

因果驱动的空天信息智能解译

孟瑜^{1,2}, 张正^{1,2}, 席智浩¹, 陈静波^{1,2}, 邓利高^{1,2},
邓毓弼¹, 孔赞珑¹

1. 中国科学院空天信息创新研究院 国家遥感应用工程技术研究中心, 北京 100094;

2. 中国科学院大学 电子电气与通信工程学院, 北京 101408

摘要: 空天信息智能解译是利用人工智能技术对从空天平台获取的多源数据进行智能化处理和解读以获得信息的过程。目前主流的数据驱动型智能解译模型主要利用大规模训练数据和先进网络结构提升解译性能, 存在大量标注数据依赖、场景泛化适应性不稳定、模型缺乏解释性等问题。因果驱动的智能解译通过结合因果推理与深度学习, 能够有效缓解上述问题以实现更高效、更可靠、更具鲁棒性的解译, 有望成为新的空天信息智能解译范式。本文主要对空天信息解译模型结合因果理论的研究工作进行综述, 首先从关联、相关和因果认知三个方面阐述空天信息解译的研究趋势, 然后建立空天信息因果智能认知的因果之梯, 进一步基于空天信息数据中的时序特征和空间统计特征, 探讨面向空天数据的因果分析框架和因果表示方法, 着重讨论以因果图模型、反事实推理、模型特征干预为核心的三种因果智能解译模型构建过程, 最后指出了因果智能解译在空天观测环境下的应用与挑战。

关键词: 因果推理, 智能解译, 深度学习, 因果驱动, 空天信息, 反事实推理, 因果干预

中图分类号: TP701/P2

引用格式: 孟瑜, 张正, 席智浩, 陈静波, 邓利高, 邓毓弼, 孔赞珑. 2025. 因果驱动的空天信息智能解译. 遥感学报, 29(6): 1705-1723

Meng Y, Zhang Z, Xi Z H, Chen J B, Deng L G, Deng Y P and Kong Y L. 2025. Causality-inspired intelligent interpretation of aerospace information. National Remote Sensing Bulletin, 29(6): 1705-1723 [DOI: 10.11834/jrs.20254309]

1 引言

空天信息 (aerospace information) 目前尚未有公认的定义, 从科技或产业链条而言, 其涵括了卫星、空间站等天基 (spacecraft) 平台与飞机、浮空器、无人机等空基 (aircraft) 平台及传感器的制造发射并利用其获取数据、提取信息、挖掘知识、提供服务等全过程, 涉及遥感、通信、导航、电磁等多个专业。空天信息具有显著的军民共用属性。在军事领域, 将利用空天平台搭载各类传感器载荷所形成的作战保障系统称为空天信息系统 (吕文平等, 2012; 周绍明等, 2014), 美军在近几场局部战争中的绝大多数通信、侦察、导航定位、气象预报类任务均主要依靠空天信息系

统完成。在国民经济建设领域, 空天信息产业 (彭玲和池天河, 2023)、空天信息服务 (李德仁, 2017) 等强调通信—导航—遥感一体化的、服务大众的、多样化智能化的数据信息服务, 涉及卫星制造、天基运营、地面平台和下游终端应用等诸多环节。在“人工智能+”行动时代, 根据领域行业应用场景需求获取空天数据、提取空天信息、挖掘时空知识, 是空天信息智能解译的核心技术需求, 本文重点围绕其中的空天信息提取环节开展论述。

依据多视角、多尺度、多模态空天对地观测数据 (通常为图像) 记录的地表反射/散射/辐射信号, 解译地表资源环境要素的数量、质量、结构、生态现状和变化等信息, 是开展全球和区域尺度

收稿日期: 2024-07-25; 预印本: 2025-01-25

基金项目: 国家重点研发计划 (编号: 2021YFB3900503)

第一作者简介: 孟瑜, 研究方向为遥感图像智能解译、自然资源监测。E-mail: mengyu@aircas.ac.cn

通信作者简介: 陈静波, 研究方向为遥感图像智能处理、遥感大数据分析。E-mail: chenjb@aircas.ac.cn

土地利用、地表覆盖和地表参量一体化监测的重要手段。空天数据到空天信息的转换过程称为空天信息解译, 面临业务广要素杂(自然资源、应急管理、生态环境等领域关注要素不同)、差异化复杂场景(立地条件、类型结构、物候水期等)及要素特征不稳定性(同谱异物、同物异谱等)等挑战, 使得基于机器学习、深度学习的空天信息解译在面对动态开放场景的适应性不足, 将空天信息智能解译技术应用于大范围、规模化的业务应用一直是产学研用管各方孜孜追求的目标。

从发展历程来看, 空天信息解译走过了纯人工目视解译的1.0时代, 实现了依赖专家经验的信息提取, 实质上是人脑抽象并利用解译标志库所蕴含因果关系规则的过程; 现在正处于人机交互解译的2.0时代, 主要采用先自动提取后人工编辑的串行解译模式, 初步实现了边人工提示边智能解译的并行解译(如SAM提示学习), 实质上人脑智能因果推断与机器智能关联推断相结合的混合智能; 在人工智能领域取得突破性进展的当下, 空天信息解译也必将走进智能解译的3.0时代(张兵等, 2022), 以智能模型为主实现强因果、高泛化的自动化信息提取。从模型视角来看, 空天信息解译模型经历了统计模型主导的数字信号处理阶段(1970年—1990年)、物理模型主导的定量遥感阶段(1990年—2010年)、数据模型主导的遥感大数据阶段(2010年至今)的发展, 其中, 统计模型和数据模型均依靠数据与信息间的关联关系开展解译(如基于像素DN值的遥感影像分类), 而物理模型则依靠数据与信息间的物理机理开展解译(如基于反射率计算植被指数并提取植被覆盖度), 3个阶段对先验知识的需求逐阶段减少而信息提取能力逐阶段增强(Zhang等, 2019)。从行业应用来看, 我国已建立了自然资源、生态环境、应急管理、气象、海洋等行业卫星应用中心, 建立了空天信息支撑行业监测监管业务的技术方法体系, 但空天信息解译仍然面临信息提取严重依赖人工、自动化程度不高的突出问题(陈军等, 2022; 张兵等, 2022)。

众所周知, 当前基于人工智能模型的分析计算均以统计学为根基。徐宗本院士指出的人工智能10个重大数理基础问题中, 大数据的统计学基础是首要问题(徐宗本, 2021)。一方面, 统计学建立在概率论以及大数定律、中心极限定理、正

态分布理论等数学基础上, 这些原理大都是在独立同分布样本假设、观测变量个数 p 远小于数据量 n (即统计学中的 $p \ll n$)假设下被证明的, 而面向未知、开放场景的实际应用中, 以上基本假设常常难以满足, 伪相关、内生性等问题随之出现。另一方面, 统计模型参数通常具有解析形式(即公式表达), 而深度神经网络模型参数难有解析形式, 导致模型不具备可解释性。如何适应开放场景、实现可解释的智能解译是当前的研究热点, 众多学者认为, 将空天信息机理与地物样本特征融合, 构建知识与数据驱动的智能解译是有效途径(Ge等, 2022; 孟瑜等, 2024; Wang等, 2024c), 其实质是将知识代表的可解释性规律与数据对应的样本特征分布融合以得到更优的决策边界。而作为知识工程中的重要概念, 因果关系理解是人类认知中的决定性特征(Goddu和Gopnik, 2024), 将因果关系知识与人工智能结合, 不仅可以让人工智能更有能力应对不断变化的环境, 还可以使模型学习数据间更多潜在的关系, 将因果融入空天信息智能解译中, 有可能会大幅提升开放场景下的空天数据到空天信息的转换的可靠性以及即时服务能力。

为了系统性总结因果驱动的空天信息智能解译方法的研究现状和趋势, 本文以空天信息特别是对地观测遥感数据智能解译为视角, 回顾了当前基于关联关系的智能解译方法, 引出因果关系驱动的智能解译并介绍了因果关系学习、因果智能解译模型等相关方法研究工作, 特别是综述了国内外因果驱动的空天信息智能解译相关工作, 最后展望了因果智能解译面临的挑战。


2 基于关联关系构建的空天信息智能解译

2.1 关联、相关与因果关系

关联关系(association)、相关关系(correlation)、因果关系(causation)是变量间常见的3种关系(Altman和Krzywinski, 2015): 关联关系是一种广泛存在的关系, 对于两个变量 X 和 Y , 若 X 可提供关于 Y 的信息, 则称 X 和 Y 之间存在关联关系; 相关关系是一种特殊的关联关系, 当 Y 随 X 单调递增或递减时, 认为 X 和 Y 之间存在相关关系; 因果关系是指 X 的变化必然导致 Y 的变


化, 则称 X 为因变量、 Y 为果变量。图1展示了空天信息领域3种关系的典型示例: 图1(a)表示关联关系, 如波长与海水反射率的关系即为关联关系(光谱曲线)(Kokaly等, 2017); 图1(b)表示相关关系, 如温度植被干旱指数(TVDI)与棉

花覆盖率呈现的正相关关系(Bannari等, 2002); 图1(c)表示因果关系, 如植被叶片中的叶绿素含量升高是造成红边波段位置向长波方向移动(即“红移”)的原因之一(Clevers等, 2002)。




(a) 关联关系: X 可提供关于 Y 的信息, 如光谱曲线

(a) Association: X delivers information about Y ,
e.g., spectral curves



(b) 相关关系: Y 随 X 单调递增或递减, 如TVDI与棉花覆盖率

(b) Correlation: Y monotonically increases or decreases with X ,
e.g., TVDI with cotton cover



(c) 因果关系: X 的变化必然导致 Y 的变化, 如红移现象

(c) Causality: the variation of X inevitably causes the variation of Y , e.g., redshift phenomenon

图1 关联、相关、因果关系示意图

Fig. 1 Illustration of association, correlation, and causation

2.2 关联关系建模方法

在Pearl提出的因果之梯中, 对应于观察行为的关联关系是最基础的决策依据。在该层级上, 我们利用观察到的变量间统计关联关系进行预测回归等应用, 当前绝大多数的机器学习方法都属于这一层级。需要说明的是, 关联关系建模中应区分边际关联与条件关联, 边际关联是在不考虑其他变量的情况下观察两个变量间的关联关系, 而条件关联在此过程中考虑了其他变量。在一些情况下, 整体考虑两个变量的关系与分组考虑两个

