

**С. Ф. ЧАЛИЙ**, доктор технічних наук, професор, Харківський національний університет радіоелектроніки, професор кафедри інформаційних управляючих систем, м. Харків, Україна; e mail: serhii.chaliy@nure.ua, ORCID: <https://orcid.org/0000-0002-9982-9091>

**Р. В. КРАВЧЕНКО**, Харківський національний університет радіоелектроніки, аспірант кафедри інформаційних управляючих систем, м. Харків, Україна; e mail: rostyslav.kravchenko1@nure.ua, ORCID: <https://orcid.org/0009-0009-0324-3597>

## МЕТОД АДАПТИВНОГО ВИБОРУ ІНТЕРВАЛІВ ЧАСУ ДЛЯ ПОБУДОВИ ГРАФІВ ТЕМПОРАЛЬНИХ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ

Предметом дослідження є процес формування графових структур для темпоральних графових нейронних мереж з адаптивним вибором рівня деталізації часових інтервалів. Мета роботи полягає у розробці підходу до формування графових структур з адаптивною деталізацією для темпоральних графових нейронних мереж. Задачі дослідження включають: структурування підходів до вибору рівня деталізації часових інтервалів при формуванні графів темпоральних графових нейронних мереж з урахуванням змін структури цих графів; розробку методу адаптивного вибору інтервалів часу на основі метрик редагування графів і спектрального аналізу структури графа. Розроблений метод включає п'ять етапів: формування графа на основі частоти спільної появи сутностей; обчислення швидкості редагування між послідовними графами; спектральне вбудовування графів через нормалізований симетричний Лапласіан; розрахунок дивергенції Кульбака – Лейблера між спектральними щільностями для виявлення структурного дрейфу; адаптивне коригування тривалості часового інтервалу з урахуванням критеріїв швидкості редагування та величини дивергенції. Метод комбінує локальну метрику редагування графа та глобальні метрики спектральної щільності, дивергенції Кульбака – Лейблера для виявлення не лише кількості змін у графі, а й їхнього впливу на топологію графа. Це дозволяє відділити шум від суттєвих змін структури графу. Метод забезпечує автоматизований вибір деталізації часу без використання експертних знань про пороги значення щодо зміни структури графу; зниження обчислювальних витрат на формування графів у періоди стабільності структури; задану точність виявлення часових залежностей у періоди різких змін структури графа. Практична значущість отриманих результатів полягає у можливості представлення та подальшого аналізу динамічних процесів у інтелектуальних системах, які оперативно адаптуються до змін у структурі взаємозв'язків, для задач побудови пояснень, рекомендацій, моніторингу, аналізу та прогнозування в системах електронної комерції, соціальних мережах, фінансовому аналізі, транспортному моніторингу.

**Ключові слова:** темпоральні графи, адаптивна деталізація часу, спектральний аналіз, структурний дрейф, динамічні графи, графові нейронні мережі, власні значення Лапласіана, темпоральні залежності.

**Вступ.** Темпоральні графові нейронні мережі моделюють об'єкти і процеси як у просторі, так і у часі, використовуючи послідовність графів, що описують зв'язки між сутностями предметної області на визначених інтервалах часу [1], [2]. Завдяки такій властивості вони знаходять широке застосування в інтелектуальних системах підтримки прийняття рішень для аналізу змінних взаємозв'язків між сутностями, включаючи прогнозування продажів в системах електронної комерції, виявлення аномалій у фінансових транзакціях, зміни зв'язків у соціальних мережах, при побудові пояснень тощо [3]. Формування графових структур при вирішенні цих задач виконується циклічно і передбачає розбиття періоду часу, що аналізується, на послідовність інтервалів та подальшу побудову окремого графа для кожного з виділених інтервалів. Така циклічна побудова дає можливість оперативно адаптувати граф до змін у структурі взаємозв'язків між сутностями предметної області, що є актуальним у рекомендаційних системах, системах моніторингу, інформаційних управляючих системах, при побудові темпоральних баз знань тощо [4]. Багаторазове формування графів для темпоральної графової нейронної мережі орієнтовано на досягнення заданого рівня точності виявлення часових залежностей при обмеженнях на обчислювальні ресурси. Вимоги до обчислювальних ресурсів пов'язані із кількістю графів, що формуються на заданому часовому проміжку. Формування графів для нейронної мережі зазвичай виконується на основі фіксованої

