹配问题，侧重于职位描述与工作经验的自由文本比对，忽视了招聘信息与简历中的结构化或半结构化字段（如教育背景、工作城市、薪资期望等）；其次，现有方法大多采用简单拼接或加权平均的方式融合特征，无法充分捕捉多源属性间的语义交互；最后，传统多头注意力机制中，不同注意力头之间计算过程独立，难以实现更深层次的信息协同，从而限制了模型的表达能力。

为此，本文提出一种新的人岗匹配模型 SIFT（structured interaction fusion transformer），旨在更全面地融合职位与简历中的结构化多元属性信息，提升模型的匹配判别能力。该模型基于 BERT 提取不同字段的上下文语义表示，并引入以下两个关键模块：一方面，设计了一个轻量级的自适应语义融合模块（MSF），利用注意力机制自适应地融合每一对 key-value 字段表示，提升结构化特征建模的能力；另一方面，采用改进的 Talking-Heads Attention 机制，突破传统多头注意力头之间的信息孤岛，实现字段间更强的语义协同与交互建模。

本文的主要贡献如下：

（1）提出 SIFT 模型结构，结合结构化字段建模、多层语义交互与高阶注意力机制，有效提升人岗匹配的语义建模能力；

（2）设计 MSF 融合模块，对岗位与简历中的 key 和 value 字段进行动态融合；

（3）引入 Talking-Heads Attention，增强注意力表达力，实现字段级别的深度协同。

本研究期望为人岗匹配任务提供更加精确、智能的解决方案，并为招聘平台的智能化发展提供技术支撑。

1 相关工作

人岗匹配任务近年来受到学术界和工业界的广泛关注。传统方法多依赖于人工制定的匹配规则或关键词搜索策略，在面对语义复杂、结构多样的文本数据时，效果往往有限。为突破这一瓶颈，研究者开始引入 NLP 技术，通过深度建模

职位描述与简历内容之间的语义关系，从而提升匹配的自动化程度与决策的客观性。

在人岗匹配的理论基础方面，国外学者提出了人与职业匹配理论、人与组织匹配理论等多种匹配范式，为后续模型设计提供了方向。例如，Caldwell 等^[1]基于 Q 分类法提出了一种衡量个体与职位适配度的评估框架；Malinowski 等^[2]构建双向推荐系统以模拟招聘双方的匹配偏好；Paparrizos 等^[3]则基于职业履历轨迹预测用户的职业流动趋势。

早期国内研究以传统机器学习方法为主。杨月坤等^[4]指出大数据背景下人岗匹配的动态性与挑战性，强调了构建动态适配系统的重要性。李司航等^[5]提出了基于 RNN 的大学生能力偏差分析与岗位匹配方案，实现了智能能力提升路径设计。徐菲菲等^[6]则提出结合 Word2Vec 和 Arc-LSTM 的岗位文本分类方法，提升了匹配效率。

随着深度学习的发展，研究者开始构建端到端的匹配模型。朱瑜等^[7]提出 BATPJF 模型，结合 TextCNN 与 BiLSTM 提取文本多粒度特征，并引入注意力机制增强对重要信息的建模能力。Zhu 等^[8]设计的 PJFNN 模型通过双通道神经网络实现简历与岗位联合建模，在大规模真实招聘数据上表现优异。

在处理结构化与半结构化数据方面，常兵等^[9]提出特征修正与数据表示方案，并使用 XGBoost 构建匹配度分类器。刘琼雯等^[10]结合实体识别与加权余弦相似度，提出适用于小样本匹配任务的岗位模糊推荐算法。

BERT 模型的引入成为人岗匹配研究的重要转折。彭超云等^[11]基于 BERT 提出冷启动与热启动并行的人岗匹配推荐系统，提升了求职推荐系统对数据稀疏问题的适应能力。段雪艳等^[12]则结合 BERT 与 LightGBM 构建匹配模型，匹配精度达到 0.926，展现出预训练模型与集成学习融合的优势。

知识图谱同样在该领域发挥了重要作用。张明星等^[13]提出基于知识图谱的人岗匹配方法，将岗位与求职者信息构建为图结构并进行嵌入学习，有效提升了推荐精度。王磊等^[14]提出结合概率语言 ORESTE 模型的人岗匹配决策方法，通过主客观权重融合实现排序优化与匹配意愿建模。

