

2. Perlin K. (1985) An Image Synthesizer. ACM SIGGRAPH Computer Graphics, vol. 19, no. 3, pp. 287–296, <https://doi.org/10.1145/325334.325247>.
3. Кудінов І. П., Ягодкін Д. (2025). Алгоритми процедурної генерації шуму Перліна. Зб. тез наук. доп. здобувачів вищої освіти Бердян. держ. пед. ун-ту, Запоріжжя, Україна, трав. 2025, с. 127-130. <https://doi.org/10.5281/zenodo.15548937>.
4. Kopel, M., Maciejewski, G. (2020). Comparison of Procedural Noise-Based Environment Generation Methods. In: Nguyen, N.T., Hoang, B.H., Huynh, C.P., Hwang, D., Trawiński, B., Vossen, G. (eds) Computational Collective Intelligence. ICCCI 2020. Lecture Notes in Computer Science, vol 12496. Springer, Cham. pp 878–887.
5. Wu Z., Mao Y., Li Q. (2021). Procedural Game Map Generation using Multi-leveled Cellular Automata by Machine Learning, in Proc. ISAIMS 2021, Chongqing, China, Oct. 2021, <https://doi.org/10.1145/3500931.3500962>.
6. Fellows M. R., Rosamond F. A., da Silva M. D., Souza U. S. (2021). A Survey on the Complexity of Flood-Filling Games. Discrete Appl. Math., vol. 304, pp. 233–246, Dec. 2021, <https://doi.org/10.1016/j.dam.2021.09.029>.
7. Popp S., Dornhaus A. (2023). Ants Combine Systematic Meandering and Correlated Random Walks when Searching for Unknown Resources. iScience, vol. 26, no. 2, 2023, Art. no. 105916, <https://doi.org/10.1016/j.isci.2022.105916>

Надійшла до редколегії 10.06.2025 р.

Красніков Влад Валерійович, старший .Net розробник, компанія Pricer24, м. Харків, Україна, e-mail: krasnikov.vlad.v@gmail.com

Ситнікова Поліна Едуардівна, кандидат технічних наук, доцент, доцент кафедри системотехніки ХНУРЕ, м. Харків, Україна, e-mail: polina.sytnikova@nure.ua, ORCID: <https://orcid.org/0000-0002-6688-4641>

УДК 004.8:004.9

DOI: 10.30837/0135-1710.2025.185.077

С.Ф. ЧАЛИЙ, Р. В. КРАВЧЕНКО

ГРАФОВА НЕЙРОННА МЕРЕЖА ДЛЯ ТЕМПОРАЛЬНО УПОРЯДКОВАНИХ ДАНИХ В ЗАДАЧІ ПОБУДОВИ ПОЯСНЕНЬ В ІНТЕЛЕКТУАЛЬНІЙ СИСТЕМІ

Об'єктом дослідження є процес побудови пояснень в інтелектуальних інформаційних системах. Предметом дослідження є моделі та методи формування пояснень в інтелектуальних інформаційних системах. Метою роботи є розробка підходу до побудови пояснень в інтелектуальних системах на основі графових нейронних мереж, які враховують темпоральний порядок у вхідних даних. Розроблено модель графової нейронної мережі для темпорально упорядкованих даних; виконано експериментальну перевірку графової мережі в задачі побудови пояснень для системи електронної комерції. Запропонована модель графової нейронної мережі включає функціональні блоки побудови векторних представлень, виявлення темпоральних патернів з використанням мережі LSTM, формування графа мережі для заданих темпоральних інтервалів, підготовки пояснень, прогнозування, генерації пояснень з використанням механізму уваги та результатів агрегації векторного представлення мережі.

1. Вступ

Інтелектуальні інформаційні системи (ІІС) використовують методи машинного навчання для того, щоб апроксимувати складні залежності в даних й використати отримані залежності для формування рішень. Проте внаслідок непрозорості таких процесів користувачі не завжди можуть зрозуміти логіку формування рішень в ІІС [1], [2]. Непрозорість процесу формування рішень призводить до зниження довіри до результатів роботи ІІС і, як наслідок, може привести до обмеження використання отриманих рішень користувачами [3].

