

DOI <https://doi.org/10.32689/maup.it.2026.1.5>
 УДК 004.891:004.414.2

МЕТОД СЕМАНТИЧНОЇ ПРЕФІЛЬТРАЦІЇ ПРИЧИННО-НАСЛІДКОВИХ ЗВ'ЯЗКІВ У ВИСОКОВИМІРНИХ МЕРЕЖАХ

О. А. Ковенько, Н. В. Апенько

METHOD OF SEMANTIC PREFILTERING OF CAUSAL RELATIONSHIPS IN HIGH-DIMENSIONAL NETWORKS

Oleksii Kovenko, Natalia Apenko

Анотація

Об'єктом дослідження у статті є процес виявлення причинно-наслідкових зв'язків у мережах надвисокої розмірності. Фундаментальна проблема, що розв'язується, полягає в експоненційній обчислювальній складності класичних алгоритмів структурного навчання (так зване «прокляття розмірності») та їхній неспроможності ефективно працювати в умовах недостатності або повної відсутності історичних статистичних даних (проблема «холодного старту»).

Суть отриманих результатів зводиться до розробки та емпіричної валідації нового методу семантичної префільтрації каузальних графів. Завдяки своїм концептуальним особливостям, а саме використанню гіпотези семантичної розрідженості, запропонований метод уможливує значне звуження простору пошуку виключно на основі аналізу метаданих вузлів. Розроблений алгоритм обробки включає чотири послідовні етапи: автоматизоване формування розгорнутих текстових тлумачень для кожного вузла за допомогою сучасних мовних моделей, перетворення цих описів у щільні числові вектори, розрахунок матриці косинусної подібності для всього простору ознак та подальше застосування стратегії адаптивного відсікання.

Отримані результати дозволили успішно подолати зазначену проблему, оскільки розроблений підхід відкидає до 88.3 відсотка нерелевантних пар вузлів для масивних графів, гарантовано зберігаючи при цьому понад 90 відсотків істинних причинних ребер. Висока ефективність алгоритму пояснюється тим, що у реальних багатовимірних системах каузальні зв'язки виникають переважно між семантично спорідненими сутностями, тоді як термінологічно віддалені вузли є ймовірно незалежними. Відповідно, моделі векторизації здатні кількісно оцінити цю семантичну близькість, відсіяти шум та природним шляхом масштабуватися пропорційно до збільшення розміру мережі.

Запропонований підхід може бути використаний на практиці в сучасних високотехнологічних доменах як інструмент попередньої фільтрації простору пошуку перед застосуванням класичних алгоритмів оптимізації. Головними умовами його найбільш ефективного впровадження є необхідність роботи з графами високої щільності та наявність якісних семантичних метаданих у сценаріях, де збір великих обсягів історичних спостережень є технічно неможливим.

Ключові слова: причинно-наслідкові графи, семантична префільтрація, прокляття розмірності, великі мовні моделі, векторні представлення, адаптивне відсікання, відкриття причинності.

Abstract.

The object of research is the process of discovering causal relationships in high-dimensional networks. The addressed problem is the exponential computational complexity of classical structural learning algorithms and their inability to operate effectively without historical statistical observations. The obtained results involve the development and empirical validation of a novel semantic pre-filtering method for causal graphs. Relying on the formulated semantic sparsity hypothesis, the method narrows the search space based solely on node metadata. The algorithm comprises four stages: generating textual interpretations for each node using language models, transforming these descriptions into dense numerical vectors, calculating a cosine similarity matrix, and applying an adaptive pruning strategy. These results solved the problem by rejecting up to 88.3 percent of irrelevant node pairs for massive graphs while preserving over 90 percent of true causal edges. This efficiency is explained by the fact that in large systems, causal links occur predominantly between semantically related entities. Vectorization models quantify this semantic proximity and scale naturally with network size. The approach can be practically applied in high-tech domains as a pre-filtering tool before executing traditional causal discovery algorithms. Conditions for its effective use include high-density networks and scenarios where collecting massive historical datasets is technically impossible, provided qualitative metadata is available.

Key words: causal graphs, semantic pre-filtering, language models, vector representations, adaptive pruning, structural learning.

