

魏廷平, 孙正宝, 黄江成, 等. 地表过程研究中的因果推理方法: 综述与实验 [J]. 地理科学, 2025, 45(9): 1986-1999. [Wei Tingping, Sun Zhengbao, Huang Jiangcheng et al. Causal inference methods in surface process research: Review and experiment. Geographical Science, 2025, 45(9): 1986-1999.] doi: 10.13249/j.cnki.sgs.20240502; cstr: 32176.14.geoscience.20240502

地表过程研究中的因果推理方法: 综述与实验

魏廷平¹, 孙正宝², 黄江成¹, 邹承权¹

(1. 云南大学国际河流与生态安全研究院, 云南 昆明 650500;

2. 云南大学现代工学院, 云南 昆明 650500)

摘要: 探明地表过程中各要素的因果作用关系并量化因果效应, 对理解地表变化规律至关重要。近年来, 遥感技术和因果推理研究的快速发展, 为基于遥感观测数据开展多尺度地表过程中的相互作用规律研究提供了机遇和可能。然而, 面向地学领域的因果关系、因果效应和因果推理研究尚处于起步阶段, 多尺度地表过程因果作用机制和规律研究仍面临诸多挑战。因此, 本文首先回顾因果推理的理论框架与方法研究进展; 然后, 通过实验探索时序因果推理方法在地表植被变化归因方面的可能性; 最后, 总结因果推理在地表过程研究中面临的机遇和挑战。结果表明: ①因果关系发现与因果效应评估是当前地表过程研究发展的迫切需求和前沿热点, 但却面临着因果关系假设过强、虚假因果关系识别困难、验证数据缺乏等诸多挑战。②2001—2020 年云南省地表植被时空变化过程的实验结果表明, 时序因果推理方法在地表植被变化的因果关系发现与因果效应评估中具有显著效果。实验结果显示: 植被与气候因子间存在显著因果作用关系和滞后效应, 其中温度与地表温度是影响云南省地表植被变化的主导因子, 同时植被对气候因子的影响表现出显著的反馈作用。③在地理大数据与地学大模型的背景下, 支持地表过程因果推理验证的数据集构建、时空耦合的因果推理与可解释性的机器学习方法将是未来的发展方向。

关键词: 因果推理; 因果关系; 归因研究; 植被变化; 云南省

中图分类号: K909 **文献标识码:** A **文章编号:** 1000-0690(2025)09-1986-14

地球系统科学研究中的诸多问题本质上是因果问题, 以确定一个变量是否以及如何影响另一个变量, 例如云的形成、评估和改善气候模型、大气远程相互作用和气候变化的检测与归因等^[1]。因果存在于原因变化到结果变化的传递过程中, 通常被定义为: 如果观测变量 X 的变化影响观测变量 Y 的变化, 并且 X 在 Y 之前发生, 则称 X 是 Y 的原因^[2]。在地球系统相互作用机制的研究中, 相关与因果一直是学者们讨论的热点话题^[3], 但相关不等于因果^[4-5]。相关仅强调变量在统计学上的关联性, 是双向的, 而因果强调变量间的依存关系, 通常是单向的。受混杂因素的影响, 大数据时代会出现诸多“伪相关”因果现象^[3,6]。

作为地球系统的一个重要内容, 地表过程是一个高度复杂且不断发展的动态系统。为应对气候变化、人口增长和经济发展等多领域、多尺度变化的挑战, 大量观测和研究地表过程和机制的方法被提出, 其中统计学中的相关分析与回归模型被证明是有效且常用的

收稿日期: 2024-05-23; **修订日期:** 2024-10-10

基金项目: 国家重点研发计划课题 (2024YFF1308101)、国家自然科学基金项目 (42271086)、云南省“兴滇英才支持计划”青年人才项目 (XDYC-QNRC-2023-0322) 资助。[Foundation: National Key R&D Program of China (2024YFF1308101), National Natural Science Foundation of China (42271086), Revitalizing Yunnan Talents Support Plan: Young Talent Program of Yunnan Province (XDYC-QNRC-2023-0322).]

作者简介: 魏廷平 (2000—), 男, 贵州毕节人, 硕士研究生, 主要从事因果推理与生态遥感研究。E-mail: weitingping@stu.ynu.edu.cn

通信作者: 孙正宝。E-mail: zbsun@ynu.edu.cn

方法^[7]。随着机器学习的发展,一些采用关联、分类、预测和异常检测等机器学习方法探究地表过程中多要素相互作用机制的研究工作被陆续报道^[8-9],这些研究工作在揭示地表过程中各要素间的相关性、敏感性及关联关系等方面取得了重要成果,但要素间相互作用规律背后的因果机制尚不清楚。与传统的统计和机器学习方法相比,因果推理方法能从观测数据中识别直接或间接的因果关系,并量化因果效应^[7],对地表过程中的相互作用规律揭示、过程理解以及模型改进等方面有重要意义。

因果推理旨在挖掘变量间隐藏的因果关系,并量化因果效应,在解释、预测、决策和控制等方面发挥了重要作用^[10],但需要满足一定假设条件,例如因果充分性、马尔可夫条件、信实假设和平稳性假设等^[1]。然而,满足这些假设非常困难,这给地表过程中的因果推理研究带来了巨大挑战。随机对照试验被认为是推断因果关系最有效的方法,但具有一定局限性^[11],其替代方法是计算机模拟试验,但该方法花费大、耗时久,且需要大量专家知识。近年来,由于地球观测数据的爆炸式增长,推动了因果推理研究向数据驱动方式的转变^[7],加上计算机和统计学的快速发展,因果理论研究取得了重要进展。格兰杰因果检验(Granger Causality Test, GTC)的提出^[12],为时序因果推理奠定了基础;潜在结果模型为因果推理研究提供了“反事实”分析基础^[13];基于状态空间重构理论的收敛交叉映射方法(Convergent Cross Mapping, CCM)^[14],适用于非线性系统的因果推理问题;耦合 Peter-Clark 算法和瞬时条件独立性检验(Momentary Conditional Independence, MCI)的 PCMCI 算法(Peter-Clark Momentary Conditional Independence, PCMCI)能够从复杂、高维的非线性系统中构建因果网络并估计因果效应^[15];结构因果模型(Structural Causal Model, SCM)结合结构方程、潜在结果框架、概率计算和有向无环图(Directed Acyclic Graph, DAG)^[16-17],促进因果推理成为了一种成熟的科学方法^[18]。

