



武汉大学学报(信息科学版)

*Geomatics and Information Science of Wuhan University*

ISSN 1671-8860, CN 42-1676/TN

## 《武汉大学学报(信息科学版)》网络首发论文

题目: 数智耦合地学时空预测建模研究进展及展望  
作者: 许磊, 陈能成, 邓敏  
DOI: 10.13203/j.whugis20240483  
收稿日期: 2025-02-18  
网络首发日期: 2025-03-20  
引用格式: 许磊, 陈能成, 邓敏. 数智耦合地学时空预测建模研究进展及展望[J/OL]. 武汉大学学报(信息科学版). <https://doi.org/10.13203/j.whugis20240483>



**网络首发:** 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

**出版确认:** 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20240483

### 引用格式：

许磊, 陈能成, 邓敏. 数智耦合地学时空预测建模研究进展及展望[J]. 武汉大学学报(信息科学版), 2025, DOI:10.13203/J.whugis20240483 (XU Lei, CHEN Nengcheng, DENG Min. Research Progress and Prospects of Data-Knowledge Coupled Spatiotemporal Prediction Modeling in Geosciences[J]. Geomatics and Information Science of Wuhan University, 2025, DOI:10.13203/J.whugis20240483)

## 数智耦合地学时空预测建模研究进展及展望

许磊<sup>1</sup> 陈能成<sup>1</sup> 邓敏<sup>2</sup>

1 中国地质大学(武汉)国家地理信息系统工程技术研究中心, 湖北 武汉, 430074

2 中南大学地球科学与信息物理学院, 湖南 长沙, 410083

**摘要：**地学时空预测是地球系统科学的重要研究问题, 针对地学时空过程, 开展时空多尺度的未来演变预测。随着大数据、人工智能和地球科学的发展, 地学时空预测从模型驱动的研究范式发展为数据驱动, 进而发展为数据-知识联合驱动(数智耦合)的研究范式。本文首先回顾了地球系统科学时空预测模型的发展, 包括统计、物理、人工智能、数智耦合模型及其局限性, 其次阐述了数智耦合的基本概念、数智耦合框架、数智耦合关键技术, 进一步探讨了数智耦合时空预测建模目前面临的重要挑战, 包括数智耦合时空预测的逻辑深度、地学过程数智精准表征能力、数智耦合时空预测的专业壁垒, 最后展望了数智耦合时空预测的未来发展方向, 包括大模型时代的数智耦合、数智耦合时空预测的通用性和数智耦合时空预测的智能性, 为地球科学领域数智耦合时空预测范式的发展提供较为全面的认知思路。

**关键词：**数智耦合; 地球系统科学; 时空预测; 人工智能

## Research Progress and Prospects of Data-Knowledge Coupled Spatiotemporal Prediction Modeling in Geosciences

XU Lei<sup>1</sup> CHEN Nengcheng<sup>1</sup> DENG Min<sup>2</sup>

1 National Engineering Research Center for Geographic Information System, China University of Geosciences (Wuhan), Wuhan 430074, China

2 School of Geosciences and Info-Physics, Central South University, Changsha 410083, China

**Abstract: Objectives:** Spatiotemporal prediction plays a crucial role in Earth system science, focusing on forecasting the multiscale future evolution of geospatial processes. With the development of big data, artificial intelligence (AI),

收稿日期: 2025-02-18

基金项目: 国家自然科学基金(42201509), 湖北省自然科学基金(2023AFB563)。

第一作者: 许磊, 博士, 副教授, 研究方向为时空预测。xulei10@cug.edu.cn

通信作者: 陈能成, 博士, 教授。chennengcheng@cug.edu.cn

and Earth science, spatiotemporal prediction has transitioned from a model-driven approach to a data-driven paradigm and, ultimately, to a data-knowledge coupled paradigm. This paper reviews the development of spatiotemporal prediction models, including statistical, physical, AI, and data-knowledge coupled models, while analyzing their limitations and challenges. This paper aims to review current progress of data-knowledge coupled spatiotemporal prediction modeling in geosciences, highlight the important challenges and provide insights on future development. **Methods:** This paper provides a systematic review of the evolution of spatiotemporal prediction models in Earth system science, with particular emphasis on the transition from statistical, physical, and AI-based models to data-knowledge coupled models. The paper further elaborates on the basic concepts, theoretical framework, and key technologies involved in data-knowledge coupling. **Results:** (1) This article proposes a four-in-one data-knowledge coupled spatiotemporal prediction framework of "data empowerment, knowledge guidance, joint drive, and intelligent computing solutions". (2) The review identifies the limitations of traditional spatiotemporal prediction models and emphasizes the advantages of data-knowledge coupled models that integrate both data-driven and knowledge-driven approaches. Key challenges in this field include the logical depth of data-knowledge coupling, the accurate representation of geoscientific processes, and overcoming professional barriers in spatiotemporal prediction modeling. (3) This paper highlights three promising development directions of spatiotemporal prediction in geosciences, including the data-knowledge coupling in the era of large models, the universality of data-knowledge coupled spatiotemporal prediction models, the intelligence of data-knowledge coupled spatiotemporal prediction models. **Conclusions:** Data-knowledge coupled spatiotemporal prediction models offer significant potential for advancing Earth sciences by enhancing prediction accuracy, interpretability, and robustness. In the future, the development of data-knowledge coupled geoscience spatiotemporal prediction will be more versatile and intelligent, with self-learning, self-evolution, self-adaptation, and self-generation capabilities, forming a highly intelligent prediction system that will demonstrate excellent adaptability and versatility in multiple fields, tasks, and scenarios.

**Key words:** Data-knowledge coupling, Earth system science, Spatiotemporal prediction, Artificial intelligence

地学时空预测问题是指基于地学时空数据，针对地学时空过程未来时刻的时空演变规律进行估计<sup>[1]</sup>。随着大数据、人工智能以及计算技术的发展，时空预测理论方法已经广泛应用于地球科学领域。例如，华为盘古气象大模型基于人工智能技术，能在 10 秒内完成全球 7 天气象要素预报，计算速度是传统数值方法的 1 万倍以上，提高了欧洲中长期天气预报中心的预报时效约 0.6 天，热带气旋路径预报误差降低 25%<sup>[2]</sup>。谷歌研发团队基于长短期记忆网络和数值预报，提出了全球河流洪水预测模型，能提前 7 天对无站点观测流域的小规模和极端洪水事件做出预测，精度优于世界上先进的洪水预测系统 GloFAS<sup>[3]</sup>。与传

统时间序列预测相比，地学时空预测需要对地学过程的时空依赖性、时空异质性、时空复杂性、时空交互性等特征进行建模，具有多尺度、异质性、区域性等特点<sup>[4]</sup>。目前，地学时空预测从模型驱动的研究范式发展为数据驱动，进而发展为数据-知识联合驱动（数智耦合）的研究范式。相比于模型驱动和数据驱动的地学时空预测范式，数智耦合的地学时空预测将数据驱动和模型驱动进行有机融合，侧重提升时空预测模型的泛化能力、可解释性和可靠性。

随着大数据、大模型、云计算等理论技术的发展，地学时空预测理论方法在地球科学领域取得了快速发展，但是高精度、高可靠、可解释的

地学时空预测仍面临巨大挑战。例如,传统数值天气预报和基于数据驱动的机器学习模型依然不能精准预测台风杜苏芮的时空路径,Google 流感预测模型 GFT 也未能准确预警非季节性流感。数据不确定性、模型不完善性、时空过程复杂性等问题制约着时空预测的精准性、可靠性和可信性<sup>[1]</sup>。数智耦合时空预测从数据和知识耦合的角度出发,融合数据驱动和知识驱动的优势,能够部分地解决上述问题,提升地学时空预测的可信可靠程度。近几年来,数智耦合的地学时空预测理论方法取得了初步的进展,在可解释性、耦合方式、预测效率、预测精度等方面开展了较多研究,实现了数智耦合时空预测在地学不同领域的科学尝试。例如,清华大学等研究团队通过融合数据驱动和物理机制,基于连续方程设计神经演变算子,并构建对流尺度生成网络,提出了 NowcastNet 极端降水临近预报大模型,将极端降水临近预报的时效延长至 3 小时<sup>[5]</sup>。虽然数智耦合的地学时空预测理论方法得到了较快发展,但是在耦合逻辑深度、精准表征能力、专业领域壁垒等方面依然存在较大挑战,阻碍了数智耦合地学时空预测的可推广性、可靠性、可实现性和智能性,需要进一步研究和发展。

本文将首先回顾地学时空预测模型的演进历程,并阐明现有模型所面临的难题与挑战;接着,着重阐述数智耦合地学时空预测建模研究进展,分析数智耦合地学时空预测的研究框架和关键技术;随后,从耦合逻辑深度、精准表征能力、专业领域壁垒三个方面,探讨数智耦合时空预测面临的重要挑战;最后,围绕大模型时代的数智耦合、数智耦合时空预测的不确定性和数智耦合时空预测的智能性,展望数智耦合地学时空预测未来的发展方向。

## 1 地学时空预测模型发展

在地学时空预测场景中,需要对预测的目标变量和影响因素之间的时空依赖关系进行建模。现有的时空依赖关系建模方法可分为四类(图 1):时空统计、人工智能、物理模型以及数智耦合。时空统计基于统计理论,例如地理加权回归(GWR)<sup>[6]</sup>、时空自回归积分移动平均(ST-ARIMA)<sup>[7]</sup>、时空克里金法(ST-kriging)<sup>[8]</sup>和贝叶斯最大熵(BME)<sup>[9]</sup>。机器学习和深度学习等新兴人工智能方法可以从数据驱动的角度对时空依赖关系进行建模<sup>[10,11]</sup>。与传统统计模型相比,人工智能模型在天气预报、交通预测、视频预测、能源估计等方面表现出色<sup>[12-14]</sup>。物理模型基于物理机制,能够合理解释预测结果,尽管当前物理模型的预测精度可能不如统计机器学习模型<sup>[13, 15, 16]</sup>。数智耦合模型则通过将人工智能与物理模型结合起来,融合它们各自的优势,提高模拟和预测精度<sup>[17,18]</sup>。例如,人工智能模型可用于细化物理模型中的参数化过程,从而可以改进正向模拟<sup>[19,20]</sup>。尽管人工智能模型的可解释性因其黑箱结构而被削弱,但研究人员正尝试用物理解释来揭示人工智能模型的内部层次<sup>[21,22]</sup>,以构建一个可理解的人工智能预测器。这四类模型在地学时空预测问题中都得到了广泛的应用。

时空统计理论和方法已广泛应用于各种学科的探索性时空数据分析和预测<sup>[23,24]</sup>。基于时空统计的地学时空预测方法以数据为驱动,依靠有限的样本来代表总体,未来预测是使用历史样本和统计方法构建的。经典的随机时间序列建模和地统计方法经过扩展能够考虑时空依赖性,例如时空自回归综合移动平均<sup>[25]</sup>、地理加权回归<sup>[26]</sup>、时空克里金<sup>[27]</sup>以及贝叶斯最大熵方法。时空统计学有坚实的统计理论基础,可以从统计学角度得到很好的解释。虽然时空统计学中的预测是由数据驱动的方法做出的,但该方法结构是基本不变的,可以在统计理论上进行解释。时空统计方法

可以模拟平稳和非平稳、线性和非线性、单变量和多变量时空过程。然而，现实世界的地学时空过程可能是高度非线性、非高斯、随机、易变和异构的，时空统计模型可能难以从海量高维数据