1. Вступ. Побудова точних причинно-наслідкових моделей (Causal Discovery) є критичним етапом у створенні надійних систем підтримки прийняття рішень (DSS) та пояснюваного штучного інтелекту (XAI). У сучасних високотехнологічних доменах, таких як системна біологія, нейронаука та моніторинг розподілених ІТ-систем, спостерігається стійка тенденція до надвисокої розмірності даних. Наприклад, аналіз функціональної МРТ вимагає обробки графів із понад 50 000 вокселів [2],



© Ковенько О. А., Апенько Н. В., 2026

Стаття поширюється на умовах ліцензії відкритого доступу CC BY 4.0

геномні дослідження оперують мережами діапазону від 20 000 до 1 000 000 вузлів [2, 3], а сучасні системи телеметрії генерують тисячі метрик у реальному часі. За таких умов виникає нагальна потреба у проведенні наукових досліджень для розв'язання проблеми «прокляття розмірності» (Curse of Dimensionality), оскільки при лінійному збільшенні кількості вузлів простір пошуку зростає суперекспоненційно [11, 19]. Результати цих досліджень дадуть практиці змогу швидко локалізувати більшість ключових причин (наприклад, у задачах Root Cause Analysis) у масивних системах за допомогою каузального ШІ, що є пріоритетнішим за обчислювально недосяжний пошук глобального оптимуму [8, 20]. Тому дослідження, присвячені розробці обчислювально ефективних методів префільтрації причинно-наслідкових зв'язків у високовимірних просторах, є надзвичайно актуальними.

Проблема масштабованості алгоритмів виявлення причинно-наслідкових зв'язків вирішується за трьома основними напрямками: алгоритмічною оптимізацією, статистичною фільтрацією та інтеграцією знань великих мовних моделей (LLM). Фундаментальні дослідження спираються на constraint-based (PC, FCI, ACI) [18, 19] та score-based (GES) [7] підходи. Невирішеним в аналізованих класичних алгоритмах залишається питання їхньої суперекспоненційної часової складності на щільних графах розмірністю понад 1000 вузлів [1, 2]. Це зумовлено об'єктивними причинами: задача точного відновлення структури баєсової мережі належить до класу NP-складних [7, 11], апаратне розпаралелювання (Parallel-PC, GPU-PC) не змінює базової алгоритмічної складності [1, 12, 13].

Методи статистичного скрінінгу (SIS, Lasso) ефективні для зменшення розмірності [10], проте невирішеною залишається проблема їх роботи у сценаріях «холодного старту» (HDLSS) [3]. Це пояснюється тим, що такі алгоритми жорстко вимагають зростання обсягу вибірки пропорційно до розмірності мережі, інакше відбувається різке падіння статистичної потужності.

Інтеграція LLM [6, 15, 16] дозволила використовувати семантику як апіорні знання. Попри це, існуючі методи стикаються з проблемами масштабованості [17] та сумнівами щодо здатності моделей до істинного каузального мислення [5]. Також невирішеною проблемою тут залишається латентність і економічна вартість. Це пов'язано з тим, що підходи на основі попарних запитів вимагають квадратичної кількості звернень до моделі [9], а оптимізовані фреймворки (наприклад, IRIS [14]) орієнтовані на глибокий видобуток нових сутностей, що є обчислювально надлишковим для задач швидкої структурної префільтрації великих просторів. Векторні підходи, у свою чергу, фокусуються переважно на передбаченні зв'язків, а не на побудові скелета графа [4].

Таким чином, загальною невирішеною проблемою є відсутність методу префільтрації каузальних графів надвисокої розмірності, який би поєднував незалежність від історичних даних, лінійну обчислювальну складність та здатність ефективно розріджувати простір пошуку.

Метою дослідження є розробка та емпірична валідація методу семантичної префільтрації високовимірних графів на основі векторних представлень вузлів. Це дасть можливість звузити простір пошуку причинно-наслідкових зв'язків та подолати експоненційну обчислювальну складність в умовах відсутності історичних спостережень.

Для досягнення мети були поставлені наступні задачі:

1. Сформулювати етапи роботи методу семантичної префільтрації з використанням великих мовних моделей та стратегії адаптивного відсікання простору ознак.
2. Дослідити ефективність семантичної префільтрації на наборах даних різної розмірності шляхом розрахунку метрик стиснення, точності та збереження цільових зв'язків.
3. Визначити оптимальний компроміс між повнотою виявлення істинних каузальних ребер та ефективністю фільтрації шуму.
4. Дослідити масштабованість алгоритму шляхом аналізу залежності показника збережених потенційних зв'язків від загальної розмірності мережі.