地表过程作为一个复杂的动态系统,相互作用与变化强烈,如水体、植被变化及滑坡泥石流等地质灾害过程等^[19-21],但在地表过程相互作用与变化的研究中,缺乏对相互作用机制的因果解释,严重限制了研究者对地表过程变化的深入理解。随着遥感技术的快速发展,地表观测数据的时空分辨率、数据种类、数据规模和数据质量等方面都得到了极大的提高^[22],加之人类对理解地表变化过程的追求,基于遥感观测数据挖掘地表过程相互作用与变化背后的因果关系,并量化因果效应显得至关重要。近年来,随着因果理论的快速发展,因果推理已成功应用于地表过程研究的多个领域^[3,23],有助于探究动力系统中要素的演变规律及其驱动、响应机制。然而,面向地学领域的因果关系、因果效应和因果推理研究的不足,严重制约着对多尺度地表过程因果作用机制和规律的认识。因此,本文首先回顾因果推理的理论框架与方法;然后,通过实验探索和验证时序因果推理方法在地表植被变化归因方面的可能性;最后,总结因果推理研究在地表过程研究中面临的挑战与未来发展方向。

1 因果推理框架

因果推理旨在获取因果关系并量化因果效应,以表达一个变量在多大程度上影响另一个变量。一般地,当变量间的相互耦合显著时,因果效应较强,反之较弱。由于不同因果推理方法检测出的因果效应存在差异,可解释性程度也不同,因此,应用因果推理方法时应充分考虑所研究的问题。

在因果理论的发展历程中,产生了多种因果推理方法,如基于匹配、因果效应树和动态干预等方法^[24-28],但这些方法大都缺乏系统性,应用领域受限^[11](表 1)。近年来,随着因果理论的迅速发展,潜在结果模型与结构因果模型逐渐成为大家普遍认可的 2 种主流因果推理框架,推动因果推理研究迈向了新阶段。

表 1 因果推理方法的比较

Table 1 Comparison of causal inference methods				
因果推理模型/方法	类型	核心理论	优点	缺点
潜在结果模型 ^[13]	时序/空间因果	干预、“反事实”分析	引入了“反事实”思想,对先验知识的要求较低,模型结构简单,应用较广泛	表达能力较差,可解释性较弱,仅适用于简单因果问题
结构因果模型 ^[16-17]	时序/空间因果	因果图、干预、结构方程	引入了因果图,表达能力较强,可消除混杂因素的影响,适用于复杂因果问题	模型较复杂,对先验知识的要求高,过于依赖因果图,应用较局限
格兰杰因果检验 ^[12]	时序因果	格兰杰因果关系理论	第一个利用时间序列的可预测性推断因果关系的方法,模型简单,对先验知识的要求较低	仅适用于线性、平稳的系统,在复杂、高维的非线性系统中,因果检测能力较弱
收敛交叉映射 ^[14]	时序因果	状态空间重构理论	适用于非线性系统的时序因果推理问题,能够消除混杂因素的影响,表达能力较强	当时间序列数据缺乏或呈现不明显变化时,具有较大局限性,且不适用于多变量系统
地理收敛交叉映射 ^[27]	空间因果	状态空间重构理论	适用于非线性系统的空间因果推理问题,表达能力较强	模型较复杂,对噪声较敏感,且不适用于多变量系统
PC ^[28]	时序因果	因果图、条件独立性检验	适用于多元非线性系统,应用广泛	不能识别瞬时因果关系,不能量化因果效应
PCMC ^[15]	时序因果	因果图、条件独立性检验	能够从复杂、高维的非线性系统中自动构建因果网络并量化因果效应,对非平稳系统有较高的鲁棒性,表达能力强	模型较复杂,不能识别瞬时因果关系

1.1 潜在结果模型

潜在结果模型的核心是对比研究对象在接受干预与不接受干预的结果差异,并认为这个结果差异就是因果效应^[13],而估计因果效应是因果推理的核心问题之一,潜在结果模型为此提供了“反事实”分析思想,可评估潜在的结果差异,挖掘变量间隐藏的因果关系。以二元干预为例, $X_i(1)$ 和 $X_i(0)$ 分别表示研究对象 X_i 在接受干预和不接受干预的结果,则个体层面的因果效应(Individual Causal Effect, ICE)定义为:

$$ICE(i) = X_i(1) - X_i(0)$$

(1)

在总体层面上,平均因果效应(Average Causal Effect, ACE)定义为:

$$ACE = E[X(1)] - E[X(0)]$$

(2)

1.2 结构因果模型

结构因果模型是一种基于因果图和概率统计方法来推断因果关系并估计因果效应的方法^[16-17],被誉为“因果革命”。它由结构方程、有向无环图和“反事实”分析组成,核心思想为:利用条件独立性检验构建有向无环图,然后基于概率统计方法评估因果效应。与其他因果推理方法相比,SCM整合了干预、有向分离准则、前门准则、后门准则和“反事实”分析等基本原理来推断因果关系,并将因果推理问题划分为:关联、干预和“反事实”3个层面,同时引入有向无环图,可清楚地表达变量间的因果作用机制,并且可以通过前、后门准则解决混杂因素问题(图1)。

虽然潜在结果模型和结构因果模型对




图 1 结构因果模型框架
Fig.1 Structural causal model framework

因果的表述不完全一致,但都是表达一个变量在多大程度上影响另一个变量。两者相比,结构因果模型的表达能力更强,适合处理复杂因果问题,但由于过于依赖因果图,应用比较局限。而潜在结果模型对先验知识的要求较低、描述简单、应用广泛,但因果可解释性较弱。

2 因果推理方法

时间和空间是构成地表过程的 2 个基本维度,因此揭示地表过程中因果作用机制的研究工作可以从时间角度开展,也可以从空间角度开展^[29],由此产生了格兰杰因果检验、收敛交叉映射、PCMCI、地理探测器和地理收敛交叉映射等多种因果推理方法。由于地表过程中的大多数变量是以时间序列的形式呈现,因此,时序因果推理一直是地表过程中因果推理研究的主流方法,而有关空间因果推理的研究鲜见报道。

