



计算机科学

COMPUTER SCIENCE

基于经验动态建模的因果检测研究综述

曹旨昊, 牟少敏, 屈洪春

引用本文

曹旨昊, 牟少敏, 屈洪春. [基于经验动态建模的因果检测研究综述](#)[J]. 计算机科学, 2023, 50(6A): 220600194-12.

CAO Zhihao, MU Shaomin, QU Hongchun. [Review on Causality Detection Based on Empirical Dynamic Modeling](#) [J]. Computer Science, 2023, 50(6A): 220600194-12.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[人工智能可解释性:发展与应用](#)

Explainability of Artificial Intelligence: Development and Application

计算机科学, 2023, 50(6A): 220600212-7. <https://doi.org/10.11896/jsjcx.220600212>

[基于冲突搜索的多智能体路径规划研究进展](#)

Research Progress of Multi-agent Path Finding Based on Conflict-based Search Algorithms

计算机科学, 2023, 50(6): 358-368. <https://doi.org/10.11896/jsjcx.220800151>

[深度强化学习中的知识迁移方法研究综述](#)

Survey on Knowledge Transfer Method in Deep Reinforcement Learning

计算机科学, 2023, 50(5): 201-216. <https://doi.org/10.11896/jsjcx.220400235>

[基于可解释性人工智能的软件工程技术方法综述](#)

Review of Software Engineering Techniques and Methods Based on Explainable Artificial Intelligence

计算机科学, 2023, 50(5): 3-11. <https://doi.org/10.11896/jsjcx.221100159>

[基于轨迹感知的稀疏奖励探索方法](#)

Sparse Reward Exploration Method Based on Trajectory Perception

计算机科学, 2023, 50(1): 262-269. <https://doi.org/10.11896/jsjcx.220700010>

基于经验动态建模的因果检测研究综述

曹旨昊¹ 牟少敏² 屈洪春¹

1 枣庄学院信息科学与工程学院 山东 枣庄 277160

2 山东农业大学信息科学与工程学院 山东 泰安 271018

(czzh@sdau.edu.cn)

摘要 相关性是目前科学研究中重要的分析标准,但是相关关系并不意味着因果关系。随着人们认识到非线性动力学的普遍性,仅仅依靠相关性进行推论,极有可能会得出错误的结论。目前,包括机器学习在内的各种相关性研究算法快速发展,而挖掘变量间因果关联的研究尚处于探索中。经验动态建模理论是一种基于数据驱动的动态系统建模框架,其最大的特点是抛弃了传统数据分析中的公式化方法,仅仅从时间序列中重构动态系统的行为。其核心思想是动态系统可以描述为一组状态在高维空间中受一定规则的驱使随时间演变的过程,可以通过重建随时间演变的状态来对动态系统进行建模。基于经验动态建模理论,通过动态系统中变量的时序数据,可以对变量之间的因果关系进行检测。如果变量 X 是变量 Y 的原因 ($X \Rightarrow Y$),那么变量 X 的信息必须隐含在变量 Y 中,且可以从变量 Y 中恢复。文中首先分析了相关性与因果关系的辩证关系,由于“虚假相关性”和“幻象性相关”现象的存在,相关性并不意味着因果性,缺乏相关性也并不意味着没有因果关联;然后全面介绍基于经验动态建模理论进行因果检测的核心思想,具体地对 Takens 嵌入定理、单纯形投影算法和收敛交叉映射算法的历史发展做了详细总结,动态系统可以描述为一组状态在高维空间中受一定规则的驱使随时间演变的过程,可以通过重建随时间演变的状态来对动态系统进行建模;接着介绍了一些经验动态建模理论改进方法和实际因果检测应用;最后分析了基于经验动态建模因果检测目前存在的一些问题,并对未来发展趋势进行了展望。

关键词: 因果检测;经验动态建模;收敛交叉映射;复杂系统;人工智能

中图法分类号 TP391

Review on Causality Detection Based on Empirical Dynamic Modeling

CAO Zhihao¹, MU Shaomin² and QU Hongchun¹

1 College of Information Science and Engineering, Zaozhuang University, Zaozhuang, Shandong 277160, China

2 College of Information Science and Engineering, Shandong Agricultural University, Taian, Shandong 271018, China

Abstract Correlation is an important analysis standard in current scientific research, but it does not mean causality. As people realize the universality of nonlinear dynamics, it is very likely to lead to wrong conclusions only by relying on correlation. At present, various correlation research algorithms, including machine learning, are developing rapidly, while the research of mining causal correlation between variables is still under exploration. Empirical dynamic modeling theory is a data-driven dynamic system modeling framework. Its biggest feature is to abandon the formulaic method in traditional data analysis and reconstruct the behavior of dynamic system only from time series. The core idea is that a dynamic system can be described as a process in which a group of states evolve over time driven by certain rules in high-dimensional space. The dynamic system can be modeled by reconstructing the states that evolve over time. Based on empirical dynamic modeling theory, the causal relationship between variables can be detected through the time series data of variables in dynamic system. If variable X is the cause of variable Y ($X \Rightarrow Y$), the information of variable X must be implicit in variable Y and can be recovered from variable Y . This paper first analyzes the dialectical relationship between correlation and causality. Correlation does not mean causality, and lack of correlation does not mean no causality. Then it comprehensively introduces the core idea of causality detection based on empirical dynamic modeling theory, and summarizes the historical development of Takens embedding theorem, simplex projection algorithm and convergent cross mapping algorithm. It introduces some improved methods of empirical dynamic modeling theory and practical application of causal detection, and finally looks forward to the future development trend of causal detection based on empirical dynamic modeling.

Keywords Causal detection, Empirical dynamic modeling, Convergent cross mapping, Complex system, Artificial intelligence

基金项目:国家自然科学基金(61902342,62172355);山东省自然科学基金重点项目(ZR2020KE001)

This work was supported by the National Natural Science Foundation of China(61902342,62172355) and Key Projects of Natural Science Foundation of Shandong Province(ZR2020KE001).

通信作者:屈洪春(hchyu@gmail.com)

1 引言

相关性是目前科学中重要的分析标准,生态学、流行病学等许多科学领域的研究人员在展开研究时往往以探索相关关系为目的^[1]。但是随着人们越来越认识到在现实中尤其是生态系统中非线性动力学的普遍性,仅仅依靠因素之间的相关性进行推论,而忽略对因果性的探讨,可能会得出错误的结论。由于动态系统中存在“虚假相关性”和“幻象性相关”现象,变量之间的关系可能会自发改变,一段时间内两个变量之间可能呈正相关,但是一段时间后可能变为负相关。这导致仅仅基于相关性的研究不具有可靠性,因此迫切需要一个更好的研究标准^[2]。

贝克莱在其著作《人类知识原理》中描述到,事件的同时发生并不一定意味着它们有因果关系,即相关性并不意味着因果关系^[3-4]。“月晕而风,础润而雨”是宋代文学家苏洵在《辨奸论》中的著名诗句,意思是月晕出现,那么将要刮风;础石湿润,那么就要下雨。但是月晕不是风产生的原因,湿润的石头也并不会导致下雨。两者看起来高度相关,但却毫无直接因果关联。传统解决因果关系分析的方法是控制变量法,例如医学中的随机双盲实验和互联网行业的 AB 测试。然而由于道德、法律或可行性原因,控制变量法无法适用于所有的场景^[5]。

针对因果性研究,图灵奖得主 Pearl 教授将因果论分成了 3 个阶梯:第一层研究“关联”,第二层研究“干预”,第三层研究“反事实推理”。传统的包括深度学习在内的机器学习算法处于第一个阶梯,以统计学的方式进行计算,虽然在相关性分析上展示出强大能力,但是无法解释两个变量发生的内在因果机理^[5]。例如通过深度学习算法,可以较为精准地拟合出土壤表面温度和 10 cm 深度温度之间关系,但是这种方法却无法解释是土壤表面温度驱使 10cm 深度温度发生变化,还是 10 cm 深度温度驱使土壤表面温度发生变化^[6]。与相关性相比,因果关系严格区分了“原因”变量和“结果”变量,在揭示事物发生机制等方面具有相关性不能替代的重要作用^[7]。

目前包括很多机器学习算法在内的基于相关性的研究快速发展,而挖掘变量间因果关联的研究尚处于不断探索中^[4,8-9]。以 Pearl 教授为代表的一些学者认为,因果研究需要建立在对系统过程理解的基础之上,构造具有可解释性的因果图模型,仅仅通过数据是无法精确探测因果关系的^[8]。但因果图建模过程需要了解系统过程复杂交互背后的机理,需要精准、复杂、专业的领域知识表达。以自然系统为代表的一些动态系统具有开放性、随机性和复杂性的特点,受多种因素的影响而呈现出典型的非线性和混沌特征,随着时间的推移这些因素间的作用也在不断变化,因此因果图的构建是非常困难的^[10]。因此基于观察的时序数据通过无模型的方式推断因果关系是一个非常有价值的研究方向^[11]。

经验动态建模(Empirical Dynamic Modelling, EDM)是一种基于数据驱动的动态系统建模框架,其最大的特点是抛弃了传统数据分析中的公式化方法,仅仅从时间序列中重构动态系统的行为^[12]。EDM 是针对复杂系统因果分析的重要研究方法,被广泛应用于生态、金融、气象、医疗、化学等许多研究领域。