деталізації часового інтервалу для даних, що використовуються при побудові цих графів. Такий підхід призводить до надмірних обчислювальних витрат у періоди, коли граф має незмінну структуру, або недостатньої деталізації у періоди різких змін структури (структурного дрейфу). Тому реалізація багаторазового формування графу в умовах динамічних змін його структури потребує додаткового вирішення задачі виявлення структурного дрейфу й уточнення деталізації часу відповідно до швидкості зміни структури графу. Остання може бути визначена з використанням метрики відстані редагування. Адаптація деталізації часу дозволяє знизити обчислювальні витрати при збереженні точності виявлення темпоральних залежностей за умов складного розподілу структурних змін у часі.

Таким чином, задача формування графів для графових нейронних мереж потребує розробки підходу до адаптивної деталізації темпоральних інтервалів з урахуванням зміни у даних з часом, що свідчить про актуальність теми даного дослідження.

### Аналіз останніх досліджень і публікацій.

Методи глибокого навчання на динамічних графах, розроблені у [1], призначені для ефективного моделювання темпоральних залежностей, що дає можливість оперативно реагувати на зміни у структурі взаємозв'язків між сутностями.

Основи графових нейронних мереж (ГНН) представлені у [2], де проаналізовано архітектури ГНН для

© Чалий С.Ф., Кравченко Р.В., 2025



**Дослідницька стаття:** Цю статтю опубліковано видавництвом *НТУ «ХПІ»* у збірнику «Вісник Національного технічного університету "ХПІ" Серія: Системний аналіз, управління та інформаційні технології». Ця стаття поширюється за міжнародною ліцензією [Creative Commons Attribution \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/). **Конфлікт інтересів:** Автор/и заявив/или про відсутність конфлікту.



графів різних типів. На основі цього аналізу розроблено евристичні та адаптивні підходи до формування графів для темпоральних мереж [5, 6]. Динамічні графи, що еволюціонують з часом, потребують адаптивного підходу до деталізації часу, оскільки використання фіксованих інтервалів часу призводить до надмірних обчислювальних витрат у періоди незмінності вхідних даних та недостатньої точності у періоди різких змін цих даних [7]. Методи порівняння графів з використанням відстані редагування використовуються для оцінки структурних змін [8]. Формування графів для темпоральних графових нейронних мереж потребує врахування концепції постійної зміни графової структури, тобто структурного дрейфу. Огляд методів адаптації до дрейфу, в тому числі з використанням індуктивного навчання, представлено в роботах [9], [10].

Проте при адаптації структури графів потрібно враховувати обчислювальну складність методів аналізу даних [11]. Виявлення структурного дрейфу у графах базується на використанні методів спектрального аналізу [12], [13]. Для моделювання залежностей між вершинами та їх змін з часом з високою точністю використовується механізм уваги [14]. Можливості представлення темпоральних знань з урахуванням порядку подій у часі представлено у [4], [15]. Таке представлення у поєднанні з графовими нейронними мережами дає можливість побудувати моделі процесів обробки даних на основі записів у журналах подій. Можливості використання темпоральних знань для побудови пояснень представлено у [3], [16], [17]. Поєднання графових нейронних мереж із запропонованими в цих роботах методами забезпечить інтеграцію темпорального й каузального аспектів пояснення.

Актуальний підхід до досліджень щодо побудови графів для темпоральних графових нейронних мереж пов'язаний аналізом власних значень матриці Лапласіана для знаходження моментів часу, коли відбулись суттєві зміни у структурі графа [18]. Даний підхід демонструє високу чутливість до структурного дрейфу та відділяє шуми у даних.