2. Матеріали і методи. Об'єктом дослідження є процес виявлення причинно-наслідкових зв'язків у мережах надвисокої розмірності.

Основною гіпотезою дослідження є гіпотеза семантичної розрідженості (Semantic Sparsity Hypothesis): у великих системах причинно-наслідкові зв'язки існують переважно між семантично спорідненими об'єктами, тоді як семантично віддалені змінні є ймовірно незалежними.

Прийнятими в роботі припущеннями є те, що семантичний зміст назв змінних (метаданих) містить достатньо апіорної інформації для оцінки ймовірності існування каузальних зв'язків, що дозволяє виконувати префільтрацію без залучення статистичних рядів спостережень (в умовах «холодного старту»).

Прийнятими в роботі спрощеннями є формування розгорнутих описів сутностей виключно на основі їхніх базових назв, а також використання косинусної подібності як єдиної лінійної метрики для кількісної оцінки семантичної відстані між вузлами у латентному просторі.

Для емпіричної валідації запропонованого методу було використано набір стандартних бенчмарк-мереж із репозиторію bnlearn, які охоплюють різні предметні області (медицина, агрономія, генетика) та варіюються за розміром від малих (35 вузлів) до масивних (1041 вузол). До вибірки увійшли мережі: mildew (35), alarm (37), barley (48), hepar2 (70), win95pts (76), diabetes (413), link (724) та munin (1041).

Дослідження проводилося шляхом комп'ютерного моделювання та реалізації розробленого методу семантичної префільтрації, який включає чотири послідовні етапи:

1. На першому етапі формувався текстовий опис кожної змінної графа. Для автоматичної генерації розгорнутих тлумачень на основі доступних метаданих використовувалася велика мовна модель gemini-2.5-pro.

2. На другому етапі отримані текстові описи перетворювалися у щільні числові вектори (embeddings) за допомогою моделі векторизації gemini-embedding-001.

3. На третьому етапі обчислювалася матриця косинусної подібності між усіма парами змінних графа.

4. На четвертому етапі застосовувалася стратегія адаптивного відсікання (Adaptive Top-k Pruning), за якої для кожного вузла зберігалися лише k сусідів з найвищим показником подібності, а решта пар відкидалися. Отриманий розріджений граф призначався як вхідні дані для класичних алгоритмів (наприклад, PC або GES).




Рис. 1. Блок-схема методу семантичної префільтрації

Оцінка ефективності префільтрації проводилася за чотирма математичними метриками. Нехай E_{true} – множина ребер істинного графа, $E_{filtered}$ – множина ребер, збережених у скелеті після фільтрації, а E_{full} – множина всіх можливих пар вузлів графа. Повнота (Recall) визначалася як частка збережених істинних зв'язків:

$$Recall = \frac{|E_{true} \cap E_{filtered}|}{|E_{true}|}$$

Ступінь стиснення простору пошуку (Reduction Rate, RR) обчислювався як частка відкинутих ребер відносно повного графа:

$$RR = 1 - \frac{|E_{filtered}|}{|E_{full}|}$$

Точність (Precision) визначалася за формулою:

$$Precision = \frac{|E_{true} \cap E_{filtered}|}{|E_{filtered}|}$$

Коефіцієнт переваги над випадковим відбором (Lift) обчислювався як відношення точності розробленого методу до загальної густини істинного графа (Density):

$$Density = \frac{|E_{true}|}{|E_{full}|}$$

$$Lift = \frac{Precision}{Density}$$

Критерієм успішності було визначено збереження не менше 90 % істинних причинних зв'язків ($Recall \geq 0.90$), оскільки їхня втрата на етапі префільтрації є незворотною. Отримані результати зведено у таблицю 1.

