引文格式:何捷,王超群,潘伟江,等.从专用模型到通用模型驱动的范式升级:GeoAI研究综述与展望[J].武汉大学学报(信息科学版),2026,51(8):1700-1724.DOI:10.13203/j.whugis20260025

Citation: HE Jie, WANG Chaoqun, PAN Weijiang, et al. From Task-Specific Models to General-Purpose Model-Driven Paradigm Shift: A Review and Future Directions of GeoAI Research[J]. Geomatics and Information Science of Wuhan University, 2026, 51(8):1700-1724.DOI:10.13203/j.whugis20260025

从专用模型到通用模型驱动的范式升级:GeoAI研究综述与展望

何 捷[1] 王超群[1] 潘伟江[2] 徐 欣[2]

1 哈尔滨工业大学(深圳)建筑学院,广东 深圳,518055

2 广东省建筑设计研究院集团股份有限公司,广东 广州,510010

摘 要:随着地理空间数据的爆炸式增长与人工智能(artificial intelligence,AI)技术的快速发展,地理空间AI(geospatial AI,GeoAI)已逐渐从依赖特定任务专用模型的传统范式,演进至以预训练与大模型等通用模型为核心的新范式。及时系统梳理该领域的研究进展与范式演变,对于把握GeoAI领域前沿动态具有重要意义。已有研究虽从多个细分领域对GeoAI的应用进行了回顾,但未结合技术迭代脉络,全景式梳理从深度学习模型、预训练模型到大模型阶段的完整发展变革历程。因此,亟需构建系统性的综述分析框架,全面阐释AI技术迭代下GeoAI的研究脉络、技术进展与未来挑战。基于对172篇代表性领域文献的分析,首先依据模型是否专为地理任务训练,将GeoAI研究划分为专用模型驱动与通用模型驱动两大类;进而依据建模目标与技术路径进行二次细分,总结各细分方向的核心进展与局限。分析结果表明,专用模型驱动的研究在时空规律挖掘、属性推断、构型优化等任务中已形成成熟的技术体系,但其任务迁移性与泛化能力有限;通用模型驱动的研究正呈现从空间嵌入、多模态对齐到大模型集成应用的演进趋势,展现出更强的多任务适应与知识迁移潜力;以大模型作为"智能中枢"来协同专用模型及人类专家知识、推动大模型实现从表层特征感知到深层空间认知的跨越,是未来的重要方向。综上,通过呈现从深度学习时代到大模型时代的GeoAI研究图景,帮助研究者快速把握该领域的发展全貌,为后续研究提供参考与启示。

关键词:GeoAI;大语言模型;知识图谱;人工智能;地理空间大数据;研究进展;时空语义

中图分类号:P208 **文献标识码**:A **收稿日期**:2026-01-16

DOI:10.13203/j.whugis20260025 **文章编号**:1671-8860(2026)08-1700-25

From Task-Specific Models to General-Purpose Model-Driven Paradigm Shift: A Review and Future Directions of GeoAI Research

HE Jie[1] *WANG Chaoqun*[1] *PAN Weijiang*[2] *XU Xin*[2]

1 School of Architecture, Harbin Institute of Technology (Shenzhen), Shenzhen 518055, China

2 Guangdong Architectural Design and Research Institute Group Co., Ltd., Guangzhou 510010, China

Abstract: **Objectives**: Geospatial artificial intelligence (GeoAI) is an interdisciplinary discipline formed by the in-depth integration of geospatial science and artificial intelligence (AI). Leveraging cutting-edge AI technologies and integrating geospatial big data with high-performance computing methods, it has profoundly revolutionized traditional spatial analysis approaches that rely heavily on GIS platforms and statistical methods. With the continuous iteration of AI technologies, GeoAI is undergoing profound paradigm transformation, shifting from the conventional paradigm driven by task-specific models to an emerging general-purpose model paradigm centered on pre-trained models and large models. Nevertheless, existing

基金项目:基于空间人文大数据的城市历史文化街区保护活化平台研究项目;国家自然科学基金(52478049);哈尔滨工业大学深圳校区新引进高精尖缺人才科研启动经费项目(ZX20230488)。

第一作者:何捷,博士,教授,研究方向为城市计算、时空语义挖掘、数字人文。hejie2021@hit.edu.cn

通信作者:王超群,博士生。23B956007@stu.hit.edu.cn

review studies fail to cover the complete evolutionary trajectory of the GeoAI domain and lack a unified analytical framework. Therefore, it is imperative to clarify the evolutionary context of this field, summarize the disparities among technical pathways, and systematically consolidate state-of-the-art advances and development trends, so as to provide solid theoretical and methodological support for future research. **Methods**: In terms of research methodology, this study first adopts the "model-driven paradigm" as the primary classification criterion and divides existing literature into two major research branches: task-specific model-driven and general-purpose model-driven frameworks. Secondary classification is further conducted based on modeling objectives and model application patterns. A seed literature database is established on the basis of previous reviews, followed by the formulation of retrieval strategies and systematic screening of core literature. Ultimately, a total of 172 representative Chinese and English publications published since 2019 are analyzed. The proposed classification system is adopted to systematically summarize the typical modeling frameworks, application scenarios, and comparative advantages of each research branch. **Results**: The research findings reveal the progress of two sub-branches within task-specific model-driven GeoAI research:First, research on spatiotemporal geographic knowledge graphs remains relatively limited, primarily owing to the dominant position of deep learning paradigms in the previous technological revolution. Early studies predominantly focused on the structured representation of geographic knowledge. The emergence of knowledge graph embedding (KGE) techniques and large language models has revitalized this domain. KGE enables the conversion of spatiotemporal geographic knowledge into machine-interpretable and computationally feasible vector representations, which effectively facilitates fine-tuning and knowledge enhancement for pre-trained and large models. It thereby serves as a critical bridge connecting structured geographic knowledge and data-driven models. Second, end-to-end deep learning models have developed into a sophisticated and mature technical system, covering five core tasks: spatiotemporal pattern mining, continuous indicator prediction, discrete label inference, spatial configuration generation, and visual semantics-assisted socioeconomic factor estimation. Although such models have achieved high accuracy and stability in previous development stages, they are still constrained by weak task transferability, insufficient cross-scene generalization capability, and excessive costs of repetitive modeling.General-purpose model-driven GeoAI research demonstrates a distinct evolutionary path alongside the iterative advancement of AI technologies: Prior to the widespread application of large models in GeoAI, spatial embedding research emerged as the earliest research direction, with a current developmental trend toward multi-modal embedded information aggregation. Universal spatiotemporal prediction models share similar paradigms yet achieve integrated spatiotemporal modeling within a unified framework. Supported by cross-city pre-training strategies, these models substantially enhance cross-domain transferability. Different from the static embedding characteristics of spatial embedding models, they focus more on addressing dynamic urban spatial issues. Compared with the previous two types, pre-trained models with geospatial-multimodal semantic alignment are more applicable to a broader range of geospatial tasks. They realize the underlying fusion of geographic, textual and visual information, eliminating intermediate spatial embedding procedures and exhibiting superior adaptability to complex spatial analysis tasks.Current GeoAI research integrated with large models mainly adopts mainstream strategies for geographic task adaptation, including lightweight fine-tuning, prompt learning, tool invocation and agent-based architectures. Meanwhile, unified evaluation frameworks are being constructed to quantify the performance of general large models in geospatial tasks. Despite the remarkable operational convenience and performance potential demonstrated by large model-enabled GeoAI, prominent challenges persist, such as deficient spatial reasoning capability, inherent geographic bias, and limited capacity for complex geographic computation. **Conclusions**: In conclusion, GeoAI has accomplished a comprehensive paradigm upgrade from task-specific models to general purpose models, with transferability, generalizability and interactivity emerging as the core development priorities. Future research should further promote the in-depth

application of large models, shifting the research focus from conventional feature extraction and pattern recognition to high-level geographic knowledge comprehension, spatial reasoning and intelligent decision-making. It is essential to construct a next-generation GeoAI ecosystem that takes large models as the intelligent hub and achieves deep integration and collaborative collaboration with knowledge graphs, task-specific models and human expertise. Furthermore, the robust logical reasoning and cognitive capabilities of large models should be fully exploited to empower innovative geographic research.

Key words: GeoAI; large language model; knowledge graph; artificial intelligence; geospatial big data; research progress; spatiotemporal semantics

在数字化浪潮推动下,地球系统衍生的空间大数据(spatial big data,SBD)呈现指数级增长,具备体量大(Volume)、多样性高(Variety)、更新快(Velocity)及价值密度低(Veracity)的典型大数据特征[1-4],为挖掘城市系统动态演变、人群空间行为模式、人类城市空间感知等经典城市任务提供了高效支撑[2]。在过去,这些任务主要依托ArcGIS等地理信息系统(geographic information system,GIS)平台的空间分析工具结合统计建模等手段来实现。但面对当前PB级规模的异构时空数据,传统GIS方法无法高效、精准地完成庞大数据的处理与分析,也较难应对多模态融合与推理预测任务[5]。地理空间人工智能(geospatial artificial intelligence,GeoAI)作为一种新兴研究范式,将人工智能(artificial intelligence,AI)技术融入地理空间分析,变革了传统依赖GIS平台和统计学的空间分析方法。这一变革始于面向特定地理任务专门训练的模型,本文将其界定为“专用模型”。近年来,随着预训练技术范式的成熟、扩展定律的发现以及大模型实现跨越式发展,GeoAI进一步经历了范式升级。与传统方法相比,当今的GeoAI不仅显著提升了数据密集型任务的处理效能[6-7],还具备知识密集型推理与决策能力[8],具体体现在多模态深度空间理解[9]、高级认知推理和跨尺度知识迁移泛化[8]等方面。

结合AI里程碑式技术突破作为时间分界,GeoAI的发展可大致划分为3个阶段,各阶段AI与地理空间学科的融合特点有所不同。

第一个阶段为深度学习技术兴起(约2012年)之前,已有少数将AI技术用于解决空间问题的研究,例如CLARKE等[10]、BATTY等[11]基于元胞自动机进行城市扩张模拟,CHOI等[12]、LEARY等[13]构建了早期城市专家系统,HART等[14]运用启发式算法进行路径规划优化。然而,这类传统方法在刻画地理过程的时空特性方面存在明显局限性。

第二个阶段为2012年前后,本体论、语义网的知识图谱技术被谷歌开发;以图卷积网络(graph convolutional networks,GCN)为代表的时空深度学习框架被提出[15],AI迎来新一轮研发热潮,迅速渗透到其他学科。在此背景下,2015年前后就出现了融合AI模型的空间科学研究[15],但GeoAI作为专业术语被提出,最早见于2017年ACM SIGSPATIAL首次举办的GeoAI主题研讨会论文集。直到2019年,随着更多文章的发表,GeoAI才受到广泛认可。

第三个阶段以2018年Transformer架构的提出为起点。以基于Transformer的双向编码器表示(bidirectional encoder representations from Transformers,BERT)为代表的预训练语言模型验证了“预训练-微调”范式在大规模语言理解任务中的有效性,为大模型的研发面世奠定了方法基础。与此同时,OpenAI通过一系列系统性研究揭示了模型性能与参数量、数据规模及计算资源的扩展规律,推动大模型进入以Scaling Law为理论指导的规模扩展时代。2020年GPT-3的诞生标志着大模型时代正式来临,其延续并拓展了预训练模型的技术路径,实现了从任务适配到通用能力的范式跃迁。而2022年ChatGPT的开放应用,则标志着基础模型技术走向大众化与工具化,使研究者能够便捷地将此类模型集成至科学分析流程中。随着高性能多模态大模型接连涌现,GeoAI的方法论体系也正在以预训练与基础模型为核心,经历着新一轮系统性重构[8]。

综上,由于GeoAI类研究的话题广泛、范式众多且发展飞速,及时、全面且系统地梳理GeoAI研究成果面临诸多挑战:如何形成对GeoAI定义与范畴的统一认识?如何构建一个具有包容性和扩展性的认知框架,从而能够有效归类不断涌现的新方法与新主题?以及如何及时、客观地评估不同技术路径的适用性与局限性,进而为该领域的知识体系构建提供前瞻性指导?

对于第一个挑战,学者们从农业科学[16]、公共卫生[17]、自然地理[18]、人文地理[18]、智慧城市[19]、城市规划[20]等多个学科的角度出发,证实GeoAI的广

泛应用范畴。高松[15]、OUCHRA等[19]、LI等[21]对GeoAI的定义有诸多探讨,通过借鉴前人观点,本文将其定义为:地理空间科学与AI深度融合的交叉学科研究领域,核心在于借助前沿AI技术,整合地理空间大数据与高性能计算手段,以此增强对地理现象及地球科学过程的动态感知、智能推理与知识发现能力,进而有效解决数据密集型或计算密集型的地理空间问题。

对于第二个挑战,学界尚未形成统一的关于如何归类GeoAI研究的共识。其中一个重要的概念是JANOWICZ等[6]提出的空间显式GeoAI,旨在构建AI模型的过程中把地理空间位置和空间约束也纳入AI模型的建模中,满足以下至少一项特征:(1)研究对象的空间位置若发生变换,空间显式模型的结果会不同;(2)空间显式模型包含所研究变量的空间表征结果,可以是地理坐标、空间关系、地名等形式;(3)空间显式模型在概念化和公式化中明确引入空间概念;(4)输入和输出都包含某种空间结构且不相同。

在明确空间显式与空间非显式GeoAI的区别后,许多学者遵循这一分类标准,针对空间显式类GeoAI研究进行了回顾[6,15,22-23],将其研究方向总结为空间位置嵌入[15]、城市动态扩张[22]、城市空间隔离[22]、地理文本挖掘与社会感知[15,22]、遥感与对地资源监测[15]、地理问答系统[6]。文献[21]基于建模逻辑的差异,将GeoAI研究划分为知识驱动型(自上而下的规律挖掘)和数据驱动型(自下而上的知识推理)两类,或文献[24]称之为符号主义和联结主义,是借助AI领域长期存在的两大方法论范式进行的分类。在符号主义GeoAI方面,陆峰等[25]对地理知识图谱做了综述,可分为知识获取、知识表达和知识推理方向。联结主义GeoAI方面的研究呈现出数量优势[15,23,26]:SONG等[26]将机器学习、深度学习等模型在地理学领域的应用分为了建筑物和基础设施的目标识别、土地利用识别、社会感知与人类活动;QIN等[27]针对GeoAI在社会感知领域的应用进行展开,包括物理空间的社会属性、能源问题感知、空间的情感和行为嵌入。

对于第三个挑战,有一些学者从不同的角度为GeoAI未来发展提出建议,刘瑜等[28]认为GeoAI需要警惕地理异质性、规律普适性和可复现性之间的矛盾。程涛等[29]从技术实现角度倡议以图结构来进行时空智能分析。SANCHEZ等[20]不仅回顾了GeoAI领域的相关成果,还使用问卷调查的形式评估了城市规划从业者对于GeoAI技术的理解程度和评估GeoAI应用于特定规划任务(例如社区规划、交通分析等问题)的合理程度,指出当前GeoAI技术离规划实践应用还有一定距离。

