

一种基于知识图谱和联合自然语言模型的知识问答方法

殷丽凤, 郭运昌

大连交通大学 轨道智能工程学院, 辽宁 大连 116028

DOI: 10.61369/TACS.2025050012

摘要 : 针对智能问答系统中用户意图识别准确率不足及旅游领域知识图谱资源匮乏的问题, 提出了一种基于大连市红色旅游知识图谱与 ERNIE-BILSTM-CRF 联合模型的知识问答系统。系统构建了涵盖城市、地区、景区、旧址、背景、意义及门票价格七类节点的红色旅游知识图谱, 利用 Neo4j 图数据库实现数据的结构化存储与可视化查询。为提升语义理解能力, 创新性地将百度预训练语言模型 ERNIE 与双向长短时记忆网络 (BILSTM)、条件随机场 (CRF) 相结合, 构建联合模型用于命名实体识别, 显著提高了关键实体和意图的识别准确率。实验基于 5000 条大连红色旅游问答数据集, 结果显示 ERNIE-BILSTM-CRF 模型在精确率、召回率及 F1 值上分别达到 98.99%、99.75% 和 98.91%, 优于多种对比模型, 验证了模型的有效性和鲁棒性。节点类型测试进一步表明系统对不同类别实体均具备较高识别能力。本文丰富了旅游领域知识图谱资源, 并为智能问答系统的自然语言理解与知识检索提供了新思路, 推动了旅游信息智能化服务。

关键词 : 知识图谱; ERNIE; 双向长短期记忆网络; 条件随机场; 联合自然语言模型

A Knowledge Question-Answering Method Based on Knowledge Graph and Joint Natural Language Models

Yin Lifeng, Guo Yunchang

(School of Intelligent Rail Transit, Dalian Jiaotong University, Dalian, Liaoning 116028)

Abstract : In response to the issues of insufficient accuracy in user intent recognition within intelligent question-answering systems and the lack of knowledge graph resources in the tourism domain, we propose a knowledge question-answering system based on a knowledge graph of red tourism in Dalian and a joint model of ERNIE-BILSTM-CRF. The system constructs a red tourism knowledge graph that encompasses seven types of nodes: city, region, scenic spot, historical site, background, significance, and ticket price. Data is structurally stored and visually queried using the Neo4j graph database. To enhance semantic understanding capabilities, we innovatively combine the Baidu pre-trained language model ERNIE with Bidirectional Long Short-Term Memory (BILSTM) and Conditional Random Fields (CRF) to build a joint model for named entity recognition, significantly improving the accuracy of identifying key entities and user intents. Experiments were conducted using a dataset of 5,000 Q&A pairs related to red tourism in Dalian, with results showing that the ERNIE-BILSTM-CRF model achieved precision, recall, and F1 scores of 98.99%, 99.75%, and 98.91%, respectively, outperforming various comparative models and validating the effectiveness and robustness of the model. Further testing of node types indicates that the system possesses a high recognition ability across different categories of entities. This paper enriches the knowledge graph resources in the tourism domain and offers new insights for natural language understanding and knowledge retrieval in intelligent question-answering systems, promoting the intelligent service of tourism information.

Keywords : knowledge graph; ERNIE; bidirectional long short-term memory; conditional random field; joint natural language model

智能问答系统是人工智能领域的重要应用之一, 其中一个关键技术是问题理解技术。由于用户提问通常以自然语言形式呈现, 如何将其转化为机器可理解的语言, 成为问答系统面临的核心挑战。当前多数智能问答系统依赖基于模板匹配的知识库实现意图识别, 该方

基金项目 : 大连市社科项目 (2024dlsky095) 的资助。

作者简介 :

殷丽凤 (1976—), 女, 黑龙江海伦人, 博士, 副教授, 硕士生导师, CCF 会员, 主要从事机器学习算法和深度学习算法的优化及应用的研究, 通讯邮箱: yinlifeng1030@djtu.edu.cn;
郭运昌 (2001—), 男, 硕士研究生, 主要从事深度学习、知识图谱领域的研究。

