

О.М. БЕСПАЛА, аспірантка, Національний технічний університет України
"Київський політехнічний інститут імені Ігоря Сікорського",
03056, м. Київ, просп. Перемоги 37, Україна,
olya327@ukr.net

ІНСТРУМЕНТАРІЙ ПРИЧИННО-НАСЛІДКОВОГО ВИСНОВКУ: ОГЛЯД ТА ПЕРСПЕКТИВИ

Робота спрямована на висвітлення спектра задач та інструментів, які застосовуються для автоматизованого виявлення причинно-наслідкового зв'язку та створення нових підходів до причинно-наслідкового виявлення на основі даних. Висвітлено ряд методів, які застосовують для причинно-наслідкового виявлення. Зосереджено увагу на застосуванні різних алгоритмів, залежно від ідентифікації припущень про причинно-наслідкову структуру. Описано сучасний стан, переваги та недоліки застосування інструментарію причинного виявлення починаючи від його золотих стандартів та до більш точних, але обмежених спектром умов, алгоритмів.

Ключові слова: встановлення причинності; інструментарій причинно-наслідкового висновку; причинно-наслідковий зв'язок; причинно-наслідковий висновок; причинно-наслідковий аналіз.

Вступ

У світовій практиці з кожним роком спостерігається експоненціальне зростання кількості вимірюваних даних. Як наслідок, виникла необхідність не лише в методах обробки інформації, а й у методах, що здійснюють пошук метаданих, які допоможуть надати нові знання, серед іншого — розкрити основні завдання в різних наукових дисциплінах — пошук причинно-наслідкових зв'язків та використання їх.

Для встановлення причинного виявлення в причинно-наслідковому аналізі великомасштабних систем реального світу, як правило, слід розглянути багато практичних питань таких як: наявність можливості отримання даних в результаті проведення експериментів, повнота наявних даних (можлива комбінація статистичних та експериментальних даних), припущення про причинну структуру досліджуваної моделі, наявність математичного апарату та його точність тощо. Залежно

від поставленої задачі та заданих умов, виникає необхідність вибору відповідних засобів її розв'язання серед наявного широкого інструментарію.

З огляду робіт світової наукової спільноти, встановлення причинно-наслідкових зв'язків відіграє важливу роль у розвитку різних галузей, таких як інтелектуальний аналіз даних, опрацювання великих даних, машинне навчання [1–4], створення нейронних мереж [5], штучний інтелект тощо. Так директор лабораторії причинно-наслідкових зв'язків штучного інтелекту Колумбійського університету, доктор філософії Єліас Берейнбойм стверджує, що розуміння причинно-наслідкових зв'язків — важливий аспект того, що людство називає здоровим глуздом, і це область, в якій системи штучного інтелекту «некоректні». Ідея полягає в тому, щоб збагатити дослідження в області штучного інтелекту знаннями з відносно нової науки причинно-наслідкових зв'язків —

у області, величезною мірою сформованій Джудою Перлом, лауреатом премії Тьюрінга. Сучасні методи штучного інтелекту потребують розуміння причинно-наслідкових зв'язків для створення мислення, подібного до людського. Встановлення причинно-наслідкових зв'язків на сьогодні є невід'ємною частиною наукових досліджень, таких як розуміння поведінки пошуку в онлайн системах [6–7], вплив соціальної політики, фактори ризику захворюваності [8–12], статистика [13, 4], соціальні науки [14], медицина [12], природничі науки, екологія тощо [15–16].

Постановка задачі

Оскільки необхідність встановлення причинності охоплює доволі широкий спектр різних галузей із різною специфікою та підходами, виникає необхідність у застосуванні різних методів для розв'язання поставлених задач (у контексті причинності). Ця стаття має на меті надати короткий огляд та аналіз сучасних методів, алгоритмів і технологій виявлення причинного зв'язку та область задач, у яких застосування цих методів є коректним.

Методи встановлення та оцінки причинно-наслідкового зв'язку

Метод рандомізованого експерименту. Рандомізовані експерименти поширилися у психології та освіті наприкінці ХІХ століття завдяки винахіднику рандомізованого експерименту Чарльзу Пірсу [17], хоча є дані, що рандомізовані експерименти застосовувалися й раніше [18, 19]. Поза психологією та освітою, рандомізовані експерименти було популяризовано в [20]. Метод рандомізованого експерименту забезпечує велику надійність та валідність статистичних оцінок впливу досліджуваних явищ. Рандомізація передбачає випадковий розподіл об'єктів експерименту між досліджуваними групами й у такий спосіб зменшує зміщення, урівнюючи інші фактори, які не можуть бути явно враховані під час планування експерименту (відповідно до закону великих чисел).

Для оцінки середнього причинного впливу необхідна відсутність систематичних відмінностей між групами об'єктів. Припущення щодо контрафакту можуть забезпечити індивідуальні причинно-наслідкові зв'язки, але оцінка впливу може погіршитися, коли контрафакти не є ідентичними для кожної групи об'єктів.

Метод рандомізованих експериментів використовують для перевірки, чи справді новий лікарський засіб виліковує хворобу або чи має він суттєві побічні ефекти, чи працює маркетингова кампанія, чи один алгоритм пошуку є кращим за інший, і навіть виявлення найкращого для користувача кольору веб-сайту.

Попри загальну надійність, рандомізовані експерименти не є надійними і можуть спричинити практичні проблеми. Насамперед тому, що не завжди можна переконатися, чи процес насправді є випадковим. Іноді припущення щодо випадковості процесу може здаватися близьким до нього, але насправді не бути таким. Також для застосування цього методу необхідні потужні статистичні дані рандомізованих експериментів, які іноді бувають занадто коштовними, неетичними або в інший спосіб недоцільними для певних ситуацій.