本文主要针对基于 EDM 的因果检测研究开展专门系统性综述研究。本文第 2 节分析了相关性与因果关系之间的辩证关系;第 3 节介绍基于 EDM 进行因果检测的发展历史和核心思想;第 4 节介绍了一些学者针对不同问题所提出的改进方法;第 5 节介绍了基于经验动态建模的因果检测在生态学、金融学和医学等领域的实际应用;第 6 节展望未来发展趋势;最后总结全文。

2 相关性与因果性

在日常交流中,依赖、关联和相关是近义词。然而从科学的角度分析,依赖和关联含义近似,但是与相关的意义不同^[3]。

关联(依赖)是一种非常普遍的关系,表示一个变量提供关于另一个变量的信息。相关性是统计学中更加具体的概念,当两个变量显示增加或减少的趋势时,它们是相关的,通常可以使用皮尔逊相关系数或斯皮尔曼相关系数进行度量。因果性与关联(依赖)存在关系,但是相关性和因果性之间不存在必然关系。

2.1 相关性 ≠ 因果性

“相关关系并不意味着因果关系”,这一观念自 17 世纪被提出以来就产生了广泛的影响^[13]。美国著名科学家 Herbert Simon 曾经这样描述,“即使在统计学的第一门课程中,相关性不代表因果性这句话也牢牢地印在了有抱负的统计学家或社会科学家的脑海中”^[14]。两个事件或过程之间观察到的规律性或相关性既不是事件或过程之间存在因果关系的充分条件,也不是必要条件。各领域学者对于两者之间的关系可通俗地归纳为“建立有意义的相关关系是一回事,而实现从相关关系到因果属性的飞跃则是另一回事”^[15]。

虽然学术界关于因果关系仍没有普遍认可的严格定义^[16],但是直到目前很多学者仍然将相关性误解为因果关联。相关性可以在没有因果关联的情况下发生,这样的相关性可以称为“虚假相关性”(Spurious Correlation),指两个并不具有因果关联的变量之间却具有高相关系数的一种统计现象^[17]。导致这种现象的原因通常可以分为 3 类:数学、方法和因果结构。其中大量的研究集中在因果结构导致的“虚假相关性”。这种现象可以用由相同外部因素驱动的两个独立样本的简单模型加以解释。

例如根据实际经验,气压计读数与暴风雨发生率之间存在非常可靠的相关性。但是这并不意味着低气压计读数会导致暴风雨发生,也不意味着暴风雨发生会导致气压计读数偏低。当绘制出因果结构图后,会发现存在一种“潜在因素”驱动两者同时发生,如图 1 所示,这种潜在的因素被称为混杂变量^[18]。因此虽然两件事情之间没有相互作用,但却表现出强烈的统计相关性。




图 1 因果结构导致的“虚假相关性”

Fig. 1 Spurious correlation due to causal structure

生态学中的莫兰效应(Moran Effect)就是一种典型的“虚假相关性”可能存在的场景^[19]。生态系统通常受到外部环境变量(如降水、气温等)的驱动,许多物种共享相似的环境,这可能会导致非相互作用物种之间的行为存在相关性和同步性,如图2所示。虽然两个种群之间可能存在较强的相关性,但是两者之间并没有直接的因果关联。




图2 生态学中的莫兰效应

Fig. 2 Moran effect in ecology

这种潜在的因果结构导致了两者之间的相关性在某种程度上说是虚假的,传统的统计方法很难检测到第三方“潜在因素”的存在。Ward认为,尽管虚假相关性的知识可能具有实用价值,但其价值取决于是否了解相关性背后的因果结构^[17]。并且在实践中,过度依赖变量之间的相关性得到的结论很有可能最终仅仅为巧合事件。Panczak等针对瑞士不同楼层住户的研究发现,住八楼以上的居民和低楼层住户相比,心血管疾病风险、癌症风险和呼吸系统疾病风险都会降低^[20]。但如果根据这种相关性就得出“居住在高楼层可降低疾病风险”的结论则是不合理的。因此在科学研究中,仅仅通过相关性进行分析具有一定的局限性。

2.2 无相关性≠无因果性

正如相关性并不意味着因果性,缺乏相关性也并不意味着没有因果关联。除了前文所述的“虚假相关性”,在生态学等领域,使用传统的相关性统计分析时,可能还有许多真实的相互作用是不可见的。在动态系统中,以非线性方式相互作用的两个变量可能会呈现正相关性、负相关性或无相关性的周期变化规律,从而给传统的统计分析造成困扰^[2]。


例如,在波罗的海中鱼类和浮游动物两类物种数量的相关性随时间发生变化,时而正向耦合、时而负向耦合、时而则是完全不相关的。生态学家George Sugihara等将这种现象称为“幻象性相关”(Mirage Correlations),意指具有相互作用的两个变量之间的相关性可随动态系统的状态变化而发生改变或消失。例如Lorenz蝴蝶吸引子中两个变量在不同的翅膀上表现出完全相反的相关性^[21]。这种与状态相关的行为是复杂非线性系统的标志特征之一,在自然界中十分普遍。

不仅是自然界这种复杂系统,即使是简单的非线性系统,也会呈现出“幻象性相关”特征,例如下述两个耦合差分方程:


$$X_{t+1} = 3.8X_t(1 - X_t) - 0.02X_tY_t$$

$$Y_{t+1} = 3.8Y_t(1 - Y_t) - 0.08Y_tX_t$$


假设 X 和 Y 初始值分别为0.2和0.5,对这两个变量的时序数据进行相关性分析,结果如图3所示。在 $[60, 70]$, $[260, 270]$ 和 $[840, 850]$ 3段时间内的皮尔逊相关系数 r 分别为0.84, -0.01 和 -0.93 ,即呈现出正相关、无相关性和负相关的特征。尽管这个系统是确定且已知的,但是却缺少固定的相关性指标进行长期的描述。



(a) $r = 0.84$



(b) $r = -0.01$



(c) $r = -0.93$

图3 幻象性相关示例

Fig. 3 Examples of mirage correlations

3 经验动态建模理论概述

EDM理论是加利福尼亚大学Sugihara教授团队于2015年发表在美国国家科学院院刊PNAS中的一篇论文中所提出的基于数据驱动的动态系统建模框架^[12], EDM最大的特点是抛弃了传统数据分析中的公式化方法,仅仅从时间序列中重构动态系统的行为。研究者通过数据驱动的方式预测了2014年加拿大弗雷泽河鲑鱼、太平洋沙丁鱼和大西洋门哈登鱼的鱼群数量,其预测结果比以往的任何建模方法都更精准。同年,DeAngelis等在PNAS上发表了主题评论文章,高度肯定了EDM理论,并认为随着计算机运算能力的提高,基于数据驱动的建模方法将有望改变传统模型方程在动态系统研究中占据统治地位的局面,为复杂动态系统分析开辟一条全新的研究途径^[22]。

EDM起源并应用于生态学,然后逐渐扩展到金融、化学、农业、工业等领域。在EDM被提出之前,许多科学领域使用模型方程近似拟合实际情况,解释历史观察值和预测未来值。在大部分情况下,这些方程基于先验知识进行建模,但先验知识的提炼过程十分复杂。同时动态系统的非线性特征导致传统模型方程对结构和参数非常敏感,随着系统状态的变化,模型参数也在不断发生变化,这会导致“临时拟合”现象,以致于模型完全参数化是几乎不可能的,模型也很难对未来做出准确预测^[12]。另一方面,非线性和动态性在复杂系统中普遍存在,这表明传统线性方法(主成分分析算法、K均值聚类算法、各种回归算法等)不适用,因为线性方法主要基于相关性展开研究。因此对于由非线性相互作用的变量组成的动态系统,相关性

虽然潜藏在启发性思维方式中,但从本质上说是错误的。

EDM 理论的核心是 Takens 嵌入定理^[23],即从时间序列数据重建系统奇异吸引子(Strange Attractor)的数学理论,该方法最初由 Takens 开发,并由其他研究者不断扩展^[24]。EDM 包含了一系列的基于状态空间重构(State Space Reconstruction, SSR)即延迟坐标值嵌入的非线性方法^[25]。SSR 起源于非线性系统的不可分离性,不可分离性表示通过单一变量信息可以得到整个系统的动力学信息^[16]。EDM 中这些方法不使用任何模型方程,而是从时间序列数据中重构动态系统的行为,从数据中推断模式和关联而不使用模型方程具有更高的灵活性。这些方法可以被描述动态系统的一些基本属性,包括复杂性、可预测性和非线性,并识别系统中变量间的因果关系。

EDM 的逻辑基于这样一个事实:动态系统可以描述为一组状态在高维空间中受一定规则的驱使随时间演变的过程,可以通过重建随时间演变的状态来对动态系统进行建模。高维空间可以称为吸引子流形 M (Attractor Manifold)。吸引子流形 M 的运动可以投影到某一变量对应的坐标轴上,形成某一变量的时间序列,因此系统状态的任何一组连续观察都可以描述为时间序列。当收集了足够的时间序列数据时,可以在高维空间中重构系统动力学行为。

假设我们已知土壤动力学特征受到土壤温度、土壤含水量和土壤微生物活跃度的影响,通过在三维状态空间中分别沿 X 、 Y 和 Z 轴绘制土壤温度、土壤含水量和土壤微生物活跃度相关的时间序列可以重构原始土壤动力学^[26]。随着时间的推移,这 3 个变量绘制了系统状态变化的轨迹,可以直观地查看系统随时间的演变过程,如图 4 所示。变量的轨迹将随时间在三维相空间中追踪一个三维吸引子流形 M 。在任何时刻 t , M 将反映一组微分方程,这些方程将生成一个奇异吸引子, M 上的点趋向于它。土壤系统的瞬时状态可以用吸引子流形 M 上的点描述。




