

## 基于社交媒体数据的知识增强多任务学习交通事件检测模型

周正<sup>1</sup>, 汪玫<sup>1</sup>, 杨林瑶<sup>2</sup>, 李莉芳<sup>3</sup>, 王晓<sup>1,4</sup>

(1. 安徽大学人工智能学院, 安徽 合肥 230031;

2. 之江实验室, 浙江 杭州 311121;

3. 中山大学新闻传播学院, 广东 广州 510006;

4. 光电信息获取与防护技术全国重点实验室, 安徽 合肥 230031)

**摘要:** 交通事件检测是智能交通系统 (ITS) 的核心环节, 现有方法在处理社交媒体非结构化文本、关联地理信息及协同多任务学习方面存在局限。为此, 提出融合地理知识增强与多任务学习的交通事件检测 (GeoKE-MTL) 模型, 以提升事件检测的准确性与鲁棒性, 该模型主要由知识增强模块和多任务学习模块两个部分组成。实验结果表明, 在自建的社交媒体文本数据集上, GeoKE-MTL 在事发地点识别任务和交通事件识别任务中的 F1 分数分别达到 79.42% 和 79.75%, 在事发地点识别任务中均优于主流基线模型。研究验证了融合地理知识增强与多任务学习对提升检测性能的有效性, 为智能交通系统的实时事件感知提供了新方案。

**关键词:** 交通事件检测; 知识增强; 多任务学习; 智能交通系统

**中图分类号:** TP39

**文献标志码:** A

**doi:** 10.11959/j.issn.2096-6652.202541

## Knowledge-enhanced multi-task learning traffic incident detection model based on social media data

ZHOU Zheng<sup>1</sup>, WANG Mei<sup>1</sup>, YANG Linyao<sup>2</sup>, LI Lifang<sup>3</sup>, WANG Xiao<sup>1,4</sup>

1. School of Artificial Intelligence, Anhui University, Hefei 230031, China

2. Zhijiang Laboratory, Hangzhou 311121, China

3. School of Journalism and Communication, Sun Yat-sen University, Guangzhou 510006, China

4. National Key Laboratory of Optoelectronic Information Acquisition and Protection Technology, Hefei 230031, China

**Abstract:** Traffic incident detection is a core component of intelligent transportation systems (ITS), but existing methods are limited in processing unstructured social media text, associated geographic information, and collaborative multi-task learning. To address this, a traffic incident detection model based on integrated geographical knowledge enhancement and multi-task learning (GeoKE-MTL) was proposed to improve the accuracy and robustness of incident detection. The model consists of two main components: a knowledge enhancement module and a multi-task learning module. Experimental results show that on a self-built social media text dataset, GeoKE-MTL achieves F1 scores of 79.42% and 79.75% in incident location identification and traffic event identification tasks, respectively, outperforming mainstream baseline models in the incident location identification task. This study validates the effectiveness of integrating geographic knowledge enhancement with multi-task learning in improving detection performance, providing a new solution for real-time event perception in intelligent transportation systems.

**Key words:** traffic incident detection, knowledge enhancement, multi-task learning, intelligent transportation system

收稿日期: 2025-09-18; 修回日期: 2025-11-25

通信作者: 王晓, xiao.wang@ahu.edu.cn

基金项目: 国家自然科学基金项目 (No.62173329)

**Foundation Item:** The National Natural Science Foundation of China (No.62173329)

## 0 引言

在现代城市化进程中,交通拥堵、事故和突发事件已成为影响居民出行效率和安全的主要问题。根据世界卫生组织的数据<sup>[1]</sup>,全球每年因交通事故导致的死亡人数超过130万,而拥堵造成的经济损失高达数万亿美元。交通事件检测作为智能交通系统的核心组成部分,能够实时识别这些事件,帮助驾驶者调整路线,并为交通管理部门应急响应提供数据支持,从而显著降低事故发生率、减少拥堵时间,并提升整体交通效率。

社交媒体的快速发展为交通事件检测开辟了全新的数据来源,社交媒体作为近乎实时的信息来源,能够为交通管理和应急决策提供即时有效的支持,这些信息成为对传统交通传感器的有力补充。尽管传统传感器能够在特定区域内提供精确的数据,但其部署成本高昂且覆盖范围有限。相比之下,社交媒体数据不仅成本低廉、覆盖全球,还能捕捉到用户对交通事件的即时反馈、主观感受以及现场描述。社交媒体的低成本特性显著增强了城市交通事件的监测能力,特别是在基础设施较弱或资源有限的地区<sup>[2]</sup>。

然而,社交媒体文本的非结构化特性(例如文本中含有大量非正式的、不规则的表达,文本内容缺乏上下文语境)<sup>[3]</sup>以及社交媒体中存在的大量无效信息,给交通事件信息的准确提取带来了一系列挑战。Wu等<sup>[4]</sup>指出尽管微博数据在空间信息提取方面具有潜力,但由于用户描述往往存在歧义和不完整等非结构性问题,严重影响了交通事件信息的识别精度和响应效率。Zhu等<sup>[5]</sup>进一步指出,这类非结构性问题直接导致地理信息关联成为难题,影响了交通事件检测的精度和响应速度,从而限制了智能交通系统的整体效率。因此,高效的交通事件信息识别技术,对于构建实时高效的智能交通系统,从而帮助交通管理部门制定及时有效的应对策略具有重要意义<sup>[6]</sup>。

近年来,研究者在基于社交媒体数据的交通事件信息检测方面取得了一些进展。例如,Ali等<sup>[7]</sup>利用本体驱动的潜在狄利克雷分配(online latent Dirichlet allocation, OLDA)和双向长短期记忆网络(bi-directional long short-term memory, BiLSTM),实现了高准确率的道路事故检测;Chang等<sup>[8]</sup>则通过卷积神经网络-长短期记忆网络(convolutional

neural network-long short-term memory network, CNN-LSTM)和改进的核密度估计(kernel density estimation, KDE\*) ,有效跟踪了交通拥堵与事故的时空分布。然而,这些方法在设计上仍存在改进空间,它们大多没有使用多个任务进行共同学习,未能充分利用任务间的内在关联性,导致数据资源和计算资源的浪费。此外,对地理知识的利用不足也是一个普遍问题。Wang等<sup>[9]</sup>提出了一种基于潜在狄利克雷分配(latent Dirichlet allocation, LDA)的自动地理编码事件检测方法,尝试从海量用户生成数据中提取相关信息,但其准确性和计算效率仍有提升空间;Suat-Rojas等<sup>[2]</sup>采用命名实体识别(named entity recognition, NER)结合地理编码技术提取位置坐标,但在处理嵌套或非显式位置时效果有限。这些不足表明,现有方法在整合地理知识和优化多任务协同方面仍有较大提升空间。

