

语义引导下的本体知识驱动城市土地利用分类

曹蕊¹, 朱凌¹, Li Songnian², 周越旋¹

1. 北京建筑大学 测绘与城市空间信息学院, 北京 102616;

2. 多伦多都会大学 土木工程系, 多伦多 M5B 2K3

摘要: 城市的快速发展和功能需求的日益变化使得城市土地利用类型更加复杂和多元, 如何自动、高效地获取精细的城市土地利用信息成为当前亟须解决的问题。针对以深度学习为代表的驱动方法可解释性弱与样本依赖性强的局限, 本文提出一种语义引导下的知识驱动城市土地利用分类方法。该方法融合遥感影像、开放街道地图 OSM (OpenStreetMap, 含兴趣点 POI (Point of Interest) 和兴趣面 AOI (Area of Interest)) 数据、本地气候区 LCZ (Local Climate Zones) 数据及全球人类居住 WSF (World Settlement Footprint) 数据等多源数据与产品, 基于 EAGLE (EIONET action group on land monitoring in Europe) 矩阵重构土地利用类型语义, 解析出本体基元, 进而提取众源数据特征、遥感指数与相关形态学指数来匹配基元的属性特征, 通过基元组合与特征约束构建本体模型。在此基础上, 提出一种融合“光谱+路网”的分割策略, 将生成的城市土地利用同质地块作为本体推理的实例, 最终通过逻辑推理判定每个地块的土地利用类型, 得到分类结果。为验证方法有效性, 选取土地利用高度复杂的加拿大多伦多市中心进行实验。结果表明, 语义引导下的知识驱动分类结果总体精度达到 87.02%, Kappa 系数为 0.84, 不仅实现了高精度分类, 融合光谱与路网的分割策略也使分类结果边界更符合实际地表情况, 为城市土地利用的精准识别与监测提供了可靠且可解释的新思路。

关键词: 知识驱动, 语义信息, EAGLE 矩阵, 多源数据, 城市土地利用

中图分类号: P237/P2

引用格式: 曹蕊, 朱凌, Li Songnian, 周越旋. 2026. 语义引导下的本体知识驱动城市土地利用分类. 遥感学报, 30(6): 1677-1695

Cao R, Zhu L, Li Songnian and Zhou Y X. 2026. Semantic-guided ontology knowledge-driven urban land use classification. National Remote Sensing Bulletin, 30(6): 1677-1695 [DOI: 10.11834/jrs.20265440]

1 引言

据 2018 年联合国统计, 全球有过半人口居住在城市, 且 2050 年预计城市人口比例增至 68% (UN, 2018)。作为人类改造土地的集中体现, 城市土地利用不仅反映了人类活动与城市景观的相互作用, 也是土地资源开发的核心与目标 (Gong 等, 2020)。因此, 精确绘制住宅、商业、工业与公共服务等城市土地利用类型的空间分布至关重要 (Zhang 等, 2018; McCutchan 和 Giannopoulos, 2022), 能直接为城市规划与管理提供数据支撑, 助力营造更加宜居、可持续的城市环境 (Li 等, 2024)。

传统土地利用信息获取方法主要通过野外调

查或人工图像判读, 存在效率低的局限。例如, 中国多时期土地利用遥感监测数据集 CNLUCC (multi-period land use land cover remote sensing monitoring dataset in China) (徐新良 等, 2018)、欧洲共同体环境信息协作计划 CORINE (coordination of information on the environment) (Bossard 等, 2000; Büttner, 2014) 土地覆盖项目以及中国每年的国土变更调查 (自然资源部, 2021) 均以人工解译为主。面对日益增长的土地利用动态监测与快速更新需求, 发展自动化生成技术已十分迫切。尽管首个全球范围城市土地利用数据集 GULU (Global Urban Land Use map) (Xiong 等, 2025) 的发布标志着重要进展, 但自动化生成城市土地利用产品的方法研究仍是亟待加强的关键环节 (Talukdar

收稿日期: 2025-10-18; 预印本: 2026-04-23

基金项目: 国家重点研发计划 (编号: 2021YFE0194700)

第一作者简介: 曹蕊, 研究方向为遥感图像信息提取与分析技术。E-mail: cao_rui_cn@163.com

通信作者简介: 朱凌, 研究方向为多源数据地表覆盖智能提取及遥感地表覆盖的分类、更新与整合。E-mail: zhuling@bucca.edu.cn

等, 2020; Li 等, 2023)。

当前城市土地利用分类的难点在于, 其复杂的社会经济功能难以通过单一数据源有效识别。与侧重于地表物理属性的土地覆盖不同 (Petrou 等, 2015; Zhu 等, 2021), 土地利用不仅包含光谱、纹理等属性 (Wu 等, 2009; Hu 和 Wang, 2013; Song 等, 2018), 更蕴含大量具有强解释性的社会经济属性 (Fang 等, 2022; Huang 等, 2020)。大数据时代为获取社会经济数据提供了契机, 智能终端、万维网联盟 W3C (World Wide Web consortium)、众源数据 (如 POI) 的普及, 使得表征社会经济属性的数据变得丰富且易于获取。因此, 融合多源数据与遥感技术进行土地利用识别的研究日益增多, 以 POI 为代表的众源数据在其中扮演着关键角色 (Lu 等, 2022; Su 等, 2024; Zhu 等, 2025)。然而, 众源数据依赖于用户生成, 在人口稀疏区存在数据缺失问题。为此, Tian 等 (2024) 提出以 LCZ 数据作为 POI 的替代方案, 并验证了 LCZ 可达到与 POI 相当的分类精度。此外, 由德国航空航天中心 DLR (Deutsches Zentrum für Luft- und Raumfahrt) 与地球观测中心 EOC (Earth Observation Center) 联合发布的全球 10 m 级分辨率人类居住区 WSF (world settlement footprint) 数据集 (Marconcini 等, 2020; Esch 等, 2022), 能刻画建成区 (如建筑、道路等) 的空间分布, 为识别建筑提供关键辅助。基于上述研究进展, 融合 POI 数据、AOI 数据、LCZ 数据及 WSF 等多源数据, 能更全面地捕捉土地利用信息, 实现更精准的城市土地利用分类。

在城市土地利用研究中, 当前主流的数据驱动方法也面临挑战。土地利用分类的数据驱动方法主要有支持向量机 (潘娇 等, 2024)、随机森林 (Gong 等, 2020)、决策树 (贾玉洁 等, 2022)、Transformer (鲁伟鹏 等, 2024) 和卷积神经网络 (Cao 等, 2020) 等。数据驱动方法存在模型性能受制于训练数据、“黑盒”特性导致可解释性低, 以及侧重于统计归纳, 难以有效融入地学先验知识与实体间语义信息的局限 (Li 等, 2022; Liu 等, 2020)。相比之下, 知识驱动方法独立于数据, 具备可解释性、强人工干预能力与良好的领域适应性, 能有效弥合分类产品与用户认知之间的语义鸿沟 (顾海燕, 2015; Gu 等, 2017; 顾海燕 等, 2018; Zhu 等, 2024)。本体 (Ontology)

作为对领域概念进行形式化表达与推理的工具, 具有强大的知识表示与共享能力, 已成为遥感知识驱动分类的核心范式 (Arvor 等, 2019, 2021; Adamo 等, 2020)。近年来, 基于多源数据构建本体进行推理的研究已展现出潜力。例如, Zhu 等 (2024) 利用多源数据实现了城市地表要素的高精度分类; 苏墨 (2021) 融合遥感影像、POI、激光雷达点云等多源数据, 结合机器学习与知识图谱, 提升了城市土地分类的精度; Ismayilova 和 Timpf (2023) 通过构建城市绿地本体, 结合开放街道地图 OSM (OpenStreetMap) 等多源数据, 改善了现有土地利用/土地覆盖产品中绿地分类的准确性与完整性。因此, 为克服数据驱动方法的固有局限, 并充分融合多源数据中的复杂语义, 采用基于本体推理的知识驱动方法, 可以实现可靠、可解释的城市土地利用分类。