集中提取非线性高级特征和复杂规则<sup>[18,28]</sup>，并且从历史数据中学习到的关系可能不适用于新的数据和场景预测（分布外泛化问题）。

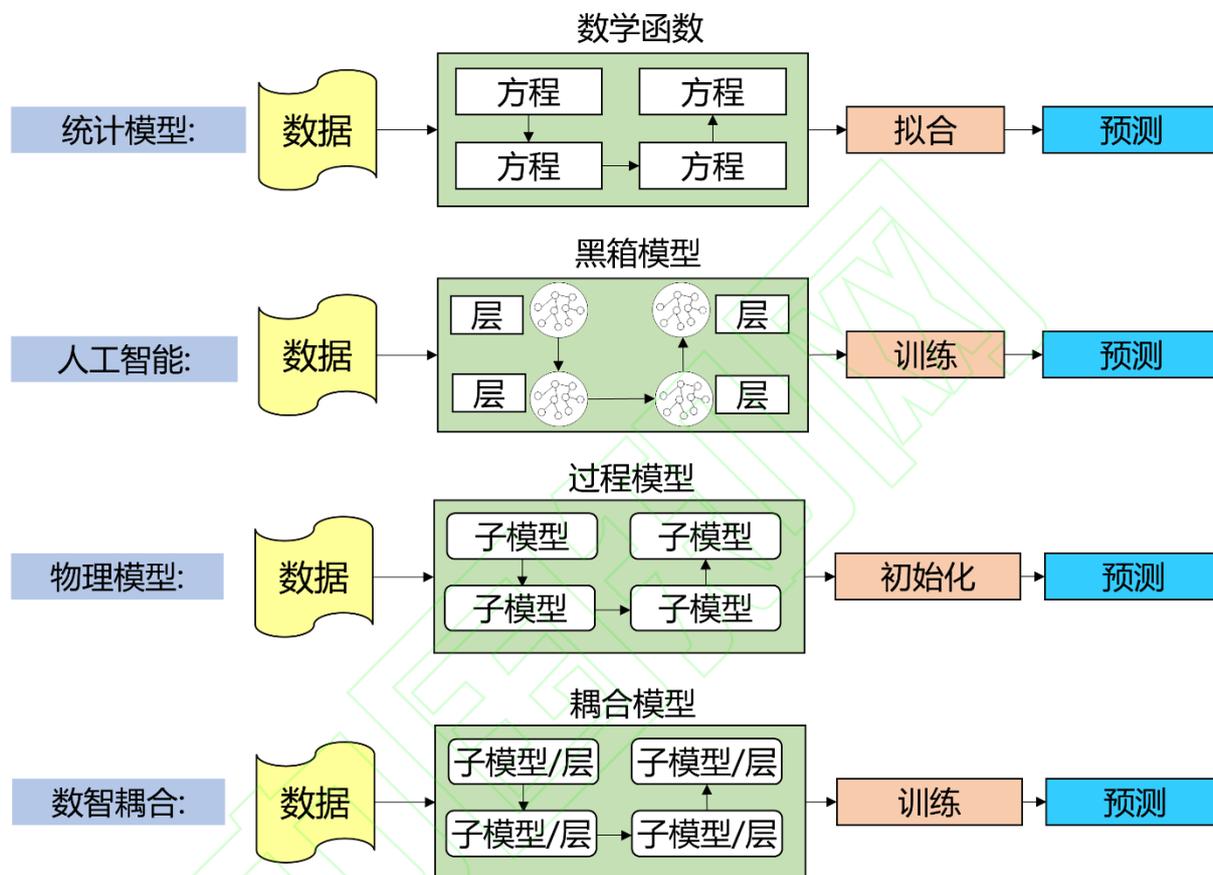


图 1 地学时空预测方法中的统计、人工智能、物理和数智耦合模型的概念性表示

Fig. 1 Conceptual Representation of Statistical, AI, Physical and Data-Knowledge Coupled Models in Geospatial Spatiotemporal Prediction Methods

人工智能是一种强大的数据驱动工具，可用于各种应用中的数据分析、挖掘和预测。近年来，随着计算科学、数学、统计学和许多相关领域的理论和技术进步，以机器学习和深度学习为代表的人工智能方法广泛应用于地学时空预测场景中<sup>[29-31]</sup>。机器学习和深度学习通过使用给定的数据集训练模型并对未知的系统状态做出预测，能够使用复杂的多层模型结构从数据集中提取高级特征，在许多实际问题中展现出良好的潜力<sup>[32-34]</sup>。

常见的机器学习预测算法包括支持向量机（SVM）<sup>[35]</sup>、随机森林（RF）<sup>[36]</sup>和人工神经网络（ANN）。深度学习通过构建深度复杂模型结构来学习高维非线性特征，进而开展地学时空预测<sup>[11,37]</sup>。常见的深度学习时空预测网络包括卷积神经网络（CNN）、卷积长短期记忆模型（ConvLSTM）、图卷积神经网络（GCN）、视觉Transformer模型等。同时，以深度学习为代表的大模型技术广泛应用于地学时空预测建模中，如盘古天气大模型<sup>[2]</sup>、伏羲大模型<sup>[38]</sup>、空天灵眸遥

感大模型<sup>[39]</sup>、OpenCity 城市时空预测大模型<sup>[40]</sup>、NowcastNet 极端降水预报大模型、多光谱遥感大模型 SpectralGPT<sup>[41]</sup>、GraphCast 天气预报大模型<sup>[42]</sup>等。基于人工智能的地学时空预测模型能够处理大规模、多源、复杂的地学时空数据，相比传统物理模型，人工智能模型可以更快地处理和预测时空数据，具有数据驱动的高效性；以深度学习为代表的人工智能模型（如 LSTM、Transformer、GNN 等）能够捕捉地学数据中的非线性和复杂关系，具有较高的预测精度；人工智能模型可以通过训练数据自动学习地学规律，减少人为干预，具有较高的自动化与适应性；通过迁移学习和模拟数据增强，人工智能模型可以在数据稀缺区域进行预测。同时，人工智能时空预测模型也存在一些不足。人工智能模型高度依赖高质量的训练数据，在数据不足或数据误差的情况下预测能力不足；人工智能模型的“黑箱”特性难以解释预测结果，无法提供预测背后的物理机制；大型深度学习模型通常需要高性能计算资源，训练和部署成本高；当训练数据不足或偏差过大时，人工智能模型可能过拟合或缺乏泛化能力，在极端事件预测中表现可能不稳定。

数据驱动和知识驱动的时空预测方法各有优势。数据驱动的时空预测模型在非线性特征提取、高维建模、计算推理效率等方面具有优势，但是可解释性较低，模型的泛化能力不足，在新数据新场景中的预测能力不足<sup>[43, 44]</sup>。知识驱动的预测模型具有较强的物理机制，跨领域迁移能力强，可解释性较高，但是存在模型构建复杂性高、灵活性受限、复杂场景泛化能力不足以及计算需求较高等问题。通过融合数据驱动和知识驱动的预测模型，构建数智耦合的地学时空预测模型，能够提升数据驱动时空预测模型的可解释性和可信度，使得预测过程和结果更遵循物理原理，提升模型的泛化能力和鲁棒性。现有数据驱动的地学

时空预测方法通过嵌入物理定律、定义物理算子、融合物理预测、添加物理约束等方式，嵌入了物理先验知识，在一定程度上提升了地学时空预测模型的精度和可解释性。例如在 NowcastNet 极端降水临近预报大模型中<sup>[5]</sup>，基于连续方程设计神经演变算子，并构建对流尺度生成网络，添加了降水运动过程的物理约束，预测效果优于目前先进的数据驱动或物理模型的方法。

由于大数据、人工智能、高性能计算等技术的发展，地学时空预测模型在预测能力、模型耦合、可解释性、计算效率等方面取得了一些进展。然而，现有地学时空预测模型依然存在一定的局限性：

(1) 数据-知识的相互作用关系不清晰。针对具体的时空预测任务，缺乏对预测任务与数据-知识在时空预测建模过程中的双向作用关系的定量剖析，难以回答数据-知识是否可用以及如何相互作用的问题。

(2) 数据-知识的耦合建模能力不足。数据-知识在地学时空预测模型中耦合不深入。主流预测模型的构建过程没有协同数据与知识的驱动作用，导致预测结果的精确性和可解释性难以有效兼顾。

(3) 地学时空预测模型的泛化性较低。时空预测模型在不同任务间适用性不强，缺乏对预测模型在不同任务之间自适应泛化能力的研究，难以保证预测性能于不同区域/时相/尺度应用中的稳健性。

(4) 地学时空预测的不确定性。在时空预测模型中，数据-知识的不确定性难以量化，无法在时空预测过程中有效估计数据不确定性和知识不确定性对预测结果的不确定性影响。

(5) 地学时空预测模型的智能性。现有地学时空预测模型智能化能力不足，自学习、自进化、自适应、自生成能力有待提升。

## 2 数智耦合地学时空预测建模研究进展

地学时空预测经历了从物理模型驱动的理论科学范式到数据驱动的数据科学范式，随着数据驱动与知识驱动研究范式的交叉融合，数智耦合的地学时空预测研究成为可能。本节将归纳总结数智耦合地学时空预测的基本概念、理论框架和关键技术，阐述数智耦合地学时空预测建模的研究进展。

### 2.1 数智耦合地学时空预测的基本概念

数智耦合地学时空预测中的“数”，这里指的是数据驱动，即以数据为驱动力，通过数据来拟合模型结构和参数来开展时空预测。地学时空预测使用的数据为时空数据，即具有时间和空间属性的数据。在大气、陆地、海洋、生物、社会、经济和人文等现象中，数据具有不同的地理空间分布，并且数据随着时间而变化，可以认为是时空数据<sup>[45, 46]</sup>。时空数据的类型有很多，包括图像、视频、社交媒体数据、轨迹数据、社会经济数据、地图数据、定位数据等等。面向地理时空过程，基于地理时空数据，开展时空过程在未来时刻的时空演变规律预测，可以理解为地学时空预测。在数据驱动的地学时空预测建模中，基于时空数据、统计或人工智能方法以及预测任务信息，构建时空预测模型，通过数据来拟合模型参数，而不是通过物理经验模型知识。在数据驱动模型中，不需要关注地学时空过程的中间物理机制，直接通过数据学习模型参数的值开展预测，得到的预测结果不具有物理可解释性，但是预测精度相对较高<sup>[18]</sup>。

数智耦合地学时空预测中的“智”，这里指的是知识驱动。知识的定义因学科和视角的不同而有所不同。例如，柏拉图在《泰阿泰德篇》中对知识提出了“有真理的信念”定义，是知识哲学的经典起点<sup>[47]</sup>。知识也是经验的积累和系统

化，现代认知科学的观点常常将知识看作是通过感知、思考和实践而积累的有用信息，是人类通过实践和经验所获得的对事物、现象、规律等方面的认识、理解和掌握。在地球科学中，知识一般是通过对数据的分析、建模和解释得来的。地球科学中的知识可以分为显式知识和隐性知识。显式知识是可以明确表达和书面化的知识，可以通过文献、数据、公式、图表等形式传递，具有清晰的结构和体系，通常是经过验证和普遍接受的科学理论或事实，如物理定律、地理定律、水文模型。隐性知识是难以用语言或文献明确表达的知识，通常通过实践经验、直觉、技能、判断等方式获得，往往依赖于个人经验和感知。在地球科学中，知识驱动的地学时空预测以地学领域的先验知识、物理模型和理论为核心，强调模型的解释性和科学性，通常建立在确定性规律的基础上，对数据依赖较低，但可能无法很好地适应复杂、非线性的地学现象。

数智耦合的地学时空预测则是通过融合数据驱动和知识驱动，核心是将地学领域的显性知识（如物理规律、理论模型）与隐性知识（从数据中学习的复杂模式）结合，以“数”+“智”的方式实现高精度、可靠性、可解释的地学时空预测。相比于知识驱动模型，数智耦合的地学时空预测模型能够利用数据驱动模块捕捉非线性特征，以及知识驱动模块提供合理约束，两者结合显著提升预测性能<sup>[18, 48-50]</sup>。同时，知识约束使模型在数据不足或质量较差时仍能保持稳定表现，增强了模型的鲁棒性。在可解释性方面，数据-知识联合驱动的数智耦合模型通过嵌入领域知识，使预测结果更易被领域专家理解。数智耦合的地学时空预测范式具有跨领域适用性，适用于地学中广泛的时空问题，包括气象、地质、生态和水文等领域。例如，通过在模型中引入水分平衡原理、理查德方程和土壤水边界条件作为约束条件，构建