总的来说,当前系统梳理GeoAI工作面临的挑战并未完全解决且还在持续变化。国外已较早开始了GeoAI的综述工作,但国内相关综述仍较少。AI技术发展的3个阶段技术突破,推动该领域经历了从以为特定地理任务而训练的专用模型为主导,转向以预训练模型及大模型为基础、支持灵活任务适配的范式变革。基于此,本文用“模型驱动范式”作为首要分类维度,将现有研究划分为专用模型驱动与通用模型驱动两大脉络;其次以建模目的和模型使用方式进一步进行二次分类。通过对GeoAI领域研究展开系统性梳理,本文旨在为学界进一步借助AI技术深化地理学研究提供参考与支持。

1　综述研究方法

本文基于层级分类框架对GeoAI研究进行梳理:首先依据所构建或使用的模型是否为地理空间任务专门训练,将现有GeoAI研究划分为两大范式——专用模型驱动的GeoAI与通用模型驱动的GeoAI。其中,专用模型驱动的GeoAI类研究是为特定地理任务进行全流程建模的研究;通用模型驱动的GeoAI类研究,其构建或使用的模型不是专为某项任务而设计的,需经过适配操作方能应用于地理空间任务,但具备多任务迁移能力。两者概念的辨析见表1。

在此基础上,本文进一步对上述两大范式进行二次分类。在专用模型驱动的GeoAI类研究中,根据模型构建目标与技术范式,划分为以结构化组织知识为目标、以知识图谱为主要技术范式的时空地理知识图谱相关研究,和从海量数据中提取潜在映射关系、以深度学习为主要技术范式的端到端深度学习建模相关研究[30-33]。在通用模型驱动的GeoAI类研究中,则根据所构建或使用通用模型的类别,划分为使用预训练模型的研究和使用大模型的研究。在这些二级分类之下,关注每个分类下的具体研究话题[34]进行详细分析与总结。

本文采取以下策略来进行文献的检索与筛选:

1)精读收集的18篇GeoAI综述类文章,首先形成技术与目标双重维度的关键词表。对综述中提及的代表性工作进行整理归类,初步形成小范围种子文献库。

2)在Web of Science、Google Scholar、中国知网

表1 专用模型和通用模型概念辨析

Table 1 Conceptual Differentiation Between Task-specific and General-Purpose Models

对比维度	专用模型驱动的GeoAI	通用模型驱动的GeoAI
定义	为特定地理空间任务进行全流程设计、训练和优化的模型	所构建或使用的模型没有特定的专用任务,但能够通过适配手段匹配于各类地理空间任务
目标	追求在特定任务上达到最优性能	追求模型的适配性与多地理空间任务的可迁移性,也追求通过适配后在特定任务上达到最优性能
典型算法或模型	知识图谱、图神经网络、卷积神经网络	BERT、CLIP等经典预训练模型;ChatGPT、LLaMA等大模型
在地理领域的典型应用	基于街景图像的建筑分类模型、人群移动预测模型、车流量预测模型	空间嵌入模型、大模型对某项任务的微调、通用城市时空预测模型
优势	面向不同任务的可迁移能力较弱,任务性能强	面向多地理空间任务的可迁移能力强;若仅对模型进行适配,则对标注数据依赖较少
局限性	针对性强,但任务可迁移性弱;依赖大量标注数据;针对不同任务,需要重新设计和训练	预训练阶段对数据的要求较高;计算资源消耗大;特定任务的表现可能不如专用模型,且需要适配,实现zero-shot较难

注:CLIP (contrastive language-image pre-training):对比式语言-图像预训练;LLaMA(large language model Meta AI):Meta AI大规模语言模型。

等权威学术平台开展模糊检索。首先以“GeoAI”结合“城市规划”“城市计算”“地理信息科学”等领域词为关键词进行检索,能够检索到较多综述类文献和实证类文献,但存在部分直接以具体技术名词命名的实证类文献缺失的问题。然后通过“GeoAI”一词和目标类关键词的组合进行检索,或使用空间、时空、城市等作为前缀加技术类关键词进行检索,尽可能全面地覆盖不同程度上可被归属于GeoAI类的文献。此外,为确保研究的时效性,主要针对2019年及以后的成果进行收录。

3)通过上述策略,初步得到文献640篇,呈现逐年增长的趋势(图1)。筛选标准如下:(1)研究需以AI技术为核心方法,应用于城市或区域等空间尺度问题;(2)优先选取方法具有代表性、内容创新性强且重复度较低的文献;(3)文献应发表于同行评议期刊或重要会议。经逐一阅读摘要与全文筛选,最终选取172篇文献构成分析样本,用于后续系统综述。

本文将按照图2的方式进行组织。



注:由于成文时间原因,2025年发文量数据可能偏少。

图1 近年发文量趋势图

Fig. 1 Trend Chart of the Number of Publications in Recent Years

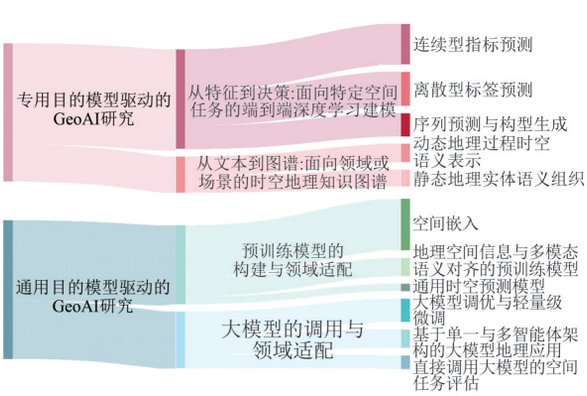


图2 文章脉络图

Fig. 2 Framework of Paper's Structure

2 专用模型驱动的GeoAI研究

专用模型驱动的GeoAI研究遵循从数据-建模-应用的研究范式。其中存在两种主要路径:一是对地理空间知识进行结构化建模,侧重于构建可解释、结构化的符号知识体系,目的为实现对地理空间认知的形式化、结构化表征;二是为特定地理空间任务训练的端到端模型,侧重于学习空间大数据背后的复杂规律和表示,目的为实现从数据到决策的自动化、高精度地理空间理解与预测。相应地,本节首先回顾了时空知识图谱类研究,面向特定地理空间领域知识或场景,然后回顾了为特定地理空间任务开发的端对端深度学习模型。

2.1 从文本到图谱:面向领域或场景的时空地理知识图谱

时空地理知识图谱是一种以图结构形式组织

和表达地理实体、概念及其之间语义与空间关系的数据模型[35],通过对网络文本、开放语义网、众包数据等多源异构地理信息进行抽取、对齐、融合与存储,将传统地理信息服务拓展为地理知识服务,例如地理信息相关语义理解、地理问答等。本节根据其知识组织本体的核心描述维度,将其分为静态语义抽取与建模和动态过程建模[25]。

2.1.1　基于实体-关系表示的静态地理实体语义组织

地理知识是人类对地理事物空间分布、演变规律和相互作用的认知体现,而地理知识图谱则是将这些知识进行结构化表达的系统[36]。根据表示侧重的不同,分为两种表示方法。第一种是较为简单的实体-关系表示,使用Schema层和实例层的常规方式来表达地理知识,较难表达时间特性。第二种是更为复杂的过程-关系表示法,通过时间维度划分实体状态,能更好地刻画时空特征。

选择采用实体-关系表示的研究主要面向一般情况下不随时间变化的事实知识或概念定义,例如行政区划、地理实体类型(山川、河流等)、空间方位等公认的领域知识,或得到验证的规律等的结构化组织。目前已有众多开源地理知识图谱项目,例如GeoNames Ontology、OSM(OpenStreetMap) Semantic Network、LinkedGeoData、GeoSciML (geoscience markup language)、YAGO2和GeoWordNet等,提供了众多地理实体如地名、山脉、行政区划及属性,并以资源描述框架存储以开放共享。百度百科、维基百科等开放型语料库,以及OSM等地理平台虽未采用知识图谱的组织形式,但凭借其海量且多源的地理空间相关的信息,为地理知识图谱的构建提供了不可或缺的数据来源支撑。文献[37-42]开发了自动化工作流,从上述网站非监督地提取地理实体及语义知识,形成地理领域知识图谱。类似的,文献[43-44]借助线上旅游平台(马蜂窝等)文本提供的景点属性与人群偏好,构建旅游景点知识图谱,并具有应用到景点推荐任务的潜力。YE等[42]和ZHU等[45]分别基于领域专家知识,将地理学和地球信息科学的学科知识结构化,形成了学科知识的概念层表示。然而概念层的实例化仍需依赖从开源数据中进行语义丰富的方法。NING等[46]探索了大模型自动构建城市领域知识图谱,试图取代以往的手动构建方式或语义提取模型。

上述研究显示,运用开源文本或已有知识库构建地理知识图谱成为可行且高效的范式。然而知识库之间在概念层、数据标准、质量等方面存在差异,亟需发展跨知识库的知识融合技术实现多个知识库之间的互通。

2.1.2　基于过程-关系的动态地理过程时空语义表示

基于过程-关系的表示方式能够将时空间、属性、行为、状态、过程信息同时涵盖在内。出于描述事件发展或地理进程演进的需求,动态时空知识图谱普遍采用多层级的表示框架。WANG等[47]提出地理进程表示的六要素:空间位置(Location)、变化(Change)、属性(Attributes)、关系(Relationship)、时间(Time)和状态(State),为后续研究奠定了理论基础。其他研究在此基础上围绕两种范式展开[48]。第一种关注过程或事件的动态表征,其核心是将地理过程或事件分解为多个状态或场景,并通过顺序关系(如早于/晚于)、因果关系、并发关系等时序逻辑进行关联。这种表示方法自下而上有地理要素(瞬时状态)-地理状态-地理进程的层级关系,其中地理要素与地理状态之间存在隶属关系,状态之间为顺序等关系[49-50]。HUANG等[51]进一步引入地理场景间的嵌套层次关系描述。ZHENG等[52]则以时间切片作为状态单元,每一个时间切片单元内含瞬时状态下的实体、事件、行为,通过时间切片的串联展示地理演化过程。该方法被用在灾害、疾病等随时间发展的过程[53-54]、病例活动与传染病传播[55]、恐怖事件或战争发展[45-56]等方面的建模中。另一种方式侧重于实体本身的时空演变表征,通过定义实体的状态或版本编号来实现,表达的信息相对简单。YANG等[57]使用此方法生成实体的时空演化摘要。ZHAO等[48]提出时空对象知识图谱,包含时空对象的类型、版本号和版本所对应的绝对时间值。在更早的研究中,KAUPPINEN等[58]使用这种方式构建了支持时空查询和可视化的历史文化地名实体的知识图谱。

综上,动态地理过程的知识多以时间切片作为最小单元,封装瞬时状态下的实体、事件、行为,通过时序逻辑串联展示连续演化过程,除时间顺序以外还额外引入因果关系、嵌套关系增强表达精度,但未见有研究量化证实这种知识表示方式的优势性。

2.2　从特征到决策:面向特定空间任务的端到端深度学习建模

本节重点回顾了端到端深度学习模型在特定下游任务中的训练与应用研究。这些模型将多源异构特征作为输入,直接映射到最终任务输出空间,如功能分类、流量、热点事件等。图神经

网络、卷积神经网络是这一领域的核心算法。以模型面向的任务所需输出的结果类型为依据,分为连续型、离散型和序列型。

2.2.1 连续型指标预测

连续型指标预测核心在于融合多源时空大数据语义,训练深度学习模型实现对时空流量、社会经济等动态变量的精准推断,揭示城市系统的复杂演化规律。

1)时空流量预测任务。时空流量预测是GeoAI领域核心研究方向之一,致力于融合多维度空间要素(包括道路网络拓扑、城市功能结构和环境背景特征)实现人车流量与出行需求的精准预测。ZHAO等[59]关注空间单元的公交需求预测,以此为节点属性、以空间单元间的邻接关系为边构建图结构,图神经网络(graph neural networks,GNN)层学习空间依赖,长短期记忆网络(long short-term memory,LSTM)层学习时间依赖,再与经典地理学回归模型学习到的城市建成环境对于公交需求的影响融合,用于出行需求的时空预测。轨迹OD(origin-destination)关系也常被用于构建图结构,文献[60-63]通过将训练集交通流量作为边属性输入GNN,实现测试集边属性流量的预测。类似的,文献[64]基于手机信令数据的分析方法通过将空间交互关系和拓扑结构建模为图边、人群活动强度作为节点属性,结合GNN和LSTM实现了人群活动的时空动态预测。文献[65-66]以道路段为基本单元构建空间拓扑图,将时序交通参数(流量、速度)作为节点特征,通过GCN捕捉空间依赖关系,并借助LSTM或门控循环单元网络学习交通流的周期性变化规律,从而建立短时交通流预测模型。QI等[67]为出行数据稀疏的小城市开发了可迁移的GNN框架,能够将模型在大城市数据训练时学习的知识安全、高效地迁移至小城市。CHEN等[68]则认为交通流量预测不仅和历史流量周期规律有关,还受到城市背景环境的影响,将兴趣点(point of interest,POI)等城市环境要素与路网拓扑共同建模。BUI等[69]对现有交通预测模型进行了系统评估,为该领域的未来发展提供了重要参考。建模有空间流量知识的知识图谱模型也服务于交通流量预测。GONG等[70]通过建模基站空间语义关系增强流量预测;ZHOU等[71]通过构建城市单元交互知识图谱来优化OD流量预测;CAO等[72]认为功能相似的空间单元其出行需求也相似,为此使用Transformer架构抽取空间单元用车需求时空特征,整合以POI语义中学习到的空间功能相似程度,综合预测出租车需求。

2)社会经济指标预测任务。社会经济指标预测是城市空间研究的重要任务之一。较多研究依赖于对街景图像反映的街区环境的分析来实现。CHEN等[73]基于ResNet开发了对全球144个城市路网平面图的分类模型,分类结果不仅能评估全球城市间结构相似性,而且能揭示路网构型分类结果与人均国内生产总值水平及PM2.5污染程度之间的相关性,为探讨何种道路布局模式更有利于推动可持续发展的目标实现提供依据。基于相似的思路,ZHANG等[74]收集世界各城市街景图像分类模型,开创了基于模型准确率的城市相似性间接度量方法。斯坦福大学一个较早的研究[75]奠定了针对街景图像的模型训练和回归建模推断社会经济指标的基础,通过训练从街景图像中识别轿车数量的模型,推断社区经济水平。FAN等[76]也证实城市街景图像的要素占比(如街道设施、人行道、建筑物立面和植被)可以较好估计该区域的健康、交通、犯罪、贫困等方面的指标。KANG等[77]基于街景等提取的视觉特征向量会显著影响房价升值,其他的自变量还包括房屋信息、人类活动、建筑环境和人口等。而绿化率则被证实与建筑租金溢价显著相关[78]。在空间感知研究方面,MIT Place Pulse训练视觉感知深度学习模型[79]为众多研究[80-81]提供基准标签数据集。KRUSE等[82]开发了城市“可玩性”评分模型并解析其空间决定因素。LAW和NEIRA[83]突破了传统打标签、进行有监督学习的方法,其构建的无监督街景表征模型自动捕捉的视觉特征与街道封闭性、路网结构等城市形态指标展现出强相关性,显示出该模型有效学习到了街道环境特征。