城市土地利用分类的另一个难点在于, 现有研究对不同分类体系的类别语义重视不足。语义表达与类别定义的差异广泛存在于各土地覆盖/土地利用分类体系之间, 极易混淆。例如, 在安德森分类体系 (Anderson 等, 1976) 中, “商业和服务”类别的描述主要为: “主要用于销售产品和提供服务, 常被住宅、农业或其他用途包围, 组成部分包括城市中心商业区、郊区和边远地区的购物中心、沿主要高速公路和城市入口道路分布的商业街、废品场、度假村等。”而中国基本城市土地利用制图产品中国基本城市土地利用类型 EULUC-China (essential urban land use categories in China) (Gong 等, 2020) 则明确定义“商业和服务”类型为: “用于商业零售、餐馆、住宿和娱乐的房屋和建筑物。”二者名称相同, 语义却差异显著。当前大多数分类研究忽视了类别语义信息的表达, 致使数据生产者与最终用户对类别的理解不一致, 容易产生语义鸿沟。为减少语义差距, 欧盟成员国组成的土地监测行动小组提出了“EAGLE” (EIONET action group on land monitoring in Europe) 的概念。EAGLE 矩阵将地类概念拆解为 3 个组件: 地表覆盖成分 LCC (Land Cover Components)、土地利用属性 LUA (Land Use Attributes/function) 和特征 CH (characteristics)。其中, LUA 模块包含了大量详细描述城市功能的属性, 尤其适用于城市土地利用分类。通过组件的灵活拆分与重组, EAGLE 矩阵能解构并表达类别语义, 可

有效避免传统语义翻译中的混淆与模糊 (Arnold 等, 2015)。因此, 为强化分类体系的语义表达并弥合语义鸿沟, 可以采用EAGLE矩阵对目标分类体系进行分析和重构。通过提取类别概念中最小的语义组成单元作为本体基元, 并组合本体基元构建本体, 实现类别语义的精确、形式化表达。

本研究在城市土地利用分类领域的主要贡献包括: 提出了一种语义引导下的知识驱动方法, 在遥感影像和POI数据的基础上, 融合OSM (含POI和AOI)、LCZ与WSF等多源数据与产品, 捕捉土地利用的物理与经济属性; 采用本体知识驱动的分类机制, 克服了传统数据驱动方法对样本的依赖及可解释性弱的局限; 引入EAGLE矩阵对类别语义进行系统性分解, 增强了分类过程中的语义表达。本研究通过融合多源数据、EAGLE矩阵与本体构建的创新性技术路线, 并充分借助类别语义信息, 实现了无需样本参与且具备强可解释性的土地利用分类, 为城市土地利用监测、规划与管理提供了精准的参考依据和新的分类方案。

2 研究区与数据

2.1 研究区概况

研究区位于加拿大多伦多市的中心区 (图1), 具体范围北起圣克莱尔大道, 南至湖滨大道与嘉丁纳高速公路, 西抵达弗林街, 东达唐谷公园大道。研究区作为多伦多高度发达的核心区, 聚集了众多大学、金融商业、高层住宅、休闲娱乐与办公场所, 构成了包含商业、服务、住宅、交通等类型的复杂城市土地利用场景, 是进行复杂城市土地利用分类研究的理想区域。

城市土地利用的分类体系以《土地利用现状分类》(GB/T 21010—2017) 为基准。该体系标准基于土地使用功能, 类别丰富, 契合城市土地利用描述需求。从中选取适用于城市分析的类别: 商服用地、住宅用地、公共管理与公共服务用地、特殊用地、交通运输用地、其他土地。针对城市中普遍存在的同一地块内多种功能并存的土地混合利用现象, 本研究增设了“混合用地”类别。该类别的设置参考了安德森体系中的混合地类思路 (Anderson 等, 1976), 并借鉴了吴鹏 (2020) 对美国规划协会相关混合利用观点的梳理。其形式主要包括: 垂直混合 (如高层建筑底层为商业、

上层为住宅区或办公区) 与水平混合 (如街道两侧同时分布住宅、商业、公园等)。区分混合用地与单一用地时, 则依据吴鹏 (2020) 的方法: 在空间上挖掘众源数据的同位模式; 在功能上分析不同区域之间的互补性 (如住宅区与商业区的互补)。若众源数据的主导功能突出 (>50%) 或功能互补性弱, 则归为单一用地类型; 若主导功能不显著且功能互补性强, 则判定为混合用地。最终土地利用类别体系如表1所示。




图1 研究区2019年9月19日哨兵二号卫星真彩色影像
Fig. 1 Sentinel-2 satellite true color image of the study area, September 19, 2019

2.2 数据

实验数据时间基准为2019年, 选用2019年9月19日的哨兵二号遥感数据。9月当地植被光谱特征显著, 与不透水面差异明显, 且19日云量条件极佳, 适宜开展城市土地利用分类研究。此外, 本研究还采用了以下多源数据: 从OSM数据平台下载的POI数据、AOI数据及路网数据, 多伦多政府官方开放数据平台提供的POI数据、本地气候区LCZ数据、WSF数据。实验所用POI、AOI数据均经过人工筛选整合, 具体数据来源与描述见表2。

为了评估分类效果, 组织遥感土地利用解译专家按照表1的一级分类, 人工解译研究区2019年9月19日的10 m分辨率哨兵二号遥感影像, 从而获得土地利用真值图 (图2)。解译过程中, 除遥感影像外, 还参考了同期谷歌地图历史影像与历史街景影像, 以辅助判断建筑用途与高度; 同时, 借助OSM历史查看器, 核实区域的店铺名称、校园边界等辅助信息。

表1 土地利用类别体系

Table 1 Land use category system

一级类名称	含义	包含的二级类
商服用地	主要用于商业、服务业的土地	零售商业用地、批发市场用地、餐饮用地、旅馆用地、商务金融用地、娱乐用地、其他商服用地
住宅用地	主要用于人们生活居住的房基地及其附属设施的土地	城镇住宅用地、农村宅基地
公共管理与公共服务用地	用于机关团体、新闻出版、科教文卫、公用设施等的土地	机关团体用地、新闻出版用地、教育用地、科研用地、医疗卫生用地、社会福利用地、文化设施用地、体育用地、公用设施用地、公园与绿地
特殊用地	用于军事设施、涉外、宗教、监教、殡葬、风景名胜等的土地	军事设施用地、使领馆用地、监教场所用地、宗教用地、殡葬用地、风景名胜设施用地
交通运输用地	用于运输通行的地面线路、场站等的土地,包括民用机场、汽车客货运场站、港口、码头、地面运输管道和各种道路以及轨道交通用地	铁路用地、轨道交通用地、公路用地、城镇村道路用地、交通服务场站用地、农村道路、机场用地、港口码头用地、管道运输用地
混合用地	同一土地或建筑空间涵盖两种及以上的土地利用类型,如居住商业混用、商业办公混用等。	—
其他土地	上述地类以外的其他类型的土地	—

表2 数据来源与描述

Table 2 Data source and description

数据	描述	来源
哨兵二号卫星遥感多光谱影像	欧洲空间局发布的卫星遥感数据,覆盖13个光谱波段,空间分辨率分别为10 m、20 m和60 m,适用于地表覆盖和土地利用变化监测	https://browser.dataspace.copernicus.eu/
开放街道地图数据	全球协作的开放地理矢量数据集,包含兴趣点、兴趣面及路网等矢量数据,提供丰富的地理位置与社会功能属性	http://www.geofabrik.de/
多伦多市官方众源数据	多伦多政府官方网站提供,包含酒店、文化空间、银行、公交站点等具体名称数据	https://www.toronto.ca/
本地气候区数据	描述城市地表覆盖和建筑形态的栅格数据,包含建筑高度、密度及地表材质等信息,可作为城市分析的描述因子	https://www.wudapt.org/
全球人类居住数据	由德国航空航天中心开发的高分辨率全球人类居住区测绘产品(2019年版本),用于识别区域内建筑信息	https://geoservice.dlr.de/web/




图2 研究区土地利用地表真实情况

Fig. 2 The actual land use situation in the study area

3 方法

语义引导下的本体知识驱动城市土地利用分类方法的核心流程（图3）包括3个步骤。首先是本体基元提取：提取多源数据特征及遥感指数，利用EAGLE矩阵将每个土地利用类别语义解构为本体基元，并建立“数据特征—本体基元—土地利用类别”之间的映射关系。其次是本体模型构建：基于分类体系建立本体模型框架，将本体基元进行组合，并根据各类别的基元特征与组合建立规则。最后是影像分割与本体推理分类：对遥感影像进行融合路网与影像光谱的分割，生成的同质地块作为实例导入本体模型，通过逻辑推理自动得到分类结果，并进行对比实验与评价分析。