变量的关系, 可能得到完全相反的结果(如辛普森悖论)。

根据建模思路不同, 关联关系建模方法可分为实验方法、观察方法。实验法通过设计与实施变量操控来理解变量间的依赖性, 而观察法并不干预变量而是通过观察分析捕捉变量间的相互影响。常见的关联关系建模方法如图2所示, 各类方法的优劣势对比可参见文献(Roberts等, 2019)。需要说明的是, 随机对照试验也是发现变量间因果关系的最可靠方法。




图2 关联关系建模方法

Fig.2 Methods for association relationship modelling

关联关系既可以利用解析形式的函数表达，也可以利用不可解析的模型参数表达。解析函数表达中，通常假设变量 X 和 Y 之间存在可解析表达的函数关系（如二次多项式），并利用最小二乘等方法确定函数中的参数（多项式系数），多元回归、支持向量机等经典模型均可得到表达关联关系的解析函数。如支持向量机是通过核函数将数据映射到高维空间，并在该空间中寻找最优边界解决非线性分类问题（李昌俊等，2018）。而随着模型复杂性的提升，深度学习等方法利用模型参数代替解析函数，通过学习到的多层次特征表达数据间的关联关系。

空天对地观测数据中蕴含着地表要素的时间—空间—光谱域特征，以遥感影像为例，地物要素的时域特征是其不同季节时相影像中的信息及上下文关系（如植被物候），空域特征是要素本身尺寸形状、结构纹理等及其与周边地物的关系，谱域特征是要素在不同模态影像中的反射、散射和辐射等物理信息及其上下文关系。空天信息解译需要基于以影像像素为载体的要素时空谱特征，提取要素的数量、质量、结构、生态现状和变化等信息，而关联关系建模要建立影像像素空间到要素特征空间、要素信息空间的关联关系。其中，影像像素空间到要素特征空间的关联关系建模过程与特征提取对应，要素特征空间到要素信息空间的关联关系建模过程与提取分类、变化检测、目标检测、时序分析、定量反演等下游任务对应。

2.3 关联关系深度学习模型

以深度学习为代表的人工智能方法已经成为空天对地观测领域主要的研究范式，其主要贡献

在于提供了一种无需人工设计特征的特征学习方法，实现了影像像素空间到要素特征空间的关联关系挖掘，而基于深度学习构建端到端的信息提取模型，实现了要素特征空间到要素信息空间的关联关系挖掘。本节主要从特征学习角度回顾空天信息关联关系深度学习模型的发展。

传统的机器学习模型中，为了获得对要素信息提取有用的特征，需要经过专家设计特征、计算特征、选择特征等过程，而深度学习方法能够根据下游任务需求自动从海量数据中完成上述过程，实现从像素空间到特征空间的关联映射。深度学习模型挖掘关联关系的方法模型共经历了经典深度学习模型、Transformer模型和基础模型3代的发展。

经典深度学习模型以卷积神经网络（CNN）、长短期记忆网络（LSTM）、图卷积神经网络（GCN）3种网络架构为代表。CNN利用三维卷积提取二维影像平面及光谱通道与要素空谱特征间的关联关系（顾小虎等，2023），这些空谱特征可用于植被、水体和建筑物等不同地物类型的识别和分类（刘艳飞等，2021）。LSTM通常用于建模多时相/时间序列空天观测数据与时域特征间的关联关系（黄翀和侯相君，2022），通过引入记忆单元和门机制可更好捕捉长时间序列的依赖关系。例如，在植被变化监测中，LSTM利用时序遥感数据得到更高精度植被分类结果（杨丹等，2020）。GCN通过在图结构数据上进行卷积操作，能够捕捉到节点（如地物单元）之间的关联关系和空间结构特征（田智慧等，2023）。遥感数据中的地物通常具有复杂的空间分布和拓扑结构，例如城市中的道路网络（刘洋等，2023）、河流流域的水系结构（陈能成等，2017）等。综合而言，CNN、LSTM、GCN等经典深度学习模型受模型参数量/运算量限制因而感受野有限，擅于学习空天数据与要素特征间的局部关联关系。

Transformer模型由Vaswani等（2017）提出，通过自注意力机制和并行处理，克服了经典深度学习模型面临的全局特征学习能力不足的问题，可以提取时—空—谱域的长距离特征依赖关系，在空天信息智能解译方面相比于经典深度学习模型性能也有提升。例如，在遥感影像语义分割中邵凯等（2024）提出基于Transformer的多尺度语义分割网络相比于CNN网络各个地物均表现更好

的提取效果，同时模型收敛速度加快。在遥感影像目标检测中，喻九阳等（2023）提出无锚框的Transformer目标检测算法，与CNN方法相比有更高的旋转框目标检测精度。张伟雄等（2023）利用Transformer架构进行时序遥感数据分类，相比与LSTM方法能有效提高小样本类别分类精度。综合而言，Transformer模型的自注意机制使得其能够更有效地学习空天数据与要素特征间的全局关联关系。

第三代是领域基础模型。前两代模型大多是专用模型，受泛化性限制在开放场景中提取满足下游任务要求的关联关系，也难以协同提取不同模态空天数据间的关联关系。针对此问题，基础模型利用多模态无标签训练模型以构建强泛化性的通用数据-特征关联关系，再通过场景微调实现特征适应下游任务（付琨等，2024）。空天信息基础模型按照学习方法分为基于对比学习和基于生成学习两类方法。基于SimCLR（Chen等，2020）框架，Jung等（2021）提出了一种遥感图像的平滑表示学习方法。Mañas等（2021）引入季节性对比损失来训练遥感基础模型SeCo。Sun等（2023）构建了RingMo遥感基础模型架构，并通过建立百万级遥感数据集，专门针对复杂场景中的小型密集目标设计训练策略。Cha等（2024）开发了遥感领域的十亿级参数模型，证明了模型性能和数据效率随模型规模的增长而提高。综合而言，空天信息基础模型有效提高了空天数据与要素特征间关联关系的场景泛化及跨模态应用能力，是当前主流的关联关系深度学习模型。

3 空天信息智能解译的因果之梯

3.1 关联关系模型的局限性

当前以深度学习为代表的人工智能解译方法在取得令人瞩目的成功背后，其迁移性、稳定性、可解释性、时效性等弱点也逐渐显露（李家宁等，2023）。造成这些局限的主要原因是深度学习在本质上追求的是对关联关系的挖掘，而关联关系依赖数据间的独立同分布假设并且容易受到伪关联现象的误导。在训练集上学习到的关联关系，难以直接迁移到分布不同的待预测数据之上，造成场景迁移泛化问题。即使两个事物间存在强关联关系，也未必能作为判别的必然依据，例如羊经

常出现在草地上，导致草地与羊之间的相关性可能超过了羊本身的判别特征与羊之间的相关性，此时草地与羊就形成了一种伪关联关系，使出现在草地上的其他动物容易被误判为羊。此外，深度模型体积的快速膨胀与算力依赖，也限制了深度学习时效性。

因果关系是一种比相关关系更稳定、更本质、不会随数据分布与输入数据而变化的判据，从定义上来说， X 与 Y 之间具有因果关系意味着 X 的改变一定会引起 Y 的改变，因果关系还具有可解释、推理相对快速、可通过联合概率分布实现分布式推理等特点。因此将因果关系引入人工智能范式是克服现有方法缺陷、促进人工智能走向下一个应用阶段的潜在方向。

3.2 关联—干预—反事实推理

为了系统性地描述因果认知能力水平，Judea Pearl（2018）提出了“因果之梯（ladder of causation）”概念，将因果认知能力自下而上分为了关联（association）、干预（intervention）、反事实（counterfactuals）3个层级，与之对应，空天信息解译也存在如图3所示的因果之梯。关联对应观察观测，从已经发生的现象中发现因果关系，关联是被动的，不对事物的发生发展进行干涉，基于数据的统计模型属于这一层级；干预对应行动介入，主动创造所需要的条件，获取对应结果，进而判断事物间的因果关系，在严格控制条件下进行实验探索属于这一层级；反事实对应联想回溯，假设未曾出现或与事实相反的情况，想象推理回溯其原因与结果，需要全面掌握事物发展规律，是最高级的因果认知能力，物理定律及其方程属于这一层级。

以关联关系为基础构建的智能解译模型可能存在的缺陷是伪关联，因此在关联层级进行因果推断的主要任务是辨别伪因果，通过混杂变量发现或知识性物理性的约束等方式调整从数据中构建的关联关系，尽可能排除伪因果现象。干预和反事实层级的主要问题是缺乏案例数据积累，尤其是在难以进行控制变量实验或完备理论推演的学科，因此需要特别关注自然发生的反常事件及其对应的观测数据，不断积累等效的干预和反事实结果。

空天信息领域具备海量且多样的观测数据，

但难以主动控制地球表层或非合作目标的变化，同时也缺少以确切方程形式描述的完备定律，因此空天信息领域的因果认知目前主要集中在关联层级，部分借助试验场网的定量遥感研究进入了干预层级，在数字孪生虚拟现实场景中也可以进

行一定的干预与反事实验证。因果关系的建立相较于关联关系更加困难，需要通过更严格的统计理论与事实数据排除混杂因素的干扰，因此在过去较长一段时间内因果认知在非实验性领域进展较慢。

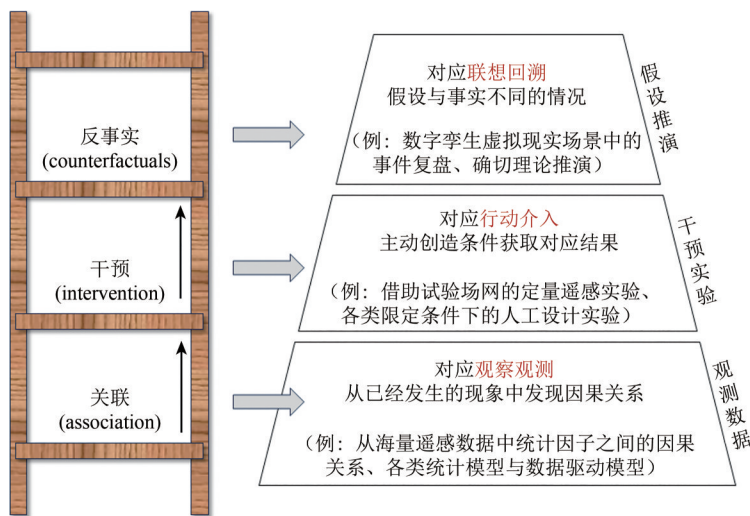


图3 空天信息因果之梯
Fig. 3 Ladder of Causation for aerospace information

机器学习与因果推理在统计学中曾经是彼此独立发展的两个方向，当前两者来到了一个相互融合促进的新阶段（Scholkopf 等，2021）。一方面，引入因果关系可以补足前述关联关系引发的各类缺陷，另一方面，机器学习为因果推理在非实验性领域的发展提供了新的方法手段，可以从海量数据中寻找、归纳、模拟、生成人工设计实验或反事实假设的等效结果，借助长时间序列、大样本量统计、多轮次迭代评估等手段（Runge 等，2019；Schölkopf, 2022）构建尽可能稳定的因果关系，助力空天信息因果智能认知向因果之梯的更高层级不断攀升。