Метод кореляційного аналізу. Метою кореляційного аналізу є виявлення істотної залежності однієї змінної від інших. Кореляційна залежність — це статистичний взаємозв'язок двох або більше випадкових величин (або величин, які можна з певним допустимим ступенем точності вважати такими). При цьому зміни значень однієї або декількох величин супроводжують систематичні зміни значень іншої або інших величин. Кореляційний аналіз — це метод обробки статистичних даних, за допомогою якого вимірюється тіснота зв'язку між двома або більше змінними. У найпростішому випадку досліджують дві вибірки (набори даних), у загальному — їх багатовимірні комплекси (групи). Кореляція відображає лише лінійну залежність величин, але не відображає їхньої функціональної зв'язаності. Однак, причини, що встановлюють кореляцію, якщо такі є, можуть бути непрямими та невідомими, а високі значення кореляції мо-

жуть перетинатися із тотожними зв'язками (тавтологіями), де немає жодного причинного процесу. Отже, встановлення кореляції між двома випадковими величинами не є достатньою умовою, аби говорити про причинний зв'язок (в обох напрямках) [21]. Наприклад, якщо дві події неодноразово збігалися (у часі чи у просторі), це є приводом припустити, що між цими подіями є залежність. Однак цього ще недостатньо, щоб вважати причинно-наслідковий зв'язок доведеним [21].

Метод регресійного аналізу. Переривання регресії. Регресійний аналіз тісно пов'язаний з кореляційним аналізом. Кореляційно-регресійний аналіз є методом обробки статистичних даних, що визначає тісноту зв'язку між двома або більше змінними та визначає необхідність включення тих чи інших факторів у рівняння множинної регресії, а також дає змогу оцінити отримане рівняння регресії на відповідність до виявлених зв'язків (використовуючи коефіцієнт детермінації).

Термінологія залежних і незалежних змінних відображає лише математичну залежність змінних, а не причинно-наслідкові зв'язки. Факт кореляційно-регресійної залежності не дає підстави твердити, що одна зі змінних має причинний вплив на іншу, або те, що змінні взагалі є причинно пов'язаними між собою, можливо спостерігається вплив інших факторів [23].

Ефективніше рішення виявлення причинного впливу запропоновано в [24], де застосовано квазіекспериментальний дотестовий та післятестовий метод переривання регресії (*Regression Discontinuity Design – RDD*). За допомогою дослідження й аналізу переривання регресії можна встановити причинно-наслідкові впливи, призначаючи граничний рівень або поріг, вище або нижче якого досліджується вплив. Порівнюючи спостереження, що лежать близько по обидва боки порога, можна оцінити середній вплив у середовищах, де неможливо застосувати метод рандомізованого експерименту. Вперше його застосували Дональд Тістлвейт і Дональд Кемпбелл для оцінки стипендіальних програм [25].

Добре виконані дослідження переривання регресії можуть генерувати оцінки ефекту впливу, подібні до оцінок рандомізованих досліджень, не вимагаючи попередньої рандомізації та обходячи етичні проблеми випадкового призначення [26]. Проте встановлені оцінки ефекту причинно-наслідкового впливу будуть достовірними, лише якщо правильно моделюється функціональна форма взаємозв'язку між фактором впливу і результатом. Найпопулярнішими застереженнями є нелінійні відношення, які помилково сприймаються як розрив.

Методи на основі кондиціонування. Методи, що ґрунтуються на кондиціонуванні, є базовими для встановлення причинного висновку, коли проведення активних експериментів є неможливим.

До них можна зарахувати такі методи як:

- Умовний вплив на причину. Кондиціонування ключових причинних змінних — найпростіший метод виокремлення причинного ефекту.

- Узгодження та стратифікація. Відповідне та стратифікаційне орієнтовне кондиціонування у великих розмірах та безперервних параметрах змінної. Мета полягає в тому, щоб забезпечити загальний баланс між досліджуваними та контрольними групами, аналогічним до того, що було би виявлено в рандомізованому експерименті.

- Двічі надійний оцінювач. Двомірні надійні методи забезпечують найкращі підходи до кондиціонування та регресії. Поєднуючи методи, засновані на регресії, причинно-наслідкова оцінка стає точнішою, коли одна з двох моделей вказана з великою точністю.

- Синтетичний метод контролю. Побудова синтетичних елементів управління є особливо корисною тоді, коли необхідно дати оцінку для багатьох значень, наприклад до всього населення в маркетингу чи трансляції соціальних оновлень.

Байєсовий метод визначення причинно-наслідкового зв'язку. Для встановлення причинно-наслідкового зв'язку байєсовий

метод використовується в різних галузях, наприклад, у медицині, статистиці, екології, машинному навчанні, тощо. Термін «байєсові мережі» (*Bayesian Networks*) запроваджено в [16], де було наголошено на відмінності причинної та доказової моделей, яку демонструє праця Томаса Байєса [28].

Байєсова мережа є ймовірнісною графовою моделлю, яка складається з набору випадкових змінних та їхніх умовних залежностей з допомогою орієнтованого ациклічного графу (*Directed Acyclic Graph — DAG*). Проте байєсова мережа не завжди може представляти причинні зв'язки, тому є таке поняття, як «причинна байєсівська мережа». Причинна байєсівська мережа (*Causal Bayesian Network — CBN*) — це байєсова мережа з явною вимогою того, що взаємозв'язки є причинними. Точніше визначення можна знайти в [29]. Застосовуючи семантику байєсових мереж, можна передбачити зовнішній вплив на підставі даних, одержаних до отримання впливу.

У [30] зазначено, що хоча байєсові мережі є загалом успішними, втім, їх застосування не виправдовує сподівань наблизити машинний інтелект до людського. Це спричинено тим, що мережі надають висновки на підставі спостереження ймовірності, не враховували причинність.

