

Ленартович Владислав Георгійович здобувач третього (освітньо-наукового) рівня вищої освіти, спеціальність F3 Комп'ютерні науки, Житомирський державний університет імені Івана Франка, м. Житомир, <https://orcid.org/0009-0002-9454-0819>

СУЧАСНІ ПІДХОДИ ДО ПРИЧИННО-НАСЛІДКОВОГО МОДЕЛЮВАННЯ У ЗАДАЧАХ ПОВЕДІНКИ АГЕНТІВ ІНТЕРАКТИВНИХ СЕРЕДОВИЩ

Анотація. У статті розглянуто сучасні підходи до причинно-наслідкового моделювання у задачах поведінки агентів інтерактивних середовищ. Основну увагу приділено аналізу та порівнянню традиційних методів побудови поведінки агентів, навчання з підкріпленням та причинно-наслідкових підходів у контексті відеоігор, симуляторів і суміжних інтерактивних систем.

Проаналізовано особливості скінченних автоматів, дерев поведінки та rule-based систем, які забезпечують передбачуваність, контрольованість і низькі обчислювальні витрати, однак мають обмежену здатність до адаптації в умовах складного динамічного середовища. Окремо розглянуто навчання з підкріпленням як підхід, що дозволяє агентам формувати поведінку на основі досвіду взаємодії із середовищем, проте має обмеження, пов'язані з інтерпретованістю та залежністю від статистичних закономірностей.

У роботі висвітлено можливості застосування структурних причинно-наслідкових моделей, причинно-наслідкового навчання з підкріпленням, методів контрфактичного аналізу та байєсівських мереж для підвищення пояснюваності, адаптивності та здатності агентів працювати з невизначеністю. Проведено порівняння зазначених підходів за критеріями ефективності навчання, інтерпретованості, масштабованості та основної сфери застосування.

Отримані результати свідчать, що причинно-наслідкове моделювання не є універсальною заміною традиційних методів побудови поведінки агентів, однак може виступати перспективним доповненням у задачах, де важливими є аналіз наслідків дій, робота з альтернативними сценаріями та підвищення інтерпретованості рішень. Перспективним напрямом подальшого розвитку є комбінування традиційних, статистичних та причинно-наслідкових підходів залежно від складності середовища та вимог до поведінки агента.

Ключові слова: причинно-наслідкове моделювання, поведінка агентів, інтерактивні середовища, відеоігри, симулятори, навчання з підкріпленням,

ISSN 2786-6025 Online

причинно-наслідкове навчання з підкріпленням, структурні причинно-наслідкові моделі, контрфактичний аналіз, байєсівські мережі, штучний інтелект у відеоіграх.

Lenartovych Vladyslav Heorhiiiovych PhD student, Specialty F3 Computer Science, Zhytomyr Ivan Franko State University, Zhytomyr, <https://orcid.org/0009-0002-9454-0819>

MODERN APPROACHES TO CAUSAL MODELING FOR AGENT BEHAVIOR IN INTERACTIVE ENVIRONMENTS

Abstract. The article examines modern approaches to causal modeling in the tasks of agent behavior design in interactive environments. The main attention is paid to the analysis and comparison of traditional agent behavior modeling methods, reinforcement learning, and causal approaches in the context of video games, simulators, and related interactive systems.

The paper analyzes the features of finite state machines, behavior trees, and rule-based approaches, which provide predictability, controllability, and low computational costs, but have limited adaptability in complex dynamic environments. Reinforcement learning is considered separately as an approach that allows agents to form behavior based on experience gained through interaction with the environment, while also having limitations related to interpretability and dependence on statistical regularities.

The article highlights the potential of Structural Causal Models, causal reinforcement learning, counterfactual analysis, and Bayesian Networks for improving explainability, adaptability, and the ability of agents to work under uncertainty.

The considered approaches are compared according to the criteria of learning efficiency, interpretability, scalability, and main area of application.

The obtained results indicate that causal modeling is not a universal replacement for traditional agent behavior modeling methods, but it can serve as a promising complement in tasks where the analysis of action consequences, consideration of alternative scenarios, and improvement of decision interpretability are important.

The most appropriate direction for further development is the combination of traditional, statistical, and causal approaches depending on the complexity of the environment and the requirements for agent behavior.

Keywords: causal modeling, agent behavior, interactive environments, video games, simulators, reinforcement learning, causal reinforcement learning, Structural Causal Models, counterfactual analysis, Bayesian Networks, game AI.