新的损失函数来引导深度学习模型的训练过程，使得模型性能显著提高并在较长预测周期内仍能保持较高精度<sup>[51]</sup>。大气-陆地-海洋耦合模式中的降雨-径流中复杂的物理模型可以用神经网络来替代，从而自适应不同地理环境和气候条件改进径流预测结果<sup>[52]</sup>。使用物理模型生成径流模拟数据计算残差误差，再利用时空预测模型进行预测，在保留物理模型物理约束的同时提高了径流预测的准确性<sup>[53]</sup>。

## 2.2 数智耦合地学时空预测框架

本文提出“数据赋能、知识指导、联合驱动、智算求解”四位一体的数智耦合时空预测框架，如图2所示。



图2 数智耦合地学时空预测框架

Fig. 2 Data-Knowledge Coupled Geospatial Spatio-temporal Prediction Framework

(1) 数据赋能：地学时空预测的基础驱动力。数据赋能是指通过高质量、多维度的数据为地学时空预测提供动力支撑，利用先进的技术手段挖掘数据背后的内在规律与复杂模式，从而提升模型的精准性、稳定性和科学性。数据赋能作为数智耦合框架的重要组成部分，奠定了预测模型的输入基础，是实现复杂地学问题求解的关键

环节。数据赋能的核心是充分发挥数据在建模与预测中的潜能，包括数据获取、数据处理、特征提取和分析建模。在数据获取阶段，需要收集针对时空预测任务的多源数据。在数据处理阶段，需要对原始数据进行清洗、融合、插值与降噪。在特征提取上，需要从数据中提取关键时空特征，为模型构建提供有效的输入变量。在分析建模阶段，利用机器学习和统计分析方法，发现数据中的模式、趋势和潜在规律。数据赋能的优势包括：高维数据支持、强大的模式识别能力和灵活适配性，支持多维度、多尺度和多模态数据的全面分析，能够利用机器学习技术从数据中发现潜在规律和复杂关联，能够快速适应不同领域与任务的需求。

(2) 知识指导：地学时空预测中的理论与经验支持

知识指导是指在地学时空预测过程中，通过引入领域知识、物理规律、理论模型和专家经验等，来指导数据驱动方法的建模与预测过程，提升模型的科学性、解释性和准确性<sup>[18, 48]</sup>。它为预测过程提供了理论框架和实际约束，使得预测结果不仅符合数据中的模式，也能够与已知的地学规律相一致。知识指导是数据赋能之外的重要组成部分，尤其在处理复杂的地学系统时，起到了极其关键的作用。知识指导的核心在于如何利用现有的地学理论、物理法则和专家经验，为数据驱动模型提供科学依据。这里的知识包括显性知识、隐性知识、先验知识等。知识指导的来源众多，包括物理和数学模型（如流体力学方程），专家知识与经验（如领域专家规则）、地学规律和启示（空间自相关性）等。在应用时，通过引入物理约束、领域专家知识嵌入、知识驱动的特征选择与构建、先验知识与数据结合等方式，实现知识指导<sup>[18, 48, 49, 54, 55]</sup>。通过知识指导，可以增强模型解释性，将理论和规律引入模型，增加了

模型预测结果的物理合理性和解释性；提高预测准确性，利用现有的知识约束，减少了预测误差和不确定性；弥补数据不足，在数据稀缺的情况下，知识指导提供了理论上的支持，确保模型的稳定性；增强跨领域适用性，在多个地学领域中，知识指导都能够为模型提供坚实的理论支撑。总之，知识指导在地学时空预测中扮演着至关重要的角色，它为模型提供了科学的理论框架、准确的边界条件和领域专家的经验，增强了模型的解释性、稳定性和准确性。

(3) 联合驱动：地学时空预测中的数据与知识融合

联合驱动是指将数据驱动和知识驱动两种模式结合，通过协同作用实现更为准确、全面和可靠的地学时空预测。在地学时空预测的实际应用中，数据和知识往往不是独立运作的，而是互为补充、互为支持。数据提供了海量的信息和模式识别能力，而知识则为数据提供了理解、约束和指导的框架，联合驱动的核心目标是通过两者的协同提升预测精度、可解释性和鲁棒性。通过联合驱动，数据与知识的优势可以得到有效的整合，使得模型既能从数据中发现隐藏的模式，又能遵循科学理论和规律，避免单纯数据驱动模型可能出现的过拟合或不可解释问题<sup>[18, 48-50]</sup>。联合驱动的核心在于如何设计有效的融合架构，以便将数据驱动的学习过程与知识驱动的推理机制相结合。常见的耦合模型包括：基于物理约束的学习模型、结合知识图谱的学习模型以及混合模型。例如通过嵌入领域知识来引导机器学习过程，或者将物理定律作为约束条件对深度学习模型的输出进行约束，以及利用知识图谱对预测进行推理与优化。通过联合驱动，地学时空预测模型能够：1) 提高预测精度，数据驱动可以通过对大规模数据的分析发现潜在的规律，而知识驱动确保这些规律符合地学规律，从而提升预测结果的准确性；2) 增

强可解释性：数据驱动模型往往缺乏可解释性，而知识驱动方法提供了科学理论的支持，使得模型输出更加可理解和透明；3) 提升鲁棒性：通过联合驱动，系统能够更好地应对数据不完备、噪声干扰等问题，提升预测的稳定性和可靠性；4) 避免过拟合：数据驱动模型容易在数据稀缺时发生过拟合，而知识驱动方法通过理论约束，有助于防止模型对噪声的过度学习。

(4) 智算求解：地学时空预测中的智能计算方法

智算求解指的是结合先进的计算技术、智能算法和人工智能方法，对数智耦合模型进行高效的求解和决策。在地学时空预测中，智算求解不仅依赖于数据和知识的集成，还依赖于高性能计算、并行计算、分布式计算等技术，以应对大规模、多维度和复杂的地学问题。通过智能化的计算框架，能够加速预测过程，提升预测的精度，并为复杂的地学系统提供优化解。智算求解的关键在于通过智能计算的方法，结合深度学习、强化学习、优化算法等多种智能算法，解决复杂的地学时空预测问题。在智算求解中，依托大规模计算平台和云计算资源，支持大数据分析和复杂模型的训练、优化和推理，通过智能算法（如深度学习、演化算法、强化学习等）对复杂的地学时空数据进行建模和预测，可以采用并行计算和分布式计算框架，在处理大规模数据时，能够显著加速计算过程，优化求解效率。同时，可以开展多层次优化，通过优化算法，进行多目标、多约束的优化求解，寻找最优的地学时空预测方案或决策支持策略。基于智算求解，可以实现高效计算，通过高性能计算平台和智能算法，能够处理大规模地学数据，提供实时、精确的预测；可以增强预测精度，通过复杂的模式识别和非线性建模，提升地学时空预测的精度；可以优化决策支持，通过优化算法，能够为地学领域的复杂决

策提供最优解。智算求解通过结合先进的计算资源与智能算法，能够应对地学时空预测中的大规模数据处理、模型训练和优化问题，推动地学领域的智能化、自动化进程。

### 2.3 数智耦合时空预测关键技术

数智耦合时空预测技术的核心在于融合数据驱动与知识驱动的优势，通过多源数据表征、知识表达建模、深度耦合机制与高性能计算支撑，实现高精度、可解释且鲁棒的预测。本节系统阐述四大关键技术的核心内涵、技术路径与研究进展（图3）。

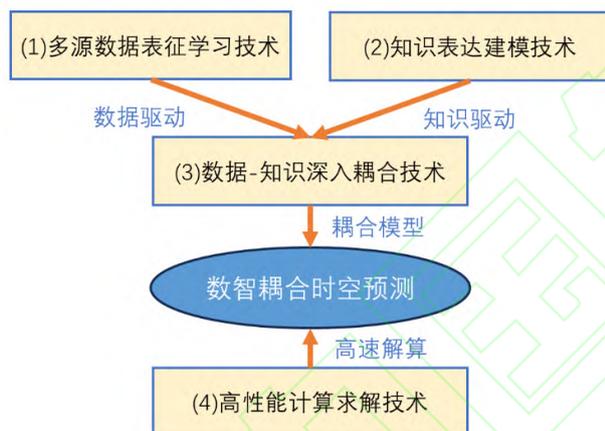


图3 数智耦合时空预测关键技术

Fig. 3 Key Technologies of Data-Knowledge Coupled Geospatial Spatiotemporal Prediction

#### (1) 多源数据表征学习技术

多源数据表征学习技术旨在从多模态、多尺度的地学时空数据（如遥感影像、气象观测、社会经济数据等）中提取统一、高效的时空特征表示，其核心作用是通过整合异构数据源、挖掘深层特征与优化数据表示，解决数据异质性、冗余性和噪声问题，从而增强模型对复杂时空模式的学习能力，为后续预测提供高质量输入。该技术体系包含数据融合、特征提取与异构数据处理三个核心环节，共同支撑地学时空预测的精度与泛

化性提升。

数据融合是多源数据表征学习的首要步骤，通过整合不同来源、格式与尺度的数据，构建统一输入框架。例如，谷歌的全球河流洪水预测模型通过融合降雨量、地形高程与土壤湿度数据，构建全局时空网格特征，显著提升预测精度<sup>[3]</sup>；华为盘古气象大模型采用跨模态注意力机制，自适应对齐卫星遥感与地面观测数据的语义特征<sup>[2]</sup>。特征提取聚焦于从原始数据中自动挖掘高价值特征，减少冗余信息干扰。卷积神经网络<sup>[56]</sup>（CNN）擅长提取遥感影像的空间分布模式，如地表覆盖类型与地形起伏特征，长短期记忆网络<sup>[57]</sup>（LSTM）捕捉气象数据的时间依赖性，例如温度序列的周期性变化与极端事件的时间演化规律，图神经网络<sup>[58]</sup>（GNN）则建模城市交通网络的拓扑关联性，通过节点嵌入与图传播机制解析区域间的动态交互。自监督学习（Self-Supervised Learning）进一步扩展无标签数据的表征能力<sup>[59]</sup>，例如通过构建正负样本对的对比学习框架，从海量未标注遥感数据中学习通用特征，提升模型对复杂场景的适应性。异构数据处理针对结构化与非结构化数据的融合挑战，通过张量分解与嵌入技术实现跨模态对齐<sup>[60]</sup>。张量分解（如CP分解与Tucker分解）将多维时空数据（如传感器时间序列）降维至低秩表示，保留核心时空信息的同时减少计算复杂度。嵌入向量化技术（如BERT扩展模型）将文本报告、社交媒体数据映射为连续向量，与图像特征在统一语义空间中关联。例如，OpenCity城市时空预测大模型通过融合交通流文本描述与视频数据，实现跨模态特征互补，增强对城市交通拥堵动态的建模能力<sup>[40]</sup>。此外，多模态变分自编码器通过生成式模型学习多源数据的联合分布，有效整合遥感影像与气象观测的跨模态特征<sup>[61]</sup>。

#### (2) 知识表达建模技术

知识表达建模技术是地学研究中至关重要的领域，其核心目标是通过整合结构化的领域知识（诸如物理定律、专家经验等）以及隐性规律（例如数据驱动模式），构建出能够被计算机计算和处理的知識表示形式，为地学模型提供科学严谨的约束条件和清晰逻辑的指导方向。这一技术在提升预测的可解释性、物理合理性以及在数据稀缺场景下的鲁棒性方面发挥着关键作用，主要涵盖了显式知识嵌入、隐性知识提取和知识结构化表示三大类别，具体内容如下：