法存在两大局限性：（1）模板设计依赖专家经验，导致开发成本高昂；（2）模板仅适配特定句式，缺乏普适性与灵活性。因此，如何让机器理解自然语言，不仅是问答系统面临的难题，也是人工智能领域亟需攻克的挑战。针对问答系统中模型理解能力不足的问题，大语言模型^[1](Large Language Models, LLM)的引入开辟了新的研究前景。这些模型经过广泛的预训练^[2]，展现了强大的语言理解和泛化能力，有望提升语义解析的准确性。

智能问答系统的另一个关键技术是建立知识库。2012年，Google提出了知识图谱^[3]的概念，尽管近年来基于领域的知识图谱快速发展，但目前主要集中在医学、工业和器械等领域。相比之下，旅游领域的知识图谱相对较少。然而，随着旅游业的蓬勃发展，公众对旅游信息的需求日益增加^[4]。传统的旅游信息获取方式，如口碑传播或依赖专业导游，往往存在信息准确性不足、真实性难以保证以及成本较高等问题。因此，如何整合官方网站上的旅游信息，并提供便捷、可靠的查询途径，已成为业内亟待解决的重要挑战。

一、相关研究

近年来，领域知识图谱技术得到了迅猛发展。知识图谱作为一种结构化的知识表示手段，致力于以图形化的形式呈现并存储丰富的知识内容，以解决信息检索^[5]、智能推荐^[6]、问答系统^[7]等问题。目前中文领域的知识图谱有Zhishi.me^[8]、Zhishi.schema^[9]和XLore^[10]等。除上述的大规模知识图谱之外，还有不少领域内的研发人员也正在着力研发自己专业的知识图谱，比如，影视领域的IMDB^[11]、生物医药领域的BMKN^[12]、资讯领域的ECKG^[13]、保健领域的SHKG^[14]等等。

不同于其他数据库，知识图谱能够体现出数据与数据之间的关系，该技术为问答系统提供了新的研究思路：让机器理解人类的语言，将人类的问题解析后，在知识图谱中通过与问题相关的关系寻找答案。不过目前让机器理解人类语言是一个相当艰难的事情，这不仅是问答系统中必须克服的问题，同时也是自然语言处理领域中必须克服的困难。而要想在图谱中获得精确的答案，对用户问题要能准确的识别，这就需要使用大语言模型来解决智能问答^[15]、文本理解^[16]等问题。如Bordes^[17]等人直接将问句和最终的答案做匹配、王子岳^[18]等人用S-LSTM模型解决整体语义的理解等。在旅游领域，王博^[19]等研究人员巧妙地融合了知识图谱与BERT-BIGRU-CRF模型，成功构建了西藏旅游问答系统，这一举措将先进的大语言模型与知识图谱技术相得益彰。鄢晗晖^[20]等人采用了知识图谱与BERT-BILSTM-CRF模型，打造了澳大利亚旅游问答系统，并通过实际应用验证了该模型相较于传统方法所展现出的卓越性能。

然而，BERT模型在实际应用中存在两大挑战：一是其在中文任务中的准确率较英文任务低约5%–10%；二是可能生成“有害幻觉事实”^{[21][22]}。自百度推出ERNIE(Enhanced Representation through Knowledge Integration)模型后，凭借其在中文领域的显著优势，罗琳凡^[23]等研究者借助知识图谱与ERNIE-CRF模型，开发了山东省旅游问答系统，有效弥补了BERT模型在中文语言处理方面的局限性。张峻菖^[24]等研究者借助知识图谱与ERNIE-BIGRU-CRF模型，构建了山西旅游问答系统，进一步提高了识别的准确率。

以上研究表明知识图谱与大语言模型的结合为智能问答系统带来了新的机遇，但仍需克服多方面的挑战，以实现更高效、更准确的问答服务。本文旨在解决这些问题，通过构建大连市红色旅游知识图谱，并开发基于ERNIE-BILSTM-CRF联合模型的问答系统，重点改进用户意图识别准确性和问答系统性能。本文提出的联合模型在旅游领域问答系统中实现了两项创新性突破^[25]：