图 4 土壤动态系统状态空间重构

Fig. 4 State space reconstruction in soil dynamic system

在实际情况下,如果原始吸引子流形 M 的基本方程是已知的,则动态系统的复杂性、非线性等属性和变量之间的因果关系易得。例如在前述的耦合差分方程中,系统的复杂程度可以描述为 2,两个变量之间具有双向的因果关系。然而在很多情况下, M 的微分方程是未知的,并且一些变量的数值难以被量化,例如土壤系统中的微生物活跃度是难以测量的。

针对这个问题,可以使用单个足够长的可观察变量 X (如温度或含水量)的时间序列来重构原始吸引子流形 M 的属性。因为如果 X 是 M 在一个方向上的投影,则 Takens 定理证明:可以仅使用单一变量 X 的滞后来重建整个动态系统的确定性发展行为,如图 5 所示。假设变量 X 的原始时间序列

是 $\{x_1, x_2, x_3, \dots\}$,取一段时间序列构成 $X(t)$:

$$X(t) = \{x_t, x_{t-\tau}, x_{t-2\tau}, \dots, x_{t-(E-1)\tau}\}$$

其中,序列长度为 E ,即嵌入维度是 E 。不同时间下的 $X(t)$ 可以形成一个 E 维吸引子流形 M_x ,一般称为影流形(Shadow Manifold),每个 $X(t)$ 表示为 M_x 的一个状态点,点的几何分布特性反应了时间序列所隐含的复杂非线性相互作用。其中嵌入维度 E 的最优值可以通过单纯形投影算法进行估计。重构 M_x 的嵌入维度 E 不需要和 M 的维度完全相同。在数学中 M_x 和原始 M 是微分同胚的,保持了 Lyapunov 指数、熵、不稳定周期轨道等非线性动力学特性, M_x 中点的局部邻域映射到原始 M 的局部邻域,依据拓扑不变性, M_x 保留了原始流形 M 的基本特征。




图 5 单一变量滞后重构动态系统

Fig. 5 Reconstruction of dynamic system through single variable lagged coordinates

3.1 Takens 嵌入定理

Takens 嵌入定理起源于早期对混沌运动的研究,自从美国大气学家 Lorenz 于 1963 年发现混沌运动后^[27],几乎所有学科领域都涌现出对混沌现象的分析,表明了自然界很多现象都是非线性的^[28]。1980 年 Packard 等提出了一种延时坐标方法,该方法利用标量时序数据重构奇异吸引子^[29],对后续研究产生了深远影响。

Takens 嵌入定理表明,每个变量都包含关于所有其他变量的信息,这允许仅从单个时间序列研究系统,方法是将单个变量的时滞坐标作为其他变量的一种表示^[23]。同时每个变量可以被视为系统状态在特定坐标轴上的一个投影,即每个变量的时间序列只是系统运动随时间在特定轴上的投影,因此每个变量的时间序列都包含原系统动力学的信息。

状态空间重构指对单一变量的一维时间序列按照延迟时间 τ 和嵌入维数 E 重构一个与原系统动力学等价的状态空间,研究重构的状态空间可以对原系统进行分析与预测。在重构过程中延迟时间 τ 和嵌入维度 E 是两个重要的参数。如果延迟时间 τ 绝对值太小,会导致 x_t 和 $x_{t-\tau}$ 在数值上非常接近,相关性太强,嵌入坐标在线性意义上成为同一信息表达;如果延迟时间 τ 绝对值太大,由于蝴蝶效应的影响会导致系统动力学特征变化剧烈。因此 τ 的选择既需要保证 x_t 和 $x_{t-\tau}$ 相互独立,又要保证两者差距不太大,在统计学上存在意义。很多研究者针对 τ 数值的选择展开了相关研究^[30],但是在 EDM 实际分析中,当系统数据收集没有过采样时, τ 一般可以直接设置为 1。很多学者研究了嵌入维度 E 的最佳选择问题^[31-32],在 EDM 分析中,一般通过的单纯形投影等算法进行估计。

3.2 单纯形投影算法

单纯形投影算法(Simplex Projection)是一种基于以往时序数据对混沌动力系统的轨迹进行短期预测的方法,是一种

基于相空间重构的无方程预测算法^[33]。该方法的总体思想为:在动态系统中,由以往的时间序列来预测系统的未来行为时,利用邻域点会得到最佳的预测效果^[34]。该方法可以根据预测能力估计时间序列数据构成的吸引子流形 M 的嵌入维数 E 。同时 E 的值在 EDM 中可以描述动态系统的复杂度,也可以定义为重构吸引子所需变量的数量。

由于“蝴蝶效应”的存在,混沌运动具有长期不可预测性,如果确定性规律支配着系统,在短期内,系统运动轨道发散小,混沌在短期内也是可以预测的。只要延迟时间 τ 相对较小,原则上可近似地认为邻域内的点经过时间后 τ 仍保持邻近特性,应用这种相邻特性可从单纯形的演变中经过投影算子来估计预测目标。单纯形投影算法无须建立复杂模型,而是直接根据历史数据序列进行预测,可以避免建模中的人为主观因素。

根据 Takens 嵌入定理,一个系统的动力学特征可以从单一变量的延迟时间序列中恢复,例如变量 x 的延迟时间序列 $\{x_t, x_{t-\tau}, \dots, x_{t-(E-1)\tau}\}$ 。在重构过程中, E 的数值选择较为灵活,不需要和原始系统的复杂度(也可以描述为吸引子的维度) D 完全相同,也不需要和相互作用的变量的数量完全相同。在上述土壤例子中,所假设的系统变量数量为 3;在上述耦合方程例子中,由公式可得变量数量为 2。但是 E 的值存在上限^[35],Whitney 在数学上证明 $E < 2D + 1$ 。在大多数实际情况下, E 的值(系统的复杂度)不是先验知识的,需要进行估计。确定系统嵌入维数 E 一般是进行 EDM 分析的首要步骤^[36]。

当使用单纯形投影算法对时间序列进行分析时,与一些机器学习算法类似,需要将数据分成两部分:一部分是训练集 X ,用于重构吸引子,另一部分是预测集 Y ,用于测试重构模型的预测能力。 x_{t_1} 表示 t_1 时刻的训练集的时序数值, E 个时序数值可以表示一个状态点 $X_{t_1} = \{x_{t_1}, x_{t_1-\tau}, \dots, x_{t_1-(E-1)\tau}\}$, X_{t_1} 是一个 E 维的点。对预测集进行预测时,使用相同的维度 E 处理预测集时序数据。对于预测集上的一个点 $Y_{t_k} = \{y_{t_k}, y_{t_k-\tau}, \dots, y_{t_k-(E-1)\tau}\}$, 计算 Y_{t_k} 和训练集重构吸引子上所有点 X_{t_i} 在状态空间的欧氏距离。假设通过计算得到 $X_{(1)}$ 为最近邻点, $X_{(2)}$ 为第二近邻点,以此类推, $X_{(E+1)}$ 为第 $E+1$ 个近邻点,根据与 Y_{t_k} 不同的距离赋予这 $E+1$ 个近邻点不同的权重。用 $d(\cdot)$ 表示欧氏距离,则其中点 $X_{(i)}$ 的权重 $W_{(i)}$ 可以表示为:

$$W_{(i)} = e^{-\frac{d(Y_{t_k}, X_{(i)})}{d(Y_{t_k}, X_{(1)})}} / \sum_{i=1}^{E+1} e^{-\frac{d(Y_{t_k}, X_{(i)})}{d(Y_{t_k}, X_{(1)})}}$$

在拓扑学中,这 $E+1$ 相邻点可以形成一个最小多边形,即单纯形(Simplex),在嵌入维度 E 下包围了预测点 Y_{t_k} ,因此在单纯形投影算法中,近邻点的个数一般选择为 $E+1$ 。计算这些近邻点 $X_{(1)}, X_{(2)}, \dots, X_{(E+1)}$ 的下一个时间点,记作 $\phi(X_{(1)}), \dots, \phi(X_{(E+1)})$ 。其中, ϕ 表示随着时间流形不断演化,一个 M 上的点所对应的下一个时间点。可以对 Y_{t_k} 的邻域下一个时间点 Y_{t_k+1} 做出预测,且 $Y_{t_k+1} = \phi(Y_{t_k})$,这 $E+1$ 个点的加权平均值就是对 Y_{t_k+1} 的预测值 \hat{Y}_{t_k+1} 。

$$\hat{Y}_{t_k+1} = \sum_{i=1}^{E+1} W_{(i)} \phi(X_{(i)})$$

在原始算法中,可以对不同延迟 T_p 的未来点做出短期预测,当 T_p 越大,预测能力越差。在 EDM 分析中,一般

$T_p = 1$,只通过比较 Y_{t_k+1} 和 \hat{Y}_{t_k+1} 之间的相关系数 ρ 、平均绝对误差(MAE)和均方误差(MSE)等指标来估计预测能力。如果时间序列长度太小,则可以采用留一交叉验证法,只使用一个点作为测试集,剩余点全部作为训练集,充分利用有限的的数据。因此即使在时序数据较少的情况下,单纯形投影算法仍可以得到较好的效果^[33]。