4 空天信息因果关系学习

在前述章节中，探讨了传统空天信息智能解译的模型构建方法，并分析了对空天观测数据进行关联关系推理的局限性。如图4所示，本节将首先介绍因果关系的两种分析框架，包括结构因果模型和潜在结果模型，并根据空天数据的时序特征和空间特征，进一步梳理空天对地观测数据的因果发现和因果效应评估方法，以及深度神经网络的因果表示学习方法。




图4 时空观测数据的因果关系学习
Fig. 4 Causal learning for spatio-temporal observation data

4.1 因果推理框架

4.1.1 潜在结果模型

潜在结果模型（POM）的核心在于通过比较同一对象在不同处理（干预和未干预）状态下的潜在结果，来估计变量之间的平均因果效应（Imbens 和 Rubin, 2015）。以二元因果变量干预为例， $X_i(1)$ 和 $X_i(0)$ 分别表示变量 X_i 在干预和非干预状态下的观测结果，个体因果效应可表达为： $ICE(i) = X_i(1) - X_i(0)$ 。然而，在很多现实情境中，同一个体通常不可能同时采取两种处理过程，因此给定变量 X_i 只能获取到一个观测结果，而另

一个未被观测到的结果称为潜在（反事实）结果。所有个体因果效应的期望即为群体平均因果效应，记为： $ACE = E(X(1)) - E(X(0))$ ，其中 $X(1)$ 和 $X(0)$ 表示群体中干预状态和非干预状态的观测结果。在因果推理的实际应用中，往往面临着数据缺失和潜在结果未被完全观测的挑战，潜在结果模型致力于评估缺失数据状态下的潜在结果。

4.1.2 结构因果模型

结构因果模型（SCM）由 Pearl 等（2000）提出，通过有向无环图（DAG）直观地表达变量之间的因果关系，每个变量利用结构方程来定义，以数学函数形式描述该变量与其他可观测变量、未观测到的隐变量或噪声变量的依赖关系（Goldberg, 2019）。在数学表示中，DAG 由节点和有向边两部分组成，节点通过有向边连接，而有向边表示一个节点到另一个节点的影响或依赖关系。无环性是 DAG 的关键特点，即不存在从某个节点出发，通过一系列有向边回到该节点的路径。以图 5 为例，DAG 中的每个节点变量 X_i 均可通过其父节点 pa_i 和潜在外生变量 u_i 函数化为 $X_i = f_i(pa_i, u_i)$ ， $\forall i = 1, 2, \dots, n$ 。




图5 DAG 示例

Fig. 5 Illustration of DAG

在实际应用研究中，SCM 可以系统地理解和分析观测变量之间的依赖关系，而因果干预则通过控制其中一个变量或多个变量的值，进而观察干预产生的变化对其他变量的影响来识别出系统中潜在的混杂因素，可以区分出变量之间的因果关系和关联关系，此过程在 SCM 中也称为 *do* 操作，评估 X 和 Y 的因果效应记为 $P(Y|(do(X=x)))$ 。然而，面对稍复杂的观测场景导致因果图的变量关系也变得复杂时，*do* 操作往往难以直接求解。如图 5 所示，常用因果干预手段为前门调整和后门调整。

任何一条 X 到 Y 之间以指向 X 的箭头为开始的路径称为后门路径，而通过控制后门路径的一个或一些变量使得后门路径被阻断的方法称为后门调整。比如图 6 (a) 中的因果图， $X \leftarrow C \rightarrow Y$ 为包含混杂因素的后门路径，在混杂变量 C 可被直接观测的前提下，通过干预来控制 C 从而阻断此路径，此时 X 对 Y 的因果效应可以通过以下公式估计：

$$P(Y|do(X)) = \sum_c P(Y|X, c)P(c) \quad (1)$$

特别地，当混杂因素 C 是无法被直接观测的变量，此时后门调整方法便不再适用。在这种情况下，前门调整可以作为评估因果图中因果关系的有效方法。如图 6 (b) 所示，通过引入中间变量 M 来阻断 X 与 Y 的关系，进而分别计算 X 与 M 以及 M 与 Y 的因果效应来估计 X 对 Y 的因果效应，此时前门调整的公式表达如下：

$$P(Y|do(X)) = \sum_m P(M = m|do(X))P(Y = y|(d(M))) = \sum_m P(M = m|X) \sum_x P(Y|M = m, x)P(x) \quad (2)$$




图6 前门调整与后门调整

Fig. 6 Front door adjustment and back door adjustment

4.2 观测数据的因果信息发现

在上述结构因果模型的分析框架中，需要在因果图已知的情况下才能进行因果效应估计。然而，在实际的观测数据因果推理任务或基于因果关系的应用研究中，因果图通常是未知的。尽管对于有限观测变量的分析问题，可以直接根据领域知识和专家经验给出先验因果结构，但很多领域的观测数据往往是庞大复杂的高维、非线性、多源数据结构，比如空天对地观测数据中可能涵盖遥感、水文、气候和海洋等地球科学领域的不同尺度时空数据，难以直接确定不同观测变量间的潜在变化规律和依赖关系（Massmann 等，2021）。因此，首先需要从一系列观测数据中提取因果信息并生成因果图，这个过程被称为因果发现。

(1) 基于独立性测试的因果发现方法。基于独立性测试的因果发现方法通过对观测的一系列条件独立性测试来逐步揭示变量间潜在的因果结构, 从一个空图或全连接图开始, 基于条件独立性迭代式添加或调整连边及其方向, 逐步构建出因果图结构, 常见算法包括 Peter-Clark 算法 (PC)、归纳因果关系算法 (IC) 和快速因果推断 (FCI) 算法 (Rohekar 等, 2021) 等。

(2) 基于评分的因果发现方法。基于评分的因果发现方法通过最大化模型的评分函数来选择最优的因果图结构, 比如贪婪等价搜索 (GES) 方法利用贝叶斯信息准则 (BIC) 进行评分来求得得分最高的因果图。

(3) 基于目标优化的方法。目标优化方法通过定义和优化目标函数, 从可能的结构中选择最优因果结构, 比如混合整数线性规划算法 (MILP) (Chen 等, 2022) 将因果发现问题转化为整数线性规划问题, 通过求解线性规划问题来确定最优因果结构, NoTears 方法 (Zheng 等, 2018) 将因果发现问题转化为可微分的连续优化问题, 通过优化一个连续可微的目标函数, 直接学习 DAG 结构。

(4) 基于机器学习和深度神经网络的因果发现方法。基于机器学习和深度神经网络的因果发现方法利用贝叶斯网络、生成对抗网络或卷积神经网络来学习数据中复杂的因果关系, 比如因果生成神经网络 (CGNN) 和深度端到端因果推断 (DECI) 通过生成对抗网络 (GAN) 或变分自编码器 (VAE) 来模拟潜在的因果机制, 比较不同因果图结构生成数据的拟合优度来选择最优因果结构 (Yuan 等, 2020)。

机器学习技术能够从大量数据中挖掘隐含的因果关系模式, 以此为基础构建因果发现方法可以识别数据和结果之间的复杂影响关系, 在高维和复杂因果推理方面具有巨大潜力。此外, 利用学习到的因果关系, 可以揭示复杂观测场景的变化规律, 增强智能模型的解释能力和场景泛化能力, 在空天信息的对地观测遥感、生态系统与复杂气候系统等领域具有广泛应用前景。然而, 空天信息领域因果发现仍然面临两方面挑战: 一是因果关系可能并不准确, 会存在真正本质原因未被观测的隐藏变量; 二是学习的因果图也可能过于简单, 通常只涉及复杂观测场景的少数变量, 无法准确的描述观测场景。

4.3 基于观测数据的时间序列因果推理

4.3.1 格兰杰因果分析

格兰杰 (Granger) 因果分析是由诺贝尔经济学奖获得者 Granger (1969) 提出的一种最早确定时间序列数据之间因果关系的统计方法, 其核心思想是: 如果一个时间序列 X 在考虑所有相关信息的情况下, 能够显著提高对另一个时间序列 Y 的预测能力, 那么就称 X 格兰杰导致 Y 。传统的格兰杰因果分析主要用于低维时间序列数据, 在变量之间线性关联的假设条件下, 通过构建回归模型并比较模型的预测效果以确定因果关系。然而实际应用中, 这种方法要求时序数据处于平稳、线性、低维度状态, 因而具有明显的局限性。随着空天信息等诸多领域大规模高维非线性数据的涌现, 需要进一步探索高维度的且变量之间存在非线性关系甚至随时间动态关系变化的高效因果关系检测方法 (Massmann 等, 2021)。

4.3.2 基于传递熵的因果分析

基于传递熵的因果分析 (Schreiber, 2000) 利用信息论中传递熵的概念来衡量一个时间序列能够提供给另一个时间序列的信息量。诸多研究者通过改进的迁移熵方法来进一步提高在非平稳、非线性的复杂系统下的推理精度。例如, 消除噪声和非平稳因素影响的归一化有效传递熵、应用于复杂系统根源变量定位的符号动态归一化传递熵以及归一化因果熵等。相比于格兰杰因果分析方法, 基于传递熵的因果分析在处理非平稳时间序列数据方面具有更强的鲁棒性, 能够在不需要对数据进行线性假设的情况下, 捕捉到时间序列数据中的非线性因果关系, 这使其在复杂系统的因果分析中更具优势。然而, 由于该类方法通常需要计算变量的概率密度函数, 因此随着变量维度的增加容易造成维度灾难问题。

4.3.3 基于状态空间模型的因果分析

基于状态空间模型的因果分析方法 (Sugihara 等, 2012) 通过建立动态系统的非线性模型来推断变量之间因果关系, 通常结合动态系统理论、概率模型和贝叶斯推断等技术, 以从时间序列数据中获取更深层次的因果信息。动态因果图模型 (DCM) 使用非线性状态空间模型来描述节点之间的动态因果关系。基于微分方程的因果模型使用