（1）通过ERNIE的多层次语义理解能力，解决了旅游领域实体名称多样性和口语化表达的识别难题（如‘关向应故居’与‘关向应纪念馆’的语义关联）；

（2）结合BILSTM-CRF的序列标注优势，显著提升了地址类实体（如‘金州区XX路XX号’）的识别准确率，弥补了传统模型在长地址分词中的不足。

二、构建知识问答系统

为了克服知识问答系统准确率低的问题，本文提出了一种新的知识问答系统方法。该系统基于大连市的旅游数据构建了知识图谱，并整合百度预训练语言模型ERNIE、双向长短时记忆（BILSTM）网络和条件随机场（CRF）这些模型的优势，构建了联合模型ERNIE-BILSTM-CRF进行命名实体识别，以提高整个问答系统的性能。该问答系统由三部分构成：用户层，问答系统层，知识图谱层，其框架如图1所示。具体细节如下：

（1）用户层：作为问答系统的实际操作者，用户得以通过自然语言向系统提出问题，系统便会智能解析问题内容，并针对性地检索相关信息，最终将搜索到的结果反馈给用户。

（2）问答系统层：在问答系统的核心层，用户提出的问题将被接口传递至ERNIE-BILSTM-CRF模型进行深入的语义分析，随后，这些分析结果将被转换成Cypher查询语句，从而在知识图谱中精确地定位并检索所需信息。

（3）知识图谱层：在知识图谱层，系统将通过接口执行Cypher语句，在图谱中进行精确查询。一旦查询顺利完成，系统将即时返回相关结果。若查询未能成功找到匹配信息，系统将提示用户，告知图谱中不存在相应的数据。

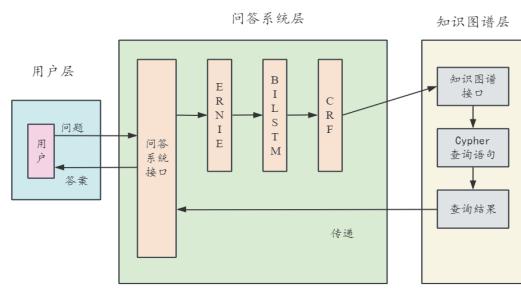


Fig.1 Knowledge Question Answering System Framework

三、知识问答系统的工作原理

本文提出的知识问答系统包括知识图谱的构建和联合模型的创建，接下来将对各个组成部分的工作原理进行详细介绍。

(一) 构建红色旅游知识图谱

为了实现红色旅游问答系统，需要构建大连市的红色旅游知识图谱。知识图谱数据来源于大连市文旅局官方公开数据、景区官方网站及权威历史文献，经人工校验确保准确性。知识图谱通过定期爬取官方数据实现动态更新，确保时效性。该知识图谱包含7种节点，分别为城市（city）、地区（area）、景区（zone）、旧址（address）、背景（background）、意义（meaning）和门票价格（money）。以景区名称为主体，建立与其他类别实体之间的关系，形成三元组（实体，实体，关系），并将数据存储到Neo4j数据库中。Neo4j是一款NoSQL图数据库，通过节点和关系存储数据，并支持可视化展示。构建成功后，可以通过浏览器访问网址localhost:7474，查看构建的知识图谱，部分图谱如图2所示。其中，黄色节点代表城市（city），粉色节点代表地区（area），绿色节点代表景区（zone），灰色节点代表旧址（address），橙色节点代表背景（background），蓝色节点代表意义（meaning），紫色节点代表门票价格（money）；节点之间的箭头则表示它们之间的关系，例如金州区有金县政府旧址等6个景区，关向应纪念馆的门票价格为15元。7类节点基于对5000条用户查询的统计分析确定，覆盖95%的高频问题类型（如‘在哪里’对应地址节点，‘多少钱’对应门票节点）。未纳入‘交通方式’节点因其查询频率不足5%，后续可通过模块化扩展支持。这种节点与节点之间关系的可视化，正是知识图谱与其他数据库的最大区别。通过这种关系，问答系统能够快速锁定答案并将其返回给用户。

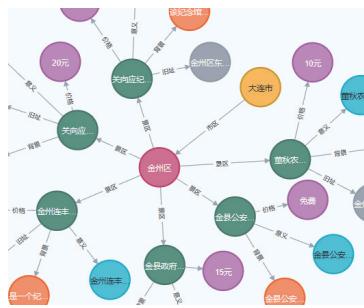


Fig.2 Knowledge Graph of Red Tourism in Dalian (Partial)