Постановка проблеми. Розвиток інтерактивних цифрових середовищ, зокрема відеоігор, симуляторів, навчальних систем та віртуальних середовищ взаємодії висуває підвищені вимоги до моделювання поведінки агентів, які мають діяти в умовах невизначеності та динамічного середовища. Традиційно для побудови поведінки агентів в інтерактивних середовищах використовуються скінченні автомати, дерева поведінки та системи на основі правил (rule-based системи), що забезпечують передбачуваність і простоту реалізації, проте в складних сценаріях демонструють суттєві обмеження: надмірне ускладнення логіки, повторюваність поведінки та нездатність адекватно реагувати на нестандартні ситуації [1], [2].

Окремою проблемою є те, що класичні rule-based системи та дерева поведінки здебільшого описують реакцію агента на певну подію, але не завжди дозволяють повноцінно враховувати причинно-наслідкові зв'язки між подіями середовища. Наприклад, агент у симуляторі або неігровий персонаж (NPC) у грі може реагувати на шум, зміну положення об'єктів чи появу гравця в певній зоні, однак така реакція часто визначається наперед заданими правилами. У більш складних системах важливо не лише зафіксувати факт події, але й оцінити, які дії або умови могли до неї призвести та які наслідки можуть виникнути після наступного рішення агента.

Методи машинного навчання, зокрема методи навчання з підкріпленням (reinforcement learning), частково долають ці недоліки, дозволяючи агентам формувати поведінку на основі досвіду [3]. Однак класичні моделі навчання з підкріпленням (RL-моделі) спираються переважно на статистичні закономірності, не забезпечуючи розуміння причинної структури середовища [8].

Це створює потребу у дослідженні підходів, які дозволяють не лише оптимізувати поведінку агента, але й аналізувати причинні залежності між діями, станами та наслідками. Причинно-наслідкове моделювання, зокрема структурні причинно-наслідкові моделі (SCM), причинно-наслідкове навчання з підкріпленням (CRL), байєсівські мережі та методи контрфактичного аналізу, відкриває можливість для більш глибокого порівняння моделей прийняття рішень у складних інтерактивних середовищах [4], [5], [6]. Попри свій потенціал, такі методи мають власні обмеження в контексті систем реального часу, що робить їх порівняльний аналіз із класичними підходами актуальним науковим завданням.

Аналіз останніх досліджень і публікацій. Теоретичні засади побудови інтелектуальних систем підтримки прийняття рішень розглянуто у працях [7], де визначено базові принципи організації управлінських інформаційних систем та механізмів обробки даних. Проблематика побудови поведінки агентів в інтерактивних середовищах тривалий час розглядається у межах досліджень зі штучного інтелекту, систем прийняття рішень та ігрового AI. У класичних

ISSN 2786-6025 Online

підходах до розробки поведінки агентів значна увага приділялася методам, які забезпечують контрольованість, передбачуваність і зрозумілу логіку роботи системи. До таких підходів належать скінченні автомати, дерева поведінки та rule-based системи, які широко застосовуються у відеоіграх і симуляторах завдяки простоті реалізації та можливості прямого керування поведінкою NPC [1], [2]. Проте зі зростанням складності середовища кількість правил і станів істотно збільшується, що ускладнює підтримку моделей та обмежує їх адаптивність.

Окремий напрям досліджень пов'язаний із застосуванням методів машинного навчання у задачах поведінки агентів. На відміну від класичних на основі правил, навчання з підкріпленням дозволяє агенту формувати стратегію поведінки на основі досвіду взаємодії із середовищем і поступового максимізування винагороди [3]. Такий підхід є особливо важливим для задач, у яких важко заздалегідь описати всі можливі сценарії дій агента, наприклад у симуляторах, іграх із відкритим середовищем або системах з великою кількістю динамічних об'єктів.

Разом з тим, у сучасних дослідженнях підкреслюється, що класичні RL-моделі мають низку обмежень. Зокрема, вони часто потребують значної кількості взаємодій із середовищем, можуть демонструвати нестабільність при зміні умов та не завжди забезпечують достатній рівень пояснюваності прийнятих рішень [6].

Для інтерактивних середовищ це є суттєвою проблемою, оскільки поведінка агента повинна бути не лише ефективною з точки зору винагороди, але й достатньо зрозумілою, контрольованою та передбачуваною для розробника або користувача.