通过设置不同的 E 的值,可以计算得到不同的预测能力,其中预测能力最优时所对应的 E 即为最佳嵌入维度。单纯形投影算法在人类疾病数据、海洋物理和生物等数据^[37]分析中取得了较好的预测效果。单纯形投影算法是 EDM 理论中的基础算法,一些学者将其单一变量嵌入进一步扩展为多变量嵌入和多视角嵌入,进一步提高了预测能力和实用性^[38-39]。Sugihara 又将近邻点扩展为流形上全部的点,称为 S-map 算法,广泛应用于非线性系统的识别中^[40]。通过吸引子流形上的近邻点进行预测的思想对 EDM 理论的发展产生了深远影响^[41-42]。

3.3 收敛交叉映射算法

诺贝尔经济学奖得主 Granger 在 1969 年以预测性作为标准提出了一种检测因果关系的框架^[5],一般称为格兰杰因果关系框架(Granger Causality, GC)。GC 以预测能力而不是相关性作为时间序列因果关系的标准,它假设系统具有可分离性,即原因可以与结果相分离,一个变量可以直接从系统中剔除。如果在移除变量 X 后对变量 Y 的预测效果下降,则认为变量 X 具有可以提高变量预测效果的信息,变量 X 是变量 Y 发生的原因。GC 在具有可分离性的系统中是可行的^[43],并且在经济学等领域取得了巨大的成功。但是 GC 不适用于动态系统^[44],因为可分离性是纯随机和线性系统的特征,动态系统变量间可能存在相互作用,不具有可分离性,因果机制往往交织在同一个时间序列之中,如 2.2 小节中的耦合差分方程。在实验中,孔雀鱼优先吃果蝇或蠕虫取决于哪类被捕食者数量更多,因此孔雀鱼对果蝇的捕食强度会根据蠕虫数量变化而变化,这种捕食切换行为表示了一种非线性状态依赖,因此无法在研究中把蠕虫直接从系统中删除。

2012 年加利福尼亚大学 Sugihara 等发表在 Science 的论文中^[2]提出了针对动态系统时序数据因果检测的收敛交叉映射算法(Convergent Cross Mapping, CCM)。CCM 基于众多前人研究成果^[45-47],其核心思想上是:如果变量 X 是变量 Y 的原因($X \Rightarrow Y$),那么变量 X 的信息必须隐含在变量 Y 中,且可以从变量 Y 中恢复。

动态系统的特点之一是变量之间存在非线性的相互影响,由此会产生混沌现象,且变量之间呈现出不可分离、弱到中度耦合的特征,这导致 GC 无法进行因果检测。针对这个问题,CCM 依据变量 Y 能够由变量 X 可靠推出的程度,判断 $X \Rightarrow Y$ 方向上(即 X 导致 Y 发生)的因果关系强度。CCM 是一种数据驱动的方法,不需要假设任何方程和先验知识,而是直接从变量的时间序列中推断出因果关系。研究者使用真实的海洋数据进行测试,分析了美国加利福尼亚州海域附近沙丁鱼数量、北凤尾鱼数量、海水表面温度(SST)三者之间的因果关系,证明了这种数据驱动因果检测方法的有效性^[2]。CCM 不是与 GC 相悖的方法,而是在非线性动态系统场景下的一种补充^[48]。GC 适用于纯随机的系统,而非线性动态系统是确定性的并且不是完全随机的,存在潜在的规则(吸引

子流形)控制系统的发展方向. 在动力系统理论中, 如果两个时间序列变量来自同一个动力系统, 则它们之间存在因果关联, 会共享一个吸引子流形 M , 这表明一个变量可以用于识别另一个变量的状态。

例如在“捕食者-被捕食者”模型中, 由于两者之间存在相互作用的因果关联(捕食者 \rightarrow 被捕食者), 则不仅可以从捕食者的时间序列中恢复被捕食者的信息, 也可以从被捕食者的时间序列中恢复捕食者的信息. 在很多实际情况下, 因果作用是单向, 假设环境变量 I 是种群数量 P 的随机环境驱动因素($I \Rightarrow P$), 则可以从 P 中恢复 I 的相关信息, 而无法从 I 中恢复 P 的相关信息. 例如 SST 温度会影响鱼群丰度, 而鱼群丰度不会影响 SST, 因此通过鱼群丰度时间序列可以估计 SST 时间序列, 反之则不行。

CCM 通过测量变量 Y 的历史时序数据可以准确地估计变量 X 的历史时序数据的程度来检测 $X \Rightarrow Y$ 的因果关系, 这种程度可以在数学上被量化为预测能力 ρ , 通常由预测值和实际值的相关系数进行描述, 为了表示直观避免负数也可以使用相关系数的平方进行描述^[49], 有时也可以使用 MAE 和 RMSE^[50]. 预测能力 ρ 越大, 该因果关系强度越高. 当存在因果关系时, 随着采集的变量时间序列长度 L 增加, 这种预测能力也会逐渐增加, 并趋向收敛于一个平稳值。

CCM 的计算过程与单纯形投影算法十分相似, 假设变量 Y 的时间序列是 $\{y_1, y_2, \dots, y_t\}$, 变量 X 的时间序列是 $\{x_1, x_2, \dots, x_L\}$. 通过变量 Y 的时滞重构吸引子流形 M_y , 通过单纯形投影算法得到最佳嵌入维数 E , M_y 上的在 t 时刻的状态点可以表示为 $Y_t = \{y_t, y_{t-\tau}, \dots, y_{t-(E-1)\tau}\}$. 根据重构的 M_y 对同样在 t 时刻的 x_t 值进行预测, 表示为 $\hat{x}_t | M_y$. 寻找 Y_t 在影流形 M_y 上的 $E+1$ 个近邻点, 假设这些近邻点所对应的时刻分别为 $t_{(1)}, t_{(2)}, \dots, t_{(E+1)}$, 可得到所对应的在 M_y 上的状态点是 $Y_{t_{(1)}}, \dots, Y_{t_{(E+1)}}$. 依据这些状态点与 Y_t 的欧氏距离, 根据前文权重公式, 分别赋予不同的权重 W_i . 最终预测在 t 时刻的 \hat{y}_t 可以表示为:

$$\hat{x}_t | M_y = \sum_{i=1}^{E+1} W_i x_{t_{(i)}}$$

在时间序列长度 L 足够长且没有噪声的理想情况下, \hat{x}_t 的值将收敛于真实值 x_t , 此时 ρ 趋向等于 1, 这是收敛现象的数学原理。

CCM 依据预测能力检测因果关系, 与单纯形投影算法有相似之处, 但是单纯形投影算法本质是对未来的值(即动态系统的演化规律)进行预测, CCM 是对变量之间互相蕴含的信息进行估计, 并不预测系统的演化规律, 因此可以避免混沌现象造成的信息丢失。

3.3.1 双向因果关系

双向因果关系指两个变量之间具有相互作用的因果关联($X \Rightarrow Y$), 同时也是 Takens 嵌入定理讨论的主要情况. 如果变量是相互耦合的, 它们将在两个方向上存在 CCM 收敛现象。

Takens 嵌入定理证明一个系统的动力学特征可以从单一变量的延迟时间序列中恢复. 一个系统所包含的全部变量的演化轨迹和状态点构成了原始吸引子流形 M . 假设该系统包含了 X 和 Y 两个变量, 且 X 和 Y 之间存在相互作用的因果关联. 通过 X 和 Y 的时间滞后所分别重构的影流形记作

M_x 和 M_y . M, M_x 和 M_y 3 个流形之间是微分同胚的, 保持了拓扑不变性^[36], 其上的状态点在 3 个流形之间存在 1-1 的映射关系, 如图 6 所示。




图 6 状态点在 3 个流形之间存在 1-1 的映射关系

Fig. 6 State points have a 1-1 mapping relationship between three manifolds

当用于重构的变量时间序列长度 L 增加时, 所重构的吸引子流形的密度也会增大, 吸引子轨迹会更加清晰, 基于近邻点进行预测的准确性也随之提高, 预测能力 ρ 趋向收敛于一个平稳值. 收敛性是存在因果关系的必要条件, 是区分因果关系和相关性的关键属性, 表明 L 和预测能力 ρ 之间存在正相关. 为了表示这种收敛性, 可以随机从时间序列中抽取不同长度 L 重建状态空间, 并计算不同 L 下的预测能力 ρ , 其中 L 最小值等于系统嵌入维度, 最大值为采集到的全部时序数据长度. 当该系统是确定性的并且没有噪声时, L 趋于无穷大时, 预测能力 ρ 将趋向 1. 但是在实际应用中, 通过时序数据构建的吸引子流形 M 仅是真实系统的低维近似, 收敛将受到观测误差、过程噪声和采集序列长度的限制^[51], 预测能力 ρ 通常会收敛于小于 1 的平稳值. 并且预测能力 ρ 越高, 表示该方向上的因果关联性越强。

以 2.2 节中的耦合差分方程为例, 虽然 X 与 Y 之间存在双向因果关系, 但是从参数可知 $X \Rightarrow Y$ 方向的因果关系比 $Y \Rightarrow X$ 强度更高. 使用 CCM 分析时, 虽然两个方向都呈现出收敛趋势, 但是 $X \Rightarrow Y$ 方向的预测能力 ρ 更高, 实验结果如图 7 所示。