Таким чином, сучасні підходи до формування графових структур для темпоральних ГНН використовують відстань редагування або спектральний аналіз для виявлення структурного дрейфу і подальшої адаптації графу на новому інтервалі часу. Проте розробці підходу, який би виконував комплексний вибір інтервалу часу для побудови адаптованого графа не приділяється достатньо уваги. Проте такий підхід дає можливість врахувати актуальні зміни у вхідних даних ГНН, знизити обчислювальні витрати для незмінних даних та оперативно врахувати дані, що змінюються з часом.

#### **Мета та задачі дослідження.**

Метою роботи є розробка підходу до формування графових структур з адаптивною деталізацією для темпоральних графових нейронних мереж.

Використання адаптивної деталізації створює умови для зниження обчислювальних витрат на побудову ГНН при збереженні точності опису темпоральних залежностей за умов структурного дрейфу.

Для досягнення мети дослідження вирішуються задачі: структуризація підходів до вибору рівня деталізації інтервалів часу при формуванні графів темпоральних графових нейронних мереж з урахуванням змін їх структури з часом; розробка методу адаптивного вибору інтервалів часу для побудови графів темпоральних графових нейронних мереж.

#### **Структуризація підходів до деталізації часу при формуванні графів темпоральних графових нейронних мереж.**

Даний підрозділ присвячено обґрунтуванню вибору підходу до побудови графових нейронних мереж зі змінною деталізацією часу з урахуванням темпоральних змін їх структури. Запропонована структуризація підходів до формування графів базується на порівнянні можливостей побудови графових мереж з використанням фіксованих інтервалів часу, евристичних правил динамічного вибору деталізації часу та адаптивного підходу на основі швидкості редагування графа.

Перший підхід передбачає розбиття періоду часу, для якого виконується аналіз, на однакові інтервали. Для кожного інтервалу формується окремий граф. Такий підхід забезпечує незалежність отриманих графів від історії змін вхідних даних, є простим в реалізації та створює умови для паралельної обробки інтервалів часу. Обчислювальні витрати в даному випадку не залежать від властивостей вхідних даних.

Однак даний підхід не враховує динаміку вхідних даних. Тому формується надлишкова кількість графів для інтервалів часу, коли вхідні дані не змінюються. Альтернативно, можуть бути пропущені важливі структурні зміни графу у періоди структурного дрейфу. Відповідно, підхід з фіксованими інтервалами часу приводить до надлишкових обчислювальних витрат у періоди, коли структура графа змінюється повільно, та до пропусків в обробці даних у періоди різких змін графу внаслідок структурного дрейфу.

Другий підхід використовує евристичні правила «якщо – то» для вибору рівня деталізації часу [6]. Ці правила базуються на експертних знаннях щодо порогових значень змін у структурі графу. В рамках даного підходу послідовно виконується моніторинг структурних змін графу та подальше уточнення довжини темпоральних інтервалів. На етапі моніторингу виконується порівняння структури поточного та попереднього графів та оцінка змін структури графа з урахуванням відмінностей щодо кількості дуг, середньої ваги дуг та кількості вершин. На етапі уточнення інтервалів часу виконується порівняння отриманих оцінок змін у графі із експертно визначеними порогоми, після чого деталізація інтервалів часу змінюється.

Помилкові спрацювання правил адаптації внаслідок шуму у даних усуваються шляхом використання ковзного середнього для декількох інтервалів щодо отриманих на етапі моніторингу оцінок зміни структури. Проте евристичні правила базуються на ретроспективному аналізі попередніх інтервалів, що обмежує повноцінне застосування даного підходу при виникненні структурного дрейфу.

Запропонований адаптивний підхід до побудови темпоральних інтервалів на основі визначення швидко-

сті редагування графа зі спектральним вбудовуванням використовує порівняння графів з використанням відстані Левенштейна, запропоноване в [14]. При реалізації даного методу замість традиційного порівняння відстані редагування графів виконується перетворення графів у рядки з подальшим застосуванням відстані редагування для рядків (відстані Левенштейна). Відстані редагування графів та рядків визначаються як мінімальна кількість операцій редагування з перетворення одного графа (відповідно, одного рядка) в інший. Тобто дана відстань відображає кількісну оцінку відмінностей між двома графами або двома рядками. Удосконалення методу виконується на основі результатів дослідження [18], в яких запропоновано виявляти моменти суттєвих змін структури графу за допомогою власних значень матриці Лапласіана графа. Останні є фундаментальними характеристиками графа, які відображають його геометричні й топологічні властивості. Наприклад, для графа соціальної мережі ці значення можуть відображати швидкість поширення інформації між вузлами мережі, для графа електромережі – сумарну електричну провідність між кластерами мережі. Тобто власні значення матриці Лапласіана відображають такі характеристики графа, як кількість зв'язних компонент, зв'язність, наявність вузьких місць тощо.