2.1 时序因果推理

时序因果推理是基于时间顺序(原因发生在结果之前)的假设,通过变量随时间的变化来推断它们之间的因果关系。主流的方法有:格兰杰因果检验、收敛交叉映射和 PCMCI。

2.1.1 格兰杰因果检验

GTC 是第一个利用时间序列的可预测性来推断因果关系的方法^[12],核心思想为:如果考虑时间序列 X 的历史信息能够提高时间序列 Y 的自回归预测,则称 X 导致 Y ^[30]。传统的 GCT 是一种基于线性自回归模型的因果推理方法,仅适用于线性、平稳的双变量因果推理问题,且不能识别间接的因果关系和共同的驱动因素。因此,在地表过程中的因果检测能力较弱,现有的工作主要集中在 GCT 的多变量和非线性扩展与算法优化的研究上^[3]。

2.1.2 收敛交叉映射

地表过程作为一个复杂的动态系统,相互作用强烈,而 GTC 是一种线性因果推理方法,在地表过程中推断因果关系存在一定挑战,甚至会得到错误的结论。CCM 是一种基于 Takens 理论的因果推理方法,适用于非线性系统的因果推理问题^[14],基本原理为:基于时间滞后重构时间序列变量 X 和 Y 的影子流形 M_x 和 M_y ,然后利用影子流形进行预测,如果可以通过 M_y 来预测 X ,则称 X 导致 Y ,并用预测能力表达因果效应。在 CCM 中,其收敛性是区分因果关系和相关性的关键性质,即变量间交叉映射的能力随时间序列长度的增加而提高,最后收敛于某特定值。CCM 作为一种非线性的因果推理方法,能够消除系统中混杂因素的影响,检测出双向的因果关系,即 2 个变量能相互交叉映射,每个变量都可以从另一个变量的信息中估计出来,但预测能力不同。CCM 也能识别单向的因果关系,即根据结果变量的信息得到原因变量的信息,反之则不行。由于 CCM 在检测单向、双向因果关系方面具有明显优势,因此被广泛应用于生态学、大气科学和水文学的研究中^[3]。

2.2 空间因果推理

尽管时序因果推理能够检测出地表过程中的大多数因果关系,但当研究对象的时间序列较短或变量间的变化不明显时,时序因果推理可能存在一定局限性,从而忽略一些重要的结论,例如土壤重金属与工业污染和居民居住密度之间的因果关系、人口密度与环境因子之间的因果关系及农田净初级生产力(NPP)与温度和降水之间的因果关系^[27]。由于时间和空间是构成地表过程的 2 个基本维度,当缺少时间序列数据时,可以利用空间数据补充研究对象的信息,通过空间分布差异和空间相互作用来推断因果关系,常用的方法有地理探测器和地理收敛交叉映射。

2.2.1 地理探测器

地理探测器是一种探测空间分异性及揭示其背后驱动力的空间分析方法,通过目标

变量与解释变量的空间分布格局来检测它们的因果关系^[31],被广泛应用于土地利用、区域经济与规划和生态学等领域^[32-35],对理解自然和社会经济变化过程有重要意义,但仅依据变量空间分布的统计关联性探测空间分异性及揭示背后驱动力,因果可解释性较弱。

2.2.2 地理收敛交叉映射

由于 CCM 只考虑研究对象的时间序列数据,缺乏空间信息,但当时间序列数据缺乏或呈现不明显变化时,CCM 具有严重局限性。而 GCCM 作为一种空间因果推理方法,可以有效利用空间信息来推断变量间的因果关系^[27],其原理与 CCM 类似,不同的是 GCCM 基于空间滞后重构影子流形。GCCM 能够在变量间的相互耦合不显著时,检测出弱-中度的因果关系,当变量间的相互耦合显著时,能识别出主要的因果方向,更好地揭示双向不对称的因果关系。

2.3 因果网络发现方法

因果网络发现是从观测数据中挖掘因果信息并生成因果网络的过程,是获取因果图的重要手段,基本原理为:从一个无向图或有向无环图开始,然后基于一定约束条件,递归地增加或删除边,逐步构建因果网络。增加或删除边的标准可以是条件独立检验或评分函数,条件独立性检验可通过偏相关进行估计,评分函数可基于贝叶斯或信息论方法^[7]。

2.3.1 PC 算法

PC 算法是一种基于约束的因果网络发现方法,主要利用条件独立性来确定因子间的因果关系^[28]。主要通过 2 个阶段实现:首先在骨架发现阶段,它从一个完整的无向图开始,然后根据条件独立性检验递归地删除边。在定向阶段,则通过一组规则对边进行定向,从而得到一个有向无环图。

2.3.2 PCMCI 算法

PCMCI 是 PC 方法的改进,也是一种基于条件独立性检验的因果网络发现方法,能够从复杂、高维的非线性系统中自动构建因果网络并量化因果效应^[15],核心思想为:从一个有向无环图开始,根据条件独立性检验递归地删除边,逐步构建因果网络。主要由 2 个阶段实现:①条件选择(PC),通过迭代条件独立性检验识别所有变量的父节点,并移除不相关的变量,可以有效避免高维灾难;②瞬时条件独立性检验(MCI),以 PC 阶段估计的父节点集作为条件集,对每个变量再次执行瞬时条件独立性检验,确定因果方向,构建更可靠的因果网络,并且 MCI 检验的统计值可量化因果效应和显著性。在复杂、高维的非线性系统中,与其他因果推理方法相比,PCMCI 具有更高的检测能力和因果可解释性、计算复杂度更小、鲁棒性更高。