针对上述问题,本文提出了一种融合地理知识增强与多任务学习的交通事件信息检测(GeoKE-MTL)模型,旨在提升交通事件信息检测的准确性与鲁棒性。本文主要贡献包括以下3个方面。

(1)提出了一个深度融合地理知识的动态门控融合模块,与现有的简单拼接或静态注入知识的模型相比,该模块能根据上下文语境自适应地调整知识权重,有效解决了地理实体歧义问题,提升了模型在噪声数据下的鲁棒性。

(2)设计了一种基于跨任务注意力的交互式多任务学习框架,与现有传统多任务模型仅共享底层参数的方法不同,该框架通过让实体识别与事件抽取任务在解码阶段进行双向信息交互,实现了任务间的深层次协同,有效缓解了流水线模型中固有的错误传播问题。

(3)在本研究组自建的社交媒体文本数据集中进行了大量实验,实验结果表明,本文模型较其他多个先进模型具有更准确的交通事件信息识别效果,在实际应用中有望提升交通管理的响应速度和决策质量。

## 1 相关工作

社交媒体数据的应用价值已得到学术界的广泛关注,其蕴含的实时性、海量性数据特征可为交通监管部门提供重要的数据支撑。本节主要介绍采用的3类关键技术:知识增强、深度学习和多任务学习,并综述了它们在智能交通领域中的研究进展。

## 1.1 知识增强

知识增强通过注入外部领域知识（如专业领域知识库、知识图谱等），可有效提升模型对非结构化数据的语义理解和鲁棒性，目前在交通事件检测任务中应用愈发广泛。该技术不仅能优化识别和事件推理过程，还可提升模型对时空信息的识别精度，为智能交通系统的实时感知提供技术支持。

近年来，众多研究已验证知识增强在社交媒体数据驱动的交通事件检测中的有效性。Melhem等<sup>[10]</sup>提出了一种基于深度学习的交通事件检测与预测框架，该框架通过向大语言模型注入语言知识和知识图谱，结合检索增强生成及动态知识图谱嵌入技术，有效提升了事件检测的质量和时空预测精度。该方法强调了知识增强在处理非正式文本和噪声数据时的作用。Bok等<sup>[11]</sup>提出了一种高效的图基事件检测方案，该方案利用社交媒体数据构建图结构，通过融合知识增强语义信息和多源数据，在实时事件检测中表现出良好的鲁棒性，尤其在交通事故识别场景中适配性较强。Salas等<sup>[12]</sup>设计了一种交通事件检测框架，该框架利用社交媒体数据注入分类知识，结合监督学习算法实现事件类型识别，并通过地理编码技术增强位置信息提取精度，进一步验证了知识增强在位置关联任务中的有效性。Kolajo等<sup>[13]</sup>构建了社交媒体事件检测分析框架（social media analysis framework for event detection, SMAFED），通过知识增强语义分析技术处理文本中的噪声术语，实现了交通事件的实时检测，其在真实场景中的验证结果为本文采用知识增强提升事件识别效率提供了直接理论支撑。

## 1.2 深度学习及其在多任务学习中的扩展

深度学习技术在自然语言处理领域的快速发展，为从社交媒体数据中提取交通事件信息提供了有效技术手段，基于深度学习的自然语言处理技术已在交通事件的实体识别、类型分类、时空关联等任务中展现出优异性能。多任务学习作为深度学习的扩展框架，通过对多个相关任务进行协同训练，充分利用任务间的共性特征与差异信息提升模型整体性能，减少数据与计算资源的浪费。目前，该技术在城市交通事件检测中的直接应用较少，但在网络流量异常检测、交通预测等相关领域已展现出良好的应用潜力。

Zhang等<sup>[14]</sup>提出一种基于深度学习的交通事故检测方法，该方法采用深度信念网络与长短期记忆

网络，对弗吉尼亚州及纽约市的300余万条推文数据进行分析。研究通过提取单个词元与成对词元特征捕捉事故相关帖子的关联规则，充分证实了社交媒体数据与交通事件间的强相关性。Hodorog等<sup>[15]</sup>提出了一种基于自然语言处理（natural language processing, NLP）和机器学习的智能城市事件检测框架，该框架通过监督学习对文本数据进行实时分类，可准确识别交通事故、交通拥堵等风险事件，实验验证其准确率可达88.5%，为交通事件检测提供了具备良好可扩展性的技术方案。Jonnalagadda等<sup>[16]</sup>提出一种专注于特定交通事件（如事故、拥堵、道路封闭）的深度学习检测方法，通过构建分类模型实现对多类事件的有效区分，且在真实数据集上表现出较高的分类性能，进一步扩展了交通事件检测的细粒度。Afyouni等<sup>[17]</sup>提出了一种混合学习模型，结合监督深度学习和无监督空间聚类技术，对25 530条社交媒体数据进行训练，不仅分类准确率超80%，还可处理12类不同事件，该研究通过基于Transformer的双向编码器表征（bidirectional encoder representations from Transformers, BERT）与基于BERT的关键词提取方法（keyword extraction with BERT, KeyBERT）生成语义关键词，验证了深度学习在整合文本与位置信息开展事件检测任务中的应用潜力。Yang等<sup>[18]</sup>将交通事件检测建模为槽填充任务，利用深度学习模型处理荷兰语推文中的非正式语言与噪声数据，成功提取事件类型、时间、地点、后果等细粒度信息，体现出在多语言场景下的良好适用性。Yang等<sup>[19]</sup>提出一种基于多任务特征选择的网络流量异常检测方法，该方法将不同时间段的流量数据视为独立任务，通过联合特征选择策略充分利用多任务信息；在包含248个特征的日本-美国跨太平洋骨干链路数据集上的实验表明，该方法性能优于单任务L1范数特征选择方法，证实了多任务学习在特征共享与性能提升中的有效性。Deng等<sup>[20]</sup>提出一种情境感知的多任务学习框架，用于交通预测任务；该框架通过自动识别交通情境（如高峰时段、事故时段），为具有相似行为特征的传感器构建专属预测模型，有效提升了交通预测精度，其情境适配与任务协同思路为本文提供了理论支持。Chen等<sup>[21]</sup>提出一种基于多模态生成对抗网络（multi-modal generative adversarial network, mmGAN）的交通事件检测方法，整合物理传感器数据与社交媒体数据，采用半监督学习方

式实现交通事件的检测与分类；在旧金山湾区的真实数据集上的评估结果显示，该多任务学习方法显著提升了事件检测准确性，直接验证了多任务学习在交通事件检测中的应用价值。Li等<sup>[22]</sup>提出一种用于稀疏交通预测的多任务学习网络，同时预测路段拥堵类别与行驶速度，在稀疏环路计数数据场景下，其性能优于单任务方法，为多任务学习在交通相关预测任务中的应用提供了借鉴。