#### Метод адаптивного вибору інтервалів часу для побудови графів для темпоральних графових нейронних мереж.

На основі розглянутого адаптивного підходу розроблено метод побудови темпоральних інтервалів. Метод включає наступні етапи.

Етап 1. Формування графу  $G_t = (V_t, E_t, W_t)$ , що містить вершини  $V_t$ , дуги  $E_t$  та ваги дуг  $W_t$  для інтервалу  $I_t = [t_i, t_{i+1}]$  на основі частоти спільної появи опису сутностей у вхідних даних.

Сутності у вхідних даних відображають об'єкти предметної області, з якими оперує інтелектуальна система, наприклад, товари в системі електронної комерції, користувачі в соціальній мережі тощо. При реалізації даного етапу розглядаються сутності, що фіксуються у вхідних даних на інтервалі часу  $I_t$ . Умовою спільної появи сутностей  $a$  та  $b$  є їх одночасна присутність у межах однієї транзакції. Наприклад, якщо покупка товарів  $a$  та  $b$  зафіксована в одному чеку. Частота спільної появи  $fr(a, b, I_t)$  обчислюється як кількість транзакцій з обома сутностями  $a$  та  $b$  на інтервалі  $I_t$ .

Вершини  $V_t$  графа  $G_t$  містять унікальні сутності із вхідних даних на інтервалі  $I_t$ . Дуги  $E_t$  графа зв'язують вершини, для яких  $fr(a, b, I_t)$  перевищує мінімальний поріг  $\omega$ . Наприклад, значення порогу  $\omega = 2$  означає, що дуга додається лише в тому випадку, якщо обидві представлені вершинами графу сутності з'являються спільно щонайменше у двох транзакціях. Вага  $w_{i,k}^{a,b}$   $k$  – дуги в матриці ваг  $W_t$  визначається через нормалізовану частоту спільної появи відповідних сутностей  $(a_k, b_k)$  для цієї дуги на інтервалі  $I_t$ :

$$w_{i,k}^{a,b} = \frac{fr(a_k, b_k, I_t)}{\sum_k fr(a_k, b_k, I_t)}. \quad (1)$$

Згідно (1), сила зв'язку між сутностями визначається частотою їх спільної появи у даних.

Етап 2. Обчислення швидкості редагування на інтервалі  $I_t$  для графу  $G_t$  поточного інтервалу  $I_t$  і графу  $G_{t-1}$  з попереднього інтервалу  $I_{t-1}$ .

Швидкість редагування  $GV_t$  обчислюється як відношення відстані редагування  $GE_t(G_t, G_{t-1})$  між графами  $G_t$  та  $G_{t-1}$  до найбільшої кількості вершин графа  $\max(|V_t|, |V_{t-1}|)$ :

$$GV_t = \frac{GE_t(G_t, G_{t-1})}{\max(|V_t|, |V_{t-1}|)}. \quad (2)$$

Відстань редагування  $GE_t(G_t, G_{t-1})$  визначається як мінімальна кількість операцій редагування, необхідних для перетворення першого графа у другий. Ці операції включають: додавання, видалення й заміну вершин, а також додавання, видалення й редагування дуг. Заміна вершини передбачає заміну атрибутів сутності. Редагування дуг включає зміну ваг. Значення  $\max(|V_t|, |V_{t-1}|)$  використовується для нормалізації, що дає можливість порівнювати графи з різною кількістю вершин.