Для вирішення проблеми зниження довіри до ІІС в галузі штучного інтелекту розвивається науковий напрямок пояснюваного штучного інтелекту (Explainable Artificial Intelligence – XAI) [4]. Напрямок XAI орієнтований на розробку моделей та методів, що забезпечують пояснення процесу та результатів роботи ІІС, забезпечуючи зрозумілість для

користувачів причин отриманих рішень [5]. Використання пояснень робить процес формування рішення інтерпретованим, що сприяє підвищенню довіри до ПС [6]. Пояснення зазвичай відображають вплив вхідних даних на рішення ПС [7]. Проте у випадках використання в ПС даних із темпоральною упорядкованістю необхідно при побудові пояснень враховувати складні причинно-наслідкові зв'язки та залежності між цими даними у часі [8]. Однак існуючі методи пояснюваного штучного інтелекту зазвичай не враховують темпоральну природу даних та темпоральні залежності між вхідними даними [7], що обмежує їхні можливості щодо побудови релевантних пояснень для ПС, які обробляють послідовності подій або станів [8]. Можливість обробки та аналізу складних залежностей в даних, які можуть бути представлені у формі графів, забезпечується з використанням графових нейронних мереж (GNN) [99]. Графова мережа забезпечує можливість аналізу складних залежностей та генерації на цій основі прогнозів й відповідних пояснень щодо процесу функціонування інтелектуальної системи [10], що створює умови для підвищення довіри користувачів до рішень ПС та розширення сфери практичного застосування цих рішень. Тому проблема побудови пояснень з використанням графової нейронної мережі для темпорально упорядкованих даних є актуальною.

2. Аналіз літературних даних і постановка проблеми дослідження

Дослідження у сфері теорії графових нейронних мереж інтенсивно розвиваються в останнє десятиріччя. Теоретичні основи графових нейронних мереж як засобу обробки даних із складними зв'язками, що представляють статичні й динамічні процеси, запропоновано в [11]. Переваги й обмеження GNN щодо представлення на розрізенні графів при кодуванні суттєвих властивостей графів розглянуто в [12].

Комбінована обробка темпоральних та просторових даних на прикладі задачі прогнозування дорожнього руху розглянута в [13] та [14]. При вирішенні даної задачі використовується спеціалізована архітектура темпоральної GNN, яка поєднує графову мережу та рекурентну нейронну мережу. Перша аналізує структуру дорожньої мережі, а друга враховує зміни трафіку з часом. В [15] представлено просторову-темпоральну мережу, в якій просторова складова обробляється з використанням традиційної GNN, а темпоральна – з використанням Long Short-Term Memory (LSTM). Використання механізму уваги для визначення ваги зв'язків між вершинами мережі розглянуто в [16]. Даний механізм дає можливість динамічно обраховувати важливість сусідніх вершин графу при виконанні процедури агрегації. Проте в цілому існуючі підходи до розробки GNN враховують окремі аспекти темпоральних властивостей даних і не забезпечують інтеграцію можливостей обробки змін у вхідних даних із змінами важливості цих даних, а також подальше пояснення виявлених темпоральних залежностей.

Для формування пояснень щодо темпоральних залежностей формуються каузальні правила на основі запропонованих в [18] та [19] поточних залежностей типу «Next» та довгострокових темпоральних залежностей типу «Future». Останнє з правил дає можливість виділити інтервали часу, для яких виявляються локальні закономірності. В [20] запропоновано модель казуальної залежності на основі темпоральної залежності, а в [21] – метод її побудови. В [22] в моделі каузальної залежності враховано альтернативні значення вхідних даних, що дає можливість побудувати пояснення для динамічних систем. Важливість таких залежностей базується на обчисленні частоти спільної появи значень змінних з урахуванням можливих альтернатив. Проте розроблені методи побудови пояснень для даних з темпоральними мітками орієнтовані на виділення локальних темпоральних патернів і не приділяють достатньо уваги формуванню концептуально-орієнтованих пояснень [23]. Останні можуть бути побудовані на основі моделювання ПС з використанням підходів, що лежать в основі темпоральних GNN, та фрагментації темпоральної упорядкованості даних на основі підходів [18] і [19], оскільки така

комбінація дає можливість враховати темпоральні патерни комплексних зв'язків між вхідними даними та результатом роботи ПС.

Таким чином, розробка нових підходів до побудови пояснень з використанням графової нейронної мережі для темпорально упорядкованих даних є актуальною задачею.