图表示学习进一步拓展了匹配模型的表达能力。Yang 等^[15]提出 DPGNN 模型，利用双视角图表示与对比学习建模求职者与岗位之间的双向互动。Wang 等^[16]开发的 PJF-CANN 模型结合共注意力机制与图神经网络，引入历史招聘信息以提升匹配准确性与鲁棒性。面对招聘样本不均衡问题，刘付谦等^[17]提出结合 SMOTE 与贝叶斯优化的 Adj-LightGBM 模型，在样本不平衡背景下取得了 F_1 -score 0.974 的优异效果。

在人岗偏好建模方面，Qin 等^[18]提出 APJFNN 模型，通过多层次能力感知注意力机制，捕捉不同求职经历对岗位需求的贡献，显著增强了模型的可解释性与泛化能力。

此外，李浩等^[19]提出结合特征匹配与文本相似度的简约算法，适用于实际招聘平台的低标签场景；武国斌等^[20]则构建岗位信息标签体系并基于图采样的 LSTM 网络实现岗位推荐，提升了人力资源数据组织与管理能力。

综上所述，人岗匹配研究已从规则驱动向数据驱动、从浅层匹配向深层语义建模演进。未来研究应进一步融合结构化知识与上下文建模能力，引入图神经网络、多任务学习与强化学习机制，推动人岗匹配系统向高效、精准与智能化发展。

2 方法

2.1 问题定义

本研究中关注的任务是预测招聘者发布的职位信息与求职者简历之间的匹配程度，即“人岗匹配”问题。该问题可以形式化为一个典型的监督学习任务，目标是根据已有的职位与简历匹配数据，训练一个模型来预测未来样本的匹配可能性。一般而言，人岗匹配数据由三部分组成：职位信息（Job）、简历信息（Resume）以及匹配标签（Match Label）。职位信息通常包含职位名称、工作城市、薪资水平等多个结构化属性字段；简历信息则包括求职者的基本信息、教育背景、工作经历、技能标签等多元属性。

为便于建模，用 J 表示一条岗位招聘信息，用 R 表示一

位候选人的简历，用公式表示为：

$$\begin{aligned} J &= \{j_1, j_2, \dots, j_i\} \\ R &= \{r_1, r_2, \dots, r_i\} \end{aligned} \quad (1)$$

式中： j_i ($i \in [1, n]$) 表示该岗位招聘信息中的第 i 条属性； r_i ($i \in [1, n]$) 则表示简历中第 i 条属性。

每个样本三元组表示为 $S = \langle J, R, Y \rangle$ ，其中 $Y \in \{0, 1\}$ 为匹配标签（是否匹配）。

本文基于上述数据结构，设计了一个结构感知的人岗匹配模型，从字段级别建模岗位与简历之间的语义关系，并准确预测两者的匹配结果。

2.2 模型概述

为精准建模岗位信息与简历之间的结构化语义关联，本文提出了一种结构感知的人岗匹配模型——SIFT。SIFT 模型结合了多字段嵌入表示、自适应特征融合机制（MSF）^[21]与改进注意力机制（Talking-Heads Attention）^[22]，以实现从字段级信息提取到全局语义交互的多层次建模，整体结构如图 1 所示。

2.2.1 字段建模与语义嵌入

在简历和职位描述中，每一条信息均可拆解为三元结构：属性名称（key）、属性值（value）、来源（source）。为实现统一建模，本文将每个字段形式化为：

$$\langle \text{key}, \text{value}, \text{source} \rangle \quad (2)$$

使用 BERT 模型对岗位和简历中的每个字段子部分进行编码，得到其语义向量表示：




图 1 SIFT 模型概述图

$$\begin{aligned}
j_i^k &= \text{BERT}(j_i^k) \\
j_i^v &= \text{BERT}(j_i^v) \\
r_i^k &= \text{BERT}(r_i^k) \\
r_i^v &= \text{BERT}(r_i^v) \\
j^s &= \text{BERT}(j^s) \\
r^s &= \text{BERT}(r^s)
\end{aligned} \quad (3)$$