图3 总体流程
Fig. 3 Overall flowchart

3.1 本体基元提取

本体基元是描述地理实体特征与属性的最小语义单元，基元的组合可表达土地利用类型中蕴含的语义信息。EAGLE矩阵作为分解地类语义的工具，可用于土地利用类别的语义解构来获取基元，并利用多源遥感数据的特征指数对这些基元进行定量表征。具体提取流程如下：提取多源数据特征并计算遥感指数，作为表征基元的属性；然后基于EAGLE矩阵，解析并提取对应的本体基元，建立数据特征与本体基元以及本体基元与土地利用类别之间的映射关系，为后续构建本体模型与语义规则奠定基础。

3.1.1 多源数据特征提取与遥感指标计算

计算众源数据特征时，将众源数据进行清洗、筛选与合并等预处理后，计算密度特征，如公共密度、商服密度、路网密度等；AOI数据则转换为栅格格式，用于表征住宅、教堂、酒店及商超等面状要素的分布，并提取LCZ、WSF数据所含信息。最终，生成一系列反映土地利用社会经济属性的特征图。

提取遥感影像特征时，对哨兵二号影像进行预处理，计算专题指数（如植被覆盖度、归一化植被指数、归一化水体指数、形态学建筑指数）与影像特征（包括几何、纹理与光谱特征）。提取的主要特征如图4所示，具体含义如表3所示。




图4 数据特征与遥感指标
Fig. 4 Data features and remote sensing indicators

表3 指标含义
Table 3 Meaning of indicators

名称	含义
归一化植被指数 NDVI (Normalized Difference Vegetation Index)	由可见光波段和近红外波段反射率计算,定量评估地表植被的生长状况与生物量
归一化水体指数 NDWI (Normalized Difference Water Index)	利用绿光波段与近红外波段,增强水体信息并抑制植被与土壤背景,提取水体范围
归一化建筑指数 NDBI (Normalized Difference Built-up Index)	利用短波红外波段与近红外波段,识别城镇、建筑等人造地表区域,区分建成区与自然地表
植被覆盖度 FVC (Fractional Vegetation Cover)	植被冠层垂直投影面积所占的百分比,反映地表植被茂密程度
形态学建筑物指数 MBI (Morphological Building Index)	基于形态学运算,从高分辨率影像中提取建筑物轮廓,反映像元属于建筑物顶部的概率
阴影指数 SI (Shading Index)	用于检测与增强影像中的阴影区域,辅助区分建筑物、树木等造成的阴影
裸土指数 BSI (Bare Soil Index)	突出裸露土壤信息,增强土壤与植被、水体等其他地类之间的光谱差异
均值	影像对象在某一波段或全波段的平均反射率或平均辐射值,反映总体亮度水平
熵	基于灰度共生矩阵计算,度量图像纹理的复杂性与无序程度
形状指数	对象形状相对于标准圆形的紧凑程度,描述形状为简单且紧凑还是复杂且松散

3.1.2 本体基元拆解与关系映射

EAGLE矩阵通过3个组件对土地利用及土地覆盖进行系统描述:LCC从视觉和物理层面界定地表覆盖状态,如建筑、树木、水体等;LUA描述社会经济功能,如居住、商业、工业等用途;CH则阐述具体生物物理属性、空间形态与管理措施。

矩阵中各层级的单元均可作为本体基元,EAGLE矩阵的部分内容示例如表4、表5、表6所示。基元提取时,需根据目标土地利用类别语义,从3个组件中选取对应单元进行组合。以“商服用地”为例,其定义为主要用于商业、服务业的土

地,涵盖零售商业、批发市场、餐饮、旅馆、商务金融、娱乐用地等二级类别。其语义可拆解为:LCC组件对应“人工表面与结构”和“非生物/无植被的表面和物体”;LUA组件对应“服务业(第三部门)”下的“商业服务”、“金融、专业和信息服务”、“住宿和餐饮服务”及“文化和娱乐服务”;CH组件对应“零散的”、“分散单一的房屋,不连续”。所选基元需通过数据特征进行表征,其中遥感特征主要表达LCC与CH组件,众源数据特征集中表达LUA组件。图5展示了商服用地类别与多源数据特征、本体基元组件之间的映射关系。

表4 EAGLE矩阵LCC模块部分内容
Table 4 Part of the EAGLE matrix LCC module

矩阵模块名称	第一层级	第二层级	第三层级	第四层级	第五层级	第六层级
地表覆盖成分 (LCC)	非生物/无植被 的表面和物体	人工表面 与结构	密封的人工表 面和结构	建筑	传统建筑	如房屋、公寓楼、城市街区、商店
					特定的建筑物	如体育场、教堂、塔楼、温室
				其他建筑	特定的结构和设施	如炼油厂、污水处理厂、回收设施、水坝、储罐(主要是技术结构)
	非密封的人工 表面和结构				开放的密封表面	如沥青、混凝土铺设的表面(如道路、停车场、广场等)
				废料	例如公用/工业废料	—
				开放非密封的人工 表面	离开原来的地方,人为地合并,如物流和仓储区、节庆广场、无植被的运动场及铁路轨道	—

表5 EAGLE矩阵LUA模块部分内容
Table 5 Part of the EAGLE matrix LUA module

矩阵模块名称	第一层级	第二层级	第三层级
土地利用属性 (LUA)	主要生产部门	农业	—
		林业	—
		采矿和采石场	—
		水产养殖和渔业	—
		其他主要生产	—
	服务业 (第三部门)	商业服务	—
		金融、专业和 信息服务	—
		住宿和餐饮服务	—
		文化和娱乐服务	文化服务
			娱乐节目
			体育基础设施
	住宅的	永久居住	—
		住宅使用与其他 兼容用途	—
		其他住宅	如临时房屋、 周末房屋、 假日别墅
	运输网络、物流、 公用事业	运输网络	—
		物流仓储	—
		公用事业	—

表6 EAGLE矩阵CH模块部分内容
Table 6 Part of the EAGLE matrix CH module

矩阵模块名称	第一层级	第二层级	第三层级
特征(CH)	空间形式	空间分布格局	均匀
			混合的
			镶嵌的
			零散的
			篱
			一排排的树木
	线性(技术)	线性模式	石头墙
			路
			管道
			宏观的景观 形式
			如沙丘、冰碛、溪谷、 峡谷
			组合模式
	空间背景	组合模式	分散单一的房屋， 不连续
			单块，不连续
			郊区排屋/排屋/ 半独立式住宅
			城市街区、封闭战线
			大型复杂建筑、大殿
			城市的
			农村的
			河岸




图5 商服用地类别、本体基元与数据特征关系概述图(白色椭圆表示拆解出的本体基元,柱体表示基元对应的数据特征及指数,虚线箭头表示本体基元与土地利用类别的对应关系,绿色细实线表示LUA模块制作密度图时选择的众源数据类型与本体基元的对应关系)

Fig. 5 Overview diagram of the relationships among commercial service facility land categories , ontological primitives , and data characteristics. (The white ellipses represent the disassembled ontology primitives , the columns represent the data features and indices corresponding to the primitives , the dashed arrows indicate the correspondence between the ontology primitives and the land use categories , and the green solid lines represent the correspondence between the crowdsource data types selected by the LUA module when making density maps and the ontology primitives)

3.2 本体模型构建与规则描述

3.2.1 本体模型构建

本体模型的构建始于框架设计，首先确立类框架与属性框架。在将土地利用类别定义为“类”的同时，为建立基元与类别的关联，EAGLE矩阵3个模块基元也被纳入类框架中。通过定义基于数据特征的语义规则来描述基元类别，并通过基元组合完成对土地利用类型的语义规则描述。模型构建使用斯坦福大学开发的protege 5.5本体编辑工具（Musen，2015）；采用万维网本体语言OWL（Web ontology language）（W3C OWL Working Group，2012）定义城市土地利用类型和图像对象特征；使用语义网规则语言SWRL（semantic Web rule language）（Horrocks等，2004）编写语义规则；最后，利用与protege集成的FaCT++描述逻辑推理机（Tsarkov和Horrocks，2006）校验本体一致性并执行规则推理。

本体构建过程涉及两个关键环节：其一为类别语义表达——使用不同本体基元组合表达类别语义，如前文对商服用地的拆解；其二为建立数据与基元映射规则——利用多源数据特征，建立影像数据与本体基元之间的联系（具体规则将在下节展示）。构建过程见图6。




图6 本体构建架构(黑色实线箭头表示数据信息到本体的转换,虚线箭头表示规则约束关系)

Fig. 6 Ontology construction framework (The black solid arrow indicates the transformation of data information to the ontology , while the dashed arrow represents the rule constraint relationship)