上述研究充分表明，深度学习及其多任务扩展在交通相关任务中具备显著优势<sup>[23-25]</sup>。然而，当前针对社交媒体数据的道路交通事件检测研究仍较为匮乏。本文通过融合知识图谱与多任务学习技术，或将为解决该领域的现存难题提供新的技术路径。

## 2 融合知识增强与多任务学习的交通事件文本信息检测方法

GeoKE-MTL模型架构流程如图1所示，该模型主要由知识增强和多任务交通信息检测两大核心模块构成。其中，知识增强模块通过注入交通领域的地理知识，有效提升社交媒体文本中位置信息的提取精度，缓解非结构化描述带来的歧义问题；多

任务交通信息检测模块则基于共享表示框架，同时处理命名实体识别和事件抽取等子任务，利用任务间互补性实现知识迁移和参数优化，从而提升模型的鲁棒性和泛化能力。该分层协作机制确保了从非结构化文本到精确事件输出的全链路高效处理。

本文模型解决问题流程首先在社交媒体原始文本数据输入阶段，通过文本编码层提取上下文相关的语义特征表示；接着利用知识增强模块检索并融合外部知识库，通过门控机制自适应地增强特征表示，避免噪声干扰；然后，多任务学习交通信息检测模块引入注意力机制，实现多个任务的协同训练，利用跨任务注意力促进信息交互；最后联合损失函数优化模型，实现端到端的交通事件检测。

### 2.1 GeoKE-MTL模型架构

GeoKE-MTL模型架构通过有机融合知识增强机制与多任务学习策略，显著强化了对复杂、非正式交通描述的语义理解和事件定位能力。GeoKE-MTL模型的整体设计遵循分层协作、动态交互的核心思想。文本编码层旨在获取高质量的上下文语义表示，为后续处理奠定基础；知识增强层的设计动机是解决社交媒体文本中地理信息的模糊性和歧




图1 GeoKE-MTL模型架构流程

义性，不同于使用简单拼接特征的知识增强方法，本文采用门控机制实现上下文感知的知识选择，使GeoKE-MTL模型能动态判断如何利用外部知识；多任务学习架构的设计旨在突破任务孤立的局限，该部分的创新核心在于引入了跨任务注意力层，该方法在特定的BiLSTM编码之后构建了一个双向的信息交互通道，使实体识别与事件抽取能够互相指导、互相增强，实现真正的协同学习。

这种层次化设计确保了从原始文本到结构化事件信息的全链路优化，每个模型层针对特定问题，通过交互机制整合为一个有机整体。

## 2.2 文本编码层

对于输入文本序列 $X = \{x_1, x_2, \dots, x_n\}$ ，本文首先使用预训练的中文BERT模型作为文本编码器，将每个词映射为上下文相关的向量表示<sup>[26]</sup>。设BERT模型的隐藏层维度为 $d$ ，文本序列长度为 $n$ 。BERT编码过程可表示为：

$$\mathbf{H} = \text{BERT}(X) \in \mathbb{R}^{n \times d} \quad (1)$$

其中， $\mathbf{H} = \{h_1, h_2, \dots, h_n\}$ 表示词向量序列的输出，输入序列先被分词映射为词嵌入，经过多层Transformer结构后得到上下文相关的语义表示，为后续模块提供了基础的语义信息<sup>[27]</sup>。

## 2.3 知识增强层

本文设计了一个专门的知识增强层，用于融合外部领域知识以提升模型对交通事件领域的理解。本文知识增强模块的核心思路不只是简单融合地理信息，而是通过门控机制实现交通领域专业知识的动态、自适应注入，以应对社交媒体文本的歧义和噪声，不同于常规地理编码的静态注入，它允许模型根据上下文学习知识权重，避免冗余干扰，提升模型的领域适应性<sup>[28]</sup>。该层主要由知识表示检索和基于门控机制的知识增强网络两个部分组成。

(1) 知识表示检索：本文首先构建了包含交通领域常见实体和事件触发词的知识库（如道路名称、地标、事故关键词等）。对于输入文本 $X$ ，知识检索通过Trie树匹配器识别文本中的实体并检索知识库中的相关知识进行匹配。知识检索过程可表示为：

$$\mathbf{K} = \text{Retrieve}(X) \quad (2)$$

基于检索结果生成与每个输入词对应的知识向量序列 $\mathbf{K} = \{k_1, k_2, \dots, k_n\}$ ，其中 $k_i$ 为空间维度为 $d_k$ 的知识表示，未匹配时可取零向量， $\mathbf{K}$ 是与原始序列长度一致的知识嵌入矩阵。

(2) 基于门控机制的知识增强网络：传统的知识融合方法是一种静态融合策略，无法根据具体语境调整知识的融合程度，容易引入噪声并导致特征冗余。受神经网络中门控机制的启发，本文设计了一种动态知识选择门以实现知识与文本的自适应融合。给定文本编码层输出的特征矩阵 $\mathbf{H}$ 和知识向量矩阵 $\mathbf{K}$ ，首先拼接得到 $[\mathbf{H}; \mathbf{K}]$ ，然后通过两组独立的可学习参数来计算门控信号和知识特征表示。

$$G = \sigma(\mathbf{W}_g[\mathbf{H}; \mathbf{K}] + b_g) \quad (3)$$

$$\mathbf{F} = \text{ReLU}(\mathbf{W}_f[\mathbf{H}; \mathbf{K}] + b_f) \quad (4)$$

其中， $\sigma(\cdot)$ 是Sigmoid激活函数。 $\mathbf{W}_g$ 、 $b_g$ 和 $\mathbf{W}_f$ 、 $b_f$ 是可学习的参数矩阵与偏置，分别用于计算门控信号 $G$ 和融合变换后的知识特征 $\mathbf{F}$ 。门控信号 $G \in (0, 1)$ ，当 $G$ 趋近于1时，则表明当前的上下文信息不足，模型会提高外部知识融合的程度；当 $G$ 趋近于0时，表明该文本语义明确，模型则倾向于保留原始文本特征。随后，本文使用门控信号 $G$ 对变换后的知识特征 $\mathbf{F}$ 和原始文本特征 $\mathbf{H}$ 进行加权组合。

$$\mathbf{H}' = G \odot \mathbf{F} + (1 - G) \odot \mathbf{H} \quad (5)$$

其中， $\odot$ 表示阿达玛（Hadamard）逐元素乘积，用于实现特征维度级别的精细融合。最后，使用残差连接与层归一化来稳定训练过程，并保留原始的梯度流。

$$\mathbf{H}_e = \text{LayerNorm}(\mathbf{H} + \mathbf{H}') \quad (6)$$

门控信号 $G$ 作为该网络中的动态信息滤波器，决定了相关信息 $\mathbf{F}$ 覆盖或补充原始文本特征 $\mathbf{H}$ 的程度，该门控机制使模型能够自适应地选择性利用知识信息，在避免干扰原始表示的同时增强了语义表示的领域相关性，简单拼接会导致维度膨胀和无关特征干扰，而本文中的门控机制通过学习门控值 $G$ 动态过滤知识，仅保留相关部分，避免冗余累积，并通过残差连接保持原始信息的完整<sup>[28]</sup>。