2.4 其他因果分析方法

2.4.1 机器学习方法

机器学习被认为是解决很多研究问题的重要方法,近年来,随着地球科学大数据时代的到来,更是为其提供了巨大潜力^[9]。随机森林(Random Forest, RF)、极度梯度提升(Extreme Gradient Boosting, XGBoost)、支持向量机(Support vector machines, SVM)等机器学习方法也被广泛应用于地表过程中植被、水体变化及滑坡、泥石流等驱动机制的研究中^[36-42],对于揭示地表要素间的相互作用规律有一定意义,特别是 XGBoost 作为一种集成算法,能够通过加性模型、前向优化策略和正则化模型提高模型预测的准确性及降低过拟合的风险^[36],但该方法基于黑箱操作,结果的可解释性较差。

2.4.2 AI 模型

随着 ChatGPT、“坤元”地理大模型和 DeepSeek 等模型的出现,社会进入了 AI 的新时代。针对 AI 在因果分析中的应用,ChatGPT 是基于模式匹配和概率生成文本,而非真正的逻辑推理,所以在因果分析上存在不足;与之相比,DeepSeek 作为一个专注于数据挖掘、信

息检索的 AI 工具, 具有更好的因果分析能力。目前, 这些 AI 模型都能在一定程度上提供一些关于因果的基础知识及解决一些简单的因果问题, 但仍存在一些局限性与挑战, 例如过于依赖文本模式、混淆相关性与因果性、缺乏训练因果模型、无法构建因果图及量化因果效应等。因此, 在解决复杂因果问题时(如地表过程中的因果问题), 建议采用“AI 知识库+专业因果推理工具+人工验证”的研究模式。并且, 随着 AI 科技与因果推理研究的发展, 如何有效利用 AI 与因果推理方法解决地表过程中复杂的因果问题将是研究未来关注的重点。

3 地表植被变化过程的因果推理实验

植被作为陆地生态系统的重要组成部分, 为生态系统与人类活动提供了有力支持^[43], 在气候变化和人类活动加剧的背景下, 植被发生了显著变化^[44-45]。然而, 针对地表植被动态变化的研究, 以往大都是基于统计相关或机器学习的方法, 忽略了植被与影响因子间复杂的相互作用^[46], 严重制约了对植被变化内在机理与过程的理解。因此, 本实验在分析云南省地表植被时空变化特征的基础上, 为探究植被与气候因子的相互作用机制, 基于因果推理思想, 利用 PCMCi 与 CCM 方法揭示 2001—2020 年云南省植被与温度(Tem)、降水(Pre)、地表温度(LST)和土壤湿度(SM)等气候因子的因果作用机制, 并构建因果网络、量化因果效应。

3.1 实验研究区

云南省位于中国西南部, 介于 97°31'E~106°11'E, 21°08'N~29°15'N 之间, 下辖 16 个地级行政区, 总面积约 39.41 万 km², 属山地高原地形, 呈西北高、东南低的分布特征, 区域海拔为 76.4~6740.0 m; 全省基本属亚热带高原季风气候, 立体气候特点显著, 类型众多, 温度随海拔垂直变化明显, 年温差小, 日温差大, 降水地域分布差异大, 干湿季节分明; 由于特殊的地形与气候条件, 云南省的植被资源丰富, 类型多样, 被誉为“植物王国”; 近年来, 受气候变化和人类活动的影响, 云南省的植被发生了显著变化, 总体呈缓慢上升趋势, 空间上呈南高北低、西高东低的分布格局^[47-49]。

3.2 数据来源

本实验所使用的归一化植被指数(NDVI)数据来源于美国航天航空局(NASA)发布的 MOD13A3 数据集^①, 时间跨度为 2001—2020 年, 空间分辨率为 1 km, 时间分辨率为 1 个月。地表温度数据来源于 NASA 发布的 MOD11A1 数据集, 空间分辨率为 1 km, 时间分辨率为 1 d, 基于逐日数据构建逐月数据。温度、降水和土壤湿度数据均来源于国家青藏高原科学数据中心^②, 空间分辨率为 1 km, 时间分辨率为 1 个月。

3.3 地表植被时空变化特征

2001—2020 年云南省的植被整体呈波动上升趋势(变化率为 0.00245/a, $R^2=0.91$, $P<0.05$, 图 2), 其中 2002 年的 NDVI 值最小, 2018 年的最大, NDVI 年平均值为 0.798。植被总体呈现南高北低、西高东低的空间分布格局(图 2), 植被覆盖存在显著地域性差异, 其中滇西、滇西南等地区的植被覆盖较高, 而滇中、滇西北、滇东北等地区的植被覆盖较低。总体而言, 云南省的植被覆盖率较高, 2001—2020 年整体呈上升趋势, 滇中部分区域可能由于气候变化、城市扩张或人类活动的影响, 植被覆盖率有所降低。

3.4 植被变化因果分析

3.4.1 时滞相关分析

鉴于相关性是推断因果关系的前提, 同时考虑植被对气候因子响应的滞后效应^[50], 本

① NASA: <https://landsweb.modaps.eosdis.nasa.gov> [2023-02-16]

② 国家青藏高原科学数据中心: <https://data.tpdc.ac.cn> [2024-03-07]




图 2 2001—2020 年云南省植被时空变化

Fig.2 Temporal and spatial change of vegetation in Yunnan Province from 2001 to 2020

实验通过时滞相关分析方法，确定了云南省植被对气候因子响应的时滞效应。如图 3 所示，当不考虑时间滞后时，NDVI 与温度、降水和地表温度等气候因子的相关系数较小，可能会忽略它们对植被的潜在影响；当时间滞后为 1 个月时，NDVI 与土壤湿度的相关系数最大，表明植被对土壤湿度的响应速度最快；当时间滞后增加至 2 个月时，NDVI 与温度和降水的相关系数最大，表明植被对它们的响应速度较快；而当时间滞后为 3 个月时，NDVI 与地表温度的相关系数最大，表明植被对地表温度的响应最不敏感。以上结论表明：植被对气候因子的响应存在显著的滞后效应，并且这种滞后效应因气候因子的不同而存在一定差异。滞后效应同时体现了因果关系的方向性，即原因在前，结果在后，为后续因果分析提供了重要基础。