图 7 双向因果关系的 CCM 收敛情况

Fig. 7 CCM convergence of bidirectional coupling

3.3.2 单向因果关系

在很多实际情况下, 两个变量之间的因果关系不是双向的, 只存在单向因果 $X \Rightarrow Y$, 变量 X 影响 Y , 而 Y 对 X 没有影响. 这经常发生在 X 是一种外部环境变量时, 此时可以从 Y 中得到 X 的信息, 而无法从 X 中得到 Y 的信息, 这和 GC 的思路正好相反。

在这种情况下, 信息流向是单向的. M_y 是与原始 M 微分同胚的有效影流形, M_y 中同时包含 Y 和 X 的信息. 而 M_x 中仅包含 X 的信息, 不存在 Y 的信息, 因此 M_y 和 M 上的

状态点不存在 1-1 映射关系^[52]。使用 CCM 分析时,在此方向上预测能力 ρ 不存在收敛现象,并且非因果方向 $Y \Rightarrow X$ 得到的 ρ 小于正确因果方向 $X \Rightarrow Y$ 得到的 ρ 。

将 2.2 节中耦合差分方程改为单向因果关系,删除 $X \Rightarrow Y$ 方向的因果联系,再使用 CCM 进行分析,实验结果如图 8 所示。可以看出, $X \Rightarrow Y$ 方向不存在收敛现象,表明该方向不存在因果关系;而 $Y \Rightarrow X$ 方向存在明显的收敛现象,表明该方向存在因果关系。

$$X_{t+1} = 3.8X_t(1 - X_t) - 0.02X_tY_t$$

$$Y_{t+1} = 3.8Y_t(1 - Y_t) - 0.08Y_t$$




图 8 单向因果关系的 CCM 收敛情况

Fig. 8 CCM convergence of unidirectional causality

典型的单向因果关系案例就是 Sugihara 等使用 CCM 分析了沙丁鱼数量、凤尾鱼和 SST 之间的关系^[2]。由实验结果的曲线的收敛性可以看出,SST 对两种鱼群数量有明显的因果关系,而两种鱼群之间、两种鱼群对 SST 不存在因果关系,这与人类的常识是一致的。

3.3.3 复杂网络关系

由于自然环境的复杂性,系统中往往不仅仅涉及两个变量之间的因果关系,同时还包含了复杂的网络关系。这种因果网络与 Pearl 教授提出的结构因果模型 (Structural Casual Model, SCM) 具有相似之处,但是 SCM 主要用于分析大量的统计学无序数据^[18],CCM 主要用于分析时间序列数据。例如生态系统中的莫兰效应,如图 2 所示,两个种群 A 和 B 不存在相互作用,但都受到共同的环境变量 Z 的影响。这在 SCM 中可以表示为分叉结构,A 和 B 在 Z 的条件下相互独立,若 Z 不是确定的,则 A 和 B 存在依赖性,但是无论哪种情况 A 和 B 之间都不存在交叉收敛现象,因为两个变量之间没有因果关系,这说明 CCM 可以区分因果性与相关性。而 $Z \Rightarrow A$ 与 $Z \Rightarrow B$ 方向存在收敛现象,因为环境变量 Z 的信息可以从变量 A 或 B 中恢复。

使用 CCM 分析复杂系统的因果网络时,因果关系具有可传递性。例如,如果狐狸捕食兔子,同时兔子吃草,则狐狸和草之间存在传递性的因果关系。即 $X \Rightarrow Y$ 同时 $Y \Rightarrow Z$,则表明 $X \Rightarrow Z$, $X \Leftrightarrow Y$ 同时 $Y \Leftrightarrow Z$,则表明 $X \Leftrightarrow Z$,如图 9 所示。传递性为 CCM 分析复杂网络关系提供了便利。




图 9 直接因果关联和间接因果关联

Fig. 9 Direct causality and indirect causality

4 因果检测的一些改进方法

自从基于 EDM 的因果检测方法被提出后,很多研究者

提出了一些改进方法,主要集中在考虑时间延迟、预测能力 ρ 评断标准、改进重构流型 M 方法以及合理注入噪声 4 个方面。

4.1 考虑时间延迟

尽管 CCM 算法成功应用于各种动态系统因果识别中,但 Sugihara 等观察到异常强烈的单向因果关系 $X \Rightarrow Y$ 会导致一种“同步”现象。此时响应变量 Y 的状态由驱动变量 X 的状态控制,整个系统“坍塌”到受驱动变量 X 控制^[53]。尽管 Y 对 X 没有因果影响,但可以通过 Y 的信息得到 X 的信息,在两个方向上都出现交叉收敛现象^[26]。因此 CCM 无法准确识别双向因果关系和强单向驱动造成的“同步”现象^[54]。

针对这个问题,Hao 等提出了一种扩展 CCM 算法^[54],一般称为 ECCM,是最重要的 CCM 改进方法之一。根据因果论的一般概念,因果关联的发生不是瞬时的,原因会在结果之前发生。通过设置不同时间延迟,根据最佳预测能力 ρ 判断,可以确定驱动变量是否对响应变量存在时间延迟,同时对直接和间接因果关系也有一定的识别能力。在强单向驱动造成的“同步”时(假设因果关系 $X \Rightarrow Y$),这种方法会在真正因果方向上 $X \Rightarrow Y$ 检测到负滞后,而在 $Y \Rightarrow X$ 方向上检测到正滞后。因为响应变量 Y 更适合预测驱动变量 X 的历史值,而驱动变量 X 更适合预测响应变量 Y 的未来值。ECCM 通过这种方式区分双向因果关系和“同步”现象。

针对 ECCM 计算繁琐的问题,Ge 等提出了一种新型的 SWGECCM 算法。该算法在 ECCM 基础上引入了一种滑动窗口技术,能够给因果关系提供更加直观和详细的解释,可以识别不同时延下耦合变量的因果关系和强弱,提高了在实际应用中的价值^[55]。

4.2 改进预测评断标准

当时间序列长度 L 较小时,CCM 收敛效果不佳。针对这个问题,Ma 等提出了一种针对短期时间序列的因果检测方法 CMS,利用两个变量之间的交叉图的平滑度检测因果关系。这种方法结合了神经网络使用吸引子流形上状态点周围点的交叉映射特征,而不使用全局信息,因此即使在数据量较小时,也能取得较好的因果检测效果^[56]。

Ma 等为 CCM 提出了一种新型的 CME 评判分数,通过构建真实值和预测值之间的距离矩阵,利用矩阵的迹评断预测能力 ρ 。这种方法不仅提高了因果检测的准确度和鲁棒性,同时可以用于识别动态系统中变量值之间的时间延迟^[57]。

Harnack 等的研究发现,不同变量重构吸引子流形 M_i 之间的映射展开不仅可以反映定向耦合强度,同时反映了系统时变状态的依赖性。基于此他们定义了一种新型的因果指数,为因果关系强度提供了一种新型度量方法^[58]。

虽然 EDM 是一种无方程建模方法,但是需要重构吸引子流形时延迟时间 τ 和嵌入维度 E。Wang 等提出了一种改进的 CCM 方法来进行吸引子流形重构时的参数选择和阈值确定问题。该方法基于伪最近邻理论确定最佳嵌入维度 E,并使用蒙特卡罗模拟来评估收敛阈值^[59]。

针对某些场景下数据中噪声会干扰因果预测的问题,Diaz 等于提出了一种更加鲁棒的 RCCM 方法。该方法依赖于时间引导决策分数和更严格的交叉映射技能分数,将 CCM 与信息几何因果推理方法相结合,用于解决强瞬态变量耦合

以及 CCM 对噪声敏感的问题^[60]。

4.3 改进重构流型方法

Mccracken 等发现,在某些情况下 CCM 会得到与因果关系的直观概念不一致的错误结论^[49],并且很大程度上取决于系统底层参数。因此提出了一种改进方法 PAI,在 CCM 中引入了多变量嵌入的思想^[38],状态点被定义为 $X_p = \{x_p, \dots, x_{t_i - (E-1)\tau}, y_p\}$,结合变量 X 和 Y 的时间序列共同估计 \hat{x} 的值,提高了 CCM 方法的实用性。

Cummins 等为 CCM 因果分析方法建立了精确的数学理论模型,并使用连续性检测算法对 CCM 进行了改进,使其更符合底层数学理论^[43]。Clark 等针对部分生态系统采集时间序列长度较短的问题,将 CCM 与结合露珠回归法相结合,并使用 Bootstrapping 技术重复抽样以重构吸引子流形,提高了从短时间序列中检测因果关系的能力^[61]。

为了充分利用有限的数据进行重构吸引子流形, Krakovská 等提出了一种基于状态空间重构的混合预测法用于检测因果关系。该方法不再使用 X 和 Y 的时间序列分别重构 M_x 和 M_y ,而是使用 X 和 Y 共同重构吸引子流形 M_{x+y} 进行预测^[62]。

因果关系具有传递性,而直接因果关系才能反映现象之间本质的内在互作机制。Leng 等提出了一种偏交叉映射方法 PCM。通过 X, Y 和 Z 的时间序列重构影流形 M_x, M_y 和 M_z ,并通过交叉图判断直接因果 $X \Rightarrow Z$ 或间接因果 $X \Rightarrow Y \Rightarrow Z$ 。因此 PCM 可以区分复杂动力系统中的直接与间接因果^[63]。