3. Результати і обговорення. Реалізація запропонованого методу дозволила автоматизувати процес звуження простору пошуку для каузальних алгоритмів. Використання великої мовної моделі gemini-2.5-pro забезпечило формування змістовних контекстних тлумачень навіть за умов наявності лише базових метаданих (назв змінних). Перетворення цих описів у латентний простір за допомогою моделі gemini-embedding-001 уможливило швидке математичне обчислення матриці косинусної подібності розмірністю $N \times N$, що є обчислювально легким порівняно з перевітками умовної незалежності в класичних алгоритмах. Застосування адаптивного Тор-к відсікання дозволило динамічно регулювати щільність отриманого каузального скелета. Перевагою цього підходу перед існуючими методами (наприклад, constraint-based [18, 19] або score-based [7]) є повна незалежність від наявності історичних спостережень, що вирішує проблему «холодного старту» (HDLSS).

Отримані в ході експериментів результати (Таблиця 1) демонструють зростання ефективності розробленого методу зі збільшенням розмірності графа.

Таблиця 1

Показники ефективності семантичної префільтрації при цільовому рівні Recall ≥ 0.90

Dataset	Вузли (N)	Обране k	Recall	Reduction Rate	Lift
mildew	35	19	0.978	0.343	1.49
alarm	37	13	0.935	0.557	2.11
barley	48	37	0.905	0.097	1.00
hepar2	70	43	0.927	0.240	1.22
win95pts	76	49	0.920	0.239	1.21
diabetes	413	73	0.900	0.773	3.97
link	724	217	0.902	0.613	2.33
munin	1041	91	0.901	0.883	7.67

Найвищі показники зафіксовано на масивному графі munin (1041 вузол). Для збереження 90.1 % істинних зв'язків знадобилося залишити лише 91 найближчого сусіда для кожного вузла, що дозволило відсіяти 88.3 % нерелевантних пар ($Reduction Rate = 0.883$). Показник Lift склав 7.67, що підтверджує здатність методу виявляти потенційні зв'язки майже у 8 разів ефективніше за випадкове вгадування. Високу ефективність також показала мережа diabetes ($Reduction Rate = 0.773$, $Lift = 3.97$). Ці результати пояснюються тим, що у великих системах змінні формують виражені семантичні кластери, які успішно ідентифікуються мовними моделями у векторному просторі. Натомість, на менших мережах (наприклад, barley) результати виявилися слабшими ($Reduction Rate = 0.097$, $Lift = 1.00$), що може вказувати на надмірну щільність семантичного простору цієї предметної області. Візуалізацію переваги методу за метрикою Lift наведено на рис. 2.

Аналіз компромісу між повнотою виявлення зв'язків (Recall) та ефективністю стиснення простору пошуку (Reduction Rate) підтвердив життєздатність запропонованого методу. На побудованій кривій ефективності (рис. 3) чітко видно, що для масивних графів (таких як munin, diabetes) точки оптимального співвідношення зміщені у цільову зону (верхній правий кут графіка). Це означає, що алгоритм здатний радикально зменшити кількість хибних кандидатів, не втрачаючи при цьому критично важливі істинні ребра.

Аналіз масштабованості продемонстрував, що метод природним шляхом адаптується до зростання розмірності мережі. Аналіз залежності відносного показника збережених сусідів (k/N) від загальної розмірності графа (N) за умови $Recall \geq 0.90$ (рис. 4) виявляє чітку зворотну залежність.

Якщо для малих мереж алгоритм зберігає від 50 % до 80 % вузлів, то для масивного графа munin цей показник падає нижче 10 %. Це пояснюється топологічною природою розростання мереж: із збільшенням вузлів середня кількість зв'язків для окремого елемента не зростає пропорційно. Локальні кластери стають віддаленішими, що дозволяє векторним моделям легко відсікати очевидно непов'язані сутності.

На відміну від методів статистичного скрінінгу, які залежать від великих обсягів історичних даних, запропонований метод семантичної префільтрації дозволяє звужити простір пошуку на етапі метаданих. Отримані результати підтверджують ефективність методу, який здатний відкинути до 88.3 % шуму при збереженні понад 90 % істинних зв'язків на графах розмірністю понад 1000 вузлів. Разом з тим, обмеженням цього дослідження є те, що метод продемонстрував неоднорідну ефективність на малих мережах (менше 50 вузлів) або в доменах з високою семантичною однорідністю. Цей недолік має бути обов'язково врахований при застосуванні алгоритму на практиці: його доцільно використовувати саме для високовимірних графів. Подальший розвиток дослідження може полягати у впровадженні гібридного відсікання та підвищенні якості семантичного сигналу через ансамблеві векторні представлення.