3.4.2 PCMCI 因果分析

尽管考虑时间滞后效应后，植被 NDVI 与不同气候因子的相关系数显著增大，但相关不等于因果。因此，为探究植被与气候因子的因果作用关系，并量化因果效应，本实验基于 PCMCI 方法构建了植被 NDVI 与温度、降水、地表温度和土壤湿度等气候因子间的因果关系网络。研究表明，PCMCI 模型很好地揭示了云南省植被与气候因子间的因果作用机制(图 4)，其中，植被对温度、降水、地表温度和土壤湿度等气候因子表现出一定时间滞





图3 云南省植被 NDVI(归一化差值植被指数)与气候因子的时滞相关分析
Fig.3 Time-lag correlation analysis between vegetation NDVI and climate factors in Yunnan Province



箭头表示因果作用方向, 无向边由于没有检测到时间滞后, 无方向; 线条上数字表示时间滞后, 单位是月; t 为时间序列的长度, 单位是月; NDVI 归一化差值植被指数、Pre 降水、Tem 温度、LST 地表温度、SM 土壤湿度

图4 云南省植被变化因果网络
Fig.4 Causal network of vegetation change in Yunnan Province


后, 当时间滞后为 1 个月时, 植被与降水间存在因果作用路径, 表明植被对降水的响应速度较快, 当时间滞后为 2 个月时, 植被与温度、地表温度和土壤湿度间均存在因果作用路径, 表明植被对其响应速度较慢。研究表明: 温度、降水、地表温度和土壤湿度等气候因子在一定时间滞后条件下, 对植被均有一定影响, 与先前的研究结果基本一致^[46, 51-52]。

3.4.3 CCM 因果分析

基于时滞相关分析与 PCMCi 因果分析, 确定云南省植被对气候因子响应的时间滞后, 构建因果网络。然而, 在确定性较高的动态系统中, CCM 方法具有更强的因果检测能力, 而 PCMCi 的检测能力较弱^[15]。因此, 为进一步理解植被与气候因子的相互作用关系, 本实验通过 CCM 模型量化植被与气候因子的因果效应。研究结果表明: CCM 很好地揭示了云南省植被与气候因子间显著的双向因果作用关系(图 5), 植被与温度交叉映射的值分别在 0.98 和 0.94 处收敛, 因果效应最强, 表明植被与温度间显著的双向因果关系, 其中主要方向为温度对植被的影响, 同时植被对温度的影响存在一定反馈作用。植被与降水交叉映射的值分别在 0.84 和 0.79 处收敛, 反映了两者间显著的双向因果关系, 但因果效应相对较小, 表明降水对植被的影响较小。植被与地表温度交叉映射的值分别在 0.96 和 0.94 处收敛, 同样反映了两者间显著的双向因果关系, 因果效应仅次于温度。植被与土壤湿度交叉映射的值分别在 0.92 和 0.94 处收敛, 同样反映了两者间显著的双向因果关系, 但植被对土壤湿度的影响更显著。CCM 结果揭示了云南省植被与气候因子间显著的双向因果关系, 其中温度与地表温度是影响植被变化的主导因子, 降水的影响相对较小, 而植被对土壤湿度的影响更显著。

3.4.4 机器学习方法评估影响因子

为进一步验证因果推理分析中确定的因果关系, 本实验通过 XGBoost 回归模型拟合



L 表示时间序列长度, ρ 表示变量间交叉映射的能力, 用于量化因果效应

图 5 云南省植被 NDVI 与气候因子收敛交叉映射结果

Fig.5 Results of convergent cross mapping of vegetation NDVI and climate factors in Yunnan Province

植被 NDVI 变化, 从而得到影响云南省植被变化的特征重要性排序。当不考虑时间滞后时, 在特征重要性排序中, 土壤湿度的排名最高, 表明土壤湿度对植被变化的影响最大, 而温度对植被变化的影响最小(图 6a), 但该结论忽略了植被与气候因子间显著的滞后效应。因此, 我们在考虑时间滞后的情况下, 重新得到影响植被变化的特征重要性排序, 如图 6b 所示, 温度的排名最高, 表明温度对植被变化的影响最大, 其次是地表温度, 而降水对植被的影响最小, 该结果与上述因果分析的研究结果基本一致。虽然 XGBoost 模型在一定程度上能够揭示植被与气候因子间的驱动机制, 但就像前面所说的, 机器学习方法基于黑箱操作, 制约了研究人员对模型逻辑与因果关系的理解。




图 6 影响云南省植被变化的特征重要性排序

Fig.6 Feature importance rank affecting vegetation change in Yunnan Province

3.5 实验结论

本实验基于 NDVI、温度、降水、地表温度和土壤湿度等数据, 分析了 2001—2020 年云南省地表植被的时空变化特征, 并通过因果推理和机器学习方法, 探究了植被与气候因子的因果作用关系, 补充了地表植被变化因果推理研究的不足, 为区域生态系统对气候变化的响应机制研究提供了新的认识, 主要结论如下: ①2001—2020 年云南省的植被覆盖率整体呈上升趋势, 空间分布总体呈南高北低、西高东低的格局, 滇中部分区域可能由于气候变化、城市扩张或人类活动的影响, 植被覆盖率有所下降。②云南省植被对温度、降水、地表温度和土壤湿度等气候因子的响应存在显著时间滞后效应。③PCMCi 与 CCM 共同揭示了云南省植被与气候因子的因果作用关系, 各气候因子对植被都有不同程度的影响, 其中温度与地表温度是影响植被变化的主导因子, 而降水与土壤湿度的影响较小。此外, 实验结果还表明植被对气候因子的影响具有一定反馈作用。XGBoost 模型在揭示植被变化与气候因子的驱动机制方面具有一定效果, 但因果可解释性较弱。

4 地表过程中因果推理的发展方向与挑战

4.1 面临的挑战

1) 因果假设。每个因果结论都需要满足一定假设条件^[4], 例如因果充分性、马尔可夫条件和信实假设等, 对于时序因果推理, 还需要满足无瞬时效应和平稳性的假设。各种不同的假设已被证明可以确定真正的因果作用机制^[53], 但在地表过程的研究中, 满足这些因果假设非常困难, 例如, 因果充分性要求观测到系统中的所有变量, 任何未观测到的变量都可能是其他变量的原因或结果, 这在复杂的地表过程中几乎是不可能实现的。因此, 因