贝叶斯推断来估计模型参数，通过观察数据与模型的状态预测之间的误差，推断出变量之间的因果关系。因果动态系统模型将因果关系建模为动态系统的状态方程，利用观测数据来估计模型参数，推断变量之间的因果关系和动态行为。随着应用场景系统越来越复杂，对模型的复杂性和通用性要求越来越高，该方法将在遥感、生态、气候等地球科学领域发挥得到广泛应用（Su等，2023）。

4.4 神经网络中的因果关系表示

深度学习模型擅于从数据中学习并提取特征，捕捉数据中的复杂统计关系并生成高度关联的数据表示。然而，由于其“黑箱”特性，这类模型缺乏可解释性和可控性，学习过程中往往忽视输入数据的因果特征，容易引入不相关的潜在混杂因素，导致归纳偏置问题，使得模型难以适应特定任务场景的准确预测。因果表示学习（Scholkopf等，2021）通过将因果模型与深度神经网络的表示学习结合，能够借助因果推理帮助深度学习模型进一步理解预测背后的因果逻辑和机制，从而超越单纯依赖数据的统计表示，提高模型的预测和决策性能。比如，因果机制可以嵌入到深度学习模型中，以学习到具有因果关系和反事实推理效果的数据表示，帮助模型适应输入条件改变或数据发生变化的场景，从而提高深度神经网络的稳健性、可靠性和无偏公平性。然而，当模型的输入和输出是高维且非结构化的数据时，如何让模型的内部运行状态由因果机制引导和调控，依然是一个巨大的挑战。

正如前文所述，空天信息解译应用中的感知数据或传感器测量数据通常是未知因果关系的耦合状态。除了数据以及任务标签，描述观测系统的因果机制往往是未知的，而因果表示学习的目标就是揭示系统数据中的关键因果结构以实现因果表示，从而能够准确预测和推理下游任务。因果模型通常使用观测数据中的抽象变量，而深度神经网络的特征提取过程可以捕获与任务相关的高级变量，或者说将低级特征映射为高级变量，这些变量可用于描述感兴趣下游任务的关键因果机制。例如，在图像识别任务中，因果表示可以将形状等固有特征与纹理等领域特征分离，以提

取因果不变特征，从而在数据的领域特征分布变化时提升模型的鲁棒性。这个过程涉及3个关键步骤：因果变量的解耦表示、包含因果机制的模型或模块的构建，以及因果干预机制的设计以学习因果特征。通过这3个步骤，可以更有效地捕捉和利用因果关系，提高模型的性能和可靠性。

对于现有基于因果理论的智能解译模型，通常是在深度神经网络的数据层面或特征层面构建结构因果模型，并选择合理的因果干预方法，以消除图像或特征空间中存在的伪关联关系。其关键在于，利用先验知识构建最优的因果结构，并嵌入模型中以实现因果关系的表示。Zhang等（2023）总结了现有基于因果理论的智能解译研究中常用的几种因果结构：图7（a）描述了输入、输出和具有伪关联的混杂因素之间的关系。如果 C 具有可观测性，通常会使用后门调整方法来阻断 X 和 C 之间的联系，从而分析 X 对 Y 的实际影响（Li和Li，2023）；图7（b）在输入和输出之间引入中间变量 M ，在混杂因素 C 无法被观测的情况下，可以通过前门调整方式实现 X 到 Y 的因果学习（Kim等，2023）；图7（c）展示了在混杂因素和输出之间引入中间变量 M 的情形，这表明混杂因素对输出的影响具有高维特征（Ouyang等，2023）；图7（d）显示了中间变量 M 在输入和混杂因素之间的因果图，此时可以通过控制 M 来阻断伪关联关系；图7（e）则关注多个混杂因素同时对输入的影响（Xu等，2022b；Zhu等，2024），通过同时阻断这些变量的伪关联关系来实现因果学习。

5 空天信息解译因果智能模型

因果智能解译模型是指智能解译模型中蕴含因果关系。相比于基于关联关系的智能解译模型，因果智能解译模型能获得更准确的空天信息。本节对于如何构建蕴含因果关系的智能解译模型进行概述。图8列举了构建蕴含因果关系的智能解译模型方法，包含构建基于因果图的解译模型、反事实结果的解译模型和模型特征干预3种方法。

5.1 基于因果图的解译模型

因果图模型是一种用于表示和分析因果关系的模型。将变量及其因果关系表示为DAG，其中节点代表变量，边表示变量之间的因果关系。构

建因果图模型的方式有线性结构方程模型、因果贝叶斯网络、结构因果模型和对抗自编码器4类。

5.1.1 线性结构方程模型

线性结构方程模型 (SEM) 属于因果图模型的一种形式, 是由 DAG 表示的简单因果模型。Otgonbaatar 等 (2022) 通过构建线性 SEM 来研究遥感数据中的因果关系。首先, 将每个遥感图像块表示为单一变量 (如熵), 采用 SEM 来研究这些变量之间的因果关系, 通过设定水量常数和云覆盖常数干预变量评价因果效应, 结果表明, 云覆盖量对农业的影响比水量更显著。文章是在已知因果结构的情况下使用遥感数据进行因果关系建模的探索。

5.1.2 因果贝叶斯网络

因果贝叶斯网络是因果图模型的一种具体实现, 结合了贝叶斯网络的概率推断能力。Xu 等 (2022a) 提出一种贝叶斯更新框架, 通过物理信息因果图将地理空间模型与遥感观测结合, 实现地震灾害中地面破坏和建筑物损坏联合估计。将地理空间特征、地面破坏、建筑物损坏、遥感观测等变量作为贝叶斯网络中的节点, 构建基于因果图的贝叶斯网络, 有效捕捉变量间的因果关系, 提高了地面破坏和建筑物损坏估计的精度。

DisasterNet 将物理信息模型、地震造成次生灾害 (海啸、建筑物破坏、泥石流等)、环境噪声和遥感观测整合到一个因果图中, 通过因果物理依赖关系连接, 将因果图表述为因果贝叶斯网络 (Li 等, 2023b)。为能够更精确地表示从父节点到子

节点的映射关系, 采用正则化流对节点间的复杂的因果依赖关系进行建模。DisasterNet 构建出蕴含因果关系的解译模型, 能够更准确地估计地震发生后的多种次生灾害和影响。




图7 因果表示学习中常用的因果图

Fig. 7 The typical causal graph in causal representation learning




图8 构建因果智能解译模型方法

Fig. 8 Methods for constructing causal intelligent interpretation models

5.1.3 结构因果模型

为了解决 SAR 影像目标识别中样本不足导致精度不高的问题，Wang 等（2024a）提出了一种因果干预的自动目标识别方法 CIATR，核心是构建一个基于因果推断的 SCM 用于揭示目标识别中关键因素的因果关系，避免因成像条件变化引起的伪关联。为消除成像条件引起的 SAR 图像和分类结果虚假相关，采用了包含数据增强、特征区分的后门调整策略：数据增强是通过空间—频率域混合变换，估计不同成像条件对 SAR 图像的潜在影响；特征区分是采用混合相似性测量，评估和减轻成像条件变化对特征的影响。通过后门调整消除成像条件的影响，可帮助模型获取 SAR 图像和分类结果之间的真实因果关系。

5.1.4 对抗自编码器结构

Guo 等（2023）提出了一个因果对抗自编码器（CAE）结构，用于实现 SAR 图像的解耦表示和目标识别。CAE 提出因果图模型描述 SAR 图像成像过程，因果图模型节点包括雷达特征、目标特性、环境条件和成像算法等，并在因果模型的基础上构造了 SAR 图像的解耦表示。SAR 图像表示的语义因子解耦为内在属性（intrinsic）、多样性（diversity）和随机性（randomness），解耦的语义因子在因果图模型中分别表示为不同的节点和关系。CAE 从因果关系的角度考虑神经网络对 SAR 图像的表示，模型在稀疏训练样本下表现出优异的性能。

5.2 构造反事实结果的解译模型

反事实推理（Counterfactual Inference）通过分析“如果某一事件没有发生或以不同方式发生，结果会怎样”的问题，来分析变量间的因果关系。在空天信息智能解译模型中，构造反事实结果的方法包括前时相影像模拟反事实结果、偏差特征随机打乱、高低频分量重组 3 类方法。

5.2.1 前时相影像模拟

在研究特定风暴造成的海岸侵蚀时，需要构建一个由假想的海岸情况、未发生风暴等反事实因素构成的可靠反事实场景用于监测风暴前后的海岸线变化。Pérez Valentín 和 Müller（2020）利用 Sentinel-1 影像监测海岸线变化，提出将断点回归策略用于估计风暴、海岸侵蚀之间的因果效应。

研究将飓风到来之前的遥感影像作为反事实结果，解决反事实结果不可被观测的问题。该研究表明在现场观测难以获得的情况下，将遥感和因果推理技术相结合，将环境变化归因于特定灾害的应用潜力。

5.2.2 偏差特征随机打乱

Zhu 等（2024）在语义分割模型的非监督域适应研究中，将偏差特征进行随机打乱进而生成反事实结果。首先，提出一种因果特征解耦模块，用于从源域和目标域图像中分离因果特征和偏差特征。然后，通过因果原型（causal prototype）对比模块学习域不变的因果特征，进一步解耦因果特征和偏差特征。在此基础上，因果干预模块通过对偏差特征进行干预生成反事实样本，即通过在每个批次中随机置换偏差特征，生成去偏反事实样本。通过以上的方 法，模型能够更好地捕捉源域和目标域之间的因果机制，从而在未标注的目标域上实现更准确的语义分割。

5.2.3 高低频分量重组

Zhang 等（2024a）研究中发现高光谱图像（HSI）中高频分量相比低频分量包含更多噪声信息。为获得反事实结果首先对 HSI 应用傅里叶变换得到低频和高频成分，然后对高频成分进行扰动，生成新的高频成分，最后通过逆傅里叶变换将低频和新的高频成分重组，得到反事实 HSI。实验结果表明，通过扰动高频成分，能更好区分因果因素和非因果因素。

5.3 模型特征干预的解译模型

将因果推理与深度学习相结合的方法，即通过干预模型特征来构建更具因果关系的特征，不仅能够提升模型的解释性和鲁棒性，还能更准确地捕捉遥感数据中的因果关系，从而改进模型的预测性能和泛化能力。通过融合因果推理与深度学习，遥感任务中的因果关系建模将变得更加精准和高效。模型特征干预可分为对比学习、前门调整、后门调整和噪声特征去除四类方法。