3. Мета і задачі дослідження

Метою даного дослідження є розробка підходу до побудови пояснень в інтелектуальних системах на основі графових нейронних мереж, які враховують темпоральний порядок у вхідних даних.

Для досягнення поставленої мети вирішуються такі задачі: розробка моделі графової нейронної мережі для темпорально упорядкованих даних; експериментальна перевірка графової мережі в задачі побудови пояснень для системи електронної комерції.

4. Графова нейронна мережа для обробки темпорально упорядкованих даних

Об'єктом даного дослідження є процес побудови пояснень в інтелектуальних інформаційних системах. Предметом дослідження є графові нейронні мережі, які формують пояснення на основі зв'язку між вхідними даними та отриманим рішенням ПС. Такий зв'язок відображає ступінь впливу значень вхідних даних на рішення ПС, обґрунтовуючи для користувача причини поточних характеристик сформованого рішення.

Головна ідея запропонованого підходу до побудови графової нейронної мережі полягає у циклічному формуванні графа мережі на визначених інтервалах часу на основі загальних правил навчання. Це дає можливість визначити поточні патерни для темпорально упорядкованих даних і на цій основі побудувати пояснення.

Блочну схему розробленої графової нейронної мережі представлено на рис. 1. Призначення кожного блоку мережі представлено в табл. 1.



Рис. 1. Блочна схема розробленої графової нейронної мережі

Таблиця 1

Призначення блоків графової нейронної мережі для обробки темпорально
упорядкованих даних

Блок	Призначення
1. Блок вхідних даних	Приймає упорядковані у часі вхідні дані
2. Блок побудови векторних представлень вхідних даних	Формує векторне представлення вхідних даних
3. Блок виявлення темпоральних патернів	Виділяє патерни, що відображають зв'язок між вхідними даними у часі; використовується мережа LSTM
4. Блок формування графа мережі	Формує граф мережі для заданого інтервалу часу; вершини графа відображають вхідні об'єкти, а дуги – різотипні залежності між цими об'єктами
5. Згорткові шари для інформації від сусідніх вершин	Реалізують механізм передачі повідомлень для оновлення представлення вершин з урахуванням інформації від вершин-сусідів
6. Механізм темпоральної уваги	Враховує темпоральні патерни як поточного, так і для сусідніх вузлів графової мережі
7. Блок агрегації	Формує єдине векторне представлення графової мережі на основі представлень її вершин
8. Блок підготовки пояснень	Розраховує вплив вхідних факторів (значень вхідних змінних) на прогнозне значення мережі
9. Блок прогнозування	Перетворює узагальнене представлення графа мережі у скаляр, що відображає прогноз роботи системи, яка моделюється мережею
10. Блок генерації пояснень	Використовує результати роботи механізму уваги та блоку підготовки пояснень для генерації пояснення щодо впливу значень вхідних даних на прогнозний результат

Блок вхідних даних приймає дані X з темпоральними мітками. Зазвичай такі дані відображають послідовність дій певного процесу. Наприклад, послідовність покупок у системі електронної комерції, послідовність станів процесу сервісного обслуговування тощо.

Блок побудови векторних представлень вхідних даних Emb формує багатовимірні векторні представлення для кожного екземпляру вхідних даних. Таке представлення кодує властивості вхідних даних. У процесі вбудовування може бути врахований контекст. Результативне векторне представлення відображає семантичні відношення між вхідними даними. Елементи відповідного вектору кодують, наприклад, такі властивості товару в системі електронної комерції, як ціна, популярність, категорія тощо. В даному блокі може бути використаний класичний алгоритм вбудовування на основі таблиці пошуку, яка містить код екземпляру та його векторне представлення. Даний підхід забезпечує зменшення часу обробки, оскільки оцінка складності є константною, тобто не залежить від кількості елементів у таблиці: доступ відбувається за індексом. Як альтернативу можна використати модель BERT, яка враховує контекст використання кожного елементу вхідних даних. Розмір отриманого у процесі вбудовування вектору залежить від предметної області задачі, для якої формується графова нейронна мережа. Наприклад, для пояснень у системі електронної комерції можуть бути використані вектори розміром до 100 вимірів, оскільки перелік товарів такої системи є достатньо обмеженим.

