



基于专家知识的主动因果效应辨识

王天佐^{1,2}, 周志华^{1,2*}

1. 南京大学计算机软件新技术全国重点实验室, 南京 210023

2. 南京大学人工智能学院, 南京 210023

* 通信作者. E-mail: zhouzh@lamda.nju.edu.cn

收稿日期: 2022-10-10; 修回日期: 2023-06-21; 接受日期: 2023-08-16; 网络出版日期: 2023-12-12

科技创新 2030 “新一代人工智能”重大项目 (批准号: 2022ZD0114800) 和软件新技术与产业化协同创新中心资助项目

摘要 因果效应定量描述变量间的影响作用, 在许多现实任务中发挥着重要作用. 辨识因果效应需要依赖已知的因果关系. 一种确定因果关系的主流方法是引入干预信息, 即通过人为干预某些因素而获取的信息. 鉴于实际干预通常会带来巨大的成本, 本文提出利用易于获取的专家知识替代干预, 通过设计形如“在 XX 干预下, 目标变量的值相较于不干预时增大还是减小?”的问题并向专家咨询, 确定因果关系, 进而辨识因果效应. 尽管每次专家返回的信息量少于干预信息, 但通过一定次数的咨询, 本文方法可以达到与使用干预信息方法相近的因果效应辨识效果. 实验验证了上述结论.

关键词 因果效应辨识, 因果关系, 人机交互, 专家知识

1 引言

因果效应辨识 (causal effect identification) 是人工智能领域的重要任务. 变量间的因果效应定量地刻画了改变某一变量对另一变量造成的影响, 其辨识方法在决策任务中受到了广泛的关注. 在很多决策任务中, 用户希望通过调整决策变量优化目标变量. 例如, 商户通过调整售价、广告投入、商品类型、目标客户等最大化商户利润, 企业的人力部门通过调整薪资、发放福利等措施, 使企业的优秀员工继续为企业服务. 在上述例子中, 商品售价、广告投入、员工薪资等是决策变量, 而商户利润和员工留任是目标变量. 针对此类任务, 一个直接的方法是辨识各决策变量对目标变量的因果效应, 由此可知如何调整各决策变量能使目标变量最优.

因果效应的辨识依赖变量间的因果关系^[1,2]. 对于现实任务, 真实的因果关系往往无法获取. 因此, 通常需要先利用观测信息确定因果关系. 已有理论表明, 如果不引入额外假设, 通过观测信息无法获得完整的因果关系^[3]. 未知的因果关系往往会使得因果效应无法辨识.

引用格式: 王天佐, 周志华. 基于专家知识的主动因果效应辨识. 中国科学: 信息科学, 2023, 53: 2341-2354, doi: 10.1360/SSI-2022-0390
Wang T-Z, Zhou Z-H. Active causal effect identification with expert knowledge (in Chinese). Sci Sin Inform, 2023, 53: 2341-2354, doi: 10.1360/SSI-2022-0390

为了解决上述问题, 一种常用的办法是引入干预 (intervention) 来确定出未知的因果关系^[4,5]. 干预是一种实验, 即人为将一些变量设定为固定值, 然后在该设定下收集相关信息. 比如上面的商户问题中, 商户可以将商品售价设置为 5 元, 收集此时客户群体、利润等信息, 据此确定出更多因果关系. 然而, 干预通常是昂贵的. 在上述例子中, 若商家将售价设置成 5 元, 利润可能会大幅降低; 为了收集足够多的干预信息, 商家要在一段时间内忍受微薄的利润额, 这在现实中是不可接受的.

因此, 本文引入专家知识替代干预以确定因果关系, 从而实现因果效应辨识. 若专家可以直接指出未知的因果关系, 则已有方法可以直接应用^[6,7]. 然而, 更常见的场景是专家无法指出具体的因果关系. 对于引入专家知识, 最关键的问题之一是我们设计足够简单的问题向专家咨询, 确保专家能够回答. 对此, 本文考虑向专家咨询形如“在 XX 干预下, 目标变量的值相较于不干预时增大还是减小?”的问题. 这出于两方面考量: (1) 专家并非对现实中的所有变量信息都敏感, 但通常对目标变量信息敏感, 例如商业专家难以评估商品售价调整后目标客户的变化情况, 但对不同干预下的利润有敏锐的判断力; (2) 专家难以精准量化干预下的目标变量变化, 但往往能够估计其变化的趋势. 利用上述形式的专家知识, 本文建立确定因果关系的方法. 虽然每次向专家咨询得到的信息少于干预信息, 但是通过一定次数的咨询, 本文方法依然能够确定出因果效应辨识所需的因果关系. 实验验证了以上结论.

综合上述讨论, 本文提出基于专家知识的主动因果效应辨识方法. 贡献主要包含 3 点:

- (1) 本文首次引入容易获取的专家知识替代实际干预, 以确定因果关系;
- (2) 本文设计易于专家回答的问题, 并建立利用专家知识确定因果关系的方法;
- (3) 本文验证了利用专家知识能够实现决策变量对目标变量的因果效应辨识.

2 背景知识

在因果推断相关研究中, 通常用一个因果图 (或称因果结构) 刻画变量间的因果关系. 有向无环图 (directed acyclic graph, DAG) 表示了一类常见的因果图, 其中每个节点 V_i 表示一个变量, 有向边 $V_i \rightarrow V_j$ 刻画 V_i 对 V_j 有因果关系.

如果一个无环图包含有向边 (\rightarrow) 和无向边 ($-$), 则称该图为部分有向无环图 (partially directed acyclic graph, PDAG). DAG 是一种特殊的 PDAG. 如果两个 DAG 诱导了相同的条件独立关系, 则称它们是马尔可夫 (Markov) 等价的. 所有马尔可夫等价的 DAG 构成的集合称为马尔可夫等价类. 本质图 (essential graph) 是刻画马尔可夫等价类的一种特殊的 PDAG, 其中, 本质图上有边 $V_i \rightarrow V_j$ 当且仅当其表示的马尔可夫等价类中每个 DAG 都有 $V_i \rightarrow V_j$, 本质图上有无向边 $V_i - V_j$ 当且仅当马尔可夫等价类的 DAG 中既包含 $V_i \rightarrow V_j$ 也包含 $V_i \leftarrow V_j$.

在相关研究中, 通常用 PDAG 表示一个部分因果关系已知的因果图, 其中有向边表示已知的因果关系, 无向边表示相连的两个变量之间存在因果关系、但其方向尚不明确. 对于一个 PDAG P , 考虑图 P 中全部节点的某子集 V' , 由节点集 V' 诱导的 P 的子图是仅保留 P 中节点 V' 和 V' 间边的图. 如果有边 $V_i \rightarrow V_j/V_i \leftarrow V_j/V_i - V_j$, 则称 V_i 是 V_j 的父母/孩子/兄弟变量. 如果图 P 上有一条从 V_i 到 V_j 的路径, 其中每条边都是指向 V_j 方向的有向边, 那么这条路径称为 V_i 到 V_j 的有向路. 如果有从 $V_i(V_j)$ 到 $V_j(V_i)$ 的有向路, 或者 $i = j$, 那么称 V_i 是 V_j 的祖先 (后代) 变量. $\text{Anc}(V_i, G)/\text{Pa}(V_i, G)$ 表示图 G 上由 V_i 的全部祖先/父母变量构成的集合. 如果在一个 PDAG 中有形如 $V_i \rightarrow V_j \leftarrow V_k$ 的结构, 其中 V_i 与 V_k 不相邻, 则称它们组成了一个关于 V_j 的 v -结构. 对于 PDAG P , 如果在 P 上有一条从变量 V_i 到变量 V_j 的路, 路上的每一条边都是无向边, 则称 V_i 和 V_j 关于无向边连通. 我们称一个因果图 G 与 PDAG P 是一致的, 如果 G 和 P 有相同的 v -结构, 并且可以通过将 P 的全部无向

边转化成有向边获得 G .

