

引用格式: 骆剑承, 吴田军, 吴志峰, 等. 地理图斑智能计算及模式挖掘方法研究[J]. 地球信息科学学报, 2020, 22(1): 57-75. [ Luo J C, Wu T J, Wu Z F, et al. Methods of intelligent computation and pattern mining based on geo-parcels[J]. Journal of Geo-information Science, 2020, 22(1): 57-75. ] DOI: 10.12082/dqxxkx.2020.190462

## 地理图斑智能计算及模式挖掘方法研究

骆剑承<sup>1,2</sup>, 吴田军<sup>3\*</sup>, 吴志峰<sup>4</sup>, 周亚男<sup>5</sup>, 郗丽静<sup>1,2</sup>, 孙营伟<sup>1,2</sup>, 吴 炜<sup>6</sup>, 杨颖频<sup>1,2</sup>, 胡晓东<sup>1,2</sup>,  
张 新<sup>1,2</sup>, 沈占锋<sup>1,2</sup>

1. 中国科学院空天信息创新研究院 遥感科学国家重点实验室, 北京 100101; 2. 中国科学院大学, 北京 100049; 3. 长安大学地质工程与测绘学院, 西安 710064; 4. 广州大学地理科学学院, 广州 510006; 5. 河海大学地球科学与工程学院, 南京 211100; 6. 浙江工业大学计算机学院, 杭州 310023

### Methods of Intelligent Computation and Pattern Mining based on Geo-parcels

LUO Jiancheng<sup>1,2</sup>, WU Tianjun<sup>3\*</sup>, WU Zhifeng<sup>4</sup>, ZHOU Ya'nan<sup>5</sup>, GAO Lijing<sup>1,2</sup>, SUN Yingwei<sup>1,2</sup>, WU Wei<sup>6</sup>,  
YANG Yingpin<sup>1,2</sup>, HU Xiaodong<sup>1,2</sup>, ZHANG Xin<sup>1,2</sup>, SHEN Zhanfeng<sup>1,2</sup>

1. State Key Laboratory of Remote Sensing Science, Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100101, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. School of Geology Engineering and Geomatics, Chang'an University, Xi'an 710064, China; 4. School of Geographical Sciences, Guangzhou University, Guangzhou 510006, China; 5. School of Earth Science and Engineering, Hohai University, Nanjing 211100, China; 6. College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China

**Abstract:** In the era of big data, high-resolution Earth observation technologies have been able to provide the most authentic, quantitative, comprehensive-coverage, and fast-updating data about the geographic phenomena and processes on the Earth's surface. Such data provide precise spatiotemporal benchmarks of information aggregation and computation of data mining for new developments of geospatial cognitive research. Geo-parcels are abstract expressions for mapping geographical entities from image-space to geographic-space. Geo-parcels are the smallest units of pattern mining with the construction of geographic scenes and loading various geospatial information. In this paper, a synergistic calculation mechanism with the machine learning methods of visual simulation and symbol inference were analyzed based on the basic unit of geo-parcels. From the dimensions of space, time, and attribute, we constructed an intelligent computation model based on geo-parcels by integrating three sub-models: zoning-stratified perception, spatiotemporal synergistically inversion, and multi-granular decision-making. Furthermore, this paper explored the pattern mining methods of geo-parcels for their distribution, growth, and function via two case studies: the agricultural planting structure mapping in Xifeng County, Guizhou province and the planning decision in Jiangzhou District of Guangxi Zhuang Autonomous Region.

**Key words:** geo-parcel; zoning-stratified perception; spatiotemporal synergistically inversion; multi-granular decision-making; distribution pattern; growth pattern; functional pattern; dynamic pattern

收稿日期: 2019-08-21; 修回日期: 2019-11-04.

基金项目: 国家自然科学基金项目(41631179、41601437); 国家重点研发计划项目(2017YFB0503600)。[ **Foundation items:** National Natural Science Foundation of China, No.41631179, 41601437; National Key Research and Development Program of China, No.2017YFB0503600. ]

作者简介: 骆剑承(1970—), 男, 浙江杭州人, 博士, 研究员, 主要从事遥感大数据智能计算研究。E-mail: luojc@radi.ac.cn

\*通讯作者: 吴田军(1986—), 男, 浙江嘉兴人, 博士, 副教授, 主要从事遥感信息智能提取研究。E-mail: wutianjun1986@163.com

\*Corresponding author: WU Tianjun, E-mail: wutianjun1986@163.com

**摘要:**在大数据时代,高分辨率对地观测技术实现了对地球表层地理现象和地理过程最为真实、量化、全面覆盖又快速更新的数据化记录,可为地理空间认知研究的新发展奠定时空信息聚合与挖掘计算的基准。地理图斑是影像空间映射到地理空间中对于地理实体的抽象化表达,是构建地理场景和承载地理空间各类信息进而开展模式挖掘的最小单元。本文以地理图斑为基本对象,通过分析其中视觉模拟、符号推测等几类机器学习的协同计算机制,从空间、时间与属性等维度构建了集“分区分层感知”、“时空协同反演”、“多粒度决策”三者于一体的地理图斑智能计算模型,并以在贵州息烽县、广西江州区开展的农业种植结构制图与规划决策为应用案例,探索了地理图斑分布、生长以及功能3种模式的挖掘方法,并进一步设计了动态视角下开展图斑动力模式挖掘的研究思路。

**关键词:**地理图斑;分区分层感知;时空协同反演;多粒度决策;分布模式;生长模式;功能模式;动力模式

## 1 引言

进入21世纪以来,以高分卫星遥感系统为影像基准,综合小卫星星座、超高分无人机系统、各类地面传感网络的天地一体化全球观测运行平台正在构筑形成。立体观测、实时感知、时空协同的新型遥感已实现对地球表层的全方位精细观测。此类聚集人类高度智慧的对地观测数据具备了极为鲜明的大数据时代特征:①全覆盖(Volume),基于“天一空一地”立体感知系统对地球影像基准底图实施了全空间覆盖的主动采集与处理计算,数据量巨大(仅米级影像覆盖中国就可达PB级);②快速更新(Velocity),以影像大数据为基底对全空间覆盖的地表空间结构底图进行了主动的认知构建,并伴随影像积累进行着信息的持续更新;③多态表达(Variety),多源多模态时空数据的一体化组织、转化与耦合,在相对稳定的空间结构上揭示了地理对象的时序演变规律及功能拓展趋势;④价值密度高(Value),地球运行发生的各类数据在结构化时空轴上实施关联与融合,提升了大数据价值密度,深度挖掘与多方应用成为可能。因此,新型的遥感大数据平台可实现对地表态势的真实场景式记录,构成了“物—物相联”信息传播的时空基准,这是后续面向社会开展各类精准化专题应用的基础保障。

在此背景下,我国也正在构建国家高分辨率对地观测系统,正逐步实现从太空、邻近空间、航空、地面等多层次观测平台上获取对地观测数据,进而通过对空间数据和地理信息产品的规模化加工与提炼,满足社会各界的广泛应用需求,而这已成为推动当前地理信息产业持续增长的源动力。尤其是,近年来国家高分专项计划的不断深化实施,进一步推动了卫星遥感事业的迅猛腾飞,在追赶国外

先进技术的同时也发展了宽视场、静轨凝视等多种独有的卫星数据获取手段。这些对地观测技术的新发展必将推动我们对地表地理现象、地理过程、地理格局的新认知,促进地理大数据从感知到认知的新发展。

然而,大规模国家遥感数据资源获取与社会化地理信息服务之间依然存在巨大的“鸿沟”,极大限制了遥感服务在广度和深度上的开展<sup>[1]</sup>。这是由于传统小数据的遥感计算模式在信息传递上存在瓶颈,数据大规模获取与信息提取应用之间仍存在系统性的流转困难,造成了“大数据—小知识”的困境<sup>[2]</sup>。究其根源:①对遥感数据本质认识、信息提取架构以及大数据计算模式缺乏理论基础与关键技术的支撑,特别是缺乏快速从遥感影像空间转换到地理信息空间的有效手段,导致地理实体单元未能真实客观呈现,多源多模态信息没有统一基准支撑其开展协同分析,影响了地理信息分析的精准性与量化,也一定程度上造成了遥感研究与地理信息研究之间的隔阂;②对人类认知时“先化繁为简,再由简入繁”的思维模式以及“眼睛看—模型算—脑子想”的逻辑过程缺少深入理解和系统模拟,往往是机械地堆砌数据开展混合计算,没有对解译流程进行全过程、分阶段地梳理,对所用算法也未能按照数据驱动、模型驱动的方式差异对其进行适用性区分、合理性改造以及分步式串联,导致遥感信息在提取模型上的混用、挖掘模式上的杂乱,因而整体的系统性表现较差,难以实用。

基于以上研究背景及现状分析,我们将充分认清各类别信息的不同深浅层次、各阶段应依赖的数据源及其融合计算方法、各环节所能达到的解译程度;在此基础上,从高分辨率影像的视觉感知出发,提出“地理图斑”的核心概念及其在地理学思维指

导下的智能提取与解析方法,并结合各流派机器学习技术与领域内遥感机理模型,发展了一套遵循“粒化—重组—关联”计算思维的遥感信息提取新理论,旨在通过统一基准的构建、多源数据的汇聚、协同分析的开展,实现面向应用的模式挖掘,生成精准的地理空间信息,从而形成强大的空间决策服务能力。这正是本文在新形势下夯实遥感信息提取理论的意旨,希望能填补该领域研究的一点理论空缺,以支持从大数据到大知识的顺畅转化。

## 2 地理图斑相关研究综述

### 2.1 地理图斑概念的提出

随着近20年高分辨率遥感卫星的不断发射及其数据量的持续积累,遥感信息提取的任务越来越重,对于智能化的信息计算研究提出了空前的迫切性。然而,无论从中低分辨率时代(20世纪90年代起)的“像素级”处理还是中高分辨率时代(本世纪初起)采用的“对象级”分析,均还停留于初级的应用水平,远远满足不了实际大规模资源调查与环境监测等相关领域的工程化应用<sup>[3]</sup>。如上述所述,其缘由是解译分析的基本单元不能与客观现实世界中的地理实体相对应,缺乏从影像空间准确映射到地理空间的有效手段,造成了与人对地球认知的时空结构差异<sup>[4]</sup>。

为实现从影像栅格向地理矢量的全面、快速、准确转换,需构建更为真实而精细的分析计算单元。为此,本文明确提出地理图斑(Geo-parcel,或者地理对象Geo-object,以下简称图斑)的概念,将其定义为在一定空间尺度(分辨率)约束下,视觉上能感知、具有确定土地利用/土地覆盖归属(类型)的最小地理实体(Geo-entity),是构建同型组团(Geo-cluster)、地理场景(Geo-scene)以及承载多源信息的基本单元。在该概念中,我们进一步辨析地理实体、地理图斑、同型组团、地理场景四者之间的关联关系:地理图斑是在某一尺度约束下(通常是亚米/亚米级空间分辨率)的最小地理实体(如建筑物、水体、林地、草地等);相同类型的相邻地理图斑聚合组成同型组团(如建筑区、水域等);相关功能的同型组团又进一步构成一个地理场景(指一定时空范围内的各种自然要素、认为要素相互联系、相互作用所构成的具体特定结构与功能的地域综合体,如居民小区、公园、科教园区等,可以含有多种类型的

同型组团自底向上综合而成的功能图斑)。具体来说,地理图斑层次反映的是个体的结果特征,如每个图斑的周长、面积等;同型组团层次反映属于相同类型图斑的共同特征,如图斑密度(某类型图斑数量除以该类型所有图斑面积之和);地理场景层次反映整体的空间结构、相互关系、功能语义等特征。3个层次逐步扩大尺度(由细到粗),与景观生态学中的斑块(Patch)、斑块类型(Class)、景观(Landscape)3个概念基本对应。