У цьому контексті дедалі більшої актуальності набувають причинно-наслідкові підходи, які дозволяють перейти від аналізу статистичних залежностей до виявлення причинних зв'язків між діями агента, станами середовища та наслідками прийнятих рішень. У фундаментальних роботах Дж. Перл причинно-наслідкове моделювання розглядається як основа для аналізу інтервенцій, контрфактичних сценаріїв та структурних залежностей між змінними [4].

Такий підхід є важливим для інтерактивних середовищ, оскільки агент у грі або симуляторі постійно діє в умовах, де його рішення змінюють подальший стан системи.

Сучасні дослідження у сфері причинно-наслідкового машинного навчання також підкреслюють, що причинно-наслідкові моделі можуть використовуватися не лише для пояснення вже наявних даних, але й для підвищення здатності моделей до узагальнення, перенесення знань та аналізу альтернативних сценаріїв [8].

Поєднання причинно-наслідкового виведення з навчанням з підкріпленням розглядається як перспективний напрям подолання обмежень класичного RL, зокрема щодо пояснюваності та адаптивності моделей [5], [6].

Отже, сучасні дослідження демонструють перехід від традиційних правилкових систем до RL та причинно-наслідкового ШІ. Кожен із підходів має власні переваги й обмеження, що зумовлює актуальність їх порівняльного аналізу в контексті інтерактивних середовищ і систем реального часу.

Мета статті – проаналізувати сучасні підходи до причинно-наслідкового моделювання у задачах поведінки агентів інтерактивних середовищ, а також порівняти їх за ключовими характеристиками для використання у відеоіграх, симуляторах і суміжних інтерактивних системах.

Виклад основного матеріалу. У сучасних інтерактивних середовищах поведінка агентів може реалізовуватися за допомогою різних підходів, які відрізняються рівнем складності, адаптивності, інтерпретованості та вимогами до обчислювальних ресурсів. У відеоіграх, симуляторах та навчальних системах вибір конкретного методу часто залежить не лише від теоретичної ефективності моделі, але й від практичних обмежень: необхідності працювати в реальному часі, забезпечувати передбачувану поведінку NPC, підтримувати контроль з боку розробника та не перевантажувати систему зайвими обчисленнями [1], [2].

До традиційних методів побудови поведінки агентів належать скінченні автомати, дерева поведінки та системи на основі правил. Скінченні автомати дозволяють описувати поведінку агента як набір окремих станів і переходів між ними.

Наприклад, NPC у грі може перебувати у станах патрулювання, переслідування, атаки або повернення до початкової позиції. Подібна модель є зрозумілою для розробника, легко налагоджується та добре підходить для задач, у яких поведінка агента має бути чітко контрольованою.

Дерева поведінки є більш гнучким варіантом організації логіки агента. Вони дозволяють будувати ієрархічну структуру дій, умов і перевірок, що робить їх зручними для створення складнішої поведінки NPC. На відміну від класичних скінченних автоматів, дерева поведінки краще масштабуються при додаванні нових дій або умов, оскільки логіку агента можна розділяти на окремі підзадачі. Перевагами таких підходів є прозорість, передбачуваність і низькі обчислювальні витрати, що зумовлює їх широке використання у системах реального часу [1], [2].

Водночас традиційні моделі мають низку обмежень. Вони значною мірою залежать від ручного проектування логіки поведінки та погано масштабуються зі збільшенням кількості станів і сценаріїв взаємодії. Крім того, такі моделі переважно описують реакцію агента на подію, але не завжди дозволяють

ISSN 2786-6025 Online

врахувати глибші причинно-наслідкові зв'язки між діями, умовами середовища та майбутніми наслідками.

Таким чином, традиційні підходи до побудови поведінки агентів можна розглядати як практичну основу для багатьох інтерактивних систем, особливо відеоігор і симуляторів. Їхніми основними перевагами є простота реалізації, передбачуваність і низькі обчислювальні витрати. Однак у середовищах, де агент повинен діяти в умовах невизначеності, неповної інформації або великої кількості можливих сценаріїв, виникає потреба у методах, здатних не лише реагувати на події, але й формувати поведінку на основі досвіду та аналізу наслідків попередніх дій.

Одним із таких підходів є навчання з підкріпленням, у межах якого агент взаємодіє із середовищем, отримує винагороду за виконані дії та поступово формує стратегію поведінки, що максимізує очікуваний результат [3].