显式知识嵌入是将领域知识以精确的数学形式融入模型架构的关键手段，其主要目的是强制模型严格遵循物理规律或逻辑规则，从而确保模型预测结果的准确性和可靠性。例如，在流体动力学模拟领域，Navier-Stokes 方程作为描述流体运动的基本方程，通过将其转化为微分算子的形式嵌入到神经网络中，为模型的预测过程设定了明确的物理约束边界，有效地限制了模型的输出范围和变化趋势，使得模型能够更加准确地模拟流体的流动特性<sup>[48]</sup>；在土壤湿度预测研究中，理查德方程作为描述土壤水分运动的经典方程，被巧妙地编码为损失函数的一部分，作为物理约束条件，对模型的预测结果进行严格限制，确保模型能够真实地反映土壤水分的运移规律，为土壤湿度的准确预测提供了坚实的理论基础<sup>[51]</sup>。隐性知识提取是从海量数据中自动发现潜在规律的核心技术，对于完善地学模型的知识体系具有不可忽视的重要意义。这一过程通常借助于先进的数据分析方法和算法，如因果推理方法。通过因果推理，可以深入挖掘数据中变量之间的因果关系，为模型的构建和优化提供关键的支持信息。以气象因子对洪灾的影响路径为例，通过运用因果推理方法，可以精确地识别出不同气象因子（如降雨量、降雨强度、降雨持续时间等）与洪灾发生之间的内在因果联系<sup>[62]</sup>。知识结构化表示主要依

靠知识图谱来构建规则库，从而为模型的推理过程提供明确的指导方向。知识图谱以图形化的方式直观地展示了知识实体之间的复杂关系，通过图神经网络或向量嵌入等先进技术，实现了对知识的动态推理和高效计算。例如，港口交通流量预测模型通过知识图谱整合船舶轨迹、潮汐规律与经济数据，实现多维度决策支持<sup>[63]</sup>。

### （3）数据-知识深入耦合技术

数据-知识深入耦合技术通过动态交互机制融合数据驱动与知识驱动的优势，解决单向依赖与冲突问题，提升模型在复杂场景下的精度与适应性，其核心作用在于实现数据模式挖掘与知识逻辑推理的协同优化，能充分发挥数据的丰富信息和知识的先验经验，确保所得到的解决方案兼具物理合理性与数据适应性。

动态权重分配技术是实现数据与知识有效融合的重要手段。它通过灵活调整数据与知识在模型中的贡献比例，使模型能根据不同情况和需求，充分利用两者的优势。该技术采用贝叶斯优化框架或强化学习机制来实现权重的动态调整，贝叶斯优化框架通过对数据和知识的概率模型进行优化来确定最佳权重分配，强化学习机制则通过与环境交互学习最优权重策略。例如，在气象预测中，初始阶段依赖物理模型（如 WRF）生成大气流场，数据充足后切换至 LSTM 拟合残差路径偏差可以有效预测误差<sup>[31]</sup>。双向反馈机制是实现数据与知识互惠优化的关键。它通过数据驱动的结果反哺知识库，同时利用知识修正数据噪声，不断提升数据和知识的质量和准确性。例如，在水文预测中，基于质量守恒定律的异常数据清洗算法，在洪水模拟中剔除不符合流量平衡的传感器异常值，提升数据质量<sup>[53]</sup>。混合架构设计通过分层耦合物理与数据驱动模块，实现了知识约束与数据学习的深度融合。底层基于物理方程生成中间变量，如大气压强场、土壤湿度分布等，为模

型提供坚实物理基础；顶层通过深度学习算法拟合残差或优化细节，提高模型预测精度。例如，在洪水模拟中，生成对抗网络（GAN）的生成器输出符合 Navier-Stokes 方程的流场分布，然后利用判别器确保虚拟场景与历史灾情数据的空间一致性<sup>[19]</sup>。

#### （4）高性能计算求解技术

高性能计算求解技术通过并行架构、分布式计算与智能算法优化等手段，加速数智耦合模型的训练与推理，应对地学时空预测中海量数据与复杂计算的挑战，其核心作用在于确保模型在大规模、实时场景下的可用性与效率，为高精度预测提供工程化支撑。并行计算框架是高性能计算的重要基石，它主要依托数据并行与模型并行两大策略，充分释放多核处理器与各类加速硬件的强大算力。如在地震波传播模拟中，基于 MPI（Message Passing Interface）的分布式计算将三维地质模型分割为多个子域，各节点并行求解弹性波动方程，大幅提升计算效率<sup>[64]</sup>。云端 - 边缘协同架构则是适应现代地学数据处理需求的创新性架构。它有机结合了云计算强大的计算能力与边缘设备的实时响应特性，实现了实时响应与全局优化之间的良好平衡。如在气象领域采用联邦学习（Federated Learning）框架，各气象站本地训练模型并加密上传梯度参数，云端聚合后下发全局模型，既保护数据隐私又提升模型泛化能力<sup>[65]</sup>。智能算法优化是高性能计算求解技术的另一关键组成部分，主要通过模型压缩、增量学习等先进手段来降低计算资源的消耗。模型压缩技术，如 TensorRT 的 INT8 量化，能够将模型中的浮点参数转换为低精度格式，在几乎不影响模型预测精度的前提下，大幅减少模型的体积，进而显著提升模型的推理速度，使其能够在资源有限的设备上快速运行<sup>[66]</sup>；增量学习则为模型的动态更新提供了高效解决方案。以基于在线序列极限学

习机（OS-ELM）的地表形变预测模型为例，该模型在面对新的观测数据时，仅需利用这些新数据对网络权重进行微调，而无需对整个模型进行全量重训练，极大地节省了计算时间和资源，确保模型能够及时反映地表形变的最新变化趋势，为地质灾害监测与预警提供了更为高效的技术手段<sup>[67]</sup>。

### 3 数智耦合地学时空预测面临的重要挑战

数智耦合地学时空预测在理论、模型和技术方面取得了一些进展，然而仍然面临着一些挑战（图4）。本节从数智耦合时空预测的逻辑深度、地学时空过程数智精准表征能力、数智耦合时空预测的专业壁垒三个方面进行阐述，分析当前数智耦合时空预测面临的重要问题和可能的解决方案。

#### 3.1 数智耦合时空预测的逻辑深度

##### （1）数据-知识耦合逻辑的理论深度不足

数智耦合缺乏统一的理论框架。当前的数据-知识耦合多以“经验融合”为主，例如将知识作为数据驱动模型的正则化约束<sup>[51]</sup>，或利用数据优化传统知识模型的参数<sup>[18]</sup>。这种方式缺乏整体性的理论指导，导致模型的适用范围和预测效果具有不确定性。数智耦合的逻辑关系相对模糊，数据驱动与知识驱动在不同阶段的作用缺乏明确的逻辑描述，例如何时优先依赖数据，何时引入知识约束。现有方法主要关注“知识指导数据”或“数据校正知识”中的单向耦合，而忽视了两者在动态变化下的双向交互。双向耦合的逻辑缺失，限制了模型在复杂情景中的应用能力。数据与知识的动态分配机制不足。在实际应用中，数据与知识的重要性可能随时间、空间、任务目标而变化。然而，现有耦合逻辑缺乏灵活性，难以动态

调整数据与知识的相对贡献。因此，需要建立统一的数智耦合理论框架，统一描述数据驱动与知识驱动的耦合逻辑，明确两者的角色与交互关系；

基于贝叶斯理论、优化理论、因果理论等，建立数据-知识的数学耦合机制；构建多层次的数智耦合逻辑，如浅层耦合、深层耦合、动态耦合等等。

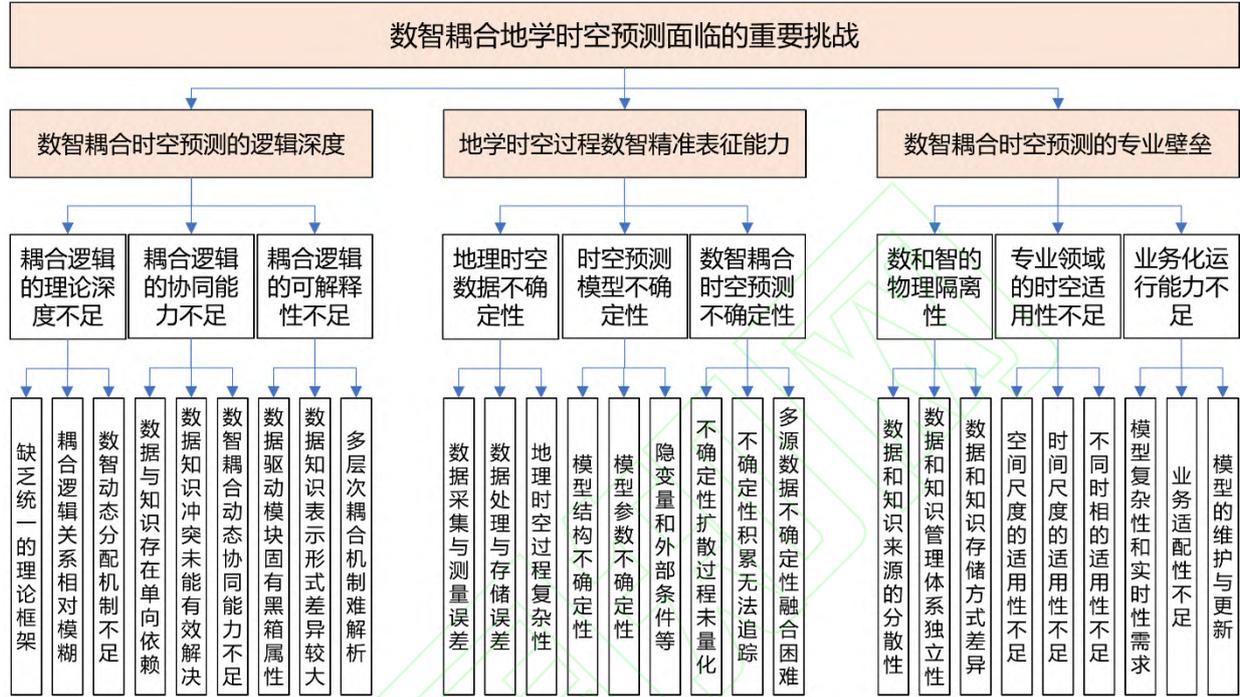


图 4 数智耦合地学时空预测面临的重要挑战

Fig. 4. Major Challenges in Data-Knowledge Coupled Spatiotemporal Prediction in Geosciences

(2) 数据-知识耦合逻辑的协同能力不足

当前数智耦合方法往往以单向模式为主，数据与知识之间存在单向依赖。在数据驱动主导情况下，知识仅作为约束条件嵌入数据驱动模型，作用有限，难以在预测中发挥指导作用。在知识驱动主导情况下，数据仅用于优化知识模型的参数，忽略数据中潜在的复杂模式。这种单向依赖导致模型在复杂环境下难以平衡两者的优劣。数据与知识冲突未能有效解决，如数据中包含噪声或偏差，与领域知识的规律不符。领域知识在复杂情境下可能失效，无法准确匹配数据模式<sup>[68]</sup>。当前耦合方法缺乏冲突处理机制，导致预测模型在数据质量下降或知识适用性不足时表现不稳定。数智耦合的动态协同能力不足。数据与知识的权

重应随情境动态变化，在数据稀缺时，知识应占主导地位；在数据充足时，应优先挖掘数据中的模式。然而，现有方法通常采用固定的融合方式，难以动态调整两者的贡献比例。数智耦合的多层次协同能力不足<sup>[18, 48]</sup>，数据与知识的协同多停留在浅层，如参数优化或结果校正，未能实现深层次的协作：如知识引导模型结构设计；数据驱动模型主动发现并修正知识中的不足。因此，需要建立统一的数智耦合表达框架，实现数据与知识的无缝对接，如利用知识图谱将知识结构化<sup>[55, 69]</sup>，与数据中的模式建立映射关系，或者通过向量化方法将知识表示为嵌入，与数据特征向量在统一空间中融合；引入动态权重机制，基于贝叶斯优化和自适应学习思想<sup>[70]</sup>，根据情境动态调整数据与知识的贡献比例；建立数据与知识的双向交互