$\text{do}(V_i = v_i)$ 表示对变量 V_i 进行干预, 将其值置为 v_i . V_i 对 Y 的因果效应记为 $\Pr(Y|\text{do}(V_i))$. 给定 DAG G , 如果 V_i 是 Y 的祖先变量, 则称 V_i 对 Y 有因果效应, 否则称 V_i 对 Y 没有因果效应. 给定变量 V_i 的所有父母变量构成的集合 $\mathbf{Z} = \text{Pa}(V_i, G)$, V_i 对 Y 的因果效应可以通过下式辨识:

$$\Pr_G(Y|\text{do}(V_i = v_i)) = \int_{\mathbf{Z}} \Pr(\mathbf{Z}) \Pr(Y|\mathbf{Z}, V_i) d\mathbf{Z}. \quad (1)$$

这里变量集 \mathbf{Z} 也被称为因果图 G 上关于 (V_i, Y) 的一个后门集, 上述辨识/估计方法称为后门准则.

3 相关工作

本文基于朱迪亚·珀尔 (Judea Pearl) 提出的因果框架, 利用专家知识确定因果关系并据此辨识出决策变量对目标变量的因果效应. 因此, 本节从因果效应辨识和因果关系学习两方面介绍相关工作.

因果效应辨识. 针对变量间因果关系完全可知的情况, 目前已有很多图理论被提出, 用以基于因果图辨识因果效应^[1, 2, 8~10]. 若变量间因果关系未知, 通过观测数据仅能获得一个马尔可夫等价类, 一些工作讨论了等价类中因果效应的可辨识性问题^[11~14]. 当马尔可夫等价类中因果效应不可辨识时, 为了能够获得关于因果效应的信息, 一些研究提出相应方法以确定因果效应的可能取值集合^[15~17]. 上述因果效应的相关研究均依赖于变量间的全部或者部分因果关系已知. 如果因果关系完全未知, 则需要首先对其进行确定 (或称学习). 变量间因果关系的学习是因果领域的一个重要问题.

因果关系学习. 在一般场景下, 基于观测数据仅能确定真实因果图的马尔可夫等价类^[3, 18, 19]. 当对变量间的函数关系进行进一步假设时, 更多的因果关系能够被确定^[20~23]. 为了在更广泛的情况下学习因果关系, 一种常见的手段是引入干预信息^[4, 5, 24~28]. 此外, 近期也有一些研究探索在变化的环境中进行因果关系的学习^[29, 30].

4 方法

4.1 问题设定

本文假设因果完全性 (causal sufficiency) 和忠实性 (faithfulness)¹⁾. 给定变量 X_1, X_2, \dots, X_p, Y 的观测数据, 其中 Y 为目标变量, 其他变量为决策变量, 本文目标是估计出各决策变量对 Y 的因果效应, 简称为对目标变量的因果效应辨识.

基于观测数据可以用 Peter-Clark (PC) 算法获得本质图 E ^[3]. 本质图是一种特殊的 PDAG. 如果本质图上全部因果关系已知, 则可以根据后门准则辨识各决策变量对目标变量的因果效应, 此时无须引入专家知识. 在大多情况下, 本质图上存在无向边, 这些未确定的因果关系导致部分因果效应无法辨识, 因此需要引入专家知识以确定这些因果关系. 本文考虑可以挑选变量 X 的某个取值 x , 向专家咨询是否 $\mathbb{E}(Y|\text{do}(X = x)) > \mathbb{E}(Y)$. 在后文中, 为了表述方便, 将此称为对变量 X 的伪干预, 称专家返回的信息为伪干预信息. 伪干预信息可以用来确定出一些额外的因果关系, 由此对图 PDAG 进行更新, 进而使得更多决策变量对目标变量的因果效应可辨识. 本文假设专家返回的信息是准确的. 本文方法主要包含两部分: 在第 4.2 小节中, 对 PDAG P 进行分解, 可以证明分解后各部分的结构学习是相互

1) 因果完全性即不存在对多个观测变量具有因果关系的未观测变量. 忠实性假设即若对任意三个两两互斥的观测变量集合 $\mathbf{A}, \mathbf{B}, \mathbf{C}$, 在因果图上有 $\mathbf{A} \perp\!\!\!\perp \mathbf{B} \mid \mathbf{C}$, 则因果图诱导出的分布上有 $\mathbf{A} \perp\!\!\!\perp \mathbf{B} \mid \mathbf{C}$. 详情见 Spirtes 等^[3].




图 1 连通块、局部因果图示意图. (a) PDAG P 和连通块 C_1, C_2, C_3 . 基于 P 的 X 局部因果图 (b) G_1 , (c) G_2 , (d) G_3 , (e) G_4 和 (f) G_5

Figure 1 Examples of chain component and local causal graph. (a) PDAG P and chain component C_1, C_2, C_3 . Local causal graph (b) G_1 , (c) G_2 , (d) G_3 , (e) G_4 , and (f) G_5

独立的, 因此复杂因果结构的学习可以转化成若干小因果结构的学习; 在第 4.3 小节中, 针对 PDAG P , 给出引入专家知识学习因果关系的方法. 结合上述两部分, 本文在第 4.4 小节给出算法, 迭代地引入伪干预并学习因果关系, 直至依据已确定的因果关系可实现对目标变量的因果效应辨识.

4.2 部分已知因果图分解

首先引入如下定义.

定义1 (连通块) 给定一个 PDAG P , 记 P' 为仅保留 P 中全部节点和无向边的子图, 由节点集 V' 诱导的 P' 的子图 $P'[V']$ 称为一个 P 上的连通块, 如果 (1) V' 中的任意两个节点在图 P' 都是关于无向边连通的; (2) 不存在 $V'' \supset V'$, 使得 V'' 中的任意两个节点在图 P' 都是关于无向边连通的.

根据定义 1 可以将 PDAG 上未确定的因果关系 (无向边) 拆解成若干部分, 每一部分是一个连通块. 以图 1 为例, 考虑如图 1(a) 所示的 PDAG P , 根据定义 1, 我们首先获得仅保留 P 中全部节点和无向边的子图 P' , 也就是说, P' 相对于 P 去掉了边 $B \rightarrow Y, C \rightarrow Y, Y \rightarrow E, Y \rightarrow D$. 在 P' 上 $\{A, B, X, C\}, \{Y\}, \{E, D\}$ 分别是连通的, 因此, P 拆解成图中虚线框表示的 3 个连通块 C_1, C_2, C_3 . 参考相关研究^[4,5], 这里给出命题 1 和 2.