在此概念界定下,我们可以基于对地观测大数据开展地表的精准理解与功能透视,也就是以地理实体为基本单元,通过浅层的视觉感知和深层的模式挖掘,逐步实现对地理实体形态、类型、指标、结构、状态、趋势的认知过程。因此,地理图斑概念的提出,一方面,在借鉴实际自然资源调查领域人工目视解译的流程与机制基础上,希望利用机器智能的巧妙设计模拟视觉感知实现实体级的精准解译,形成可统计、可验证的地理信息成果;另一方面,通过其将地表空间离散化,把一个复杂的地表认知问题先抽象简单化,再以此为基准重组各类时空信息使其描述丰富化,再从中找出隐含关联关系实现模式挖掘,这样的认知机制恰与大数据“粒化(Mapping)—重组(Fusion)—关联(Relation)”的计算思维相吻合。

如图1所示,地理图斑是从高分辨率影像中提取的实体单元,有明确“图斑边界形态”(几何)与“谱相物理特征”(代数),其内涵和外延包括:①定位,图斑在空间分布的精确位置、形态及组团结构;②定性,图斑的自然与社会功能属性;③定量,图斑所承载信息内容的量化指标及变化过程;④定制,图斑在环境中存在的状态差异(内因)及受外力扰动影响后的变化趋势(外因)。上述4个方面,从图斑形态、类型、指标、结构、状态、趋势等维度进行了由浅入深的刻画,是其“图(外在空间形态与结构)—谱(内在多维/时序特征与规律)”耦合特性的具体指向<sup>[5]</sup>。而这4个方面准确的认知,需要通过“眼睛看”、“模型算”、“脑子想”3个环节的前后串联和有机协同才能有望实现;特别是要从浅层视觉感知的理解(形成“信息图谱”Info-TUPU)升华到深层模式挖掘的透视(形成“知识图谱”Know-TUPU),才能实现对地理实体表象、过程、格局、机理的全方面认知,以支撑知识化的地理信息决策服务。为此,本文将紧紧围绕“地理图斑”这一核心概念,搭



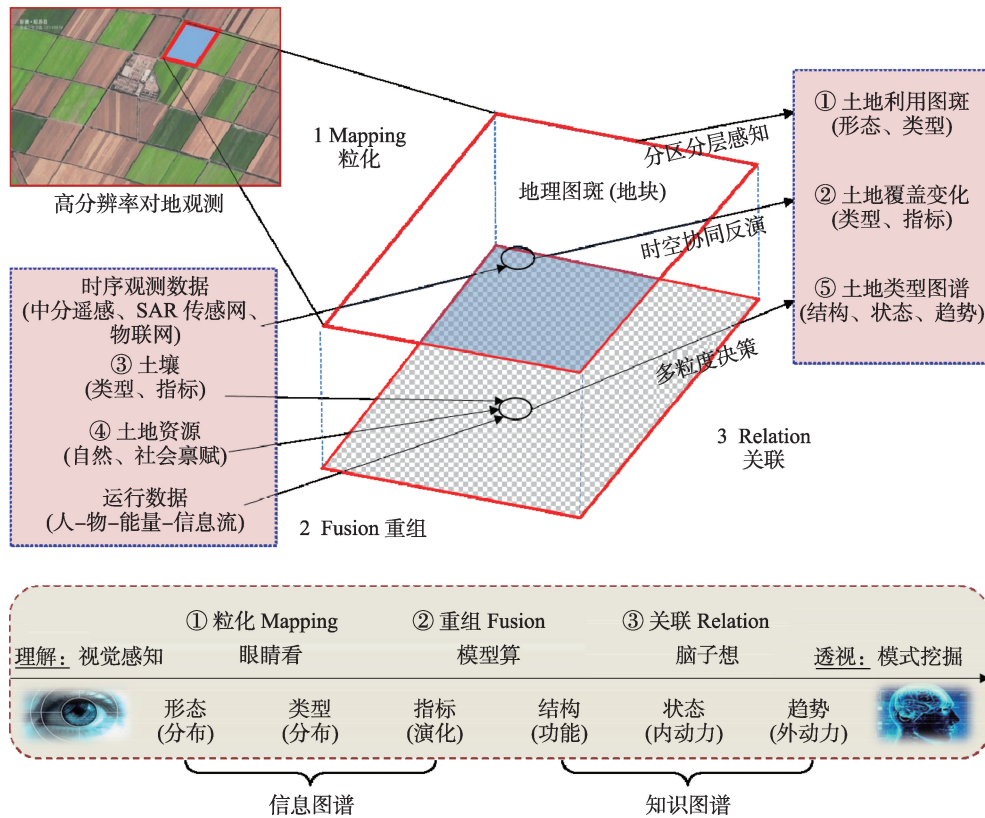


图1 地理图斑及其图谱的耦合关系

Fig. 1 Geo-parcels and coupling relationships of their TUPU

建一个逐层递进的智能计算模型,以期通过“粒化(图斑提取)—重组(数据融合)—关联(模式挖掘)”的三部曲实现精准地理信息的生成与应用,为突破对地观测数据在应用中长期存在成本高、效率低、普适性差、信息层次低等瓶颈问题夯实理论基础、创新方法技术、拓展应用深度。

## 2.2 相关研究的综述分析

### 2.2.1 地理图斑的提取(粒化 Mapping)

随着卫星传感器的空间分辨率不断提高,遥感卫星影像对地表现状的刻画越来越精细,信息解译的基本单元也随之经历了从“像元”到“空间对象”的过渡。针对中高分辨率的遥感信息提取,本世纪初流行的是面向对象分类策略<sup>[4]</sup>,一般依据像元光谱、纹理等特征同质性,采用自底向上的聚合方式来生成对象<sup>[6]</sup>,但影像本身可用特征不足,特别是高层语义特征因表达问题又往往难以被有效利用,因此生成的对象与地理实体并不匹配<sup>[7-8]</sup>。而现今的米级/亚米级高分影像又衍生了图斑级解译需求,对图斑形态完整性和类型精准性都提出了较高要求。与此同时,自然资源调查所需的大区域、多类型

图斑生产,目前仍主要依靠人工目视解译来完成<sup>[9]</sup>,这其中的技术瓶颈就是难以提取综合了人类既有知识且符合人类视觉感官的图斑单元。因此,如何模拟人的视觉感知机制,充分挖掘影像边缘与纹理等高显著性视觉特征来构建可支撑地理图斑智能化提取的机器学习模型,是本文关注的重点之一。

在这方面,擅长处理视觉感知问题的深度学习技术仍是当前的有效工具。特别是深度卷积神经网络通过端到端、像素对像素的训练,可以在多个尺度上学习并表达训练数据所隐含的视觉特征,在图斑提取中具有良好的应用前景<sup>[10-11]</sup>。我们分析,边缘和纹理是图斑在影像上最显著的两类视觉特征,对其提取时显然需重点考虑并有区别地开展模型设计。在边缘模型的图斑构建方面,现有的研究考虑设计边界检测公式实现边界定位<sup>[12-13]</sup>或者通过构建多尺度卷积神经网络模型来提取图斑边缘<sup>[14]</sup>。而基于纹理模型的图斑构建方法则可归类为直接法和间接法两类:前者通常是在语义分割网络的基础上获取地物类型再进一步构建图斑的轮廓信息<sup>[15-16]</sup>;后者的常规思路是先对遥感影像进行分割获取初始对象,并在类型判别基础上进一步进行对象综合



以实现图斑的构建<sup>[17]</sup>。除了上述两方面,为了可兼顾图斑形态和类别准确性,近几年也陆续提出了同时考虑边缘和纹理特征的模型。例如,Yuan<sup>[18]</sup>和Prathap等<sup>[19]</sup>通过预处理使标签同时包含建筑物轮廓边界和内部信息,并把浅层的高频边缘特征和深层的语义类别特征融合后进行学习,取得了不错的效果。尽管如此,目前的方法大多停留在基于公开数据集开展的方法探索阶段,如何在大区域、多类型的地理图斑的实际生产中实践规模化运用尚需进一步评估。

### 2.2.2 多源数据的融合(重组 Fusion)

图斑基准构建形成后,可以通过在其结构化的单元上重组多方来源的数据以便在更高信息维度上开展地表认知。能融合的多源数据可以包括中分辨率时序遥感数据、定量遥感产品、站点观测数据、土地资源相关的各类静态数据、各种模态产生的物联网数据和社会经济数据以及互联网社交消费产生的数据等。种种记录地表发生态势的数据均能以地理图斑为载体提供多视角、多层次的特征描述,其与图斑关联聚合后可以图斑属性的方式参与计算分析。

我们认为可用于特征计算的典型数据源有以下3个方面:①高空间分辨率遥感可提供图斑位置、形态、纹理等视觉描述特征<sup>[8]</sup>;高时间分辨率遥感可用于获取图斑内部地物随时间的波谱变化特征及其衍生的量化指标<sup>[20-21]</sup>;多角度遥感可提供地表各向异性信息,为基于物理模型反演地物空间结构参数提供丰富的立体观测数据<sup>[22]</sup>;高光谱遥感可提供地物高维的光谱反射率信息,大大拓展估算地表定量参数的特征维度<sup>[23]</sup>。可以想象,协同这些不同特色的遥感数据及其产品必可集各家所长并丰富地理图斑的特征描述,但现有研究大多是开展数据级融合,通过降尺度等方式完成从低分辨率数据到中高分辨率数据的转化<sup>[24]</sup>,而鲜有从影像空间(像元)直接转化到地理空间(图斑)的尺度转化方法,如何结合图斑属性开展多源遥感数据及其衍生产品的降尺度以及特征层融合值得深入探索。②在地面站点观测数据的协同方面,现有研究通常是针对农业、气象、土壤、水文、生态等领域研究对象的关键环境参数进行长时间序列的定点观测,再利用空间插值等地统计方式将观测数据外推到站点以外区域,实现观测数据点信息的扩展<sup>[25]</sup>,但同样缺少专门针对观测点到图斑面的信息扩展方法研究,且在

外扩时对空间异质性缺乏充分考虑和针对性设计。当前,基于非线性回归的机器学习方法在与基于空间平稳性假设的地统计方法比较时逐渐展露出优势,有待引入至由点到面的图斑属性推测研究中来<sup>[26-27]</sup>。③社会经济和互联网数据大多为宏观尺度或碎片化的非(半)结构化数据(文本、音视频、表格、图片、电子地图POI等),而为了在图斑上有效实现此类多模态数据的空间结构化与协同计算,以往遵循自上而下思路的研究有待革新。例如,在人口或GDP数据空间化时,通常将行政单元的统计数据作为模型整体输入,进而在小尺度规则格网上对宏观调查数据按照某种原则进行空间分解<sup>[28]</sup>;若其分解权重和调查总量能在考虑非规则图斑形态、类型、指标等信息后进行空间分配,则利用相关的社会经济数据获取的图斑结构化特征信息应当更加精细可靠。

综合来看,地理图斑单元上的数据重组与信息融合大致可分为3个层次:①数据组合(物理反应),数据在叠合图斑并利用求均值、最大/小值、众数等统计方式进行简单集成,使图斑的属性字段得到直接增加,数据属性本质没有改变;②数据整合(化学反应),多方数据经过相互匹配和简单公式计算后得到一个新的值作为图斑属性(特征),使多源数据重组后产生了一定价值;③数据聚合(核反应),由多方数据聚合孵化产生(反演)出新的图斑属性。这3个层次由低到高的数据重组方法均有待进一步创新,希望通过在图斑上合理巧妙地设计信息聚合方法,促进多源多模态数据与图斑之间的深度交互与协同计算。

### 2.2.3 多元模式的挖掘(关联 Relation)

模式的内涵是因地理实体之间、实体与环境之间存在静态依存或动态变化关系而形成的稳定性状或异常现象,因而地理模式挖掘的本质是要揭示地表因时空相关性与异质性而形成的分布与演化规律。研究表明,地理模式挖掘与尺度密切相关,空间异质性与均匀性都可随尺度发生变化<sup>[29]</sup>;而大尺度上的复杂模式可视为由若干均匀小尺度模式叠加而成<sup>[29]</sup>,因而小尺度(如本文的图斑尺度)上的模式挖掘研究具有重要意义。在我们的框架下,就是要在图斑提取和多源数据融合基础上进一步进行模式的挖掘,解析其在空间、时间、属性等维度上的关联关系。