Блок виявлення темпоральних патернів $LSTM$ обробляє послідовність отриманих від попереднього блока векторів для виявлення патернів темпоральних залежностей. Даний блок використовує мережу LSTM яка є рекурентною нейронною мережею з можливостями

збереження суттєвої інформації в пам'яті. Дані мережа зберігає довгострокові патерни та адаптується до контексту, відкидаючи неактуальні залежності. Використання даної мережі дає можливість на основі даних з мітками часу отримати темпоральні патерни та використати їх для прогнозування майбутніх залежностей.

Такі патерни в подальшому служать основою для побудови пояснень у графовій нейронній мережі. Наприклад, патерн «Після початку продажів нової моделі смартфону з часом зростають продажі чохлів» дає можливість, з одного боку, прогнозувати ріст продажу чохлів для певної моделі, а з іншого боку – пояснити це збільшення продажів.

Блок формування графа мережі *B* будує граф на основі вхідних даних для визначеного інтервалу часу. Вершини графа відображають вхідні екземпляри (наприклад, товари в системі електронної комерції), а дуги – зв'язки між ними. Вершини можуть бути різних типів в залежності від категорії вхідних даних. Дуги моделюють різні типи зв'язків. Даний блок розраховує нормовані ваги дуг в залежності від частоти спільної появи елементів у вхідному наборі даних.

Згорткові шари для інформації від сусідніх вершин *GCN* призначенні для передачі повідомлень між вершинами графа. На основі цих повідомлень кожен вузол оновлює своє поточне представлення. Тобто при передачі повідомлень кожна вершина виконує зважене сумування своїх ознак та ознак сусідів. Такий підхід дає можливість кожній вершині оновити свої ознаки з урахуванням контексту, тобто локального фрагменту структури графа. У запропонованій моделі використано два шари. Перший шар аналізує зв'язки вершинам-сусідами. Другий шар аналізує зв'язки між трійками вершин. Наприклад, для системи електронної комерції перший шар може аналізувати зв'язок Ноутбук – Миша, а другий шар – зв'язок Ноутбук – Миша – Килимок для миші.

Механізм темпоральної уваги *ATT*, який враховує два типи темпоральних патернів: внутрішні та зовнішні. Вони відображають повтор певних змін у даних через проміжки часу. Внутрішні патерни враховують темпоральні залежності для однієї вершини графової нейронної мережі, наприклад, сезонні коливання продажів в системі електронної комерції. Зовнішні патерни враховують зміни у часі, пов'язані із декількома вузлами, наприклад, затримку продажів нових товарів у роздрібних торговців порівняно із оптовиками. Механізм уваги для кожного вузла графової мережі розраховує вагу уваги до вершин-сусідів та уваги поточної вершини до своєї історії, після чого комбінує отримані результати. Головна ідея механізму уваги полягає в тому, щоб врахувати з різною вагою релевантні для поточного прогнозування та пояснення темпоральні патерни.

Блок агрегації *Pool* інтегрує представлення всіх вершин графа у єдине векторне представлення всієї мережі. Для побудови такого представлення використовується середнє значення векторів для вузлів мережі. Можуть також бути використані максимальне, зважене значення, агрегація з увагою, коли ваги вершин визначаються у відповідності до релевантності цих вершин задачі, що вирішує мережа.

Блок підготовки пояснень *PExpl* перетворює внутрішнє векторне представлення мережі у числове представлення впливу вхідних факторів на прогноз. У випадку використання агрегованого представлення мережі розраховується вплив поточної комбінації значень вхідних даних на прогнозне значення мережі. Отримане значення відображає ступінь впливу. Наприклад, для системи електронної комерції може бути розраховано вплив на результат роботи системи комбінації поточних продажів товарів через різні канали в різних регіонах. Для подальшої деталізації блок підготовки пояснень використовує як вхідні дані внутрішнє представлення вершин мережі.

Блок прогнозування *Predictor* отримує векторне представлення графа мережі та

перетворює цей вектор у числове значення, що характеризує прогнозний показник роботи системи, яка моделюється графовою нейронною мережею. У даному шарі може бути використано лінійне перетворення, що дає можливість врахувати вагу кожного елементу вектору графу мережі. Наприклад, для торгівельної системи як прогноз виступає об'єм продажів для заданої номенклатури товарів, каналів та регіонів продажів.