(二) 构建 ERNIE-BILSTM-CRF 联合模型

为了更高效地实现用户语义识别和特征提取，本节提出了ERNIE-BILSTM-CRF的联合模型。接下来将对这三个模型进行逐一详细介绍。

1. 语义识别模型 ERNIE

ERNIE是百度研发的基于Transformer架构的预训练语言模型，通过整合大规模语料和知识图谱，采用多任务学习与分层预训练策略，提升语言理解与生成能力。其架构（见图3）包括通用表示模块和特定任务表示模块，前者捕获基础特征，后者针对生成与理解任务进行适配。ERNIE通过多种预训练任务覆盖词法、句法和语义信息，支持自然语言生成、理解和关系抽取，构建一个通用多模式预训练框架，实现了在多任务上的显著性能提升。

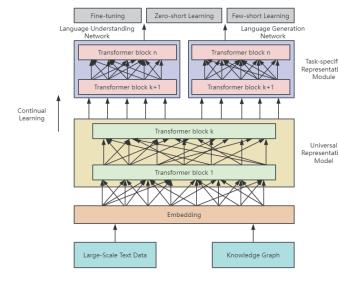


Fig.3 ERNIE Model structure diagram

2. 特征提取模型 BILSTM

为了更有效地对用户的问题进行特征提取，采用了双向长短时记忆网络（Bidirectional Long Short-Term Memory，BILSTM）。BILSTM由前向LSTM与后向LSTM组合而成。每个LSTM单元包含三个门——记忆门、遗忘门和输出门，如图4所示。

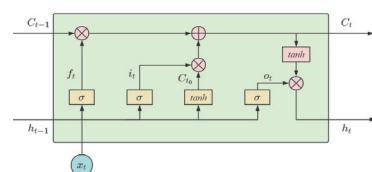


Fig.4 LSTM structure diagram

图5展示了BILSTM的模块流程。BILSTM由前向LSTM和后向LSTM组成，用于更有效地对用户的问题进行特征提取。

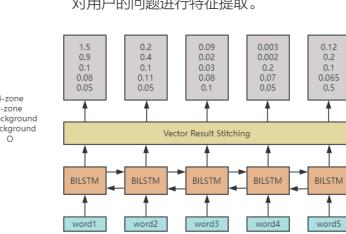


Fig.5 BILSTM Module flowchart

输入一个词向量序列，每个词向量可以是预先训练好的，也可以随机初始化，并且在模型训练过程中还可以进一步训练。前向LSTM从序列的开始到结束依次处理每个词向量。每个时间步，前向LSTM会输出一个隐层状态 h_t 。例如，对于输入序列 w_1, w_2, w_3, w_4, w_5 ，前向LSTM经过5个时间步后，输出

隐层状态 h_1, h_2, h_3, h_4, h_5 。后向 LSTM 从序列的结束到开始依次处理每个词向量。每个时间步，后向 LSTM 也会输出一个隐层状态 h_t 。例如，对于输入序列 w_5, w_4, w_3, w_2, w_1 ，后向 LSTM 经过 5 个时间步后，输出隐层状态 h_5, h_4, h_3, h_2, h_1 。前向 LSTM 和后向 LSTM 的输出隐层状态在每个时间步上进行拼接。例如，对于时间步 t ，前向 LSTM 的输出和后向 LSTM 的输出拼接成一个新的向量。最终，所有时间步的拼接向量形成 BiLSTM 的输出序列。

表 1 展示了一些生成词示例，例如用户输入问题“关向应故居有什么背景故事”时，经过 BiLSTM 的提取后结果为（关向应故居，背景故事，background），这些词将作为关键信息填充到 Cypher 语句中，以便将其调用到知识图谱寻找答案。

表 1 生成词

Tab.1 Generate words

输入语句	输出词
大连市都有哪些地区	<大连市, 地区, area>
关向应故居在哪里	<关向应故居, 哪里, address>
关向应故居有什么背景故事	<关向应故居, 背景故事, background>

3. 条件随机场 (Conditional Random Field, CRF)

序列标注 (Sequence Tagging) 是 NLP 中最基础的任务之一，应用十分广泛，包括分词、词性标注、命名实体识别、关键词提取、语义角色标注以及槽位抽取 (Slot Filling) 等，这些任务都属于序列标注的范畴。在本模型中，文本文件以 BIO 格式存储。在进行命名实体识别时，通常需要对每个字符进行标注，其中中文以单个字为单位，英文则以单词和空格进行分割。标注标签的类型如表 2 所示。