从现有的研究来看,地理信息领域的模式挖掘

在实现方法上大致可分为经验模型和机理模型两大类<sup>[30-31]</sup>。经验模型是借助机器学习等手段构建特征与模式之间的统计关系,其高度依赖于输入数据源与选取样本,且多为黑箱模型,机理的可解释性较弱,但其实现过程简单、计算效率高,因而也广泛应用于空间分布<sup>[32]</sup>和空间过程<sup>[33]</sup>的模式挖掘领域中。相反地,机理模型更侧重于物理过程,能够模拟丰富而复杂的现实场景而开展原理性地建模,在机理性的模式挖掘领域中具有独特的优势。例如,模拟作物呼吸、光合、蒸腾、营养等一系列生理过程构建得到的农作物生长过程模型<sup>[34]</sup>。显然,两类模型各有优劣势,适用的背景问题也略有差异。因此,在模拟“眼睛看”的过程感知图斑基础上,如何进一步借鉴“模型算一脑子想”的人类认知机制,有机组合“数据驱动”和“知识驱动”2种思维设计“数据与知识双向驱动”的图斑模式挖掘方法值得深入。

### 3 地理图斑智能计算模型

按照从浅层影像理解到深层功能透视的研究

脉络,本文在上一节分析了地理空间外在场景结构(图)与内在发生机理(谱)耦合的认知机制,前者要求实现图斑的构建,后者要求在图斑上进一步重组数据并挖掘模式。对此,我们紧密结合地学分析、机器学习与遥感机理方法发展了一套集“分区分层感知-时空协同反演-多粒度决策”3个基础模型于一体的地理图斑智能计算模型。图2设计了模型整体的示意框架,3个基础模型之间呈现的是一种相互耦合、依次递进的逻辑关系,分别对应“粒化”、“重组”、“关联”的三类大数据计算思维。

该模型的整体思路是,首先基于高分遥感影像的分区分层感知提取地理图斑;在此基础上逐步融入时序观测数据开展时空协同反演;进而再结合自然资源禀赋、生态环境本底、社会经济等各类静态数据以及生产生活中产生的动态数据开展多粒度决策分析,最终对地理图斑的空间分布、过程演化、属性功能、内外动力等模式实现全面挖掘。本套模型将从空间、时间、属性等维度对地表进行层层解构,通过“信息图谱”——“形态(图)—类型/指标(谱)”和“知识图谱”——“结构(图)—状态/趋势(谱)”2个层级的图谱分析来解构“定位—定性—定

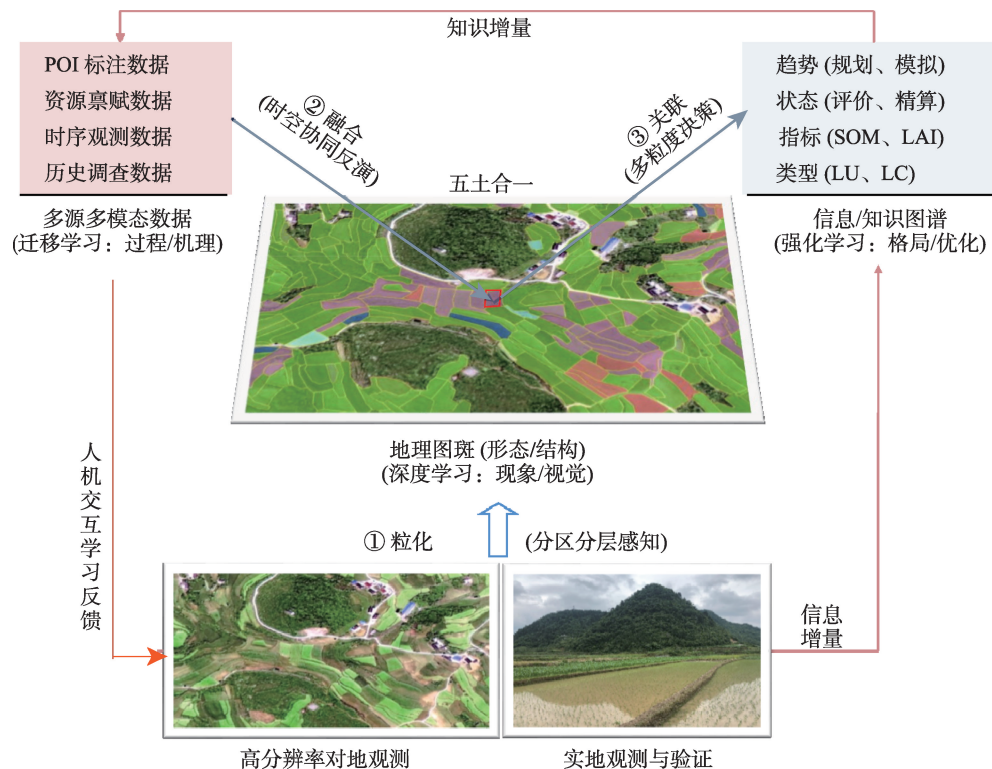


图2 集“分区分层感知—时空协同反演—多粒度决策”于一体的地理图斑智能计算模型

Fig. 2 Intelligent computation model of geo-parcels based on three sub-models: zoning-stratified perception, spatiotemporal synergistically inversion, and multi-granular decision-making

量一定制”四位一体的复杂地表认知问题。

### 3.1 分区分层感知模型

高分辨率对地观测为地理图斑的构建提供了“精准”的时空影像基准,其中的“精”是指精细的图斑形态,“准”是指准确的图斑类型及量化指标。对此,本文以高空间分辨率影像为基底,模拟视觉对地物的选择性注意机制,设计了地理图斑的分区分层感知模型,对应了大数据计算路线中的“粒化”环节。所谓的分区分层感知是根据不同类型地物在高空间分辨率影像上所呈现视觉特征差异,在不同地理区块内逐层次地从影像中提取矢量多边形图斑。这个过程主要包含分区与分层2个空间粒化过

程(图3):①分区,鉴于人类活动与自然作用形成的交通、水系以及山地区的地形线联结而成的网络体系在地表纵横交错,若将场景划分为若干地理区块,每个区块内土地利用格局相对独立,易于区分,且彼此互不干扰;受此启发,先在影像上对分区控制的要素进行提取,包括由路面、水面等要素联结成交通与水系网络,以及通过对DEM数据的地形分析提取地形线(如山脊线/沟谷线)并联结成地形网络<sup>[5]</sup>;进而再通过这些网络分区对区域化的大规模生产区块分解为若干独立的子任务,为实施图斑提取任务的并行化计算亦提供了控制单元;②分层,参考土地利用的分类体系<sup>[9]</sup>,依据地物在高分影像上表现的不同解译特征,将地表类型分为“建(建筑)”、“水(水体)”、

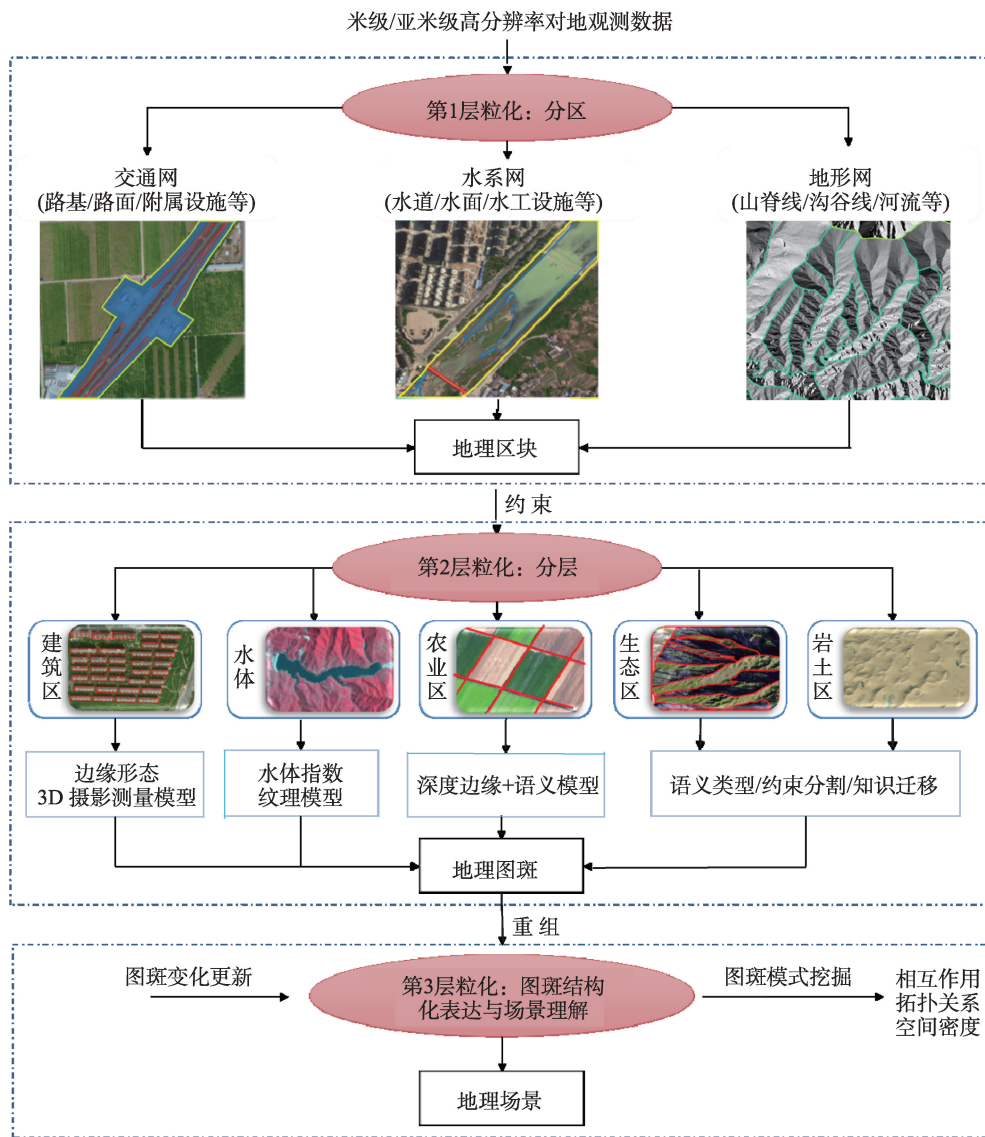


图3 分区分层感知模型

Fig. 3 Zoning-stratified perception model



“土(类耕地)”、“生(林草)”、“地(岩土)”5大类,并针对每种地物呈现视觉特征差异,分别设计方法(常规的指数方法或深度学习算法)构建相应的地物提取模型,进而分层次地从每个控制区内对影像实施空间粒化(即基于面状矢量多边形的地表二维空间离散化),实现地表不同种类的图斑分离,而相应的图斑可称之为“空间粒”。

在具体的提取模型上,本文以农业类耕地(即上述5大类中的“土”,包括平原区耕地以及山地区的梯田、坡耕地等)图斑提取为例加以细述。因为人为作用,该类图斑在影像上呈现为规则且清晰的边缘特征(如水田),或者内部纹理清晰且均质性较强的视觉特征(如坡耕地)。因此,本文提出了一种“边缘/语义”结合的深度学习提取模型进行该类图斑提取:①基于影像视觉差异构建深度边缘模型,通过多层网络卷积强化边缘特征,模拟视觉感知从影像中提取地块边界;②基于深度边缘模型计算每个影像区块内的边缘强度,并结合 Canny 算子补充局部边缘信息,在保持全局边缘完整的同时兼顾局部边界位置精度,进而基于骨架提取的线图层采用轮廓自动连接、曲线跟踪、线段平滑等算法进行优化,从而获取精确且完整的边界线并构造形成图斑面状矢量对象;③对于类似坡耕地、经济作物的地块,其边缘形态并非特别清晰,则先采用基于纹理的语义分割深度学习模型对疑似种植图斑进行预