5.3.1 对比学习

Yu 等（2024）提出一种新颖的学习范式——图像内和图像间因果干预（I3-CI）学习，旨在减轻遥感图像语义分割中的偏差影响。具体来说，

针对图像内偏差,通过对比学习将同类像素特征聚集,不同类像素特征分开,减少图像内的非因果偏差。针对图像间偏差,为了克服从所有像素中学习的计算困难,I3-CI引入了一组类别原型特征,这些特征作为代理,用于跟踪不同类别特征的全局中心。以上两点,均可视为针对模型特征的因果干预,因为均是减少非因果因素对特征表示的影响。

Dong等(2024b)为解决高光谱跨场景分类任务中同类物体反射光谱差异导致分类性能下降问题,提出空间光谱增强和因果约束网络。采用结构因果模型概念构建因果判别器,从因果角度构建因果贡献向量,并使用对比学习约束类别标签,从光谱和空间域提取潜在的因果不变特征。该模型的基本假设是因果机制跨域稳定,并通过引入因果贡献向量的对比损失来实现因果一致性。模型挖掘出因果对齐后的稳定因果机制,并将这种模式定义为因果不变性。因果贡献对齐模块通过计算人为干预下的特征输出与随机干预下的特征输出差值,通过量化和约束每个输入特征对标签的因果影响。

5.3.2 前门调整

Yang等(2021)提出因果注意力机制(CATT),用来消除现有注意力机制关注训练数据之间伪关联的现象。CATT使用前门调整来进行因果干预,CATT包含样本内注意力和交叉样本注意力,交叉样本注意力中强制将其他样本引入样本内注意力,模仿因果干预。CATT可利用更少的数据和计算资源,达到其他注意力机制在大规模预训练相同的效果,表明了CATT可有效缓解模型学习数据之间的伪关联现象。

5.3.3 后门调整

Dong等(2024)为了在偏振合成孔径雷达分类中提升卷积神经网络提取的特征质量,在CNN训练和测试过程构建结构因果模型,采用后门调整识别影响提取特征质量的变量。在结构因果模型中通过干预混杂因素和训练集直接相关的特征,使用分层特征语义消除了特征区分性和泛化性相关的混杂变量实现后门调整过程,得到特征与测试标签之间真实的因果关系。

5.3.4 噪声去除

Zhang等(2024d)提出一种基于因果推理的船舶检测方法,该方法结合奇异值分解(SVD)和Transformer对数据进行降维和分类,使得模型能够更好地聚焦与目标结果相关的因果特征、忽略背景信息的伪关联。首先采用SVD用于对图像进行稀疏表示和降维处理,使得特征信息更加紧凑并抑制不相关噪声,之后对于稀疏图像特征利用Transformer模型结构进行识别舰船。相比于仅使用Transformer结构识别舰船的模型,SVD部分的加入去除图像的噪声特征,保留图像的重要信息,增强模型对因果特征的关注,减少对虚假相关特征的依赖,提高模型对背景信息等非因果信息的鲁棒性。

6 因果驱动的空天信息智能解译典型应用

在遥感大数据和人工智能飞速发展的时代,为了揭示不同尺度的时空异构数据潜在的复杂关联和变化规律,因果推理在地球观测应用领域引起了越来越多的关注,而面向持续获取的大规模多模态数据需要进一步挖掘应用本质的因果关系,提高模型对开放场景的泛化适应能力(Runge等,2023)。本节主要介绍因果推理与空天对地观测时空大数据、因果模型与不同智能解译任务的深度学习模型相结合的典型应用思路,如图9所示。

6.1 时空观测数据下的因果推理

在空天观测信息中,通过分析融合卫星、无人机和航空器等不同空天观测平台获取的遥感影像和传感器数据,从因果角度解释数据在时间和空间上的相互作用所产生的复杂关系,能够更全面、精确地理解和分析地球表面及其动态变化。本节从时间和空间角度,结合不同空天观测数据,介绍因果推理的典型应用。

6.1.1 时序因果推理

时序因果推理是对一段时间内的观测数据,从时间角度确定数据中变量间的因果关系以揭示环境和地表变化的动态过程。通过分析多年卫星图像数据,可以监测森林砍伐、城市扩张或冰川消退的趋势。如在洪水发生时,通过高时间分辨率的遥感数据可实时监测洪水的扩展情况,帮助

制定救灾和疏散计划。Zhang 等 (2024a) 以中国丹江口水库 6 年时间序列数据为基础探究河流系统变化周期, 将 LSTM 网络、因果推理和时频分析相结合, 以提高数据驱动型深度模型的预测可靠性和稳健性。Peng 等 (2024) 针对非线性高维时间

序列观测数据提出一种基于时空信息变换的神经网络结构, 采用时相卷积网络将高维数据映射为时间上的目标变量, 进一步结合时空信息变换机制进行格兰杰因果分析以提取有效的空间信息, 从而提高时间序列预测的准确性和稳健性。




图9 空天对地观测时空数据的因果智能解译技术流程及典型应用

Fig. 9 Technology process and typical application of causal intelligent interpretation of spatio-temporal data for aerospace information

6.1.2 空间统计因果推理

空间统计因果推理是利用遥感数据进行空间分析, 探究地理空间数据中变量之间因果关系。例如, 通过空间叠加分析, 可以找到污染源与受污染区域之间的关系, 帮助进行归因分析并制定环境治理措施。Wang 等 (2023) 将 InSAR 图像信息与洪水和飓风的物理模型相融合, 使用因果贝叶斯网络构建飓风、洪水、建筑物损坏和 InSAR 图像之间的因果依赖关系, 实现对建筑物损坏的快速准确检测, 进而评估建筑物损毁情况。Gao 等 (2023) 利用地球系统丰富的空间截面数据, 建立基于状态空间交叉映射预测的空间因果推理方法,

以充分利用地理空间数据并评估地球科学复杂动态系统的因果效应。Xu 等 (2022b) 从卫星影像和其他地理空间数据中联合提取和评估多种灾害影响的复杂相互作用, 通过建模因果关系推断地震引发的次生效应和建筑物损毁, 从而在区域范围内提供高分辨率的建筑物损毁估计。

6.1.3 时空因果推理

时空因果推理结合时间序列分析和空间统计学, 通过应用时空回归模型、时空贝叶斯网络、机器学习等方法, 揭示空间地理和时间维度上变量之间的因果关系。Ali 等 (2024) 提出了基于深度学习的时空因果推理潜在结果模型, 利用 U-Net

架构来捕捉数据中随时间变化的全局和局部空间干扰,并基于潜在结果模型的平均因果效应估计空间干扰对数据的直接和间接效应。Wang等(2024b)利用因果机制在时空动态系统中的稳定不变性,基于Transformer结构和自监督训练进行因果不变学习以提取因果特征,进一步通过迁移学习提升下游任务的模型性能,揭示时空复杂动态系统中的内在因果模式,提高表示学习与迁移学习等过程的解释性和可靠性,在极端天气感知与预测任务中取得显著效果。

6.2 因果赋能智能解译能力提升

近年来,多模态大模型和通用基础模型的兴起将空天信息智能解译应用推向了新的高潮。深度学习模型在强大算力和大规模参数的加持下,凭借其卓越的特征表示和非线性拟合能力,能够从海量观测数据中自动提取内在信息和特征,然而忽略了学习对模式和特征关联的明确理解。这种缺乏解释性的特征,使得模型在实际应用中可能面临可控性和可解释性的问题,限制了其在某些关键领域的应用效果。因此,早期智能解译模型主要追求准确率,而近几年的研究则更加关注模型普适性、鲁棒性和可靠性的预测,比如对长尾、类别不平衡或样本缺乏场景下的无偏推理能力(Tang等,2020)、无标注数据场景下的可靠迁移能力(Qiu,2023)、任务场景发生变化时(不满足独立同分布假设)的泛化适应能力(Liu等,2021)以及复杂场景下模型推理的可解释性(Wu等,2023),本质上是使模型具备因果推理能力的需求,保证模型在现实应用中一些极端场景下的可靠性和稳定性。

6.2.1 无偏推理能力

在样本不均衡场景下的无偏推理与精度优化方面,统计关联学习容易受数据偏差影响产生偏置问题,导致训练的模型并不稳定甚至结果不可控,以因果关系为基础的方法则更倾向关注与目标对象相关的因果因素,推导出具有逻辑性的因果链而不受数据变化或伪关联的干扰(Zhang等,2023)。Zhou等(2022)关注SAR影像的开集目标识别问题,通过构建生成因果模型将样本特征和类别解耦进而生成反事实图像,以缓解可见类别和未知类别识别率的不平衡问题。Wang等(2019)将生成对抗网络(GAN)与因果推理相结合,在

学习数据分布时考虑观测变量之间的潜在因果关系以通过GAN生成更加逼真的遥感图像,消除各种遥感任务训练样本缺乏的问题。

6.2.2 迁移泛化能力

在领域分布变化场景的模型泛化性增强和领域迁移方面,基于因果理论的方法通常侧重于将不同领域或多源异构数据的领域上下文信息视为混杂因素,通过因果结构的指导进行干预调控,消除模型对混杂因素的依赖以学习因果不变特征,实现领域分布产生偏移场景下的稳定学习(Zhang等,2024b)。Zhu等(2024)针对遥感影像的域偏移问题,构建因果特征解耦模块和因果干预模块,以缓解传统统计关联学习模型容易受混淆噪声和数据分布偏移影响的问题,从而提高模型在高分辨率遥感影像光谱成像模式和传感器类型发生变化时的场景适应能力。Xu等(2024)将因果推理引入遥感影像的多模态智能解译任务,提出两阶段因果特征提取框架,通过捕捉多模态异构数据之间的因果关系来帮助网络学习更具泛化性的类别表示,从而解决低分辨率遥感影像土地覆盖任务中因传感器成像偏差导致的类别特征混淆问题。Yu等(2024)为了消除遥感影像中由于背景和目標外观变化导致的图像内在偏差,以及地理环境差异导致的图像之间分布差异,提出了一种基于因果干预的遥感影像语义分割范式,进一步结合图像内与图像间像素对比学习保持模型特征空间的紧凑对齐,从而提高模型在影像外观分布变化等非因果偏差影响下的鲁棒性。

6.2.3 模型推理的可解释性

在神经网络的可解释性应用方面,利用因果效应来驱动模型的决策过程,克服基于关联关系的数据驱动方法容易受伪关联信息错误引导问题,提高模型的可解释性和学习可靠性(Chen等,2018)。Xiong等(2022)针对天基海洋观测系统获取的光学遥感影像目标分类任务,联合因果图与Transformer的多头注意力机制设计出因果注意力以挖掘注意力特征区域与分类结果的本质因果关系,构建出具有高分类精度和可解释性的神经网络框架。Dong等(2024a)针对SAR影像分类任务提出因果关系驱动的特征增强框架,在训练和测试过程构建结构因果模型,利用因果干预和后门调整方法提高卷积神经网络的特征提取质量。Li