命题1 (He 等^[4] 定理 4 和 5, Wang 等^[5] 命题 1) 考虑 PDAG P 中任一连通块 C . 当对变量 V 进行伪干预时, C 中部分未知因果关系可确定当且仅当 V 在 C 中.

命题2 (Wang 等^[5] 命题 2) 考虑 PDAG P 中的一个连通块 C , 且目标变量 Y 不在 C 中. 如果在 P 中不存在从 C 中变量到 Y 的有向路, 则在任一与 P 一致的因果图 G 中, 不存在从 C 中变量到 Y 的有向路.

命题 1 说明了连通块的结构学习是独立的. 假设有连通块 C_1, C_2, \dots, C_d , 如果对 C_1 中变量进行伪干预, 那么 C_2, \dots, C_d 中的无向边依旧无法确定. 此结论保证了整个因果结构的学习可以在不损失信息的前提下, 拆解成每个小连通块上因果结构的学习. 命题 2 说明了如果在某 PDAG 上, 不存在从某一个连通块 C 到变量 Y 的有向路, 那么在真实的因果结构中, C 上的所有变量都不可能是 Y 的祖先, 所以 C 上的任一变量对 Y 没有因果效应, 也就是说, 我们没有必要学习 C 中的因果关系. 例如, 在图 1(a) 中, 连通块 C_3 没有到 Y 的有向路, 因此, D, E 两变量对 Y 均没有因果效应, 此时无须学习

D, E 间的因果关系.

4.3 基于伪干预数据的因果关系学习

基于任一 PDAG P , 本小节提出利用伪干预数据进行因果关系学习的方法. 记伪干预变量为 X , 其选取方法将在第 4.4 小节给出. 首先, 我们引入假设 1. 它假设了如果在两个马尔可夫等价的因果图中 X 对 Y 的因果效应是不恒等的, 那么在上述两个因果图中, 对于变量 X 的任意干预值 x , 干预下 Y 的期望是不相同的.

假设1 (干预忠实性²⁾) 对于两个马尔可夫等价的因果图 G_i 和 G_j , 如果存在全体变量的观测分布使得通过式 (1) 估计的因果效应 $\Pr_{G_i}(Y|\text{do}(X)) \neq \Pr_{G_j}(Y|\text{do}(X))$, 则对任意观测分布, 对变量 X 的任意干预值 x , 有 $\mathbb{E}_{G_i}(Y|\text{do}(X=x)) \neq \mathbb{E}_{G_j}(Y|\text{do}(X=x))$.

由于 P 包含无向边, 它可以表示多个马尔可夫等价的因果图. 如何从马尔可夫等价的因果图中学习真实因果结构本质上是一个因果结构搜索的问题. 本小节因果关系学习的核心思想是, 对于不同马尔可夫等价的因果图, 当干预 $X=x$ 时, 干预下目标变量 Y 的分布可能是不同的. 因此, 我们可以根据实际干预下观测到的 Y , 排除掉一些与伪干预数据不符的因果图. 基于此思想, 一个直接的方法是, 基于 PDAG P 找到所有与 P 一致的因果图, 然后利用式 (1) 对每个因果图估计干预 X 时 Y 的期望. 通过与伪干预数据比对, 排除掉与伪干预数据不一致的因果图, 由此缩小因果结构的搜索范围, 使得部分因果关系可确定.

尽管上述方法是理论可行的, 由于图 P 可能包含很多节点, 遍历所有因果图并分别估计干预下 Y 的分布需要大量的计算开销, 现实中往往不可行. 实际上, 上述思路并不需要遍历全部图, 只需要遍历所有 X 的局部结构^[15], 也即 X 的全部无向边. 本文引入以下定义.

定义2 (基于 P 的 X 局部因果图) 给定一个 PDAG P , 在不引入新的 v -结构的前提下将 X 的无向边全部转化成有向边, 转化后的图 P' 称为一个基于 P 的 X 局部因果图.

由于 X 的每条无向边只有两种可能的方向, 所以不难遍历所有 X 的局部结构. 以图 1(a) 为例, 假设 X 有 3 条邻边, 因此有 8 种可能的结构组合. 根据定义 2, 可以获得 5 个基于 P 的 X 局部因果图, 如图 1(b)~(f) 所示. 其余 3 种未列出的结构组合会产生关于 X 的 v -结构, 不符合定义 2 中的条件, 在这里不做展示. 接下来, 我们在定义 3 引入关于 (X, Y) 的最小邻接后门集, 当上下文明确时, 我们省略掉 (X, Y) 并将其简称为 MPS (minimal parental set). 命题 3 指出, 两个因果图上 X 对 Y 的因果效应相同当且仅当两个因果图有相同的 MPS.

定义3 (关于 (X, Y) 的最小邻接后门集) 在一个 DAG G 中, 变量集 M 被称为关于 (X, Y) 的最小邻接后门集, 如果 (1) $M \subseteq \text{Pa}(X, G)$; (2) 在 G 中 $\text{Pa}(X, G) \setminus M \perp Y \mid M, X$; (3) 对任意 $\emptyset \subseteq T \subset M$, 在 G 中 $\text{Pa}(X, G) \setminus T \not\perp Y \mid T, X$.

命题3 记 G_i 和 G_j 是两个马尔可夫等价的因果图, M_i 和 M_j 分别是图 G_i 和 G_j 上关于 (X, Y) 的最小邻接后门集. 则有

$$\mathbb{E}_{G_i}(Y|\text{do}(X=x)) = \int_{M_i} \Pr(M_i) \mathbb{E}(Y|M_i, X) dM_i. \quad (2)$$

此外, 对任意观测分布恒成立 $\mathbb{E}_{G_i}(Y|\text{do}(X=x)) = \mathbb{E}_{G_j}(Y|\text{do}(X=x))$ 当且仅当 $M_i = M_j$.

2) 因果的经典假设“忠实性假设”也可等价定义成“给定因果图 G , 对任意两两互斥的变量集 A, B, C , 若存在 X_1, \dots, X_p, Y 的观测分布使得 $A \perp B \mid C$, 则对任意观测分布, 有 $A \perp B \mid C$ ”. 这里我们将对条件独立性的考量, 推广到对干预下分布的考量, 因此称该假设为干预忠实性.

证明 下面首先证明式 (2) 成立, 然后根据式 (2) 和干预忠实性假设可得待证的充要条件:

$$\mathbb{E}_{G_i}(Y|\text{do}(X = x)) = \int_{\text{Pa}(X, G_i)} \Pr(\text{Pa}(X, G_i)) \mathbb{E}(Y|\text{Pa}(X, G_i), X) d\text{Pa}(X, G_i) (\because \text{式(1)}) \quad (3)$$

$$= \int_{\text{Pa}(X, G_i)} \Pr(\text{Pa}(X, G_i)) \mathbb{E}(Y|\mathbf{M}_i, X) d\text{Pa}(X, G_i) (\because \text{定义 3 的条件 (2)}) \quad (4)$$

$$= \int_{\mathbf{M}_i} \Pr(\mathbf{M}_i) \mathbb{E}(Y|\mathbf{M}_i, X) d\mathbf{M}_i. \quad (5)$$

因此式 (2) 得证. 下面考虑充要条件的证明. 充分性可由式 (2) 直接得证; 对于必要性, 假设 $\mathbf{M}_i \neq \mathbf{M}_j$, 由假设 1, 有 $\mathbb{E}_{G_i}(Y|\text{do}(X = x)) \neq \mathbb{E}_{G_j}(Y|\text{do}(X = x))$, 矛盾. 必要性得证. 证毕.