机制,实现数据与知识之间的反馈循环,如利用数据挖掘发现知识中的盲区或不足,迭代更新领域知识;或者利用知识优化数据驱动模型的结构设计,例如引入物理约束的神经网络。在冲突处理与融合方面,引入置信度评估和多模态优化,构建数据与知识冲突的解决机制,通过算法自动评估数据与知识的可信度,权衡冲突中的优先级,在冲突场景中引入多目标优化算法,寻求数据与知识的最佳融合。数据-知识协同能力的提升,能够显著提高模型的预测精度和鲁棒性,尤其是在数据稀缺或场景复杂时。同时,通过协同增强,数智耦合时空预测模型可以动态适应情境变化,为地学领域提供智能化、实时化的决策支持。

### (3) 数据-知识耦合逻辑的可解释性不足

数智耦合的地学时空预测模型依然存在可解释性问题。首先,数据驱动模块具有固有的黑箱属性<sup>[18]</sup>,耦合逻辑如何在数据模式与知识约束之间分配权重或优化模型,缺乏清晰的解释;再者,数据与知识的表示形式差异较大,数据多为高维向量、时间序列或图像形式,知识常为规则、逻辑公式或微分方程,缺乏统一的表示方法,导致融合后难以解释两者的协作机制;另外,数智耦合模型通常涉及多层次、多阶段的耦合机制,数据模式与知识规则的交互复杂,深度学习模型中高维参数与知识约束的关系难以解析;最后,当前研究多偏向提升预测精度,往往通过复杂网络或高维优化实现,而解释性设计未被优先考虑,缺乏机制分析工具用于解读耦合模型的内部运作。在可解释性提升方面,可以从以下几个方面来考虑:1)基于知识图谱和因果网络<sup>[55,71]</sup>,构建统一的表达方法,将数据和知识映射到统一的语义空间,便于分析两者的协作机制;2)基于模块化设计和物理约束网络,提高模型结构的透明性,在融合模型设计中注重结构的可解释性<sup>[2]</sup>;3)引入解释性算法,如可视化方法、反事实推理、特征

归因分析等方法,分析数智耦合时空预测模型的运行机制<sup>[72]</sup>;4)构建可解释的动态权重机制,在模型中加入解释性动态权重分配,明确在何种场景下知识的权重增大或减小,通过数学形式表达权重变化的依据(如贝叶斯推断<sup>[70]</sup>或强化学习);5)加强耦合过程的理论化,理论上明晰数据与知识的融合逻辑,如使用概率图模型或数学优化方法,显式描述数据与知识交互的动态过程。

## 3.2 地学时空过程数智精准表征能力

### (1) 地理时空数据不确定性

地理时空数据不确定性是指地理和时空数据在采集、处理、分析和应用过程中,由于多种内外部因素而产生的误差、模糊性或未知性,这种不确定性可能影响模型的预测结果。由于采集与测量误差、数据处理与存储误差、自然现象复杂性、模型和算法局限性等原因,地理时空数据存在不确定性<sup>[73]</sup>。在时空数据质量方面,可以通过缺失数据填补、多源数据融合、数据质量评估等方法,减小数据不确定性,提升数据质量<sup>[74,75]</sup>。在不确定性表征方法上,可以通过统计方法、模糊集理论、概率分布建模、深度学习方法来建模数据不确定性。在统计方法上,通过误差传播分析,量化数据处理过程中的误差累积,评估数据的不确定性;或者基于置信区间分析,为预测结果提供上下限范围,量化其可信程度。在模糊集理论方面,通过表征不确定性和模糊性的程度,来表示复杂地学现象的不确定性。概率分布建模是表征数据不确定性常用的方法,利用贝叶斯推断或蒙特卡洛模拟,生成预测结果的概率分布<sup>[76,77]</sup>。在深度学习方法中,通过贝叶斯神经网络,将参数表示为概率分布,提高模型对数据不确定性的感知能力。另外,通过深度概率模型,如变分自动编码器(VAE)和生成对抗网络(GAN)表征复杂数据中的模糊性。

### (2) 时空预测模型不确定性

模型不确定性指的是模型在预测过程中由于自身结构、参数、算法或外部条件等因素导致结果偏差或模糊性的现象，模型不确定性是影响预测可靠性和结果可信度的重要问题<sup>[73,78]</sup>。模型不确定性来源主要包括：模型结构不确定性、参数不确定性、隐变量和外部条件等原因。在模型不确定性表征方法上，可以通过概率分布方法、集成学习、深度学习等方法来建模<sup>[79,80]</sup>。在概率分布方法方面，通过贝叶斯推断，将模型参数表示为概率分布，预测结果附带置信区间，或者基于统计方法计算预测结果的不确定性范围和置信区间估计。在集成学习方法方面，通过随机森林、XGBoost 等算法集成多棵决策树，通过模型集成减少单一模型的不确定性<sup>[17]</sup>，或者使用深度集成模型，如多神经网络集成，通过不同架构模型的综合表决量化不确定性。在深度学习中，可以使用贝叶斯深度学习算法对深度神经网络参数进行分布式建模，生成预测分布。另外，可以基于蒙特卡洛 Dropout 的方式，在测试阶段随机丢弃部分神经元，通过多次采样量化模型的不确定性<sup>[80]</sup>。

### (3) 数智耦合时空预测不确定性

数据（随机）和模型（认知）不确定性是预测不确定性的主要影响因素<sup>[73,78,81]</sup>。在时空预测过程中，由于数据本身、嵌入的知识和时空传播特性的相互作用，导致不确定性未能充分量化和追踪，尤其是在复杂的地理时空过程中，时空不确定性传播的动态过程难以精确刻画。时空数据和知识的相互作用增加了预测模型的复杂性和挑战，特别是在面对动态变化和不完全知识时，传播不确定性难以估计。数智耦合时空预测不确定性主要体现在以下几个方面：①不确定性扩散过程未量化：在时空预测模型中，数据和知识的不确定性常常没有得到有效的传播建模。模型通常局限于对单一时空点的预测，未能考虑到从一个点或区域到另一个点的时空不确定性传播。②不

确定性积累无法追踪，数据和知识的不确定性随着时间的推移可能逐渐积累，特别是在动态系统中，如气候变化或灾害预测。然而，大部分模型未能有效跟踪和量化这种不确定性积累的过程，导致长期预测的精度较低。③多源数据不确定性融合困难：在多源数据（如遥感、气象、地质数据等）和领域知识的融合过程中，不同数据源和知识的不同不确定性会影响最终结果。然而，如何有效融合这些不确定性，尤其在时空传播的背景下，仍缺乏有效的量化方法。

针对数智耦合不确定性时空传播问题，可以从几个方面来开展建模：①强化时空传播模型：引入时空随机过程，如马尔科夫过程和时空高斯过程，来模拟不确定性如何随时间和空间传播。通过将不确定性看作随机变量，研究其随时间和空间传播的规律。②不确定性传播路径建模，设计不确定性传播路径，模拟从一个时空点的不确定性向邻近时空点的传播过程。此过程可以通过图论、网络分析等技术来量化时空传播效应。或者引入时空系统中的反馈机制，帮助揭示如何通过不同变量的互动和依赖关系，导致不确定性的积累和传播。③融合多源不确定性，如使用贝叶斯方法来融合不同数据源的时空不确定性，在模型中结合不同源的不确定性分布，进行不确定性加权平均。或者通过集成学习结合不同模型的预测结果和不确定性，在时空模型中减小单一模型对不确定性传播的影响<sup>[17]</sup>。④动态知识嵌入：结合实时数据更新领域知识库，根据实时观测结果调整和优化知识的推理过程。或者使用因果推理方法（如结构方程模型或因果图）来更清晰地揭示数据和知识之间的因果关系，从而更好地理解不确定性是如何传播和积累的<sup>[62,82]</sup>。

在不确定性时空传播方法上，可以使用蒙特卡洛模拟对时空预测的不确定性进行量化，估算预测结果的分布，尤其适用于处理复杂的时空依

赖关系<sup>[76,77]</sup>。另外,在大规模时空数据集上,基于贝叶斯推理框架,使用变分推理方法来近似计算不确定性传播。同时,可以开展多层次不确定性分析,分析数据、模型和知识层次的不同不确定性来源,通过分层级量化和跟踪不确定性传播。最后,要充分发挥领域知识的协同作用,在模型中嵌入领域专家的知识,并通过知识推理机制处理不确定性,改进模型的推理能力;结合深度学习与传统领域知识,提出联合推理算法,使模型能够适应不确定性变化并持续优化。

### 3.3 数智耦合时空预测的专业壁垒

(1) “数”和“智”在专业领域的物理隔离性

在时空预测中,传统的“数”通过构建模型、海量分析数据来进行预测,依赖于特定场景下的数据。“智”则是基于已知的科学理论方法通过适普性的定律和公式进行推导,或特定场景下积累的专业知识、技能和经验,一般不受数据的限制。在实际应用中,“数”和“智”通常是分离的。数据科学家专注于数据收集、模型训练,而物理学家、工程师关注于科学理论的建立和验证,这就导致了“数”和“智”在专业领域的物理隔离性,如何在实际的时空预测问题中,将数据驱动的方法与基于科学规律的知识进行有效结合,以获得更具普适性、可扩展性的预测模型。

“数”和“智”的物理隔离性还体现在部门之间的协作障碍。在许多跨领域应用中,对使用数据的收集、分析和应用通常跨越多个部门。这些数据的管理、分析和应用往往由不同的团队或者部门进行,这些团队和部门有各自的工作流程,缺乏统一的沟通和协作。这种分散性增加了数据共享和整合的难度,还使得各个部门之间的工作成果难以融合。同时,许多时空预测任务涉及多个学科和专业领域的知识,这要求在数智耦合时

空预测任务中,各领域的专家能够共同参与并协调工作。然而传统的学科壁垒使得不同领域的专家在实际工作中难以进行有效的沟通和合作。数据科学家和物理学家的思维方式、工作方法存在较大差异,导致了他们在合作时常常产生偏差。

因此,解决物理隔离性是数智耦合时空预测中的重要问题。从不同领域、不同部门的分散性和孤立性,到跨学科知识融合困难,这些因素限制了数智耦合时空预测模型的使用和推广。要克服这些障碍,需要加强跨部门和跨学科的协作,统一技术标准和平台,推动不同领域知识的融合与创新,从而使得数据驱动的方法和科学理论能够有效结合,提升数智耦合时空预测模型的准确性、普适性和可扩展性。

(2) 数智耦合时空预测模型在专业领域的时空适用性不足

数智耦合时空预测模型在实际应用中,面临的第二个问题是在不同区域/时相、时间/尺度上的时空适用性不足。时空预测模型依赖于特定区域的时空数据,这使得模型在跨区域、跨时相或者在不同时间尺度下的表现不好。融合了数据驱动与科学理论的时空预测模型,在面对不同区域或时相的应用时,往往需要采用不同的数据和知识方法。这种时空适用性不足的问题,根源在于模型对于时空变化的泛化能力不足,尤其是在区域异质性和时间变化性较大的情境下,模型的预测效果容易受到限制。

地理区域差异是影响时空预测模型性能的关键因素。不同区域的环境、气候、社会、经济等因素存在的显著差异,会导致同一预测模型在不同区域的应用效果有很大差别<sup>[83]</sup>。例如在气候预测领域,某些模型可能在特定的气候带中表现优异,但将模型应用到气候条件迥异的区域时,预测的准确度往往会显著降低<sup>[84]</sup>。这是因为许多时空预测模型,尤其是那些基于数据驱动模型,

过于依赖于训练数据集的区域特征，如果训练数据主要来源于某一特定区域，那么模型对其他区域的预测能力就会受到影响。

数智耦合时空预测模型在不同时间尺度上的适用性不足也是一个重要问题。时间尺度差异对长时间序列预测模型的影响十分显著。例如，在交通流量预测中，短期内的交通流量波动可能受到实时事件的影响，而长期的交通流量变化则可能与城市发展、人口迁移等宏观因素密切相关<sup>[85-87]</sup>。数据驱动的预测模型往往依赖于历史数据来进行训练，不同时间尺度下的数据特性差异较大，模型往往很难同时在短期和长期尺度上都有出色的表现。