3.2.2 语义规则建立

以“商服用地”的归类为例，基于构建的城市土地利用本体模型框架，使用SWRL语言描述规则（规则描述及含义如表7所示），其核心在于一个区域需同时满足对应的基元条件，才可被推定为商服用地。

表7 商服用地规则描述及含义
Table 7 Description and meaning of commercial land use rules

SWRL规则	具体含义
分散单一的房屋,不连续(? x),服务业(第三产业)(? x),零散的(? x),非生物/无植被的表面和物体(? x),人工表面与结构(? x)->商服用地(? x)	若一个区域(? x)同时满足“分散单一的房屋,不连续”、“服务业(第三产业)”、“零散的”、“非生物/无植被的表面和物体”以及“人工表面与结构”的基元条件,则归类为商服用地
紧凑性(? x, ? y), greaterThanOrEqualTo(? y, 1.18), lessThan(? y, 2.0), GLCM_熵(? x, ? z), greaterThanOrEqualTo(? z, 5.5), lessThanOrEqualTo(? z, 8.3)->零散的(? x)	满足紧凑性∈[1.18, 2.0]且GLCM_熵∈[5.5, 8.3],可被推定为零散的
FVC(? x, ? y), greaterThanOrEqualTo(? y, 0.0), lessThan(? y, 0.3), NDVI(? x, ? z), greaterThanOrEqualTo(? z, -1.0), lessThan(? z, 0.05)->非生物/无植被的表面和物体(? x)	满足植被覆盖度∈[0, 0.3]且归一化植被指数∈[-1.0, 0.05),可被推定为非生物/无植被表面和物体
WSF(? x, ? y), greaterThanOrEqualTo(? y, 1300.0),SI(? x, ? z), greaterThanOrEqualTo(? z, 1200.0), lessThan(? z, 1600.0),MBI(? x, ? w), greaterThanOrEqualTo(? w, 0.45), lessThanOrEqualTo(? w, 1.0)->人工表面与结构(? x)	满足WSF≥1300、阴影指数∈[1200, 1600)且形态学建筑指数∈[0.45, 1.0],可被推定为人工表面与结构
LCZ8(? x, ? y), greaterThanOrEqualTo(? y, 893.0), 密度(? x, ? z), greaterThanOrEqualTo(? z, 1.8), 形状指数(? x, ? w), greaterThanOrEqualTo(? w, 1.3)->分散单一的房屋,不连续(? x)	满足LCZ8≥893、密度≥1.8且形状指数≥1.3可被推定为分散单一的房屋,不连续
商业密度(? x, ? y), greaterThanOrEqualTo(? y, 510.0), 商业属性面(? x, ? z), greaterThanOrEqualTo(? z, 427.0)->服务业(第三产业)(? x)	满足商业密度≥510且商业属性面≥427,可被推定为服务业(第三产业)

为评估规则阈值的可靠性，采用单变量扰动法分析规则敏感度。具体做法是：保持其他阈值不变，上下扰动单一阈值（±5%），然后对比分类图并计算类别总面积变化率与空间一致性（Dice 系数）。结果表明，扰动范围内总面积变化率小于

5%，Dice 系数大于 0.85，证明规则具有良好的稳健性。集成上述语义规则后的本体模型如图 7 所示，其中左侧为本体类别概念框架，中间为属性框架，右侧为描述的语义规则。

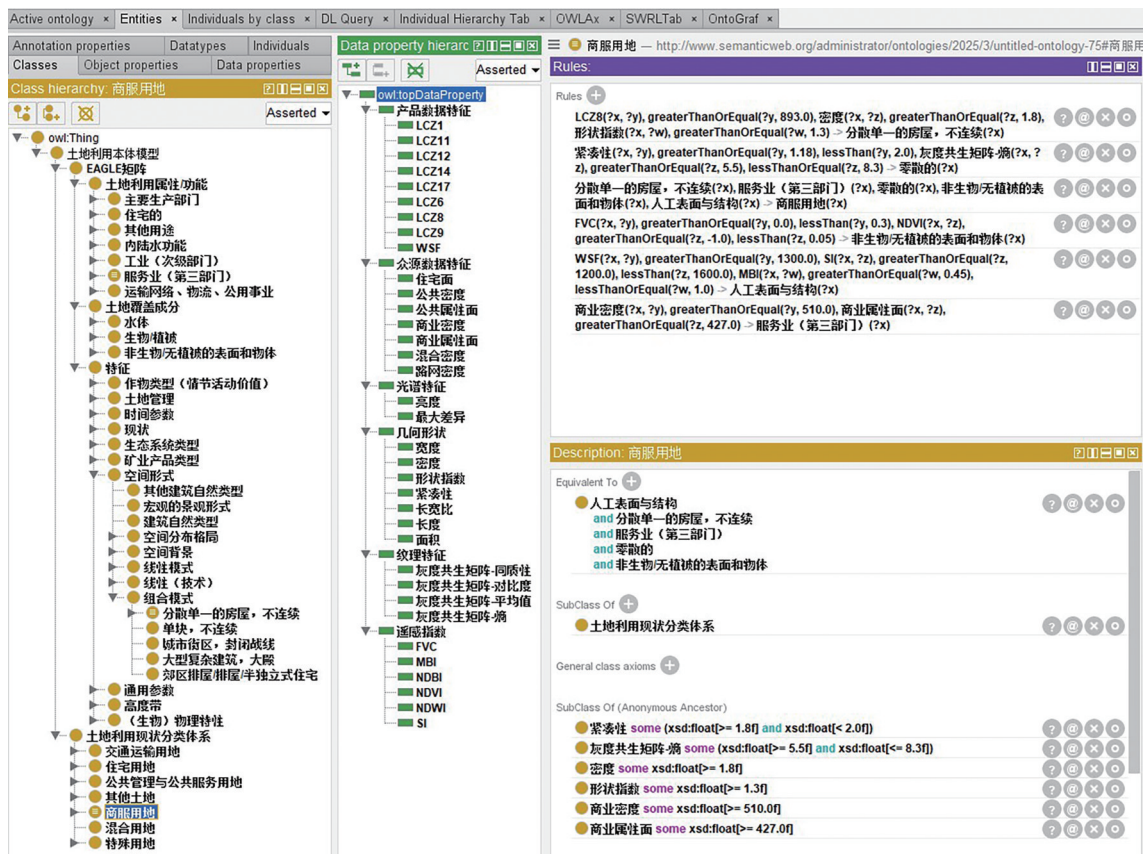


图7 城市土地利用本体模型
Fig. 7 Urban land use ontology model

为提升模型透明度，表 8 列举了城市土地利用各类别包含的本体基元、每个基元与数据特征映射关系及相关数量统计。

3.3 影像分割与本体推理分类

3.3.1 影像分割

完成本体模型与规则构建后，需将影像分割所得同质地块作为实例，导入模型进行推理分类。由于路网与城市规划基本单元更契合，当前城市土地利用的研究常以路网街区为基本单元进行面向对象的分类（Chen 等，2021；Huang 等，2021；Zhu 等，2022；Zhou 和 Cao，2022；Deng 等，2024）。然而路网分割却存在几何形态与自然地物边界脱节、无法识别街区内部的微观用地差异，以及缺乏动态适应性、难以体现土地利用渐进更新

的局限。

基于 eCognition 软件（Trimble 公司）与哨兵二号 b1—b8a、b10—b12 波段光谱数据，尝试比较了 3 种分割方式。（1）基于光谱信息的分割：采用多尺度分割算法，通过 ESP（Estimation of Scale Parameter）工具分析对象层间方差变化率峰值，确定最优尺度参数；鉴于城市地物具有规整边界和紧凑形态，在控制变量逐步调整的基础上结合目视评价，确定形状因子与紧凑度因子数值。（2）基于路网的分割：以 OSM 路网数据作为矢量边界进行分割，剔除人行小路、地铁线等无关要素。（3）融合光谱与路网的分割：在引入 OSM 路网矢量边界约束的同时，设置与“基于光谱的分割”相同的多尺度分割参数，使分割结果同时兼顾光谱同质性与道路边界特征。