Методи на основі обмежень. Методи на основі обмежень використовують умовні обмеження незалежності та залежності й дають змогу інтегрувати загальні базові знання. Вони здатні виявляти причинно-наслідкові структури за наявності і спрямованих циклів (циклів зворотного зв'язку), і прихованих змінних із будь-якого заданого набору пасивних спостережних або експериментальних наборів даних. Оскільки задіяно комбіновані проблеми оптимізації, то такі методи, як правило, складно масштабуються, оскільки кількість змінних швидко збільшується [31].

У [32] представлено підхід до причинно-наслідкового виявлення на підставі обмежень. Показано, як дані спостережень можуть обмежувати причинно-наслідкові зв'язки між вимірюваними змінними, іноді ще до того,

як можна зробити висновок, що одна змінна спричиняє вплив на іншу.

Алгоритми та технології виявлення причинності

Далі подано опис алгоритмів, які є найбільш широкоживаними для масштабування звичайних причинно-наслідкових висновків, здебільшого, використовуючи сучасні великомасштабні масиви даних для прийняття рішень в автоматизованих системах.

Алгоритм жадібного пошуку еквівалентності (Greedy Equivalence Search — GES) — це алгоритм, заснований на оцінках, який жадібно максимізує функцію оцінки у просторі спостережуваних графіків у три фази, починаючи з порожнього графіка. Пряма фаза — *GES* рухається у просторі основних графіків з кроками, які відповідають додаванню одного ребра в простір *DAG*; фаза переривається, як тільки нова оцінка вже не може бути збільшена. Зворотна фаза — алгоритм виконує кроки, які відповідають видаленню одного ребра в просторі *DAG*, поки оцінка вже не може бути збільшена. Фаза повороту — алгоритм виконує кроки, які відповідають розвороту однієї стрілки в просторі *DAG*, аж поки рахунок вже більше не можна збільшувати. [33].

Алгоритм швидкого жадібного пошуку еквівалентності (Fast Greedy Equivalence Search — FGES) — це оптимізована версія алгоритму *GES*, який розроблений і вивчений в [34]. Алгоритм має застосування, використовуючи як вхідний набір даних дискретні та неперервні змінні, він жадібно шукає вибрані причинно-наслідкові структури Байєса (*Causal Bayesian Network — CBN*) (моделі) та видає найвищу оцінку, яку знайшов. Повернення моделі *FGES* слугує гіпотезою, що підтримується даними про причинно-наслідкові зв'язки, що існують серед змінних у наборі даних. *FGES* видає найвірогіднішу структуру *CBN*, яку він знайшов за інформаційним критерієм Байєса (*Bayesian Information Criterion — BIC*). За допомогою цього алгоритму можна знайти дуги, які представ-

ляють прямий причинно-наслідковий зв'язок, та ненаправлені краї, де таке ребро вказує на наявність причинно-наслідкової дуги, але напрямок дуги визначити неможливо.

Дискретний алгоритм IMaGES (оцінка BDeu). Алгоритм налаштовує дискретний показник змінної оцінки *BDeu FGES*, даючи у такий спосіб можливість використовувати кілька наборів даних як вхід. Точніше визначення оцінки *BDeu* можна знайти в [35]. Оцінки *BDeu* для кожного набору даних усереднюють на кожному кроці алгоритму, створюючи модель для всіх наборів даних, яка передбачає, що вони мають однакову графічну структуру для набору даних. Для використання цього алгоритму в нетривіальному ключі потрібно завантажити чи змоделювати декілька наборів даних.

Неперервний алгоритм IMAGES (оцінка моделей структурних рівнянь SEM BIC). Алгоритм налаштовує безперервний бал змінних (*SEM BIC*) *FGES*, уможливаючи використання кількох наборів даних як вхідних даних. Лінійні оцінки *BIC* Гауса для кожного набору даних усереднюють на кожному кроці алгоритму, створюючи модель для всіх наборів даних, яка передбачає, що вони мають однакову графічну структуру в наборі даних.

Алгоритми FOFC та MIMBUILD шукають причинно-наслідкову структуру за прихованими змінними, де справжніми моделями є множинні індикаторні моделі (*MIM*). Чим більшим є розмір вибірки, тим краще. Алгоритм є чутливим до так званих «домішок», тобто причинних країв серед вимірюваних змінних або між вимірюваними змінними та кількома прихованими змінними. Алгоритм фактично вилучить з розгляду одну міру в кожній нечистій парі.

Алгоритм FTFC. *FTFC (Find Two Factor Clusters)* є подібним до *FOFC*, але замість того, щоб кожен кластер, який є батьківським, мав одну приховану змінну для всієї міри в кластері, він натомість має дві. Отже, кожна міра має двох прихованих батьків — це два фактори. Подібно до *FOFC*, обмеження перевіряються, але в цьому разі обмеження мають бути нечисленними, і більша частина з них має бути ви-

конана для кожного чистого кластера. Отже, кількість заходів у кожному кластері, коли враховано нечисті краї, має дорівнювати щонайменше шести, бажано більше.

Алгоритм LiNGAM [36] був одним із перших алгоритмів, що передбачав лінійність серед змінних. Він базується на використанні негауссованості даних. Ідея полягає в тому, щоб використовувати алгоритм незалежного аналізу компонентів для перевірки всіх перестановок змінних, щоб знайти той, який є причинно-наслідковим порядком, тобто такий, у якому попередні змінні можуть спричинити пізніші змінні, але не навпаки. Алгоритм ефективно видає оцінки моделей структурних рівнянь або лінійних байєсівських мереж.

Алгоритм PC. Алгоритм *PC* [37] виконує пошук за шаблоном, який передбачає, що основна причинно-наслідкова структура вхідних даних є ациклічною та що дві змінні не спричинені тією самою прихованою (невимірюваною) змінною. Крім того, передбачається, що набір вхідних даних є або цілковито безперервним, або цілковито дискретним; якщо набір даних є безперервним, передбачається, що причинно-наслідковий зв'язок між будь-якими двома змінними є лінійним, а розподіл кожної змінної — нормальним. Нарешті, зразок в ідеалі має бути ідентифікатором.