式中： j_i^k 表示岗位信息中第 i 个字段的键（key）经 BERT 编码后的向量； j_i^v 表示该字段的值（value）； j^s 表示其来源为“岗位”； r_i^k 、 r_i^v 、 r^s 分别表示对应简历信息的相应部分。

通过这种方式，所有子部分被映射到统一语义空间中，为后续融合与交互建模打下基础。随后，通过自适应平均池化（AdaptiveAvgPool）操作将其转换为定长向量表示，统一维度。

2.2.2 自适应特征融合模块

为增强字段内部不同语义子部分的协同建模能力，SIFT 引入了轻量级的 MSF（multi-scale selective fusion）模块。该模块用于动态加权融合 key 和 value 两部分信息，核心思想是根据全局特征重要性自动调整其权重。

首先对 key 和 value 执行通道维度上的全局平均池化（GAP）：

$$\mathbf{w}_1 = \text{GAP}(\text{keys}^\top), \mathbf{w}_2 = \text{GAP}(\text{values}^\top) \quad (4)$$

GAP 操作会将每个通道的所有时序特征进行平均，得到代表该通道全局统计特征的向量 $\mathbf{w}_1$ 、 $\mathbf{w}_2$ 。将 GAP 得到的向量分别输入线性层并激活，获得通道注意力权重：

$$\mathbf{w}_1' = \sigma(\mathbf{W}_1 \cdot \mathbf{w}_1), \mathbf{w}_2' = \sigma(\mathbf{W}_2 \cdot \mathbf{w}_2) \quad (5)$$

式中： $\mathbf{W}_1$ 、 $\mathbf{W}_2$ 表示可学习参数矩阵； σ 表示 Sigmoid 函数，确保权重落在 $[0,1]$ 区间。该步骤学习每个通道在 key 和 value 中的重要性。为确保 key 与 value 的权重之和为 1，执行 Softmax：

$$\text{weights} = \text{Softmax}([\mathbf{w}_1', \mathbf{w}_2']) \quad (6)$$

此步骤将注意力权重标准化，确保不同来源的信息可比较、可加权组合。最终使用归一化权重对 key 和 value 的原始特征加权求和，生成融合字段：

$$f = \mathbf{w}_1^{\text{norm}} \cdot \text{keys} + \mathbf{w}_2^{\text{norm}} \cdot \text{values} \quad (7)$$

式中： $\mathbf{w}_1^{\text{norm}}$ 、 $\mathbf{w}_2^{\text{norm}}$ 分别为归一化后的通道权重，作用于 key 和 value 的表示。此融合方式不仅整合了多源信息，还实现了可学习的注意力分配，提升了字段表达的灵活性与语义密度。

2.2.3 语义交互建模

为了进一步建模字段之间及岗位与简历之间的语义关系，SIFT 采用双阶段 Transformer 架构。第一阶段进行字

段内编码。岗位字段序列 $J = \{j_1, j_2, \dots, j_i\}$ 与简历字段序列 $R = \{r_1, r_2, \dots, r_i\}$ 分别输入多层 Transformer Encoder 进行局部语义建模。每层编码器采用 Talking-Head Attention 替代标准多头注意力机制，其核心操作为：

$$\text{Attn}_{\text{talk}} = \mathbf{P}_w(\text{Softmax}(\mathbf{P}_l(\frac{\mathbf{Q}\mathbf{K}^\top}{\sqrt{d_k}}))) \quad (8)$$

式中： $\mathbf{Q}$ 、 $\mathbf{K}$ 为查询和键向量； $\mathbf{P}_l$ 、 $\mathbf{P}_w$ 分别为注意力 logits 与权重的可学习线性投影矩阵； d_k 为每个头的维度；Softmax 用于归一化注意力分数。该机制允许注意力头之间进行信息交互，解决传统多头注意力中“头之间相互独立”的问题，提升语义整合能力。

第二阶段为跨文档字段交互。岗位字段序列与简历字段序列拼接为一个整体序列 $[J;R][J;R]$ ，再输入另一个多层 Transformer Encoder。该阶段重点建模岗位字段与简历字段之间的交叉语义依赖（如“技能匹配”或“地点一致性”），从而捕捉多对多字段之间的语义对齐关系。