Блок генерації пояснень *Expl* отримує значення (ваги) уваги для конкретних типів вхідних даних, а також для темпоральних патернів, що відображають зміни цих даних. На основі цих даних розраховується вплив ключових даних на прогнозний результат. У процесі розрахунку враховуються темпоральні закономірності, тобто тренди впливу вхідних даних на результат у часі. Отримані залежності представляються у текстовій формі. Тобто даний блок враховує суттєві компоненти вектору внутрішнього представлення мережі і узгоджує результат із ментальною моделлю користувача.

Таким чином, модель графової нейронної мережі для обробки темпорально упорядкованих даних забезпечує формування пояснення e для поточного прогнозу у через композицію блоків *Expl, Predictor, PExpl, Pool, ATT, GCN, B, LSTM, Emb*. Ця модель має такий формальний вигляд:

$$e|y = \text{Expl} \left(\text{Predictor} \wedge \text{PExpl} \left(\text{Pool} \left(\text{ATT} \left(\text{GCN} \left(\text{B} \left(\text{LSTM} \left(\text{Emb} \left(X \right) \right) \right) \right) \right) \right) \right) \right). \quad (1)$$

Граф, що формується блоком *B*, містить вузли, які зберігають інформацію про об'єкти, описані вхідними даними. Дуги відображають вплив вузлів. Наприклад, для системи електронної комерції вузли можуть містити інформацію про товари, категорії товарів, канали продажів тощо. Дуги відображають зв'язок між продажами товарів, залежності продажів категорій товарів від каналу, регіону тощо.

5. Експериментальна перевірка графової нейронної мережі в задачі побудови пояснень щодо продажів в системі електронної комерції

Експериментальну перевірку виконано з використанням фрагменту логу системи електронної комерції. Вхідний лог містить елементи, що відображають час кожної транзакції, а також інформацію про товари, що були продані в рамках цієї транзакції. Зокрема, лог містить інформацію про тип продукту (ноутбук, смартфон, планшет тощо), категорію продукту (електроніка, аксесуари тощо), канали продажів (веб-сайт, мобільний застосунок, маркетплейс), регіони продажів продукції (Київ, Львів, Одеса тощо), кількість та вартість проданої продукції. Фрагмент вхідних даних представлено в табл. 2.

Таблиця 2

Фрагмент вхідних даних із обчисленням зміни продажів

Дата	Вартість продукції	Зміни продажів
2025-03-24	7115,98	
2025-03-25	11949,45	1,67
2025-03-26	13637,02	1,14
2025-03-27	6733,06	0,49
2025-03-28	9336,34	1,39
2025-03-29	8401,17	0,90
2025-03-30	52336,09	0,63

Сформовано граф, який структурує продажі за тиждень. Граф містить 14 вершин та 18 дуг. Вершини розподілені за категоріями: продукти (6), класи товарів (2), канали продажів (3), регіони (3). Кожна дуга представляє зв'язок між продуктами, класами,

каналами продажів та регіонами. Дуга має вагу, яка відображає силу кожного із зв'язків. Наприклад, сила зв'язку Ноутбук – Миша становить 0,83, оскільки це комплементарні товари. Сила зв'язку Ноутбук – Клавіатура становить 0,72 оскільки додаткову клавіатуру часто купують з ноутбуком. Сила зв'язку, що визначає належність до категорій, становить 1,0. Наприклад, всі електронні пристрої мають вагу 1,0 зв'язку з категорією «Електроніка».

Модель генерує пояснення через механізм уваги та аналіз внеску кожного вузла. Пояснення відображає вплив змін у вхідних даних на результативну продажі. Наприклад, пояснення щодо зростання продажів від 25 березня має формальний вигляд:

$$\begin{aligned} \text{Категорія(електроніка(+0,43))} \wedge \text{Канал(мобільні_застосунки(+0,54))} \Rightarrow \\ \text{Продажі(+0,67)} | \text{Дата} = 25.03.2025. \end{aligned} \quad (2)$$

Тобто зростання продажів 25 березня на 67 % порівняно з 24 березня відбулося внаслідок збільшення активності в категорії Електроніка (+45 %) та зростання продажів через канал мобільних застосунків (+32 %).