Алгоритм *PC* доцільно застосовувати, коли є доступними процедури ухвалення рішень щодо незалежності та умовної незалежності. Процедура проводить послідовність тестів незалежності та умовної незалежності та ефективно буде шаблон на підставі результатів цих тестів. Алгоритм ефективно приймає факти умовної незалежності як вхідні дані. Таким чином, він є ефективним для будь-якого типу даних, для яких відомі факти умовної незалежності, зокрема для лінійних, гаусових, дискретних багаточленних даних та змішаних мультиноміальних/гаусових даних.

Алгоритм *PC* іноді видає подвійні краї. За великого обмеження вибірки подвійні головні ребра у вихідних даних вказують на те, що сусідні змінні мають незафіксовану загальну причину. *PC* має тенденцію створювати хиб-

нопозитивні подвійні напрями на невеликих вибірках.

У [38] застосовано алгоритм *PC* та запропоновано його модифікацію для дослідження впливу лікування на хворобу або відновлення причинно-наслідкового зв'язку між генами в регуляції генів мережі [39].

Консервативний *PC* алгоритм. Алгоритм *CPC* (*Conservative PC algorithm – CPC*) [39] модифікує крок орієнтації колайдера *PC*, щоб зробити його консервативнішим — тобто, підвищити точність орієнтації колайдера завдяки відкликанню. Колайдер — це вершина X в орієнтованому графі, яка не є кінцевою у шляху P . Якщо ребра входять у вершину X в орієнтованому графі, то ця вершина називається неколайдером. Точніше визначення можна знайти в [40]. У разі необхідності в орієнтуванні $X - Y - Z$ як колайдер або неколайдер, алгоритм *PC* розглядає змінні, суміжні з X , або змінні, суміжні з Z , щоб знайти підмножину S таку, що X не залежить від Z , і що залежить від S . Алгоритм *CPC* розглядає всі можливі множини та записує множину, на якій X умовно не залежить від Z . Якщо всі ці набори містять Y , він орієнтує $X - Y - Z$ як неколайдер. Якщо жоден з них не містить Z , орієнтує $X - Y - Z$ як колайдер. Якщо деякі множини містять Z , а інші не містять, це позначається як двозначне, з підкресленням. Таким чином, результат є неоднозначним між шаблонами. Для того, щоб отримати конкретний зразок із результату, спочатку потрібно вирішити, чи підкреслені трійки є колайдерами, чи неколайдерами, а потім застосувати правила орієнтації [33].

Алгоритм *CPC* виводить коректні дані, коли доступні процедури прийняття рішень щодо незалежності та умовної незалежності. Процедура проводить послідовність тестів незалежності й умовної незалежності та ефективно будує шаблон на основі результатів цих тестів.

Стабільний *PC* алгоритм. Ідея стабільного *PC* (*PC Stable*) алгоритму [41] полягає в тому, щоб змінити пошук суміжності *PC* так, що, коли порядок змінних є рандомізованим, вихід суміжності не впливав на стабільність. Це робиться в такий спосіб. Порядок операцій для кроку,

де обчислюються безумовні незалежності, не впливає на результат, його можна робити в будь-якому порядку. Однак для етапу, в якому один крок визначає одну змінну, на вихід цього кроку може впливати порядок виконання операцій. Отже, замість того, щоб видаляти краї на цьому кроці, просто рееструють, які краї можна було б видалити, а потім в кінці кроку видаляють їх усі. Аналогічно для подальших кроків послідовності. Таким чином, суміжності змінних на виході кроку фіксуються незалежно від порядку здійснення операцій. Один із них орієнтує колайдера і застосовує правила орієнтації Міка [42]. Можливими є зміни орієнтації від одного циклу до наступного, якщо порядок змінних у наборі даних змінено.

Алгоритм швидкого причинно-наслідкового висновку. Алгоритм *FCI* (*FastCausalInference – FCI*) засновано на обмеженнях [43], він є модифікацією алгоритму *PC*, який приймає як вихідні дані вибіркові дані та необов'язкові фонові знання, а у великому обмеженні вибірки виводить клас еквівалентності *CBN*, який (включно з тими, що мають приховані змінні), тягне за собою набір умовних відносин незалежності.

У [43] доведено, що алгоритм *FCI* є надійним за наявності багатьох прихованих змінних. У [44] розширено факт надійності, щоб врахувати також вибіркові змінні. У [45] представлено додаткові правила орієнтації, які роблять *FCI* повноцінним, коли його вихідні дані інтерпретуються як частково родовий граф (*Partial Ancestral Graph – PAG*).

Алгоритм *FCI* обмежено кількома тисячами змінних, а на реальних розмірах вибірки він є неточним і в суміжних, і в орієнтованих напрямках.

Є також декілька модифікованих версій алгоритму *FCI*, зокрема алгоритм *Anytime FCI*, що враховує лише умовні тести незалежності з наборами кондиціонерів, розмір яких є меншим від певної заданої граничної межі. *Anytime FCI*, як правило, є швидшим, але менш інформативним, ніж *FC* [46].

Алгоритм справді швидкого причинного висновку (*Really Fast Causal Inference – RFCI*) [47],

який використовує вивчення *PAG* також є модифікацією алгоритму *FCI*. Алгоритм *RFCI* використовує менше умовних тестів незалежності, ніж *FCI*, і його тести визначають меншу кількість змінних. Як наслідок, *RFCI* є набагато швидшим, ніж *FCI*, і його вихід, як правило, є надійнішим для невеликих зразків, оскільки умовні тести незалежності високого порядку мають низьку потужність. З іншого боку, вихід *RFCI* може бути менш інформативним. У цьому сенсі алгоритм пов'язаний із алгоритмом *Anytime FCI* [46].