表 2 BIO 格式

Tab.2 BIO format

类型	含义
B	Begin，表示实体片段的开始。
I	Intermediate，代表实体片段的中间。
O	Other，代表字符不为任何实体。

对所有数据标注完毕后如图 6 所示。例如问句“关向应故居有什么背景故事”中，“关向应故居”作为 zone 实体，“背景”作为 background 关系。

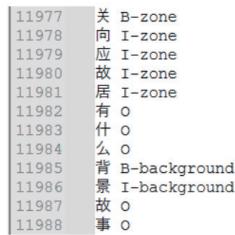


图 6 数据标注结果图

Fig.6 Data annotation result graph

在命名实体识别 (NER) 任务中，其表征标签的可解释性序列存在严格的“语法”约束，例如实体的起始标记必须为 B-，而 I- 代表实体片段的中间。鉴于此，引入条件随机场 (CRF) 模型

具有重要意义。CRF 层可捕捉句子的上下文依赖关系，为标签序列预测提供关键的上下文信息。通过学习标记之间的转移概率，CRF 能确保预测的标签序列符合既定的约束规则，从而有效提升命名实体识别的准确性和合理性，使最终预测结果更加可靠。CRF 考虑前后标记依赖约束，综合使用标记状态转移概率作为评分，如公式 (1)。

$$score(x, y) = \sum_{i=1}^n P_{i, y_i} + \sum_{i=1}^{n+1} A_{y_{i-1}, y_i} \quad (1)$$

上式意为对整个序列 x ，整个序列标注的打分等于各个位置的打分之和，打分为两个部分：前者由 LSTM 输出的决定。后者由 CRF 转移矩阵 A 决定，其中 A_{y_{i-1}, y_i} 表示从第 y_{i-1} 个标签到第 y_i 个标签的转移得分。

4. BiLSTM-CRF 模型

为了更有效地实现特征提取和语义识别，本文将双向长短时记忆网络 (BiLSTM) 与条件随机场 (CRF) 相结合，为知识问答系统的构建做好准备。

BiLSTM-CRF 模型如图 7 所示，ERNIE 输出词向量经 BiLSTM 双向编码后，通过 CRF 层优化标签转移概率，其中转移矩阵约束规则为：B-zone 必须后接 I-zone 或 O，禁止 B-background 直接跳转至 I-address，最后经过 CRF 模型对向量进行评分，得分最高的向量即为识别结果。

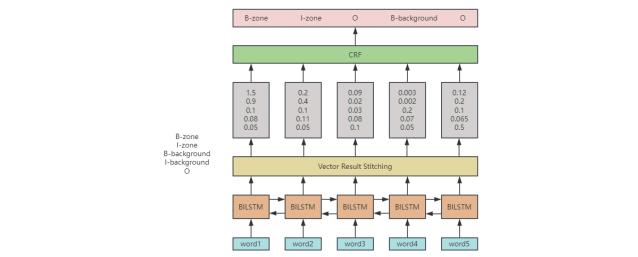


图 7 BiLSTM-CRF 模型结构图

Fig.7 BiLSTM-CRF Model structure diagram

(三) 知识问答系统的工作流程

用户提出问题后，问答系统将问题传输给 ERNIE-BiGRU-CRF 模型，经过模型分析后，系统获得意图识别结果，并将该结果代入 Cypher 语句，以从知识图谱中找出准确的答案。找到答案后，系统将其返回给用户。例如用户输入问题“关向应故居在哪里”，系统首先使用 ERNIE-BiGRU-CRF 模型进行识别，提取出关键词“关向应故居”，并与类别库进行比较，最终确定该问题的类别为“address”，该类别对应知识图谱中的关系；接着，构建查询模板“match (n)->(m) where n.title = '{0}' return n.title, m.title”，将提取到的关系和关键词填入查询语句中，最终语句变为“match (n)->(r:address)->(m) where n.title = '{关向应故居}' return n.title, m.title”。通过查询知识图谱，系统返回结果。结果如图 8 所示。

```
节点类型：地址，表示地名或人名
属性：无
操作：无
参数：无
返回结果：无

节点类型：实体，表示地名或人名
属性：无
操作：无
参数：无
返回结果：无

查询语句：{'text': '关向应故居', 'type': '实体'}，{'text': '关向应故居', 'type': '地址'}
查询结果：{'text': '关向应故居', 'type': '实体', 'title': 'Guangxiang', 'id': 11977}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11980}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11981}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11982}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11983}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11984}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11985}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11986}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11987}, {'text': '关向应故居', 'type': '地址', 'title': 'Guangxiang', 'id': 11988}
```