Проте слід зазначити, що висока швидкість редагування у виразі (2) не завжди відображає суттєві структурні зміни графа. Так, велика кількість локальних змін, наприклад, пов'язаних із додаванням дуг між існуючими вершинами, може не впливати суттєво на глобальну топологію графа. Альтернативно, мала кількість суттєвих змін, наприклад додавання лише однієї дуги, що зв'язує два раніше ізольовані кластери, може призводити до суттєвої реорганізації структури графа. Для вирішення цієї проблеми на подальших етапах використовується спектральний аналіз структури графа. Спектральний аналіз дає можливість виділити глобальні структурні характеристики графа та виявити структурний дрейф шляхом порівняння спектральних щільностей графів для двох послідовних інтервалів часу.

Етап 3. Спектральне вбудовування графів  $G_t$  та  $G_{t-1}$ .

Вбудовування виконується традиційно, шляхом обчислення власних значень нормалізованого симетричного Лапласіана:

$$L = I - D_t^{-1/2} A_t D_t^{-1/2}, \quad (3)$$

де  $A_t$  – матриця суміжності графа;  $D_t$  – діагональна матриця ступенів вершин;  $I$  – одинична матриця розміру  $|V_t|$ .

Матриця суміжності відображає топологічну структуру графа. Ненульові елементи матриці вказують на наявність ребер між вершинами графа. Значення (ваги) цих елементів відображають силу зв'язків.

Діагональна матриця ступенів містить на головній діагоналі суми ваг дуг, інцидентних кожній вершині графа. Тобто ця матриця відображає «популярність» вершини у графі. Високий ступінь вершини означає, що сутність має багато зв'язків з іншими сутностями (наприклад, певний товар достатньо часто продається разом з іншими товарами). Нормалізація через  $D_i^{-1/2}$  знижує вплив зв'язків між вершинами з високими ступенями на спектр порівняно з незваженим Лапласіаном і тому використовується для графів, де розмір та розподіл ступенів можуть змінюватися у часі. Без нормалізації спектральні характеристики графа будуть залежати не лише від його структури, а й від абсолютних значень ступенів, що не дає можливість порівняти графи для різних інтервалів часу.

Спектральне розкладання нормалізованого Лапласіана дає набір власних значень  $\lambda_k$  та відповідних власних векторів, які кодуєть структуру графа, наприклад відображають зв'язність графа, наявність «вузьких місць» у його структурі. Тому спектр Лапласіана можна використати для виявлення структурних змін між графами  $G_{i-1}$  та  $G_i$ . Зміни у розподілі власних значень свідчать про реорганізацію топології графа, наприклад про появу нових кластерів, зміну зв'язності для існуючих кластерів, зміни у структурі.

Етап 4. Розрахунок дивергенції Кульбака – Лейблера  $KL(P \parallel Q)$  між спектральною щільністю поточного графа  $G_i$  та попереднього графа  $G_{i-1}$ .

Спектральна щільність інваріантна щодо перестановки вершин графа, тобто не залежить від способу нумерації вершин. Тому дана характеристика може бути використана для порівняння графів  $G_i$  та  $G_{i-1}$  без визначення відповідності між їх вершинами. Розподіл спектральної щільності містить інформацію про структурні властивості графа – високу зв'язність, кластерну структуру тощо. Зміщення або поява нових піків щільності свідчать про трансформацію структури графа. Значення дивергенції Кульбака – Лейблера дає можливість порівняти поточний та очікуваний розподіл спектральної щільності. Суттєві відмінності між поточною та очікуваною щільностями свідчать про суттєві зміни в структурі графа. У випадку стабільної структури графа дивергенція Кульбака – Лейблера є нульовою.

Етап 5. Уточнення інтервалу часу для формування графу темпоральної графової нейронної мережі.

У випадку зменшення швидкості редагування  $GV_i$  та зменшення дивергенції інтервал  $\Delta t_{i+1}$  збільшується у два рази за умови не перевищення максимального можливої протяжності інтервалу  $\Delta t_{\max}$ :

$$\Delta t_{i+1} = \min(2|t_{i+1} - t_i|, \Delta t_{\max}). \quad (4)$$

Якщо збільшується швидкість редагування або збільшується дивергенція, то відбувається зменшення інтервалу в 2 рази за умови, що ще не досягнуто мінімальне значення довжини інтервалу  $\Delta t_{\min}$ :

$$\Delta t_{i+1} = \min(0,5|t_{i+1} - t_i|, \Delta t_{\min}). \quad (5)$$

Наприклад, в сфері електронної комерції деталізація інтервалів дає можливість відображати детальні зміни в структурі графа при проведенні рекламних акцій, під час свят, продажів нових категорій товарів.