Алгоритм *RFCI-BSC.RFCI-BSC* — це комбінація алгоритму *RFCI* [47] та методу Байєсівського підрахунку обмежень (*Bayesian Scoring of Constraints – BSC*) [48], який може генерувати та надавати ймовірнісну оцінку для кількох моделей, виводячи найімовірнішу. Цей алгоритм пошуку є гібридним методом, який отримує байєсівську ймовірність того, що сукупність тестів незалежності, пов'язаних із певною причинно-наслідковою моделлю, є правильними. Використовуючи цей метод оцінювання на основі обмежень, можна оцінити безліч причинно-наслідкових моделей, які, можливо, містять приховані змінні, і вивести найвірогіднішу.

Алгоритм жадібного швидкого причинного висновку *GFCI.GFCI (Greedy Fast Causal Inference – GFCI)* — це комбінація алгоритму *FGES* та алгоритму *FCI*, яка покращує точність та ефективність *FCI*. Є алгоритм жадібного швидкого причинного висновку для неперервних та дискретних змінних.

GFCId (алгоритм жадібного швидкого причинного висновку для дискретних змінних) — це алгоритм, який бере як вхідний набір даних дискретні змінні та має дві фази. Перший етап жадібно здійснює пошук за вибраними причинно-наслідковими структурами байєсівської мережі (*CBN*) і виводить найвищу бальну модель, яку він знаходить, припускаючи, що немає невимірених змішувачів та упередженості відбору.

Потім цей результат вводиться в невелику модифікацію алгоритму швидкого причинного висновку (*FCI*), який обробляє вихідні дані

для отримання представлення набору моделей, які можуть містити невимірені незрозумілі фактори. Модель, яку повертає *GFCId*, слугує гіпотезою, що підтримується даними про причинно-наслідкові зв'язки, наявні серед змінних у наборі даних. Такі моделі призначені допомогти вченим формувати гіпотези та керувати розробкою експериментів для дослідження цих гіпотез.

GFCIc (алгоритм жадібного швидкого причинного висновку для неперервних змінних) — це алгоритм, що бере безперервні змінні як вхідний набір даних та виводить графічну модель, яка називається *PAG*, що є набором причинно-наслідкових мереж, які можуть включати приховані змішувачі. *PAG*, який повертає *GFCIc*, слугує гіпотезою, що підтримується даними про причинно-наслідкові зв'язки, наявні серед змінних у наборі даних. Такі моделі призначені допомогти вченим формувати гіпотези та керувати розробкою експериментів для дослідження цих гіпотез. *GFCIc* не передбачає відсутності прихованих перешкод [49].

Слід зазначити, що до переліку алгоритмів, які використовуються для вивчення, відображення, пошуку причинності в різних моделях, можна зарахувати такі алгоритми та їхні модифікації: *TsGFCI*, який використовує оцінку *BIC* для пошуку скелета причинної моделі; *tsFCI* — версія *FCI* для даних часових рядів; *TisIMAGES* — версія *tsGFCI*, яка в середньому оцінює *BIC* для декількох наборів даних; Алгоритм *FGES-MB* — обмеження алгоритму *FGES* на об'єднання ребер над комбінованим марківським покриттям набору цілей, включно з цілями; алгоритм *MBFS* — алгоритм пошуку марківського покриття; *FAS* — це алгоритм пошуку суміжностей в алгоритмі *PC*; *MGM* — алгоритм пошуку випадкового марківського покриття; *FASK* — вивчає лінійну модель, у якій усі змінні змішено; алгоритми орієнтації *R3*, *Rskew*, *Skew* — орієнтують ребро $X-Y$ для неперервних змінних на підставі негауссової інформації; тощо.

З огляду на описані алгоритми в табл. 1 продемонстровано порівняльну характеристику алгоритмів.

Таблиця 1. Порівняльна характеристика алгоритмів

Особливість алгоритму	PC	FCI	GES	LINGAM
Наявність припущень причинності	+	+	+	-
Наявність припущень щодо розподілу даних	-	-	+	+
Коректне відображення факторів впливу	-	+	-	-
Вихідні дані	Клас еквівалентності Маркова [50]	PAG	Клас еквівалентності Маркова	DAG а також причинно-наслідкова модель (за відповідних умов ідентифікації)

Виявлення причинних наслідків стає невід'ємною частиною наукового дослідження, що охоплює широкий спектр питань, таких як розуміння поведінки в Інтернет-системах, вплив соціальної політики чи фактори ризику захворювань. Оскільки обчислювальна техніка все більше впливає на всі сфери життя, питання пошуку причинно-наслідкових зв'язків також має вирішальне значення для проектування та оцінки на основі даних комп'ютерних систем та додатків. Доповнюючи основні дослідження та з метою розширення використання причинно-наслідкових методів у наукових колах та промисловості, відомі світові наукові установи та комп'ютерні корпорації прагнуть зробити технології доступними за допомогою інструментів з відкритим кодом та бібліотеками. Зокрема, деякі з них наведено в табл. 2.

Висновки

Посилаючись на теоретичний та практичний досвід світових наукових досліджень з впровадження інструментів виявлення причинності, в роботі проаналізовано сучасні підходи, методи, алгоритми та технології, які використовуються для розв'язання практичних задач з різних галузей.

Висвітлено спектр задач, у яких має місце застосування відповідних інструментів для

знаходження причинно-наслідкового зв'язку, та труднощі, які можуть виникати в ході проведення досліджень. Наведено приклад сучасних технологій передових розробників, які реалізовані методами та алгоритмами, направлені на вирішення питань розуміння причинно-наслідкових зв'язків.

З огляду та аналізу робіт в галузі встановлення причинності, можна дійти висновку, що розроблений інструментарій використовується в багатьох галузях, проте потребує певних умов забезпечення якості вхідних даних, що передбачає: реальні експерименти, які не завжди можуть бути проведені; припущення про причинно-наслідкову структуру моделі; повноту даних; припущення щодо розподілу даних; припущення щодо існування контрафактів, які можуть мати хибнопозитивний вплив на модель тощо.