图 8 返回的查询结果

Fig.8 The results of the query that were returned

四、实验

(一) 实验环境和数据集

本研究的实验环境搭建在拥有 NVIDIA RTX 4060 显卡的个人计算机上，该显卡具备出色的计算性能和 12GB 的显存，配备了 32GB 的 RAM 以及 1TB 的 SSD 存储，确保了数据的高效读写和模型的流畅运行。操作系统采用 Windows 10 专业版，其良好的硬件兼容性和软件支持为实验提供了稳定的运行基础。主要开发工具为 PyCharm，Python 环境为 3.11 版本，该版本在性能和兼容性方面表现出色，能够满足大语言模型开发的需要。

实验采用原创的大连市红色旅游问答数据集，包含 5000 条问答语句，涵盖景区信息、历史背景、门票价格等 7 类节点问题。这些问答语句经过严格的筛选和审核，确保了数据的质量和多样性，能够充分满足实验对于数据规模和内容丰富度的需求。

(二) 对比实验

本节对所使用的 ERNIE-BILSTM-CRF 模型进行了实验，并与其他模型进行了对比。实验采用精确率 (Precision, P)、召回率 (Recall, R) 和 F1 值 (F1-Measure) 作为评价标准，实验结果如表 3 所示，各个模型的可视化结果如图 9 所示（其中 B 为 BERT，BL 为 BiLSTM，C 为 CRF，BG 为 BIGRU）。

表3 各种模型实验性能指标对比

Tab.3 Comparison of experimental performance indicators of various models

模型类型	P	R	F1
BERT	56.80%	51.84%	52.11%
BERT-CNN	60.52%	55.23%	57.14%
BERT-RCNN	62.93%	59.64%	60.36%
BERT-GNN	80.52%	76.65%	78.27%
GPT-3.5	88.56%	89.79%	89.12%
BERT-BILSTM-CRF	91.23%	90.34%	90.78%
ERNIE-CRF	94.96%	96.88%	96.22%
ERNIE-BIGRU-CRF	95.83%	98.58%	96.53%
ERNIE-BILSTM-CRF	98.99%	99.75%	98.91%

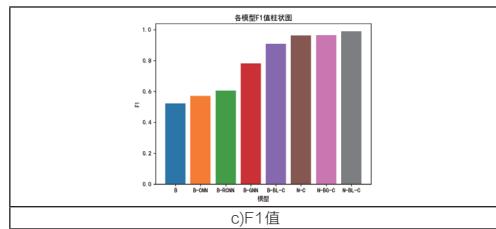
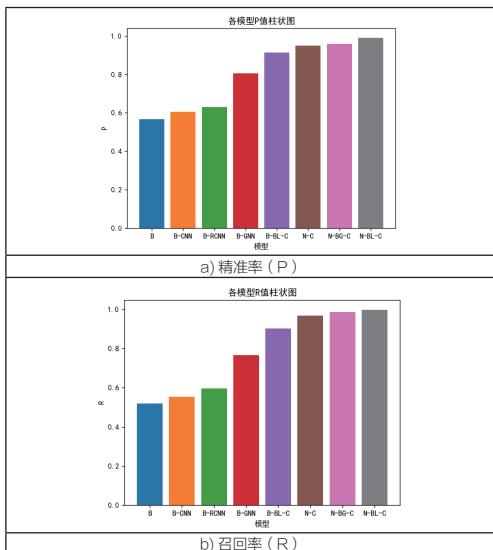