对于不同的基于 P 的 X 局部因果图, 本文提出算法 1 获取具有该局部结构的因果图 MPS. 命题 3 指出, 在 P 表示的马尔可夫等价的因果图中, X 对 Y 的因果效应只与 MPS 有关. 又因为给定基于 P 的 X 局部因果图可以确定 X 的邻边, 此时 MPS 可确定. 因此, 通过对 X 的伪干预, 可以获取真实因果图 MPS, 该 MPS 对应的局部结构为通过伪干预确定的因果关系.

算法 1 GetMPS

输入: 基于 P 的 X 局部因果图 P' .

输出: M .

- 1: 初始化 $M = \text{Pa}(X, P')$;
 - 2: **if** P' 有无向边 **then**
 - 3: 在不生成新的 v -结构和有向环的前提下, 将 P' 的无向边全部转化为有向边;
 - 4: **end if**
 - 5: **for** 任一 M 中的变量 v **do**
 - 6: **if** 在 P' 中成立 $v \perp Y | \{X, M \setminus \{v\}\}$ **then**
 - 7: $M = M \setminus \{v\}$;
 - 8: **end if**
 - 9: **end for**
-

我们仍以图 1 为例展示上述过程. 记图 1(b)~(f) 为 G_1, G_2, \dots, G_5 , \mathbf{M}_i 为 G_i 上的 MPS. 则 $\mathbf{M}_1 = \emptyset, \mathbf{M}_2 = \mathbf{M}_4 = \{B\}, \mathbf{M}_3 = \{A\}, \mathbf{M}_5 = \{C\}$. 由命题 3 可知, 对于上述 5 个图, 当干预 X 时, 除了 G_2 和 G_4 有相同的干预下 Y 的分布, 其他任意两个图上 Y 的分布均不同. 因此可将 5 个基于 P 的 X 局部因果图分成 $\{G_1\}, \{G_2, G_4\}, \{G_3\}, \{G_5\}$ 4 组. 其中组间因果效应不同、组内相同, 每组因果图上 X 对 Y 的因果效应期望可用式 (2) 估计. 通过伪干预数据, 可以选出和伪干预数据一致的一组因果图, 该组中各图共有的 X 邻边为通过本次伪干预确定的因果关系.

遗憾的是, 向专家咨询时往往不能确定干预 X 下目标变量 Y 的分布, 只能获得形如“干预下 Y 的值相较不干预时增大还是减小?” 的回答, 数学表示为 $\mathcal{I}(\mathbb{E}(Y|\text{do}(X = x)) > \mathbb{E}(Y))$, 其中 $\mathcal{I}(\cdot)$ 为指示函数. 为了解决这一问题, 干预值 x 的选取十分关键. 对于任意两个不同 MPS 的局部因果图组, 我们要选取某干预值 x , 使得两个组中 $X = x$ 干预对 Y 有相反的作用. 这样, 通过专家知识我们可以选出与专家知识一致的组别. 这里的一个重要问题是: 是否恒存在这样的干预值? 对此, 本文给出命题 4, 保证了在一定的假设下, 这样的干预值是存在的.

命题 4 假设以下 3 个条件成立: (1) X 定义域为闭区间, 且对任意因果图 G , $\mathbb{E}_G(Y|\text{do}(X = x))$ 是关于 X 的连续函数; (2) 如果 X 对 Y 有因果效应, 则存在干预 $\text{do}(X = x')$ 与干预 $\text{do}(X = x'')$ 使得 $(\mathbb{E}(Y|\text{do}(X = x')) - \mathbb{E}(Y)) \times (\mathbb{E}(Y|\text{do}(X = x'')) - \mathbb{E}(Y)) < 0$; (3) 干预忠实性. 那么, 对于两个马尔

可夫等价的因果图 G, G' , 若 $\Pr_G(Y|\text{do}(X)) \neq \Pr_{G'}(Y|\text{do}(X))$, 则存在一个干预值 x 使得

$$(\mathbb{E}_G(Y|\text{do}(X = x)) - \mathbb{E}(Y)) \times (\mathbb{E}_{G'}(Y|\text{do}(X = x)) - \mathbb{E}(Y)) < 0. \quad (6)$$

也就是说, 对于因果结构 G 和 G' , 干预 $\text{do}(X = x)$ 对 Y 有相反的作用.

证明 根据假设 1, 2 及介值定理, X 至少存在一个值 x_1 使得 $\mathbb{E}_G(Y|\text{do}(X = x_1)) = \mathbb{E}(Y)$ 且 $\left. \frac{d\mathbb{E}_G(Y|\text{do}(X=x))}{dx} \right|_{x=x_1} \neq 0$. 根据干预忠实性, $\mathbb{E}_G(Y|\text{do}(X = x_1)) \neq \mathbb{E}_{G'}(Y|\text{do}(X = x_1))$. 不失一般性, 令 $\mathbb{E}_G(Y|\text{do}(X = x_1)) < \mathbb{E}_{G'}(Y|\text{do}(X = x_1))$, 有 $\mathbb{E}_G(Y|\text{do}(X = x_1)) = \mathbb{E}(Y) < \mathbb{E}_{G'}(Y|\text{do}(X = x_1))$. 因为 $\mathbb{E}_G(Y|\text{do}(X = x_1))$ 关于 X 连续, 一定存在与 $\left. \frac{d\mathbb{E}_G(Y|\text{do}(X=x))}{dx} \right|_{x=x_1}$ 正负性相同的 Δx , 使得 $\mathbb{E}_G(Y|\text{do}(X = x_1 - \Delta x)) < \mathbb{E}(Y)$, $\mathbb{E}_{G'}(Y|\text{do}(X = x_1 - \Delta x)) > \mathbb{E}(Y)$.

注释 1 命题 4 中的第 1 个假设要求 X 的取值范围是一个闭区间, 且 Y 在其干预下的期望关于干预值连续, 这一点在现实中是常见的, 例如在商家提高利润的例子中, 考虑 X 是售价, 售价存在取值范围, 利润 Y 关于售价通常是连续的. 第 2 个假设要求存在干预对目标变量有正向/负向作用 ($\mathbb{E}(Y|\text{do}(X = x)) - \mathbb{E}(Y) > / < 0$). 该假设在现实中通常成立, 依然以商户为例, 假如把售价 X 设置得非常大, 此时商品无人购买, 显然会导致销售额低于不干预的情况, 即 $\mathbb{E}(Y|\text{do}(X = x')) - \mathbb{E}(Y) < 0$; 而商户通常也可以通过调整售价成某个值 x'' , 使其利润提升, 即 $\mathbb{E}(Y|\text{do}(X = x'')) - \mathbb{E}(Y) > 0$.