Також слід зазначити, що описаний інструментарій стає неефективним у тому разі, коли причинно-наслідкова модель має циклічну структуру. Зокрема, таку структуру можуть мати моделі, пов'язані зі встановленням причинно-наслідкового впливу економічних або екологічних показників на якість здоров'я людини. Некоректні, помилково позитивні висновки в подібних системах можуть призвести до важких та неконтрольованих наслідків.

Таблиця 2. Технології встановлення причинного зв'язку

Розробник	Короткий опис	Використані методи та алгоритми
<i>Causal-cmd</i> , <i>Center of Causal Discovery</i>	<i>Java API</i> та реалізація алгоритмів командного рядка для виконання причинно-наслідкового виявлення на великих даних. Використовуйте це програмне забезпечення, якщо вам цікаво включати аналіз за допомогою сценарію оболонки або в програму на основі <i>Java</i> .	<i>FGES</i> для безперервних або дискретних змінних; оптимізовану версію <i>GES</i> , протестовану з наборами даних, що містять до 1 млн безперервних змінних; <i>GFCI</i> для неперервних та дискретних змінних; алгоритми <i>bpc</i> , <i>eb</i> , <i>fang-concatenated</i> , <i>fas</i> , <i>fask-concatenated</i> , <i>fci</i> , <i>fges</i> , <i>fges-mb</i> , <i>fofc</i> , <i>ftfc</i> , <i>gfc</i> , <i>glasso</i> , <i>imgs_cont</i> , <i>imgs_disc</i> , <i>mbfs</i> , <i>mgm</i> , <i>pc-all</i> , <i>pc-stable-max</i> , <i>r-skew</i> , <i>r-skew-e</i> , <i>r1</i> , <i>r2</i> , <i>r3</i> , <i>r4</i> , <i>rfci</i> , <i>skew</i> , <i>skew-e</i> , <i>ts-fci</i> , <i>ts-gfci</i> , <i>ts-imgs</i> .
<i>Tetrad</i> , <i>Center of Causal Discovery</i>	<i>Java API</i> та робоче середовище для навчання, проведення аналізів та експериментів з алгоритмами причинного виявлення.	Алгоритми <i>PC</i> , <i>CPC</i> , <i>PCStable</i> , Стабільний алгоритм <i>CPC</i> , <i>PcMax</i> , <i>FGES</i> , <i>IMaGES</i> (оцінка <i>BDeu</i>), неперервний алгоритм <i>IMAGES</i> (оцінка <i>SEM BIC</i>), <i>FCI</i> , <i>RFCI</i> , <i>RFCI-BSC</i> , <i>GFCI</i> , <i>TsFCI</i> , <i>TsGFCI</i> , <i>TsIMaGES</i> , <i>FGES-MB</i> , <i>MBFS</i> , <i>FAS</i> , <i>MGM</i> , <i>GLASSO</i> , <i>FOFCma</i> , <i>MIMBUILD</i> , <i>FTFC</i> , <i>LiNGAM</i> , <i>FASK</i> , <i>MultiFASK</i> , Алгоритми орієнтації (<i>R3</i> , <i>Rskew</i> , <i>Skew</i>).
Причинний <i>REST API v0.0.8</i> , <i>Center of Causal Discovery</i>	Причинний <i>REST API v0.0.8</i> розроблений для причинно-наслідкової мережі. Він реалізує специфікації <i>JAX-RS</i> , використовуючи Джерсі.	Алгоритми постійний <i>FGES</i> , <i>FGESd</i> , <i>FGESc</i> , <i>GFCIc</i> , <i>GFCId</i> .
<i>py-causal</i> , <i>Center of Causal Discovery</i>	<i>API Python</i> для алгоритмів причинного моделювання	<i>FGES</i> як для безперервних і для дискретних змінних, <i>GFCI</i> для неперервних і для дискретних змінних.
<i>R-causal</i> , <i>Center of Causal Discovery</i>	Модуль <i>R</i> , який обгортає алгоритми для проведення причинно-наслідкового виявлення на великих даних.	<i>FGES</i> як для безперервних і для дискретних змінних, <i>GFCI</i> для неперервних і для дискретних змінних.
<i>DoWhy</i> , <i>Microsoft</i>	Бібліотека <i>Python</i> , яка визначає причинно-наслідковий висновок та аналіз. Забезпечує уніфікований інтерфейс для методів причинно-наслідкового висновку та автоматично перевіряє багато припущень, роблячи таким чином висновок доступним для неспеціалістів.	Метод регресії та переривання регресії, використання інструментальних змінних, способи стратифікації, відповідності та зважування, тощо.
<i>EconML</i> , <i>Microsoft</i>	Пакет <i>Python</i> для оцінки різномірних ефектів впливу від даних спостережень за допомогою машинного навчання. Набір інструментів призначено для вимірювання причинного ефекту деяких змінних.	Методи оцінки: подвійне машинне навчання; ортогональні випадкові ліси; метанавчання; подвійно надійне навчання; ортогональні інструментальні змінні; глибокі інструментальні змінні; тощо.

Відомі світові наукові установи та передові корпорації комп'ютерних технологій плідно займаються розробкою та впровадженням дедалі досконалішого інструментарію встановлення причинності, щоб розробити автоматизовані

програмні проекти наближеними до людського мислення. А розробка технологій встановлення причинного висновку з урахуванням циклічних структур моделей може допомогти позбутися помилково позитивних висновків.