2.2.4 匹配度预测

通过上述交互建模后，模型分别对岗位和简历字段序列进行池化操作，获得整体向量表示：

$$\mathbf{v}_J = \text{AvgPool}(J), \mathbf{v}_R = \text{AvgPool}(R) \quad (9)$$

为了综合考虑岗位与简历之间的共性与差异性，构造最终输入向量：

$$\mathbf{x} = [\mathbf{v}_J; \mathbf{v}_R; \mathbf{v}_J - \mathbf{v}_R] \quad (10)$$

该向量被送入一个包含两层线性变换的多层感知机（MLP），并通过 Sigmoid 激活函数输出匹配概率：

$$\hat{y} = \sigma(\text{MLP}(\mathbf{x})) \quad (11)$$

式中： $\hat{y} \in [0,1]$ 表示岗位与简历的匹配程度。

3 实验结果与分析

3.1 数据集描述

为验证 SIFT 模型的有效性，实验使用智联招聘平台提供的公开可用数据集。为保护用户隐私，所有简历都做了脱敏处理，删除了姓名、性别、地址等身份属性。处理后的数据集统计汇总情况如表 1 所示，原始数据集包含 4 500 份简历、269 534 份招聘信息和 700 938 条申请记录。首先通过删除属性不完整的职位和简历数据来清洗数据。对于收集到的职位和简历历史交互行为，可以很清楚地看到成功招聘的实例远少于招聘失败的实例，将招聘成功的实例称为正实例，将招聘失败的实例则称为负实例。为了减少正负实例不均衡的问题，随机抽取与正实例相同数量的负实例来进行实验。然后，将数据集按 8:1:1 划分为训练集、测试集和验证集。

表 1 数据统计表

统计数据	值
简历	4 500
招聘信息	269 534
交互信息	700 938
正实例	28 595
负实例	619 578

3.2 实验描述

本文抽取与正实例数量相同的负实例对模型进行训练。以下是实验中的一些基础设置：

batch_size 设置为 64，epoch 设置为 20。训练集和测试集按照 8:2 划分，若验证集上的评估结果连续 5 个 epoch 没有增加，训练将提前停止。为了尽可能地避免过拟合现象的发生，采用层归一化和梯度裁剪机制。将 drop_out 设置为 0.5，并选择 Softmax 作为激活函数，以提高模型的非线性表达能力并加速模型收敛速度。为了更好地学习模型参数，选择 Adam 作为优化器进行训练，学习速率设置为 2×10^{-5} 。

3.3 实验结果

为验证本文提出的 SIFT 模型性能，将其与 PJFNN、BPJFNN、APJFNN、SBERT-UT、BATPJF、INEXIT 模型进行比较，将人岗匹配任务视为一个二分类问题，一般来说，预测阈值默认设置为 0.5，如果样本的预测匹配度超过 0.5，则可以将其视作正样本，即当前的工作与简历匹配；如果样本的预测匹配度小于 0.5，则可以将其视作负样本，即当前的工作与简历不匹配。评价指标主要采用常用的分类指标，如准确率（ACC）、精度、召回率和 F_1 分数，来综合判断模型的性能。此外，在现实的招聘过程中，招聘方通常会决定一个潜在的阈值，从推荐的求职者中筛选合格的求职者，这个阈值与专业经验和个人偏好相关。因此，本文也使用 AUC 分数来评价模型在不同情况下的性能。实验结果如表 2 所示。

表 2 实验结果

模型	AUC	ACC	PRE	REC	F_1
PJFNN	0.682 5	0.636 5	0.639 9	0.636 1	0.638 0
BPJFNN	0.709 6	0.657 1	0.660 9	0.655 2	0.658 1
APJFNN	0.651 2	0.636 1	0.549 4	0.346 5	0.514 5
SBERT-UT	0.621 2	0.586 4	0.536 4	0.497 3	0.461 2
BATPJF	0.689 4	0.643 1	0.119 8	0.583 6	0.294 6
INEXIT	0.754 8	0.695 9	0.705 1	0.680 9	0.692 8
SIFT	0.789 9	0.733 1	0.732 4	0.670 1	0.699 9