因此, 对于两个 MPS 分别为 M_1, M_2 的局部因果图组, 可以通过选取合适的干预值, 使得不同组的因果图上 $X = x$ 对 Y 有相反的作用. 在算法运行中, 我们需要确定这样的干预值. 对任意值 x , 可以通过式 (2), 对 $M = M_1, M_2$ 分别利用观测数据估计出 $\mathcal{I}(\widehat{\mathbb{E}}_M(Y|\text{do}(X = x)) - \widehat{\mathbb{E}}(Y) > 0)$, 其中 $\widehat{\mathbb{E}}_M(Y|\text{do}(X = x))$ 表示 MPS 为 M 的因果图上估计的干预下 Y 的数学期望. 当搜索到某个值 x 使得两组结构中干预对目标变量影响相反时, 我们将该值作为决策值提供给专家. 根据专家知识, 排除掉与专家知识不一致的局部因果图组. 整合上述思想, 利用专家知识的因果关系学习见算法 2. 其中, 算法 2 第 3 行选取了两个不同组 ($M_i \neq M_j$) 的基于 P 的 X 局部因果图, 第 4 行选取了某个干预值 $X = x$, 使得对 i, j 两组中的因果图, 一组 $\text{do}(X = x)$ 对 Y 有正向作用, 一组有反向作用. 在第 5~8 行中, 算法根据专家返回的干预对 Y 的影响趋势信息, 排除掉与专家知识不一致的局部因果图组. 最后, 当只剩下一个组的时候 (也即剩下的图有相同的 MPS), 算法停止与专家交互, 在第 11 行, 算法将剩余一组的共同有向边作为确定的因果关系, 更新到原 PDAG P 中. 当这些新确定的因果知识被引入时, 根据图有向无环等约束, 可以进一步更新图. Meek^[6] 提出了 Meek 准则, 用来正确且完备地根据额外的因果知识更新 PDAG. 因此, 第 12 行引入 Meek 准则对 PDAG 进行更新.

4.4 基于伪干预的因果效应辨识

本小节给出算法 ACI-exp (active causal identification with expert knowledge), 基于本质图, 通过主动伪干预不断学习因果关系, 实现对目标变量的因果效应辨识. 由于伪干预需要与专家的交互成本, 我们希望用尽量少的伪干预实现对目标变量的因果效应辨识. 因此首先考虑通过干预要确定哪些因果关系. 如果有些因果关系对因果效应辨识没有帮助, 则没有必要考虑对此类因果关系的学习. 对此, 我们定义祖先边. 定理 1 证明了实现对目标变量的因果效应辨识当且仅当确定出全部祖先边, 同时, 定理 1 也给出了确定出祖先边后每个变量对目标变量因果效应辨识方法, 如式 (7) 所示. 所以, 算法将仅关注祖先边的确定. 基于上述几部分, 本文给出算法 3, 通过不断与专家交互, 学习出一个所有祖先边已确定的 PDAG, 基于式 (7) 可以辨识各决策变量对目标变量的因果效应.

定义 4 (祖先边) 给定 DAG G , 其中 Y 为目标变量, G 上的边 $X_i \rightarrow X_j$ 被称为祖先边当且仅当

算法 2 StructureLearn

输入: PDAG P , 伪干预变量 X .

输出: 更新后的 P .

- 1: 对每个基于 P 的 X 局部已知的部分因果图 $P'_j, j = 1, \dots, s$, 通过算法 1 获得其 MPS, 记为 M_j {注: 对 $i \neq j$, 可能 $M_i = M_j$ };
 - 2: 初始化 $I \leftarrow \{1, \dots, s\}$ {注: 记录候选 MPS 索引};
 - 3: **while** 存在 $i, j \in I$, 使得 $M_i \neq M_j$ **do**
 - 4: 选取使式 (6) 成立的干预值 $X = x$, 向专家询问 $\mathcal{I}(\mathbb{E}(Y|\text{do}(X = x)) > \mathbb{E}(Y))$;
 - 5: **if** $(\mathbb{E}_{P'_i}(Y|\text{do}(X = x)) - \mathbb{E}(Y)) \times (\mathbb{E}(Y|\text{do}(X = x)) - \mathbb{E}(Y)) > 0$ **then**
 - 6: $I \leftarrow I \setminus \{k \in I | M_k = M_j\}$;
 - 7: **else**
 - 8: $I \leftarrow I \setminus \{k \in I | M_k = M_i\}$;
 - 9: **end if**
 - 10: **end while**
 - 11: 将 $P'_k, k \in I$ 的公共有向边更新到 P ;
 - 12: 用 Meek 准则更新 P .
-

算法 3 ACI-exp

输入: 本质图 E .

输出: P .

- 1: 将初始的 PDAG P 初始化为 E ;
 - 2: $I_{\text{set}} \leftarrow \emptyset$ {注: I_{set} 记录已干预变量};
 - 3: **while** 1 **do**
 - 4: 将 P 上全部连通块的集合记为 C' ;
 - 5: $C = \{\mathbf{A} \in C' \mid |\mathbf{A}| > 1, \mathbf{A} \cap \text{Anc}(Y, P) \neq \emptyset\}$ {注: 详情见注释 2};
 - 6: **if** $C \neq \emptyset$ **then**
 - 7: 从 C 中随机选取一个连通块 C , 并在 $\mathbf{V}(C) \setminus (I_{\text{set}} \cup Y)$ 中选择无向边最多的变量作为伪干预变量 X ;
 - 8: $I_{\text{set}} \leftarrow I_{\text{set}} \cup \{X\}$;
 - 9: 用算法 2 对 P 进行更新;
 - 10: **else**
 - 11: 终止循环;
 - 12: **end if**
 - 13: **end while**
-

$\{X_i, X_j\} \cap \text{Anc}(Y, G) \neq \emptyset$.

定理1 假设因果图为 DAG G . 实现对目标变量的因果效应辨识当且仅当确定出 G 的全部祖先边方向. 进一步地, 当全部祖先边已确定, 可知 $\text{Anc}(Y, G)$ 和 $\text{Pa}(X, G)$. 对任意决策变量 X , 有

$$\mathbb{E}(Y|\text{do}(X)) = \begin{cases} \mathbb{E}(Y), & X \notin \text{Anc}(Y, G), \\ \int_{\mathbf{Z}} \Pr(\text{Pa}(X, G)) \Pr(Y|X = x, \text{Pa}(X, G)) d\text{Pa}(X, G), & X \in \text{Anc}(Y, G). \end{cases} \quad (7)$$

证明 分别证明充分性和必要性. 充分性: 用反证法. 假设对目标变量的因果效应可辨识, G 上有祖先边 $A \rightarrow B$ 未确定. 即在 PDAG P 上有 $A - B$. 根据祖先边定义, 在 G 上 A, B 至少有一个点存在不经过另一点的到 Y 的有向路. 我们分类讨论. (1) 如果在 G 上, A, B 都有不经过另一点的到 Y 的有向路, 由于 $A - B$ 可以表示 $A \rightarrow B$ 和 $A \leftarrow B$, 两种可能的结构下, 关于 (A, Y) 的 MPS 不同, 根据命题 3, 两种可能的结构下 A 对 Y 的因果效应不同, 所以有 $A - B$ 时 A 对 Y 的因果效应不可辨

识; (2) 若只有一个点有不经过另一点的到 Y 的有向路, 不妨设其为 A . 此时若有 $A \rightarrow B$, B 对 Y 没有因果效应, 若有 $A \leftarrow B$, B 对 Y 有因果效应, 显然此时 B 对 Y 的因果效应不可辨识. 所以两种情况下均会导出矛盾.