通过聚合多元语义,实现社会经济指标预测的研究逐渐成为当前主流趋势。LIANG等[84]构建了融合街景图像视觉特征与道路网络空间依赖的图神经网络聚类模型,提出使用街景图像监测城市视觉环境特征演化的方法。ZHOU等[85]创新性地构建多类异构空间大数据的全局图谱和面向不同领域知识的局部图谱,将全局嵌入结果在子图中进一步嵌入,将嵌入结果用于空间单元社会经济指标的回归。SHEEHAN等[41]利用维基百科文本构建南非城市的知识图谱并生成嵌入,结合夜间灯光数据实现城市贫困预测。KANG等[86]探索了使用通过街景提取的人类感知量化特征及通过访问量提取的人类活动特征来预测房价。DENG等[87]认为,具有相似城市属性的区域,其城市指标(如人口密度)

也相似,因此开发了UrbanICL框架,首先检索相似城市区域(通过卫星图像和POI语义)、聚合加权来预测新区域的城市指标,而无需进行复杂的预训练或微调。

2.2.2　离散型标签预测

离散型的预测任务本质上是分类问题,要求输出的是定性的标签,包括功能与活动类型预测、事件预测和分类标签预测。

1)土地功能预测任务。在土地功能预测领域,IDDIANOZIE等[88]采用建筑-道路拓扑关系作为边结构,并将拓扑类型和功能类别分别作为边属性和节点属性,成功实现了功能与拓扑类型的双重预测;KONG等[89]通过整合建筑几何特征、多源影像特征(街景与卫星)及POI语义信息构建复合节点表征,并评估了各特征维度的贡献度;ZHANG等[90]进一步考虑了人群行为模式与建筑功能的潜在关联,在构建图结构的节点属性中加入了人流量指标以提升模型功能预测能力。ZHU等[91]一方面将街景影像提取的视觉特征和现有功能特征共同编码为节点属性,另一方面同时考虑空间邻近性和基于OD流量的交互关系两种连接模式作为边类型实现了功能预测,并通过实验揭示了边类型选择对模型性能的决定性影响。YAO等[92]创新性地构建深度学习模型遥感影像反映的物理形态特征和时序电力数据反映的社会经济活动特征相聚合,实现土地功能推测。

2)热点或灾害事件预测任务。在离散型热点事件或灾害预测方面,ZHANG等[93]以道路段拓扑关系为边、道路段间距离为权重,将热点事件的发生时间段作为节点属性,训练后得到用于热点事件预测的时空传播模型。GE等[94]提出了基于时空知识图谱的灾害预测通用框架,采用机器学习算法分析灾害发生概率并生成预测规则,进而通过知识图谱整合多源灾害数据进行规则推理。此框架被应用于森林火灾[95]和滑坡[96]的预测中。而后该团队结合知识图谱嵌入(knowledge graph embedding,KGE)技术,首先整合灾害相关地理环境要素构建专用知识图谱,再以此为依据对比地点与历史灾害发生地的相似度,以此实现灾害预测[97]。

3)分类任务。在其他分类标签预测方面,在街景图像研究中,较多涉及到图像的分类问题,通常遵循“图像标注与数据集构建-模型训练-图像分类”的标准流程。LI和LONG[98]使用目标检测技术关注街景图像中的空置商铺为检测城市资源浪费点提供新方法;通过训练视觉分类模型,SUN等[99]实现了图像中的建筑年龄分类,YI等[100]和SHALUNTS等[101]进行了建筑与构件风格分类,KANG等[102]进行了旅游目的地形象分类等。但通过将分类结果落位至地理空间,与各类地理要素开展关联分析,并结合多案例交叉对比,研究者可有效揭示分类要素隐含的深层空间规律。例如SUN等[99]通过对阿姆斯特丹街景图像中的建筑年代进行分类,得出阿姆斯特丹不同年代建筑的空间分布,并将分类模型迁移到斯德哥尔摩,根据预测准确性衡量两个城市之间的相似性;XUE等[103]则以全球城市的街道平面样本为数据集,训练了路网模式分类模型。进一步地,通过模型在不同城市间的迁移性能评分来衡量城市之间的路网相似性。

知识图谱与图神经网络所基于的图结构,在建模实体间复杂关联与拓扑依赖方面具有天然优势,尤其适用于需要捕捉结构化关系的分类任务。LIU等[104]通过构建用户移动行为知识图谱,提取轨迹距离、语义熵等特征,有效实现了基于移动语义的用户分类。唐曾杨等[105]将建筑群的方位、大小以及建筑间的空间关系构建为知识图谱,通过预定义的建筑排布模式规则库,实现大规模建筑群空间布局模式的自动化识别与分类。ZHAO等[106]也聚焦于建筑物分布模式识别的问题,以建筑群之间的空间位置关系为边建模为图,对建筑物所属分布模式作为节点属性进行标签,训练后的GNN模型能够实现建筑空间模式识别,与唐曾杨团队[105]的研究形成了方法学上的有益互补。LIU和DE SABBATA[107]提出一种基于图的半监督深度学习方法,综合考虑社交媒体帖子的文本与图像联合表征以及时空关联,能够对大规模地理标记的社交媒体内容进行高效分类。

2.2.3　序列预测与构型生成

序列预测与构型生成是一类涉及序列顺序输入数据的建模任务,其输出不限于连续值或离散值,还可包括结构化的序列或配置方案。这类任务的研究涵盖用户行为预测、系统配置生成等多个领域。

1)用户访问预测任务。用户访问地点推荐类问题通过建模用户历史轨迹反映的偏好规律,实现用户未来可能访问地点的预测。在这类研究中,POI代表的功能语义对用户偏好的解释能力受大多数学者认可并利用。该类问题也高度依赖于图结构的算法。LAI等[108]、WANG等[109]通过学习用户与

POI交互的时空规律来建立访问推荐模型;YU等[110]在此基础上增加了访问交通方式的考虑,实现更符合真实出行场景的POI访问预测;PRAKKI等[111]以用户和景点之间的历史访问关系构建图模型,以用户评分作为边权重,使用GCN模型捕捉交互特征,实现景点的推荐。类似的,通过知识图谱结构建模和嵌入,也能够实现地点的推荐预测。WANG等[112]将用户历史访问POI记录构建为三元组知识图谱,将推荐问题转化为三元组补全任务;LIU等[113]则通过联合嵌入用户访问记录和POI类别语义,在保证推荐结果符合用户偏好的同时兼顾空间合理性;LIU等[114]通过嵌入区域、POI和品牌实体关系实现商铺选址推荐。类似的,LIU等[115]在原有的时序预测模型基础上进一步引入POI信息和精细化时间描述信息来提升对人群移动预测的精度;TERASHIMA等[116]通过集成Transformer架构开发了输出连续15天轨迹预测的模型LP-BERT,实现了更复杂的长序列生成。

2)空间构型生成任务。众多学者采用不同的技术路径探索了最优构型生成问题[117],如WANG等[118]将以城市空间单元的邻接关系建模为图,通过整合社区房价、POI分布及交通流量等多维特征,构建了基于对抗学习的空间优化模型。该研究通过建立正负样本对比学习机制(正样本代表优质规划案例,负样本代表欠佳方案),成功实现了对高价值空间构型的智能识别与生成。ZHENG等[119]将15 min社区规划任务转化为城市土地与道路网络的序列决策问题,开发了融合图神经网络与强化学习的社区规划设计方案自动生成工作流。MASOUMI等[120]则聚焦城市地块土地利用最优分配问题,设计了高效的多目标优化算法解决方案。SHOER等[121]将GNN与图自编码器结合,能够通过用户输入关键词生成对应风格的路网。ZHENG等[122]聚焦非正式聚居区改造,开发了以最小连接成本为目标的路网自动规划系统,通过图神经网络有效捕捉既有路网的拓扑特征,为特殊地区的基建规划提供了智能化解决方案。

3 通用模型驱动的GeoAI研究

本节所述"通用模型"泛指所有基于预训练技术范式构建的模型(pre-training model,PTM),纳入讨论的研究需满足以下条件之一:以构建面向地理空间任务的预训练模型为目标,或在研究流程中应用预训练模型以服务于地理空间相关研究。与§2介绍的专用模型相比,预训练技术范式具有本质差异:其核心在于首先基于大规模无标注数据集,通过自监督或无监督学习训练出具备通用基础表征能力的模型,再通过进一步训练将其迁移至具体下游任务。此类模型迁移性更好,尤其体现为可灵活应用于需求多样、涉及模态复杂的地理空间任务。近年来备受关注的大语言模型(large language model,LLM)是PTM的一个子类,其与传统PTM(如BERT、ResNet等)的根本区别在于前者具有极大的参数量(通常达百亿乃至万亿级别),而后者规模相对较小。在GeoAI领域,近年来基于大模型开展领域适配的研究与基于传统预训练模型架构的研究均较为活跃,这里将对这两类方向进行回顾。

3.1 预训练模型的构建与领域适配

本节根据模型目标与任务类型,进一步划分为3个方向进行综述:空间嵌入研究(旨在将空间要素映射至向量空间)、时空预测研究(面向捕捉城市时空特征的热点任务),以及多模态语义融合研究(旨在使预训练模型综合掌握多类跨模态语义知识)。

3.1.1 空间嵌入表示学习

空间嵌入类研究构建特征提取器,生成对空间要素的低维向量表示。经过机器学习、回归建模等步骤,可应用于土地功能预测、流量预测、其他标签预测的下游任务。空间嵌入模型与端到端深度学习模型在应用场景上具有高度重合性,但二者在技术范式上存在显著差异:前者首先生成空间要素的嵌入向量,随后将嵌入向量作为中间特征,输入至后续的机器学习或回归模型中进行预测,嵌入模型本身并无特定的任务目的;而后者则直接构建从原始数据到最终输出的完整映射,无需显式的中间表示转换步骤。MAI等[123]曾对各类空间嵌入模型进行了回顾。本文按照空间嵌入的对象类型来总结相关研究。

1)空间点的嵌入。Sphere2Vec对POI点的空间位置和功能语义进行嵌入[124-125]。有更多嵌入模型使用图结构实现空间上下文语义的聚合:Place2Vec[126]以缓冲区内POI的共现关系构建上下文,对POI点的功能、受欢迎程度语义进行嵌入。带地理标记的社交媒体数据点作为人群活动特征的代理,也被纳入嵌入对象。Cross-Modal[127]方法利用社交媒体数据点与其文本的双重时空共现关系构建上下文,建立跨模态的联合嵌入表示。LIU和DE SABBATA[107]进一步将社交媒体图像点及图像特征融入嵌入学习框架。实验表明,这些嵌入模型能够有效支持空间活动类型的识别与预测。空间轨迹点也是理想的嵌入对象,其包含的序列信息本身

构成了上下文,通过LSTM等适用于捕捉时序关系的模型,学习轨迹点及相关语义的嵌入,可用于用户下一个访问地点的预测推荐[128-129]。TorchSpatial[130]整合了多个广泛使用的空间点嵌入模型,并提出衡量嵌入偏差的基准框架。SpaBERT模型[131]能够对于某空间点地理实体,输出其与临近空间实体共同构成的地理上下文嵌入结果,其实现方式是使用OSM地理要素的空间关系形成伪句子,再对BERT进行领域自适应。

2)空间面的嵌入。空间单元面的嵌入以土地功能预测任务为目标,展现出比空间点嵌入更强大的多维信息表征能力。较多研究遵循以下技术路线:首先基于城市空间结构(如路网拓扑、行政边界或交通小区划分规则)将城市区域划分为若干个空间单元面;继而设计空间排序算法,如距离排序法[132]、最短路径遍历法[133-135]等,对单元内POI点进行序列化组织以构建语义上下文;随后通过神经网络学习POI点的分布式表示;进而利用空间单元与POI的映射关系,通过对单元内所有POI向量的聚合运算,生成具有区域整体特征的空间单元嵌入表示;最终基于带标注的训练数据构建预测模型,实现高精度的城市土地功能分类。此外,轨迹的空间连接模式可能揭示区域功能相似性,这一理论假设已获得学界广泛实证支持。基于此,研究者们发展了一类基于移动关系的空间面嵌入学习范式:ZHANG等[136]、ZHOU等[137]、LI等[138]以空间单元之间的OD连接关系或连续轨迹时序关联构建上下文,学习每个单元面的嵌入,再根据嵌入结果推测功能类型、交通流量等属性;CRIVELLARI等[139]的工作验证了以上方法的有效性,首先利用移动轨迹点学习空间单元的嵌入表示并进行功能预测,随后将其与POI反映的传统功能进行对比验证。类似的,HU等[140]先基于轨迹时序特征嵌入道路段,再根据道路段与空间单元映射关系推导区域功能。此外,近年来得益于视觉模型强大的图像特征提取能力,学界还发展了融合多模态的空间单元嵌入模型。LUO等[141]提出了一种两阶段嵌入方法,首先生成基于OD关系的空间单元表示,继而融合由预训练CNN嵌入的街景图像特征,形成多模态融合的空间单元嵌入。该方法在多元的分类与回归任务中验证了其有效性,如HUANG等[142]开发了一种融合遥感影像和街景图像视觉语义的空间单元表征方法,支持对空间单元的土地利用分类预测、城中村识别等多项任务。UrbanVLP[143]融合图像(包括影像和街景)与文本语义及空间位置,通过视觉-语言预训练模态对齐,构建城市空间单元表示学习模型。基于图的城市区域预训练和提示框架(Graph-based Urban Region Pre-training and Prompting framework,GURPP)[144]基于区域、POI、道路、交叉口、品牌等构成的知识图谱及嵌入,开展自监督预训练和任务适配,以生成城市单元面的嵌入表示。ReFound框架[145]是视觉-语言多模态预训练模型,在训练过程中创新性地使用了多个大模型进行蒸馏,以应对数据不足和通用性弱的问题,能够生成城市空间单元的综合考虑遥感影像和POI语义的嵌入。

空间单元的嵌入研究正呈现出融合多源异构数据的明显趋势。研究已突破以往仅依赖POI提供语义、OD关系构建上下文的局限,转向更全面挖掘空间隐含语义信息。主要表现为:上下文构建依据日趋多样,预测目标更具灵活性,嵌入数据类型向多模态扩展。例如GURPP、ReFound、UrbanVLP等模型。

3)其他空间要素与知识图谱嵌入。也有研究聚焦于GPS轨迹[146]、3D点云[147]、栅格数据[148]的嵌入,同样有着向多模态语义嵌入发展的趋势,如CityFM框架[149]创新性地开发了以OSM提供的数据为材料,生成所有地理空间实体多模态(视觉、文本、空间)嵌入的预训练模型,已证实可用于交通速度推断、建筑功能分类、人口密度估计的下游任务。TrajSceneLLM[150]为轨迹场景生成多模态嵌入,整合了视觉化地图图像和由LLM生成的对GPS轨迹特征的文本描述,形成对轨迹的视觉-文本多模态深入理解。

此外,将嵌入技术与知识图谱技术结合的KGE技术能够发挥更有效的作用。由于城市环境具有数据丰富、语义复杂的特点,加之其广泛的应用需求,使得城市领域成为知识图谱嵌入技术研究和应用的重要场景。PATEL等[151]早期开发的GeoTeGra框架支持将常用的开源空间大数据,包括OSM、出租车轨迹、推特文章等不同性质和模式的数据集加以连接,反映出从开源城市空间大数据提取聚合时空语义的思想。LIU等[152]总结了知识图谱技术用于城市空间知识提取的经验,提出了融合常见城市空间大数据的城市知识图谱(urban knowledge graph,UrbanKG)模式,并给出了从图谱构建到存储、到功能开发的示例,指出其在用户画像、用户访问预测、OD流预测等方面应用的潜力。也有更多研究基于特定任务需求嵌入相关语义图谱,继而通过针对性训练,形成表现更好的地点推荐类模型。LIU团队