ЛІТЕРАТУРА

1. Mahajan D., Tan C., Sharma A., 2019. Preserving causal constraints in counterfactual explanations for machine learning classifiers. arXiv preprint arXiv:1912.03277.
2. Lecuyer M., Lockerman J., Nelson L., Sen S., Sharma A., Slivkins A., 2017. "Harvesting randomness to optimize distributed systems", Proceedings of the 16th ACM Workshop on Hot Topics in Networks, pp. 178–184.
3. Pearl J., 2019. "The seven tools of causal inference, with reflections on machine learning", Communications of the ACM, 62 (3), pp. 54–60. DOI: 10.1145/3241036.
4. Kiciman E., Sharma A., 2019. "Causal Inference and Counterfactual Reasoning (3hr Tutorial)", Proceedings of the 12th ACM International Conference on Web Search and Data Mining, pp. 828–829. DOI: 10.1145/3289600.3291381.
5. Zhang C., Zhang K., Li Y., 2020. A Causal View on Robustness of Neural Networks, arXiv preprint arXiv:2005.01095.
6. Saha K., Sharma A., 2020. "Causal Factors of Effective Psychosocial Outcomes in Online Mental Health Communities", Proceedings of the International AAAI Conference on Web and Social Media, 14, pp. 590–601. [online] Available at: <<https://ojs.aaai.org/index.php/ICWSM/article/view/7326>> [Accessed 23 December 2020].
7. Sharma A., Hofman J. M., Watts D. J., 2015. "Estimating the causal impact of recommendation systems from observational data", EC'15: Proceedings of the 16th ACM Conference on Economics and Computation, pp. 453–470. DOI: 10.1145/2764468.2764488
8. Wager S., Athey S., 2018. "Estimation and inference of heterogeneous treatment effects using random forests", Journal of the American Statistical Association, 113 (523), pp. 1228–1242. DOI: 10.1080/01621459.2017.1319839.
9. Chiba Y., 2018. "Bayesian inference of causal effects for an ordinal outcome in randomized trials", Journal of Causal Inference, 6 (2). DOI: 10.1515/jci-2017-0019.
10. Halloran M. E., Struchiner C. J., 1995. "Causal inference in infectious diseases", Epidemiology, 6 (2), pp. 142–151. DOI: 10.1097/00001648-199503000-00010.
11. Hudgens M. G., Halloran M. E., 2008. "Toward causal inference with interference", Journal of the American Statistical Association, 103 (482), pp. 832–842. DOI: 10.1198/016214508000000292.
12. Makar M., Swaminathan A., Kiciman E., 2019. "A Distillation Approach to Data Efficient Individual Treatment Effect Estimation", Proceedings of the AAAI Conference on Artificial Intelligence, 33 (1), pp. 4544–4551. DOI: 10.1609/aaai.v33i01.33014544.
13. Pearl J., 2003. "Statistics and causal inference: A review", Test, 12 (2), pp. 281–345. DOI: 10.1007/BF02595718.
14. Hofman J. M., Sharma A., Watts D. J., 2017. "Prediction and explanation in social systems", Science, 355 (6324), pp. 486–488. DOI: 10.1126/science.aal3856.
15. Tu R., Zhang K., Bertelson B., Kjellstrom H., Zhang C., 2019. "Neuropathic Pain Diagnosis Simulator for Causal Discovery Algorithm Evaluation", Advances in Neural Information Processing Systems, pp. 12793–12804.
16. Imbens G. W., Rubin D. B., 2015. Causal inference in statistics, social, and biomedical sciences, Cambridge University Press. DOI: 10.1017/CBO9781139025751.
17. Peirce C. S., Jastrow J., 1884. "On small differences in sensation", Memoirs of the National Academy of Sciences, 3, pp. 75–83.
18. Dehue T., 1997. "Deception, efficiency, and random groups: Psychology and the gradual origination of the random group design", 88 (4), pp. 653–673. DOI: 10.1086/383850.
19. Neuhauser D., Diaz M., 2004. "Daniel: using the Bible to teach quality improvement methods", Qual. Saf. Health Care, 13 (2), pp. 153–155. DOI: 10.1136/qshc.2003.009480.
20. Fisher R. A., Kotz S., Johnson N. L., 1992. "Breakthroughs in Statistics. Statistical methods for research workers", Breakthroughs in statistics, Springer, New York, NY, pp. 66–70.
21. Aldrich J., 1995. "Correlations genuine and spurious in Pearson and Yule", Statistical science, 10 (4), pp. 364–376.
22. Vigen T., 2015. Spurious Correlations. Hachette Books.
23. Yeliseyeva I., Yuzbashev M., 2008. Obshchaya teoriya statistiki: Uchebnik, in Yeliseyevoy I. I., 4th ed, Finansy i Statistika, Moscow, 480 p.