传统 EDM 吸引子流形重构 M 时,假定样本点随时间呈均匀分布,但是在实际应用中,数据经常是不规则采样,从而影响 M 重构过程。Johnson 等提出了一种可基于变步长的改进方法,将样本点的时间间隔融入到左边延迟嵌入中^[64]。

4.4 合理注入噪声

通常认为数据中含有噪声会影响分析的准确性,但是在动态系统中却存在一种反直觉的现象。Jiang 等基于非线性生态系统的实际数据和模型研究,发现噪声可以反直觉地增强定向因果检测的能力,合理地时间序列中注入非对称噪声可以提高动态系统底层重构特性^[65]。同年,Monster 等也发现在某些情况下 CCM 算法会得出错误结论,表现为预测能力 ρ 无法呈现出收敛趋势^[51]。动态系统中噪声的存在降低了 CCM 的预测能力,其收敛值与噪声强弱呈现负相关,因此 Monster 等认为合理地控制噪声注入可以实现更精确的因果推断。

5 因果检测的实际应用

5.1 生态学领域

EDM 理论最早被应用于生态学领域,并在生态学研究中得到了最广泛的使用,因为生态系统是符合 Takens 嵌入定理的确定性动态系统。生态系统的稳定性导致其内部的因果关系也相对稳定,当没有外部影响,物种之间的相互作用不会发生显著的变化。

除了上文所述的鱼群数量和 SST 之间的因果分析,Sugihara 等也将 CCM 用于检测“捕食者 G 猎物”系统中的因果关系,对时间序列进行分析。研究者发现捕食者和猎物之间存在非对称的双向因果关系^[2]。Kawatsu 等分析了昆虫群落的

营养链动态因果相互作用^[66]。McGowan 等研究了加利福尼亚州沿海浮游藻类的动力学特征,研究结果表明这些浮游藻类的不规则现象不是随机产生的,而是外部随机驱动因素导致的非线性种群现象^[67]。Ye 等研究了水库中水位波动和浮游植物生物量的非线性因果关系^[68]。Ushio 等研究了日本尾如湾自然海洋鱼类群落 12 年的历史数据,构建了一个动态相互作用因果网络,实验结果表明夏季生态系统的弱相互作用和较小的种群波动有关^[69]。Cao 等研究了夏季和冬季土壤不同深度下温度和含水量之间的因果关系,用数学的方法描述了不同深度土壤系统各因素之间的因果网络^[6]。

Chang 等为 16 个全球分布的生态系统构建了因果网络,以进一步了解水生生态系统中的生物多样性^[70],如物种多样性的关键因素和传播途径等。Kitayama 使用 CCM 方法研究了热带常绿雨林生物群落,结果表明温度是影响落叶的最主要驱动力^[71]。Shi 等研究了干旱传播问题,重点分析了气象干旱和水文干旱之间的因果关系以及干旱传播的时滞问题^[72]。Doi 等使用 CCM 方法分析了海底颗粒有机碳和温度对海洋物种丰富度的因果效应,为深水循环过程提供了见解^[73]。

5.2 金融领域

与生态系统相比,金融系统由于人类的扰动等因素更加易变^[74],其内部很难存在长期稳定的因果关系。但是金融时间序列具有长记忆性,这使得使用数据驱动的方法来描述经济和金融系统中的动态行为也是合适的^[75]。

Hufaker 等使用 CCM 方法研究了啤酒的促销和销售量之间的动态因果关系。实验结果表明两者之间存在非线性耦合,啤酒的促销和销售量之间的因果关系是双向的,促销对销售量有明显的影 响,同时销售量对促销决策也有长期影响^[76]。Azqueta 研究了新闻媒体叙事方式与加密货币价格之间的因果关系,实验结果表明两者之间存在强烈双向因果关系^[77]。Ge 等将其提出的 SWGECCM 算法应用于金融系统,研究了中美股市道琼斯指数、深证指数等收益率之间的因果关系。研究者发现股票市场中因果关系是时变的,并且高度依赖不可预测的政治事件。这些研究补充和加深了对中美股市时变因果关系的理解^[55]。

5.3 气象学领域

气象系统与生态系统具有相似之处,但是与生态系统相比其作用的范围更广,通常会受到全球性甚至地球外因素的影响,因此高维度和混沌特征更加明显^[78]。

Tsonis 等分析了银河宇宙射线与全球气温逐年变化之间的因果关系,实验结果表明,长期来看,银河宇宙射线与全球气温变化没有较强的因果关联,解决了学术界长久以来的争议^[79]。Wang 等使用 CCM 研究碳循环对热带温度变化的敏感性^[80],分析了大气二氧化碳增长率和地表年平均气温之间的因果关系。Egbert 等研究了气候动力学非线性特征,分析了温度变化和温室气体浓度之间的因果关系^[81]。Wang 等分析了北半球中低纬度地区土壤水分与降水之间的因果关系,明确了土壤水分对降水的影响强度和影响时滞^[82]。Huang 等针对大气系统高维度、混沌的特征,提出了一种时滞 CCM 来检测平流层 G 对流层复杂耦合中的因果关系,并分析了极涡活动引起的因果链^[83]。Zhang 等使用 CCM 分析了东北亚地区西伯利亚高压、冬季地表气温和北半球环行模式之间的

因果关系和反馈效应,为季节性气候变化分析提供了借鉴意义^[84]。

5.4 医疗领域

EDM 理论在医疗领域也有着重要的应用价值,人体内部复杂的生理过程和各类疾病的传播过程都可以看作动态系统,其非线性、动态性和混沌的长时间序列数据为了 EDM 提供了丰富的因果检测应用场景。

Heskamp 等基于 CCM 方法使用动脉血压和脑血流速度的时序数据来评估脑自动调节过程,对于床边监测具有重要的实用价值^[85]。Mcbride 等将 CCM 方法应用于开发新型生物标记物,以区分正常衰老、轻度认知障碍和早期阿尔茨海默病,并捕捉由认知缺陷引起的生物活动特征变化^[86]。Deyle 等应用 CCM 方法通过流行病时间序列研究了流感爆发的全球环境驱动因素和关键阈值,实验结果表明绝对湿度和温度是推动全球流感爆发的原因之一^[87]。Müller 等通过非线性方法研究了人类心血管时间序列数据,为心肺耦合、神经-心脏耦合等复杂生理相互作用提供了重要的见解^[88]。Verma 等研究了人体心脏-姿势-肌肉骨骼系统内部的因果机理,在检测老年人跌倒方面具有潜在的临床实用价值^[89]。传染病的传播具有复杂的动态过程,很难通过拟合模型来检验假设。Cobey 等分析了历史数据中儿童髓灰质炎、流行性腮腺炎、水痘、百日咳等传染病之间的因果关系^[90]。Ma 等研究了香港心血管疾病入院记录和空气污染长期历史数据,揭示了导致疾病的主要空气污染物和隐藏的时间延迟^[57]。

5.5 其他应用

具有时变内部耦合的动态系统在自然界中十分常见,这些系统的完整控制方程通常是未知的,但通常会有一主导元素^[91]。Bozrgmagham 等将 CCM 应用于识别复杂耦合动力系统的主导元素,为 CCM 在多个等动态领域的应用提供了借鉴意义。

在化学过程中,确定故障和干扰原因对于提高安全性非常重要,而化学过程中各类物质之间复杂的、动态的、非线性的交互过程给 EDM 分析提供了应用场景。Luo 等使用改进 CCM 方法确定田纳西 G 伊斯曼等化学过程中的干扰传播路径和传播时间延迟^[92]。Wang 等研究了加氢裂化工艺中反应过程中各类温度参数之间的因果关系^[59]。Xiang 等提出了一种因果分析多视图嵌入方法,用小数据集预测化工过程关键参数的趋势,提高了生产的安全性^[93]。

6 研究展望

基于经验动态建模的因果检测研究已经成为因果分析领域的重要研究方向,该方向进一步的研究工作主要包括 5 个方面:

(1) 基于 EDM 的因果分析理论在很多研究领域得到了广泛的应用,但是从本质上说,其仍然是一种基于纯数学原理的方法,缺乏对特定过程的物理解释。如何提高该方法尤其是预测能力 ρ 变化趋势的可解释性? 如何将该方法与结构因果模型相结合? 这两个问题可能是未来重要的研究方向。

(2) 各种研究表明该方法在变量较少的系统中更加适用。在长期的历史过程中,动态系统也是不断发展变化的,当变量较多时建模过程缺乏稳定性,而吸引子流形在重构过程中需要系统状态之间保持一致性。例如随着鱼群自身进化与

发展,2015 年和 1950 年同一海域的沙丁鱼难以完全相同。而传统的状态空间重构理论是难以捕捉这种时间序列发展规律的,将该方法与机器学习中时间序列分析相结合,挖掘时间序列在演化中的内在规律具有很大的研究空间。

(3) 由于该方法基于状态空间重构理论,因此需要较长的时间序列数据才能保证预测能力可收敛。但是受到采集、实验和技术等很多因素的限制,有时长时间的数据是很难获取的,这会影响因果分析的效果。如何通过数据生成、改进抽样等方法提高在小样本数据时的有效性具有着重要的理论价值和实践意义。

(4) 当数据未充分覆盖状态空间,即存在大量时间段数据缺失时,该方法因果检测效果很差。因为状态空间重构理论假定样本点随时间均匀分布,即采样延迟时间 τ 是固定的。受到采集、实验和技术等很多因素的限制,这个问题在生态学、医学、大气等领域十分常见,经常会出现数据丢失或不规则采样。如何提高数据缺失的因果检测能力,改进状态空间的重构效果有待深入探讨分析。