另一项研究[153]提出知识增强的对比学习框架KnowCL,将包含空间、流动性、功能、商业等多维城市知识的UrbanKG融入视觉表示学习,构建了可生成融合语义知识的城市图像(卫星影像或街景图像)嵌入模型,同时训练了基于该嵌入的回归模型,实现依据城市图像对城市社会经济指标的精准预测。在运用知识图谱提供地理知识服务方面,MAI等[154]提出了空间显式的知识图谱嵌入模型TransGeo,该模型能够通过空间实体在行政层级、空间关联、机构关系等方面的临近性,构建起地理实体间的相似性关联,间接实现对地理查询问题的宽松化改写;该团队的另一模型SE-KGE[155]用知识图谱嵌入的方式实现了针对地理空间实体的编码器,该编码器综合考虑了空间实体的绝对位置、与其他实体间的空间关系以及区别于实体尺度的内容(小尺度实体编码点坐标、大尺度实体编码覆盖范围)。

综上,空间嵌入一直是GeoAI领域的研究热点且发展迅速,其技术路径正从早期仅聚焦POI或OD等单一要素的浅层建模,逐步向融合多源异构数据的深层语义建模演进。此类研究先得到通用型空间表征,后在有标签数据集上微调,得以具备地理空间下游任务的迁移性。然而,现有嵌入模型在跨城市迁移应用场景下的普适性与适配性有待验证与优化,即领域迁移性仍需优化。

3.1.2 通用时空预测模型

有较多研究训练了通用时空预测模型。SHI等[156]在现有数据与成熟模型框架基础上通过提示学习的适配方法,为城市计算中的时序数据分析构建通用模型,能高效处理多种时序任务(如预测、分类、时序补全、异常检测)。不同城市区域若在空间结构及功能布局层面具有较高的同质性,其内部所呈现的时空演化规律亦趋于一致。基于这一假设,YUAN等[157]在来自不同城市时空大数据的基础上,构建了通用的城市时空预测模型UniST。HAN等[158]基于来自于多个城市的多领域大数据预训练了通用时空预测模型CompactST,并验证该模型在交通流量、空气质量、太阳能发电等多种时空预测任务表现优异。ZHANG等[159]提出了能捕捉这种时空共性的城市预测通用预训练模型GPST,并以提示调优的方法进行微调,匹配多项城市任务。WU等[160]开发了基于Transformer架构的用户移动预测的预训练模型,在大规模无标签位置服务轨迹数据上进行预训练,并进行了任务微调,主要针对下一跳位置预测和掩码位置填充任务。

通用时空预测模型与空间嵌入模型逻辑相近,二者均先学习通用表征,再结合具体任务进行微调;与空间嵌入模型相比,通用时空预测模型的优势体现在:在统一框架内完成空间结构与时序规律的联合建模,并通过融合多城市数据预训练获得更强的跨领域迁移能力。

3.1.3 地理空间-多模态语义对齐的预训练模型

在多个领域中,地理空间信息与多模态材料信息的语义对齐研究不断深化,相应涌现出大量旨在融合多模态语义的预训练模型。该类研究在数据构建、模型架构和适配训练实现融合多模态语义:在输入层即引入融合多模态语义的异构图数据,使模型从底层开始学习跨模态关联;各模态数据先经过独立编码器提取各维度特征,再通过跨模态注意力等机制进行交互与融合;或基于已有预训练模型,通过针对性微调实现跨模态语义的适应与对齐。前者具有快速复用的优势,后者具有更贴合领域的优势。

1)空间与文本语义对齐。有较多研究面向地图类服务,要求模型解决地理和文本的知识整合问题。MA等[161]在大规模中文地质语料库上预训练了面向中文地质领域的语言模型。有较多学者认为,地理知识的缺失是导致模型在地理服务领域的性能提升陷入瓶颈的主要原因[162]。HUANG等[162]在海量文本与地理信息异构图数据上预训练了ERNIE-GeoL模型,它将地理信息(如坐标、空间关系)与自然语言深度融合,从而显著提升地图服务(地址匹配、POI查询、地理编码等)的性能和智能化水平,当前已应用于百度地图。类似的,WU等[163]在基于物流配送地址、配送路线及兴趣面共现关系等构成的异构图上训练了G2PTL预训练模型,有效融合了地址语义、空间拓扑关系与行政层级知识,显著提升了物流配送等地理任务的执行效率。针对POI查询的地图服务,对用户输入的查询进行宽松化改写,以和POI名称匹配,称为Query Rewriting(QR)任务。LIU等[164]从POI、行政区域等信息构成的特征图上训练了Geo-BERT预训练模型,融合文本语义与地理知识,并将其集成到当前常用的QR模型中,显著提升模型的查询重写能力。DING等[165]首先构建包含查询文本、POI信息及地理上下文的大规模基准数据集,在此基础上进行了跨模态对齐的预训练,得到MGeo模型,并使用POI及对应查询文本构成的部分标注数据集

进行了领域自适应预训练,最终提升POI查询任务性能。有学者对已有预训练模型进一步做地理领域自适应预训练[166],提升了模型在地理位置预测任务(根据文本推测其空间位置)上的表现。RAMRAKHIYANI等[167]则通过地理问答,对已有预训练语言模型(pre-trained language model, PLM)在地理知识方面的掌握程度开展评测。

2)图像与文本语义对齐。基于城市环境数据和相关社交媒体数据,HE等[168]通过对BERT模型进行有标签的三层微调,构建了从社交媒体文本中提炼人群主观热感知的模型HP-BERT。ZHANG等[169]提出一种基于PLM微调的跨模态感知方法SFT-BERT,实现了图像与文本之间的语义对齐。该方法采用ResNet模型提取图像特征,并利用BERT模型提取文本特征,通过在少量带有文本标注的街景图像数据上进行微调训练,可以输出街景图像的文本描述。

还有一类预训练模型服务于分类任务,多为实现图像与特定标签文本之间的语义对齐。CAO等[170]对BERT进行微调后,开发了基于城市绿地对应的POI,能够对绿地进行标准化分类(由作者定义)。YANG等[171]通过分别训练POI和影像的编码器,再使用部分标注后的影像-POI类别对进行微调,能够识别影像中的用地类别。类似的,还有从遥感影像识别公共空间的预训练模型[172]。

与空间嵌入模型相比,多模态预训练更加强调跨模态语义关联建模,从输入层便引入空间、文本、图像等多模态信息,模型直接在统一语义空间内完成多模态信息的理解,省去了显式生成空间嵌入向量的中间环节。总的来说,此类模型更高效捕捉了多模态空间信息,在复杂地理任务中表现出更强的适应性与迁移性。

3.2　大模型的调用与领域适配

大模型的兴起正在推动AI实现持续突破,融合地理空间科学与大模型的研究已成为极具潜力且快速发展的领域。然而,由于大模型参数量巨大,难以从头训练,当前GeoAI研究对大模型的应用主要采取两种方式:一是通过提示学习、上下文示例等轻量级适配手段激发其已有知识,以更好地适应空间科学问题;二是直接调用其通用能力解决地理空间任务。与常规预训练模型的参数微调不同,大模型的适配更侧重于知识引导而非参数更新,体现出更高效、灵活的应用特点。

已有多个权威机构与研究团队开始系统梳理大模型技术在GeoAI领域的研究进展与应用现状。例如,中国科学院空天信息创新研究院在《空间数据智能大模型研究——2024年中国空间数据智能战略发展白皮书》[173]中,系统总结了空间数据智能大模型的关键技术、创新应用与发展方向。面向城市领域的基模型开源社区持续整合该方向的最新研究进展[174]。FENG等[175]则围绕城市尺度人群行为模拟类大模型的研究进展展开综述。

3.2.1　地理空间任务驱动的大模型调优

有较多学者通过对通用大模型进行调优和轻量级微调,希望开发适用于空间科学问题的大模型。部分研究以人群行为活动方面的强化为目标,例如LIANG等[176]开发了基于大模型的公共事件人群移动预测方法,首先由大模型将非结构化公共事件描述标准化简化处理,结合对历史人流数据中常规流动和公共事件引发流动的结果,引导大模型预测未来事件引起的出行需求,同时生成预测解释以支持实时决策。JIANG等[177]、DU等[178]还探索了在框架中集成LLM以在学习人群流动模式的基础上生成人群活动轨迹。在此基础上,FENG等[179]进一步考虑城市环境影响和人群活动共享模式的影响,SHAO等[180]、MANSOURIAN等[181]通过加入逐步推理和指令工程方式辅助大模型更好理解人群出行意愿,以优化大模型对人群出行需求的模拟效果。也有研究聚焦基于偏好理解的人群生活需求(餐饮、放松、购物等)的预测生成。UrbanGPT[182]架构尝试取代传统多由GNN和LSTM等模型实现的时空流量预测的问题,通过向LLM集成时空依赖编码器和指令调优的方式。OpenCity[183]结合Transformer和GNN架构,实现跨城市零样本的城市环境交通流量预测。CityGPT[184]通过指令调优和微调为大模型注入城市知识,在移动性预测和轨迹生成任务展示出优越性能。HUANG等[185]对视觉-语言大模型CLIP进行提示工程的方式,打造UrbanCLIP这一零样本城市功能推断框架,输入街景图像,能够推断图像中空间的功能。

在其他城市地理任务方面,GeoLLM[186]框架通过微调使得基础模型掌握地点与坐标、地点空间关系的知识,进而显著提升大模型的人口密度预测准确性。ZHANG等[187]通过指令调优和再训练强化通用大模型的GIS专业知识。此外,GeoChat[188]是针对遥感影像开发的大视觉语言模型(vision-language model, VLM),在遥感影像场景分类、视觉问答、图像描述等任务表现稳健。GeoReasoner[175,189]通过对已有VLM进行微调,显著提升了大型视觉语言模型在根据街景图像

进行地理定位任务中的性能。

相较于§3.1.3针对预训练模型开展的微调研究,大模型的参数量巨大、权重更新成本高,因此本节面向地理空间领域的大模型适配研究,通常不修改模型原始权重,或仅对极小部分参数进行轻量级微调。该方式能够显著降低计算资源消耗,同时依托大模型本身具备的丰富世界知识与通用语义理解能力,可在高效适配的前提下保证模型在地理空间任务中的应用效果。

3.2.2 大模型在空间任务中的零样本/少样本评估

还有较多工作评估大模型能否用于解决地理领域内的任务,是否真正掌握地理空间知识[190]。有研究评估大模型在常用地理空间任务上的表现,TAN等[191]结果显示,GPT-4和GPT-4V在图像特定要素识别、地理类问答、数据分析、城市规划知识检索、城市问题分析等方面表现较好,但在需要精细识别、计数、推理、专业设计的任务中表现不佳。XU等[192]结果显示,虽然GPT-4在零样本测试中取得了优于其他大模型的成绩,但在进行提示策略调优后,Moonshot模型在地名识别任务中超过GPT-4,且提示策略可显著提升模型表现。JI等[193]尝试评估主流大语言模型(GPT-3.5-turbo、GPT-4和DeepSeek-R1-14B)是否能够理解地理空间数据(wkt格式,一种文本表示格式)及其拓扑空间关系描述词,发现GPT-4获得最优性能。在对多模态大模型处理视觉类地理任务的评估中,GPT-4V并不总是表现最好的模型,在进行图像地理定位的任务中,Qwen-VL和LLaVA-1.5的表现更好[194]。MAI等[195]在地名识别、疾病等时序数据预测、分类(包括基于POI分类城市功能、基于街景影像推测噪声强度分类、遥感影像的分类)任务下,将较早的大模型(GPT-3、GPT-2与InstructGPT)和各自领域的SOTA(state-of-the-art)模型进行比较,结果显示大模型在地名识别、时序数据预测的任务中表现更好,但在分类任务中尚且不佳。City-Bench[196]是一套面向城市任务大模型能力评估的基准性框架,其中城市任务涵盖了感知理解和决策制定两大维度。不仅如此,该平台实现了从多源城市数据采集、城市环境动态模拟、大模型(LLM/VLM)与环境交互到最终性能评估的全流程闭环,从而为大模型用于城市任务提供了标准化的实验环境。GeoBenchX[197]设计了测试框架以评估常用LLM在多步骤地理空间任务的表现,通过比较模型输出的解决方案和参考解决方案的匹配度实现。MOONEY等[198]对GPT-4和GPT-3以及人类学生共同设计了GIS考试,证实GPT模型当前难以处理复杂数学统计和地理分析工作流任务。MANVI等[199]通过将大模型对多国社会经济指标(如人口密度、婴儿死亡率、夜间灯光数据等)的评分与真实数据进行对比,指出大模型存在地理偏见。GeoAnalystBench[200]对主流大语言模型在多步骤地理空间分析工作流规划与Python代码生成能力展开测评,结果表明,商用模型整体表现显著优于开源模型;研究同时提出,可通过增强模型的GIS领域知识、提供空间数据集的详细描述,提升大模型在空间分析任务中的性能。

3.2.3 基于单一与多智能体架构的大模型地理应用

大模型为构建新一代智能化、自动化的地理分析工作流提供了核心驱动力。其一,将大模型深度嵌入地理任务工作流,实现从用户指令到分析执行的无缝衔接;其二,将大模型本身视为多角色智能代理,利用其模拟与协作能力服务于复杂的空间决策场景。本节依次对这两类前沿探索进行梳理与评述。

1)置入大模型的地理任务工作流开发。与此同时,也有学者思考如何灵活运用大模型的智能开发自动化地理类工作流。ZHANG等[201]提出GeoGPT框架,能够理解用户的需求,输出GIS执行方案工作流,辅助非专业用户进行地理分析。也有更多研究则通过指令调优[181]或者检索增强生成[202]等方式优化已有大模型,使其能够直接调用空间分析的代码模块,直接完成多步骤的地理空间分析任务。ChatGeoAI[181]使用指令调优,应用大模型理解用户需求,生成PyQGIS代码自动执行空间查询操作。TrajAgent[203]使用了一种混合架构,将大模型与“小”模型结合,大模型负责解读需求、选择合适的专业模型、调整模型参数等,实现多种轨迹建模任务的灵活应对。GeoBenchX[197]使用一个简单的工具调用代理,调用配置好的地理空间功能工具实现多步骤地理空间任务,还提出了相应的评估框架。可用于自动制图的继承大模型工作流也被开发[204],通过大模型理解用户对话中的制图和修改要求,按顺序调用相应的绘图工具模块完成制图或修改。以上研究反映出大模型的出现使得智能辅助决策和自动化工作流生成逐渐成为新趋势。