等 (2023a) 分析 SAR 影像中目标类别、背景杂波和阴影区域的相互作用, 从模型过拟合角度解释数据偏差与模型偏差对因果关系的影响, 表明深度学习模型通过因果推理来抑制背景杂波的有效性, 在实际应用中能够提高模型对目标特征变化的鲁棒性。

7 结 论

因果推断凭借其对因果关系的深入发掘与有效利用正逐渐成为当前人工智能范式的有效补充, 有望实现更可靠、更稳定、可迁移、可解释、分布式新型空天信息智能解译框架。尽管空天领域具备丰富多样的观测数据, 但较难主动控制地球表层或非合作目标的变化以进行人工实验, 更需要充分借助最新的机器学习方法从海量数据中挖掘稳定的因果关系。

针对空天信息领域的数据与应用特点, 本文梳理了空天信息因果智能解译的概念、问题、方法、应用与未来挑战。在回顾结构因果模型与潜在结果模型两类因果学习框架的基础上, 介绍了多种能够考虑空天数据时序特征与空间信息特征的因果推理方法。在利用因果关系进行智能解译时, 本文归纳了因果图模型、反事实推理、模型特征干预 3 类蕴含因果关系的智能解译模型构建方法, 并列举了因果推理与时空大数据以及因果模型与深度智能解译模型相结合的典型应用。

总体而言, 目前因果智能在空天信息领域的研究仍处于起步阶段。面向未来, 因果智能在空天信息领域仍将面临高维数据因果表示、复杂场景因果变量解耦、因果基准数据集等多项挑战。随着研究与应用的逐步深入, 因果智能将不断为空天信息智能解译注入新的持续驱动力。

参考文献 (References)

Ali S, Faruque O and Wang J W. 2024. Estimating direct and indirect causal effects of spatiotemporal interventions in presence of spatial interference//Proceedings of the European Conference on Machine Learning and Knowledge Discovery in Databases. Research Track. Vilnius: Springer: 213-230 [DOI: 10.1007/978-3-031-70352-2_13]

Altman N and Krzywinski M. 2015. Association, correlation and causation. *Nature Methods*, 12(10): 899-900. [DOI: 10.1038/nmeth.3587]

Bannari A, Asalhi H and Teillet P M. 2002. Transformed difference

vegetation index (TDVI) for vegetation cover mapping//IEEE International Geoscience and Remote Sensing Symposium. Toronto: IEEE: 3053-3055 [DOI: 10.1109/IGARSS.2002.1026867]

Cha K, Seo J and Lee T. 2024. A billion-scale foundation model for remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*: 1-17. [DOI: 10.1109/jstars.2024.3401772]

Chen J, Wu H, Zhang J X, Wang D H, Liao A P, Liu W Z, Zhang J, Miao Q J, Feng W L and Lu W H. 2022. Building natural resources surveying and monitoring technological system: direction and research agenda. *Acta Geographica Sinica*, 77(5): 1041-1055 (陈军, 武昊, 张继贤, 王东华, 廖安平, 刘万增, 张俊, 苗前军, 冯文利, 卢卫华. 2022. 自然资源调查监测技术体系构建的方向与任务. *地理学报*, 77(5): 1041-1055) [DOI: 10.11821/dlxb202205001]

Chen J B, Song L, Wainwright M J and Jordan M I. 2018. Learning to explain: an information-theoretic perspective on model interpretation//Proceedings of the 35th International Conference on Machine Learning. Stockholm: ICML: 882-891

Chen N C, Liu D D and Du W Y. 2017. Improved balloon snake method for water boundary extraction in remote sensing images. *Journal of Remote Sensing (in Chinese)*, 21(3): 425-433 (陈能成, 刘丹丹, 杜文英. 2017. 改进 Balloon Snake 算法提取遥感影像水体边界. *遥感学报*, 21(3): 425-433) [DOI: 10.11834/jrs.20176126]

Chen T, Kornblith S, Norouzi M and Hinton G E. 2020. A simple framework for contrastive learning of visual representations//Proceedings of the 37th International Conference on Machine Learning. [s.l.]: ICML: 1597-1607

Chen Z A, Liu J L, Wang X S, Lu J F and Yin W T. 2022. On representing mixed-integer linear programs by graph neural networks//Proceedings of the 11th International Conference on Learning Representations. Kigali: ICLR: 1-31

Clevers J G P W, De Jong S M, Epema G F, Van Der Meer F D, Bakker W H, Skidmore A K and Scholte K H. 2002. Derivation of the red edge index using the MERIS standard band setting. *International Journal of Remote Sensing*, 23(16): 3169-3184 [DOI: 10.1080/01431160110104647]

Dong H W, Si L Y, Qiang W W, Zhang L M, Yu J Z, Wu Y Q, Zheng C W and Sun F C. 2024a. A novel causal inference-guided feature enhancement framework for PolSAR image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5200816. [DOI: 10.1109/tgrs.2023.3343380]

Dong L J, Geng J and Jiang W. 2024b. Spectral-spatial enhancement and causal constraint for hyperspectral image cross-scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5507013 [DOI: 10.1109/TGRS.2024.3360103]

Fu K, Lu W X, Liu X Y, Deng C B, Yu H F and Sun X. 2024. A comprehensive survey and assumption of remote sensing foundation modal. *National Remote Sensing Bulletin*, 28(7): 1667-1680 (付琨, 卢宛萱, 刘小煜, 邓楚博, 于泓峰, 孙显. 2024. 遥感基础模型发展综述与未来设想. *遥感学报*, 28(7): 1667-1680) [DOI: 10.11834/jrs.20233313]

Gao B B, Yang J Y, Chen Z Y, Sugihara G, Li M C, Stein A, Kwan M P

- and Wang J F. 2023. Causal inference from cross-sectional earth system data with geographical convergent cross mapping. *Nature Communications*, 14(1): 5875 [DOI: 10.1038/s41467-023-41619-6]
- Ge Y, Zhang X N, Atkinson P M, Stein A and Li L F. 2022. Geoscience-aware deep learning: a new paradigm for remote sensing. *Science of Remote Sensing*, 5: 100047 [DOI: 10.1016/j.srs.2022.100047]
- Goddu M K and Gopnik A. 2024. The development of human causal learning and reasoning. *Nature Reviews Psychology*, 3(5): 319-339 [DOI: 10.1038/s44159-024-00300-5]
- Goldberg L R. 2019. The book of why: the new science of cause and effect. *Quantitative Finance*, 19(12): 1945-1949 [DOI: 10.1080/14697688.2019.1655928]
- Granger C W J. 1969. Investigating causal relations by econometric models and cross-spectral methods. *Econometrica*, 37(3): 424-438 [DOI: 10.2307/1912791]
- Gu X H, Li Z J, Miao J H, Li X H and Shen H F. 2023. Dual-channel parallel hybrid convolutional neural networks based classification method for high-resolution remote sensing image. *Acta Geodaetica et Cartographica Sinica*, 52(5): 798-807 (顾小虎, 李正军, 缪健豪, 李星华, 沈焕锋. 2023. 高分遥感影像双通道并行混合卷积分类方法. 测绘学报, 52(5): 798-807) [DOI: 10.11947/j. AGCS.2023.20220163]
- Guo Q, Xu H L and Xu F. 2023. Causal adversarial autoencoder for disentangled SAR image representation and few-shot target recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5221114 [DOI: 10.1109/TGRS.2023.3330478]
- Huang C and Hou X J. 2022. Crop classification with time series remote sensing based on Bi-LSTM model. *Scientia Agricultura Sinica*, 55(21): 4144-4157 (黄翀, 侯相君. 2022. 基于 Bi-LSTM 模型的时间序列遥感作物分类研究. 中国农业科学, 55(21): 4144-4157) [DOI: 10.3864/j.issn.0578-1752.2022.21.005]
- Imbens G W and Rubin D B. 2015. *Causal Inference for Statistics, Social, and Biomedical Sciences*. Cambridge: Cambridge University Press [DOI: 10.1017/CBO9781139025751]
- Jung H, Oh Y, Jeong S, Lee C and Jeon T. 2022. Contrastive self-supervised learning with smoothed representation for remote sensing. *IEEE Geoscience and Remote Sensing Letters*, 19: 8010105.
- Kim J, Lee B K and Ro Y M. 2023. Causal unsupervised semantic segmentation. *arXiv*: 2310.07379 [DOI: 10.48550/arXiv.2310.07379]
- Kokaly R F, Clark R N, Swayze G A, Livo K E, Hoefen T M, Pearson N C, Wise R A, Benzel W M, Lowers H A, Driscoll R L and Klein A J. 2017. *USGS Spectral Library Version 7. Geological Survey Data Series 1035*. USGS: 61
- Li C J, Huang H and Li W. 2018. Research on agricultural remote sensing image cultivated land extraction technology based on support vector machine. *Instrumentation Technology*, 11: 5-8, 48 (李昌俊, 黄河, 李伟. 2018. 基于支持向量机的农业遥感图像耕地提取技术研究. 仪表技术, (11): 5-8, 48) [DOI: 10.19432/j.cnki.issn1006-2394.2018.11.002]
- Li D R. 2017. Construction of civil-military integrated aerospace information real-time service system. *Civil-Military Integration on Cyberspace*, (2): 23-27 (李德仁. 2017. 建设军民深度融合的空天信息实时服务系统. 网信军民融合, (2): 23-27)
- Li J N, Xiong R B, Lan Y Y, Pang L, Guo J F and Cheng X Q. 2023. Overview of the frontier progress of causal machine learning. *Journal of Computer Research and Development*, 60(1): 59-84 (李家宁, 熊睿彬, 兰艳艳, 庞亮, 郭嘉丰, 程学旗. 2023. 因果机器学习的前沿进展综述. 计算机研究与发展, 60(1): 59-84) [DOI: 10.7544/issn1000-1239.202110780]
- Li W and Li Z X. 2023. Causal-SETR: a segmentation transformer variant based on causal intervention//*Proceedings of the 16th Asian Conference on Computer Vision*. Macao, China: Springer: 414-430 [DOI: 10.1007/978-3-031-26293-7_25]
- Li W J, Yang W, Liu L, Zhang W P and Liu Y X. 2023a. Discovering and explaining the noncausality of deep learning in SAR ATR. *IEEE Geoscience and Remote Sensing Letters*, 20: 4004605. [DOI: 10.1109/lgrs.2023.3266493]
- Li X C, Bürgi P M, Ma W, Noh H Y, Wald D J and Xu S S. 2023b. DisasterNet: causal bayesian networks with normalizing flows for cascading hazards estimation from satellite imagery//*Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. Long Beach: ACM: 4391-4403 [DOI: 10.1145/3580305.3599807]
- Liu C, Sun X W, Wang J D, Tang H Y, Li T, Qin T, Chen W and Liu T Y. 2021. Learning causal semantic representation for out-of-distribution prediction//*Proceedings of the 35th International Conference on Neural Information Processing Systems*. [s.l.]: ACM: 471
- Liu Y, Kang J, Guan H Y and Wang H Y. 2023. Road extraction model of high-resolution remote sensing images based on dual-attention residual network. *Journal of Geo-information Science*, 25(2): 396-408 (刘洋, 康健, 管海燕, 汪汉云. 2023. 基于双注意力残差网络的高分遥感影像道路提取模型. 地球信息科学学报, 25(2): 396-408) [DOI: 10.12082/dqxxkx.2023.220513]
- Liu Y F, Ding L L and Meng F X. 2021. High spatial resolution imagery semantic segmentation based on object-context representation CNN. *Remote Sensing Information*, 36(6): 66-74. (刘艳飞, 丁乐乐, 孟凡效. 2021. 目标上下文卷积神经网络高分遥感影像语义分割. 遥感信息, 36(6): 66-74) [DOI: 10.3969/j.issn.1000-3177.2021.06.009]
- Lyu W P, Li W M and Chen G. 2012. Development status and tendency analysis of foreign air and space information systems. *Aerodynamic Missile Journal*, (1): 38-43 (吕文平, 李为民, 陈刚. 2012. 国外空天信息系统发展现状及趋势分析. 飞航导弹, (1): 38-43) [DOI: 10.16338/j.issn.1009-1319.2012.01.020]
- Mañas O, Lacoste A, Giró-i-Nieto X, Vazquez D and Rodríguez P. 2021. Seasonal contrast: unsupervised pre-training from uncurated remote sensing data//*Proceedings of the IEEE/CVF International Conference on Computer Vision*. Montreal: IEEE: 9394-9403 [DOI: 10.1109/ICCV48922.2021.00928]
- Massmann A, Gentine P and Runge J. 2021. Causal inference for process understanding in Earth sciences. *arXiv*: 2105.00912. [DOI: 10.48550/arXiv.2105.00912]
- Meng Y, Chen J B, Zhang Z, Liu Z Q, Zhao Z T, Huo L Z, Shi K L, Liu D Y, Deng Y P and Tang P. 2024. Knowledge and data driven remote sensing image interpretation: recent developments and