(5) 虽然目前已经有一些方法可以区分复杂系统的中间接因果关联和直接因果关联,但是这些方法对数据量要求极高并且受到多个因素的约束,导致实用效果较差。迄今为止还没有系统、完善的解决这一问题的有效方法,为该领域的未来工作留下了空间。

结束语 理解复杂系统内变量之间的相互作用是理解系统运行机制的重要依据,基于 EDM 的因果检测是复杂系统分析的重要方法。本文首先分析了相关性与因果关系的辩证关系,接着全面介绍了基于经验动态建模理论进行因果检测的核心思想,然后介绍了一些经验动态建模理论改进方法和实际因果检测应用,最后分析了该方法目前存在的一些问题,并展望未来发展趋势。

参考文献

- [1] ADLER J, PARMRYD I. Quantifying colocalization by correlation: the Pearson correlation coefficient is superior to the Mander's overlap coefficient[J]. Cytometry Part A, 2010, 77(8): 733-742.
- [2] SUGIHARA G, MAY R, YE H, et al. Detecting causality in complex ecosystems[J]. science, 2012, 338(6106): 496-500.
- [3] ALTMAN N, KRZYWINSKI M. Points of Significance: Association, correlation and causation[J]. Nature Methods, 2015, 12(10): 899-900.
- [4] HUANG Y, FU Z, FRANZKE C L E. Detecting causality from time series in a machine learning framework[J]. Chaos: An Interdisciplinary Journal of Nonlinear Science, 2020, 30(6): 063116.
- [5] PEARL J, MACKENZIE D. The book of why: the new science of cause and effect[M]. Basic Books, 2018.
- [6] CAO Z, MU S, XU L, et al. Causal Research on Soil Temperature and Moisture Content at Different Depths[J]. IEEE Access, 2021, 9: 39077-39088.
- [7] PEARL J. Theoretical impediments to machine learning with seven sparks from the causal revolution[J]. arXiv:1801.04016, 2018.
- [8] GRANGER C W J. Investigating causal relations by econometric models and cross-spectral methods[J]. Econometrica: Journal of

- the Econometric Society, 1969; 424-438.
- [9] PEARL J. Causal inference in statistics: An overview[J]. *Statistics surveys*, 2009, 3: 96-146.
- [10] LINDEGREN M, CHECKLEY D M, ROUYER T, et al. Climate, fishing, and fluctuations of sardine and anchovy in the California Current[J]. *Proceedings of the National Academy of Sciences*, 2013, 110(33): 13672-13677.
- [11] PARK J, PAO G M, SUGIHARA G, et al. Empirical mode modeling[J]. *Nonlinear Dynamics*, 2022; 108(3): 2147-2160.
- [12] YE H, BEAMISH R J, GLASER S M, et al. Equation-free mechanistic ecosystem forecasting using empirical dynamic modeling[J]. *Proceedings of the National Academy of Sciences*, 2015, 112(13): E1569-E1576.
- [13] PAGANO R R. Understanding statistics in the behavioral sciences[M]. Cengage Learning, 2012.
- [14] SIMON H A. Spurious correlation: A causal interpretation[J]. *Journal of the American statistical Association*, 1954, 49(267): 467-479.
- [15] GUO F, TIAN L W. Correlation and causality [J]. *National Medical Journal of China*, 2019(10): 790-795.
- [16] MA H, LENG S, CHEN L. Data-based prediction and causality inference of nonlinear dynamics[J]. *Science China Mathematics*, 2018, 61(3): 403-420.
- [17] WARD A. Spurious correlations and causal inferences[J]. *Erkenntnis*, 2013, 78(3): 699-712.
- [18] GLYMOUR M, PEARL J, JEWELL N P. Causal inference in statistics: A primer[M]. John Wiley & Sons, 2016.
- [19] MORAN P A P. The statistical analysis of the Canadian lynx cycle[J]. *Australian Journal of Zoology*, 1953, 1(3): 291-298.
- [20] PANCAK R, GALO BARDES B, SPOERRI A, et al. High life in the sky? Mortality by floor of residence in Switzerland[J]. *European Journal of Epidemiology*, 2013, 28(6): 453-462.
- [21] LORENZ E N. Deterministic nonperiodic flow [J]. *Journal of Atmospheric Sciences*, 1963, 20(2): 130-141.
- [22] DEANGELIS D L, YUREK S. Equation-free modeling unravels the behavior of complex ecological systems[J]. *Proceedings of the National Academy of Sciences*, 2015, 112(13): 3856-3857.
- [23] TAKENS F. Detecting strange attractors in turbulence[M]// *Dynamical Systems and Turbulence*, Warwick 1980. Springer, 1981; 366-381.
- [24] DEYLE E R, SUGIHARA G. Generalized theorems for nonlinear state space reconstruction [J]. *Plos One*, 2011, 6(3): e18295.
- [25] KANTZ H, SCHREIBER T. Nonlinear time series analysis [M]. Cambridge University Press, 2004.
- [26] BRUNTON S L, PROCTOR J L, KUTZ J N. Discovering governing equations from data by sparse identification of nonlinear dynamical systems[J]. *Proceedings of the National Academy of Sciences*, 2016, 113(15): 3932-3937.
- [27] STROGATZ S H. Nonlinear dynamics and chaos: with applications to physics, biology, chemistry, and engineering[M]. CRC press, 2018.
- [28] ASCIOTI F A, BELTRAMI E, CARROLL T O, et al. Is there chaos in plankton dynamics? [J]. *Journal of Plankton Research*, 1993, 15(6): 603-617.
- [29] PACKARD N H, CRUTCHFIELD J P, FARMER J D, et al. Geometry from a time series[J]. *Physical Review Letters*, 1980, 45(9): 712.
- [30] LIEBERT W, SCHUSTER H G. Proper choice of the time delay for the analysis of chaotic time series[J]. *Physics Letters A*, 1989, 142(2/3): 107-111.
- [31] PECORA L M, MONIZ L, NICHOLS J, et al. A unified approach to attractor reconstruction[J]. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 2007, 17(1): 013110.
- [32] KENNEL M B, BROWN R, ABARBANEL H D I. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. *Physical Review A*, 1992, 45(6): 3403.
- [33] SUGIHARA G, MAY R M. Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series[J]. *Nature*, 1990, 344(6268): 734-741.
- [34] FARMER J D, SIDOROWICH J J. Predicting chaotic time series [J]. *Physical Review Letters*, 1987, 59(8): 845.
- [35] WHITNEY H. Differentiable manifolds [J]. *Annals of Mathematics*, 1936; 645-680.
- [36] CHANG C W, USHIO M, HSIEH C. Empirical dynamic modeling for beginners[J]. *Ecological Research*, 2017, 32(6): 785-796.
- [37] HSIEH C, GLASER S M, LUCAS A J, et al. Distinguishing random environmental fluctuations from ecological catastrophes for the North Pacific Ocean[J]. *Nature*, 2005, 435(7040): 336-340.
- [38] DIXON P A, MILICICH M J, SUGIHARA G. Episodic fluctuations in larval supply[J]. *Science*, 1999, 283(5407): 1528-1530.
- [39] YE H, SUGIHARA G. Information leverage in interconnected ecosystems: Overcoming the curse of dimensionality [J]. *Science*, 2016, 353(6302): 922-925.
- [40] SUGIHARA G. Nonlinear forecasting for the classification of natural time series[J]. *Philosophical Transactions of the Royal Society of London. Series A: Physical and Engineering Sciences*, 1994, 348(1688): 477-495.
- [41] KRAKOVSKÁ A, JAKUBÍK J. Implementation of two causal methods based on predictions in reconstructed state spaces[J]. *Physical Review E*, 2020, 102(2): 022203.
- [42] MA H, LENG S, AIHARA K, et al. Randomly distributed embedding making short-term high-dimensional data predictable [J]. *Proceedings of the National Academy of Sciences*, 2018, 115(43): E9994-E10002.
- [43] CUMMINS B, GEDEON T, SPENDLOVE K. On the efficacy of state space reconstruction methods in determining causality[J]. *SIAM Journal on Applied Dynamical Systems*, 2015, 14(1): 335-381.
- [44] ARNOLD A, LIU Y, ABE N. Temporal causal modeling with graphical granger methods[C]// *Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2007; 66-75.
- [45] LE VAN QUYEN M, MARTINERIE J, ADAM C, et al. Nonlinear analyses of interictal EEG map the brain interdependences in human focal epilepsy[J]. *Physica D: Nonlinear Phenomena*, 1999, 127(3/4): 250-266.
- [46] DAVID O, GUILLEMAIN I, SAILLET S, et al. Identifying neural drivers with functional MRI: an electrophysiological validation[J]. *PLoS biology*, 2008, 6(12): e315.