Формально задача reinforcement learning часто описується за допомогою марковського процесу прийняття рішень:

$$M_{MDP} = \langle S, A, P, R, \gamma \rangle$$

де S – множина станів середовища, A – множина можливих дій агента, P – функція переходів між станами, R – функція винагороди, а γ – коефіцієнт дисконтування майбутньої винагороди [3].

На відміну від rule-based систем, RL не потребує повного формального опису всіх можливих сценаріїв поведінки, що робить його ефективним для складних динамічних середовищ. Агент здатний адаптувати власну поведінку відповідно до накопиченого досвіду, однак класичні RL-моделі переважно виявляють статистичні закономірності між станами, діями та винагородами без явного врахування причинних залежностей [4], [6]. Унаслідок цього моделі можуть демонструвати нестійкість при зміні умов середовища та недостатню пояснюваність прийнятих рішень.

Для інтерактивних середовищ це є важливою проблемою. У відеоіграх і симуляторах агент часто діє у середовищі, де наслідки його рішень залежать не лише від поточного стану, але й від прихованих факторів, попередніх дій, поведінки користувача та взаємодії між різними об'єктами. Через це модель, навчена на одному наборі сценаріїв, може демонструвати нестабільну або недостатньо передбачувану поведінку при зміні умов. Саме тут виникає потреба у причинно-наслідковому моделюванні, яке дозволяє перейти від простого виявлення статистичних зв'язків до аналізу реальних причинних залежностей між подіями.

Для подолання зазначених обмежень у сучасних дослідженнях активно використовуються причинно-наслідкові підходи, зокрема структурні

причинно-наслідкові моделі (SCM), причинно-наслідкове навчання з підкріпленням (CRL), контрфактичний аналіз і байєсівські мережі. SCM дозволяють формалізувати причинні зв'язки між змінними системи та аналізувати наслідки втручань у середовище [4]. У загальному вигляді структурна причинно-наслідкова модель може бути представлена так:

$$M_{SCM} = \langle U, V, F, P(U) \rangle$$

де U – множина зовнішніх змінних, V – множина внутрішніх змінних системи, F – набір функціональних залежностей, а $P(U)$ – імовірнісний розподіл зовнішніх факторів [4].

На відміну від класичних статистичних моделей, SCM дозволяють не лише фіксувати наявність залежностей між подіями, але й аналізувати, як зміна однієї змінної може вплинути на інші елементи системи. У контексті поведінки агентів це означає, що модель може бути використана для оцінки того, які саме умови середовища або дії агента призводять до певного результату. Наприклад, у симуляторі поведінки NPC важливо не лише встановити, що поява гравця часто супроводжується зміною стану агента, але й визначити, які фактори стали причиною такої реакції: шум, візуальний контакт, попередні дії гравця або зміна стану ігрового об'єкта.

Інтеграція навчання з підкріпленням і причинно-наслідкового виведення реалізується в causal reinforcement learning (CRL). У таких моделях агент оцінює причинний вплив власних дій на подальший стан середовища за допомогою інтервенційного підходу:

$$P(Y | \text{do}(X = x))$$

Це дозволяє відокремлювати пасивне спостереження від активного втручання у систему та підвищує рівень інтерпретованості рішень агента [4], [5]. На практиці це дозволяє відрізнити ситуацію, коли агент лише спостерігає певну подію, від ситуації, коли він сам виконує дію, яка змінює стан середовища.

Для відеоігор і симуляторів така відмінність є суттєвою, оскільки поведінка агента часто має оцінюватися не лише за фактом результату, але й за тим, яким шляхом цей результат був досягнутий.

Важливою складовою причинно-наслідкового підходу є також можливість аналізу альтернативних сценаріїв розвитку подій. У традиційних моделях поведінки агент зазвичай працює з фактичним станом середовища: він отримує вхідні дані, перевіряє умови та виконує відповідну дію. Однак у складніших інтерактивних середовищах цього може бути недостатньо, оскільки для

ISSN 2786-6025 Online

прийняття якісного рішення агенту важливо оцінювати не лише те, що відбулося, але й те, що могло б відбутися за інших умов.