数智耦合时空预测模型在不同时相上的适用性不足，也是限制其广泛应用的一个原因。在许多实际应用中，时空预测模型往往需要考虑某一特定时相下的预测效果，然而，不同的时相可能会面临完全不同的环境条件和预测需求。例如，在气候变化预测中，模型需要在不同季节、不同气候条件下进行预测，不同的时相会涉及到不同的变量和系统动态，因此，模型的时空适应性必须能够解决这些多变的条件。

因此，需要①增强数智耦合时空预测模型的时空尺度适配性，通过采用多尺度建模技术，根据不同领域的时空尺度需求，设计不同分辨率的模型子系统。例如，气候模型可能需要长时间尺度的预测，而交通流模型则需实时响应。通过层次化或多尺度模型<sup>[38]</sup>，可以使模型在不同的时间、空间尺度下都具备适用性。另外，通过采用自适应建模技术，根据数据的时空特征动态调整模型参数或结构。比如，在实时交通流预测中，根据流量数据的变化，调整模型的时间窗和空间范围。②提升数据和知识融合能力，将多源数据与领域知识有机结合，利用机器学习、深度学习和知识图谱等技术，优化模型的知识表达和推理能力<sup>[49]</sup>。

<sup>55, 69]</sup>。通过引入领域知识，可以弥补数据不足或缺失的部分，提高模型的准确性和时空适用性。

③开展专业领域特性与模型的定制化，针对不同专业领域，设计量身定制的时空预测模型。例如，在气象领域中可以结合气象物理学与数据驱动模型<sup>[2, 5, 38]</sup>，在交通领域中可以结合流量预测与行为模式识别。通过领域特定的优化，增强模型在特定任务下的时空适用性。④采用动态模型与实时更新策略，在一些快速变化的专业领域（如灾害预警），模型需要具备实时更新和动态适应的能力。通过集成学习和在线学习方法，使模型能够根据最新的数据和知识快速调整预测结果，提高时空适用性。

(3)数智耦合时空预测模型的业务化运行能力不足

数智耦合时空预测模型的业务化运行能力不足是实际应用中面临的一个问题，要将模型有效地部署到业务场景中，仍然存在许多问题。这些问题既包括技术上的局限性，也涉及业务需求与模型能力之间的脱节。数智耦合时空预测模型在业务化运行过程中面临模型复杂性、实时性需求、业务适配性、数据质量保障、模型维护与更新等多方面的问题。

数智耦合时空预测模型的复杂性直接影响了其业务化运行的能力。数智耦合时空预测模型往往具有复杂的架构和庞大的参数规模。这些复杂模型在实验室环境中可以通过高性能计算资源运行，但在实际业务环境中，计算资源通常有限，模型的部署和推理效率会受到严重影响。其次，实时性和响应速度是业务化运行中的核心需求。在许多业务场景中，预测模型需要能够快速处理数据并生成结果，例如交通流量预测、灾害预警等场景，实时性直接决定了预测的价值。然而，由于数智耦合模型不仅需要同时处理大量的时空数据，还需要结合物理规律进行复杂计算，导致

其推理过程可能耗时较长。此外，业务适配性不足也是影响数智耦合模型业务化运行能力的关键因素之一。业务需求通常具有高度的多样性和动态性，数智耦合时空预测模型在设计时往往采用特定的模型架构和知识结合，针对特定的应用场景和目标，缺乏灵活性。需求的多样性对模型提出了定制化和灵活化的要求。模型的维护与更新也是业务化运行中的重要挑战，业务环境的动态变化要求预测模型能够不断适应新的数据和条件，这就需要模型具备高效的更新能力。然而，数智耦合模型的更新涉及到模型参数的重新训练甚至结构的调整，这需要大量时间，同时也增加了业务运维的复杂性。

因此，需要①进一步提高数智耦合时空预测系统集成性与适配性，将数智耦合模型设计为可模块化的系统，便于与现有业务流程和技术架构进行集成。通过设计可扩展的 API 接口、插件等方式，实现与现有系统的无缝衔接，降低系统集成的难度。开展数智耦合时空预测系统的自动化部署与运维，采用自动化部署和持续集成（CI/CD）工具，简化模型的部署过程。通过自动化监控和运维管理，确保模型能够稳定运行并及时调整。②加强数智耦合时空预测模型的实时性与计算效率，采用云计算平台来处理大规模数据和高复杂度的计算任务，同时利用边缘计算实现实时预测和快速响应。通过分布式计算架构，提升模型的计算效率和响应速度。采用更高效的算法和计算框架（如并行计算、GPU 加速等）来优化模型的计算性能，减少对计算资源的需求，提高模型的实时性。③进一步增强模型的可解释性与决策支持能力，采用可解释的人工智能技术<sup>[72-88]</sup>，如 LIME、SHAP 等，增强模型的透明性和可解释性，使决策者能够理解模型的预测结果及其

依据，从而提升对模型的信任和依赖。开发具有交互性和反馈机制的决策支持系统，让业务人员能够根据预测结果调整决策，并实时反馈调整模型的输入和参数，使模型更加适应实际业务需求。

④引入数据治理和质量控制机制，确保输入数据的准确性和一致性。此外，利用数据清洗和增强技术，弥补数据缺失和不一致问题。采用流式数据处理技术，建立实时数据传输和处理管道，以确保模型可以及时获取并处理最新的数据。⑤强化业务理解与场景定制化，开展领域知识嵌入，在模型中嵌入行业特定的知识和规则，使其能够更好地适应特定业务场景的需求，提升模型在特定领域的精度和适用性。设计灵活的模型结构，能够根据不同的业务场景需求，快速调整模型参数和预测逻辑，从而提高其在多种业务环境中的适应性。

#### 4 数智耦合地学时空预测研究展望

目前，数智耦合地学时空预测研究仍存在不足，例如大模型时代的数智耦合相对较弱，数智耦合时空预测模型的通用性不足，数智耦合时空预测模型智能性较低。在大模型时代，很多大模型主要是数据驱动的，如何赋予大模型‘智’仍是一个挑战。其次，数智耦合时空预测的通用性尚有巨大提升空间，当前的模型往往需要针对不同应用领域进行大量的定制化调整，缺乏足够的跨领域适应性。最后，数智耦合时空预测的智能性尚有不足，在自学习、自进化、自适应、自生成能力方面亟待提升。因此，未来研究需进一步解决这些问题，推动数智耦合时空预测模型的深入发展（图 5）。

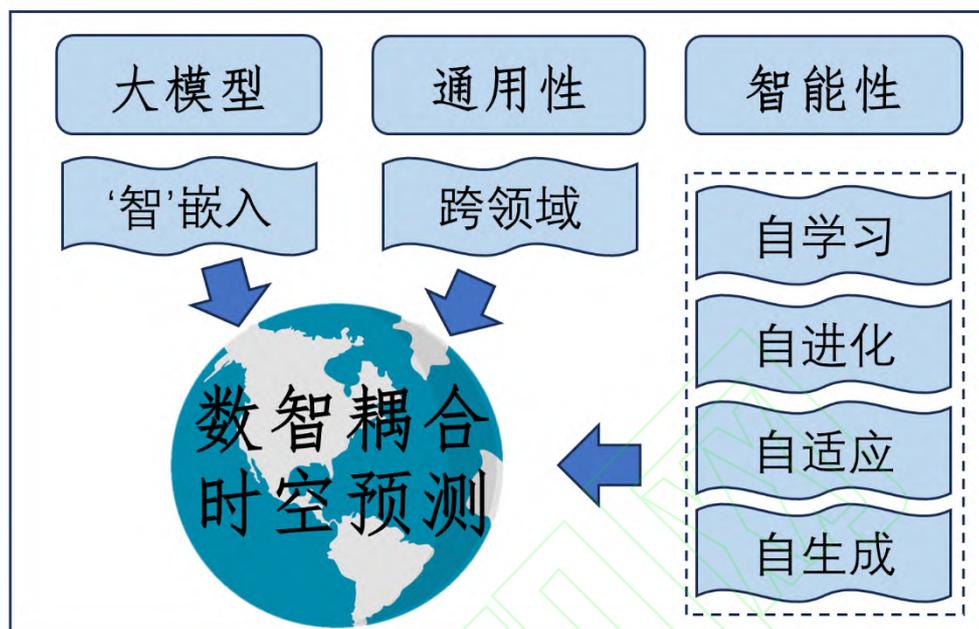


图 5. 数智耦合地学时空预测研究展望

Fig. 5. Research Prospects of Data-Knowledge Coupled Geospatial Spatiotemporal Prediction

#### 4.1 大模型时代的数智耦合

随着人工智能技术的快速发展，大模型（Large Models），如 ChatGPT、DeepSeek 等，已经成为当前智能化研究和应用的核心。例如，在天气预报领域，盘古气象大模型<sup>[2]</sup>由华为研发，作为首个精度超过传统数值预报方法的人工智能预测模型，其预测速度大幅提升。原本预测一个台风未来 10 天的路径需在庞大的服务器集群上花费数小时进行仿真，而现在通过人工智能推理，在单台服务器上单卡配置下，10 秒内即可获得更精确的结果。伏羲（FuXi）大模型<sup>[38]</sup>由复旦大学团队提出，采用创新的级联方法，整合多个精心调试的模型分别针对不同预报时段进行优化，生成全面的预报结果。而在地学领域，地学人工智能大模型为地学研究带来新机遇。如“坤元”，由中国科学院多单位共同研发，是全球首个多模态地理科学大模型，可实现多种地理功能，在地理学基准测试集上准确性高。还有上海交通大学

团队推出的 GeoGalactica，以 Galactica 为基座，收集约 600 万篇地学论文训练改进，具备较高地学语言生成能力。目前，地学时空预测大模型的数据驱动能力较强，知识嵌入和耦合能力相对较弱，时空预测大模型的透明性、可解释性、泛化能力不足。

大模型时代的到来为数智耦合提供了强大的技术支持，重塑了数据和知识在地学时空预测中的融合方式。未来大模型能够同时处理文本、图像、时间序列、地理数据等多模态信息，实现数据和知识的统一表征。借助大模型的语义理解能力，可以与知识图谱结合，将领域知识嵌入模型推理过程中。大模型通过预训练在超大规模数据上学习跨领域的普适规律，在特定任务上进行微调时，能够更好地适应多场景、多区域、多尺度的复杂地学问题，增强数智耦合时空预测模型的泛化能力。大模型具备多步推理和因果关系分析能力，有助于更深层次地挖掘地学过程中的因果关系。大模型可通过持续学习更新自身能力，支

持动态环境中实时调整数智耦合时空预测模型。在大模型支持下，数智耦合时空预测模型能够高效处理海量数据，通过并行处理和高效优化算法，能显著提升数据处理效率。同时，大模型具备强大的自然语言处理能力，可以将复杂的领域知识转化为通用的模型输入，降低非专业人员使用的技术门槛。大模型驱动の数智耦合时空预测模型能够支持跨学科协同，通过结合多学科知识（如气象学、地质学、生态学），促进跨领域知识在地质时空预测中的深度融合。因此，大模型时代为数智耦合提供了强大的工具和方法，能够显著提升数据与知识融合的效率 and 深度。

#### 4.2 数智耦合时空预测的通用性

当前，数智耦合时空预测模型在不同领域、不同场景和不同数据条件下应用和扩展能力存在不足，其通用性面临诸多挑战。不同地学领域的的数据格式、尺度和语义存在巨大差异，这使得数据的融合和知识的嵌入变得极为困难。例如，地质数据可能侧重于岩石的微观结构和宏观构造，而气象数据则关注大气的温度、湿度等宏观变量，将这些不同性质的数据整合到统一的数智耦合模型中，需要解决复杂的数据转换和适配问题。此外，不同地学现象的物理机制和时空演化规律各不相同，要构建通用的数智耦合模型，需要深入理解和抽象这些复杂的规律，这对模型的构建和优化提出了极高的要求。