图9 各模型性能指标的柱状图

Fig.9 Histogram of the performance metrics of each model

根据表 3 和图 9 可以看出，随着模型结构的优化，精确率、召回率和 F1 值均显著提升。基础 BERT 模型在三项指标上表现较弱，分别为 56.80%、51.84% 和 52.11%；引入 CNN、RCNN 和 GNN 后，性能稳步提高，尤其是 BERT-GNN 的 F1 达 78.27%。结合序列标注的 BERT-BiLSTM-CRF 进一步提升至 90.78%。ERNIE 系列模型表现更优，尤其是 ERNIE-BiLSTM-CRF，精确率和召回率分别达到 98.99% 和 99.75%，F1 高达 98.91%，体现了其在命名实体识别任务中的卓越准确性和全面性，显示出明显的优势。4.3 消融实验消融实验是验证模型各模块有效性的关键环节，通过逐步移除或替换核心组件，定量分析其对性能的影响。本节对所使用的 ERNIE-BiLSTM-CRF 模型进行的消融实验如表 4 所示。

表4 消融实验对比

Tab.4 Comparison of ablation experiments

模型类型	P	R	F1
ERNIE	88.61%	90.96%	89.63%
ERNIE-BiLSTM	95.54%	96.17%	96.06%
ERNIE-CRF	94.96%	96.88%	96.22%
ERNIE-BiLSTM-CRF	98.99%	99.75%	98.91%

表 4 的消融实验结果显示，不同模型组件对性能的影响显著。基础 ERNIE 模型的 Precision、Recall 和 F1 值分别为 88.61%、90.96% 和 89.63%。加入 BiLSTM 后，模型性能显著提升，Precision、Recall 和 F1 分别达到 95.54%、96.17% 和 96.06%，表明 BiLSTM 增强了上下文信息的捕捉能力。结合 CRF 后，Recall 和 F1 进一步提高至 96.88% 和 96.22%，显示 CRF 在优化标签依赖关系方面的有效性。当同时使用 BiLSTM 和 CRF 时，性能达到最佳，Precision 为 98.99%，Recall 为 99.75%，F1 为 98.91%，验证了这两者在捕获上下文特征和序列依赖中的互补作用，体现了模型设计的合理性和有效性。4.4 节点类型实验在模型整合完毕后，需要对系统进行评估，本文随机抽取了 200 条问题用于所有节点的测试，测试结果如表 5 所示。

表5 测试结果

Tab.5 Test results

节点类型	P	R	F1
city	100%	100%	100%
area	99.57%	100%	98.78%
zone	98.56%	99.88%	97.87%
address	95.83%	98.64%	96.87%
background	100%	100%	100%
meaning	100%	100%	100%
money	100%	100%	100%

表 5 的测试结果显示，整合模型在不同节点类型上的性能表现

极为优秀。城市 (city)、背景 (background)、意义 (meaning) 和金钱 (money) 节点均实现了 100% 的 Precision、Recall 和 F1 值，表明模型在这些领域具备完美的识别能力。区域 (area) 节点的 Precision 为 99.57%、Recall 为 100%、F1 值为 98.78%，显示出其性能的可靠性；而区域 (zone) 节点的 Precision 为 98.56%、Recall 为 99.88%、F1 值为 97.87%，同样表现优异。地址 (address) 节点的 Precision 为 95.83%、Recall 为 98.64%、F1 值为 96.87%，"Address" 节点 F1 值较低 (96.87%) 主要因用户输入中存在非标准地址格式（如‘关向应故居旁边’），未来可通过地址归一化模块（如结合高德地图 API）提升识别率。总体而言，模型在所有节点类型上均展现了高水平的准确性与稳定性，验证了系统的有效性和鲁棒性。

五、结束语

本文提出的基于 ERNIE-BILSTM-CRF 联合模型与大连市红色旅游知识图谱的智能问答系统，有效提升了旅游领域用户意图识别的准确性和问答的精确度，充分发挥了预训练语言模型与结构化知识图谱的协同优势。系统不仅丰富了红色旅游的知识资源，还通过多层次语义理解和序列标注技术，实现了对多类别实体的高效识别，显著优于传统模型。随着知识图谱规模的扩大和多模态数据的引入，未来工作包括：（1）集成多模态数据（如景区图片）增强问答丰富性；（2）结合强化学习优化对话策略；（3）拓展至全域旅游场景，验证模型泛化能力。