Такий підхід відомий як контрфактичний аналіз. Він дозволяє моделювати ситуації, які фактично не відбулися, але могли б виникнути у випадку іншої дії агента або зміни окремих параметрів середовища [4], [5]. У контексті відеоігор і симуляторів це має практичне значення, оскільки поведінка агента часто залежить від послідовності попередніх рішень. Наприклад, NPC може оцінювати не лише результат виконаної дії, але й потенційні наслідки альтернативного рішення: що сталося б, якби він обрав інший маршрут, не вступив у взаємодію з гравцем або змінив власну стратегію поведінки.

У причинно-наслідковому моделюванні контрфактичні запити можуть бути представлені у вигляді:

$$P(Y_x = y \mid X = x', Y = y')$$

де система оцінює ймовірність того, що подія Y набула б значення y за умови виконання дії $X = x$, навіть якщо в реальності спостерігався інший сценарій $X=x'$ та результат $Y=y'$ [4].

На відміну від звичайного прогнозування, контрфактичний аналіз дозволяє агенту працювати з альтернативними варіантами розвитку ситуації. Це особливо важливо для задач, у яких необхідно оцінити наслідки різних стратегій поведінки ще до їх безпосереднього виконання. У симуляційних системах такий підхід може використовуватися для аналізу ефективності рішень агента, перевірки можливих сценаріїв розвитку подій або пояснення того, чому певне рішення виявилось кращим чи гіршим за інші.

Разом з тим, контрфактичний аналіз має і суттєві обмеження. Його використання потребує достатньо точної моделі причинних залежностей у середовищі, оскільки без розуміння того, як змінні впливають одна на одну, оцінка альтернативних сценаріїв може бути неточною. Для відеоігор і симуляторів це створює додаткову складність, адже середовище часто містить велику кількість об'єктів, подій і взаємодій, які складно повністю формалізувати. Тому контрфактичний аналіз доцільно розглядати не як універсальний метод побудови поведінки агентів, а як інструмент для задач, де важливими є пояснюваність, прогнозування наслідків і порівняння альтернативних варіантів дій.

Окремий клас моделей становлять байєсівські мережі, які використовуються для роботи з невизначеністю та неповними даними. Вони описують залежності між змінними у вигляді орієнтованого графа, а спільний ймовірнісний розподіл подається як:

$$P(X_1, \dots, X_n) = \prod_{i=1}^{\{n\}} P(X_i | Parents(X_i))$$

де кожна змінна X_i залежить від набору батьківських вершин $Parents(X_i)$, що описують залежності між змінними у графі [4].

Байєсівські мережі є ефективними у випадках, коли агент не має повної інформації про стан середовища та змушений оцінювати ймовірність подій на основі часткових спостережень. Наприклад, агент у симуляторі може не мати повного доступу до всіх параметрів середовища, але може оцінювати ймовірність певного стану на основі доступних спостережень. У відеоіграх це може бути корисним для моделювання поведінки NPC, який не “знає” точного місцезнаходження гравця, але робить припущення на основі шуму, слідів, зміни стану об’єктів або попередніх дій користувача.

Порівняно з rule-based системами, байєсівські мережі забезпечують більш гнучке представлення невизначеності. Якщо система правил зазвичай працює за принципом чітко визначених умов, то байєсівські мережі дозволяють оцінювати ймовірності та змінювати їх залежно від нових спостережень. Це робить такі моделі придатними для задач, де поведінка агента не повинна бути повністю детермінованою, але водночас має залишатися достатньо контрольованою та інтерпретованою.

Водночас байєсівські мережі не завжди можна прямо ототожнювати з повноцінними причинно-наслідковими моделями. Вони добре описують ймовірнісні залежності між змінними, однак причинна інтерпретація таких залежностей потребує додаткового обґрунтування. Якщо структура графа побудована саме як причинна, байєсівські мережі можуть використовуватися для причинно-наслідкового виведення та аналізу альтернативних сценаріїв. Якщо ж граф відображає лише статистичні залежності, то можливості причинного аналізу залишаються обмеженими [4], [8].

Таким чином, байєсівські мережі можна розглядати як проміжний підхід між класичними статистичними моделями та більш формалізованими причинно-наслідковими моделями. Їхньою сильною стороною є робота з невизначеністю та неповними даними, тоді як основним обмеженням залишається складність побудови коректної структури графа, особливо у великих динамічних середовищах.

У поєднанні зі структурними причинно-наслідковими моделями (SCM), причинно-наслідковим навчанням з підкріпленням та контрфактичним аналізом ці підходи можуть використовуватися для доповнення системи прийняття рішень агента, однак потребують обґрунтованого вибору задачі та відповідного рівня деталізації моделі.