必要性: 如果所有的祖先边已被确定, 此时可以确定 $\text{Anc}(Y, G)$. 对于变量 $X \notin \text{Anc}(Y, G)$, 显然 $\mathbb{E}(Y|\text{do}(X)) = \mathbb{E}(Y)$. 对 $X \in \text{Anc}(Y, G)$, 因为 X 是 Y 的祖先, X 的任意边均为祖先边, 所以 X 的边均方向已知, 也可确定 $\text{Pa}(X, G)$, 记 $\mathbf{Z} = \text{Pa}(X, G)$, 根据后门准则, 有 $\mathbb{E}(Y|\text{do}(X = x)) = \int_{\mathbf{Z}} \Pr(\mathbf{Z}) \Pr(Y|X = x, \mathbf{Z}) d\mathbf{Z}$. 证毕.

注释2 算法 3 中, 如果第 5 行 $C \neq \emptyset$, 说明 P 上有从 C 中某变量 Z 到 Y 的有向路. 因为 C 的变量数大于 1, Z 有无向边, 因此该边为未确定的祖先边. 所以 $C \neq \emptyset$ 说明存在未被确定的祖先边, 因而需要引入伪干预.

注释3 在算法 3 的第 7 行, 当连通块中有祖先边未确定时, 我们选取无向边最多的变量进行伪干预, 这是因为通过伪干预该变量可能确定出更多的无向边.

5 实验

本节通过合成数据实验和真实数据实验分别验证 ACI-exp 能够有效地实现因果效应辨识.

5.1 合成数据实验

首先, 随机生成 100 个 DAG 作为真实因果图, 其中, 每个图的变量数 $d = 30$, 变量间以 $p = 0.3$ 概率有边, 边的方向完全随机. 如果有边 $X_j \rightarrow X_i$, 则从均匀分布 $U[1, 2]$ 采样该边的权重 $w_{j,i}$. 给定 DAG, 生成 $n = 1000$ 个观测样本, 其中每个样本的变量 X_i 由式 (8) 生成:

$$X_i = \sum_{k \in \text{Pa}_i} w_{k,i} X_k + \epsilon_i, \epsilon_i \sim N(0, 4), \quad (8)$$

其中 Pa_i 表示 X_i 的全体父母变量. ACI-exp 的输入为真实的本质图. 当伪干预 $\text{do}(X_j = x_j)$ 时, 为了模拟专家返回的 $\mathcal{I}(\mathbb{E}(Y|\text{do}(X_j = x_j)) - \mathbb{E}(Y) > 0)$, 收集 $n^{\text{int}} = 200$ 个干预数据. 干预数据的生成同观测数据一致, 唯一的不同是将 X_j 的值置为 x_j , 通过干预数据估计 $\hat{\mathbb{E}}(Y|\text{do}(X_j = x_j)) = \frac{1}{n^{\text{int}}} \sum_{s=1}^{n^{\text{int}}} y_s^{\text{int}}$, 其中 y_s^{int} 为第 s 个干预数据的 Y 值, 通过观测数据可以估计 $\hat{\mathbb{E}}(Y) = \frac{1}{n} \sum_{s=1}^n y_s$, 其中 y_s 为第 s 个观测数据的 Y 值, 将 $\mathcal{I}(\hat{\mathbb{E}}(Y|\text{do}(X_j = x_j)) - \hat{\mathbb{E}}(Y) > 0)$ 作为模拟的专家知识提供给算法.

目前没有基于伪干预数据进行因果结构学习或者因果效应辨识的相关方法. 我们将 ACI-exp 与 ACI^[5] 进行对比. ACI 利用干预下目标变量的分布信息实现对目标变量的因果效应辨识, 利用的信息比 ACI-exp 多, 因此 ACI 的结果可以作为 ACI-exp 的上界. 由于 ACI-exp 在选取伪干预变量时, 选取未确定祖先边最多的变量进行伪干预, 我们也引入了一个对比方法 ACI-exp-random, 该方法中每一步随机选取有未确定祖先边的变量进行伪干预. 定理 1 已经证明了实现对目标变量的因果效应辨识当且仅当确定出所有的祖先边, 且基于祖先边, 式 (7) 可以用来辨识因果效应, 因此我们通过确定的祖先边个数情况来评估对目标变量的因果效应辨识效果. 考虑确定的祖先边的 F1 得分、标准化 SHD (structural Hamming distance), 及标准化 SID (structural intervention distance) 3 个评估指标, 其中标准化 SHD 由估计的因果图矩阵与真实的因果图矩阵的汉明距离除以边数得出, 标准化 SID 由估计的因果图矩阵与真实的因果图矩阵的结构干预距离除以 $d(d-1)/2$ 得出, 上述指标的具体计算请参见文献 [31]. 在实验中, 一次干预指的是算法 3 中第 7 行选取一个变量进行伪干预. 实验结果如图 2 所示.

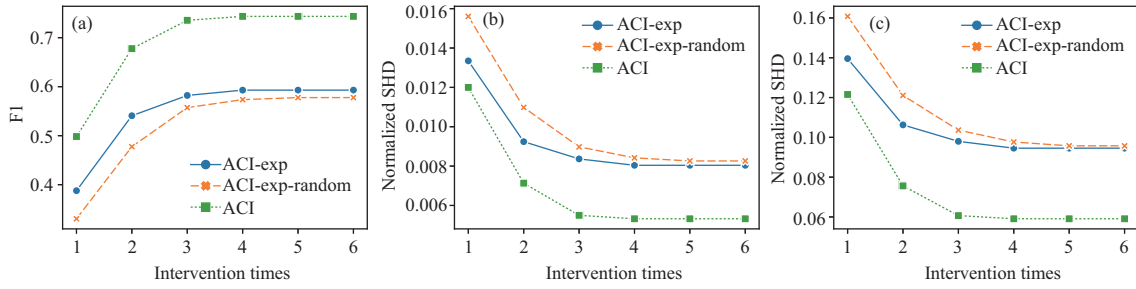


图 2 (网络版彩图) 各方法在不同干预次数下的 (a) F1 得分, (b) 标准化 SHD, 及 (c) 标准化 SID

Figure 2 (Color online) (a) F1 score, (b) normalized SHD, and (c) SID over 100 simulations under different intervention times by each method

ACI-exp 相较 ACI-exp-random 收敛得更快, 且收敛后各指标几乎没有差异, 这说明本文干预策略对以尽量少的伪干预实现因果效应辨识是有效的. 此外, 我们注意到 ACI-exp 和 ACI 相比, 存在一些祖先边未能正确学习, 这是因为专家返回的信息是二值信息 (0 或者 1), 信息量少于干预信息. 这为因果关系的学习带来了误差. 尽管如此, 两种方法的各项评估指标差距并不明显, 这验证了通过多次向专家咨询, 可以取得与利用干预信息方法相近的因果效应辨识结果. 另外, ACI-exp 收敛需要的干预次数均少于 4 次, 这说明现实任务中, 通过 ACI-exp 实现对目标变量的因果效应辨识不需要大量的伪干预次数. 最后, 我们也将 ACI-exp 与对函数关系进行假设、仅利用观测数据学习因果结构的方法 Resit [32] 进行了比较, 对于 100 个随机因果图, Resit 利用观测数据只能正确确定 197 条祖先边, 而 ACI-exp 利用伪干预可以正确确定 231 条祖先边, 这说明在广泛场景下, 引入额外信息对学习因果关系是有帮助的.