2)大模型作为多智能体参与规划决策。LLM展现出的强大通用知识表示与自然语言交互能力,使其能够作为多角色智能代理,为城市规划领域的

智能决策支持提供新的技术范式。LLM不仅能够通过角色扮演模拟多样化的人类智能体行为,还能以自然语言生成的方式为复杂规划问题提供多角度的决策建议,因而被广泛应用于社会模拟、政策评估和虚拟环境构建等多个领域[205]。在城市规划的特定任务上,DESHPANDE等[206]对GPT-3进行了微调,能够以自然语言形式生成社区规划概念。ZHU等[207]则构建了面向专业规划需求的PlanGPT模型,实现了规划文本生成、风格转换、重点提炼和方案评估等核心功能的智能化支持。LLM作为智能代理的应用范式仍在不断拓展,ZHOU等[208]使用LLM模拟不同利益相关方对土地利用的差异化需求,为规划方案的协同优化提供了新的技术手段;QIAN等[209]进一步将LLM智能体整合到多智能体强化学习框架中,通过模拟多方利益博弈过程,最终生成了更具包容性的土地利用优化方案;KALYUZHNAYA等[210]构建多代理LLM系统并集成到数字城市平台,能够为用户提供城市规划、资源管理、公共服务、基础设施建设、环境评估、政策法规等多个方面问题的查询和分析,实现为智能城市的管理支持。

大模型以智能体形式嵌入地理空间应用场景,实现了通用能力向地理空间交互与决策类任务的迁移,构建了可交互、可协作、可执行的智能化工作流与协同决策机制,降低了地理空间分析与决策的技术门槛,进一步拓展了大模型在城市规划、数字城市建设及综合空间治理领域的落地应用场景。

4　GeoAI研究趋势总结与未来挑战

4.1　专用模型驱动的GeoAI研究总结与展望

专用模型驱动的GeoAI研究发展时间较长、数量较多。对比专用模型的两种导向,其中构建端到端的深度学习模型的研究数量相对更多,在深度学习时代积累了丰富研究成果。其进展集中在以下几个方面:

1)时空规律挖掘。针对轨迹数据所反映的人-空间、空间-空间的交互模式,学者常结合图神经网络与循环神经网络,捕捉交通流量或出行需求中的时空依赖关系,进而实现精准的时空预测。

2)离散型属性推断。在图神经网络与循环神经网络的支持下,研究者通过灵活定义图中节点与边的类型及属性,实现对节点属性或关系属性的分类与预测,常见于对兴趣点功能、土地利用类型、社交媒体内容或人类活动模式的识别任务。

3)空间构型优化。旨在寻求规划要素的合理空间配置与比例分配。相较于依赖遗传算法、多目标优化的传统方法,当前研究引入图神经网络、生成对抗网络等,通过专家标注的构型样本训练模型,进而生成符合专业预期的空间设计方案。

4)视觉语义辅助的感知与社会经济因子推断。依托卷积神经网络等方法,从街景、遥感与志愿者地理信息图像中提取视觉特征,进而支持空间要素识别(如建筑年代、路网结构)、环境感知分类(如街道安全评价)及社会经济指标(如地区生产总值、犯罪率)的推断。

总的来说,以多源异构空间数据为输入、直接映射任务输出为核心逻辑,以GNN、CNN、Transformer等为核心算法,构建了空间特征理解和决策输出的高效路径。出现了多模态数据语义协同的趋势,依赖知识图谱对语义的结构化组织能力,或依赖图神经网络对各模态数据分别提取语义特征的融合嵌入,实现了深度多模态语义协同。另外,该类研究有对于特定空间任务进行架构定制的特点,使算法能更好地契合空间数据特性,但也会限制其泛化性。

时空知识图谱的研究数量相对较少,在深度学习模型时代,其主要内容是地理知识的结构化表达,涵盖静态与动态两种类型。静态本体侧重于地理实体、属性及其间关系的规范化定义,而动态本体侧重刻画地理过程的时序演化规则。通过构建适配领域的结构化表达,不仅能够显式揭示地理现象的内在规律,也为实现可解释的复杂空间分析提供了方法论基础。然而知识图谱嵌入为该领域注入了新的活力,使其对知识的结构化组织能力能够转化为机器可理解、可计算的向量,作为编码器被融入到端对端为特定空间任务训练的架构、或预训练模型的一部分。以UrbanKG系列研究为例,知识图谱带来的提升体现在两方面:一是实现了结构化知识与大数据驱动的结合,即先通过知识图谱整合多源语义,再借助深度学习挖掘关系型三元组中的隐含模式;二是增强了模型的可解释性,知识图谱所承载的知识具备明确的人类可读性,使得嵌入模型的输出结果更易于验证与理解。更重要的是,在大模型时代到来后,知识图谱能够服务于大模型微调,发挥知识增强、提升可解释性的作用。因此,时空知识图谱领域具有广阔发展空间,但也应注重图谱的可迁移性、使用广泛性和复用性,推动统一构建与标准化进程,尽可能引入开源或官方语义网/知识图谱作为参考框架。此外,应顺应多

模态语义融合的趋势[24],进一步借助TransE、RotatE等嵌入技术将实体与关系映射至低维向量空间,以支持高效查询、知识推理与下游任务开发。

当下,大模型的发展已深刻重塑了GeoAI的研究范式,使得研究者无需为特定任务从头构建数据集、设计专用架构并训练模型,转而可通过优化调用现有预训练模型实现目标,显著降低了开发资源消耗与成本。未来,需着力构建专用模型与通用大模型的协同生态系统,探索建立专用模型作为可靠工具被大模型调用的标准化接口与技术范式。

4.2 通用模型驱动的GeoAI研究总结与展望

通用模型驱动的GeoAI研究正迅速发展为一个充满活力的新兴交叉领域。这一趋势始于以BERT为代表的轻量化预训练模型的出现,推动了地理空间领域借鉴模型架构、开发针对性预训练模型以提升多空间任务迁移能力的研究浪潮;随后,以GPT为代表的大模型持续演进,又催生了围绕大模型工具开展多样空间知识增强与决策支持的多类型研究。

首先,预训练模型的构建与领域适配可被归纳为3个分类:空间嵌入的表示学习、通用时空预测模型和地理空间与其他语义对齐的模型。其进展表现为:

1)空间嵌入的对象正在从点扩展到面,方法从单一走向融合。早期研究侧重嵌入POI点、空间单元面,随后扩展至点线面多类空间实体以及时空知识图谱的嵌入,技术路径也向着融合多模态信息、构建具有更强语义表达能力的联合嵌入发展。

2)多模态语义的对齐正逐渐走向深度协同。由简单的对多模态语义各自编码、加权拼接的方式,转为预训练阶段,即通过异构图建模、跨模态注意力等机制,实现地理、文本与视觉信息的底层语义对齐,省去了生成空间嵌入向量的中间环节,应对涉及复杂模态需求的地理空间任务迁移性更强。

3)知识图谱成为增强模型理解与推理的关键结构。知识图谱的结构化组织多源语义的能力已成为空间嵌入的高阶语义来源。

其次,大模型在地理空间领域的应用研究也逐渐涌现并越来越多。有学者致力于开发更具专业性的垂向大模型,通过针对性训练增强其在人类移动模式理解、地理概念认知、空间关系推理及视觉问答等方面的专门能力。此外,大模型在地理任务中的适用性评估已形成系统性,随着CityBench[196]、GeoBenchX[197]、GeoAnalystBench[200]等标准化评估框架的出现,该领域正逐步建立科学化的能力评测体系。评估结果表明,大模型在空间推理能力上存在明显局限,并表现出不同程度的地理偏见,这进一步凸显了构建地理空间领域专用大模型的必要性。得益于大模型掌握的广泛通用知识和推理能力,大模型正被深度集成至传统地理研究流程的关键环节。它们正逐步替代人类专家完成部分语义标注工作,或在特定场景中取代专门训练的深度学习模型,承担特征提取、时空预测等任务[211]。更重要的是,凭借其强大的知识表示与自然语言交互能力,大模型正成为智能城市规划决策的核心技术范式——既可作为工作流定制的智能中枢,也能以多智能体形式嵌入城市系统,实现对人群活动、政策实施、设施使用等复杂场景的模拟分析。经优化后集成至数字平台的大模型,还有望提供更直观、专业的城市咨询服务,展现出广阔的应用前景。

值得注意的是,尽管通用模型驱动的GeoAI新范式在多样地理空间任务下有更好的迁移性,显示出替代传统专用GeoAI模型的潜力,但其发展仍面临挑战。在数据层面,模型预训练、指令微调及检索增强生成均依赖海量高质量样本,而多模态异构地理数据的统一表征框架尚未成熟。CityBench[196]等平台通过城市环境模拟生成训练数据,为缓解数据瓶颈提供了可行路径。在可靠性层面,大模型固有的“黑箱”特性与“幻觉”现象导致其输出结果可信度存疑,决策过程的不透明性也加剧了用户信任危机。当前亟需建立面向地理空间的专用评估框架,并通过人机协同验证等机制提升模型决策的空间公平性与可问责性。在应用层面,在未经优化的零样本任务中,大模型尚难胜任复杂的地理计算与推理,传统空间计量与深度学习方法仍具不可替代价值,当前大模型只能通过担任智能中介的角色、协调调用专业工具完成复杂地理空间任务,或仍需额外的微调训练。

在未来,通用模型需要致力于实现从感知到认知的跨越,即从表层特征提取和模式识别迈向深层理解、推理与决策,充分利用大模型的思维与逻辑能力,为此,必须推动领域知识、逻辑规则与上下文语义的深度融入。与此同时,应当积极构建以通用大模型为“智能中枢”,与知识图谱、专用模型以及人类专家深度融合、协同工作的下一代GeoAI生态系统,使其具备更高的可信性、协作性与可持续演进能力。

5　结　语

GeoAI将智能算法应用于地理空间科学问题,依托强大的数据与算力支持,从海量数据中提取、解析并预测地理现象的规律,为空间决策提供科学依据。凭借其在复杂人地系统建模方面的技术突破、对前沿算法架构的高度兼容、对多源异构空间数据的有效整合,以及对空间动态预测精度与效率的显著提升,GeoAI已成为一个迅速发展的重要研究方向,也是未来城市科学与地理空间科学发展的必然趋势。

本研究系统梳理了地理AI研究中的两类主要范式——专用模型驱动与通用模型驱动,回顾了该领域的研究现状,深入分析了各子领域面临的关键问题、代表性方法与主要贡献。通过对现有成果的系统比较与总结,本文揭示了在AI技术范式演进背景下,GeoAI领域在研究内容、方法论路径上的发展趋势与取向变化,并对该领域的未来发展方向作出展望。本文旨在揭示复杂地理空间任务与AI模型融合过程中尚存的不足,以增进学界认识,并为后续创新性研究提供方向指引,从而推动GeoAI领域的持续拓展与深化发展。

参　考　文　献

[1] SHU H. Big Data Analytics: Six Techniques[J]. *Geospatial Information Science*, 2016, 19(2): 119-128.

[2] YANG C W, CLARKE K, SHEKHAR S, et al. Big Spatiotemporal Data Analytics: A Research and Innovation Frontier[J]. *International Journal of Geographical Information Science*, 2020, 34(6): 1075-1088.

[3] HILBERT M. Big Data for Development: A Review of Promises and Challenges[J]. *Development Policy Review*, 2016, 34(1): 135-174.

[4] YANG C W, HUANG Q Y, LI Z L, et al. Big Data and Cloud Computing: Innovation Opportunities and Challenges[J]. *International Journal of Digital Earth*, 2017, 10(1): 13-53.

[5] CHOI Y. GeoAI: Integration of Artificial Intelligence, Machine Learning, and Deep Learning with GIS[J]. *Applied Sciences*, 2023, 13(6): 3895.

[6] JANOWICZ K, GAO S, MCKENZIE G, et al. GeoAI: Spatially Explicit Artificial Intelligence Techniques for Geographic Knowledge Discovery and Beyond[J]. *International Journal of Geographical Information Science*, 2020, 34(4): 625-636.

[7] HOCHMAIR H, JUHÁSZ L, LI H. Advancing AI-Driven Geospatial Analysis and Data Generation: Methods, Applications and Future Directions [J]. *ISPRS International Journal of Geo-Information*, 2025, 14(2): 56.

[8] LIANG Y X, WEN H M, XIA Y T, et al. Foundation Models for Spatiotemporal Data Science: A Tutorial and Survey [PP/OL]. arXiv (2025-03-12) [2025-11-12]. https://arxiv.org/abs/2503.13502.

[9] YAN Y B, WEN H M, ZHONG S R, et al. UrbanCLIP: Learning Text-Enhanced Urban Region Profilingwith ContrastiveLanguage-ImagePretraining from the Web [PP/OL]. V1. arXiv (2023-10-22) [2025-11-22]. https://arxiv.org/abs/2310.18340.

[10] CLARKE K, HOPPEN S, GAYDOS L. Methods and Techniques for Rigorous Calibration of a Cellular Automaton Model of Urban Growth[C]//The 3rd International Conference/Workshop on Integrating GIS and Environmental Modeling, Santa Fe, New Mexico, USA, 1996.

[11] BATTY M. Urban Modelling: Algorithms Calibrations, Predictions[M]. Cambridge, New York: Cambridge University Press, 1976.

[12] CHOI J, USERY E L. System Integration of GIS and a Rule-Based Expert System for Urban Mapping [J]. *Photogrammetric Engineering & Remote Sensing*, 2004, 70(2): 217-224.

[13] LEARY M E. Knowledge and Reasoning in Development Control and Urban Design: An Expert Systems Approach[J]. *Environment and Planning B: Planning and Design*, 1988, 15(4): 383-398.

[14] HART P E, NILSSON N J, RAPHAEL B. A Formal Basis for the Heuristic Determination of Minimum Cost Paths[J]. *IEEE Transactions on Systems Science and Cybernetics*, 1968, 4(2): 100-107.

[15] 高松. 地理空间人工智能的近期研究总结与思考[J]. 武汉大学学报(信息科学版), 2020, 45(12): 1865-1874.
GAO Song. A Review of Recent Researches and Reflections on Geospatial Artificial Intelligence[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(12): 1865-1874.

[16] PEREIRA G, OJO A, CURRY E, et al. Data Acquisition and Processing for GeoAI Models to Support Sustainable Agricultural Practices[C]// The 53rd Hawaii International Conference on System Sciences, Maui, Hawaii, USA, 2020.

[17] VOPHAM T, HART J E, LADEN F, et al. Emerging Trends in Geospatial Artificial Intelligence (GeoAI): Potential Applications for Environmental Epidemiology [J]. *Environmental Health*, 2018, 17(1): 40.

[18] ZHOU T Y. Application of Artificial Intelligence in Geography[J]. *Journal of Physics: Conference Se-*

ries, 2023, 2646(1): 012006.

[19] OUCHRA H, BELANGOUR A, ERRAISSI A. An Overview of GeoSpatial Artificial Intelligence Technologies for City Planning and Development[C]//The 5th International Conference on Electrical, Computer and Communication Technologies, Erode, India, 2023.

[20] SANCHEZ T W, SHUMWAY H, GORDNER T, et al. The Prospects of Artificial Intelligence in Urban Planning[J]. *International Journal of Urban Sciences*, 2023, 27(2): 179-194.

[21] LI W W. GeoAI: Where Machine Learning and Big Data Converge in GIScience[J]. *Journal of Spatial Information Science*, 2020(20): 71-77.

[22] LIU P Y, BILJECKI F. A Review of Spatially-Explicit GeoAI Applications in Urban Geography[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 112: 102936.

[23] GAO S. Artificial Intelligence and Human Geography[M]//The Encyclopedia of Human Geography. Cham: Springer International Publishing, 2024.