表 8 本体模型体系规模统计				
Table 8 Statistical overview of the ontology model system size				
城市土地利用类别	本体基元	多源数据特征信息参考	类别—基元映射数量	规则条目数量
住宅用地	人工表面与结构	WSF、SI、MBI	5	6
	非生物/无植被的表面和物体	FVC、NDVI		
	住宅的	住宅密度、住宅面、最大差		
	均匀的	紧凑性、GLCM_熵		
	郊区排屋/排屋/半独立式住宅	LCZ6、形状指数		
交通运输用地	人工表面与结构	WSF、BSI、MBI	5	6
	非生物/无植被的表面和物体	FVC、NDVI		
	道路网(包括停车场)、铁路网	路网密度、形状指数		
	线性的	长宽比、长度、对比度		
公共管理与公共 服务用地	非生物/无植被的表面和物体	FVC、NDVI	9	7
	人工表面与结构	WSF、SI、MBI		
	生物/植被	FVC、NDVI、近红外波段均值		
	公用事业、社区服务、文化服务、体育基础设施	公共密度、公共面		
	均匀的	对比度、标准差		
	单块、不连续	形状指数、密度		
特殊用地	人工表面与结构	WSF、SI、MBI	4	5
	生物/植被	FVC、NDVI		
	宗教服务	特殊密度、特殊面		
	单块、不连续	密度、形状指数		
混合用地	人工表面与结构	WSF、NDBI、MBI、SI	3	4
	非生物/无植被的表面和物体	FVC、NDVI		
	混合的	混合密度、混合面		
商服用地	分散单一的房屋、不连续	LCZ8、密度、形状指数	8	6
	零散的	紧凑性、GLCM_熵		
	非生物/无植被的表面和物体	FVC、NDVI		
	人工表面与结构	WSF、SI、MBI		
	商业服务,住宿和餐饮服务,文化和娱乐服务, 金融、专业和信息服务	商业密度、商业面		
总计			34	34

3.3.2 土地利用本体推理分类

将最优分割方式产生的同质地块及其所含的多源数据特征及遥感指数数值，以表格形式导出并导入本体模型。利用FaCT++推理机推理语义规则，自动将各地块实例归类至相应土地利用类别中，从而得到每个地块的土地利用类别信息，并据此生成最终的城市土地利用分类图。

4 结 果

4.1 影像分割结果与对比分析

通过ESP工具确定分割实验的最优尺度参数为25，以0.1为步长控制变量，最终确定形状因子

为0.8、紧凑度因子为0.6，并据此获得了基于光谱、基于路网以及融合光谱与路网的分割结果。为定量评估分割效果，将真值数据提取的参考边界与分割生成的矢量边界转换为二值栅格进行对比分析。评价指标选用召回率评估分割边界提取的完整性，即识别出的真实边界占参考边界的像素比例，值越高表明边界提取越完整；同时引入豪斯多夫（Hausdorff）距离（Berezkyi, 2025）评估分割边界与参考边界的形状相似度，值越低表明形状一致性越高。实验区局部地块不同分割方式结果对比见图8，实验区整体不同分割方式分类结果精度见表9。




图 8 实验区局部地块不同分割方式结果对比

Fig. 8 Comparison of results from different segmentation methods for local areas within the test zone

表 9 实验区整体不同分割方式分类结果精度
Table 9 The classification result accuracy of different segmentation methods for the overall test zone

分割方式	召回率	豪斯多夫距离
基于光谱信息分割	0.39	21.93
基于路网分割	0.76	18.36
融合光谱与路网分割	0.78	18.36

由以上结果可知，从分割效果看，融合光谱与路网的分割方法最优；基于光谱信息的分割对物理特征敏感，细节划分更精准，但对道路分割效果较差；基于路网的分割几何规整，道路分割

效果好，但会忽略自然差异显著的地类边界，如图 8 (c) 中城市绿地与住宅未被区分；融合光谱与路网的分割方法同时兼顾地物的自然属性与经济属性，弥补了单一方法的不足。融合光谱与路网的分割方法不仅道路分割优异，对自然与人造地物、路网内部建筑边界也实现了较好分割。从评估结果看，基于光谱信息的分割在完整性与形状相似度上均表现不佳；基于路网的分割及融合光谱与路网的分割具有相同的形状相似度，但融合分割在边界完整性上更优。综上，融合路网与光谱的分割方法能协同发挥路网的结构性约束与

光谱的细节优势,在保证几何精度的同时,实现精准分割。

4.2 本体分类结果与对比分析

为验证知识驱动方法的有效性,本文进行了数据驱动模型的对比实验。选取融合光谱与路网分割所得地块作为样本,标注地类标签。Li等(2024)基于路网分割和多源数据的城市土地利用研究证实, MobileNet 模型在准确率与效率上较

ResNet、VGGNet等模型取得了良好平衡。同时,将支持向量机SVM(Support Vector Machine)作为典型机器学习模型纳入对比。综上,本文选用 MobileNet与SVM作为数据驱动对比模型。知识驱动与数据驱动分类结果如图9所示,另选取4处局部区域对比细节,结果如图10所示。

通过对比 MobileNet、SVM、知识驱动分类结果与真值数据,可以得出以下结论。





图9 知识驱动与数据驱动分类结果

Fig. 9 Knowledge-driven and data-driven classification results






图 10 知识驱动与数据驱动分类结果局部对比
Fig. 10 Local comparison of knowledge-driven and data-driven classification result

(1) 知识驱动分类结果地类分布更合理；数据驱动结果较杂乱，存在多处与地学常识或场景语义不符的错分。例如图 9 (a) 和图 9 (b) 以城市绿地为主的公共区域出现了混合用地和住宅用地，图 10 (h) 中居民区内出现了混合用地与特殊用地，图 10 (i) 也存在类似的混合用地错分。知识驱动方法本质是将专家判读地类的过程形式化为可计算的规则，其决策过程基于显性的领域知识，从而在语义层面保证了结果的合理性与可解释性。相比之下，数据驱动方法依赖从训练数据中归纳的、内隐的统计规律，在面对复杂市场场景时，更易产生统计上可行但地理语义不合理的分类结果。

(2) 图 10 (t) 中混合用地区域知识驱动方法出现了明显错分，主要原因在于该区域众源数据稀疏，各类特征显著性不足，使得依据规则进行判别时存在困难。相比之下，数据驱动方法在训练阶段已学习过同类样本的分布模式，因此能进行相对可靠的类别识别。

4.3 分类精度评价

为验证分类精度，从真值数据（图 2）中随机均匀抽取 263 个验证点，如图 11 所示。其中，商服用地 20 个、住宅用地 50 个、公共管理与公共服务用地 45 个、特殊用地 20 个、交通运输用地 68 个及混合用地 60 个。基于上述选取的验证点，分别计算知识驱动、MobileNet 及 SVM 3 种分类结果的

混淆矩阵，见表 10 至表 12。




图 11 验证样本集空间分布情况
Fig. 11 Spatial distribution of the verification sample set

为直观对比，将表中的各项数值可视化，结果如图 12 (a) 至图 12 (f) 所示。

综合总体精度、Kappa 系数及混淆矩阵可知，知识驱动方法在分类精度与结果可靠性上均达到最优，具体如下。

(1) 知识驱动方法的分类性能显著优于数据驱动。知识驱动总体精度和 Kappa 系数最高，为 87.02% 和 0.84，SVM 为 76.75% 和 0.71，MobileNet 为 57.05% 和 0.47。在大多数类别上，数据驱动方法的精度也整体显著低于知识驱动方法。

表 10 知识驱动本体推理分类结果混淆矩阵

Table 10 Confusion matrix of knowledge-driven ontology reasoning classification results

类别名称	住宅用地	交通运输用地	公共管理与公共服务用地	特殊用地	混合用地	商服用地	用户精度
住宅用地	2286	26	47	83	229	150	81.04%
交通运输用地	36	2626	20	61	71	3	93.22%
公共管理与公共服务用地	220	86	3416	73	319	17	82.69%
特殊用地	11	0	60	1626	0	0	95.82%
混合用地	72	35	247	30	2359	20	85.38%
商服用地	0	1	0	0	0	536	99.81%
制图精度	87.09%	94.66%	90.13%	86.81%	79.21%	73.83%	—
总体精度	87.02%						
Kappa 系数	0.84						

表 11 基于对象的SVM分类结果混淆矩阵

Table 11 Confusion matrix of object-based SVM classification results

类别名称	住宅用地	交通运输用地	公共管理与公共服务用地	特殊用地	混合用地	商服用地	用户精度
住宅用地	2900	280	282	210	918	286	59.47%
交通运输用地	200	3468	87	40	388	32	82.28%
公共管理与公共服务用地	381	297	4358	84	159	8	82.43%
特殊用地	0	14	225	1908	0	0	88.87%
混合用地	330	281	292	104	2988	31	74.22%
商服用地	0	0	0	0	6	688	99.14%
制图精度	76.10%	79.80%	83.10%	81.33%	67.01%	65.84%	—
总体精度	76.75%						
Kappa 系数	0.71						