## 2.4 多任务学习架构

传统多任务学习架构通常依赖于编码器底层进行硬参数共享，这种浅层的共享方式难以在解码阶段实现任务间信息的深度互补<sup>[29]</sup>。为解决上述问题，使模型充分利用实体识别与事件抽取任务之间的协同关系，本节构建了一个交互式协同的多任务学习架构，不同于传统多任务学习架构的独立解码形式，该架构通过引入跨任务注意力层实现解码阶段任务间信息的双向交互，形成不同任务之间的协同效应。

针对实体识别任务, 本文使用 BiLSTM 来建模序列上下文依赖。设输入特征序列为  $\mathbf{H}_e = \{h_1, h_2, \dots, h_n\}$ , BiLSTM 输出序列表示为:

$$\mathbf{H}_{\text{ner}} = \text{BiLSTM}(\mathbf{H}_e) \quad (7)$$

其中,  $\mathbf{H}_{\text{ner}} \in \mathbb{R}^{n \times d}$ , 经 Dropout 等处理后送至 NER 输出层预测实体标签。在获得任务特定表示后, 使用相应的输出层生成最终预测, 在 NER 任务中使用线性层输出每个词的标签概率, 再通过条件随机场 (conditional random field, CRF) 层建模标签序列依赖, 实现全局最优的标签序列解码, 其计算过程为:

$$s_i = \mathbf{W}_{\text{ner}} \hat{h}_i + b_{\text{ner}}, \quad s_i \in \mathbb{R}^{C_{\text{NER}}} \quad (8)$$

$$\text{Score}(X, y) = \sum_{i=1}^n (A_{y_{i-1}, y_i} + s_i[y_i]) \quad (9)$$

其中,  $\hat{h}_i$  为跨任务注意力后的第  $i$  个 token 表示;  $\mathbf{W}_{\text{ner}}$  为权重矩阵, 用于将 token 的语义表示映射到“标签空间”;  $C_{\text{NER}}$  为标签总数。X 为输入的文本序列;  $y = \{y_1, y_2, \dots, y_n\}$  为待评估的标签序列;  $\mathbf{A}$  为转移矩阵;  $s_i[y_i]$  表示第  $i$  个 token 的打分向量中, 标签  $y_i$  对应的元素。在预测阶段, 模型选择标签序列中得分最高的标签。

$$\hat{y} = \arg \max_y \text{Score}(X, y) \quad (10)$$

对于事件抽取任务, 本文首先对共享特征  $\mathbf{H}_{\text{enh}}$  进行双层双向 LSTM 编码, 提高对长距离依赖的建模能力, 得到序列特征。

$$\mathbf{H}_{\text{event}} = \text{BiLSTM2}(\mathbf{H}_e) \quad (11)$$

然后, 通过注意力池化机制聚合序列信息, 令  $\mathbf{H}_{\text{event}} = \{h_1, \dots, h_n\}$ , 计算注意力权重。

$$e_i = \mathbf{v}^T \tanh(\mathbf{W}_o \hat{h}_i + b_o) \quad (12)$$

$$\alpha_i = \text{softmax}(e_i) \quad (13)$$

$$\mathbf{c} = \sum_{i=1}^n \alpha_i \hat{h}_i \quad (14)$$

其中,  $\mathbf{W}_o$  为维度变化矩阵, 将特征映射到隐藏空间,  $\mathbf{v}^T$  进一步将隐藏特征映射为注意力权重, 然后通过 softmax 归一化, 得到每个时间步的权重  $\alpha_i$ , 注意力机制通过学习权重  $\alpha$  让模型聚焦最关键的特征序列位置。基于注意力权重  $\alpha$  对特征矩阵进行加权求和计算得到固定长度的上下文向量  $\mathbf{c}$  (维度与隐藏层相同), 将此向量输入多层全连接分类网络 (multi-layer perceptron, MLP) 进行事件类别预测。分类器形式为:

$$p_{\text{event}} = \text{softmax}(U_2(\text{ReLU}(U_1 \mathbf{c} + b_1)) + b_2) \quad (15)$$

其中  $U_1$ 、 $U_2$ 、 $b_1$ 、 $b_2$  为映射参数,  $U_1 \mathbf{c} + b_1$  为第一层映射, 将上下文向量  $\mathbf{c}$  映射到中间维度, 通过 ReLU 激活函数引入非线性, 增强模型表达能力;  $U_2 \text{ReLU}(\cdot) + b_2$  为第二层映射, 进一步变换特征空间, 捕捉更复杂的分类模式; 最后通过 Softmax 输出类别概率分布  $P^{\text{event}}$ 。该注意力机制使模型能够自动聚焦于与事件类别关联最强的时刻, 从而提高事件抽取的效果。

为了促进任务间的信息交互, 本文设计了一种跨任务注意力层, 该层分别对 NER 任务特征和事件任务特征进行双向交叉注意力计算, 其核心思想是让独立任务在做出最终决策前能够动态有选择地参考另一个任务所学习到的特征信息。具体计算过程如下。

在事件抽取任务对实体识别任务的注意力过程中, 本文令查询向量  $\mathbf{Q}_E$  来自事件特征, 键值向量  $\mathbf{K}_N$  来自实体特征, 让事件抽取聚焦于与事件相关的关键实体。

$$\begin{aligned} \mathbf{Q}_E &= \mathbf{W}_Q^E \mathbf{H}_{\text{event}} \\ \mathbf{K}_N &= \mathbf{W}_K^N \mathbf{H}_{\text{ner}} \\ \mathbf{V}_N &= \mathbf{W}_V^N \mathbf{H}_{\text{ner}} \end{aligned} \quad (16)$$

计算注意力权重  $A_{e2n} = \text{softmax}\left(\frac{\mathbf{Q}_E \mathbf{K}_N^T}{\sqrt{d_k}}\right)$ , 其中

$d_k$  是查询向量的维度, 再将  $A_{e2n}$  与实体值向量  $\mathbf{V}_N$  相乘得到实体细节信息  $\mathbf{C}_E = A_{e2n} \mathbf{V}_N$ , 为事件抽取提供实体级别的语义特征。

在实体识别任务对事件抽取任务的注意力过程中, 类似地, 以实体特征为查询, 事件特征为键值, 使实体识别能够借助事件的全文特征来消歧和修正实体边界。

$$\begin{aligned} \mathbf{Q}_N &= \mathbf{W}_Q^N \mathbf{H}_{\text{ner}} \\ \mathbf{K}_E &= \mathbf{W}_K^E \mathbf{H}_{\text{event}} \\ \mathbf{V}_E &= \mathbf{W}_V^E \mathbf{H}_{\text{event}} \end{aligned} \quad (17)$$