上述合成实验中, 变量之间的关系是线性的. 为了验证方法的广泛适用性, 我们也将 ACI-exp 应用于非线性数据. 数据生成方式如下:

$$\begin{aligned}
 X_1 &= 1 + E_1, \quad E_1 \sim U[-1, 1], \\
 X_2 &= \frac{X_1^2}{3} + E_2, \quad E_2 \sim U[-0.8, 0.8], \\
 X_3 &= \frac{\tan(\exp(-X_1^2 + 4))}{6} + \log(X_2^2) + E_3, \quad E_3 \sim U[-0.2, 0.2], \\
 X_4 &= \frac{(X_2 + X_3)^2}{5} + E_4, \quad E_4 \sim U[-0.5, 0.5], \\
 X_5 &= \frac{1}{X_1 + 1} + \log(X_4^2) + E_5, \quad E_5 \sim U[-0.2, 0.2], \\
 X_6 &= \frac{X_3}{3} + \cos(X_2 - 1.5) + E_6, \quad E_6 \sim U[-0.5, 0.5], \\
 Y &= \log(X_3^2) + (X_2 + 1)^2 - X_6 + E_7, \quad E_7 \sim U[-1, 1].
 \end{aligned}$$

对于该场景, 实验显示, ACI-exp 可以通过 4 次伪干预确定全部的祖先边. 每轮干预下的结果如图 3 所示, 其中双向边表示 PDAG 中的无向边, 节点 $1, \dots, 7$ 表示变量 X_1, \dots, X_6, Y . 该实验验证了 ACI-exp 针对非线性数据依然有效.

5.2 真实数据实验

本小节通过真实数据验证 ACI-exp 的有效性. 我们利用包含干预数据的经典因果数据集 —— 蛋




图 3 ACI-exp 在非线性数据的输出因果图. (a) 本质图. 干预 (b) X_3 , (c) X_4 , (d) X_1 和 (e) X_6 后得到的 PDAG

Figure 3 The output graph by ACI-exp for non-linear data. (a) Essential graph. PDAG learned from intervening (b) X_3 , (c) X_4 , (d) X_1 , and (e) X_6

表 1 不同干预下的样本数

Table 1 The sample number in different intervention groups

Intervention variable	-	Akt	PKC	PIP2	Mek	PIP3
Sample number	1755	911	723	810	799	848

白质调节数据集^[33], 模拟进行基于专家知识的主动因果效应辨识. 这里对数据的处理参照文献^[26]. 该数据集记录了不同实验条件下记录的人类初级免疫系统细胞中磷蛋白和磷脂丰度的测量值, 包含 11 个变量 (Raf, Mek, PLCg, PIP2, PIP3, Akt, PKA, PKC, p38, JNK, Erk). 经过一系列处理后, 可以分成观测数据和干预数据, 不同干预下的数据量如表 1 所示, 无干预数据即观测数据. 变量之间的因果关系和本质图如图 4 所示.

在真实因果图中, Erk 变量具有的祖先变量数目最多, 所以将 Erk 模拟成目标变量. 在本质图上, 待确定的祖先边为 $PIP3 \rightarrow PIP2$, $PIP3 \rightarrow PLCg$, $PLCg \rightarrow PKC$, $PLCg \rightarrow PIP2$, $PIP2 \rightarrow PKC$, $Raf \rightarrow Mek$. 在实验过程中, 当需要伪干预 $X = x$ 时, 将 X 的干预数据引入, 用其中 X 取值在 x 附近的样本作为伪干预 $X = x$ 下的干预数据. 类似于线性合成数据实验中的处理, 我们计算出 $\mathcal{I}(\hat{\mathbb{E}}(Y|do(X_j = x_j)) - \hat{\mathbb{E}}(Y) > 0)$, 将其作为模拟的专家知识提供给 ACI-exp. 关于祖先边 $Raf \rightarrow Mek$ 的确定, 需要引入干预 Raf 的数据, 然而由于数据集中不存在这样的数据, 忽略这条祖先边的确定. 对于其他的祖先边, 通过引入模拟的 PIP2 的伪干预数据, 确定出 $PIP3 \rightarrow PIP2(\checkmark)$, $PIP3 \rightarrow PLCg(\checkmark)$, $PLCg \rightarrow PKC(\checkmark)$, $PLCg \leftarrow PIP2(\times)$, $PIP2 \rightarrow PKC(\checkmark)$, 其中正确确定 4 条祖先边, 错误 1 条.

6 结语

本文提出方法, 通过获取专家知识来确定因果关系, 实现因果效应的辨识, 继而能够指导现实中的决策. 决策一直是人工智能领域的核心问题^[34~36], 近年许多考虑因果关系的决策方法被提出^[37,38]. 但是, 现实问题中确定因果关系往往是十分困难的, 这制约了相关方法的应用. 最新研究




图 4 蛋白质调节数据因果关系. (a) 真实因果图; (b) 本质图
Figure 4 Causal graph of the protein signaling dataset. (a) True causal graph; (b) essential graph

指出 [39], 相关关系对预测是必要的, 因果关系对科学发现是必要的, 而决策依赖介于相关关系和因果关系之间的某种关系, 作者将其称为影响关系. 未来对影响关系的进一步探索有望指导设计实用性更强的决策方法. 此外, 反绎学习, 一种结合逻辑推理与机器学习的学习范式 [40, 41], 近年在人工智能领域收获了广泛的关注. 因果关系本质上是一种逻辑表达式, 将因果关系形式的逻辑知识与机器学习融合也有望对机器学习算法降低样本依赖、提升稳健性发挥促进作用.

参考文献

- 1 Pearl J. Causality. Cambridge: Cambridge University Press, 2009
- 2 Shpitser I, Pearl J. Identification of joint interventional distributions in recursive semi-markovian causal models. In: Proceedings of the 21st AAAI Conference on Artificial Intelligence (AAAI), 2006. 1219–1226
- 3 Spirtes P, Glymour C N, Scheines R. Causation, Prediction, and Search. Cambridge: MIT Press, 2000
- 4 He Y B, Geng Z. Active learning of causal networks with intervention experiments and optimal designs. J Mach Learn Res, 2008, 9: 2523–2547
- 5 Wang T Z, Wu X Z, Huang S J, et al. Cost-effectively identifying causal effects when only response variable is observable. In: Proceedings of the 37th International Conference on Machine Learning (ICML), 2020. 10060–10069
- 6 Meek C. Causal inference and causal explanation with background knowledge. In: Proceedings of the 11st Annual Conference on Uncertainty in Artificial Intelligence (UAI), 1995. 403–410
- 7 Wang T Z, Qin T, Zhou Z H. Sound and complete causal identification with latent variables given local background knowledge. Artif Intell, 2023, 322: 103964
- 8 Tian J, Pearl J. A general identification condition for causal effects. In: Proceedings of the 18th AAAI Conference on Artificial Intelligence (AAAI), 2002. 567–573
- 9 Deng K, Pineau J, Murphy S A. Active learning for developing personalized treatment. In: Proceedings of the 27th Conference on Uncertainty in Artificial Intelligence, 2011. 161–168
- 10 Qin T, Wang T Z, Zhou Z H. Budgeted heterogeneous treatment effect estimation. In: Proceedings of the 38th International Conference on Machine Learning (ICML), 2021. 8693–8702
- 11 Shpitser I, VanderWeele T J, Robins J M. On the validity of covariate adjustment for estimating causal effects. In: Proceedings of the 26th Conference on Uncertainty in Artificial Intelligence (UAI), 2010. 527–536
- 12 Perkovic E, Textor J, Kalisch M, et al. A complete generalized adjustment criterion. In: Proceedings of the 31st Conference on Uncertainty in Artificial Intelligence (UAI), 2015. 682–691
- 13 Jaber A, Zhang J, Bareinboim E. Causal identification under markov equivalence. In: Proceedings of the 34th