先提取,进而从外部迁移时序观测、土地资源等数据,对实际种植的作物覆盖类型进行判别,再结合地块生长环境相似性来推测其利用类型,分析是否具备耕作利用属性,从而将这一类耕地与自然生长的林草图斑进行分离。

### 3.2 时空协同反演模型

地表演化是一个随时间变化的动态过程。卫星遥感按照一定周期重返,以相同的观测角度、相似的成像条件对地表进行长时间观测,获取的多时相影像可记录地表现象的这些动态变化过程。因而时间序列的卫星对地观测已成为当前分析地表现象时空演变规律的重要数据源。然而,获取同时具有高时间和高空间分辨率的卫星影像往往较为困难。在此情形下,协同利用高时间和高空间分辨率的多源卫星数据成为必然选择。对此,在分区分层感知模型基础上,本文进一步提出图斑尺度的时空协同反演模型(图4),即以高空间分辨率影像提取的图斑为空间单元约束,融合高时间分辨率的多期影像特征,协同起来实现精细图斑尺度上的地表覆盖识别与定量指标反演。

该模型涉及的研究内容主要包括:①有效时间序列特征的提取,多时相遥感数据存在像素几何不对齐、影像辐射差异、云和阴影导致区域数据缺失等问题,可能会造成时序特征的异常变化,故而需

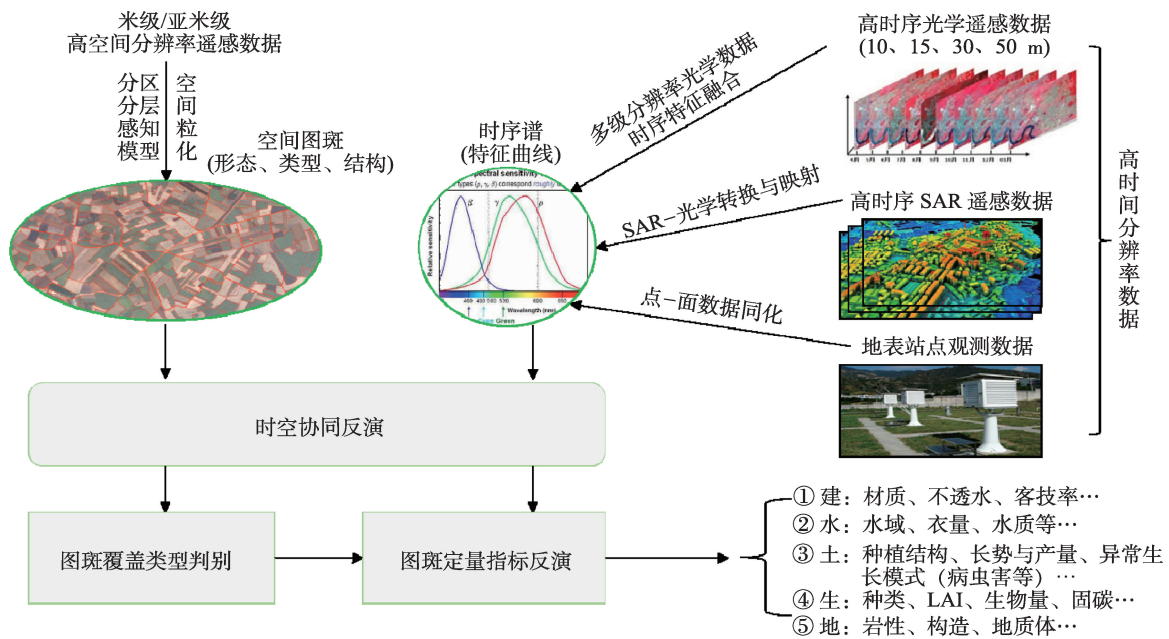


图4 时空协同反演模型

Fig. 4 Spatiotemporal synergistically inversion model

要通过几何配准<sup>[36]</sup>、辐射归一化<sup>[37]</sup>、云影掩膜<sup>[38]</sup>等预处理流程来提取有效的时序特征；同时，若利用SAR、站点观测等更易获取的异构数据来构建时序特征，还需解决不同结构数据间的非线性同步响应、光谱通道差异、点-面同化等问题，以提高不同时间获取数据间的可比性和空间全覆盖性；②平滑时空特征曲线的重建，针对高时间分辨率影像构建的时序特征稀疏、间隔不规则等问题，需要发展面向稀疏特征、不等间隔、噪声鲁棒的特征曲线拟合方法，以获得平滑的、时间间隔固定的时空特征曲线用于分析；③地表覆盖类型判别与定量指标反演，需要耦合时间序列特征来增强地物的可区分性与反演指标的准确性<sup>[39]</sup>；例如，不同农作物由于生长周期重合且特征相似，利用单一时间的影像难以准确区分，时空协同的方法可以利用在时间维度上的微小差异，结合生长物候实现地表上不同类型作物的准确识别<sup>[40]</sup>，反映其生长态势与产量的定量指标亦能得到更加可靠的反演。

### 3.3 多粒度决策模型

上述2个基础模型是基于高空间与高时间分辨率遥感数据开展的设计，而为了更加深入解析地理图斑，发现其隐含属性或潜在模式，需要更多地协

同多源异构的非遥感类数据，利用它们蕴含的互补信息加强对地理图斑的表征，通过多源属性数据丰富其内涵并进而实现图斑内在属性的透视(属性上的关联关系分析)和外围邻斑的组团(空间上关联关系分析)<sup>[41]</sup>。为此，本文进一步设计了多粒度决策基础模型(图5)，需经地理图斑形态提取、类型识别形成多粒度的空间面状单元(图形)后，进一步融合多源多模态数据(如土地资源禀赋数据、互联网地图POI数据、历史调查数据等)形成结构化的多维属性表，再通过映射关系的机器学习(数据驱动)或专家知识的嵌入引导(模型驱动)对图斑隐含语义属性进行推测，对图斑空间结构组团进行重建(图式，即通过地理图斑形成地理场景，对应为图3中下方的第三层空间粒化)，进而揭示其内动力(存在状态的背景及条件分析)，并引入高频动态数据分析(时间上关联关系分析)外动力(发展演化的模拟及趋势预测)机制，最终能以专题图的形式服务于精算、评价、规划、预测等多方位的空间决策应用(图解)。

该模型涉及的研究内容主要包括：①图斑的多源数据融合，即不同来源、形态、格式的数据在图斑单元上的重组融合，需要在空间化、指标化、规范化、趋同化、离散化等计算过程中解决尺度转换、粒

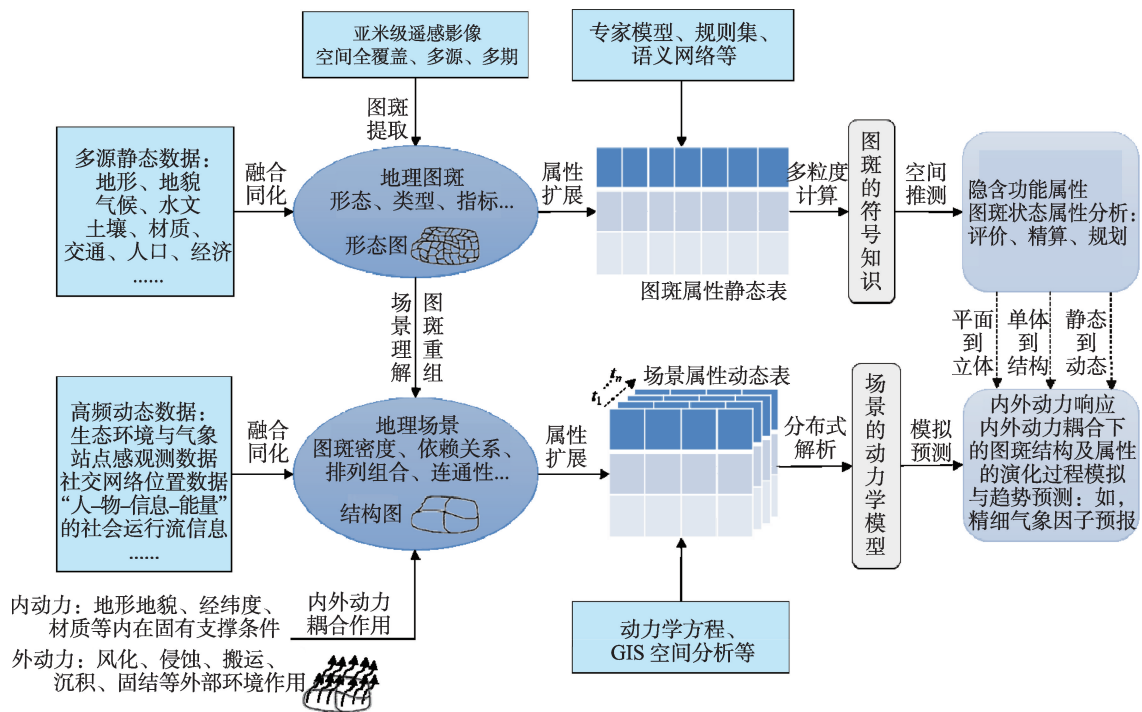


图5 多粒度决策模型

Fig. 5 Multi-granular decision-making model

度选择、权重分解、聚集综合、指标衍生等关键问题,以形成结构化的多维属性表;②图斑的隐含属性推测,需要在属性表中基于互补、跨域的多维描述特征,通过树状决策式机器学习算法(软模型——决策树、随机森林等)的训练或专家知识(硬模型——规则、物理模型、测算公式等)的嵌入,构建图斑多维条件属性与所关注隐含属性间的关联关系,以形成面向图斑决策的符号化规则知识,并据此推测其隐含的语义信息;同时依据图斑间的空间邻近关系、属性条件关系形成组团单元(对应图3中的第三层空间粒化),形成地理场景,揭示地理格局;③场景的动力学分析,在图斑聚合形成的结构化场景上进一步融入气象模式、社会运行等反映场景实时变化的数据,改造传统基于规则网格的动力学解析方程等方法,并结合GIS空间分析及领域知识构建面向不规则场景单元的动力学模型,从而在较大的场景尺度上模拟内外动力作用下的地表自组织结构优化与过程演化,进而指导对该场景下的未来趋势预测。

## 4 地理图斑模式挖掘及案例简析

### 4.1 图斑模式挖掘体系

上述3个基础模型联合构建了本文提出的地理图斑智能计算模型,可面向各领域专题应用与分析决策的需求,逐步实现对地理图斑“信息图谱”(形态(图)、类型/指标(谱))的浅层理解和“知识图谱”(结构(图)、状态/趋势(谱))的深层透视,并随之挖掘揭示地理现象、过程、格局以及机理的各类显式或隐式模式。图6示意了上述2层图谱的演进关系及其实现过程中存在的4种典型模式的挖掘(分布模式与功能模式对应于静态模式,生长模式与动力模式则对应于动态模式)。

对于图斑模式挖掘的总体过程,可以描述如下:①在分区分层的地理学分析思想指导下,利用控制要素构建分区通道与划分网络,运用模拟视觉机制的深度学习分层式构建感知模型,对具有精准“定位”的图斑进行形态提取,并进一步对图斑土地利用(LU)类型进行“定性”判别,实现图斑“形态(图)—类型(谱)”耦合的分布模式挖掘;②重点针