表 12 基于对象的MobileNet分类结果混淆矩阵

Table 12 Confusion matrix of object-based MobileNet classification results

类别名称	住宅用地	交通运输用地	公共管理与公共服务用地	特殊用地	混合用地	商服用地	用户精度
住宅用地	1514	63	727	246	569	134	46.54%
交通运输用地	135	2286	132	40	201	8	81.58%
公共管理与公共服务用地	323	153	2030	390	176	0	66.08%
特殊用地	72	23	168	644	254	38	53.71%
混合用地	349	216	402	553	1753	298	49.09%
商服用地	232	35	331	0	113	248	25.86%
制图精度	57.68%	82.35%	53.56%	34.38%	57.18%	34.16%	—
总体精度	57.05%						
Kappa 系数	0.47						

(2) 两种数据驱动方法中SVM表现明显优于MobileNet，这主要是因为研究区域为单一城市中心，样本分布及数量有限，导致MobileNet作为深度学习模型未能充分发挥优势，易发生过拟合；而SVM基于特征工程，更能适应小样本场景，表现更稳健。

(3) 图 12 (d) 至图 12 (f) 展示了3种方法的混淆矩阵热力图，表示各类别样本中真实类别占比大小。对角线颜色深度代表分类精度，即分类

正确的比例，颜色越深精度越高；对角线外表示类别间错分比例，反映了类别间混淆程度，颜色越浅误分与漏分越少。知识驱动方法对角线颜色普遍最深，且对角线外无明显深色区块，在保持高精度的同时，有效控制了类别间混淆。数据驱动方法整体对角线颜色较浅，其中MobileNet存在较多深色混淆类别，SVM虽优于MobileNet，但精度与抗混淆能力仍低于知识驱动方法。



5 讨 论

语义引导下的本体知识驱动城市土地利用分类方法在城市土地利用分类中取得了总体精度87.02%、Kappa系数0.84的效果，显著优于常见的数据驱动分类方法。与苏墨（2021）的研究方法对比，本研究所得分类结果精度提升约10%，这是由于语义引导下的本体知识驱动方法通过强化语义表达，弥合了语义鸿沟，使分类结果具有逻辑一致性；同时，采用的融合光谱与路网的分割方式兼顾了自然边界与社会经济边界。相较于Gu等（2017）和Zhu等（2024）的本体驱动方法，本研究进一步引入EAGLE矩阵进行语义标准化与重构，对LUA模块的运用也更深入。

对比数据驱动与知识驱动方法的结果与精度，得到以下发现。

对比数据驱动与知识驱动方法的结果与精度，得到以下发现。

（1）语义引导下的本体知识驱动、SVM与MobileNet方法的分类结果在商服用地与住宅用地

之间均存在混淆。主要由于研究区内商服用地分布分散且无明显物理特征,除大型商超外难以准确分割轮廓,且商服用地常与住宅用地相邻,分割时多被包含在住宅地块中;同时存在混合用地错分情况,主要源于混合用地众源数据特征与商服、公共等用地部分重叠,难以判别。未来可在分割阶段引入POI与社交媒体热力图作为辅助,从数据时空特征角度加以区分。

(2) 尽管知识驱动方法规则明确、可解释性强,但分类过程仍依赖数据质量。针对众源数据稀疏导致数据特征不显著的区域,知识驱动方法无法准确识别,如图9(c)右下与左上区域部分未识别出类别的地块,被归类至其他用地类别。未来,可引入夜光遥感、社交媒体热度、交通流量等辅助数据,增强对城市复杂功能的表征能力。

(3) 知识驱动方式决策透明且结果合理,但数据驱动方式自动化程度与泛化能力同样具有潜力。未来将结合数据驱动与知识推理,探索“数据+知识”双驱动模型,保持可解释性的同时提升自动化水平。

(4) 实验以加拿大多伦多中心区为案例,该区域在北美大城市中具有代表性。由于知识驱动方法仍依赖输入数据,因此在验证模型的泛化能力和迁移性时,实验效果也会受数据影响。基于此,知识驱动方法适用于发达城市核心区域。未来研究将在不同形态与文化背景的城市进一步验证该方法,并重点关注数据质量降级时模型的稳健性和数据补充策略。

6 结 论

针对当前城市土地利用分类中数据驱动方法可解释性差、领域研究对类别语义重视不足以及路网分割地块忽视自然边界的问题,本研究提出了一种语义引导下的知识驱动城市土地利用分类方法。该方法利用EAGLE矩阵重构地类语义提取本体基元;基于多源数据特征与基元组合构建本体模型与规则;采用融入光谱与路网的分割方法生成的同质地块作为分类实例,导入本体模型进行推理,实现高精度城市土地利用分类。全流程无需样本,兼具可解释性与高分类精度,并在加拿大多伦多市中心得到了成功验证。实验结果表明:(1) 知识驱动方法凭借强大的可解释性展现出显著优势;(2) EAGLE矩阵有效弥合了用户认

知与数据产品之间的语义鸿沟,强化了对类别语义的形式化表达;(3) 融合光谱与路网的分割策略刻画了符合现实情景的土地利用边界。知识驱动城市土地利用分类方法为城市土地利用动态监测、科学规划与管理以及城市健康评估,提供了一套精准、可靠且可解释的技术方案。

参考文献(References)

- Adamo M, Tomaselli V, Tarantino C, Vicario S, Veronico G, Lucas R and Blonda P. 2020. Knowledge-based classification of grassland ecosystem based on multi-temporal WorldView-2 data and FAO-LCCS taxonomy. *Remote Sensing*, 12(9): 1447 [DOI: 10.3390/rs12091447]
- Anderson J R, Hardy E E, Roach J T and Witmer R E. 1976. A Land Use and Land Cover Classification System for Use with Remote Sensor Data. U.S. Geological Survey Professional Paper 964. U. S. Geological Survey.
- Arnold S, Smith G, Hazeu G W, Kosztra B, Perger C H, Banko G, Soukup T, Strand G H, Valcarcel Sanz N and Bock M. 2015. The EAGLE concept: a paradigm shift in land monitoring//Ahlgqvist O, Varanka D, Fritz S and Janowicz K, eds. *Land Use and Land Cover Semantics: Principles, Best Practices, and Prospects*. [s.l.]: CRC Press: 107-144 [DOI: 10.1201/b18746-7]
- Arvor D, Belgiu M, Falomir Z, Mougenot I and Durieux L. 2019. Ontologies to interpret remote sensing images: why do we need them? *GIScience and Remote Sensing*, 56(6): 911-939 [DOI: 10.1080/15481603.2019.1587890]
- Arvor D, Betbeder J, Daher F R G, Blossier T, Le Roux R, Corgne S, Corpetti T, de Freitas Silgueiro V and da Silva Junior C A. 2021. Towards user-adaptive remote sensing: knowledge-driven automatic classification of Sentinel-2 time series. *Remote Sensing of Environment*, 264: 112615 [DOI: 10.1016/j.rse.2021.112615]
- Berezkyi M. 2025. Analysis of freschet and hausdorf metrics and their modifications for image comparison. *Computer Systems and Information Technologies*, (3): 8-16 [DOI: 10.31891/csit-2025-3-1]
- Bossard M, Feranec J and Otahel J. 2000. CORINE land cover technical guide-Addendum 2000. Technical report 40/2000. European Environment Agency.
- Büttner G. 2014. CORINE land cover and land cover change products//Manakos I and Braun M, eds. *Land Use and land Cover Mapping in Europe*. Dordrecht: Springer: 55-74 [DOI: 10.1007/978-94-007-7969-3_5]
- Cao R, Tu W, Yang C X, Li Q, Liu J, Zhu J S, Zhang Q, Li Q Q and Qiu G P. 2020. Deep learning-based remote and social sensing data fusion for urban region function recognition. *ISPRS Journal of Photogrammetry and Remote Sensing*, 163: 82-97 [DOI: 10.1016/j.isprsjprs.2020.02.014]
- Chen B, Tu Y, Song Y M, Theobald D M, Zhang T, Ren Z H, Li X C,