数智耦合时空预测通用性的提升可从多个方面开展。一方面，需要研发通用的数据处理和知识融合技术，能够自动识别和处理不同格式、尺度和语义的数据，实现多源地学数据的无缝融合。另一方面，要加强对不同地学现象底层物理机制的研究，通过建立统一的模型框架，将各种地学现象的特殊规律进行参数化处理，纳入到通用的数智耦合模型中。同时，随着人工智能技术的不断发展，如迁移学习、元学习等技术的应用，有

望让数智耦合模型在不同地学领域之间快速迁移和自适应调整，进一步提升其通用性。此外，还可以通过强化领域知识整合增强通用性，构建跨领域的知识图谱，将通用知识与领域特定知识结合，以及通过因果推理方法强化模型对因果关系的理解，增强跨领域适应性。

#### 4.3 数智耦合时空预测的智能性

当前，数智耦合时空预测模型的智能性尚有不足。主要体现在：

①数智耦合时空预测模型的自学习能力不足。自学习是指模型在样本数据稀疏或不完整的情况下，能够通过已有知识、领域先验或未标注数据，主动进行优化和学习的能力。地学数据稀疏性普遍存在，模型对未标注数据的利用能力不足，依赖于大规模标注数据训练。在稀疏样本下，模型容易过拟合或表现不稳定。在此情况下，可以通过无监督学习与半监督学习、主动学习、增强学习等技术，提升数智耦合时空预测模型的自学习能力。

②数智耦合时空预测模型的自进化能力不足。自进化是指模型在动态变化的任务需求或环境下，能够协同优化自身的结构与参数，以适应新的预测目标。地学任务需求常随时间变化，当前模型多为静态结构，难以适应动态任务变化，缺乏领域知识与数据动态融合的进化机制。针对自进化能力不足的问题，通过迁移学习方法，将已有模型知识应用于新的任务场景，实现快速适应；引入增量学习机制，逐步更新模型的知识库和特征表示；建立数据与知识双驱动的进化框架，动态优化模型结构和参数；结合遗传算法或强化学习实现模型协同优化。

③数智耦合时空预测模型的自适应能力不足。自适应是指模型能够在面对多模态数据、多场景任务或动态环境时，快速调整策略和结构以适应变化的能力。地学数据多模态特征明显，不同任

务场景对模型要求差异大，模型缺乏通用适应机制，容易因场景变化导致性能下降。有效的提升策略包括：开发支持多模态输入的模型架构，如Transformer 结合图像与文本数据的处理能力；构建能够对任务层、数据层和模型层进行分级适应的框架；引入动态权重机制，根据场景变化实时调整模型对不同输入数据的依赖程度。

④数智耦合时空预测模型的自生成能力不足。自生成是指模型能够通过自主优化机制，实现结构设计、超参数调节和训练策略的自动化，从而减少人工干预。地学时空模型的结构设计和超参优化通常依赖人工经验，效率低下。当前的自动化搜索方法在大规模时空数据处理上仍存在局限。数智耦合时空预测模型的自生成能力可以从以下方面进行优化：使用神经架构搜索技术自动搜索最优网络结构，针对特定地学任务生成高效模型；引入贝叶斯优化或进化算法自动调整模型的超参数；开发基于领域知识的模型生成器，可根据输入任务自动生成预测模型。

## 5 总结

本文对数智耦合地学时空预测建模研究进展进行了较为详细的综述，并对未来发展进行了展望。数据驱动和知识驱动的地学时空预测模型研究经历了快速发展，有各自的优势和不足。数据驱动的地学时空预测模型具有较高的自适应能力、非线性建模能力和计算推理效率，而知识驱动的时空预测模型具有较强的物理机制、可解释性和泛化能力。因此，数智耦合的地学时空预测研究范式通过融合数据驱动和知识驱动，提升时空预测模型的泛化能力、可解释性和可靠性。本文提出了“数据赋能、知识指导、联合驱动、智算求解”四位一体的数智耦合时空预测框架，梳理了数智耦合时空预测的关键技术，总结了数智耦合地学时空预测面临的重要挑战，包括数智耦

合逻辑深度、时空过程精准表征和数智耦合专业壁垒。大模型时代为数智耦合地学时空预测提供了前所未有的机遇，通过整合大规模数据和领域知识，可以显著提升时空预测的精准性和智能化水平。未来数智耦合地学时空预测的发展将具有更高的通用性和智能性，具备自学习、自进化、自适应、自生成能力，形成高度智能化的预测系统，并将在多领域、多任务、多场景中展现卓越的适应性和通用性，为应对地球科学领域的复杂问题提供强有力的工具支持，同时助力科学研究和决策管理向更加智能化和精准化的方向发展。

## 参考文献

- [1] Xu L, Chen N, Chen Z, et al. Spatiotemporal forecasting in earth system science: Methods, uncertainties, predictability and future directions[J]. *Earth-Science Reviews*, 2021, 222: 103828
- [2] Bi K, Xie L, Zhang H, et al. Accurate medium-range global weather forecasting with 3D neural networks[J]. *Nature*, 2023, 619(7970): 533-538
- [3] Nearing G, Cohen D, Dube V, et al. Global prediction of extreme floods in ungauged watersheds[J]. *Nature*, 2024, 627(8004): 559-563
- [4] Liu Yu, Wang Keli, Xing Xiaoyue, et al. On spatial effects in geographical analysis[J]. *Acta Geographica Sinica*, 2023, 78(3): 517-531(刘瑜, 汪珂丽, 邢潇月, 等. 地理分析中的空间效应[J]. *地理学报*, 2023, 78(3): 517-531)
- [5] Zhang Y, Long M, Chen K, et al. Skilful nowcasting of extreme precipitation with NowcastNet[J]. *Nature*, 2023, 619(7970): 526-532
- [6] Fotheringham A S, Brunson C, Charlton M E. Geographically weighted regression[J]. *The Sage handbook of spatial analysis*, 2009, 1: 243-254

- [7] Martin R L, Oeppen J E. The identification of regional forecasting models using space: time correlation functions[J]. *Transactions of the Institute of British Geographers*, 1975: 95-118
- [8] Dimitrakopoulos R, Luo X. Spatiotemporal modelling: covariances and ordinary kriging systems[Z]. Springer, 1994: 88-93
- [9] Skilling J. *Maximum Entropy and Bayesian Methods*: Cambridge, England, 1988[M]. Springer Science & Business Media, 2013
- [10] Jordan M I, Mitchell T M. Machine learning: Trends, perspectives, and prospects[J]. *Science*, 2015: 255-260
- [11] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521: 436-444
- [12] Zang H, Liu L, Sun L, et al. Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations[J]. *Renewable Energy*, 2020, 160: 26-41
- [13] Akbari Asanjan A, Yang T, Hsu K, et al. Short-term precipitation forecast based on the PERSIANN system and LSTM recurrent neural networks[J]. *Journal of Geophysical Research: Atmospheres*, 2018, 123(22): 12-543
- [14] Chen Y, Li F, Deng Z, et al. PM2.5 forecasting with hybrid LSE model-based approach[J]. *Software: Practice and Experience*, 2017, 47(3): 379-390
- [15] Sønderby C, Espeholt L, Jonathan H, et al. MetNet: A Neural Weather Model for Precipitation Forecasting[J]. arXiv: Learning. 2020.
- [16] Shi X, Chen Z, Wang H, et al. Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting[J]. arXiv: Computer Vision and Pattern Recognition, 2015
- [17] Xu L, Chen N, Zhang X, et al. A data-driven multi-model ensemble for deterministic and probabilistic precipitation forecasting at seasonal scale[J]. *Climate Dynamics*, 2020, 54: 3355-3374
- [18] Reichstein M, Camps-Valls G, Stevens B, et al. Deep learning and process understanding for data-driven Earth system science[J]. *Nature*, 2019, 566(7743): 195-204
- [19] Gagne D J, Christensen H M, Subramanian A C, et al. Machine learning for stochastic parameterization: Generative adversarial networks in the Lorenz'96 model[J]. *Journal of Advances in Modeling Earth Systems*, 2020, 12(3): e2019MS001896
- [20] Yuval J, O Gorman P A. Stable machine-learning parameterization of subgrid processes for climate modeling at a range of resolutions[J]. *Nature Communications*, 2020, 11: 3295
- [21] Ebert-Uphoff I, Hilburn K. Evaluation, tuning and interpretation of neural networks for working with images in meteorological applications[J]. *Bulletin of the American Meteorological Society*, 2020: 1-47
- [22] Mcgovern A, Lagerquist R, John Gagne D, et al. Making the Black Box More Transparent: Understanding the Physical Implications of Machine Learning[J]. *Bulletin of the American Meteorological Society*, 2019, 100(11): 2175-2199
- [23] Makridakis S, Spiliotis E, Assimakopoulos V. Statistical and Machine Learning forecasting methods: Concerns and ways forward[J]. *PloS one*, 2018, 13(3): e0194889
- [24] Tukey J W. *Exploratory data analysis*[J]. Reading/Addison-Wesley, 1977
- [25] Biau G, Scornet E. A random forest guided tour[J]. *Test*, 2016, 25: 197-227
- [26] Demšar U, Fotheringham A S, Charlton M. Explor-

ing the spatio-temporal dynamics of geographical processes with geographically weighted regression and geovisual analytics[J]. *Information Visualization*, 2008, 7(3-4): 181-197

[27] 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(高松. 地理空间人工智能的近期研究总结[J]. *武汉大学学报(信息科学版)*, 2020, 45(12): 1865-1874)

[28] Sugiyama M. *Introduction to statistical machine learning*[M]. Morgan Kaufmann, 2015

[29] Ham Y, Kim J, Luo J. Deep learning for multi-year ENSO forecasts[J]. *Nature*, 2019, 573(7775): 568-572.

[30] Wadoux A M, Minasny B, Mcbratney A B. Machine learning for digital soil mapping: Applications, challenges and suggested solutions[J]. *Earth-Science Reviews*, 2020, 210: 103359

[31] Xu L, Chen N, Zhang X, et al. Improving the North American multi-model ensemble (NMME) precipitation forecasts at local areas using wavelet and machine learning[J]. *Climate dynamics*, 2019, 53: 601-615

[32] Devries P M, Vi E Gas F, Wattenberg M, et al. Deep learning of aftershock patterns following large earthquakes[J]. *Nature*, 2018, 560(7720): 632-634

[33] Quilty J, Adamowski J, Boucher M E L. A stochastic data-driven ensemble forecasting framework for water resources: A case study using ensemble members derived from a database of deterministic wavelet-based models[J]. *Water Resources Research*, 2019, 55(1): 175-202

[34] Xu L, Chen N, Zhang X. A comparison of large-scale climate signals and the North American Multi-Model Ensemble (NMME) for drought prediction in China[J]. *Journal of hydrology*, 2018, 557: 378-390.

[35] Cortes C. *Support-Vector Networks*[J]. *Machine Learning*, 1995

[36] Breiman L. Random forests[J]. *Machine learning*, 2001, 45: 5-32

[37] He Yi, Yao Sheng, Chen Yi, et al. Spatio-temporal prediction of time-series InSAR Land subsidence based on ConvLSTM neural network[J/OL]. *Geomatics and Information Science of Wuhan University*, 2023(何毅, 姚圣, 陈毅, 等. ConvLSTM神经网络的时序InSAR地面沉降时空预测[J/OL]. *武汉大学学报(信息科学版)*. 2023)

[38] Chen L, Zhong X, Zhang F, et al. FuXi: A cascade machine learning forecasting system for 15-day global weather forecast[J]. *npj Climate and Atmospheric Science*, 2023, 6(1): 190.

[39] Yao F, Lu W, Yang H, et al. RingMo-sense: Remote sensing foundation model for spatiotemporal prediction via spatiotemporal evolution disentangling[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2023

[40] Li Z, Xia L, Shi L, et al. Opency: Open spatio-temporal foundation models for traffic prediction[J]. arXiv:2408.10269. 2024

[41] Hong D, Zhang B, Li X, et al. SpectralGPT: Spectral remote sensing foundation model[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024

[42] Lam R, Sanchez-Gonzalez A, Willson M, et al. Learning skillful medium-range global weather forecasting[J]. *Science*, 2023, 382(6677): 1416-1421.