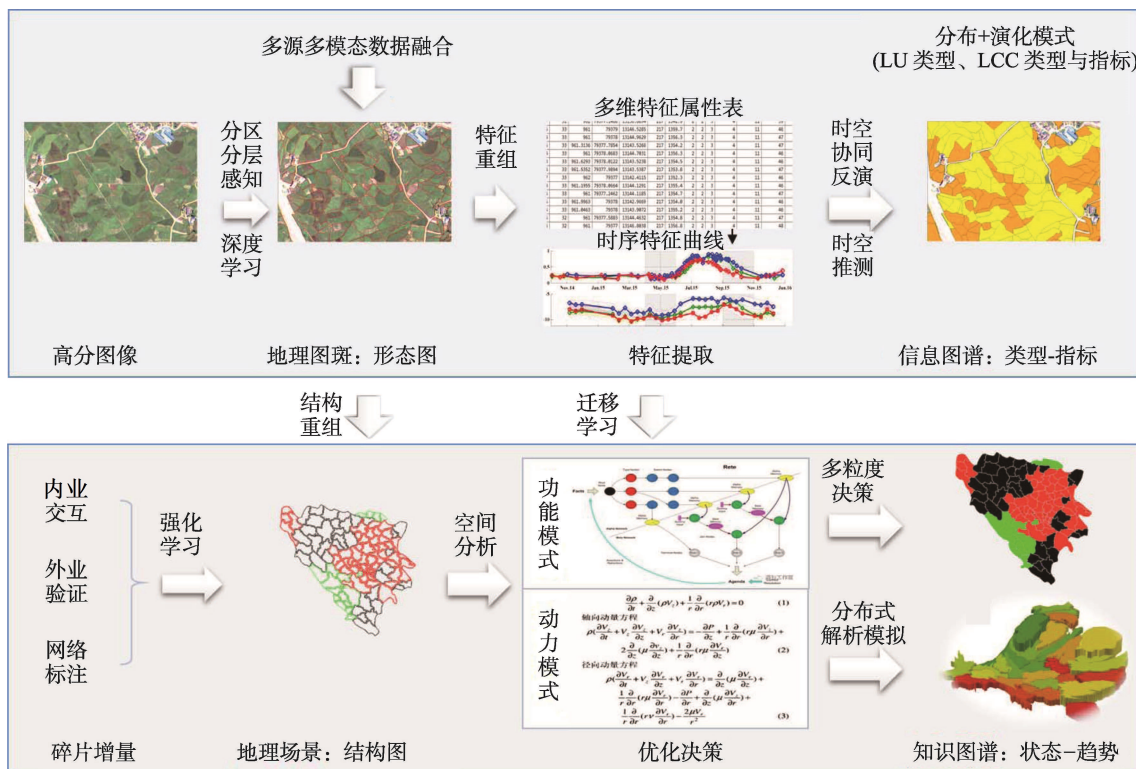


图6 地理图斑模式挖掘以及两层图谱的演进关系

Fig. 6 Pattern mining and progressive relation of two-layer graph-spectrum based on geo-parcels



对“土”、“生”两类土地利用图斑(图),同化融合时序观测数据进行地物覆盖变化特征曲线(谱)的构建,进而利用时空协同反演模型挖掘图斑之上的生长模式,实现图斑土地覆盖(LC)类型的“定性”判别以及“定量”指标的准确反演,从而生成图斑“形态(图)—类型/指标(谱)”耦合的“信息图谱”;③利用空间聚合技术迁移静态的各类非遥感类数据,并运用多粒度决策模型挖掘面向精算、评价、空间优化、规划等应用的图斑功能模式,进而实现图斑空间结构的组团以及面向具体应用的专题“定制”与地理场景搭建;④进一步借助高频动态的非遥感类数据进行不规则图斑的分布式解析与模拟,挖掘面向预测等应用的图斑动力模式,实现内动力支撑下的“状态”解构和外动力驱动下的“趋势”预测,从而生成图斑“结构(图)—状态/趋势(谱)”耦合的“知识图谱”。

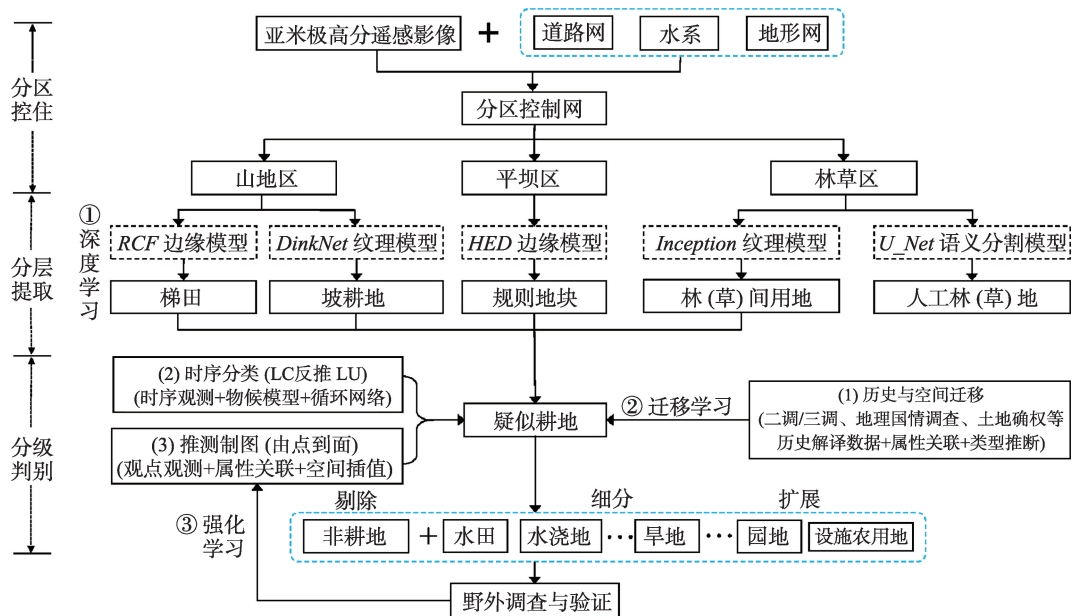
#### 4.2 图斑分布模式挖掘——以我国西南山区的耕地制图为案例

图斑分布模式(形态—类型)是依据地理实体在高分影像上呈现的视觉特征差异来展示其在地理空间上的分异特性,是按照分区分层的地理学思想,对复杂地表场景中分布的地理图斑在所被划分的区块内依据视觉特征差异,分别设计模拟视觉感知的提取模型,实现对图斑空间形态的高精度定位的提取;进而依据其归属的分级特性,从大类到

细类,通过逐步向内迁移外部信息,以及关联推测对图斑类型进行不断深化地判别。

本文以我国西南山区的耕地制图应用为案例来阐述视觉感知层面的图斑分布模式挖掘。在“分区—分层—分级”思想指导下,本文设计了一套在该区域进行耕地图斑分布模式挖掘的思路(图7)。在我国西南以贵州为典型区域的农业耕地地块细小破碎,主要分布在相对平坦的坝区、地形起伏的山地坡面以及两者过渡的林草区(用于分区);根据耕地特点进一步又可分为平坝区的规则地块、山区的梯田和坡耕地、林草区的林(草)间用地以及人工林(草)地用地5大类型(用于分层)。

根据耕地形态视觉特征差异分别设计针对性的深度学习图斑提取模型,分层次地在不同分区的区块内进行耕地地块的提取:①平坝区耕地主要为形态较为规则的地块,因而采用HED网络<sup>[42]</sup>进行边缘模型训练实现对边界线的监督式提取,进而通过“由线构面”形成耕地图斑面状矢量;②山地梯田的边缘形态也较为清晰,但其地块形态上表现为更加狭长或细小,因而采用去掉第三层池化的RCF网络<sup>[44]</sup>实现精细线特征的表达,并通过数学形态学处理与自适应矢量构面算法实现对此类耕地图斑的多边形提取;③山地坡面上大量开垦的还有旱地、园地等坡耕地,这类耕地由于土地质量相对较差,



注:以中国西南山区的耕地制图为案例。

图7 地理图斑分布模式挖掘

Fig. 7 Distribution pattern mining based on geo-parcels

种植比较随意,随时可能撂荒,造成其在高分影像上的边缘形态比较模糊,主要通过色差纹理特征加以区分,因而我们改造 Dinknet 网络<sup>[43]</sup>训练纹理模型,实现对高可信及疑似坡耕地图斑的提取;④耕地还可能零散夹杂在林(草)间用地或人工林(草)地用地的林草区内,视觉特征上表现为与草地接近,但具备特殊的纹理特征,因而先利用 U-Net 网络<sup>[44]</sup>语义分割区分林(草)间用地与人工林(草)地用地,再进一步针对林(草)间用地的纹理特点,利用 Inception 网络<sup>[45]</sup>在林(草)地用地的图斑中找出疑似耕地地块。经过上述的分层式提取可得到较为完整的、带有较高置信度的耕地地块,而后再结合二调/三调、地理国情调查、土地确权等历史解译数据以及时序和站点观测数据,有针对性地设计时序分类、空间推测等方法进一步剔除其中的部分非耕地地块,并依据耕地的分类体系将提取的图斑细分为“水田”、“旱田”、“水浇地”等分级类型,最后通过野外调查和实地验证获取准确的地面点信息,作为增量信息用于上述耕地图斑分布模式的优化。

本文以贵州省息烽县为研究区开展了全县耕地图斑分布模式的挖掘。图8展示了遵照上述技术流程完成的息烽县耕地分布制图。通过“分区—分层”的方式,全县共提取了124 552个耕地图斑,并从中形成了规则耕地、梯田、坡耕地、林间耕地4个分级亚类的空间分布。与目视解译相对比,这些耕地图斑与实际地块边界较为吻合,利用形态学的交并比 IoU 指标<sup>[46]</sup>显示大于0.7的图斑占比大于60%,0.5~0.7达到了30%,只有少量图斑精度小于0.5,这充分

验证了本文基于“分区—分层—分级”思想设计的图斑分布模式挖掘策略在边界的精细勾绘与类型的准确识别方面均具有明显优势和推广价值。

#### 4.3 图斑生长模式挖掘——以多云多雨地区的种植结构制图为例

图斑生长模式(形态—指标)是在地理图斑形态提取与类型判别的基础上,在图斑之上进一步融入具有时序变化特征的多尺度观测数据集,对比图斑周期性或持续变化的生物学或物候规律,构建图斑内时序演化的参数定量反演模型,实现对图斑内生长过程的动态监测以及对其变化机制的量化分析。这个过程的重点是在图斑形态提取及土地利用类型识别基础上,协同利用高时间分辨率观测数据(如 Landsat, GF-1-WFV 和 Sentinel-1 等卫星数据)构建的时序特征,通过时空协同反演模型来识别图斑土地覆盖类型(如作物类型)及其上的量化指标(如作物长势、产量)<sup>[47]</sup>。

本文以我国西南山地区域的农业应用为案例来阐述图斑生长模式的挖掘。在该区域,除了分布模式中涉及的地块细小破碎问题,多云多雨的气候还带来了传统光学被动遥感难以持续获取数据的新问题,必须协同高时序的主动遥感来实现对耕地上种植作物的生长模式挖掘。因此,提出了“光学—SAR”协同的地块级种植结构制图方法(图9):①基于高空间分辨率影像采用4.2节的技术流程对耕地进行提取,以图斑为基本单元构建区域内耕地地块的空间分布;②通过 SAR 数据预处理以及多时相数据之间几何精纠正,得到时空基准统一的