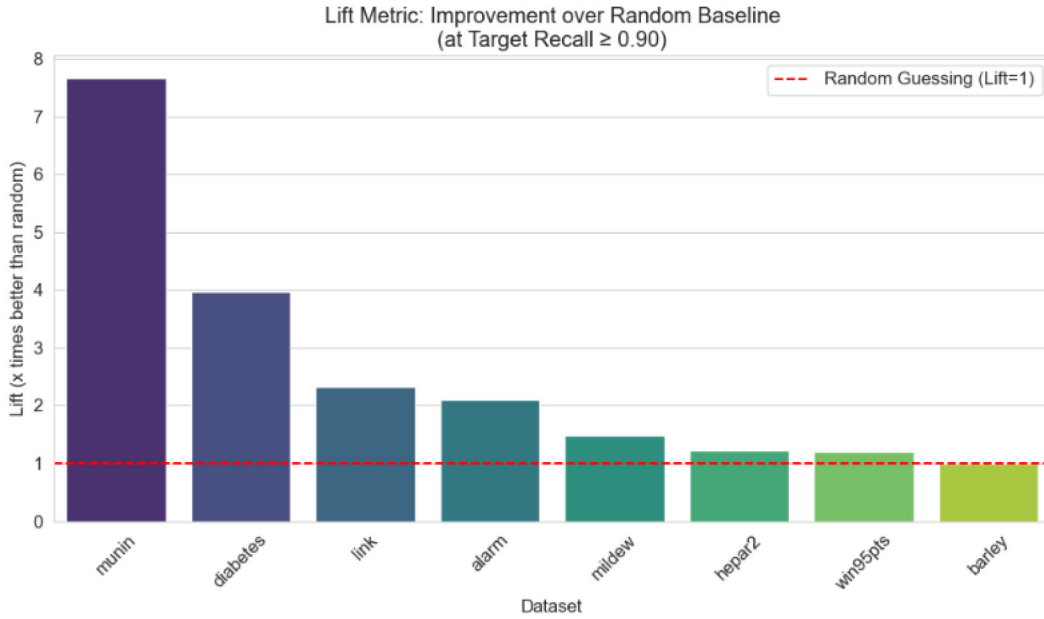


Рис. 2. Залежність метрики Lift від набору даних

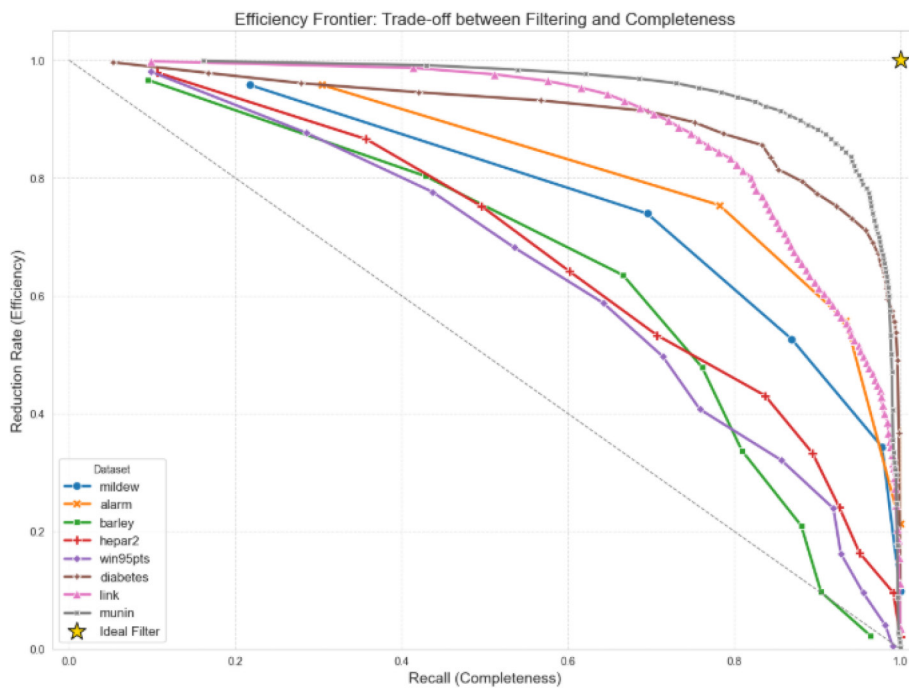


Рис. 3. Залежність ступеня стиснення від повноти

4. Висновки. Розроблено метод семантичної профільтрації, який базується на гіпотезі семантичної розрідженості та не потребує наявності статистичних рядів спостережень (розв'язуючи проблему HDLSS). Завдяки інтеграції великих мовних моделей (gemini-2.5-pro для генерації тлумачень та gemini-embedding-001 для векторизації) метод перетворює базові метадані вузлів у щільний латентний простір. Обчислення матриці косинусної подібності з подальшим адаптивним відсіканням дозволяє подолати експоненційну складність класичних алгоритмів.

Експериментальна перевірка на бенчмарк-мережах засвідчила, що метод дозволяє радикально звужити простір пошуку на етапі, що передує структурному навчанню. Для масивного графа munin (1041 вузол) алгоритм досяг ступеня стиснення 0.883 (відкинута 88.3 % можливих ребер), зберігши при цьому 90.1 % істинних причинно-наслідкових зв'язків. Коефіцієнт переваги над випадковим відбором (Lift) для цієї мережі склав 7.67, що підтверджує високу селективну здатність методу у високимірних просторах.

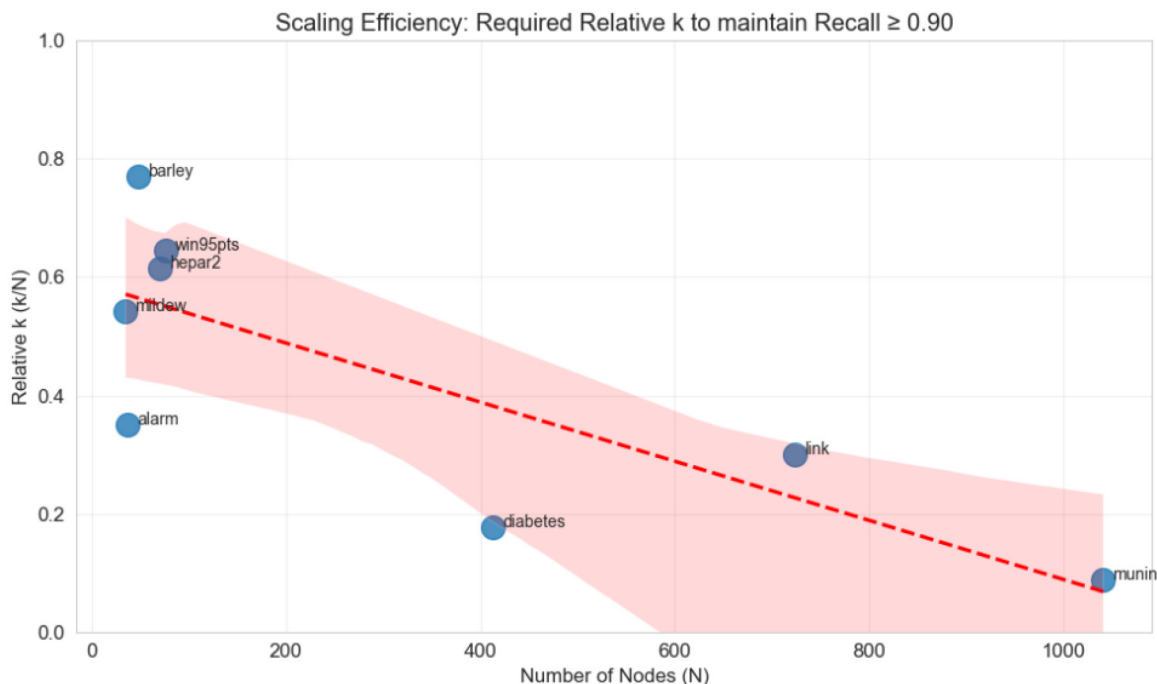


Рис. 4. Залежність відносного показника k від розмірності мережі

Оптимальний компроміс між повнотою та ефективністю фільтрації досягається переважно на графах великої розмірності (понад 400 вузлів). Аналіз кривої ефективності показав, що для графів diabetes та munin метод забезпечує максимальне відсікання нерелевантних кандидатів без критичної втрати істинних ребер ($Recall \geq 0.90$). Це пояснюється тим, що у великих предметних областях змінні утворюють більш виражені семантичні кластери. Натомість на мережах малої розмірності (наприклад, barley) зі щільним семантичним простором ступінь стиснення є незначним ($Reduction Rate = 0.097$).