[43] Wang Peixiao, Zhang Hengcai, Zhang Yan, et al. GeoAI-driven Spatiotemporal Prediction: Progress and Prospects[J]. *Journal of Geo-information Science*, 2025, 27(1): 60-82(王培晓, 张恒才, 张岩, 等. 地理空间智能预测研究进展与发展趋势[J]. *地球信息科学学*

报, 2025, 27(1): 60-82)

[44] Deng Min, Cai Jian Nan, Yang Wen Tao, et al. Spatio-temporal Analysis Methods for Multi-modal Geographic Big Data[J]. Journal of Geo-information Science, 2020, 22(1): 41-56(邓敏, 蔡建南, 杨文涛, 等. 多模态地理大数据时空分析方法[J]. 地球信息科学学报, 2020, 22(1): 41-56)

[45] Wang Jing Feng, Ge Yong, Li Lian Fa, et al. Spatiotemporal data analysis in geography[J]. Acta Geographica Sinica, 2014, 69(09): 1326-1345(王劲峰, 葛咏, 李连发, 等. 地理学时空数据分析方法[J]. 地理学报, 2014, 69(09): 1326-1345)

[46] Gettier E. Is Justified True Belief Knowledge?[M]. Macat International Limited, 2016

[47] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations[J]. Journal of Computational physics, 2019, 378: 686-707

[48] Meng Yu, Chen Jing Bo, Zhang Zheng, et al. Knowledge and data driven remote sensing image interpretation: Recent developments and prospects[J]. National Remote Sensing Bulletin, 2024, 28(11): 2698-2718(孟瑜, 陈静波, 张正, 等. 知识与数据驱动的遥感图像智能解译: 进展与展[J]. 遥感学报. 2024, 28(11): 2698-2718)

[49] Shi Yan, Wang Da, Deng Min, et al. Spatio-temporal anomaly detection: connotation transformation and implementation path from data-driven to knowledge-driven modeling[J]. Acta Geodaetica et Cartographica Sinica, 2024, 53(08): 1493-1504(石岩, 王达, 邓敏, 等. 时空异常探测: 从数据驱动到知识驱动的内涵转变与实现路径[J]. 测绘学报, 2024, 53(08): 1493-1504)

[50] Wang Y, Wang W, Ma Z, et al. A deep learning

approach based on physical constraints for predicting soil moisture in unsaturated zones[J]. Water Resources Research, 2023, 59(11): e2023WR035194

[51] Chandwani V, Vyas S K, Agrawal V, et al. Soft computing approach for rainfall-runoff modelling: a review[J]. Aquatic Procedia, 2015, 4: 1054-1061

[52] Cho K, Kim Y. Improving streamflow prediction in the WRF-Hydro model with LSTM networks[J]. Journal of Hydrology, 2022, 605: 127297

[53] Zhao W L, Gentine P, Reichstein M, et al. Physics - constrained machine learning of evapotranspiration[J]. Geophysical Research Letters, 2019, 46(24): 14496-14507

[54] Xue Gui Xiang, Wang Hui, Zhou Wei Feng, et al. Port traffic flow prediction based on knowledge graph and spatio-temporal diffusion graph convolutional network[J]. Journal of Computer Applications, 2024, 44(09): 2952-2957(薛桂香, 王辉, 周卫峰, 等. 基于知识图谱和时空扩散图卷积网络的港口交通流量预测[J]. 计算机应用, 2024, 44(09): 2952-2957)

[55] Li Z, Liu F, Yang W, et al. A survey of convolutional neural networks: analysis, applications, and prospects[J]. IEEE transactions on neural networks and learning systems, 2021, 33(12): 6999-7019

[56] Hochreiter S. Long Short-term Memory[J]. Neural Computation MIT-Press. 1997

[57] Kipf T N, Welling M. Semi-supervised classification with graph convolutional networks[J]. arXiv:1609.02907. 2016

[58] Chen T, Kornblith S, Norouzi M, et al. A simple framework for contrastive learning of visual representations[Z]. Proceedings of Machine Learning Research, 2020, 1597-1607

[59] Jian Song Lei, Lu Kai. Survey on Representation

- Learning of Complex Heterogeneous Data[J]. *Computer Science*, 2020, 47(2): 1-9(蹇松雷, 卢凯. 复杂异构数据的表征学习综述[J]. *计算机科学*. 2020, 47(2): 1-9)
- [60] Wu M, Goodman N. Multimodal generative models for scalable weakly-supervised learning[J]. *Advances in neural information processing systems*, 2018, 31
- [61] Tesch T, Kollet S, Garcke J. Causal deep learning models for studying the Earth system[J]. *Geoscientific Model Development*, 2023, 16(8): 2149-2166
- [62] Akcelik V, Bielak J, Biroš G, et al. High resolution forward and inverse earthquake modeling on terascale computers[Z]. 2003, 52
- [63] Li T, Sahu A K, Talwalkar A, et al. Federated learning: Challenges, methods, and future directions[J]. *IEEE signal processing magazine*, 2020, 37(3): 50-60.
- [64] Krishnamoorthi R. Quantizing deep convolutional networks for efficient inference: A whitepaper[J]. *arXiv:1806.08342*. 2018
- [65] Zhao J, Wang Z, Park D S. Online sequential extreme learning machine with forgetting mechanism[J]. *Neurocomputing*. 2012, 87: 79-89
- [66] Hu X, Shi L, Lin G, et al. Comparison of physical-based, data-driven and hybrid modeling approaches for evapotranspiration estimation[J]. *Journal of Hydrology*. 2021, 601: 126592
- [67] Deng Min, Wang Da. Research progress in spatiotemporal big data mining and knowledge services for natural resources[J]. *Journal of Geo-information Science*, 2025, 27(1): 1-14(邓敏, 王达. 自然资源时空大数据挖掘与知识服务研究进展[J]. *地球信息科学学报*, 2025, 27(1): 1-14)
- [68] Wang H, Yeung D. A survey on Bayesian deep learning[J]. *ACM computing surveys*, 2020, 53(5): 1-37.
- [69] Xu L, Lv Y, Moradkhani H. Daily multistep soil moisture forecasting by combining linear and nonlinear causality and attention-based encoder-decoder model[J]. *Stochastic Environmental Research and Risk Assessment*, 2024: 1-22
- [70] Lundberg S, Lee S. SHAP: A Unified Approach to Interpreting Model Predictions[J]. *Advances in neural information processing systems*, 2017: 1-10
- [71] Xu Lei. Analysis and Processing of Spatiotemporal Precipitation Forecasting by Considering Data and Model Uncertainties[D]. Wuhan University, 2021(许磊. 顾及数据与模型不确定性的降雨时空预测分析及处理方法研究[D]. 武汉大学, 2021)
- [72] Xu L, Abbaszadeh P, Moradkhani H, et al. Continental drought monitoring using satellite soil moisture, data assimilation and an integrated drought index[J]. *Remote Sensing of Environment*, 2020, 250: 112028
- [73] Xu L, Chen N, Zhang X, et al. In-situ and triple-collocation based evaluations of eight global root zone soil moisture products[J]. *Remote Sensing of Environment*, 2021, 254: 112248
- [74] Xu L, Chen N, Yang C. Quantifying the uncertainty of precipitation forecasting using probabilistic deep learning[J]. *Hydrology and Earth System Sciences*, 2021: 1-27
- [75] Loquercio A, Segù M, Scaramuzza D. A general framework for uncertainty estimation in deep learning[J]. *IEEE Robotics and Automation Letters*, 2020, 5(2): 3153-3160
- [76] Xu Lei, Li Qi, Tao Yun, et al. Design of a data-driven reliability analysis technical system for precipitation nowcasting[J]. *Journal of Spatiotemporal Information*, 2023, 30(04): 508-517 (许磊, 李琪, 陶云,

等. 数据驱动的短临降水预报可靠性分析技术体系研究[J]. 时空信息学报, 2023, 30(04): 508-517

Lei Xu, Qi Li, Yun Tao, et al. 2023, 30(04): 508-517.

[77] Abdar M, Pourpanah F, Hussain S, et al. A re-view of uncertainty quantification in deep learning: Techniques, applications and challenges[J]. Information fusion, 2021, 76: 243-297

[78] Maddox W J, Izmailov P, Garipov T, et al. A simple baseline for bayesian uncertainty in deep learning[J]. Advances in neural information processing systems, 2019, 32

[79] Kendall A, Gal Y. What uncertainties do we need in bayesian deep learning for computer vision?[J]. Advances in neural information processing systems, 2017, 30

[80] Rubin D B. Causal inference using potential outcomes: Design, modeling, decisions[J]. Journal of the American Statistical Association, 2005, 100(469): 322-331

[81] Pan S J, Yang Q. A survey on transfer learning[J]. IEEE Transactions on knowledge and data engineering, 2009, 22(10): 1345-1359

[82] Price I, Sanchez-Gonzalez A, Alet F, et al. Probabilistic weather forecasting with machine learning[J]. Nature, 2025, 637(8044): 84-90

[83] Feng S, Huang J, Shen Q, et al. A Hybrid Model

Integrating Local and Global Spatial Correlation for Traffic Prediction[J]. IEEE Access, 2022, 10: 2170-2181

[84] Yuan Z, Zhou X, Yang T. Hetero-convlstm: A deep learning approach to traffic accident prediction on heterogeneous spatio-temporal data[Z]. 2018, 984-992.

[85] Zhang C, Patras P. Long-term mobile traffic forecasting using deep spatio-temporal neural networks[Z]. 2018, 231-240

[86] Zafar M R, Khan N. Deterministic local interpretable model-agnostic explanations for stable explainability[J]. Machine Learning and Knowledge Extraction, 2021, 3(3): 525-541

[87] Lin Z, Deng C, Zhou L, et al. Geogalactica: A scientific large language model in geoscience[J]. arXiv preprint arXiv:2401.00434. 2023

[88] Yang Bi Sheng, Chen Yi Ping, Zou Qin. Opportunities and Challenges of Spatiotemporal Information Intelligent Processing of Surveying and Mapping in the Era of Large Models[J]. Geomatics and Information Science of Wuhan University, 2023, 48(11): 1756-1768(杨必胜, 陈一平, 邹勤. 从大模型看测绘时空信息智能处理的机遇和挑战[J]. 武汉大学学报 (信息科学版). 2023, 48(11): 1756-1768)

#### 网络首发:

标题: 数智耦合地学时空预测建模研究进展及展望

作者: 许磊, 陈能成, 邓敏

收稿日期: 2025-02-18

DOI:10.13203/j.whugis20240483

#### 引用格式:

许磊, 陈能成, 邓敏. 数智耦合地学时空预测建模研究进展及展望[J]. 武汉大学学报(信息科学版), 2025, DOI:10.13203/J.whugis20240483 (XU Lei, CHEN Nengcheng, DENG Min. Research Progress and Prospects of Data-Knowledge Coupled Spatiotemporal Prediction Modeling in Geosciences[J]. Geomatics and Information Science of Wuhan University, 2025, DOI:10.13203/J.whugis20240483)

网络首发文章内容和格式与正式出版会有细微差别, 请以正式出版文件为准!

---

您感兴趣的其他相关论文:

**融合多源数据研究积石山地震灾害及人口伤亡时空演化**

李伟, 杜锦辰, 张超, 颀旭康, 张超越, 刘东, 刘美琳, 张丽琼, 杨建华, 闫浩文

武汉大学学报(信息科学版), 2025, 50(2): 271-283.

<http://ch.whu.edu.cn/article/doi/10.13203/j.whugis20240094>

**变分模态分解与自适应图卷积门控循环网络的交通流量组合预测模型**

龚循强, 邱万锦, 吕开云, 张通, 张瑞, 罗升

武汉大学学报(信息科学版), 2024, 49(12): 2329-2341.

<http://ch.whu.edu.cn/article/doi/10.13203/j.whugis20230249>