[24] MAI G C, HU Y J, GAO S, et al. Symbolic and Subsymbolic GeoAI: Geospatial Knowledge Graphs and Spatially Explicit Machine Learning[J]. *Transactions in GIS*, 2022, 26(8): 3118-3124.

[25] 陆锋, 诸云强, 张雪英. 时空知识图谱研究进展与展望[J]. 地球信息科学学报, 2023, 25(6): 1091-1105.
LU Feng, ZHU Yunqiang, ZHANG Xueying. Spatiotemporal Knowledge Graph: Advances and Perspectives[J]. *Journal of Geo-Information Science*, 2023, 25(6): 1091-1105.

[26] SONG Y Z, KALACSKA M, GAŠPAROVIĆ M, et al. Advances in Geocomputation and Geospatial Artificial Intelligence (GeoAI) for Mapping[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2023, 120: 103300.

[27] QIN K, LIN H, YUE Y, et al. Spatial Humanities and Geo-Computation for Social Sciences: Advances and Applications[J]. *Journal of Geodesy and Geoinformation Science*, 2022, 5(2): 1-6.

[28] 刘瑜, 郭浩, 李海峰, 等. 从地理规律到地理空间人工智能[J]. 测绘学报, 2022, 51(6): 1062-1069.
LIU Yu, GUO Hao, LI Haifeng, et al. A Note on GeoAI from the Perspective of Geographical Laws[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(6): 1062-1069.

[29] 程涛, 张洋, James HAWORTH. 基于网络和图的时空智能: 概念、方法和应用[J]. 测绘学报, 2022, 51(7): 1629-1639.
CHENG Tao, ZHANG Yang, HAWORTH James. Network and Graph-Based SpaceTimeAI: Conception, Method and Applications[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(7): 1629-1639.

[30] BOGNAR M. Prospects of AI in Architecture: Symbolicism, Connectionism, Actionism [J/OL]. *Journal of Architectural Informatics Society*, 2021. https://openreview.net/pdf? id=gvHffM4DlpG.

[31] SUN Q Y, YANG L X. From Independence to Interconnection—A Review of AI Technology Applied in Energy Systems[J]. *CSEE Journal of Power and Energy Systems*, 2019, 5(1): 21-34.

[32] WANG L, LIU Z C, LIU A, et al. Artificial Intelligence in Product Lifecycle Management[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 114(3): 771-796.

[33] ZHONG Y X. Structuralism? Functionalism? Behaviorism? or Mechanism? -Looking Backward and Forward on Better Approach to AI[C]//IEEE International Conference on Granular Computing, Atlanta, GA, USA, 2006.

[34] 王圣音, 高勇, 陆锋, 等. 场所模型及大数据支持下的场所感知[J]. 武汉大学学报(信息科学版), 2020, 45(12): 1930-1941.
WANG Shengyin, GAO Yong, LU Feng, et al. Place Model and Big Geo-data Supported Place Sensing[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(12): 1930-1941.

[35] 陆锋, 余丽, 仇培元. 论地理知识图谱[J]. 地球信息科学学报, 2017, 19(6): 723-734.
LU Feng, YU Li, QIU Peiyuan. On Geographic Knowledge Graph[J]. *Journal of Geo-Information Science*, 2017, 19(6): 723-734.

[36] 张雪英, 张春菊, 吴明光, 等. 顾及时空特征的地理知识图谱构建方法[J]. 中国科学: 信息科学, 2020, 50(7): 1019-1032.
ZHANG Xueying, ZHANG Chunju, WU Mingguang, et al. Spatiotemporal Features Based Geographical Knowledge Graph Construction[J]. *Scientia Sinica (Informationis)*, 2020, 50(7): 1019-1032.

[37] WANG C B, MA X G, CHEN J G, et al. Information Extraction and Knowledge Graph Construction from Geoscience Literature[J]. *Computers & Geosciences*, 2018, 112: 112-120.

[38] GUO X, QIAN H Z, WU F, et al. A Method for Constructing Geographical Knowledge Graph from Multisource Data[J]. *Sustainability*, 2021, 13(19): 10602.

[39] LI J, LIU R, XIONG R. A Chinese Geographic Knowledge Base for GIR[C]// IEEE International Conference on Computational Science and Engineering and IEEE International Conference on Embedded and Ubiquitous Computing, Guangzhou, China, 2017.

[40] CHEN J Y, DENG S M, CHEN H J. CrowdGeoKG: Crowdsourced Geo-Knowledge Graph [C]// China Conference on Knowledge Graph and Semantic Computing, Chengdu, China, 2017.

[41] SHEEHAN E, MENG C, TAN M, et al. Predicting Economic Development using Geolocated Wikipedia Articles[C]//The 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, Anchorage, AK, USA, 2019.

[42] YE S, WANG N, BAI M, et al. A Knowledge Graph-Driven Method for Geospatial Data Production [C]//The 30th International Conference on Geoinformatics, London, United Kingdom, 2023.

[43] 高嘉良, 陆锋, 彭澎, 等. 基于网络文本迁移学习的旅游知识图谱构建[J]. 武汉大学学报(信息科学版), 2022, 47(8): 1191-1200.
GAO Jialiang, LU Feng, PENG Peng, et al. Construction of Tourism Attraction Knowledge Graph Based on Web Text and Transfer Learning[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(8): 1191-1200.

[44] 高嘉良, 仇培元, 余丽, 等. 基于旅游知识图谱的可解释景点推荐[J]. 中国科学:信息科学, 2020, 50(7): 1055-1068.
GAO Jialiang, QIU Peiyuan, YU Li, et al. An Interpretable Attraction Recommendation Method Based on Knowledge Graph[J]. *Science in China (Information Sciences)*, 2020, 50(7): 1055-1068.

[45] ZHU Y Q, SUN K, WANG S, et al. An Adaptive Representation Model for Geoscience Knowledge Graphs Considering Complex Spatiotemporal Features and Relationships[J]. *Science China Earth Sciences*, 2023, 66(11): 2563-2578.

[46] NING Y S, LIU H. UrbanKGent: A Unified Large Language Model Agent Framework for Urban Knowledge Graph Construction[PP/OL]. V2. arXiv(2024-10-06)[2025-11-26]. https://arxiv.org/abs/2402.06861.

[47] WANG S, ZHANG X Y, YE P, et al. Geographic Knowledge Graph (GeoKG): A Formalized Geographic Knowledge Representation[J]. *ISPRS International Journal of Geo-Information*, 2019, 8(4): 184.

[48] ZHAO X K, CAO Y B, WANG J H, et al. A Hierarchical Spatiotemporal Object Knowledge Graph Model for Dynamic Scene Representation[J]. *Transactions in GIS*, 2023, 27(7): 1992-2016.

[49] CAO Y W, HUANG Y, CHEN J, et al. Geographic Process Modeling Based on Geographic Ontology[J]. *Open Geosciences*, 2018, 10(1): 782-796.

[50] XUE C J, WU C B, LIU J Y, et al. A Novel Process-Oriented Graph Storage for Dynamic Geographic Phenomena[J]. *ISPRS International Journal of Geo-Information*, 2019, 8(2): 100.

[51] HUANG Y, YUAN M, SHENG Y H, et al. Using Geographic Ontologies and Geo-characterization to Represent Geographic Scenarios[J]. *ISPRS International Journal of Geo-Information*, 2019, 8(12): 566.

[52] ZHENG K, XIE M H, ZHANG J B, et al. A Knowledge Representation Model Based on the Geographic Spatiotemporal Process [J]. *International Journal of Geographical Information Science*, 2022, 36(4): 674-691.

[53] BOUYERBOU H, BECHKOUM K, LEPAGE R. Geographic Ontology for Major Disasters: Methodology and Implementation[J]. *International Journal of Disaster Risk Reduction*, 2019, 34: 232-242.

[54] 朱军, 付林, 李维炼, 等. 知识引导的滑坡灾害场景动态表达方法[J]. 武汉大学学报(信息科学版), 2020, 45(8): 1255-1262.
ZHU Jun, FU Lin, LI Weilian, et al. Knowledge-Guided Dynamic Representation Method of Landslide Disaster Scene[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(8): 1255-1262.

[55] 陈晓慧, 刘俊楠, 徐立, 等. COVID-19病例活动知识图谱构建: 以郑州市为例[J]. 武汉大学学报(信息科学版), 2020, 45(6): 816-825.
CHEN Xiaohui, LIU Junnan, XU Li, et al. Construction of the COVID-19 Epidemic Cases Activity Knowledge Graph: A Case Study of Zhengzhou City [J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(6): 816-825.

[56] 刘俊楠, 刘海砚, 陈晓慧, 等. 利用知识图谱的恐怖主义事件模型[J]. 武汉大学学报(信息科学版), 2022, 47(2): 313-322.
LIU Junnan, LIU Haiyan, CHEN Xiaohui, et al. Terrorism Event Model by Knowledge Graph[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(2): 313-322.

[57] YANG E, HAO F, GAO J, et al. Entity Spatiotemporal Evolution Summarization in Knowledge Graphs [C]//IEEE International Conference on Knowledge Graph, Nanjing, China, 2020.

[58] KAUPPINEN T, VÄÄTÄINEN J, HYVÖNEN E. Creating and Using Geospatial Ontology Time Series in a Semantic Cultural Heritage Portal[C]// The 5th European Semantic Web Conference, Tenerife, Canary Islands, Spain, 2008.

[59] ZHAO T H, HUANG Z D, TU W, et al. Coupling Graph Deep Learning and Spatial-Temporal Influence of Built Environment for Short-Term Bus Travel Demand Prediction[J]. *Computers, Environment and Urban Systems*, 2022, 94: 101776.

[60] YAO X, GAO Y, ZHU D, et al. Spatial Origin-Destination Flow Imputation Using Graph Convolutional Networks[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(12): 7474-7484.

[61] XIA T, LIN J J, LI Y, et al. 3DGCN: 3-Dimensional Dynamic Graph Convolutional Network for Citywide Crowd Flow Prediction[J]. *ACM Transactions on Knowledge Discovery from Data*, 2021, 15(6): 1-21.

[62] SHI H Z, YAO Q M, GUO Q, et al. Predicting Origin-Destination Flow via Multi-perspective Graph Convolutional Network [C]//IEEE 36th International Conference on Data Engineering, Dallas, TX, USA, 2020.

[63] ZHUANG D, WANG S, KOUTSOPOULOS H, et al. Uncertainty Quantification of Sparse Travel Demand Prediction with Spatial-Temporal Graph Neural Networks[C]//The 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, New York, NY, USA, 2022.

[64] LI M X, GAO S, LU F, et al. Prediction of Human Activity Intensity Using the Interactions in Physical and Social Spaces Through Graph Convolutional Networks[J]. *International Journal of Geographical Information Science*, 2021, 35(12): 2489-2516.

[65] ZHANG Y, CHENG T, REN Y B. A Graph Deep Learning Method for Short-Term Traffic Forecasting on Large Road Networks[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2019, 34(10): 877-896.

[66] ROY A, ROY K K, ALI A A, et al. SST-GNN: Simplified Spatiotemporal Traffic Forecasting Model Using Graph Neural Network[PP/OL]. arXiv(2021-03-31)[2026-01-10]. https://arxiv.org/abs/2104.00055.

[67] QI Y X, WU J, BASHIR A K, et al. Privacy-Preserving Cross-Area Traffic Forecasting in ITS: A Transferable Spatial-Temporal Graph Neural Network Approach [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(12): 15499-15512.

[68] CHEN J H, YANG L N, QIN C, et al. Heterogeneous Graph Traffic Prediction Considering Spatial Information Around Roads[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 128: 103709.

[69] BUI K N, CHO J, YI H. Spatial-Temporal Graph Neural Network for Traffic Forecasting: An Overview and Open Research Issues[J]. *Applied Intelligence*, 2022, 52(3): 2763-2774.

[70] GONG J, LIU Y, LI T, et al. Empowering Spatial Knowledge Graph for Mobile Traffic Prediction [C]//The 31st ACM International Conference on Advances in Geographic Information Systems, Hamburg, Germany, 2023.

[71] ZHOU Z, DING J, LIU Y, et al. Towards Generative Modeling of Urban Flow through Knowledge-enhanced Denoising Diffusion[C]//The 31st ACM International Conference on Advances in Geographic Information Systems, Hamburg, Germany, 2023.

[72] CAO D, ZENG K, WANG J, et al. BERT-Based Deep Spatial-Temporal Network for Taxi Demand Prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 9442-9454.

[73] CHEN W Y, HUANG H M, LIAO S Y, et al. Global Urban Road Network Patterns: Unveiling Multiscale Planning Paradigms of 144 Cities with a Novel Deep Learning Approach[J]. *Landscape and Urban Planning*, 2024, 241: 104901.

[74] ZHANG F, ZHOU B L, RATTI C, et al. Discovering Place-Informative Scenes and Objects Using Social Media Photos[J]. *Royal Society Open Science*, 2019, 6(3): 181375.

[75] GEBRU T, KRAUSE J, WANG Y L, et al. Using Deep Learning and Google Street View to Estimate the Demographic Makeup of Neighborhoods Across the United States [J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2017, 114(50): 13108-13113.

[76] FAN Z Y, ZHANG F, LOO B P Y, et al. Urban Visual Intelligence: Uncovering Hidden City Profiles with Street View Images[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2023, 120(27): e2220417120.

[77] KANG Y H, ZHANG F, PENG W Z, et al. Understanding House Price Appreciation Using Multi-source Big Geo-data and Machine Learning [J]. *Land Use Policy*, 2021, 111: 104919.

[78] YANG J C, RONG H, KANG Y H, et al. The Financial Impact of Street-Level Greenery on New York Commercial Buildings[J]. *Landscape and Urban Planning*, 2021, 214: 104162.

[79] ZHANG F, ZHOU B L, LIU L, et al. Measuring Human Perceptions of a Large-Scale Urban Region Using Machine Learning[J]. *Landscape and Urban Planning*, 2018, 180: 148-160.

[80] ZHANG F, FAN Z Y, KANG Y H, et al. "Perception Bias": Deciphering a Mismatch Between Urban Crime and Perception of Safety[J]. *Landscape and Urban Planning*, 2021, 207: 104003.

[81] KANG Y H, ABRAHAM J, CECCATO V, et al. Assessing Differences in Safety Perceptions Using GeoAI and Survey Across Neighbourhoods in Stockholm, Sweden [J]. *Landscape and Urban Planning*, 2023, 236: 104768.

[82] KRUSE J, KANG Y H, LIU Y N, et al. Places for Play: Understanding Human Perception of Playability in Cities Using Street View Images and Deep Learning [J]. *Computers, Environment and Urban Systems*, 2021, 90: 101693.

[83] LAWS, NEIRAM. AnUnsupervisedApproachto Geographical Knowledge Discovery Using Street Level and Street Network Images[C]// The 3rd ACM SIGSPATIAL International Workshop on AI for Geographic Knowledge Discovery, Chicago, IL, USA, 2019.

[84] LIANG X C, ZHAO T H, BILJECKI F. Revealing Spatiotemporal Evolution of Urban Visual Environments with Street View Imagery[J]. *Landscape and Urban Planning*, 2023, 237: 104802.

[85] ZHOU Z, LIU Y, DING J, et al. Hierarchical Knowledge Graph Learning Enabled Socioeconomic Indicator Prediction in Location-Based Social Network[C]//The ACM Web Conference, Austin, TX, USA, 2023.