- prospects. *National Remote Sensing Bulletin*, 28(11): 2698-2718 (孟瑜, 陈静波, 张正, 刘志强, 赵智韬, 霍连志, 史科理, 刘帝佑, 邓毓珊, 唐娉. 2024. 知识与数据驱动的遥感图像智能解译: 进展与展望. *遥感学报*, 28(11): 2698-2718) [DOI: 10.11834/jrs.20243547]
- Otgonbaatar S, Datcu M and Demir B. 2022. Causality for remote sensing: an exploratory study//IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium. Kuala Lumpur: IEEE: 259-262 [DOI: 10.1109/IGARSS46834.2022.9883060]
- Ouyang C, Chen C, Li S R, Li Z J, Qin C, Bai W J and Rueckert D. 2023. Causality-inspired single-source domain generalization for medical image segmentation. *IEEE Transactions on Medical Imaging*, 42(4): 1095-1106 [DOI: 10.1109/TMI.2022.3224067]
- Pearl J. 2000. *Causality: Models, Reasoning and Inference*. Cambridge: Cambridge University Press: 379
- Pearl J. 2018. Theoretical impediments to machine learning with seven sparks from the causal revolution//Proceedings of the 11th ACM International Conference on Web Search and Data Mining. Marina Del Rey: ACM: 3 [DOI: 10.1145/3159652.3176182]
- Peng H, Chen P, Liu R and Chen L N. 2024. Spatiotemporal information conversion machine for time-series forecasting. *Fundamental Research*, 4(6): 1674-1687 [DOI: 10.1016/j.fmre.2022.12.009]
- Peng L and Chi T. 2023. Aerospace information science and technology innovation and industrial development layout. *People's Tribune*, (16): 18-23. (彭玲, 池天河. 2023. 空天信息科技创新与产业发展布局. *人民论坛*, (16): 18-23) [DOI: 10.3969/j.issn.1004-3381.2023.16.004]
- Pérez Valentín J M and Müller M F. 2020. Impact of hurricane maria on beach erosion in puerto rico: remote sensing and causal inference. *Geophysical Research Letters*, 47(6): e2020GL087306 [DOI: 10.1029/2020GL087306]
- Qiu S. 2023. Causality-inspired source-free domain adaptation for medical image classification//Proceedings of the 12th International Conference on Image and Graphics. Nanjing: Springer: 68-80 [DOI: 10.1007/978-3-031-46317-4_7]
- Roberts M R, Ashrafzadeh S and Asgari M M. 2019. Research techniques made simple: interpreting measures of association in clinical research. *Journal of Investigative Dermatology*, 139(3): 502-511.e1 [DOI: 10.1016/j.jid.2018.12.023]
- Rohekar R Y, Nisimov S, Gurwicz Y and Novik G. 2021. Iterative causal discovery in the possible presence of latent confounders and selection bias//Proceedings of the 35th International Conference on Neural Information Processing Systems. [s.l.]: ACM: 188
- Runge J, Bathiany S, Bollt E, Camps-Valls G, Coumou D, Deyle E, Glymour C, Kretschmer M, Mahecha M D, Muñoz-Marí J, van Nes E H, Peters J, Quax R, Reichstein M, Scheffer M, Schölkopf B, Spirtes P, Sugihara G, Sun J, Zhang K and Zscheischler J. 2019. Inferring causation from time series in Earth system sciences. *Nature Communications*, 10(1): 2553 [DOI: 10.1038/s41467-019-10105-3]
- Runge J, Gerhardus A, Varando G, Eyring V and Camps-Valls G. 2023. Causal inference for time series. *Nature Reviews Earth and Environment*, 4(7): 487-505 [DOI: 10.1038/s43017-023-00431-y]
- Schölkopf B. 2022. Causality for machine learning//Probabilistic and Causal Inference: The Works of Judea Pearl. [s.l.]: ACM: 765-804 [DOI: 10.1145/3501714.3501755]
- Scholkopf B, Locatello F, Bauer S, Ke N R, Kalchbrenner N, Goyal A and Bengio Y. 2021. Toward causal representation learning. *Proceedings of the IEEE*, 109(5): 612-634. [DOI: 10.1109/jproc.2021.3058954]
- Schreiber T. 2000. Measuring information transfer. *Physical Review Letters*, 85(2): 461-464 [DOI: 10.1103/PhysRevLett.85.461]
- Shao K, Wang M Z and Wang G Y. 2024. Transformer-based multiscale remote sensing semantic segmentation network. *CAAI Transactions on Intelligent Systems*, 19(4): 920-929 (邵凯, 王明政, 王光宇. 2024. 基于Transformer的多尺度遥感语义分割网络. *智能系统学报*, 19(4): 920-929) [DOI: 10.11992/tis.20230426]
- Su J B, Chen D X, Zheng D H, Su Y and Li X. 2023. The insight of why: causal inference in earth system science. *Science China Earth Sciences*, 66(10): 2169-2186 [DOI: 10.1007/s11430-023-1148-7]
- Sugihara G, May R, Ye H, Hsieh C H, Deyle E, Fogarty M and Munch S. 2012. Detecting causality in complex ecosystems. *Science*, 338(6106): 496-500 [DOI: 10.1126/science.1227079]
- Sun X, Wang P J, Lu W X, Zhu Z C, Lu X N, He Q B, Li J X, Rong X E, Yang Z J, Chang H, He Q L, Yang G, Wang R P, Lu J W and Fu K. 2023. RingMo: a remote sensing foundation model with masked image modeling. *IEEE Transactions on Geoscience and Remote Sensing*, 61: 5612822 [DOI: 10.1109/tgrs.2022.3194732]
- Tang K H, Huang J Q and Zhang H W. 2020. Long-tailed classification by keeping the good and removing the bad momentum causal effect//Proceedings of the 34th International Conference on Neural Information Processing Systems. Vancouver: ACM: 128
- Tian Z H, Chang P, He X H and Cheng X J. 2023. Land cover classification of high resolution remote sensing images based on CNN-GCN. *Science of Surveying and Mapping*, 48(6): 59-72 (田智慧, 常蓬, 赫晓慧, 程渐杰. 2023. 一种基于CNN-GCN的高分辨率遥感影像土地覆盖分类. *测绘科学*, 48(6): 59-72) [DOI: 10.16251/j.cnki.1009-2307.2023.06.008]
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser Ł and Polosukhin I. 2017. Attention is all you need//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: ACM: 6000-6010
- Wang C G, Liu Y P, Zhang X J, Li X C, Paramygin V, Subgranon A, Sheng P, Zhao X L and Xu S S. 2023. Causality-informed rapid post-hurricane building damage detection in large scale from InSAR imagery//Proceedings of the 8th ACM SIGSPATIAL International Workshop on Security Response using GIS. Hamburg: ACM: 7-12 [DOI: 10.1145/3615884.3629422]
- Wang C W, Chen X, Qin Y, Luo S Y, Huang Y L, Pei J F and Yang J Y. 2024a. Unveiling causalities in SAR ATR: a causal interventional approach for limited data. *IEEE Geoscience and Remote Sensing Letters*, 21: 4009305 [DOI: 10.1109/lgrs.2024.3393623]
- Wang G X, Dong G S, Li H, Han L R, Tao X W and Ren P. 2019. Remote sensing image synthesis via graphical generative adversarial networks//International Geoscience and Remote Sensing Sympos-