Аналогічно, зниження продажів 26 березня обґрунтовується таким поясненням:

$$\begin{aligned} \text{Категорія(аксесуари(-0,59))} \wedge \text{Канал(веб\textendashсайт(-0,42))} \Rightarrow \\ \text{Продажі(-0,51)} | \text{Дата} = 27.03.2025. \end{aligned} \quad (3)$$

Тобто зниження продажів обумовлено спадом попиту на аксесуари та зниженням віддачі від веб-сайту.

6. Обговорення результатів

Розроблена графова нейронна мережа на основі вхідних даних із мітками часу буде графове представлення системи, яка описана вхідними даними. На основі отриманого графового представлення мережа формує прогнозний результат роботи системи, що моделюється, а також пояснення до даного прогнозу. Система відрізняється від існуючих моделей використанням блоків підготовки та формування пояснення, що дає можливість обґрунтувати отримане рішення на основі його залежності від значень вхідних даних.

Розроблена модель відрізняється від існуючих виділенням часових інтервалів, для яких на основі загальних правил будується граф мережі. Такий темпоральний підхід дає можливість отримувати відмінні патерни на різних інтервалах часу та порівнювати ці патерни. Крім того, розроблена мережа в рамках механізму уваги комбінує темпоральні патерни для однієї вершини графа та спільні патерни для декількох вершин.

Результати експериментальної перевірки показали, що отримані в графовій нейронній мережі пояснення враховують як зважені властивості вхідних об'єктів, так і зміну значень цих властивостей з часом.

Ключове обмеження даної моделі пов'язане із кількістю категорій (класів) вхідних даних, які відображаються як вершини графа. При збільшенні кількості класів даних ускладнюється механізм уваги, що приводить до підвищення обчислювальних витрат.

Подальші дослідження у даному напрямку орієнтовані на використання контекстної векторизації та формування пояснень зі змінною деталізацією на основі векторного представлення вершин графу та механізму уваги.

7. Висновки

Розроблено модель графової нейронної мережі для темпорально упорядкованих даних в задачі побудови пояснень в інтелектуальній системі. Модель містить блоки побудови векторних представлень вхідних даних, виявлення темпоральних патернів, формування графа мережі, прогнозування, підготовки та формування пояснень на основі агрегації представлення мережі та використання механізму уваги. Модель відрізняється від моделей

існуючих темпоральних графових нейронних мереж інтеграцією модулів підготовки та формування пояснення, а також врахуванням темпоральних патернів для однієї та декількох вершин графа мережі. Модель дає можливість сформувати пояснення на основі числової оцінки впливу на прогнозний результат ключових факторів, представлених упорядкованими у часі значеннями вхідних даних, з урахування змін цих даних з часом.

Експериментальна перевірка розробленої графової нейронної мережі в задачі побудови пояснень щодо продажів в системі електронної комерції показала можливості формування пояснення на основі визначення впливу змін у продажах окремих категорій товарів через окремі канали розповсюдження на загальний показник роботи системи.

Перелік посилань:

1. Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "Why should I trust you?" Explaining the predictions of any classifier. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 1135-1144).
2. Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on Explainable Artificial Intelligence (XAI). IEEE Access, 6, 52138-52160. <https://doi.org/10.1109/ACCESS.2018.2870052>.
3. Чалий, С. Ф., & Лещинська, І. О. (2024). Принципи побудови ментальних моделей рішення для зовнішнього користувача в задачі формування пояснень в інтелектуальній системі. АСУ і прилади автоматики, 181, 17-25.
4. Gunning, D., & Aha, D. W. (2019). DARPA's Explainable Artificial Intelligence (XAI) program: A retrospective. AI Magazine, 40(2), 44-58. <https://doi.org/10.1609/aimag.v40i2.2850>.
5. Miller, T. (2019). Explanation in artificial intelligence: Insights from the social sciences. Artificial Intelligence, 267, 1-38.
6. Чалий, С., & Лещинська, І. (2023). Концептуальна ментальна модель пояснення в системі штучного інтелекту. Вісник Національного технічного університету «ХПІ». Серія: Системний аналіз, управління та інформаційні технології, 1 (9), 70–75. <https://doi.org/10.20998/2079-0023.2023.01.11>
7. Arrieta, A. B., Díez-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ... & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. Information Fusion, 58, 82-115.
8. Чалий, С., Лещинський, В., & Лещинська, І. (2022). Каузальна модель процесу побудови пояснень в інформаційній системі. Системи управління, навігації та зв'язку, 3(69), 99-103. <https://doi.org/10.26906/SUNZ.2022.3.099>.
9. Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., & Philip, S. Y. (2020). A comprehensive survey on graph neural networks. IEEE Transactions on Neural Networks and Learning Systems, 32(1), 4-24.
10. Zheng, C., Fan, X., Wang, C., & Qi, J. (2020). GMAN: A graph multi-attention network for traffic prediction. In Proceedings of the AAAI Conference on Artificial Intelligence, 34 (01), 1234-1241.
11. Battaglia, P. W., Hamrick, J. B., Bapst, V., Sanchez-Gonzalez, A., Zambaldi, V., Malinowski, M., ... & Pascanu, R. (2018). Relational inductive biases, deep learning, and graph networks. arXiv preprint arXiv:1806.01261.
12. Xu, K., Hu, W., Leskovec, J., & Jegelka, S. (2018). How powerful are graph neural networks? arXiv preprint arXiv:1810.00826.
13. Zhao, L., Song, Y., Zhang, C., Liu, Y., Wang, P., Lin, T., ... & Li, H. (2019). T-gcn: A temporal graph convolutional network for traffic prediction. IEEE Transactions on Intelligent Transportation Systems, 21(9), 3848-3858.
14. Jin, G., Liang, Y., Fang, Y., Huang, J., Zhang, J., & Zheng, Y. (2023). Spatio-temporal graph neural networks for predictive learning in urban computing: A survey. IEEE Transactions on Knowledge and Data Engineering, 35(8), 8075-8095.
15. Li, Y., Yu, R., Shahabi, C., & Liu, Y. (2017). Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. arXiv preprint arXiv:1707.01926.
16. Veličković, P., Cucurull, G., Casanova, A., Romero, A., Lio, P., & Bengio, Y. (2017). Graph attention networks. arXiv preprint arXiv:1710.10903.
17. Чала, О. В., «Моделі, методи та інформаційні технології автоматизованого управління темпоральними базами знань для підтримки управлінських рішень», дис. докт. техн. наук, Харків. нац. ун-т радіоелектроніки, Харків, 2021. [Електронний ресурс]. Режим доступу: https://nure.ua/wp-content/uploads/2021/Disertation/robota_chaloj_ov.pdf. Дата звернення: 20.05.2025.
18. Чала, О. В. (2018). Принципи автоматизованої побудови та використання темпоральної бази знань для підтримки прийняття рішень з управління підприємством. Системи управління, навігації та зв'язку, 6, 122-128.

<https://doi.org/10.26906/SUNZ.2018.6.122>

19. Chalyi, S., & Leshchynskyi, V. (2022). Temporal-oriented model of causal relationship for constructing explanations for decision-making process. *Advanced Information Systems*, 6(3), 60–65. <https://doi.org/10.20998/2522-9052.2022.3.09>
20. Чалий С. Ф., Лещинський В. О. (2024). Темпорально-каузальні методи побудови пояснень в системах штучного інтелекту. *АСУ та прилади автоматики*, 181, 91-99. <https://doi.org/10.30837/0135-1710.2024.181.091>.
21. Чалий С. Ф., Лещинський В. О., Лещинська І. О. (2021). Контрфактуальна темпоральна модель причинно-наслідкових зв'язків для побудови пояснень в інтелектуальних системах. *Вісник Національного технічного університету «ХПІ»*. Сер. : Системний аналіз, управління та інформаційні технології: зб. наук. пр. Харків : НТУ «ХПІ», 2 (6), 41-46. <https://doi.org/10.20998/2079-0023.2021.02.07>.
22. Guidotti, R., Monreale, A., Ruggieri, S., Turini, F., Giannotti, F., & Pedreschi, D. (2018). A survey of methods for explaining black box models. *ACM Computing Surveys*, 51(5), 1-42.

Надійшла до редколегії 25.05.2025 р.

Чалий Сергій Федорович, доктор технічних наук, професор, професор кафедри ІУС ХНУРЕ, м. Харків, Україна, e-mail: serhii.chalyi@nure.ua; ORCID: <https://orcid.org/0000-0002-9982-9091>

Кравченко Ростислав Вікторович, аспірант кафедри ІУС ХНУРЕ, м. Харків, Україна, e-mail: rostyslav.kravchenko1@nure.ua; ORCID: <https://orcid.org/0009-0009-0324-3597>