计算注意力权重  $A_{n2e} = \text{softmax}\left(\frac{\mathbf{Q}_N \mathbf{K}_E^T}{\sqrt{d_k}}\right)$ , 得到

事件场景信息  $\mathbf{C}_N = A_{n2e} \mathbf{V}_E$ , 为实体识别提供全文语义约束。

最终, 将获得的跨任务上下文特征与原特征进行残差连接, 并通过线性映射得到最终增强后的任务特征。

$$\widehat{H}_{\text{ner}} = H_{\text{ner}} + C_N \quad (18)$$

$$\widehat{H}_{\text{event}} = H_{\text{event}} + C_E \quad (19)$$

上述过程使模型中的NER任务可获得事件层面信息（如整体事件情景），而事件分类任务可利用实体层面细节，实现语义信息的双向交互。这种方式区别于单纯共享层的硬参数共享，通过动态权重自适应地融合任务间重要信息，有效提升了多任务学习性能。

## 2.5 损失函数与模型优化

本文模型框架的总损失函数为各任务加权损失的组合。

$$\mathcal{L} = \lambda_{\text{ner}} \mathcal{L}_{\text{ner}} + \lambda_{\text{event}} \mathcal{L}_{\text{event}} \quad (20)$$

其中， $\lambda$ 为不同任务的权重系数，用于平衡任务优先级。在不同任务中，NER任务采用CRF损失以建模序列依赖，从而避免非法标签的出现得到整体最优的预测结果；事件抽取任务中存在非事件样本远多于事件样本数量，因此在该任务中使用加权交叉熵函数来处理文本中的类别不平衡问题。不同任务的损失函数定义为：

$$\mathcal{L}_{\text{ner}} = - \sum_{i=1}^n \sum_{j=1}^{|T|} w_j y_{ij} \log_e(P_{ij}^{\text{ner}}) \quad (21)$$

$$\mathcal{L}_{\text{event}} = - \sum_{k=1}^{|E|} y_k \log_e(P_k^{\text{event}}) \quad (22)$$

其中， $w_j$ 是第 $j$ 类的权重，用于缓解类别不平衡问题； $n$ 为样本序列长度， $| \cdot |$ 为相应任务的类别数； $y$ 为相应任务的真实标签独热编码（one-hot）表示， $P$ 为样本的预测概率。模型优化选择Adam优化器自适应调整学习率，通过梯度下降方法优化总损失 $\mathcal{L}$ ，实现各任务参数的联合训练与更新<sup>[30]</sup>。

## 3 实验与讨论

### 3.1 数据集与实验环境配置

本文使用的社交媒体数据集为1 000条经过筛选和标注的交通事件相关微博文本数据（均为2012年上海区域相关的帖子）<sup>[31-33]</sup>。标注工作由4名标注人员使用标签工作室对数据进行手动标注完成，标注过程中对交通事件关键词以及事发地点实体进行选中标注，并构建实体之间的关系标签。为保证训练、测试的合理划分，数据按7:2:1的比例划分为训练集、测试集和验证集。在预处理阶段，对文本进行了清洗与规范化，去除了文本中的重复空白、特定符号以及停用词等。在模型训练阶段

使用网格搜索方法，在验证集上评估不同超参数组合（如学习率、批量大小、隐藏层维度等）的性能，选择验证集上F1分数最高的组合作为最佳超参数。

模型实现基于Pytorch框架，实验的硬件配置包括14代Intel(R)Core(TM)i7-14700KF处理器、32 GB运行内存及NVIDIA GeForce RTX 4070 super显卡。软件环境基于64位Ubuntu 18.04操作系统。以上配置确保了实验过程的顺利以及实验结果的可靠性。

### 3.2 基线模型与评估指标

为了更加全面地评估GeoKE-MTL的性能，将本文模型与多种先进模型进行比较：命名实体识别领域先进模型基于Transformer的双向编码器表征-双向长短期记忆网络-条件随机场（bidirectional encoder representations from transformers-bidirectional long short-term memory-conditional random field, Bert-BiLSTM-CRF）<sup>[34]</sup>；多任务学习领域的多种先进模型稳健优化的BERT预训练多任务学习（robustly optimized BERT pretraining approach + multi-task learning, RoBERTa + MTL）模型<sup>[35]</sup>、多任务深度神经网络（multi-task deep neural network, MT-DNN）<sup>[36]</sup>以及层级式多任务学习（hierarchical multi-task learning, HMTL）模型<sup>[37]</sup>；近几年交通事件检测领域中取得优秀表现的成熟模型，如在线隐狄利克雷分配+双向长短期记忆网络（online latent Dirichlet allocation + bidirectional long short-term memory, OLDA+BiLSTM）<sup>[7]</sup>以及卷积神经网络-长短期记忆网络+核密度估计（convolutional neural network-long short-term memory + kernel density estimation, CNN-LSTM+KDE\*）模型<sup>[8]</sup>。

本节实验通过使用精确率（Precision）、召回率（Recall）、F1分数（F1-score）3个指标来衡量模型的表现<sup>[39]</sup>，其中TP表示真实为正类的文本实体被正确预测为正类的数量，FP表示真实为负类的文本实体被错误预测为正类的数量，FN表示真实为正类的文本实体被错误预测为负类的数量。

精确率是自然语言处理领域中衡量模型的文本识别性能的一个重要指标，它表示在所有预测为正类的文本实体中模型正确预测的实例比例。精确率的计算式为：

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (23)$$

召回率表示在所有真实为正类的文本实体中，

模型正确预测为正类的比例，其计算式为：

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (24)$$

F1 分数是精确率和召回率的调和平均数，用于综合评估模型性能，具体的计算式为：

$$\text{F1-score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (25)$$

### 3.3 对比实验

表1展示了GeoKE-MTL模型在自建数据集上与其他多个基线模型在事发地点识别与交通事件识别任务中的定量对比结果。由实验数据可知，相较于各类基线模型，GeoKE-MTL模型通过整合地理知识增强与多任务学习机制，在社交媒体交通事件检测任务中表现出显著综合优势。

在事发地点识别任务中，GeoKE-MTL模型精确率达78.48%、召回率达80.84%、F1分数达79.42%，较最优基线模型OLDA+BiLSTM（F1分数78.50%）和CNN-LSTM+KDE\*（F1分数78.41%）均有一定提升，且相较于传统的Bert-BiLSTM-CRF模型（F1分数67.59%）提升幅度达17.5%。在交通事件识别任务中，GeoKE-MTL模型的F1分数为79.75%，


与表现最优的基线模型MT-DNN（F1分数80.07%）基本持平，但明显优于其他模型。与最优基线模型相比，GeoKE-MTL模型在召回率（79.12%）与精确率（80.39%）之间取得了更佳平衡，显示出模型对正负样本的判别能力更稳健。