- [47] HLAVÁČKOVÁ-SCHINDLER K, PALUŠ M, VEJMEĽKA M, et al. Causality detection based on information-theoretic approaches in time series analysis[J]. *Physics Reports*, 2007, 441(1): 1-46.
- [48] PALUŠ M, KRAKOVSKÁ A, JAKUBÍK J, et al. Causality, dynamical systems and the arrow of time[J]. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 2018, 28(7): 075307.
- [49] MCCracken J M, WEIGEL R S. Convergent cross-mapping and pairwise asymmetric inference[J]. *Physical Review E*, 2014, 90(6): 062903.
- [50] HSIEH C, OHMAN M D. Biological responses to environmental forcing: the linear tracking window hypothesis [J]. *Ecology*, 2006, 87(8): 1932-1938.
- [51] MØNSTER D, FUSAROLI R, TYLÉN K, et al. Causal inference from noisy time-series data—testing the convergent cross-mapping algorithm in the presence of noise and external influence[J]. *Future Generation Computer Systems*, 2017, 73: 52-62.
- [52] SCHIFF S J, SO P, CHANG T, et al. Detecting dynamical interdependence and generalized synchrony through mutual prediction in a neural ensemble[J]. *Physical Review E*, 1996, 54(6): 6708.
- [53] COUFAL D, JAKUBÍK J, JAJCAY N, et al. Detection of coupling delay: A problem not yet solved[J]. *Chaos: An Interdisciplinary Journal of Nonlinear Science*, 2017, 27(8): 083109.
- [54] YE H, DEYLE E R, GILARRANZ L J, et al. Distinguishing time-delayed causal interactions using convergent cross mapping [J]. *Scientific Reports*, 2015, 5(1): 1-9.
- [55] GE X, LIN A. Dynamic causality analysis using overlapped sliding windows based on the extended convergent cross-mapping [J]. *Nonlinear Dynamics*, 2021, 104(2): 1753-1765.
- [56] MA H, AIHARA K, CHEN L. Detecting causality from nonlinear dynamics with short-term time series [J]. *Scientific Reports*, 2014, 4(1): 1-10.
- [57] MA H, LENG S, TAO C, et al. Detection of time delays and directional interactions based on time series from complex dynamical systems[J]. *Physical Review E*, 2017, 96(1): 012221.
- [58] HARNACK D, LAMINSKI E, SCH? NEMANN M, et al. Topological causality in dynamical systems [J]. *Physical Review Letters*, 2017, 119(9): 098301.
- [59] WANG Y, HU F, CAO Y, et al. Improved CCM for variable causality detection in complex systems[J]. *Control Engineering Practice*, 2019, 83: 67-82.
- [60] DÍAZ E, ADSUARA J E, MARTÍNEZ Á M, et al. Inferring causal relations from observational long-term carbon and water fluxes records[J]. *Scientific Reports*, 2022, 12(1): 1-12.
- [61] CLARK A T, YE H, ISBELL F, et al. Spatial convergent cross mapping to detect causal relationships from short time series [J]. *Ecology*, 2015, 96(5): 1174-1181.
- [62] KRAKOVSKÁ A, HANZELY F. Testing for causality in reconstructed state spaces by an optimized mixed prediction method [J]. *Physical Review E*, 2016, 94(5): 052203.
- [63] LENG S, MA H, KURTHS J, et al. Partial cross mapping eliminates indirect causal influences [J]. *Nature communications*, 2020, 11(1): 1-9.
- [64] JOHNSON B, MUNCH S B. An empirical dynamic modeling framework for missing or irregular samples[J]. *Ecological Modelling*, 2022, 468: 109948.
- [65] JIANG J J, HUANG Z G, HUANG L, et al. Directed dynamical influence is more detectable with noise[J]. *Scientific Reports*, 2016, 6(1): 1-9.
- [66] KAWATSU K, USHIO M, VAN VEEN F J F, et al. Are networks of trophic interactions sufficient for understanding the dynamics of multi-trophic communities? Analysis of a tri-trophic insect food-web time-series [J]. *Ecology Letters*, 2021, 24(3): 543-552.
- [67] MCGOWAN J A, DEYLE E R, YE H, et al. Predicting coastal algal blooms in southern California [J]. *Ecology*, 2017, 98(5): 1419-1433.
- [68] YE L, TAN L, WU X, et al. Nonlinear causal analysis reveals an effective water level regulation approach for phytoplankton blooms controlling in reservoirs [J]. *Science of The Total Environment*, 2022, 806: 150948.
- [69] USHIO M, HSIEH C, MASUDA R, et al. Fluctuating interaction network and time-varying stability of a natural fish community [J]. *Nature*, 2018, 554(7692): 360-363.
- [70] CHANG C W, MIKI T, YE H, et al. Causal networks of phytoplankton diversity and biomass are modulated by environmental context [J]. *Nature Communications*, 2022, 13(1): 1-11.
- [71] KITAYAMA K, USHIO M, AIBA S I. Temperature is a dominant driver of distinct annual seasonality of leaf litter production of equatorial tropical rain forests [J]. *Journal of Ecology*, 2021, 109(2): 727-736.
- [72] SHI H, ZHAO Y, LIU S, et al. A new perspective on drought propagation: Causality [J]. *Geophysical Research Letters*, 2022, 49(2): e2021GL096758.
- [73] DOI H, YASUHARA M, USHIO M. Causal analysis of the temperature impact on deep-sea biodiversity [J]. *Biology Letters*, 2021, 17(7): 20200666.
- [74] WEN C, YANG J. Complexity evolution of chaotic financial systems based on fractional calculus [J]. *Chaos, Solitons & Fractals*, 2019, 128: 242-251.
- [75] WANG Z, HUANG X, SHI G. Analysis of nonlinear dynamics and chaos in a fractional order financial system with time delay [J]. *Computers & Mathematics with Applications*, 2011, 62(3): 1531-1539.
- [76] HUFFAKER R, FEARNE A. Empirically testing for dynamic causality between promotions and sales beer promotions and sales in england [C] // 2014 International European Forum. 2014: 17-21.
- [77] AZQUETA-GAVALDÓN A. Causal inference between cryptocurrency narratives and prices: Evidence from a complex dynamic ecosystem [J]. *Physica A: Statistical Mechanics and its Applications*, 2020, 537: 122574.
- [78] VISSIO G, LUCARINI V. A proof of concept for scale-adaptive parametrizations; the case of the Lorenz'96 model [J]. *Quarterly Journal of the Royal Meteorological Society*, 2018, 144(710): 63-75.
- [79] TSONIS A A, DEYLE E R, MAY R M, et al. Dynamical evidence for causality between galactic cosmic rays and interannual variation in global temperature [J]. *Proceedings of the National Academy of Sciences*, 2015, 112(11): 3253-3256.

- [80] WANG X, PIAO S, CIAIS P, et al. A two-fold increase of carbon cycle sensitivity to tropical temperature variations[J]. *Nature*, 2014, 506(7487): 212-215.
- [81] VAN NES E H, SCHEFFER M, BROVKIN V, et al. Causal feedbacks in climate change[J]. *Nature Climate Change*, 2015, 5(5): 445-448.
- [82] WANG Y, YANG J, CHEN Y, et al. Detecting the causal effect of soil moisture on precipitation using convergent cross mapping [J]. *Scientific Reports*, 2018, 8(1): 1-8.
- [83] HUANG Y, FRANZKE C L E, YUAN N, et al. Systematic identification of causal relations in high-dimensional chaotic systems; application to stratosphere-troposphere coupling[J]. *Climate Dynamics*, 2020, 55(9): 2469-2481.
- [84] ZHANG N, WANG G. Detecting the causal interaction between Siberian high and winter surface air temperature over northeast Asia[J]. *Atmospheric Research*, 2020, 245: 105066.
- [85] HESKAMP L, MEEL-VAN DEN ABELEN A S, LAGRO J, et al. Convergent cross mapping: a promising technique for cerebral autoregulation estimation [J]. *Int. J. Clin. Neurosci. Ment. Heal. S.*, 2014, 20.
- [86] MCBRIDE J C, ZHAO X, MUNRO N B, et al. Sugihara causality analysis of scalp EEG for detection of early Alzheimer's disease[J]. *NeuroImage: Clinical*, 2015, 7: 258-265.
- [87] DEYLE E R, MAHER M C, HERNANDEZ R D, et al. Global environmental drivers of influenza[J]. *Proceedings of the National Academy of Sciences*, 2016, 113(46): 13081-13086.
- [88] MÜLLER A, KRAEMER J F, PENZEL T, et al. Causality in physiological signals [J]. *Physiological Measurement*, 2016, 37(5): R46.
- [89] VERMA A K, GARG A, XU D, et al. Skeletal muscle pump drives control of cardiovascular and postural systems[J]. *Scientific Reports*, 2017, 7(1): 1-8.
- [90] COBEY S, BASKERVILLE E B. Limits to causal inference with state-space reconstruction for infectious disease[J]. *PLoS One*, 2016, 11(12): e0169050.
- [91] BOZORGMAGHAM A E, MOTESHARREI S, PENNY S G, et al. Causality analysis; identifying the leading element in a coupled dynamical system[J]. *PLoS One*, 2015, 10(6): e0131226.
- [92] LUO L, CHENG F, QIU T, et al. Refined convergent cross-mapping for disturbance propagation analysis of chemical processes[J]. *Computers & Chemical Engineering*, 2017, 106: 1-16.
- [93] XIANG S, BAI Y, ZHAO J. Medium-term prediction of key chemical process parameter trend with small data[J]. *Chemical Engineering Science*, 2022, 249: 117361.



CAO Zhihao, born in 1992, Ph.D, lecturer, is a member of China Computer Federation. His main research interests include artificial intelligence and complex systems.



QU Hongchun, born in 1979, Ph.D, professor, Ph.D supervisor, is a member of China Computer Federation. His main research interests include complex systems and artificial intelligence.