Ефективність семантичної префільтрації масштабується природним шляхом зі зростанням мережі. Аналіз залежності підтвердив, що для підтримання цільової повноти ($Recall \geq 0.90$) у малих графах необхідно зберігати як потенційних сусідів від 50 % до 80 % вузлів (відносний показник k/N), тоді як для масивних графів цей показник експоненційно знижується (менше 10 % для munin). Здатність моделі превентивно відтинати переважну частку шуму зумовлена топологічною розрідженістю зв'язків у великих системах.

Конфлікт інтересів. Автори декларують, що не мають конфлікту інтересів стосовно даного дослідження, в тому числі фінансового, особистісного характеру, авторства чи іншого характеру, що міг би вплинути на дослідження та його результати, представлені в даній статті.

Фінансування. Дослідження проводилося без фінансової підтримки.

Доступність даних. Дані будуть надані за обґрунтованим запитом.

Використання засобів штучного інтелекту. Під час створення представленої роботи автори використовували такі засоби штучного інтелекту:

1. Модель gemini-2.5-pro була використана у розділі «2. Матеріали і методи» для автоматичної генерації розгорнутих текстових тлумачень (пояснень) кожної змінної на основі їх базових назв як складова частина реалізованого алгоритму.

2. Модель gemini-embedding-001 була використана у розділі «2. Матеріали і методи» для перетворення згенерованих текстових описів у числові вектори (embeddings) як складова частина реалізованого алгоритму.

3. Автори перевіряли результати генерації шляхом вибіркового аналізу згенерованих тлумачень на відповідність доменній специфіці бенчмарк-мереж.

4. Аналіз отриманих результатів, інтерпретацію метрик ефективності алгоритму та формулювання висновків виконано авторами самостійно.

Внесок авторів. Олексій Ковенько: концептуалізація, розробка методу, програмна реалізація алгоритму, проведення експериментів, аналіз результатів, написання початкового проекту статті; Наталія Апенько: наукове керівництво, критичний перегляд методології, перевірка результатів, редагування тексту статті.

References:

1. A Fast PC Algorithm for High Dimensional Causal Discovery with Multi-Core PCs / T. D. Le et al. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*. 2019. Vol. 16, no. 5. P. 1483–1495. DOI: 10.1109/TCBB.2016.2591526
2. A million variables and more: the Fast Greedy Equivalence Search algorithm for learning high-dimensional graphical causal models, with an application to functional magnetic resonance images / J. Ramsey et al. *International Journal of Data Science and Analytics*. 2017. Vol. 3, no. 2. P. 121–129. DOI: 10.1007/s41060-016-0032-z
3. Ancestral causal learning in high dimensions with a human genome-wide application / U. Noè et al. *arXiv preprint arXiv:1910.05166*. 2019. DOI: 10.48550/arXiv.1910.05166
4. Balashankar A., Subramanian L. Learning Faithful Representations of Causal Graphs. *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics (ACL)*. 2021. P. 1002–1011. DOI: 10.18653/v1/2021.acl-long.81
5. Causal Parrots: Large Language Models May Talk Causality But Are Not Causal / M. Zečević et al. *Transactions on Machine Learning Research*. 2023. DOI: 10.48550/arXiv.2308.13067
6. Causal Reasoning and Large Language Models: Opening a New Frontier for Causality / E. Kicman et al. *Transactions on Machine Learning Research*. 2024. DOI: 10.48550/arXiv.2305.00050
7. Chickering, D. M. (2002). Optimal structure identification with greedy search. *Journal of Machine Learning Research*. Vol. 3. P. 507–554. DOI: 10.1162/153244303321897717
8. Detecting and quantifying causal associations in large nonlinear time series datasets / J. Runge et al. *Science Advances*. 2019. Vol. 5, no. 11. DOI: 10.1126/sciadv.aau4996
9. Efficient Causal Graph Discovery Using Large Language Models / T. Jiralerspong et al. *arXiv preprint arXiv:2402.01207*. 2024. DOI: 10.48550/arXiv.2402.01207
10. Fan, J., Lv, J. (2008). Sure independence screening for ultrahigh dimensional feature space. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*. Vol. 70, no. 5. P. 849–911. DOI: 10.1111/j.1467-9868.2008.00674.x
11. Feigenbaum, I., Khanna, S., Vempala, S. S. (2024). On the Unlikelihood of D-Separation. *Proceedings of Machine Learning Research*. Vol. 246. P. 1–17. DOI: 10.48550/arXiv.2303.05628
12. Guo, C., Luk, W. (2022). Accelerating Constraint-Based Causal Discovery by Shifting Speed Bottleneck. *Proceedings of the 2022 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays (FPGA '22)*. P. 123–134. DOI: 10.1145/3490422.3502363
13. Hagedorn, C., Huegle, J. (2021). GPU-Accelerated Constraint-Based Causal Structure Learning for Discrete Data. *SIAM International Conference on Data Mining (SDM)*. P. 37–45. DOI: 10.1137/1.9781611976700.5
14. IRIS: An Iterative and Integrated Framework for Verifiable Causal Discovery in the Absence of Tabular Data / T. Feng et al. *arXiv preprint arXiv:2406.10526*. 2024. DOI: 10.48550/arXiv.2406.10526
15. Darvariu, V.-A., Hailes, S., Musolesi, M. (2024). Large Language Models are Effective Priors for Causal Graph Discovery. *arXiv preprint arXiv:2401.12838*. DOI: 10.48550/arXiv.2401.12838
16. Large Language Models for Causal Discovery: Current Landscape and Future Directions / G. Wan et al. *International Joint Conference on Artificial Intelligence (IJCAI)*. 2024. DOI: 10.24963/ijcai.2024/889
17. LLM-Driven Causal Discovery via Harmonized Prior / T. Ban et al. *IEEE Transactions on Knowledge and Data Engineering*. 2024. DOI: 10.1109/TKDE.2025.3353067
18. Magliacane, S., Claassen, T., Mooij, J. M. (2016). Ancestral Causal Inference. *Advances in Neural Information Processing Systems*. Vol. 29. P. 4473–4481. URL: <https://papers.nips.cc/paper/6266-ancestral-causal-inference>
19. Spirtes, P., Glymour, C., Scheines, R. (2000). *Causation, Prediction, and Search*. 2nd ed. Cambridge : MIT Press, 543 p. DOI: 10.7551/mitpress/1754.001.0001
20. Ultra-Scalable and Efficient Methods for Hybrid Observational and Experimental Local Causal Pathway Discovery / A. Statnikov et al. *Journal of Machine Learning Research*. 2015. Vol. 16. P. 3219–3267. URL: <https://jmlr.org/papers/v16/statnikov15a.html>

Відомості про авторів

Англ.	Укр.
Kovenko Oleksii Postgraduate Student Department of Intelligent Cybernetic Systems Kyiv Aviation Institute 1 Liubomyra Huzara Ave., Kyiv, 03058, Ukraine 3414934@stud.kai.edu.ua ORCID: 0009-0007-2418-7761	Ковенько Олексій Анатолійович аспірант Кафедра інтелектуальних кібернетичних систем, Київський авіаційний інститут просп. Любомира Гузара, 1, Київ, 03058 3414934@stud.kai.edu.ua ORCID: 0009-0007-2418-7761
Apenko Nataliia PhD, Associate Professor Department of Intelligent Cybernetic Systems Kyiv Aviation Institute 1 Liubomyra Huzara Ave., Kyiv, 03058, Ukraine nataliia.apenko@npp.kai.edu.ua ORCID: 0000-0001-6891-0869	Апенько Наталія Вікторівна кандидат технічних наук, доцент Кафедра інтелектуальних кібернетичних систем, Київський авіаційний інститут просп. Любомира Гузара, 1, Київ, 03058 nataliia.apenko@npp.kai.edu.ua ORCID: 0000-0001-6891-0869

Дата надходження статті: 19.03.2026

Дата надходження виправленої версії статті: 07.04.2026

Дата прийняття статті: 17.04.2026

Дата публікації статті: 01.06.2026