- Conference on Uncertainty in Artificial Intelligence (UAI), 2018. 978–987
- 14 van der Zander B, Liskiewicz M, Textor J. Separators and adjustment sets in causal graphs: complete criteria and an algorithmic framework. *Artif Intell*, 2019, 270: 1–40
 - 15 Maathuis M H, Kalisch M, Bühlmann P, et al. Estimating high-dimensional intervention effects from observational data. 2009. ArXiv:0810.4214
 - 16 Malinsky D, Spirtes P. Estimating causal effects with ancestral graph markov models. In: *Proceedings of the 8th International Conference on Probabilistic Graphical Models*, 2016. 299–309
 - 17 Wang T Z, Qin T, Zhou Z H. Estimating possible causal effects with latent variables via adjustment. In: *Proceedings of the 40th International Conference on Machine Learning (ICML)*, 2023
 - 18 Chickering D M. Optimal structure identification with greedy search. *J Mach Learn Res*, 2002, 3: 507–554
 - 19 Colombo D, Maathuis M H, Kalisch M, et al. Learning high-dimensional directed acyclic graphs with latent and selection variables. *Ann Stat*, 2012, 40: 294–321
 - 20 Shimizu S, Hoyer P O, Hyvärinen A, et al. A linear non-gaussian acyclic model for causal discovery. *J Mach Learn Res*, 2006, 7: 2003–2030
 - 21 Zhang K, Hyvärinen A. On the identifiability of the post-nonlinear causal model. In: *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence (UAI)*, 2009. 647–655
 - 22 Cai R, Xie F, Glymour C, et al. Triad constraints for learning causal structure of latent variables. In: *Proceedings of the Advances in Neural Information Processing Systems 32 (NeurIPS)*, 2019. 12863–12872
 - 23 Cai R, Huang L, Chen W, et al. Learning dynamic causal mechanisms from non-stationary data. *Appl Intell*, 2022. 1–12
 - 24 Hauser A, Bühlmann P. Characterization and greedy learning of interventional markov equivalence classes of directed acyclic graphs. *J Mach Learn Res*, 2012, 13: 2409–2464
 - 25 Meinshausen N, Hauser A, Mooij J M, et al. Methods for causal inference from gene perturbation experiments and validation. *Proc Natl Acad Sci USA*, 2016, 113: 7361–7368
 - 26 Wang Y, Solus L, Yang K, et al. Permutation-based causal inference algorithms with interventions. In: *Proceedings of the Advances in Neural Information Processing Systems 30 (NeurIPS)*, 2017. 5824–5833
 - 27 Wang T Z, Zhou Z H. Actively identifying causal effects with latent variables given only response variable observable. In: *Proceedings of the Advances in Neural Information Processing Systems 34 (NeurIPS)*, 2021. 15007–15018
 - 28 Wang Y, Cao F, Yu K, et al. Efficient causal structure learning from multiple interventional datasets with unknown targets. In: *Proceedings of the 36th AAAI Conference on Artificial Intelligence (AAAI)*, 2022. 8584–8593
 - 29 Zhang K, Huang B, Zhang J, et al. Causal discovery from nonstationary/heterogeneous data: skeleton estimation and orientation determination. In: *Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI)*, 2017. 1347–1353
 - 30 Peters J, Bühlmann P, Meinshausen N. Causal inference by using invariant prediction: identification and confidence intervals. *J R Stat Soc Ser B-Stat Methodol*, 2016, 78: 947–1012
 - 31 Peters J, Bühlmann P. Structural intervention distance for evaluating causal graphs. *Neural Comput*, 2015, 27: 771–799
 - 32 Peters J, Mooij J M, Janzing D, et al. Causal discovery with continuous additive noise models. *J Mach Learn Res*, 2014, 15: 2009–2053
 - 33 Sachs K, Perez O, Pe’er D, et al. Causal protein-signaling networks derived from multiparameter single-cell data. *Science*, 2005, 308: 523–529
 - 34 Zhao P, Li L F, Zhou Z H. Dynamic regret of online markov decision processes. In: *Proceedings of the 39th International Conference on Machine Learning (ICML)*, 2022. 26865–26894
 - 35 Wang H, Yu Y, Jiang Y. Review of the progress of communication-based multi-agent reinforcement learning. *Sci Sin Inform*, 2022, 52: 742–764 [王涵, 俞扬, 姜远. 基于通信的多智能体强化学习进展综述. *中国科学:信息科学*, 2022, 52: 742–764]
 - 36 Zhang B, Zhu J, Su H. Toward the third generation artificial intelligence. *Sci China Inf Sci*, 2023, 66: 121101
 - 37 Zhang J, Bareinboim E. Designing optimal dynamic treatment regimes: a causal reinforcement learning approach. In: *Proceedings of the 37th International Conference on Machine Learning (ICML)*, 2020. 11012–11022
 - 38 Zhu Z M, Chen X H, Tian H L, et al. Offline reinforcement learning with causal structured world models. 2022.

ArXiv:2206.01474

39 Zhou Z H. Rehearsal: learning from prediction to decision. *Front Comput Sci*, 2022, 16: 164352

40 Zhou Z H. Abductive learning: towards bridging machine learning and logical reasoning. *Sci China Inf Sci*, 2019, 62: 076101

41 Zhou Z H, Huang Y X. Abductive learning. In: *Neuro-Symbolic Artificial Intelligence: the State of the Art*. Amsterdam: IOS Press, 2022. 353–369

Active causal effect identification with expert knowledge

Tian-Zuo WANG^{1,2} & Zhi-Hua ZHOU^{1,2*}

1. *National Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023, China;*

2. *School of Artificial Intelligence, Nanjing University, Nanjing 210023, China*

* Corresponding author. E-mail: zhouzh@lamda.nju.edu.cn

Abstract Causal effects play a crucial role in quantifying the impact between variables and are widely applied to various real-world problems. The identification of causal effects relies on known causal relations. To learn causal relations, traditional methods incorporate interventional information obtained by manipulating factors. However, such interventions can be costly in practice. Our study introduces an alternative method leveraging expert knowledge instead of interventions. Our methodology involves formulating questions such as “does the value of the target variable increase or decrease under intervention?” and posing these queries to experts. This allows our approach to learn causal relations, facilitating causal effect identification. Although less information than interventional information is provided by each expert consultation, our method achieves comparable results in causal effect identification through a sufficient number of inquiries. Experimental results validate this finding.

Keywords causal effect identification, causal relation, human-in-the-loop, expert knowledge