图2进一步展示了对比实验的可视化结果，从图2可以看出，GeoKE-MTL模型在两个任务中均表现出色。尽管在交通事件识别任务中GeoKE-MTL模型性能与最优基线模型性能相当，但对比最优基线模型，GeoKE-MTL模型在对比实验中的性能方差降低约15%，表明模型在噪声数据下具有更强的稳定性，这种稳健性的提升主要得益于跨任务注意力机制带来的信息互补，使模型抵抗非结构化文本对单一任务带来的噪声干扰能力更强。


上述性能的提升可归因于以下几个关键因素：首先，知识增强模块通过引入外部知识显著提高了本文模型对社交媒体中噪声数据的理解能力，尤其在位置识别任务中，知识增强方法帮助本文模型更好地理解文本中和交通事件地名有关的语义描述。其次，多任务学习架构促进了任务间协同优化，与

表1 本文方法和基线方法的指标对比

| 模型              | 事发地点识别性能  |        |        | 模型              | 交通事件识别性能  |        |        |
|-----------------|-----------|--------|--------|-----------------|-----------|--------|--------|
|                 | Precision | Recall | F1分数   |                 | Precision | Recall | F1分数   |
| Bert-BiLSTM-CRF | 67.14%    | 68.06% | 67.59% | Bert-BiLSTM-CRF | 78.16%    | 78.59% | 78.37% |
| RoBERTa + MTL   | 65.74%    | 70.79% | 68.17% | RoBERTa + MTL   | 78.30%    | 79.09% | 78.69% |
| MT-DNN          | 71.23%    | 73.05% | 72.13% | MT-DNN          | 81.65%    | 78.55% | 80.07% |
| HMTL            | 65.49%    | 66.28% | 65.88% | HMTL            | 74.97%    | 76.36% | 75.65% |
| OLDA+BiLSTM     | 79.17%    | 77.85% | 78.50% | OLDA+BiLSTM     | 79.15%    | 71.47% | 75.12% |
| CNN-LSTM+KDE*   | 77.50%    | 79.34% | 78.41% | CNN-LSTM+KDE*   | 79.74%    | 73.53% | 76.51% |
| GeoKE-MTL       | 78.48%    | 80.84% | 79.42% | GeoKE-MTL       | 80.39%    | 79.12% | 79.75% |



(a) 事发地点识别性能比较



(b) 交通事件识别性能比较

图2 事发地点与交通事件识别性能比较可视化

单任务模型相比，多任务框架的底层共享表示和跨任务交互机制充分利用了不同任务之间的内在关联，提高了本文模型的泛化能力和资源利用效率。此外，动态权重机制确保了训练过程的均衡性，避免了某一任务主导优化过程，进一步提升了整体性能。这些因素的协同作用，不仅解决了现有方法在地理信息提取和任务孤立方面的局限，还在实验中体现了显著的量化优势。

### 3.4 模型计算复杂度与时间代价分析

#### (1) 模型复杂度计算

本文模型由知识增强与多任务学习两个部分组成，这种设计可能增加了模型的复杂度和时间代价，因此本文对 GeoKE-MTL 模型的计算复杂度进行了详细的理论分析。其中模型整体复杂度主要来源于以下几个部分。

模型的编码层采用预训练 BERT 模型，其复杂度为  $O(n^2 \cdot d)$ ，其中  $n$  为输入序列长度， $d$  为隐藏层维度。这是模型计算复杂度增加的主要部分，与标准的 Transformer 架构基本一致。知识增强部分包含动态门控融合机制，计算复杂度为  $O(n \cdot d^2)$ 。其中知识检索基于高效的 Trie 树匹配算法，时间复杂度仅为  $O(n \cdot L)$ ， $L$  为平均实体长度，对整体计算开销影响较小。不同任务的特定编码层部分，NER 任务采用单层 BiLSTM，复杂度为  $O(n \cdot d^2)$ ；事件抽取任务采用双层 BiLSTM 结合自注意力机制，复杂度为  $O(2 \cdot n \cdot d^2 + n^2 \cdot d)$ 。跨任务注意力层部分采用双向交叉注意力机制，复杂度为  $O(2 \cdot n^2 \cdot d)$ 。输出预测层部分，NER 输出层复杂度为  $O(n \cdot d \cdot C)$ ，其中  $C$  为 NER 标签数量；事件输出层采用注意力池化和多层分类器，复杂度为  $O(n \cdot d^2)$ 。

综合上述分析，当处理社交媒体文本时，由于隐藏层维度  $d$  为固定值， $n^2$  在复杂度中占主导地位，GeoKE-MTL 模型的整体复杂度近似为  $O(n^2 \cdot d + n \cdot d^2)$ 。与其他基线模型相比，Bert-BiLSTM-CRF 的复杂度为  $O(n^2 \cdot d + n \cdot d^2)$  量级，MT-DNN 等多任务模型的复杂度同样为  $O(n^2 \cdot d + n \cdot d^2)$  量级，表明 GeoKE-MTL 模型在引入知识增强和跨任务交互机制的同时，保持了与主流多任务学习模型相当的计算复杂度。

#### (2) 时间损耗分析

在时间效率方面，由图3可以看出，本文模型的训练时间和推理速度与其他多任务基线模型基本处于同一水平，尽管模型引入了知识增强模块与跨任务注意力层等额外组件，但通过合理的结构设计及并行计算优化，其训练总时间为 1 025 s，介于 RoBERTa+MTL 与 HMTL 之间，优于 MT-DNN。在推理效率方面，GeoKE-MTL 模型的单样本推理时间为 38.4 ms，吞吐量为 28 Sa/s，略优于 RoBERTa+MTL，显著优于 MT-DNN，表明模型在保持高性能的同时，具备良好的实时处理能力。

这种效率表现得益于模型在实现上的优化，知识检索阶段采用高效的 Trie 树结构，门控融合机制与跨任务注意力层均设计为轻量级模块，并通过 GPU 并行计算有效降低了额外开销。总体而言，GeoKE-MTL 模型在计算复杂度与时间代价之间取得了良好平衡，具备实时部署的潜力。

### 3.5 消融实验

为了验证 GeoKE-MTL 模型中各关键组件在不同任务下的有效性，本文逐一去除模型中的特定模块进行消融实验，通过观察模型在事发地点识别和交通事件识别两个任务上的性能变化，从而量化每个组件的独立影响。本节实验去除的组件包括：知识增强模块（w/o KE），该模块负责注入地理领域知识以处理模糊位置信息；跨任务注意力层（w/o CTA），该层促进实体识别与事件抽取间的双向信息交互；动态权重机制（w/o DW），该机制在训练中动态调整各任务的损失权重以实现平衡优化。所有消融变体在相同数据集、硬件环境和超参数设置下重新训练和评估，使用精确率、召回率和 F1 分数作为评价指标，以全面反映模型的准确性和完整性。