- Yang J, Wang J, Wang X, Gong P, Bai Y Q and Xu B. 2021. Mapping essential urban land use categories with open big data: results for five metropolitan areas in the United States of America. *ISPRS Journal of Photogrammetry and Remote Sensing*, 178: 203-218 [DOI: 10.1016/j.isprsjprs.2021.06.010]
- Deng K, Hu X Y, Zhang Z L, Su B, Feng C J, Zhan Y Z, Wang X K and Duan Y S. 2024. Cross-modal change detection using historical land use maps and current remote sensing images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 218: 114-132 [DOI: 10.1016/j.isprsjprs.2024.10.010]
- Esch T, Brzoska E, Dech S, Leutner B, Palacios-Lopez D, Metz-Marconcini A, Marconcini M, Roth A and Zeidler J. 2022. World Settlement Footprint 3D-a first three-dimensional survey of the global building stock. *Remote Sensing of Environment*, 270: 112877 [DOI: 10.1016/j.rse.2021.112877]
- Fang F, Zeng L Y, Li S W, Zheng D Y, Zhang J H, Liu Y Y and Wan B. 2022. Spatial context-aware method for urban land use classification using street view images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 192: 1-12 [DOI: 10.1016/j.isprsjprs.2022.07.020]
- Gong P, Chen B, Li X C, Liu H, Wang J, Bai Y Q, Chen J M, Chen X, Fang L, Feng S L, Feng Y J, Gong Y L, Gu H, Huang H B, Huang X C, Jiao H Z, Kang Y D, Lei G B, Li A N, Li X T, Li X, Li Y C, Li Z L, Li Z D, Liu C, Liu C X, Liu M C, Liu S G, Mao W L, Miao C H, Ni H, Pan Q S, Qi S H, Ren Z H, Shan Z R, Shen S Q, Shi M J, Song Y M, Su M, Suen H P, Sun B, Sun F D, Sun J, Sun L, Sun W Y, Tian T, Tong X H, Tseng Y, Tu Y, Wang H, Wang L, Wang X, Wang Z M, Wu T H, Xie Y W, Yang J, Yang J, Yuan M, Yue W Z, Zeng H D, Zhang K, Zhang N, Zhang T, Zhang Y, Zhao F, Zheng Y C, Zhou Q M, Clinton N, Zhu Z L and Xu B. 2020. Mapping essential urban land use categories in China (EULUC-China): preliminary results for 2018. *Science Bulletin*, 65(3): 182-187 [DOI: 10.1016/j.scib.2019.12.007]
- Gu H Y. 2015. The Technology of Geo-ontology Modeling Driven Object Classification for Remote Sensing Image. Wuhan: Wuhan University (顾海燕. 2015. 遥感影像地理本体建模驱动的对象分类技术. 武汉: 武汉大学)
- Gu H Y, Li H T, Yan L, Han Y S, Yu F, Yang Y and Liu Z J. 2018. A geographic object-based image analysis methodology based on geo-ontology. *Geomatics and Information Science of Wuhan University*, 43(1): 31-36 (顾海燕, 李海涛, 闫利, 韩颜顺, 余凡, 杨懿, 刘正军. 2018. 地理本体驱动的遥感影像面向对象分析方法. 武汉大学学报(信息科学版), 43(1): 31-36) [DOI: 10.13203/j.whugis.20150468]
- Gu H Y, Li H T, Yan L, Liu Z J, Blaschke T and Soergel U. 2017. An object-based semantic classification method for high resolution remote sensing imagery using ontology. *Remote Sensing*, 9(4): 329 [DOI: 10.3390/rs9040329]
- Horrocks I, Patel-Schneider P F, Boley H, Tabet S, Grosz B and Dean M. 2004. SWRL: a semantic web rule language combining OWL and RuleML[2025-07-12]. <http://www.w3.org/Submission/SWRL/>.
- Hu S G and Wang L. 2013. Automated urban land-use classification with remote sensing. *International Journal of Remote Sensing*, 34(3): 790-803 [DOI: 10.1080/01431161.2012.714510]
- Huang X, Yang J J, Li J Y and Wen D W. 2021. Urban functional zone mapping by integrating high spatial resolution nighttime light and daytime multi-view imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 175: 403-415 [DOI: 10.1016/j.isprsjprs.2021.03.019]
- Huang Z, Qi H J, Kang C G, Su Y L and Liu Y. 2020. An ensemble learning approach for urban land use mapping based on remote sensing imagery and social sensing data. *Remote Sensing*, 12(19): 3254 [DOI: 10.3390/rs12193254]
- Ismayilova I and Timpf S. 2023. Towards an ontology of urban green spaces. *GI Forum*, 10(2): 47-57 [DOI: 10.1553/giscience2022_02_s47]
- Jia Y J, Liu Y G, Yang S L, Wang Y, Zhang C, Xu H F and Zheng S J. 2022. Applicability of land use classification method in Dali City based on Sentinel-2A image. *Journal of Zhejiang A and F University*, 39(6): 1350-1358 (贾玉洁, 刘云根, 杨思林, 王妍, 张超, 徐红枫, 郑淑君. 2022. 面向 Sentinel-2A 影像的大理市土地利用分类方法适用性研究. 浙江农林大学学报, 39(6): 1350-1358) [DOI: 10.11833/j.issn.2095-0756.20220134]
- Li W B, Sun K M, Li W Z, Wei J J, Miao S X, Gao S and Zhou Q H. 2023. Aligning semantic distribution in fusing optical and SAR images for land use classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 199: 272-288 [DOI: 10.1016/j.isprsjprs.2023.04.008]
- Li Y S, Ouyang S and Zhang Y J. 2022. Combining deep learning and ontology reasoning for remote sensing image semantic segmentation. *Knowledge-Based Systems*, 243: 108469 [DOI: 10.1016/j.knsys.2022.108469]
- Li Z M, Chen B, Wu S B, Su M, Chen J M and Xu B. 2024. Deep learning for urban land use category classification: a review and experimental assessment. *Remote Sensing of Environment*, 311: 114290 [DOI: 10.1016/j.rse.2024.114290]
- Liu B, Du S H, Du S J and Zhang X Y. 2020. Incorporating deep features into GEOBIA paradigm for remote sensing imagery classification: a patch-based approach. *Remote Sensing*, 12(18): 3007 [DOI: 10.3390/rs12183007]
- Lu W P, He Q K, Li J L, Li S Y and Tao C. 2024. Object units and transformer networks combined with urban functional zone classification method. *National Remote Sensing Bulletin*, 28(8): 1927-1939 (鲁伟鹏, 贺清康, 李佳铃, 李诗逸, 陶超. 2024. 结合对象单元和 Transformer 网络的城市功能区分类. 遥感学报, 28(8): 1927-1939) [DOI: 10.11834/jrs.20233036]
- Lu W P, Tao C, Li H F, Qi J and Li Y S. 2022. A unified deep learning framework for urban functional zone extraction based on multi-source heterogeneous data. *Remote Sensing of Environment*, 270: 112830 [DOI: 10.1016/j.rse.2021.112830]
- Marconcini M, Metz-Marconcini A, Üreyen S, Palacios-Lopez D, Han-