- sium. Yokohama: IEEE: 10027-10030 [DOI: 10.1109/IGARSS.2019.8898915]
- Wang K, Wu H, Duan Y F, Zhang G B, Wang K, Peng X J, Zheng Y, Liang Y X and Wang Y. 2024b. NuwaDynamics: discovering and updating in causal spatio-temporal modeling//12th International Conference on Learning Representations. Vienna: ICLR
- Wang S, Han W, Huang X H, Zhang X H, Wang L Z and Li J. 2024c. Trustworthy remote sensing interpretation: concepts, technologies, and applications. *ISPRS Journal of Photogrammetry and Remote Sensing*, 209: 150-172. [DOI: 10.1016/j.isprsjprs.2024.02.003]
- Wu C W, Wang X T, Lian D F, Xie X and Chen E H. 2023. A causality inspired framework for model interpretation//Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining. Long Beach: ACM: 2731-2741 [DOI: 10.1145/3580305.359240]
- Xiong W, Xiong Z Y and Cui Y Q. 2022. An explainable attention network for fine-grained ship classification using remote-sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 60: 5620314 [DOI: 10.1109/tgrs.2022.3162195]
- Xu S S, Dimasaka J, Wald D J and Noh H Y. 2022a. Bayesian updating of seismic ground failure estimates via causal graphical models and satellite imagery. *arXiv preprint arXiv: 2204.07653* [DOI: 10.48550/arXiv.2204.07653]
- Xu S S, Dimasaka J, Wald D J and Noh H Y. 2022b. Seismic multi-hazard and impact estimation via causal inference from satellite imagery. *Nature Communications*, 13(1): 7793 [DOI: 10.1038/s41467-022-35418-8]
- Xu Z B. 2021. Ten fundamental problems for artificial intelligence: mathematical and physical aspects. *SCIENTIA SINICA Informationis*, 51(12): 1967-1978. (徐宗本. 2021. 人工智能的10个重大数理基础问题. *中国科学: 信息科学*, 51(12): 1967-1978) [DOI: 10.1360/SSI-2021-0254]
- Xu Z Y, Jiang W and Geng J. 2024. Texture-aware causal feature extraction network for multimodal remote sensing data classification. *IEEE Transactions on Geoscience and Remote Sensing*, 62: 5103512 [DOI: 10.1109/tgrs.2024.3368091]
- Yang D, Zhou Y N, Yang X Z, Gao L J and Feng L. 2020. Vegetation mapping in Taibai Mountain Area supported by LSTM with time series Sentinel-1A data. *Journal of Geo-information Science*, 22(12): 2445-2455 (杨丹, 周亚男, 杨先增, 郜丽静, 冯莉. 2020. LSTM支持下时序Sentinel-1A数据的太白山山区植被制图. *地球信息科学学报*, 22(12): 2445-2455) [DOI: 10.12082/dqxxkx.2020.200338]
- Yang X, Zhang H W, Qi G J and Cai J F. 2021. Causal attention for vision-language tasks//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE: 9842-9852 [DOI: 10.1109/CVPR46437.2021.00972]
- Yu J Y, Hu T H, Dai Y N, Zhang D A and Xia W F. 2023. Anchor-free transformer algorithm for aerial remote sensing target detection. *Acta Electronica Sinica*, 51(11): 3238-3247. (喻九阳, 胡天豪, 戴耀南, 张德安, 夏文凤. 2023. 面向遥感目标检测的无锚框Transformer算法. *电子学报*, 51(11): 3238-3247) [DOI: 10.12263/DZXB.20220612]
- Yu L, Jin Q Z and Wang W. 2024. Intra- and inter-image causal intervention for robust semantic segmentation in remote-sensing images. *IEEE Geoscience and Remote Sensing Letters*, 21: 6007005 [DOI: 10.1109/lgrs.2024.3383457]
- Yuan Y, Ding X Y and Bar-Joseph Z. 2020. Causal inference using deep neural networks DOI:10.48550/arXiv.2011.12508
- Zhang B, Chen Z C, Peng D L, Benediktsson J A, Liu B, Zou L, Li J and Plaza A. 2019. Remotely sensed big data: evolution in model development for information extraction [point of view]. *Proceedings of the IEEE*, 107(12): 2294-2301 [DOI: 10.1109/jproc.2019.2948454]
- Zhang B, Yang X M, Gao L R, Meng Y, Sun X, Xiao C C and Ni L. 2022. Geo-cognitive models and methods for intelligent interpretation of remotely sensed big data. *Acta Geodaetica et Cartographica Sinica*, 51(7): 1398-1415 (张兵, 杨晓梅, 高连如, 孟瑜, 孙显, 肖晨超, 倪丽. 2022. 遥感大数据智能解译的地理学认知模型与方法. *测绘学报*, 51(7): 1398-1415) [DOI: 10.11947/j. AGCS.2022.20220279]
- Zhang C, Nong X Z, Behzadian K, Campos L C, Chen L H and Shao D G. 2024a. A new framework for water quality forecasting coupling causal inference, time-frequency analysis and uncertainty quantification. *Journal of Environmental Management*, 350: 119613 [DOI: 10.1016/j.jenvman.2023.119613]
- Zhang K X, Sun Q Y, Zhao C Q and Tang Y. 2024b. Causal reasoning in typical computer vision tasks. *Science China Technological Sciences*, 67(1): 105-120 [DOI: 10.1007/s11431-023-2502-9]
- Zhang W, Wang X S, Wang H Y and Cheng Y H. 2024c. Causal meta-reinforcement learning for multimodal remote sensing data classification. *Remote Sensing*, 16(6): 1055 [DOI: 10.3390/rs16061055]
- Zhang W X, Tang P and Zhang Z. 2023. Time series classification of remote sensing data based on temporal self-attention mechanism. *National Remote Sensing Bulletin* 27(8): 1914-1924 (张伟雄, 唐娉, 张正. 2023. 基于时序自注意力机制的遥感数据时间序列分类. *遥感学报*, 27(8): 1914-1924) [DOI: 10.11834/jrs.20210453]
- Zhang Y F, Kang B Y, Hooi B, Yan S C and Feng J S. 2023. Deep long-tailed learning: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(9): 10795-10816 [DOI: 10.1109/TPAMI.2023.3268118]
- Zhang Y M, Li R Q, Du Z R and Ye Q. 2024d. A ship detection method in infrared remote sensing images based on image generation and causal inference. *Electronics*, 13(7): 1293 [DOI: 10.3390/electronics13071293]
- Zheng X, Aragam B, Ravikumar P and Xing E P. 2018. Dags with NO TEARS: continuous optimization for structure learning//Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: ACM: 9492-9503
- Zhou S M, Liu X and Wang K. 2014. A brief analysis of the development and application patterns of aerospace information systems. *Aerodynamic Missile Journal*, (10): 57-60 (周绍明, 刘旭, 王坤. 2014. 空天信息系统发展及应用模式浅析. *飞航导弹*, (10): 57-60) [DOI: 10.16338/j.issn.1009-1319.2014.10.018]
- Zhou X Y, Tang T, Cui Y T and Kuang G Y. 2022. SAR open set recog-

tion based on counterfactual framework//2022 Photonics and Electromagnetics Research Symposium (PIERS). Hangzhou: IEEE: 249-253 [DOI: 10.1109/PIERS55526.2022.9793029]
Zhu J R, Guo Y, Sun G, Hong L and Chen J. 2024. Causal prototype-

inspired contrast adaptation for unsupervised domain adaptive semantic segmentation of high-resolution remote sensing imagery. IEEE Transactions on Geoscience and Remote Sensing, 62: 5640017 [DOI: 10.1109/TGRS.2024.3430556]

Causality-inspired intelligent interpretation of aerospace information

MENG Yu^{1,2}, ZHANG Zheng^{1,2}, XI Zhihao¹, CHEN Jingbo^{1,2}, DENG Ligao^{1,2},
DENG Yupeng¹, KONG Yunlong¹

1. Aerospace Information Research Institute, Chinese Academy of Sciences, Beijing 100094, China;

2. School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 101408, China

Abstract: Aerospace information intelligent interpretation refers to the utilization of artificial intelligence technology to intelligently process multi-source remote sensing data acquired from space-based platforms such as satellites and space stations, or from unmanned aerial vehicles and floatation vehicles, in order to extract key information from them and to realize highly efficient and automated analysis as well as application. With the rapid advancement of deep learning, data-driven intelligent interpretation models have become the mainstream approach. These models leverage large-scale, high-quality annotated datasets and sophisticated neural network architectures to enhance interpretation performance. However, despite their success, such methods still face several challenges in practical applications. For instance, they heavily rely on extensive annotated datasets, leading to high data acquisition and manual labeling costs. Additionally, these models often exhibit limited generalization capabilities, making them less adaptable to diverse remote sensing environments and varying data distributions. Furthermore, traditional deep learning models typically lack interpretability, as their feature-fitting processes based on statistical correlations are susceptible to confounding factors, reducing reliability and trustworthiness in real-world decision-making. To address these challenges, causality-inspired intelligent interpretation methods integrate causal reasoning with deep learning, incorporating causal relationship modeling into data analysis. Unlike conventional data-driven methods, causality-inspired intelligent interpretation emphasizes not only statistical correlations among variables but also the modeling of causal relationships. This enables more rational inference and decision-making in complex aerospace data environments, thereby improving both interpretability and reliability. Consequently, causality-inspired intelligent interpretation is considered to be an essential development direction for aerospace information intelligent interpretation in the future, and it is promising to become a new interpretation paradigm. This review focuses on integrating causal theory into aerospace information interpretation models. First, it explores current trends and research directions in aerospace information interpretation from three perspectives: correlation analysis, statistical modeling, and causal cognition. Based on the principles of causality—association, intervention, and counterfactual reasoning—this review constructs a “ladder of causation” framework to illustrate the role of causal reasoning in aerospace information analysis. Next, the study examines causal discovery and causal effect estimation methods tailored to the spatiotemporal characteristics of aerospace data. It also investigates causal representation learning in deep neural networks to assess how causal reasoning can enhance the accuracy and robustness of intelligent interpretation. Subsequently, three primary approaches to constructing causality-inspired intelligent interpretation models are discussed: (1) interpretation based on causal graphical models, (2) interpretation using counterfactual reasoning, and (3) interpretation centered on feature-level causal interventions. By embedding causal relationships into intelligent interpretation models, these methods improve model generalization and explainability, offering scientifically grounded solutions for aerospace data analysis. Finally, this review introduces typical applications of causality-inspired intelligent interpretation in aerospace observation environments, and summarizes the ideas of combining causal reasoning with spatiotemporal data from earth observation, causal model with intelligent interpretation model, aiming to provide valuable insights and references for future research in this field.

Key words: causal inference, intelligent interpretation, deep learning, causality-inspired, aerospace information, counterfactual inference, causal intervention

Supported by National Key Research and Development Program of China (No. 2021YFB3900503)