ISSN 2786-6025 Online

Загалом розглянуті підходи демонструють різні способи вирішення проблеми поведінки агентів в інтерактивних середовищах. Традиційні скінченні автомати, дерева поведінки та системи на основі правил характеризуються простотою реалізації, контрольованістю та низькими обчислювальними витратами. Навчання з підкріпленням забезпечує можливість формування поведінки на основі досвіду та адаптації до середовища. Структурні причинно-наслідкові моделі (SCM) дозволяють формалізувати причинні залежності між змінними, причинно-наслідкове навчання з підкріпленням поєднує адаптивність із причинним аналізом, контрфактичний аналіз забезпечує оцінювання альтернативних сценаріїв розвитку подій, а байєсівські мережі – роботу з невизначеністю та неповними даними.

Вказані підходи було узагальнено за критеріями, що мають практичне значення для інтерактивних середовищ: ефективність навчання, інтерпретованість, масштабованість та основна сфера застосування (табл. 1).

Таблиця 1

Порівняльний аналіз підходів

| Метод / підхід | Ефективність навчання | Інтерпретованість | Масштабованість | Основна сфера застосування |
|---|---|-------------------|-----------------|---|
| Скінченні автомати (Finite State Machines) | Не потребують навчання | Висока | Низька-середня | Прості NPC, базова поведінка агентів, системи з чітко визначеними станами |
| Дерева поведінки (Behavior Trees) | Не потребують навчання | Висока | Середня | Поведінка NPC у відеоіграх, сценарні інтерактивні системи, керовані агенти |
| Підходи на основі правил (Rule-based approaches) | Не потребують навчання | Висока | Низька-середня | Системи з передбачуваними умовами, навчальні симулятори, прості інтерактивні середовища |
| Навчання з підкріпленням (Reinforcement Learning) | Середня–висока, але потребує значної кількості ітерацій | Низька-середня | Середня-висока | Симулятори, адаптивні агенти, навчання поведінкових стратегій |

| Метод / підхід | Ефективність навчання | Інтерпретованість | Масштабованість | Основна сфера застосування |
|--|---|-------------------|-----------------|---|
| Структурні причинно-наслідкові моделі (Structural Causal Models) | Середня, залежить від якості побудови причинної структури | Висока | Середня | Аналіз причинних залежностей, пояснення поведінки агентів, моделювання впливу дій |
| Причинно-наслідкове навчання з підкріпленням (Causal Reinforcement Learning) | Середня-висока | Середня-висока | Середня | Адаптивні агенти, узагальнення поведінки, задачі з причинною структурою середовища |
| Контрфактичний аналіз (Counterfactual Analysis) | Середня, залежить від наявності коректної causal-моделі | Висока | Низька-середня | Аналіз альтернативних сценаріїв, прогнозування наслідків дій, оцінка стратегій NPC |
| Байєсівські мережі (Bayesian Networks) | Середня | Середня-висока | Середня | Моделювання невизначеності, поведінка агентів за неповної інформації, прогнозування станів середовища |

Висновки. Наведене порівняння показує, що традиційні підходи, зокрема скінченні автомати, дерева поведінки та rule-based системи, характеризуються високою інтерпретованістю, простотою реалізації та низькими обчислювальними витратами, однак мають обмежену масштабованість у складних динамічних середовищах. Навчання з підкріпленням забезпечує вищий рівень адаптивності поведінки агента, проте потребує значної кількості навчальних взаємодій і має нижчий рівень пояснюваності. Причинно-наслідкові підходи, зокрема структурні причинно-наслідкові моделі (SCM), причинно-наслідкове навчання з підкріпленням (CRL), контрфактичний аналіз і байєсівські мережі, забезпечують можливість аналізу причинних залежностей, наслідків дій та альтернативних сценаріїв, однак їх практичне застосування ускладнюється необхідністю формалізації причинної структури середовища та підвищеними обчислювальними вимогами.

ISSN 2786-6025 Online

Встановлено, що навчання з підкріпленням дозволяє агенту формувати поведінку на основі досвіду взаємодії із середовищем, що забезпечує вищий рівень адаптивності порівняно з традиційними підходами. Однак класичні RL-моделі переважно орієнтовані на статистичні залежності між станами, діями та винагородою, що ускладнює інтерпретацію прийнятих рішень і перенесення набутих стратегій у нові умови.