24. *Imbens G., Lemieux T.*, 2008. "Regression discontinuity designs: A guide to practice", *Journal of econometrics*, 142 (2), pp. 615–635.
25. *Thistlethwaite D. L., Campbell D. T.*, 1960. "Regression-discontinuity analysis: An alternative to the ex post facto experiment", *Journal of Educational psychology*, 51 (6), pp. 309–317. DOI: 10.1037/h0044319.
26. *Moss B. G., Yeaton W. H., Lloyd J. E.*, 2014. "Evaluating the effectiveness of developmental mathematics by embedding a randomized experiment within a regression discontinuity design", *Educational Evaluation and Policy Analysis*, 36 (2), pp. 170–185.
27. *Pearl J.*, 1985. "Bayesian networks: A model of self-activated memory for evidential reasoning", *Proceedings of the 7th Conference of the Cognitive Science Society, University of California, Irvine, CA, USA*, pp. 15–17.
28. *Bayes T., Price M.*, 1763. "An essay towards solving a problem in the doctrine of chances. By the late Rev. Mr. Bayes, FRS communicated by Mr. Price, in a letter to John Canton, A.M.F.R.S.", *Philosophical transactions, Royal Society of London*, 53 (1763), 53 p. DOI: 10.1098/rstl.1763.0053.
29. *Pearl J.*, 2009. *Causality*, Cambridge university press.
30. Gill K. S., 2020. *Pearl, Judea and Mackenzie, Dana: The book of why: the new science of cause and effect*, AI & Society.
31. *Spirtes P., Zhang K.*, 2016. "Causal discovery and inference: concepts and recent methodological advances", *Applied informatics*, Springer Berlin Heidelberg, 3 (1), pp. 3. DOI: 10.1186/s40535-016-0018-x.
32. *Cooper G. F.*, 1997. "A simple constraint-based algorithm for efficiently mining observational databases for causal relationships", *Data Mining and Knowledge Discovery*, 1 (2), pp. 203–224.
33. *Meek C.*, 1997. *Graphical Models: Selecting causal and statistical models*, Doctoral dissertation, PhD thesis, Carnegie Mellon University.
34. *Chickering D. M.*, 2002. "Optimal structure identification with greedy search", *Journal of machine learning research*, 3, pp. 507–554.
35. *Buntine W.*, 1991. "Theory refinement on Bayesian networks", *Uncertainty Proceedings 1991*, Morgan Kaufmann, pp. 52–60.
36. *Shimizu S., Hoyer P., Hyvriinen A., Kerminen A.*, 2006. "A linear non-Gaussian acyclic model for causal discovery", *Journal of Machine Learning Research*, 7, pp. 2003–2030.
37. *Spirtes P., Glymour C.*, 1991. "An algorithm for fast recovery of sparse causal graphs", *Social science computer review*, 9 (1), pp. 62–72. DOI: 10.1177/089443939100900106.
38. *Zarebavani B., Jafarnejad F., Hashemi M., Salehkaleybar S.*, 2019. "cuPC: CUDA-based parallel PC algorithm for causal structure learning on GPU", *IEEE Transactions on Parallel and Distributed Systems*, 31 (3), pp. 530–542. DOI: 10.1109/TPDS.2019.2939126.
39. *Friedman N., Linial M., Nachman I., Pe'er D.*, 2000. "Using Bayesian networks to analyze expression data", *Journal of computational biology*, 7 (3–4), pp. 601–620. DOI: 10.1089/106652700750050961.
40. *Zhang J.*, 2012. A characterization of Markov equivalence classes for directed acyclic graphs with latent variables, arXiv preprint arXiv:1206.5282.
41. *Dron M., Maathuis M.*, 2017. "Structure learning in graphical modeling", *Annual Review of Statistics and Its Application*, 4, pp. 365–393. DOI: 10.1146/annurev-statistics-060116-053803.
42. *Meek C.*, 1995. Causal inference and causal explanation with background, *Uncertainty in Artificial Intelligence*, in Besnard P. & Hanks S. (eds.), *Proceedings of the 11th conference on Uncertainty in artificial intelligence*, pp. 403–410.
43. *Spirtes P., Glymour C., Scheines R., Heckerman D.*, 2000. *Causation, prediction, and search*. MIT press.
44. *Spirtes P. L., Meek C., Richardson T.*, 2013. Causal inference in the presence of latent variables and selection bias, arXiv preprint arXiv:1302.4983.
45. *Zhang J.*, 2008. "On the completeness of orientation rules for causal discovery in the presence of latent confounders and selection bias", *Artificial Intelligence*, 172 (16–17), pp. 1873–1896. DOI: 10.1016/j.artint.2008.08.001
46. *Spirtes P.*, 2001. "An Anytime Algorithm for Causal Inference", *AISTATS*.
47. *Colombo D., Maathuis M., Kalisch M., Richardson T.*, 2011. "Learning high-dimensional DAGs with latent and selection variables", *UAI*, p. 850.
48. *Jabbari F., Ramsey J., Spirtes P., Cooper G.*, 2017. "Discovery of causal models that contain latent variables through Bayesian scoring of independence constraints", *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, Springer, Cham., pp. 142–157. DOI: 10.1007/978-3-319-71246-8_9.
49. *Ogarrío J. M., Spirtes P., Ramsey J.*, 2016. "A hybrid causal search algorithm for latent variable models", *Conference on Probabilistic Graphical Models*, pp. 368–379.
50. *Zhang J.*, 2012. A characterization of Markov equivalence classes for directed acyclic graphs with latent variables. arXiv preprint arXiv:1206.5282.

Надійшла 10.10.2020

O.M. Bospala, PhD student, National Technical University of Ukraine
“Igor Sikorsky Kyiv Polytechnic Institute”,
03056, Prosp. Peremohy, 37, Kyiv, Ukraine,
Olya327@ukr.net

TOOLS OF CAUSAL INFERENCE: REVIEW AND PROSPECTS

Introduction. The need to establish causality covers a fairly wide range of different industries with different specifics and approaches. Therefore, it becomes necessary to apply various methods to solve the assigned tasks (in the context of causality), which is accompanied by the choice of a wide range of tools, depending on the task at hand.

Purpose. The purpose of this work is a brief overview and analysis of modern methods, algorithms and technologies for detecting causation and the range of tasks in which the use of the appropriate tools takes place.

Methods. Starting from the gold standards of causal identification and to more accurate, but limited by the range of conditions, algorithms, the current state, advantages and disadvantages of the use of tools are described.

Result. The analysis of the current state of existing methods, algorithms and technologies for establishing causality is carried out the prospects for further development and improvement of tools for causal detection are examined.

Conclusions. At the moment there is a large list of known methods, algorithms and technologies, there is a number of problems in which there is a need for more accurate detection of causality. The paper shows that most of the tools for establishing causality give good results for acyclic structures, at the same time they can give false positive conclusions for cyclic structures. Well-known world scientific institutions and leading corporations of computer technology are fruitfully engaged in the development and implementation of more and more perfect tools for establishing causality in order to develop automated software projects close to human thinking.

Keywords: *establishment of causality; causal inference tools; causal relationship; causal conclusion; causal analysis.*