[86] KANG Y H, ZHANG F, GAO S, et al. Human Settlement Value Assessment from a Place Perspective: Considering Human Dynamics and Perceptions in House Price Modeling[J]. *Cities*, 2021, 118: 103333.

[87] DENG Z R, HAN L Z, ZHU T Y, et al. Urban In-Context Learning: A New Paradigm for Urban Indicator Prediction[C]//The 34th ACM International Conference on Information and Knowledge Management, Seoul, Republic of Korea, 2025.

[88] IDDIANOZIEC, MCARDLEG. TowardsRobustRepresentations of Spatial Networks Using Graph Neural Networks[J]. *Applied Sciences*, 2021, 11(15): 6918.

[89] KONG B, AI T H, ZOU X Y, et al. A Graph-Based Neural Network Approach to Integrate Multi-source Data for Urban Building Function Classification[J]. *Computers, Environment and Urban Systems*, 2024, 110: 102094.

[90] ZHANG X C, LIU X P, CHEN K, et al. Inferring Building Function: A Novel Geo-aware Neural NetworkSupportingBuilding-LevelFunctionClassification [J]. *SustainableCitiesandSociety*, 2023, 89: 104349.

[91] ZHU D, ZHANG F, WANG S Y, et al. Understanding Place Characteristics in Geographic Contexts Through Graph Convolutional Neural Networks [J]. *Annals of the American Association of Geographers*, 2020, 110(2): 408-420.

[92] YAO Y, YAN X Q, LUO P, et al. Classifying Land-Use Patterns by Integrating Time-Series Electricity Data and High-Spatial Resolution Remote Sensing Imagery[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2022, 106: 102664.

[93] ZHANG Y, CHENG T. Graph Deep Learning Model for Network-Based Predictive Hotspot Mapping of Sparse Spatiotemporal Events[J]. *Computers, Environment and Urban Systems*, 2020, 79: 101403.

[94] GE X T, YANG Y, CHEN J H, et al. Disaster Prediction Knowledge Graph Based on Multi-source Spatiotemporal Information [J]. *Remote Sensing*, 2022, 14(5): 1214.

[95] GE X T, YANG Y, PENG L, et al. Spatiotemporal Knowledge Graph Based Forest Fire Prediction with Multi-source Heterogeneous Data[J]. *Remote Sensing*, 2022, 14(14): 3496.

[96] CHEN J H, YANG Y, PENG L, et al. Knowledge Graph Representation Learning-Based Forest Fire Prediction[J]. *Remote Sensing*, 2022, 14(17): 4391.

[97] CHEN L J, GE X T, YANG L N, et al. An Improved Multi-source Data-Driven Landslide Prediction Method Based on Spatiotemporal Knowledge Graph[J]. *Remote Sensing*, 2023, 15(8): 2126.

[98] LI Y, LONG Y. Inferring Storefront Vacancy Using Mobile Sensing Images and Computer Vision Approaches [J]. *Computers, Environment and Urban Systems*, 2024, 108: 102071.

[99] SUN M R, ZHANG F, DUARTE F, et al. Understanding Architecture Age and Style Through Deep Learning[J]. *Cities*, 2022, 128: 103787.

[100] YI Y K, ZHANG Y H, MYUNG J. House Style Recognition Using Deep Convolutional Neural Network [J]. *Automation in Construction*, 2020, 118: 103307.

[101] SHALUNTS G, HAXHIMUSA Y, SABLATNIG R. Architectural Style Classification of Building Facade Windows[C]// International Symposium on Visual Computing, Las Vegas, NV, USA, 2011.

[102] KANG Y, CHO N, YOON J, et al. Transfer Learning of a Deep Learning Model for Exploring Tourists' Urban Image Using Geotagged Photos [J]. *ISPRS International Journal of Geo-Information*, 2021, 10(3): 137.

[103] XUE J W, JIANG N, LIANG S W, et al. Quantifying the Spatial Homogeneity of Urban Road Networks via Graph Neural Networks[J]. *Nature Machine Intelligence*, 2022, 4(3): 246-257.

[104] LIU Y, ZHOU Z L, LI Y, et al. Urban Knowledge Graph Aided Mobile User Profiling [J]. *ACM Transactions on Knowledge Discovery from Data*, 2023, 18(1): 1-30.

[105] 唐曾杨, 艾廷华, 徐海江. 地理知识图谱下的建筑群空间分布模式推理[J]. 地球信息科学学报, 2023, 25(6): 1202-1214.
TANG Zengyang, AI Tinghua, XU Haijiang. Rea-

soning of Spatial Distribution Pattern of Building Cluster Based on Geographic Knowledge Graph[J]. *Journal of Geo-Information Science*, 2023, 25(6): 1202-1214.

[106]ZHAO R, AI T H, YU W H, et al. Recognition of Building Group Patterns Using Graph Convolutional Network[J]. *Cartography and Geographic Information Science*, 2020, 47(5): 400-417.

[107]LIU P Y, DE SABBATA S. A Graph-Based Semi-Supervised Approach to Classification Learning in Digital Geographies[J]. *Computers, Environment and Urban Systems*, 2021, 86: 101583.

[108]LAI Y, SU Y, WEI L, et al. Multi-view Spatial-Temporal Enhanced Hypergraph Network for Next POI Recommendation[C]// The 28th International Conference on Database Systems for Advanced Applications, Tianjin, China, 2023.

[109]WANG D J, WANG X L, XIANG Z Z, et al. Attentive Sequential Model Based on Graph Neural Network for Next Poi Recommendation[J]. *World Wide Web*, 2021, 24(6): 2161-2184.

[110]YU B, ZHANG R Q, CHEN W, et al. Graph Neural Network Based Model for Multi-behavior Session-Based Recommendation[J]. *GeoInformatica*, 2022, 26(2): 429-447.

[111]PRAKKI S, DANESHYARI M. Travel Recommendation System Using Graph Neural Networks [J]. *International Journal of Computing and Artificial Intelligence*, 2023, 4(2): 6-18.

[112]WANG H D, YU Q H, LIU Y, et al. Spatiotemporal Urban Knowledge Graph Enabled Mobility Prediction[PP/OL]. V2. arXiv(2021-11-10)[2025-09-27]. https://arxiv.org/abs/2111.03465.

[113]LIU C, GAO C, JIN D P, et al. Improving Location Recommendation with Urban Knowledge Graph[PP/OL]. arXiv(2021-11-01)[2025-03-24]. https://arxiv.org/abs/2111.01013.

[114]LIU Y, DING J T, LI Y. Knowledge-Driven Site Selection via Urban Knowledge Graph[PP/OL]. arXiv(2021-11-01)[2025-03-28]. https://arxiv.org/abs/2111.00787.

[115]LIU Y Z, TAN H K, KANJARIA R, et al. Classical Feature Embeddings Help in BERT-Based Human Mobility Prediction[PP/OL]. arXiv(2025-10-23)[2025-12-25]. https://arxiv.org/abs/2510.20275.

[116]TERASHIMA H, TAMURA N, SHOJI K, et al. Human Mobility Prediction Challenge: Next Location Prediction using Spatiotemporal BERT[C]//The 1st International Workshop on the Human Mobility Prediction Challenge, New York, NY, USA, 2023.

[117]CAO K, ZHOU C H, CHURCH R, et al. Revisiting Spatial Optimization in the Era of Geospatial Big Data and GeoAI[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2024, 129: 103832.

[118]WANG D, FU Y, WANG P, et al. Reimagining City Configuration: Automated Urban Planning via Adversarial Learning [C]//The 28th International Conference on Advances in Geographic Information Systems, Seattle, WA, USA, 2020.

[119]ZHENG Y, LIN Y M, ZHAO L, et al. Spatial Planning of Urban Communities via Deep Reinforcement Learning[J]. *Nature Computational Science*, 2023, 3(9): 748-762.

[120]MASOUMI Z, VAN GENDEREN J. Artificial Intelligence for Sustainable Development of Smart Cities and Urban Land-Use Management[J]. *Geo-spatial Information Science*, 2024, 27(4): 1212-1236.

[121]SHOER I, SOHSAH G N, OZTAYLAN M, et al. User-Centric Synthetic Road Network Generation Using Graph Neural Networks and Graph Autoencoders [C]//International Conference on Machine Learning and Applications, Jacksonville, FL, USA, 2024.

[122]ZHENG Y, SU H Y, DING J T, et al. Road Planning for Slums via Deep Reinforcement Learning [C]//The 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Long Beach, CA, USA, 2023.

[123]MAI G C, JANOWICZ K, HU Y J, et al. A Review of Location Encoding for GeoAI: Methods and Applications[J]. *International Journal of Geographical Information Science*, 2022, 36(4): 639-673.

[124]MAI G C, XUAN Y, ZUO W Y, et al. Sphere2Vec: Multi-scale Representation Learning over a Spherical Surface for Geospatial Predictions [PP/OL]. arXiv (2022-10-25) [2025-12-23]. https://arxiv.org/abs/2201.10489.

[125]MAI G C, JANOWICZ K, YAN B, et al. Multi-scale Representation Learning for Spatial Feature Distributions Using Grid Cells[PP/OL]. arXiv(2020-02-16)[2025-02-16]. https://arxiv.org/abs/2003.00824.

[126]YAN B, JANOWICZ K, MAI G C, et al. From ITDL to Place2Vec: Reasoning About Place Type Similarity and Relatedness by Learning Embeddings from Augmented Spatial Contexts [C]//The 25th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems, Redondo, Beach, CA, USA, 2017.

[127]ZHANG C, ZHANG K Y, YUAN Q, et al. Regions, Periods, Activities: Uncovering Urban Dynamics via Cross-Modal Representation Learning [C]// The 26th International Conference on World

Wide Web, Perth, Australia, 2017.

[128]SHIMIZU T, YABE T, TSUBOUCHI K. Enabling Finer Grained Place Embeddings Using Spatial Hierarchy from Human Mobility Trajectories[C]//The 28th International Conference on Advances in Geographic Information Systems,Seattle, WA, USA, 2020.

[129]LIN Y, WAN H Y, GUO S N, et al. Pre-training Context and Time Aware Location Embeddings from Spatial-Temporal Trajectories for User Next Location Prediction[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2021, 35(5): 4241-4248.

[130]WU N, CAO Q, WANG Z Y, et al. TorchSpatial: A Location Encoding Framework and Benchmark for Spatial Representation Learning[PP/OL]. V3. arXiv (2025-01-19)[2026-01-11]. https://arxiv.org/abs/2406.15658.

[131]LI Z K, KIM J, CHIANG Y Y, et al. SpaBERT: A Pretrained Language Model from Geographic Data for Geo-Entity Representation[PP/OL]. arXiv[2022-01-28]. https://arxiv.org/abs/2210.12213.

[132]SUN Z H, JIAO H Z, WU H, et al. Block2vVec: An Approach for Identifying Urban Functional Regions by Integrating Sentence Embedding Model and Points of Interest[J]. *ISPRS International Journal of Geo-Information*, 2021, 10(5): 339.

[133]YAO Y, LI X, LIU X P, et al. Sensing Spatial Distribution of Urban Land Use by Integrating Points-of-Interest and Google Word2Vec Model[J]. *International Journal of Geographical Information Science*, 2017, 31(4): 825-848.

[134]ZHANG C K, XU L C, YAN Z, et al. A GloVe-Based POI Type Embedding Model for Extracting and Identifying Urban Functional Regions[J]. *ISPRS International Journal of Geo-Information*, 2021, 10(6): 372.

[135]HUANG W M, CUI L Z, CHEN M, et al. Estimating Urban Functional Distributions with Semantics Preserved POI Embedding[J]. *International Journal of Geographical Information Science*, 2022, 36(10): 1905-1930.

[136]ZHANG J B, LI X, YAO Y, et al. The Traj2Vec Model to Quantify Residents' Spatial Trajectories and Estimate the Proportions of Urban Land-Use Types[J]. *International Journal of Geographical Information Science*, 2021, 35(1): 193-211.

[137]ZHOU Y, HUANG Y. DeepMove: Learning Place Representations Through Large Scale Movement Data[C]// IEEE International Conference on Big Data (Big Data),Seattle, WA, USA, 2019.

[138]LI Y Z, FEI T, ZHANG F. A Regionalization Method for Clustering and Partitioning Based on Trajectories from NLP Perspective[J]. *International Journal of Geographical Information Science*, 2019, 33(12): 2385-2405.

[139]CRIVELLARI A, RESCH B. Investigating Functional Consistency of Mobility-Related Urban Zones via Motion-Driven Embedding Vectors and Local POI-Type Distributions[J]. *Computational Urban Science*, 2022, 2(1): 19.

[140]HU S, GAO S, WU L, et al. Urban Function Classification at Road Segment Level Using Taxi Trajectory Data: A Graph Convolutional Neural Network Approach[J]. *Computers, Environment and Urban Systems*, 2021, 87: 101619.

[141]LUO Y, LEONG C T, JIAO S H, et al. GeoTile2Vec: A Multi-modal and Multi-stage Embedding Framework for Urban Analytics[J]. *ACM Transactions on Spatial Algorithms and Systems*, 2023, 9(2): 1-25.

[142]HUANG Y J, ZHANG F, GAO Y, et al. Comprehensive Urban Space Representation with Varying Numbers of Street-Level Images[J]. *Computers, Environment and Urban Systems*, 2023, 106: 102043.

[143]HAO X X, CHEN W, YAN Y B, et al. UrbanVLP: Multi-granularity Vision-Language Pretraining for Urban Socioeconomic Indicator Prediction[PP/OL]. V3. arXiv (2025-01-22) [2026-01-11]. https://arxiv.org/abs/2403.16831.

[144]JIN J, SONG Y, KAN D, et al. Urban Region Pre-Training and Prompting: A Graph-Based Approach[C]//The 31st ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Toronto, ON, Canada, 2025.

[145]XIAO C, ZHOU J, XIAO Y, et al. ReFound: Crafting a Foundation Model for Urban Region Understanding upon Language and Visual Foundations[C]// The 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining,Barcelona,Spain, 2024.

[146]YIN Y, LIU Z, ZHANG Y, et al. GPS2Vec: Towards Generating Worldwide GPS Embeddings[C]//The 27th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems,Chicago, IL,USA, 2019.

[147]VALSESIA D, FRACASTORO G, MAGLI E. Learning Localized Generative Models for 3D Point Clouds via Graph Convolution[C]//International Conference on Learning Representations, Vancouver, BC, Canada, 2018.

[148]JEAN N, WANG S, SAMAR A, et al. Tile2Vec: Unsupervised Representation Learning for Spatially Distributed Data[J]. *Proceedings of the AAAI Con-*

ference on Artificial Intelligence, 2019, 33(1): 3967-3974.

[149]BALSEBRE P, HUANG W M, CONG G, et al. City Foundation Models for Learning General Purpose Representations from OpenStreetMap[C]//The 33rd ACM International Conference on Information and Knowledge Management, Boise, ID, USA, 2024.

[150]JI C H, LI Q M. TrajSceneLLM: A Multi-modal Perspective on Semantic GPS Trajectory Analysis[PP/OL]. arXiv(2025-06-19)[2025-11-24]. https://arxiv.org/abs/2506.16401.