果假设被认为是地表过程中因果研究面临的重要挑战。

2) 因果关系检验。因果关系检验旨在判断检测的因果关系是否正确, 有助于正确理解相互作用背后的因果机制。然而, 在因果推理研究的发展过程中, 始终没有一个统一的理论框架, 由于不同因果推理模型对因果的表达不同, 因果关系的检验也存在一定差异, 这是地表过程中因果推理研究亟需解决的问题。

3) 混杂因素与虚假因果的识别。地表过程作为一个复杂的动力系统, 涉及很多变量和强相互作用过程, 由于对地表过程观测的限制与不足, 隐变量必然存在, 从而产生混杂因素干扰。在混杂因素的影响下, 没有相关性的 2 个变量, 可能存在强相关关系, 进而产生一些虚假因果关系, 导致错误的结论。此外, 混杂因素会导致具有因果关系的两个变量表现出相互独立性^[54], 给因果推理研究带来了巨大挑战。特别是大数据时代的到来, 从复杂、高维的地表过程中识别混杂因素非常困难, 这是阻碍地表过程中因果推理研究发展的主要困难之一。

4) 缺乏验证数据。地学研究可以通过野外调查、室内模拟、数值模拟、数字孪生等多种方式来验证研究结果, 而地学方面的因果推断及检验需要已知因果关系的数据集来验证, 但这些数据集大都来自专家知识, 目前提供的数据很少, Runge 等开发的 `causeme.net` 平台^[7], 可提供部分因果关系明确的数据集, 但还未被广泛使用。目前针对地学因果关系研究或因果推理的专题数据库还很少, 这给因果模型的检验带来一定挑战, 是阻碍地表过程中因果推理研究发展的重要原因之一。

4.2 发展方向

1) 时空因果推理。目前, 时序因果推理仍然是地球系统科学中主流的因果推理方法, 但没有考虑空间信息。近年来, 空间因果推理也引起了越来越多研究者的关注, 但将两者耦合的研究鲜见报道, 缺乏时空一体化的因果推理框架。随着计算机和遥感观测技术的发展, 进入了“地球大数据”时代, 基于地球大数据的强时空关联性, 同时考虑时间和空间 2 个维度, 整合变量的时间序列和空间分布数据, 将时序因果推理与空间因果推理相结合的研究模式, 将是地表过程中因果推理研究的重要方向。

2) 面向地表过程研究的因果推理数据集构建。因果推理方法需要因果关系明确的真实数据或模拟实验数据来验证, 然而目前公开的数据集很少, 严重制约了地表过程中因果推理研究的发展。因此, 为进一步加强地表过程中因果理论的研究及规律的认识, 更多的研究应注重地表过程研究中因果推理数据集的构建, 为相关研究人员提供因果关系可靠的数据, 推动地表过程中的因果推理研究迈向新阶段。

3) 地学因果大模型。因果推理与机器学习有密切的联系, 机器学习促进了因果推理的研究, 同时因果推理也有助于机器学习的发展^[11], 如支持向量机、随机森林和神经网络等机器学习方法可预测潜在的结果, 为因果推理研究提供“反事实”分析基础, Cui 等人利用因果性特征训练神经网络模型, 提升了模型的稳健性^[55]。尽管机器学习方法在很多领域取得了成功, 但大多数是基于黑箱操作, 缺乏可解释性, 而因果推理作为一种强有力的逻辑语言, 可提供解释性分析, 因此因果推理方法与机器学习模型的结合, 将有助于机器学习模型做出可解释的预测与分类。

参考文献(References):

- [1] Runge J, Gerhardus A, Varando G et al. Causal inference for time series[J]. *Nature Reviews Earth & Environment*, 2023, 4(7): 487-505.
- [2] Pearl J. *Causality: Models, reasoning, and inference*[M]. Cambridge: Cambridge University Press, 2009.
- [3] 苏建宾, 陈都鑫, 郑东海, 等. 追索为什么? 地球系统科学中的因果推理 [J]. *中国科学: 地球科学*, 2023, 53(10): 2199-2216. [Su Jianbin, Chen Duxin, Zheng Donghai et al. The insight of why? Causal inference in earth system science. *Sci-*