- ke W, Bachofer F, Zeidler J, Esch T, Gorelick N, Kakarla A, Paganini M and Strano E. 2020. Outlining where humans live, the World Settlement Footprint 2015. *Scientific Data*, 7(1): 242 [DOI: 10.1038/s41597-020-00580-5]
- Mc Cutchan M and Giannopoulos I. 2022. Encoding geospatial vector data for deep learning: LULC as a use case. *Remote Sensing*, 14(12): 2812 [DOI: 10.3390/rs14122812]
- Ministry of Natural Resources. 2021. Technical Regulation of Annual Land Use Change Survey: 2021 Trial Version. Beijing: General Office of the Ministry of Natural Resources (自然资源部). 2021. 国土变更调查技术规程: 2021年度试用. 北京: 自然资源部办公厅) Musen M A. 2015. The protégé project: a look back and a look forward. *AI Matters*, 1(4): 4-12 [DOI: 10.1145/2757001.2757003]
- Pan J, Li C, Peng W Y, Li Y Z and Li W F. 2024. Land use classification in yunnan province based on random forest and support vector machine. *Science Technology and Engineering*, 24(17): 7043-7051 (潘娇, 李超, 彭文忆, 李影芝, 李文峰. 2024. 基于随机森林和支持向量机的云南省土地利用分类. *科学技术与工程*, 24(17): 7043-7051) [DOI: 10.12404/j.issn.1671-1815.2306050]
- Petrou Z I, Manakos I, Stathaki T, Múcher C A and Adamo M. 2015. Discrimination of vegetation height categories with passive satellite sensor imagery using texture analysis. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(4): 1442-1455 [DOI: 10.1109/JSTARS.2015.2409131]
- Song J C, Lin T, Li X H and Prishchepov A V. 2018. Mapping urban functional zones by integrating very high spatial resolution remote sensing imagery and points of interest: a case study of Xiamen, China. *Remote Sensing*, 10(11): 1737 [DOI: 10.3390/rs10111737]
- Su C, Hu X L, Meng Q Y, Zhang L L, Shi W X and Zhao M F. 2024. A multimodal fusion framework for urban scene understanding and functional identification using geospatial data. *International Journal of Applied Earth Observation and Geoinformation*, 127: 103696 [DOI: 10.1016/j.jag.2024.103696]
- Su M. 2021. Urban Land Classification Based by Coupling Machine Learning and Knowledge Graph. Wuhan: Wuhan University (苏墨. 2021. 融合机器学习与知识图谱的城市土地分类方法. 武汉: 武汉大学) [DOI: 10.27379/d.cnki.gwhdu.2021.002609]
- Talukdar S, Singha P, Mahato S, Shahfahad N, Pal S, Liou Y A and Rahman A. 2020. Land-use land-cover classification by machine learning classifiers for satellite observations—a review. *Remote Sensing*, 12(7): 1135 [DOI: 10.3390/rs12071135]
- Tian T, Yu L, Tu Y, Chen B and Gong P. 2024. Mapping the time-series of essential urban land use categories in China: a multi-source data integration approach. *Remote Sensing*, 16(17): 3125 [DOI: 10.3390/rs16173125]
- Tsarkov D and Horrocks I. 2006. FaCT++ description logic reasoner: system description//Third International Joint Conference on Automated Reasoning. Berlin, Heidelberg: Springer: 292-297 [DOI: 10.1007/11814771_26]
- UN. 2018. World Urbanization Prospects. New York: United Nations.
- W3C OWL Working Group. 2012. OWL 2 Web Ontology Language Document Overview. 2nd ed[2025-07-12]. <https://www.w3.org/TR/owl2-overview/>
- Wu P. 2020. A Study of the Urban Functional Zoning Method from the Multi-Source Heterogeneous Data Fusion Analysis Perspective. Changchun: University of Chinese Academy of Sciences (Northeast Institute of Geography and Agroecology, Chinese Academy of Sciences) (吴鹏. 2020. 多源异构数据融合分析视角下的城市功能分区方法研究. 长春: 中国科学院大学(中国科学院东北地理与农业生态研究所))
- Wu S S, Qiu X M, Usery E L and Wang L. 2009. Using geometrical, textural, and contextual information of land parcels for classification of detailed urban land use. *Annals of the Association of American Geographers*, 99(1): 76-98 [DOI: 10.1080/00045600802459028]
- Xiong S P, Zhang X Y, Wang H Y, Lei Y C, Tan G and Du S H. 2025. Mapping the first dataset of global urban land uses with Sentinel-2 imagery and POI prompt. *Remote Sensing of Environment*, 327: 114824 [DOI: 10.1016/j.rse.2025.114824]
- Xu X L, Liu J Y, Zhang S W, Li R D, Yan C Z and Wu S X. 2018. China's multi-period land use remote sensing monitoring dataset (CNLUCC). Resource and Environment Science Data Platform (徐新良, 刘纪远, 张树文, 李仁东, 颜长珍, 吴世新. 2018. 中国多时期土地利用遥感监测数据集(CNLUCC). 资源环境科学数据注册与出版系统) [DOI: 10.12078/2018070201]
- Zhang X Y, Du S H and Wang Q. 2018. Integrating bottom-up classification and top-down feedback for improving urban land-cover and functional-zone mapping. *Remote Sensing of Environment*, 212: 231-248 [DOI: 10.1016/j.rse.2018.05.006]
- Zhou Q H and Cao R. 2022. A coarse-to-fine approach for urban land use mapping based on multisource geospatial data//2022 29th International Conference on Geoinformatics. Beijing: IEEE: 1-7 [DOI: 10.1109/Geoinformatics57846.2022.9963851]
- Zhu G Y, Tang M, Ma Y H, Hu Z H, Yu C L, Zhang X, Hu H J, Guan Q F and Yao Y. 2025. LandGPT: a multimodal large language model for parcel-level land use classification with multi-source data. *International Journal of Geographical Information Science*, 39(12): 2862-2885 [DOI: 10.1080/13658816.2025.2506533]
- Zhu L, Jin G S and Gao D J. 2021. Integrating land-cover products based on ontologies and local accuracy. *Information*, 12(6): 236 [DOI: 10.3390/info12060236]
- Zhu L, Lu Y Z and Fan Y W. 2024. Classification of urban surface elements by combining multisource data and ontology. *Remote Sensing*, 16(1): 4 [DOI: 10.3390/rs16010004]
- Zhu Q Q, Lei Y, Sun X L, Guan Q F, Zhong Y F, Zhang L P and Li D R. 2022. Knowledge-guided land pattern depiction for urban land use mapping: a case study of Chinese cities. *Remote Sensing of Environment*, 272: 112916 [DOI: 10.1016/j.rse.2022.112916]

Semantic-guided ontology knowledge-driven urban land use classification

CAO Rui¹, ZHU Ling¹, LI Songnian², ZHOU Yuexuan¹

1. School of Geomatics and Urban Spatial Informatics, Beijing University of Civil Engineering and Architecture,
Beijing 102616, China;

2. Department of Civil Engineering, Toronto Metropolitan University, Toronto M5B 2K3, Canada

Abstract: Land use represents one of the most intensive forms of human modification of the Earth's surface. It has both economic and natural attributes, and future populations are expected to become increasingly concentrated in urban areas. In the context of rapid urbanization and diversified functional demands, automatic and efficient acquisition of urban land use information is essential for the design, construction, and management of sustainable urban environments. Traditional data-driven algorithms are limited by “black-box” opacity, strong dependence on training data, and difficulty incorporating prior knowledge and semantic information. Reliance on remote sensing data alone also makes accurate land use identification difficult. In addition, existing studies of urban land use often neglect the explicit representation of category semantics, and inconsistencies in semantic representation across classification systems can create a semantic gap between data users and data producers. To obtain precise urban land use information, this study proposes a semantic-guided ontology knowledge-driven urban land use classification.

To address these issues, this study develops a semantic-guided ontological knowledge-driven approach that mitigates the limitations of purely data-driven methods. The method integrates multi-source data and products, including remote sensing imagery, POI, AOI, OSM, LCZ, and WSF data. First, land use types are semantically reconstructed using the EAGLE matrix, and land use semantics are decomposed into ontological primitives. Next, crowdsourced-data features, remote sensing indices, and morphological characteristics are extracted to match the attribute features of the primitives, and an ontological model is constructed from these primitives. A segmentation strategy that integrates spectral information and road network structure is then used to generate homogeneous parcels as instances for ontological reasoning. During ontological model construction, constraint rules are established by defining relationships between primitives and data features, enabling land use types for each parcel to be determined through rule-based reasoning. To validate the method, the highly complex downtown area of Toronto, Canada, is selected as the study area. Land use classification is performed according to the “Current Land Use Classification” (GB/T 21010-2017), with an additional “mixed-use” category introduced for practical application.

The experimental results validate the effectiveness of the proposed knowledge-driven framework. The method achieves an overall classification accuracy of 87.02% and a Kappa coefficient of 0.84, representing a substantial improvement over two baseline data-driven approaches: support vector machine (SVM) and the MobileNet deep learning network. A major advantage of the proposed method is its strong interpretability, which derives from the transparent reasoning process. In addition, the EAGLE matrix helps bridge the semantic gap between users’ conceptualization of land use and its representation in data products. The proposed fusion segmentation strategy, which integrates spectral and road network information, delineates urban land use boundaries that are more consistent with physical reality and functional units.

The knowledge-driven approach proposed in this study mitigates key limitations of data-driven methods in urban land use classification, including weak interpretability, limited accuracy, and semantic ambiguity. By integrating multi-source data, the EAGLE matrix, and ontology, the framework provides a reliable solution for representing the complex characteristics of urban environments. This research establishes a foundation for future studies that aim to improve the intelligence and sustainability of urban planning and management.

Key words: Knowledge-driven, semantic information, EAGLE matrix, multi-source data, urban land use

Supported by National Key Research and Development Program of China (No. 2021YFE0194700)