[151]PATEL H, PARASKEVOPOULOS P, RENZ M. GeoTeGra: A System for the Creation of Knowledge Graph Based on Social Network Data with Geographical and Temporal Information[C]//IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, Barcelona, Spain, 2018.

[152]LIU Y, DING J T, FU Y J, et al. UrbanKG: An Urban Knowledge Graph System[J]. *ACM Transactions on Intelligent Systems and Technology*, 2023, 14(4): 1-25.

[153]LIU Y, ZHANG X, DING J T, et al. Knowledge-Infused Contrastive Learning for Urban Imagery-Based Socioeconomic Prediction[C]//The ACM Web Conference, Austin, TX, USA, 2023.

[154]MAI G C, YAN B, JANOWICZ K, et al. Relaxing Unanswerable Geographic Questions Using a Spatially Explicit Knowledge Graph Embedding Model[C]//The 11th International Conference on Geographic Information Science, Portland, Ore, 2020.

[155]MAI G C, JANOWICZ K, CAI L, et al. SE-KGE: A Location-Aware Knowledge Graph Embedding Model for Geographic Question Answering and Spatial Semantic Lifting[J]. *Transactions in GIS*, 2020, 24(3): 623-655.

[156]SHI H C, DU S D, YANG Y, et al. A Knowledge-Guided Pre-Training Temporal Data Analysis Foundation Model for Urban Computing[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(11): 6259-6271.

[157]YUAN Y, DING J, FENG J, et al. A Universal Pre-training and Prompting Framework for General Urban Spatiotemporal Prediction[EB/OL]. [2025-12-09]. https://ieeexplore.ieee.org/abstract/document/10904327.

[158]HAN J D, WANG H, XIONG H, et al. Scalable Pre-training of Compact Urban Spatiotemporal Predictive Models on Large-Scale Multi-domain Data[J]. *Proceedings of the VLDB Endowment*, 2025, 18(7): 2149-2158.

[159]ZHANG Y Q, LI C, HE S B, et al. Toward Generalized Urban Computing: Pretraining a Spatial-Temporal Model for Diverse Urban Tasks[J]. *IEEE Transactions on Mobile Computing*, 2025, 24(10): 10840-10852.

[160]WU X H, HE H Y, WANG Y C, et al. Pretrained Mobility Transformer: A Foundation Model for Human Mobility[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2026, 27(6): 6775-6786.

[161]MA K, ZHENG S, TIAN M, et al. CnGeoPLM: Contextual Knowledge Selection and Embedding with Pretrained Language Representation Model for the Geoscience Domain[J]. *Earth Science Informatics*, 2023, 16(4): 3629-3646.

[162]HUANG J, WANG H, SUN Y, et al. ERNIE-GeoL: A Geography-and-Language Pre-trained Model and its Applications in Baidu Maps[C]//The 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining, Boise, Idaho, USA, 2024.

[163]WU L X, LIU J L, LOU J H, et al. G2PTL: A Geography-Graph Pre-trained Model[C]//The 33rd ACM International Conference on Information and Knowledge Management, Boise, Idaho, USA, 2024.

[164]LIU X, HU J, SHEN Q, et al. Geo-BERT Pre-training Model for Query Rewriting in POI Search[C]//The 2021 Conference on Empirical Methods in Natural Language Processing, Association for Computational Linguistics, Online, 2021.

[165]DING R, CHEN B, XIE P, et al. MGeo: Multi-modal Geographic Language Model Pre-training[C]//The 46th International ACM SIGIR Conference on Research and Development in Information Retrieval, Taipei, Taiwan, China, 2023.

[166]HOFMANN V, GLAVAŠ G, LJUBEŠIĆ N, et al. Geographic Adaptation of Pretrained Language Models[J]. *Transactions of the Association for Computational Linguistics*, 2024, 12: 411-431.

[167]RAMRAKHIYANI N, VARMA V, PALSHIKAR G, et al. Zero-Shot Probing of Pretrained Language Models for Geography Knowledge[C]//The 4th Workshop on Evaluation and Comparison of NLP Systems, Bali, Indonesia, 2023.

[168]HE P G, CHEN S T, SHI G, et al. HP-BERT: Social Media - Based Insights into Differential Impacts of Urban Environmental Factors on Objective and Subjective Heat Exposure[J]. *Building and Environment*, 2026, 289: 114027.

[169]ZHANG Y, ZHANG F, CHEN N C. Migratable Urban Street Scene Sensing Method Based on Vision Language Pre-trained Model[J]. *International Journal of Applied Earth Observation and Geoinfor-*

mation, 2022, 113: 102989.

[170]CAO S, ZHAO X S, DU S H. Multi-type and Fine-Grained Urban Green Space Function Mapping Based on BERT Model and Multi-source Data Fusion [J]. *International Journal of Digital Earth*, 2024, 17(1): 2308723.

[171]YANG R Y, ZHONG Y F, SU Y, et al. Self-Supervised Joint Representation Learning for Urban Land-Use Classification with Multisource Geographic Data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 5608021.

[172]WEI W T, CHEN H, JIANG Y, et al. An Improved MAE-Based Pretraining Method for Urban Public Space Monitoring with Optical Remote Sensing Imagery[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2025, 18: 16929-16941.

[173]王少华, 谢幸, 李勇, 等. 2024年中国空间数据智能战略发展白皮书[EB/OL]. [2024-07-25]. https://higisx.github.io/zh/news/20240524.html. WANG Shaohua, XIE Xing, LI Yong, et al. White Paper on Strategic Development of Spatial Data Intelligence in China (2024) [EB/OL]. [2024-07-25]. https://higisx.github.io/zh/news/20240524.html.

[174]ZHANG W J, HAN J D, XU Z, et al. Towards Urban General Intelligence: A Review and Outlook of Urban Foundation Models [PP/OL]. V2. arXiv (2025-01-05) [2025-12-28]. https://arxiv.org/abs/2402.01749.

[175]FENG J, ZENG J W, LONG Q Y, et al. A Survey of Large Language Model-Powered Spatial Intelligence Across Scales: Advances in Embodied Agents, Smart Cities, and Earth Science[PP/OL]. arXiv (2025-04-14) [2025-11-22]. https://arxiv.org/abs/2504.09848.

[176]LIANG Y B, LIU Y C, WANG X H, et al. Exploring Large Language Models for Human Mobility Prediction Under Public Events[J]. *Computers, Environment and Urban Systems*, 2024, 112: 102153.

[177]JIANG R H, KOSHIZUKA N, ONIZUKA M, et al. Large Language Models as Urban Residents: An LLM Agent Framework for Personal Mobility Generation [C]//Advances in Neural Information Processing Systems 37, Vancouver, Canada, 2024.

[178]DU Y W, FENG J, YUAN J, et al. CAMS: A CityGPT-Powered Agentic Framework for Urban Human Mobility Simulation[PP/OL]. arXiv(2025-06-16)[2025-12-28]. https://arxiv.org/abs/2506.13599.

[179]FENG J, DU Y W, ZHAO J, et al. AgentMove: A Large Language Model Based Agentic Framework for Zero-Shot Next Location Prediction[PP/OL]. V2. arXiv(2025-02-09)[2025-12-28]. https://arxiv.org/abs/2408.13986.

[180]SHAO C, XU F, FAN B, et al. Beyond Imitation: Generating Human Mobility from Context-Aware Reasoning with Large Language Models[PP/OL]. V2. arXiv(2024-06-05)[2025-06-28]. http://arxiv.org/abs/2402.09836.

[181]MANSOURIAN A, OUCHEIKH R. ChatGeoAI: Enabling Geospatial Analysis for Public Through Natural Language, with Large Language Models[J]. *ISPRS International Journal of Geo-Information*, 2024, 13(10): 348.

[182]LI Z H, XIA L H, TANG J B, et al. UrbanGPT: Spatiotemporal Large Language Models [PP/OL]. V3. arXiv (2024-03-19) [2025-06-28]. https://arxiv.org/abs/2403.00813

[183]LI Z H, XIA L, SHI L, et al. OpenCity: Open Spatiotemporal Foundation Models for Traffic Prediction [PP/OL]. V1. arXiv (2024-08-16) [2025-12-25]. https://doi.org/10.1145/3773912.

[184]FENG J, LIU T H, DU Y W, et al. CityGPT: Empowering Urban Spatial Cognition of Large Language Models[C]// The 31st ACM SIGKDD Conference on Knowledge Discovery and Data Minin, Toronto, Canada, 2025.

[185]HUANG W M, WANG J, CONG G. Zero-Shot Urban Function Inference with Street View Images Through Prompting a Pretrained Vision-Language Model[J]. *International Journal of Geographical Information Science*, 2024, 38(7): 1414-1442.

[186]MANVI R, KHANNA S, MAI G C, et al. GeoLLM: Extracting Geospatial Knowledge from Large Language Models[PP/OL]. V2. arXiv(2024-02-24)[2026-09-25]. https://arxiv.org/abs/2310.06213.

[187]ZHANG Y F, WANG Z Y, HE Z T, et al. BB-GeoGPT: A Framework for Learning a Large Language Model for Geographic Information Science[J]. *Information Processing & Management*, 2024, 61(5): 103808.

[188]KUCKREJA K, DANISH M S, NASEER M, et al. GeoChat: Grounded Large Vision-Language Model for Remote Sensing [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, Seattle, WA, USA, 2024.

[189]LI L, YE Y, ZHOU Y, et al. GeoReasoner: Geo-Localization with Reasoning in Street Views Using a Large Vision-Language Model[PP/OL]. V4. arXiv (2025-11-22)[2025-12-23]. https://arxiv.org/abs/2406.18572.

[190]ROBERTS J, LÜDDECKE T, DAS S, et al.

GPT4GEO: How a Language Model Sees the World's Geography[PP/OL]. arXiv(2023-03-30)[2025-10-20]. https://arxiv.org/abs/2306.00020.

[191]TAN C J, CAO Q, LI Y W, et al. On the Promises and Challenges of Multimodal Foundation Models for Geographical, Environmental, Agricultural, and Urban Planning Applications[PP/OL]. arXiv(2023-11-23)[2025-07-21]. https://arxiv.org/abs/2312.17016.

[192]XU L C, ZHAO S, LIN Q M, et al. Evaluating Large Language Models on Spatial Tasks: A Multi-task Benchmarking Study[PP/OL]. V4. arXiv(2025-01-03)[2025-07-21]. https://arxiv.org/abs/2408.14438.

[193]JI Y H, GAO S, NIE Y, et al. Foundation Models for Geospatial Reasoning: Assessing the Capabilities of Large Language Models in Understanding Geometries and Topological Spatial Relations[J]. *International Journal of Geographical Information Science*, 2025, 39(9): 1866-1903.

[194]ROBERTS J, LÜDDECKE T, SHEIKH R, et al. Charting New Territories: Exploring the Geographic and Geospatial Capabilities of Multi-modal LLMS[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Seattle, WA, USA, 2024.

[195]MAI G C, HUANG W M, SUN J, et al. On the Opportunities and Challenges of Foundation Models for Geospatial Artificial Intelligence[PP/OL]. arXiv(2023-04-13)[2025-12-24]. https://arxiv.org/abs/2304.06798.

[196]FENG J, ZHANG J, LIU T H, et al. CityBench: Evaluating the Capabilities of Large Language Models for Urban Tasks[PP/OL]. V3. arXiv(2025-03-31)[2025-11-21]. https://arxiv.org/abs/2406.13945.

[197]KRECHETOVA V, KOCHEDYKOV D. GeoBenchX: Benchmarking LLMS in Agent Solving Multistep Geospatial Tasks[PP/OL]. V2. arXiv(2025-10-22)[2025-12-25]. https://arxiv.org/abs/2503.18129

[198]MOONEY P, CUI W C, GUAN B Y, et al. Towards Understanding the Geospatial Skills of ChatGPT: Taking a Geographic Information Systems (GIS) Exam[C]//The 6th ACM SIGSPATIAL International Workshop on AI for Geographic Knowledge Discovery, Hamburg, Germany, 2023.

[199]MANVI R, KHANNA S, BURKE M, et al. Large Language Models Are Geographically Biased[C]// The 41st International Conference on Machine Learning, Vienna, Austria, 2024.

[200]ZHANG Q H, GAO S, WEI C, et al. GeoAnalystBench: A GeoAI Benchmark for Assessing Large Language Models for Spatial Analysis Workflow and Code Generation[PP/OL]. arXiv(2025-09-07)[2025-11-21]. https://arxiv.org/abs/2509.05881.

[201]ZHANG Y F, WEI C, WU S Y, et al. GeoGPT: Understanding and Processing Geospatial Tasks Through an Autonomous GPT[PP/OL]. arXiv(2023-07-16)[2025-07-26]. https://arxiv.org/abs/2307.07930.

[202]CHEN Y X, WANG W J, LOBRY S, et al. An LLM Agent for Automatic Geospatial Data Analysis[PP/OL]. V2. arXiv(2024-10-25)[2025-12-25]. https://doi.org/10.48550/arXiv.2410.18792.

[203]DU Y W, FENG J, ZHAO J, et al. TrajAgent: An LLM-Agent Framework for Trajectory Modeling *via* Large-and-Small Model Collaboration[PP/OL]. V5. arXiv(2025-10-28)[2025-12-25]. https://doi.org/10.48550/arXiv.2410.20445.

[204]ZHANG Y F, HE Z T, LI J X, et al. MapGPT: An Autonomous Framework for Mapping by Integrating Large Language Model and Cartographic Tools[J]. *Cartography and Geographic Information Science*, 2024, 51(6): 717-743.

[205]GUO T C, CHEN X Y, WANG Y Q, et al. Large Language Model Based Multi-agents: A Survey of Progress and Challenges[PP/OL]. V2. arXiv(2024-04-19)[2025-12-23]. https://doi.org/10.48550/arXiv.2402.01680.

[206]DESHPANDE R, VIJAY PATEL S, WEIJENBERG C, et al. Generative Pre-trained Transformers for 15-Minute City Design[C]//The 28th Conference on Computer Aided Architectural Design Research in Asia, Hong Kong, China, 2023.

[207]ZHU H, ZHANG W J, HUANG N X, et al. PlanGPT: Enhancing Urban Planning with Tailored Language Model and Efficient Retrieval[PP/OL]. arXiv(2024-02-29)[2025-11-20]. https://arxiv.org/abs/2402.19273.

[208]ZHOU Z L, LIN Y M, JIN D P, et al. Large Language Model for Participatory Urban Planning[PP/OL]. arXiv(2024-02-27)[2025-06-15]. https://arxiv.org/abs/2402.17161.

[209]QIAN K J, MAO L J, LIANG X, et al. AI Agent as Urban Planner: Steering Stakeholder Dynamics in Urban Planning via Consensus-Based Multi-agent Reinforcement Learning[PP/OL]. V2. arXiv(2023-11-09)[2025-11-20]. https://arxiv.org/abs/2310.16772.

[210]KALYUZHNAYA A, MITYAGIN S, LUTSENKO E, et al. LLM Agents for Smart City Management: Enhancing Decision Support Through Multi-agent AI Systems[J]. *Smart Cities*, 2025, 8(1): 19.

[211]WANG S Q, HU T, XIAO H, et al. GPT, Large Language Models (LLMS) and Generative Artificial Intelligence (GAI) Models in Geospatial Science: A Systematic Review[J]. *International Journal of Digital Earth*, 2024, 17(1): 2353122.