- ence China Earth Sciences, 2023, 66(10): 2169-2186.]
- [4] Pearl J. Causal inference[J]. Causality: Objectives and Assessment, 2010: 39-58.
- [5] Altman N, Krzywinski M. Points of significance: Association, correlation and causation[J]. Nature Methods, 2015, 12(10).
- [6] Calude C S, Longo G. The deluge of spurious correlations in big data[J]. Foundations of Science, 2017, 22: 595-612.
- [7] Runge J, Bathiany S, Bollt E et al. Inferring causation from time series in Earth system sciences[J]. Nature Communications, 2019, 10(1): 2553.
- [8] 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.
- [9] Karpatne A, Ebert-Uphoff I, Ravela S et al. Machine learning for the geosciences: Challenges and opportunities[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 31(8): 1544-1554.
- [10] Zhang K, Schölkopf B, Spirtes P et al. Learning causality and causality-related learning: Some recent progress[J]. National Science Review, 2018, 5(1): 26-29.
- [11] 王东明, 陈都鑫. 因果推断: 起源和发展 [J]. 控制工程, 2022, 29(3): 464-473. [Wang Dongming, Chen Duxin. Causal inference: Origin and development. Control Engineering of China, 2022, 29(3): 464-473.]
- [12] Granger C W J. Investigating causal relations by econometric models and cross-spectral methods[J]. Econometrica: Journal of the Econometric Society, 1969: 424-438.
- [13] Imbens G W, Rubin D B. Causal inference in statistics, social, and biomedical sciences[M]. Cambridge: Cambridge University Press, 2015.
- [14] Sugihara G, May R, Ye H et al. Detecting causality in complex ecosystems[J]. Science, 2012, 338(6106): 496-500.
- [15] Runge J, Nowack P, Kretschmer M et al. Detecting and quantifying causal associations in large nonlinear time series datasets[J]. Science Advances, 2019, 5(11): eaau4996.
- [16] Pearl J. Causal diagrams for empirical research[J]. Biometrika, 1995, 82(4): 669-688.
- [17] Pearl J. Models, reasoning and inference[M]. Cambridge, UK: Cambridge University Press, 2000.
- [18] Pearl J, Mackenzie D. The book of why: The new science of cause and effect[M]. New York: Basic Books, 2018.
- [19] Pekel J F, Cottam A, Gorelick N et al. High-resolution mapping of global surface water and its long-term changes[J]. Nature, 2016, 540(7633): 418-422.
- [20] Mottl O, Flantua S G A, Bhatta K P et al. Global acceleration in rates of vegetation change over the past 18000 years[J]. Science, 2021, 372(6544): 860-864.
- [21] Casagli N, Intrieri E, Tofani V et al. Landslide detection, monitoring and prediction with remote-sensing techniques[J]. Nature Reviews Earth & Environment, 2023, 4(1): 51-64.
- [22] Guo H D, Zhang L, Zhu L W. Earth observation big data for climate change research[J]. Advances in Climate Change Research, 2015, 6(2): 108-117.
- [23] Ma T J, Chen W, An X D. Quantifying the teleconnections between East Asian winter precipitation and tropical sea surface temperatures using causal analysis[J]. Journal of Geophysical Research: Atmospheres, 2025, 130: e2024JD042689.
- [24] Stuart E A. Matching methods for causal inference: A review and a look forward[J]. Statistical Science, 2010, 25(1): 1.
- [25] Athey S, Imbens G W. Machine learning methods for estimating heterogeneous causal effects[J]. Statistics, 2015, 1050(5): 1-26.
- [26] Chakraborty B, Murphy S A. Dynamic treatment regimes[J]. Annual Review of Statistics and Its Application, 2014, 1: 447-464.
- [27] Gao B, Yang J, Chen Z et al. Causal inference from cross-sectional earth system data with geographical convergent cross mapping[J]. Nature Communications, 2023, 14(1): 5875.
- [28] Spirtes P, Glymour C, Scheines R. Causation, prediction, and search[M]. Cambridge: MIT Press, 2001.
- [29] Gao B, Li M, Wang J et al. Temporally or spatially? Causation inference in earth system sciences[J]. Science Bulletin, 2022, 67: 232-235.
- [30] Papagiannopoulou C, Miralles D G, Decubber S et al. A non-linear Granger-causality framework to investigate climate-vegetation dynamics[J]. Geoscientific Model Development, 2017, 10(5): 1945-1960.
- [31] 王劲峰, 徐成东. 地理探测器: 原理与展望 [J]. 地理学报, 2017, 72(1): 116-134. [Wang Jinfeng, Xu Chengdong. Geodetector: Principle and perspective. Acta Geographica Sinica, 2017, 72(1): 116-134.]
- [32] Ju H, Zhang Z, Zuo L et al. Driving forces and their interactions of built-up land expansion based on the geographical detector—A case study of Beijing, China[J]. International Journal of Geographical Information Science, 2016, 30(11): 2188-2207.
- [33] 丁悦, 蔡建明, 任周鹏, 等. 基于地理探测器的国家级经济技术开发区经济增长率空间分异及影响因素 [J]. 地理科学进展, 2014, 33(5): 657-666. [Ding Yue, Cai Jianming, Ren Zhoupeng et al. Spatial disparities of economic growth rate of