参考文献

- [1] Brown T, Mann B, Ryder N, et al. Language models are few-shot learners[J]. Advances in neural information processing systems, 2020, 33: 1877–1901.
- [2] Ouyan L, Wu J, Jiang X, et al. Training language models to follow instructions with human feedback [J]. Advances in neural information processing systems, 2022, 35: 27730–27744.
- [3] Etzioni O, Cafarella M, Downey D, et al. Unsupervised named-entity extraction from the web: An experimental study[J]. Artificial intelligence, Elsevier, 2005, 165(01): 91–134.
- [4] 王荣坤. 基于旅游知识图谱的智能问答系统设计与实现 [D]. 青岛大学, 2022. DOI: 10.27262/d.cnki.gqda.2022.001953.
- [5] WANG L, MA C, FENG X, et al. A survey on large language model based autonomous agents [J]. arXiv preprint arXiv:230811432, 2023.
- [6] Auer S, Bizer C, Kobilarov G, et al. Dbpedia: A nucleus for a web of open data[M]//The semantic web. Springer, Berlin, Heidelberg, 2007: 722–735.
- [7] Suchanek F M, Kasneci G, Weikum G. Yago: a core of semantic knowledge[C]//Proceedings of the 16th international conference on World Wide Web. 2007: 697–706.
- [8] Niu X, Sun X, Wang H, et al. Zhishi.me—weaving chinese linking open data[C]//International Semantic Web Conference. Springer, Berlin, Heidelberg, 2011: 205–220.
- [9] Wang H, Wu T, Qi G, et al. On Publishing Chinese Linked Open Schema[M]//The Semantic Web—ISWC 2014. Springer International Publishing, 2014: 293–308.
- [10] Wang Z, Li J, Wang Z, et al. XLore: A Large-scale English–Chinese Bilingual Knowledge Graph[C]// International semantic web conference (Posters & Demos). 2013, 1035: 121–124.
- [11] IMDB Official. IMDB[EB/OL]. [2020-11-23]. <http://www.lmda.com>.
- [12] BAI T, GONG L, ANG Y, et al. A method for exploring implicit concept relatedness in biomedical knowledge network[J]. BMC Bioinformatics, 2016, 17(9): 53–66.
- [13] ROSPOCHE R M, VAN E R P M, VOSSEN P, et al. Building event-centric knowledge graphs from news[J]. Journal of Web Semantics, 2016, 37: 132–151.
- [14] Aliod D M, van Zaanen M, Smith D. Named entity recognition for question answering[C]. Australasian Language Technology Workshop (ALTA). Australia and New Zealand: ALTA, 2006: 51–58.
- [15] SHI L, LI S, YANG X, et al. Semantic health knowledge graph: Semantic integration of heterogeneous medical knowledge and services[J]. BioMed Research International, 2017, 1(4): 1–12.
- [16] Cheng P, Erk K. Attending to entities for better text understanding[C]. Proceedings of the AAAI Conference on Artificial Intelligence (AAAI). Menlo Park, CA, USA: AAAI, 2020, 34(05): 7554–7561.
- [17] Bordes A, Usunier N, Chopra S, et al. Large-scale simple question answering with memory networks[J]. arXiv preprint arXiv: 1506.02075, 2015.
- [18] 王子岳. 基于深度学习的自然语言理解 模型 [D]. 南京邮电大学, 2021. DOI: 10.27251/d.cnki.gnjdc. 2021.000042.
- [19] 王博, 群诺, 王京博, 等. 基于知识图谱的西藏旅游问答系统设计与实现 [J]. 信息技术与信息化, 2023, (12): 181–184.
- [20] 翟晗晖. 基于知识图谱的问答系统的设计与实现 [D]. 华东师范大学, 2022. DOI: 10.27149/d.cnki.ghdsu.2022.000894.
- [21] SHANAHAN M. Talking about large language models[J]. Communications of the ACM, 2024, 67(2): 68–79.
- [22] TAYLOR R, KARDAS M, CUCURULL G, et al. Galactica: A large language model for science[J]. arXiv preprint arXiv: 221109085, 2022.
- [23] 罗琳凡. 基于预训练模型的旅游领域知识图谱构建及智能问答应用 [D]. 东南大学, 2022. DOI: 10.27014/d.cnki.gdnau.2022.001730.
- [24] 张峻菖. 基于 ERNIE-BiGRU-CRF 的山西旅游领域命名实体识别研究 [D]. 山西财经大学, 2024.
- [25] 徐捷, 邵玉斌, 杜庆治, 等. 结合混合特征提取与深度学习的长文本语义相似度计算 [J]. 计算机工程与科学, 2024, 46(08): 1513–1520.