Показано, що причинно-наслідкові моделі мають потенціал для подолання частини зазначених обмежень. Структурні причинно-наслідкові моделі забезпечують формалізацію причинних залежностей, поєднує адаптивність RL із причинно-наслідковим виведенням, контрфактичний аналіз підтримує оцінювання альтернативних сценаріїв, а байєсівські мережі дозволяють працювати з невизначеністю та неповними даними. Це створює передумови для підвищення пояснюваності поведінки агентів, аналізу наслідків дій та покращення здатності моделей до узагальнення.

Разом із тим використання causal AI у відеоіграх і симуляторах пов'язане зі складністю побудови причинної структури середовища, високими вимогами до формалізації моделей та додатковими обчислювальними витратами. Тому причинно-наслідкові підходи доцільно розглядати не як повну альтернативу традиційним методам, а як перспективне доповнення для задач, у яких критичними є пояснюваність, прогнозування наслідків рішень та аналіз альтернативних сценаріїв поведінки агента.

Література:

1. Millington I., Funge J. *Artificial Intelligence for Games*. 2nd ed. Boca Raton : CRC Press, 2009. 895 p.
2. Yannakakis G. N., Togelius J. *Artificial Intelligence and Games*. Cham : Springer, 2018. 395 p. DOI: 10.1007/978-3-319-63519-4.
3. Глибовець М. М., Олецкий О. В. *Штучний інтелект*. Київ : ВД “Києво-Могилянська академія”, 2002. 366 с.
4. Pearl J. *Causality: Models, Reasoning, and Inference*. 2nd ed. Cambridge : Cambridge University Press, 2009. 487 p.
5. Bareinboim E., Lee S., Zhang J. An Introduction to Causal Reinforcement Learning. *Columbia CausalAI Laboratory Technical Report*. 2020. № R-65. URL: <https://causalai.net/r65.pdf>.
6. Deng Z., Jiang J., Long G., Zhang C. Causal Reinforcement Learning: A Survey. *arXiv preprint arXiv:2307.01452*. 2023. DOI: <https://doi.org/10.48550/arXiv.2307.01452>.
7. Литвин В. В. *Бази знань інтелектуальних систем підтримки прийняття рішень*. Львів : Видавництво Львівської політехніки, 2011. 240 с.
8. Kaddour J., Lynch A., Liu Q., Kusner M. J., Silva R. Causal Machine Learning: A Survey and Open Problems. *arXiv preprint arXiv:2206.15475*. 2022. DOI: 10.48550/arXiv.2206.15475.

References:

1. Millington, I., & Funge, J. (2009). *Artificial intelligence for games* (2nd ed.). CRC Press.

ISSN 2786-6025 Online

2. Yannakakis, G. N., & Togelius, J. (2018). *Artificial intelligence and games*. Springer. DOI: <https://doi.org/10.1007/978-3-319-63519-4>.

3. Hlybovets, M. M., & Oletskyi, O. V. (2002). *Shtuchnyi intelekt [Artificial Intelligence]*. VD «Kyievo-Mohylianska akademiia». [in Ukrainian].

4. Pearl, J. (2009). *Causality: Models, reasoning, and inference* (2nd ed.). Cambridge University Press.

5. Bareinboim, E., Lee, S., & Zhang, J. (2020). *An introduction to causal reinforcement learning* (Technical Report No. R-65). Columbia CausalAI Laboratory. Retrieved from causalai.net.

6. Deng, Z., Jiang, J., Long, G., & Zhang, C. (2023). *Causal reinforcement learning: A survey*. *arXiv*. DOI: <https://doi.org/10.48550/arXiv.2307.01452>.

7. Lytvyn, V. V. (2011). *Bazy znan intelektualnykh system pidtrymky pryiniattia rishen [Knowledge Bases for Intelligent Decision Support Systems]*. Vydavnytstvo Lvivskoi politekhniki. [in Ukrainian].

8. Kaddour, J., Lynch, A., Liu, Q., Kusner, M. J., & Silva, R. (2022). *Causal machine learning: A survey and open problems*. *arXiv*. DOI: <https://doi.org/10.48550/arXiv.2206.15475>.

Дата першого надходження статті до видання: 08.05.2026

Дата прийняття статті до друку після рецензування: 22.05.2026