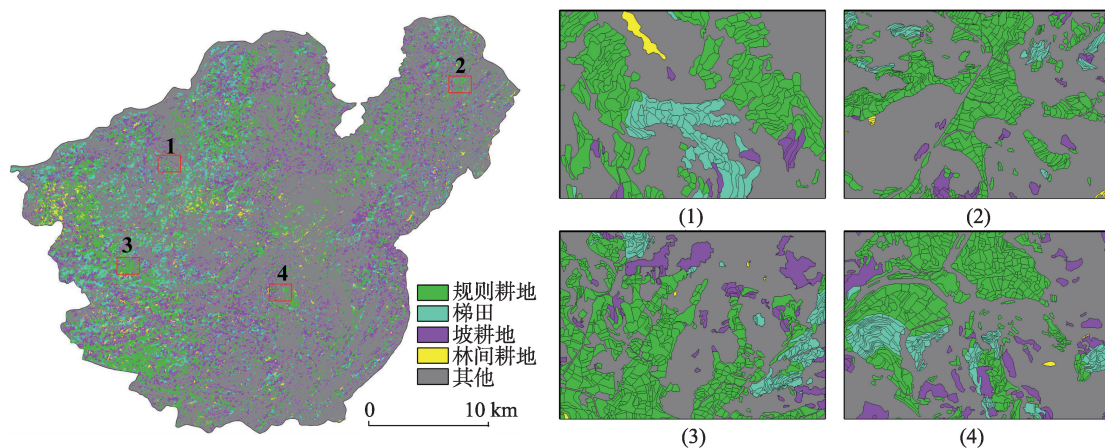
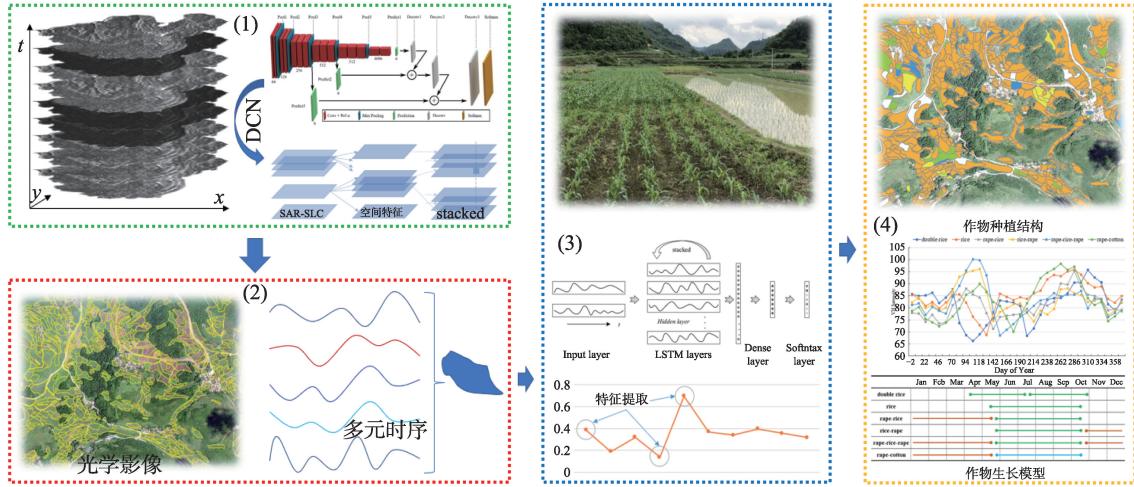


图8 贵州省息烽县耕地地块的图斑提取试验结果

Fig. 8 Experimental results of geo-parcels extraction with cultivated land in Xifeng County, Guizhou Province





注：以多云多雨地区种植结构制图为案例。

图9 地理图斑生长模式挖掘技术流程

Fig. 9 Growth pattern mining based on geo-parcels

SAR时序数据集,再利用预训练的深度卷积网络DCN<sup>[48]</sup>提取SAR时序数据的多尺度特征,在图斑上生成上百个维度的特征向量;③将多时相的SAR特征层叠加到耕地图斑上,构建图斑尺度的时间序列曲线,形成图斑之上的生长模式,进而利用循环神经网络RNN<sup>[49]</sup>可对多元时序曲线实施种植作物类型的判别,生成精准的图斑级种植结构图,基于此可进一步反演作物生物量的相关定量指标。

本文在4.2节提取的耕地图斑基础上,进一步针对贵州息烽县多云雨造成时序光学数据难获取

的问题,开展了Sentinel-1 SAR时序数据的下载与预处理,并结合其演化特征利用DCN和RNN实现了“光学—SAR”协同的图斑尺度作物分类。图10展示了制图结果,整体上看,全县农业种植结构吻合了自然条件和社会经济因素共同制约的规律:水稻等主要粮食作物主要种植于山坡梯田与平原坝区的规则耕地上(参见区域A),主要是为了利用高原地形切割形成的水利系统对于田地层层灌溉的有利条件;而区域B邻近省会贵阳市,因城市供应需求和交通便利,在此区域种植有较多的经济作物

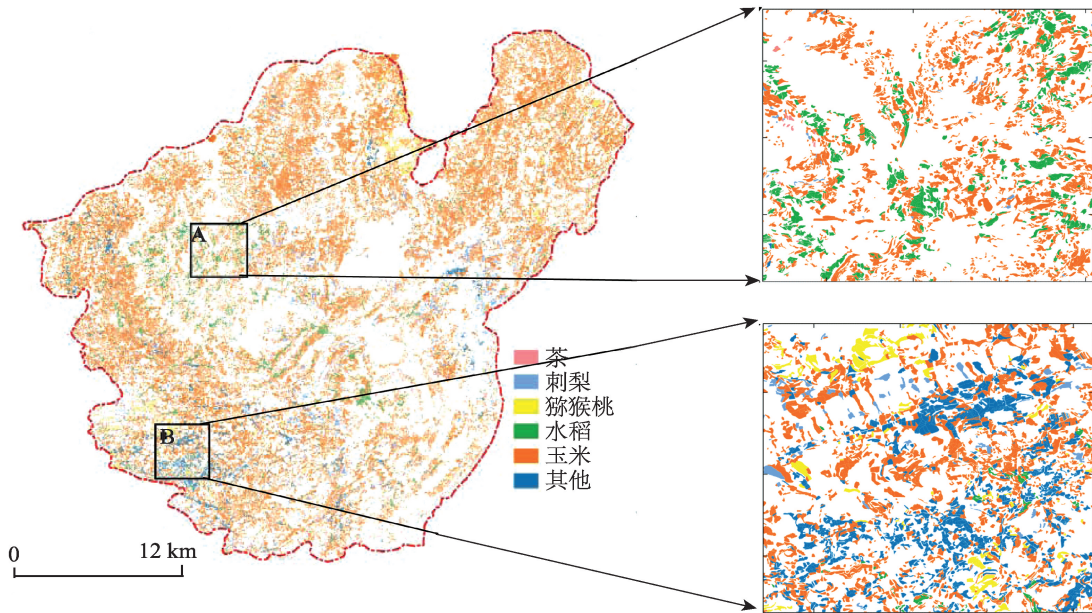


图10 贵州省息烽县图斑级作物分类试验结果

Fig. 10 Experimental results of crop mapping based on geo-parcels in Xifeng County, Guizhou Province



(如猕猴桃和刺梨)和蔬菜(图中以其他类别代替)来提高耕作的效益。本结果的制图精度可达87.87%,且多组对比实验也验证了基于时序演化特征开展作物分类的可行性与有效性<sup>[50]</sup>,为精细化作物种植结构调查以及进一步的作物生物量指标反演提供了创新的思路。

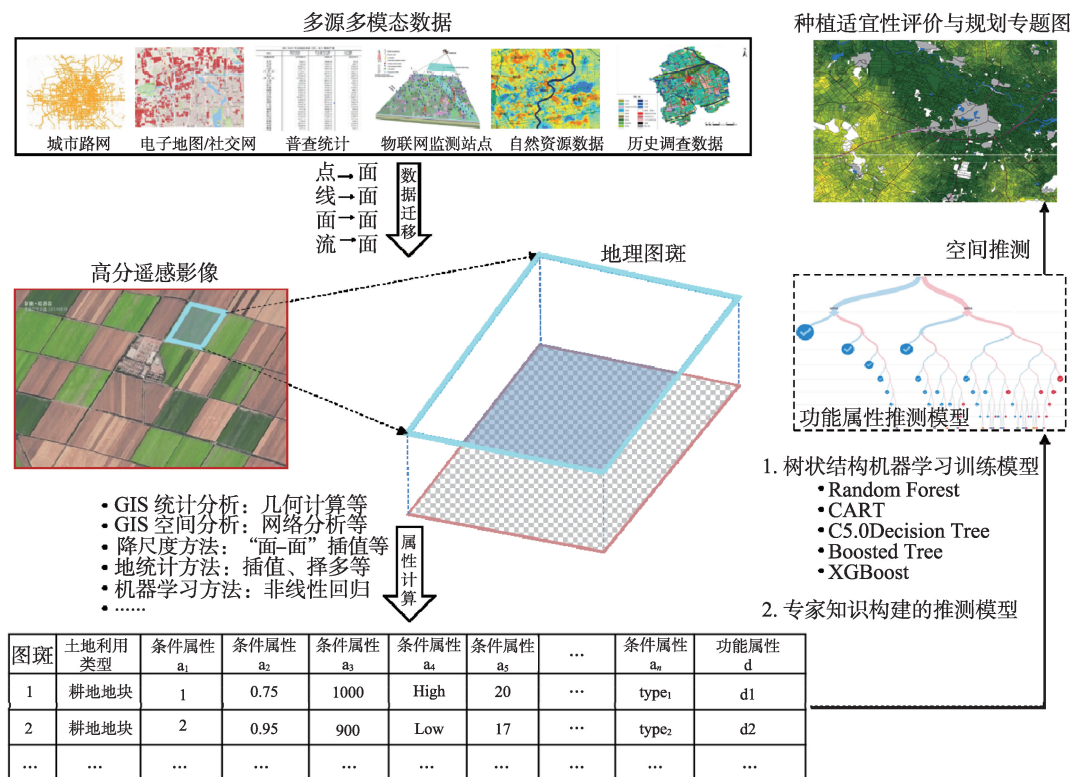
#### 4.4 图斑功能模式挖掘——以地块级作物种植适宜性评价制图为案例

图斑功能模式(结构—状态)是在以上单个各自独立的图斑提取及其功能语义等隐含属性分析基础上,考虑如何进一步通过分析内在相互作用机制来构建图斑间的聚合关系而形成地理场景的综合体。也就是针对空间结构的地理特征,同时反映图斑在地理场景上排列组合与拓扑网络关系等空间特征;进一步可融入自然与人文静态要素,通过建模分析计算地理综合体对人口、资源、环境与灾害等自然与社会运行的承载能力(内动力状态),这是开展数据驱动的规划设计及空间优化的基础。

图斑的隐含语义属性一般不能通过“眼睛看”感知遥感影像获得,往往需要叠加多源多模态的非

遥感类数据,并经过“模型算”(软模型的学习或硬模型的计算)以及“脑子想”(有经验专家的先验知识融入),才能获得集自然条件与人文社会特性于一体的图斑功能属性,而也只有这类透视得到的语义信息才能进一步指导图斑依据空间上的相互依赖关系、连通性、排列组合以及功能上的相似性、互联性、依存性进行结构的重组。图斑作为一定地理空间尺度下各类资源、事件发生发展的最小载体,相互之间存在着千丝万缕的关联关系,只有在其功能属性的深入透视基础上才能建立有效的纵向转换及横向聚合模型,从而综合形成空间组团结构(即图3中第三层粒化得到的空间稳定构形,即本文所谓的地理场景),而这些结构化表达的综合体结构是由地理现象跨越到地理过程、地理格局研究的必要准备,将使得各类空间决策具备精细可靠的场景支撑。

在本文研究体系下,图斑功能模式的挖掘主要依赖于多粒度决策模型(图5)的上层实现,核心思路是依据图斑单元上自然环境与社会人文的空间相似性与异质性进行推测。图11展示了以农作物种植适宜性评价为应用的图斑功能模式挖掘过程:



注:以地块级种植适宜性评价制图为案例。

图11 地理图斑功能模式挖掘

Fig. 11 Functional pattern mining based on geo-parcels

首先,在图斑之上整合相对静态的多源空间数据(包括自然资源禀赋、生态环境本底在内的历史调查数据,以及路网、互联网POI语义标注等社会感知数据);其次,利用决策树、随机森林等机器学习技术<sup>[51]</sup>(基于软模型的间接推测)或专家模型(基于硬模型的直接推测)构建图斑功能属性的推理机,从而提炼条件属性与功能属性之间的关联关系;最后,据此进行空间推测获得农作物种植适宜性等级的专题信息<sup>[41]</sup>,这一功能属性将为地理场景(如高适宜片区、低适宜片区、不适宜片区等)的构建以及在场景之上的种植规划、优化调整、基地增设等空间决策提供科学依据。这是对图斑内动力支撑下的“状态”解构,同时也是后续图斑外动力驱动下进行“趋势”预测的重要基础。资源环境承载力、国土空间开发适宜性与优化、城市环境宜居性等面向不同应用出口的功能属性均可按此思路在图斑单元上开展挖掘而得到。

在本案例中,我们将国家糖料甘蔗种植综合标准化示范区——广西崇左市江州区作为试验区,开展了当地特色农作物——甘蔗的种植适宜性评价与规划制图。在全区耕地图斑提取基础上,结合种植区域的地形、地貌、气候、土壤、区位等条件属性数据,使用C5.0决策树算法提取了多元条件属性与种植适宜性等级之间的映射规则集,并在全区耕地

地块用之推测获得图斑级的甘蔗种植适宜性等级图(图12),这是对地块耕种甘蔗的适宜性“状态”(功能)进行的评价,十重交叉法验证得到该结果的评价准确率可达80.27%<sup>[41]</sup>。在此基础上,进一步面向政府、糖企、种植户制作了一系列图斑级的甘蔗专题图,形成了本案例的一套“知识图谱”,这些图谱成果可服务于当地甘蔗种植产业优化调整与后续规划的多项决策制定。比如,针对坡度较缓的大面积适宜种植连片区(对应于本文“地理场景”的概念)建议开展机械化种植作业;而将种植适宜性等级较高的集中连片区,作为未来规划新增“双高”(产量高、含糖量高)基地的目标靶区,这些功能模式的挖掘成果将是当地进一步实施空间功能分区、产业优化调整等规划决策的重要依据。

#### 4.5 图斑动力模式挖掘

图斑动力模式(结构—趋势)是对地理场景在一定条件下的内动力状态分析基础上,考虑如何进一步动态地融入反映外动力驱动的实时观测与社会感知信息,构建基于地理图斑及其综合体对自然与社会事件行为进行动态模拟的空间解析模型,实现内外动力耦合下对事件行为的发生过程及演化趋势的精准判断、跟踪、预测与决策,这对因人类活动而快速变化的地理格局动态监测以及机制分析

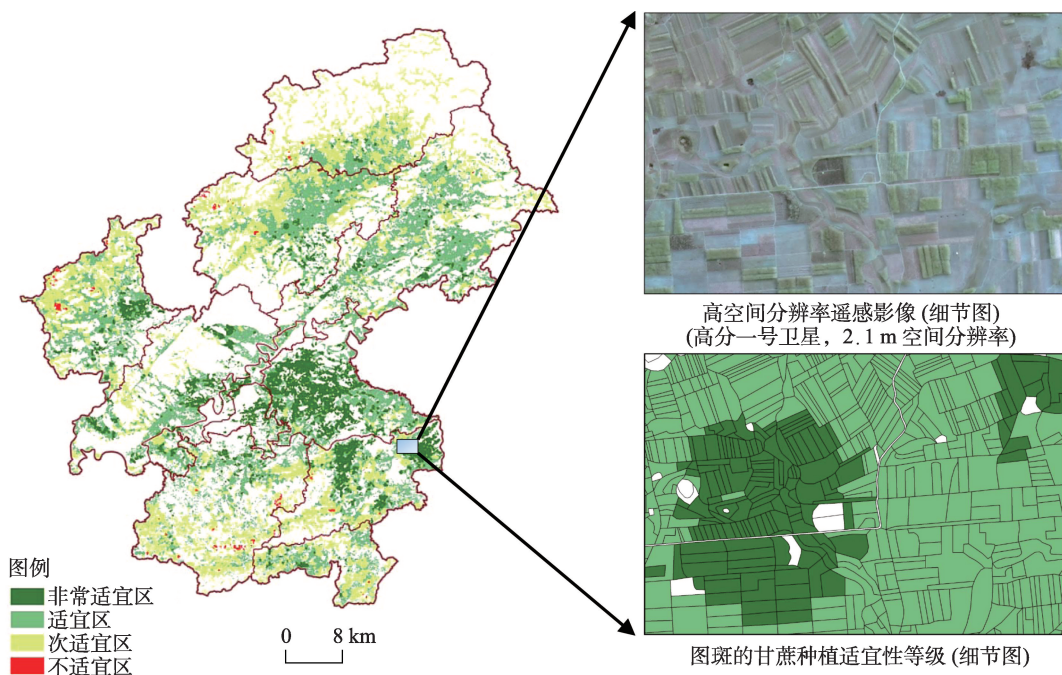


图12 广西崇左市江州区甘蔗种植适宜性评价试验结果

Fig.12 Experimental results of sugarcane planting suitability evaluation in Jiangzhou District of Chongzuo City, Guangxi



研究具有重要的支撑作用。

本文提出的图斑是精准(精细+定量)刻画地表状态的信息载体,因而各类静动态数据均可通过位置关联在其上汇聚,并产生物化反应;这一方面将反映固化图斑空间组团结构的内动力条件,另一方面也将导致图斑属性值的平稳/非平稳、周期/非周期的动态变化,进而导致图斑形态、类型、指标以及图斑综合体结构、状态的变化。因此,稳定的图斑结构依赖于图斑间相互作用形成的拓扑与网络关系,受益于地理实体存在于地表状态的内动力条件(具有相对静态性的图斑内部作用,比如重力、地质应力、互作用力、依存关系等);变化的图斑属性蕴含了驱动事件演化发生的外动力条件(具有相对动态性的图斑外部作用,比如光照、降水、环境污染、人类活动等)。

在本文研究体系下,图斑动力模式的挖掘主要依赖于多粒度决策模型(图5)的下层实现,核心思路是对内外动力作用下的图斑进行解析。图13展示了对此所做的设计:①将静态数据融入图斑构建结构化属性表,并依据图斑层次结构、相互作用、拓扑关系、空间密度等指标进行GIS空间分析,构建图斑组团后形成相对稳定的地理场景(内动力作用下的“结构”重组与“状态”解析),此环节通过上一节的功能模式挖掘已得到实现;②在此基础上,将各类动态数据与地理场景进行关联聚合,构成场景尺度的动态属性表,并进行不规则场景尺度下的分

布式解析计算,模拟其结构和状态的快速演变,这是外动力不断作用下导致场景结构不断调整、状态持续变化的过程(外动力作用下的“结构”调整与“状态”变化);③内外动力协同作用于地理场景,内外矛盾共同驱动场景更迭、事件发生(内外动力作用下的“趋势”预测)。因此,这是一个以非规则地理场景为基本单元的动力模式挖掘过程,具有模拟复杂系统时空演化过程的能力。作者在此仅做初步的讨论,尚未形成具体的应用案例分析。但我们认为这个模型的研究具有较大的潜在应用价值,下一步我们拟在较大的地理场景尺度上,针对气象过程模拟与精准预报(物理空间—气态)、基于不规则空间结构的分布式水文模型建构及水动力过程模拟(物理空间—液态)、滑坡/泥石流流灾害发生过程模拟及风险评估(物理空间—固态)、城市人流量空间分布的变化监测及事件发生预警(社会空间—事件)等应用方向开展探索。

## 5 结论与展望

针对传统遥感信息挖掘一直难以打通数据资源向信息知识转化链路的问题,本文在“分区—分层—分级”地理分析思想指导下提出了使用“地理图斑”的核心概念进行有序组织,并借鉴“粒化—重组—关联”的大数据计算思维,从“空间—时间—属性”协同的视角出发,发展了由“分区—分层—感知—时空协同反演—多粒度决策”3个基础模型构建而成的

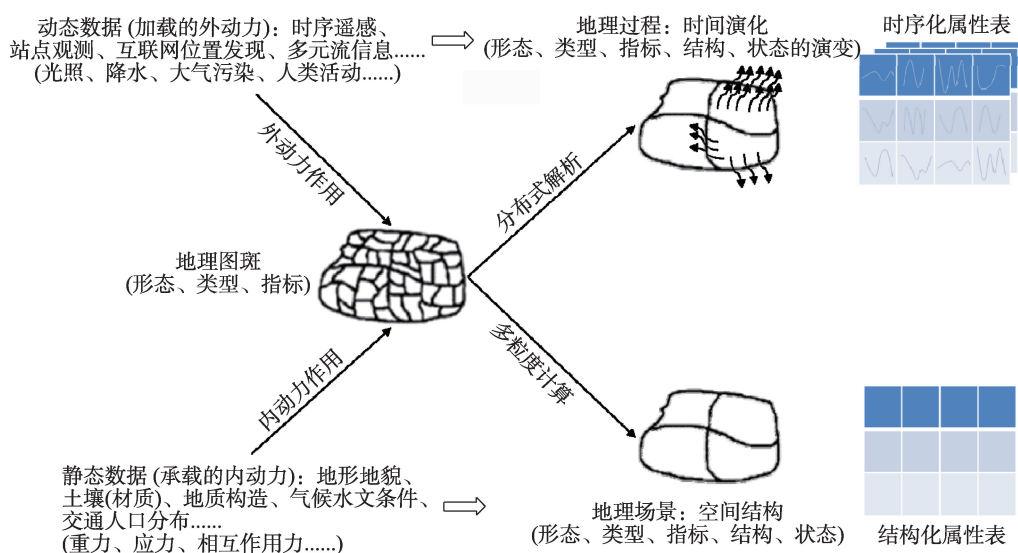


图13 地理图斑动力模式挖掘

Fig. 13 Dynamic pattern mining based on geo-parcels



地理图斑智能计算模型。整套模型是对人类“眼睛看—模型算—脑子想”智能系统的整体模拟,旨在以“地理图斑”为“空间粒”单元,通过从浅层理解到深层透视的循序渐进,逐步挖掘分布、生长、功能、动力等模式,最终实现对复杂地表现象、过程、格局的层层解构与逐级认知。若干农业应用案例的成功实践已初步验证了其可支撑精准应用所需的的空间信息生成,复杂地表的认知问题能得到一定程度上的近似求解。此外,结合我们前期探索工作和实验尝试,本文提出的这套地理图斑智能计算模型尚有以下3方面的问题值得进一步深入。

(1)对于分区分层感知模型,其泛化能力有待进一步增强。本文根据地形地貌的差异与耕地的特点将贵州省息烽县划分为平坝区、山地区和林草区,针对不同区块特征,借助先验知识采用5个不同的深度学习模型,得到了较好的图斑提取效果。但若将现在设计的分区分层感知模型拓展到更大尺度,比如省域尺度或者国家尺度,将形成更多更复杂的地理区块,这也就需要更多更复杂的先验知识融合后训练模型,现有模型的推广运用能力可能会受影响。能否采用较少的深度学习模型,而更多地利用定量模型分析参数与地理环境的关系,通过调节模型参数来适应不同的地理环境,从而使得模型在广域空间上的推广应用成为可能,这个从可解释性机理层面的切入点是值得在未来研究中探索的。

(2)对于时空协同反演模型,本文基于地理图斑开展了农作物分类的案例研究,通过结合多时相SAR数据与深度卷积网络DCN,在地块尺度上识别出了不同作物类型。事实上,可以进一步获取反映作物生长发育状态的指标信息,也就是在图斑类型识别基础上,通过对作物长势(NDVI、LAI等)、健康状况(CHI等)、水分条件(LSWI、NDWI等)、干旱胁迫(PDSI等)、病虫害、产量等信息开展挖掘,并与平均状态相比分析该年份的作物长势与产量处于何等水平,而这些丰富的定量指标信息对于精准农业具有更高的应用价值。