由表 2 可知，本文提出的模型相比参照模型中最好的模型 INEXIT 在指标 AUC 和 ACC 上分别提高了 3.51% 和 3.72%。

由此可见，SIFT 模型能充分发挥 BERT 提取局部特征的优点与 MSF 模块动态加权融合的特点，且 Talking-Heads Attention 注意力机制的加入，可以计算工作要求对不同工作经验的重要性以及工作经验对不同工作要求的贡献，因此性能优于其他对比模型。

3.4 消融实验

为评估 SIFT 各模块对分类性能的贡献，本文设计了一系列消融实验，逐步替换关键模块，并将其性能与完整的 SIFT 模型进行比较。本实验主要考虑 3 种融合策略，即加法、拼接以及 SIFT 方法中的 MSF，配合 Transformer 自身的多头注意力机制或者其改良的 Talking-Heads Attention 在提升模型性能方面的作用。

在消融实验中，首先使用三种特征融合方式分别配合多头注意力机制，以评估这两个模块的整体贡献。实验结果显示，使用加法特征融合方式的分类准确率由 72.86% 下降至 69.59%，而使用拼接特征融合方式的准确率也降低了，表明在融合属性语义方面，添加融合操作比连接操作更有效。随后，在不同的特征融合策略中引入 Talking-Heads Attention，以测试该注意力机制在模型的表达能力，分类准确率均有提升，说明该注意力机制有效提高了模型的性能。实验结果如表 3 所示，显然，当将 SIFT 替换任何组件时，整体模型性能通常会下降。特别是，当从 SIFT 中替换掉融合策略时，模型最显著的性能下降。这表明，MSF 融合策略相比于其他特征融合策略更有效。

表 3 消融实验

		单位：%				
注意力机制	融合机制	AUC	ACC	PRE	REC	F_1
Multi-Head Attention	相加	75.48	69.59	70.51	68.09	69.28
	拼接	75.13	69.14	71.27	64.86	67.91
	MSF	77.99	72.61	73.85	63.50	68.29
Talking- Heads Attention	相加	78.78	72.86	74.83	62.62	68.18
	拼接	78.84	72.73	75.53	61.06	67.53
	MSF	78.99	73.31	73.24	67.01	69.99

综上，实验验证了 SIFT 各模块的必要性及其对模型性能的贡献。意味着本文提出的 SIFT 模型可以很好地利用半结构化的多元属性，对招聘服务中的职位与简历进行综合匹配。

4 结论

本文针对人岗匹配问题提出了一种基于自然语言处理的人岗匹配模型 SIFT。模型首先通过预训练语言模型 BERT 将简历和职位信息半结构化多元属性的键、值及其来源进行编码，并利用 MSF 模块融合各个子属性。接着，构建了一个分

层的 Transformer 结构,使用改进的 Talking-Heads Attention 对简历和岗位进行文档间和跨文档的信息交互建模。最后,采用聚合匹配层来度量匹配度。通过与其他模型进行对比,证明了本文模型 SIFT 的有效性。由于人岗匹配领域可用的半结构化数据稀缺,该方法只在一个数据集上进行了实验验证。因此,对于之后的工作,可以考虑使用未标记的数据进行自监督或无监督人岗匹配,帮助推动人岗匹配的发展。

参考文献:

- [1] CALDWELL D F, O'REILLY III C A. Measuring person-job fit with a profile-comparison process[J]. Journal of applied psychology, 1990, 75(6): 648-657.
- [2] MALINOWSKI J, KEIM T, WENDT O, et al. Matching people and jobs: a bilateral recommendation approach[C//OL]. Proceedings of the 39th Annual Hawaii International Conference on System Sciences (HICSS'06). Piscataway: IEEE, 2006[2025-12-30]. <https://ieeexplore.ieee.org/document/1579569>. DOI: 10.1109/HICSS.2006.266.
- [3] PAPARRIZOS I, BARLA CAMBAZOGLU B, GIONIS A. Machine learned job recommendation[C//RecSys'11: Proceedings of the fifth ACM conference on Recommender system. New York: ACM, 2011: 325 - 328.
- [4] 杨月坤, 蒋忠惠. 大数据技术在人岗匹配中的实践与挑战[J]. 领导科学, 2016(27): 53-54.
- [5] 李司航, 季波, 王永盛, 等. 基于深度学习的大学生求职能力与岗位匹配的设计[J]. 电脑知识与技术, 2021, 17(20): 186-187.
- [6] 徐菲菲, 许赞杰. 基于 Arc-LSTM 的人职匹配研究[J]. 山东大学学报(理学版), 2021, 56(1): 83-90.
- [7] 朱瑜, 魏嘉银, 卢友军, 等. 基于深度学习的端到端人岗匹配模型[J]. 智能计算机与应用, 2023, 13(4): 47-51.
- [8] ZHU C, ZHU H S, XIONG H, et al. Person-job fit: adapting the right talent for the right job with joint representation learning[J]. ACM transactions on management information systems (TMIS), 2018, 9(3): 1-17.
- [9] 常兵, 褚志海, 印忠文, 等. 数据表示和特征修正在人岗匹配研究中的应用[J]. 计算机时代, 2022(4): 9-12.
- [10] 刘琼雯, 林川. 面向小样本的岗位模糊匹配推荐算法[J]. 电子设计工程, 2023, 31(14): 51-56.
- [11] 彭超云, 姚渺波, 曾东晨. 基于 BERT 模型的人岗匹配混合推荐系统研究[J]. 信息记录材料, 2025, 26(4): 236-238.
- [12] 段雪艳, 吕卫东, 冯俊磊, 等. 基于 BERT 与 LightGBM 的人岗匹配模型[J]. 计算机科学与应用, 2025, 15(1): 46-53.
- [13] 张明星, 张骁雄, 李明浩, 等. 基于知识图谱的人岗匹配模型设计与研究[C//第五届体系工程学术会议论文集. 长沙: 国防科技大学系统工程学院, 2023.
- [14] 王磊, 李文杰, 王海. 改进概率语言 ORESTE 的人岗匹配决策方法[J]. 计算机工程, 2024, 50(12): 407-416.
- [15] YANG C, HOU Y P, SONG Y, et al. Modeling two-way selection preference for person-job fit[C//RecSys '22: Proceedings of the 16th ACM Conference on Recommender Systems. New York: ACM, 2022: 102-112.
- [16] WANG Z Y, WEI W, XU C W, et al. Person-job fit estimation from candidate profile and related recruitment history with co-attention neural networks[J]. Neurocomputing, 2022, 501: 14-24.
- [17] 刘付谦, 秦华妮, 赖惠慧. 基于 SMOTE 和贝叶斯优化的 Adj-LightGBM 人岗匹配算法[J]. 计算机与现代化, 2023(3): 90-95.
- [18] QIN C, ZHU H S, XU T, et al. Enhancing person-job fit for talent recruitment: an ability-aware neural network approach[C//SIGIR '18: The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York: ACM, 2018: 25-34.
- [19] 李浩, 郭嘉莉, 梁艳, 等. 网络招聘的人岗匹配度算法研究[J]. 电脑与信息技术, 2024, 32(4): 19-22.
- [20] 武国斌, 张之明, 杨文欣. 基于信息标签体系的人员岗位匹配方法研究[J]. 网络安全与数据治理, 2024, 43(9): 41-48.
- [21] XIE L Y, LI C, WANG Z R, et al. SHISRCNet: Super-resolution and classification network for low-resolution breast cancer histopathology image[EB/OL]. (2023-06-25)[2025-12-30]. <https://doi.org/10.48550/arXiv.2306.14119>.
- [22] SHAZEER N, LAN Z Z, CHENG Y L, et al. Talking-heads attention[EB/OL]. (2020-03-05)[2025-12-30]. <https://doi.org/10.48550/arXiv.2003.02436>.

【作者简介】

啜子涵(2000—), 女, 山西太原人, 硕士研究生, 研究方向: 自然语言处理, email: zhchuai@163.com。

薛霞(1985—), 女, 陕西西安人, 博士, 副教授、硕士生导师, 研究方向: 人才计算、自然语言处理。

(收稿日期: 2025-07-14 修回日期: 2026-01-28)