- China's National-level ETDZs and their determinants based on geographical detector analysis. *Progress in Geography*, 2014, 33(5): 657-666.]
- [34] 杨忍, 刘彦随, 龙花楼, 等. 中国村庄空间分布特征及空间优化重组解析 [J]. 地理科学, 2016, 36(2): 170-179. [Yang Ren, Liu Yansui, Long Hualou et al. Spatial distribution characteristics and optimized reconstructing analysis of rural settlement in China. *Scientia Geographica Sinica*, 2016, 36(2): 170-179.]
- [35] Shen J, Zhang N, He B et al. Construction of a GeogDetector-based model system to indicate the potential occurrence of grasshoppers in Inner Mongolia steppe habitats[J]. *Bulletin of Entomological Research*, 2015, 105(3): 335-346.
- [36] Chen Y, Zhao Q, Liu Y et al. Exploring the impact of natural and human activities on vegetation changes: An integrated analysis framework based on trend analysis and machine learning[J]. *Journal of Environmental Management*, 2025, 374: 124092.
- [37] Wang S, Peng H, Hu Q et al. Analysis of runoff generation driving factors based on hydrological model and interpretable machine learning method[J]. *Journal of Hydrology: Regional Studies*, 2022, 42: 101139.
- [38] Liu C, Hu Y, Sun F et al. Quantitative analysis of the driving factors of water quality variations in the Minjiang River in Southwestern China[J]. *Water*, 2023, 15(18): 3299.
- [39] Liu S, Xu J, Wang R et al. Investigating the causal effects of anthropogenic factors on urban streams and lakes water quality by integrating causal inference with interpretable machine learning[J]. *Journal of Cleaner Production*, 2025, 488: 144626.
- [40] Cheng J, Dai X, Wang Z et al. Landslide susceptibility assessment model construction using typical machine learning for the Three Gorges Reservoir Area in China[J]. *Remote Sensing*, 2022, 14(9): 2257.
- [41] Zhao Y, Meng X, Qi T et al. Modeling the spatial distribution of debris flows and analysis of the controlling factors: A machine learning approach[J]. *Remote Sensing*, 2021, 13(23): 4813.
- [42] Zhou J, Huang J, Sun Z et al. Machine learning approaches to debris flow susceptibility analyses in the Yunnan section of the Nujiang River Basin[J]. *PeerJ*, 2024, 12: e17352.
- [43] 金凯, 王飞, 韩剑桥, 等. 1982—2015 年中国气候变化和人类活动对植被 NDVI 变化的影响 [J]. 地理学报, 2020, 75(5): 961-974. [Jin Kai, Wang Fei, Han Jianqiao et al. Contribution of climatic change and human activities to vegetation NDVI change over China during 1982—2015. *Acta Geographica Sinica*, 2020, 75(5): 961-974.]
- [44] Shi Y, Jin N, Ma X L et al. Attribution of climate and human activities to vegetation change in China using machine learning techniques[J]. *Agricultural and Forest Meteorology*, 2020, 294: 108146.
- [45] 耿庆玲, 陈晓青, 赫晓慧, 等. 中国不同植被类型归一化植被指数对气候变化和人类活动的响应 [J]. 生态学报, 2022, 42(9): 3557-3568. [Geng Qingling, Chen Xiaoqing, He Xiaohui et al. Vegetation dynamics and its response to climate change and human activities based on different vegetation types in China. *Acta Ecologica Sinica*, 2022, 42(9): 3557-3568.]
- [46] 燕丹妮, 武心悦, 王博恒, 等. 1982—2015 年黄土高原植被变化特征及归因 [J]. 生态学报, 2023, 43(23): 9794-9804. [Yan Danni, Wu Xinyue, Wang Boheng et al. Characteristics and driving forces of changes in vegetation coverage on the Loess Plateau, 1982—2015. *Acta Ecologica Sinica*, 2023, 43(23): 9794-9804.]
- [47] 徐虹, 刘琴. 2001—2019 年云南省植被 NDVI 变化及其气候因子的关系 [J]. 水土保持研究, 2022, 29(1): 162-168. [Xu Hong, Liu Qin. Analysis of vegetation NDVI dynamic and its relationship with climatic factors in Yunnan Province during 2001—2019. *Research of Soil and Water Conservation*, 2022, 29(1): 162-168.]
- [48] 李加顺, 刘丽. 2000—2020 年云南省植被时空变化及影响因素分析 [J]. 草地学报, 2023, 31(11): 3503-3513. [Li Jiashun, Liu Li. Analysis of the spatiotemporal change and influencing factors of vegetation in Yunnan Province from 2000 to 2020. *Acta Agrestia Sinica*, 2023, 31(11): 3503-3513.]
- [49] 夏凯, 黄义忠. 基于 MODIS-NDVI 的云南省植被时空变化及驱动因素分析 [J]. 南方农业学报, 2023, 54(11): 3427-3437. [Xia Kai, Huang Yizhong. Spatiotemporal changes and driving factors of vegetation in Yunnan based on MODIS-NDVI. *Journal of Southern Agriculture*, 2023, 54(11): 3427-3437.]
- [50] 崔林丽, 史军, 杨引明, 等. 中国东部植被 NDVI 对温度和降水的旬响应特征 [J]. 地理学报, 2009, 64(7): 850-860. [Cui Linli, Shi Jun, Yang Yinming et al. Ten-day response of vegetation NDVI to the variations of temperature and precipitation in eastern China. *Acta Geographica Sinica*, 2009, 64(7): 850-860.]
- [51] 缪丽娟, 余志巍, 何昱, 等. 中国城市植被物候变化及其对地表温度的响应 [J]. 生态学报, 2024, 44(6): 2479-2494. [Miao Lijuan, Yu Zhiwei, He Yu et al. Spatiotemporal variations in vegetation phenology across Chinese major cities and its response to surface temperature. *Acta Ecologica Sinica*, 2024, 44(6): 2479-2494.]
- [52] 白子怡, 薛亮, 张肿. 基于土壤湿度与植被覆盖变化的黄土高原生态恢复项目适宜性评价 [J]. 水土保持研究, 2019, 26(4): 292-298. [Bai Ziyi, Xue Liang, Zhang Chong. Evaluation on suitability of ecological restoration project in the Loess Plateau based on soil moisture and vegetation cover change. *Research of Soil and Water Conservation*, 2019, 26(4): 292-298.]
- [53] Runge J. Causal network reconstruction from time series: From theoretical assumptions to practical estimation[J].

Chaos, 2018, 28 (7): 075310.

- [54] 耿直, 何洋波, 王学丽. 因果链上因果效应的关系及推断 [J]. 中国科学 (A 辑: 数学), 2004(2): 227-236. [Geng Zhi, He Yangbo, Wang Xueli. The relationship and inference of causal effects in the causal chain. Science in China (Ser. A Mathematics), 2004(2): 227-236.]
- [55] Cui P, Athey S. Stable learning establishes some common ground between causal inference and machine learning[J]. Nature Machine Intelligence, 2022, 4(2): 10-115.

Causal inference methods in surface process research: Review and experiment

Wei Tingping¹, Sun Zhengbao², Huang Jiangcheng¹, Zou Chengquan¹

(1. *Institute of International Rivers and Eco-security, Yunnan University, Kunming 650500, Yunnan, China;*

2. *School of Engineering, Yunnan University, Kunming 650500, Yunnan, China*)

Abstract: Exploring the causal relationships among various elements in surface processes and quantifying their causal effects are crucial for understanding the laws of surface changes. In recent years, the rapid development of remote sensing technology and causal inference research has provided opportunities and possibilities for revealing the interaction patterns in multi-scale surface processes based on remote sensing observation data. However, research on causal relationships, causal effects, and causal inference in the field of geoscience is still in its infancy, and the study of the causal mechanisms and laws of multi-scale surface processes still faces many challenges. This article first reviewed the research progress of the theoretical framework and methods of causal inference. Then, we explored the possibility of temporal causal inference methods in attributing surface vegetation changes through experiments. Finally, we summarized the opportunities and challenges faced by causal inference in the study of surface processes. The research results showed that: 1) Causal relationship discovery and causal effect assessment are urgent needs and frontier hotspots in the current research and development of surface processes. However, they still face many challenges, such as overly strong causal assumptions, difficulties in identifying false causal relationships, and a lack of verification datasets. 2) Experimental results based on the spatiotemporal change process of surface vegetation in Yunnan Province from 2001 to 2020 showed that the temporal causal inference methods had a significant effect in discovering the causal relationship and assessing the causal effect of surface vegetation cover changes. Experimental results showed significant causal relationships and lag effects between vegetation and climate factors. Among these factors, temperature and surface temperature are the primary influences on surface vegetation changes in Yunnan Province. At the same time, vegetation has obvious feedback effects on climate factors. 3) In the context of big geographical data and large geoscience models, the construction of datasets to support the verification of causal inference of surface processes, causal inference of spatiotemporal coupling and the interpretable machine learning approaches will be the future development direction.

Key words: causal inference; causal relationship; attribution research; vegetation change; Yunnan Province