由图4可见，事发地点识别任务主要依赖于地理信息的精确提取，因此知识增强模块对该任务的影响较大。而交通事件识别任务更注重整体语境捕捉，因此跨任务交互机制的作用更显著。通过消融实验结果图，可以更加直观地比较完整模型与各消融变体的性能差异。此外，通过对比图3和图4可以看出，在事发地点识别任务中，完整模型的 F1 分数显著高于其他基线模型，而消融变体则接近或低于这些基线，这种现象表明消融后的模型性能退化到了基线水平，证明了模型中的关键组件对于模型性能提升的重要性。




图3 各模型训练时间损耗对比




图4 事发地点识别任务及交通事件识别任务消融实验结果

### 3.6 真实场景识别效果分析

为了验证本文模型对真实场景社交媒体文本的理解与识别能力,本节选取了部分涵盖不同语言特征的未训练微博文本数据进行案例分析,并展示了

6种不同特征类别文本的识别效果,见表2。

本文模型对于结构化或非结构化文本表现出了精准的识别能力,本文构建的知识增强模块能够有效匹配和注入交通领域实体知识,而多任务学习架

表2 案例识别结果

| 文本类型   | 文本内容               | 识别结果           |
|--------|--------------------|----------------|
| 结构化文本  | 上海延安东路隧道一如既往堵      | 交通拥堵,延安东路隧道    |
| 结构化文本  | 早高峰路况内环南浦大桥至鲁班立交事故 | 交通事故,南浦大桥至鲁班立交 |
| 地理信息残缺 | 张江真堵还堵绕路还堵         | 交通拥堵,张江路       |
| 非结构化文本 | 擦水产路宝杨路堵           | 交通拥堵,水产路,宝杨路   |
| 无关文本   | 早上起来心里堵得慌          | 无,无            |
| 语义模糊文本 | 南浦大桥成停车场           | 无,无            |

构确保了事件类型与地理位置信息的协同准确抽取。在面对地理信息残缺文本时, 本文模型展现出一定的语义推理和泛化能力, 在“张江真堵还堵绕路还堵”这条文本中, 本文模型成功匹配并补全事发地点“张江路”, 验证了知识增强对于缓解信息模糊的积极作用。

但是本文模型对于深层语义和隐含逻辑的理解上仍存在局限性, 对于“南浦大桥成停车场”这条文本, 模型未能识别出其隐喻的交通拥堵事件, 此类文本的稀疏和隐晦的表达方式导致了识别失败, 表明模型在深层次语义理解方面仍有提升空间。

## 4 结束语

本文针对社交媒体文本非结构化、地理信息模糊及传统模型任务协同不足的问题, 提出融合地理知识增强与多任务学习的交通事件检测模型, 实验结果验证了模型对社交媒体数据中交通事件信息识别的有效性。交通事件实时检测作为智能交通系统的重要组成部分, 其识别准确性和高效率至关重要。

然而, 本文也存在一定局限性。首先, 实验所使用的数据集规模有限且时间跨度较小, 未能充分涵盖当前社交媒体中新兴的表达方式以及多样化的复杂交通事件场景。此外, 模型的可扩展性尚未在实时数据流和大规模处理环境中得到充分验证, 计算资源需求仍需进一步优化, 以适配实际应用中的部署需求。

未来研究可从以下方面展开改进: 扩展数据集规模, 纳入近期、多样化的社交媒体数据, 覆盖多城市、多平台及多语言场景; 探索多模态数据的融合, 整合文本、图像、交通传感器等多源数据, 进一步提升交通事件检测的细粒度与识别准确性; 优化模型架构以更好地适配实时数据流和高流量处理场景, 例如通过边缘计算或硬件加速实现低延迟处理<sup>[38-41]</sup>。上述改进方向可有效提升模型的实用价值与泛化能力。

## 参考文献:

- [1] Global status report on road safety 2023[R]. 2023.
- [2] SUAT-ROJAS N, GUTIERREZ-OSORIO C, PEDRAZA C. Extraction and analysis of social networks data to detect traffic accidents[J]. *Information*, 2022, 13(1): 26.
- [3] 陈苑文, 王晓, 李灵犀, 等. 基于社交媒体数据增强的交通态势感知研究及进展[J]. *智能科学与技术学报*, 2022, 4(1): 1-13.  
CHEN Y W, WANG X, LI L X, et al. Traffic situational awareness re-
- search and development enhanced by social media data: the state of the art and prospects[J]. *Chinese Journal of Intelligent Science and Technology*, 2022, 4(1): 1-13.
- [4] WU Y L, CHEN Y J, ZHANG R Y, et al. A spatial information extraction method based on multi-modal social media data: a case study on urban inundation[J]. *ISPRS International Journal of Geo-Information*, 2023, 12(9): 368.
- [5] ZHU R X, LIN D, JENDRYKE M, et al. Geo-tagged social media data-based analytical approach for perceiving impacts of social events[J]. *ISPRS International Journal of Geo-Information*, 2019, 8(1): 15.
- [6] DU Q C, XU L L, WU Q, et al. SafeCrossNet: multi-modal fusion with social-aware for pedestrian crossing intention prediction[J]. *Information Fusion*, 2026, 126: 103609.
- [7] ALI F, ALI A, IMRAN M, et al. Traffic accident detection and condition analysis based on social networking data[J]. *Accident Analysis & Prevention*, 2021, 151: 105973.
- [8] CHANG H L, LI L S, HUANG J X, et al. Tracking traffic congestion and accidents using social media data: a case study of Shanghai[J]. *Accident Analysis & Prevention*, 2022, 169: 106618.
- [9] WANG D, AL-RUBAIE A, CLARKE S S, et al. Real-time traffic event detection from social media[J]. *ACM Transactions on Internet Technology*, 2018, 18(1): 1-23.
- [10] MELHEM W, ABDI A, MEZIANE F. Traffic detection and forecasting from social media data using a deep learning-based model, linguistic knowledge, large language models, and knowledge graphs[C]//*Proceedings of the 16th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management. Setcibal: SCITEPRESS - Science and Technology Publications*, 2024: 235-242.
- [11] BOK K, KIM I, LIM J, et al. Efficient graph-based event detection scheme on social media[J]. *Information Sciences*, 2023, 646: 119415.
- [12] SALAS A, GEORGAKIS P, NWAGBOSO C, et al. Traffic event detection framework using social media[C]//*Proceedings of the 2017 IEEE International Conference on Smart Grid and Smart Cities (ICSGSC)*. Piscataway: IEEE Press, 2017: 303-307.
- [13] KOLAJO T, DARAMOLA O, ADEBIYI A A. Real-time event detection in social media streams through semantic analysis of noisy terms[J]. *Journal of Big Data*, 2022, 9(1): 90.
- [14] ZHANG Z H, HE Q, GAO J, et al. A deep learning approach for detecting traffic accidents from social media data[J]. *Transportation Research Part C: Emerging Technologies*, 2018, 86: 580-596.
- [15] HODOROG A, PETRI I, REZGUI Y. Machine learning and natural language processing of social media data for event detection in smart cities[J]. *Sustainable Cities and Society*, 2022, 85: 104026.
- [16] JONNALAGADDA J, HASHEMI M. A deep learning-based traffic event detection from social media[C]//*Proceedings of the 2021 IEEE 22nd International Conference on Information Reuse and Integration for Data Science (IRI)*. Piscataway: IEEE Press, 2021: 1-8.
- [17] AFYOUNI I, KHAN A, AL AGHBARI Z. Deep-Eware: spatio-temporal social event detection using a hybrid learning model[J]. *Journal of Big Data*, 2022, 9(1): 86.
- [18] YANG X Y, BEKOULIS G, DELIGIANNIS N. Traffic event detection as a slot filling problem[J]. *Engineering Applications of Artificial Intelligence*, 2023, 123: 106202.
- [19] YANG L, WANG Y, PAN Z, et al. Multi-task feature selection based anomaly detection[J]. *arXiv preprint*, 2014, arXiv:1403.4017.
- [20] DENG D X, SHAHABI C, DEMIRYUREK U, et al. Situation aware multi-task learning for traffic prediction[C]//*Proceedings of the 2017*

- IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2017: 81-90.
- [21] CHEN Q, WANG W, HUANG K Z, et al. Multi-modal generative adversarial networks for traffic event detection in smart cities[J]. Expert Systems with Applications, 2021, 177: 114939.
- [22] LI J, LI J, GONG Y J. Multi-task learning for sparse traffic forecasting[J]. arXiv preprint, 2022, arXiv:2211.09984.
- [23] ZHANG H W, QIAN S S, FANG Q, et al. Multi-modal meta multi-task learning for social media rumor detection[J]. IEEE Transactions on Multimedia, 2021, 24: 1449-1459.
- [24] LIU Y Q, GAO Y F, ZHANG Q C, et al. Multi-task safe reinforcement learning for navigating intersections in dense traffic[J]. Journal of the Franklin Institute, 2023, 360(17): 13737-13760.
- [25] ZHUANG L, FEI H, HU P. Knowledge-enhanced event relation extraction via event ontology prompt[J]. Information Fusion, 2023, 100: 101919.
- [26] HU F F, ZHANG S T, LIN X B, et al. Network traffic classification model based on attention mechanism and spatiotemporal features[J]. EURASIP Journal on Information Security, 2023, 2023(1): 6.
- [27] 覃缘琪, 季青原, 葛俊, 等. 城市交通路网动态短时推理与精准预测研究[J]. 智能科学与技术学报, 2022, 4(3): 380-395.
- QIN Y Q, JI Q Y, GE J, et al. Short-term traffic state reasoning and precise prediction in urban networks[J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(3): 380-395.
- [28] ADNAN K, AKBAR R. An analytical study of information extraction from unstructured and multidimensional big data[J]. Journal of Big Data, 2019, 6(1): 91.
- [29] LIU L, YU Y J, WU Y F, et al. Method for multi-task learning fusion network traffic classification to address small sample labels[J]. Scientific Reports, 2024, 14: 2518.
- [30] 王晓, 杨林瑶, 胡斌, 等. 平行推理: 一种基于 ACP 方法的虚实互动的知识协同框架[J]. 智能科学与技术学报, 2023, 5(1): 69-82.
- WANG X, YANG L Y, HU B, et al. Parallel reasoning: a virtual-real interactive knowledge collaboration framework based on ACP approach[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(1): 69-82.
- [31] MREDULA M S, DEY N, RAHMAN M S, et al. A review on the trends in event detection by analyzing social media platforms' data[J]. Sensors, 2022, 22(12): 4531.
- [32] PUTRA P K, MAHENDRA R, BUDI I. Traffic and road conditions monitoring system using extracted information from Twitter[J]. Journal of Big Data, 2022, 9(1): 65.
- [33] 李炎英, 王新宇, 王晓, 等. 基于大语言模型的交通异常事件检测与辅助决策[J]. 智能科学与技术学报, 2024, 6(3): 347-355.
- LI Y Y, WANG X Y, WANG X, et al. Traffic anomaly event detection and auxiliary decision-making based on large language models[J]. Chinese Journal of Intelligent Science and Technology, 2024, 6(3): 347-355.
- [34] TANG W, ZHANG Y, MAO X, et al. Enhanced named entity recognition and event extraction for power grid outage scheduling using a universal information extraction framework[J]. Energies, 2025, 18(14): 3617.
- [35] LIU Y, DU J, GOYAL N, et al. Roberta: a robustly optimized bert pre-training approach[J]. arXiv preprint, 2019, arXiv:1907.11692.
- [36] LIU X, HE P, CHEN W, et al. Multi-task deep neural networks for natural language understanding[J]. arXiv preprint, 2019, arXiv:1901.11504.
- [37] SANH V, WOLF T, RUDER S. A hierarchical multi-task approach for learning embeddings from semantic tasks[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 6949-6956.
- [38] DU Q C, WANG X, YIN S G, et al. Social force embedded mixed graph convolutional network for multi-class trajectory prediction[J].

IEEE Transactions on Intelligent Vehicles, 2024, 9(9): 5571-5580.

- [39] XU S S, LI S N, HUANG W, et al. Detecting spatiotemporal traffic events using geosocial media data[J]. Computers, Environment and Urban Systems, 2022, 94: 101797.
- [40] WANG X, HUANG J, TIAN Y L, et al. Parallel driving with big models and foundation intelligence in cyber-physical-social spaces[J]. Research, 2024, 7: 349.
- [41] 杜泉成, 王晓, 李灵犀, 等. 行人轨迹预测方法关键问题研究: 现状及展望[J]. 智能科学与技术学报, 2023, 5(2): 143-162.
- DU Q C, WANG X, LI L X, et al. Key problems and progress of pedestrian trajectory prediction methods: the state of the art and prospects[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(2): 143-162.

## [作者简介]



周正 (2000- ), 男, 安徽大学人工智能学院硕士生, 主要研究方向为智能交通系统、自然语言处理、深度学习。



汪玫 (2005- ), 女, 安徽大学人工智能学院本科生, 主要研究方向为交通事件预测、机器学习。



杨林瑶 (1995- ), 男, 之江实验室副研究员, 主要研究方向为知识图谱、知识增强大模型等。



李莉芳 (1989- ), 女, 中山大学新闻传播学院副教授, 主要研究方向为应急信息传播、应急管理、谣言治理。



王晓 (1988- ), 女, 安徽大学人工智能学院教授, 主要研究方向为社会计算、群体行为建模、无人自主系统及其平行测试。