(3)对于多粒度决策模型,以下问题可以再深化:①在数据融合方面,针对多源多模态数据在图斑单元汇集融合时的质量控制、尺度转换、时序重建、点面同化、语义关联等问题,需根据每种数据来源及类型的差异,设计一套以图斑为基本对象的跨领域特征级信息融合模型集;②在“关联”分析方面,一方面要减少“粒化”、“重组”等前续环节的误差累积与传递,另一方面应由应用问题为导向构建

差异化的属性指标体系,同时需发展小数据、碎片化增量下的强化学习以及多步传递式的迁移学习;③在模式挖掘方面,要进一步深化动态流数据支持下的动力模式挖掘,开展诸如基于天气动力模式数据同化的精准气象预报、分布式水动力模型计算、协同时空流与互联网感知信息的社会经济行为预测等交叉研究;④在行业应用方面,可基于本文思路进一步拓展城乡土地资源精算与规划、社会经济数据空间化、灾害风险评价、国土空间双评价与优化等方面的创新应用,且在此过程中力争要增强对地观测数据与社会感知数据的协同来分析人地关系,强化多尺度认知格局与过程的耦合以及多功能景观单元的识别<sup>[52]</sup>。

#### 参考文献(References):

- [1] 宫鹏.对遥感科学应用的一点看法[J].遥感学报,2019,23(4):567-569. [Gong P. Towards more extensive and deeper application of remote sensing[J]. Journal of Remote Sensing, 2019,23(4):567-569. ]
- [2] 李德仁,张良培,夏桂松.遥感大数据自动分析与数据挖掘[J].测绘学报,2014,43(12):1211-1216. [Li D R, Zhang L P, Xia G S. Automatic analysis and mining of remote sensing big data[J]. Acta Geodaetica Et Cartographica Sinica, 2014,43(12):1211-1216. ]
- [3] 骆剑承,吴田军,李均力,等.遥感图谱认知[M].北京:科学出版社,2017. [Luo J C, Wu T J, Li J L, et al. Spatial-spectral cognition of remote sensing[M]. Beijing: Science Press, 2017. ]
- [4] Blaschke T. Object based image analysis for remote sensing[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2010,65(1):2-16.
- [5] 骆剑承,吴田军,夏列钢.遥感图谱认知理论与计算[J].地球信息科学学报,2016,18(5):578-589. [Luo J C, Wu T J, Xia L G. The theory and calculation of spatial-spectral cognition of remote Sensing[J]. Journal of Geo-information Science, 2016,18(5):578-589. ]
- [6] 李秦,高锡章,张涛,等.最优分割尺度下的多层次遥感地物分类实验分析[J].地球信息科学学报,2011,13(3):409-417. [Li Q, Gao X Z, Zhang T, et al. Optimal segmentation scale selection and evaluation for multi-layer image recognition and classification[J]. Journal of Geo-information Science, 2011,13(3):409-417. ]
- [7] 陶超,谭毅华,蔡华杰,等.面向对象的高分辨率遥感影像城区建筑物分级提取方法[J].测绘学报,2010,39(1):39-45. [Tao C, Tan Y H, Cai H J, et al. Object-oriented method of hierarchical urban building extraction from high-resolution remote-sensing imagery[J]. Acta Geodaetica Et

- Cartographica Sinica, 2010,39(1):39-45. ]
- [ 8 ] Blaschke T, Hay G J, Kelly M, et al. Geographic object-based image analysis-towards a new paradigm[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014,87(100):180-191.
- [ 9 ] 自然资源部.第三次全国国土调查实施方案[R]. 2018年18号文件,2018. [ Ministry of Natural Resources. Third national land survey implementation plan[R]. Document No.18 in 2018, 2018. ]
- [10] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015:3431-3440.
- [11] Zhang L P, Zhang L F, Du B. Deep learning for remote sensing data: A technical tutorial on the state of the art[J]. IEEE Geoscience and Remote Sensing Magazine, 2016,4(2):22-40.
- [12] Leordeanu M, Sukthankar R, Sminchisescu C. Generalized boundaries from multiple image interpretations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014,36(7):1312-1324.
- [13] Hwang J J, Liu T L. Pixel-wise deep learning for contour detection[C]. Proceedings of the International Conference on Learning Representation (ICLR), 2015.
- [14] Liu Y, Cheng M M, Hu X, et al. Richer convolutional features for edge detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017:3000-3009.
- [15] Deng Y, Manjunath B S. Unsupervised segmentation of color-texture regions in images and video[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001,23(8):800-810.
- [16] Cimpoi M, Maji S, Kokkinos I, et al. Deep filter banks for texture recognition, description, and segmentation[J]. International Journal of Computer Vision, 2016,118(1):65-94.
- [17] 李志刚,张小勇,艾廷华.土地利用图斑综合研究[J].地理空间信息,2004,2(3):13-18. [ Li Z G, Zhang X Y, Ai T H. Generalization research of land use patch[J]. Geospatial Information, 2004,2(3):13-18. ]
- [18] Yuan J. Learning building extraction in aerial scenes with convolutional networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017,40(11):2793-2798.
- [19] Prathap G, Afanasyev I. Deep learning approach for building detection in satellite multispectral imagery[C]. Proceedings of 9<sup>th</sup> IEEE International Conference on Intelligent Systems, 2018:1-5.
- [20] Liang S. Quantitative remote sensing of land surfaces[M]. Hoboken: John Wiley & Sons Inc., 2005.
- [21] Reed B C, Brown J F, VanderZee D, et al. Measuring phenological variability from satellite imagery[J]. Journal of vegetation science, 1994,5(5):703-714.
- [22] Diner D J, Beckert J C, Reilly T H, et al. Multi-angle Imaging SpectroRadiometer (MISR) instrument description and experiment overview[J]. IEEE Transactions on Geoscience and Remote Sensing, 1998,36(4):1072-1087.
- [23] 童庆禧,张兵,郑兰芬.高光谱遥感:原理,技术与应用[M]. 北京:高等教育出版社,2006. [ Tong Q X, Zhang B, Zhen L F. Hyperspectral remote sensing: Principle, technology and application[M]. Beijing: Higher Education Press, 2006. ]
- [24] Wu H, Li Z L. Scale issues in remote sensing: A review on analysis, processing and modeling[J]. Sensors, 2009,9(3):1768-1793.
- [25] Jeffrey S J, Carter J O, Moodie K B, et al. Using spatial interpolation to construct a comprehensive archive of Australian climate data[J]. Environmental Modelling & Software, 2001,16(4):309-330.
- [26] Heuvelink G B M, Brus D, Hengl T, et al. Uncertainty quantification of interpolated maps derived from observations with different accuracy levels[C]. Proceedings of Spatial Accuracy 2016 (12<sup>th</sup> Int. Symp. Spatial Accuracy Assessment Natural Resources Environmental Sciences), Montpellier, 2016,49-51.
- [27] Hengl T, Heuvelink G B M, Kempen B, et al. Mapping soil properties of Africa at 250 m resolution: Random forests significantly improve current predictions[J]. PLoS One, 2015,10(6):e0125814.
- [28] Wardrop N A, Jochem W C, Bird T J, et al. Spatially disaggregated population estimates in the absence of national population and housing census data[J]. Proceedings of the National Academy of Sciences, 2018,115(14):3529-3537.
- [29] 裴韬,刘亚溪,郭思慧,等.地理大数据挖掘的本质[J].地理学报,2019,74(3):586-598. [ Pei T, Liu Y X, Guo S H, et al. Principle of big geodata mining[J]. Acta Geographica Sinica, 2019,74(3):586-598. ]
- [30] 李德仁,王树良,史文中,等.论空间数据挖掘和知识发现[J].武汉大学学报·信息科学版,2001,26(6):491-499. [ Li D R, Wang S L, Shi W Z, et al. On spatial data mining and knowledge discovery[J]. Geomatics and Information Science of Wuhan University, 2001,26(6):491-499. ]
- [31] 李德仁,王树良,李德毅,等.论空间数据挖掘和知识发现的理论与方法[J].武汉大学学报·信息科学版,2002,27(3):221-233. [ Li D R, Wang S L, Li D Y, et al. Theories and technologies of spatial data mining and knowledge discovery[J]. Geomatics and Information Science of Wuhan University, 2002,27(3):221-233. ]

- [32] Huang C, Davis L S, Townshend J R G. An assessment of support vector machines for land cover classification[J]. *International Journal of Remote Sensing*, 2002, 23(4): 725-749.
- [33] Povinelli R J. Time series data mining: identifying temporal patterns for characterization and prediction of time series events[M]. Milwaukee: Marquette University, 1999.
- [34] 陈劲松, 黄健熙, 林琿, 等. 基于遥感信息和作物生长模型同化的水稻估产方法研究[J]. *中国科学: 信息科学*, 2010, S1(40): 173-183. [Chen J S, Huan J X, Lin H, et al. Rice yield estimation by assimilation remote sensing into crop growth model[J]. *Science China: Information Sciences*, 2010, S1(40): 173-183.]
- [35] Gao L J, Luo J C, Xia L G, et al. Topographic constrained land cover classification in mountain areas using fully convolutional network[J]. *International Journal of Remote Sensing*, 2019, 18(40): 7127-7152.
- [36] Wu T J, Ge Y, Wang J H, et al. A WTLS-based method for remote sensing imagery registration[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, 53(1): 102-116.
- [37] Wu W, Sun X, Wang X, et al. A long time series radiometric normalization method for Landsat images[J]. *Sensors*, 2018, 18(12): 4504.
- [38] Wu W, Luo J C, Hu X D, et al. A thin-cloud mask method for remote sensing images based on sparse dark pixel region detection[J]. *Remote Sensing*, 2018, 10(4): 617.
- [39] Karpatne A, Jiang Z, Vatsavai R R, et al. Monitoring land-cover changes: A machine-learning perspective[J]. *IEEE Geoscience and Remote Sensing Magazine*, 2016, 4(2): 8-21.
- [40] Yang Y P, Huang Q T, Wu W, et al. Geo-parcel based crop identification by integrating high spatial-temporal resolution imagery from multi-source satellite data[J]. *Remote Sensing*, 2017, 9(12): 1298.
- [41] Wu T J, Dong W, Luo J C, et al. Geo-parcel-based geographical thematic mapping using C5.0 decision tree: A case study of evaluating sugarcane planting suitability[J]. *Earth Science Informatics*, 2019, 12(1): 57-70.
- [42] Xie S N, Tu Z W. Holistically-nested edge detection[C]. *Proceedings of the IEEE International Conference on Computer Vision*, 2015: 1395-1403.
- [43] Zhou L C, Zhang C, Wu M. D-LinkNet: LinkNet with pre-trained encoder and dilated convolution for high resolution satellite imagery road extraction[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 182-186.
- [44] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. *Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2015: 234-241.
- [45] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 1-9.
- [46] Nowozin S. Optimal decisions from probabilistic models: the intersection-over-union case[C]. *Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2014: 548-555.
- [47] Zhou Y N, Luo J C, Li F, et al. Long-short-term-memory-based crop classification using high-resolution optical images and multi-temporal SAR data[J]. *GIScience & Remote Sensing*, 2019, 8(56): 1170-1191.
- [48] Chen S, Wang H, Xu F, et al. Target classification using the deep convolutional networks for SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 1-12.
- [49] Ndikumana E, Minh D H T, Baghdadi N, et al. Deep recurrent neural network for agricultural classification using multitemporal SAR sentinel-1 for Camargue, France [J]. *Remote Sensing*, 2018, 10(8): 1217.
- [50] Zhou Y N, Luo J C, Li F, et al. DCN-based spatial features for improving parcel-based crop classification using high-resolution optical images and multi-temporal SAR data[J]. *Remote Sensing*, 2019, 11(13): 1619.
- [51] Breiman L. Random forests[J]. *Machine Learning*, 2001, 45(1): 5-32.
- [52] 傅伯杰, 刘焱序. 系统认知土地资源的理论与方法[J]. *科学通报*, 2019, 64(21): 2172-2179. [Fu B J, Liu Y X. The theories and methods for systematically understanding land resource[J]. *Chinese Science Bulletin*, 2019, 64(21): 2172-2179.]