**Реалізація метода формування графових структур з адаптивною деталізацією.**

Розглянемо приклад реалізації метода для системи електронної комерції. Фрагмент вхідних даних наведено в табл. 1.

Таблиця 1 – Фрагмент вхідних даних

| ID транзакції | Дата  | Товари (сутності)            |
|---------------|-------|------------------------------|
| T1            | 15.03 | Ноутбук, Миша, Клавіатура    |
| T2            | 16.03 | Ноутбук, SSD-диск            |
| T3            | 17.03 | Миша, Килимок для миші       |
| T4            | 18.03 | Ноутбук, Миша, SSD-диск, RAM |
| T5            | 19.03 | Клавіатура, Килимок для миші |
| T6            | 20.03 | Ноутбук, RAM                 |

Ця таблиця містить такий набір сутностей (вершин графа): {Ноутбук, Миша, Клавіатура, SSD-диск, RAM, Килимок для миші}. Аналіз транзакцій показує, що сутності Ноутбук та Миша з'являються разом у двох транзакціях (T1, T4). Тому за умов одиничного порогового значення граф включає 10 дуг:

$$E_i = \left\{ \begin{array}{l} (\text{Ноутбук, Миша}), \\ (\text{Ноутбук, Клавіатура}), \\ (\text{Ноутбук, SSD}), (\text{Ноутбук, RAM}), \\ (\text{Миша, Клавіатура}), (\text{Миша, SSD}), \\ (\text{Миша, RAM}), (\text{Миша, Килимок}), \\ (\text{Клавіатура, Килимок}), (\text{SSD, RAM}). \end{array} \right\}. \quad (6)$$

Результуючий граф має 6 вершин та 10 дуг.

Загальна кількість спільних появ сутностей становить 14. Вагові коефіцієнти мають наступні значення:

$$w_{i,k}^{\text{Ноутбук, Миша}} = \frac{2}{14} = 0,143, \quad w_{i,k}^{\text{Ноутбук, SSD}} = \frac{2}{14} = 0,143, \\ w_{i,k}^{\text{Клавіатура, Килимок}} = \frac{1}{14} = 0,071.$$

Граф за минулий тиждень має наступні вершини:

$$V_{i-1} = \left\{ \begin{array}{l} \text{Ноутбук, Миша, Клавіатура,} \\ \text{SSD, RAM.} \end{array} \right\}. \quad (7)$$

Дуги графа  $E_{i-1}$  мають вигляд:

$$E_{i-1} = \left\{ \begin{array}{l} \{(\text{Ноутбук, Миша}), \\ (\text{Ноутбук, SSD}), (\text{Ноутбук, RAM}), \\ (\text{Миша, Клавіатура}), (\text{SSD, RAM}). \end{array} \right\}. \quad (8)$$

Відповідно, для переходу від графа  $G_{i-1}$  до графа  $G_i$  необхідно додати вершину Килимок та 5 дуг:

$$\begin{array}{l} (\text{Ноутбук, Клавіатура}), (\text{Миша, SSD}), (\text{Миша, RAM}), \\ (\text{Миша, Килимок}), (\text{Клавіатура, Килимок}), \end{array}$$

тобто  $GE_l(G_l, G_{l-1}) = 6$ .

Оскільки  $\max(|V_l|, |V_{l-1}|) = 6$ , то без урахування вартості операцій редагування графа  $GV_l = 1$ . Запропонований метод дає можливість врахувати вагу дуг та вершин при розрахунку  $GE_l$ . З урахуванням ваг вершин та дуг для системи електронної комерції  $GE_l(G_l, G_{l-1}) = 3, 6$ ,  $GV_l = 0, 6$ .

Результатами етапу 3 є власні значення для  $G_l$ :  $\lambda_1 = 0$  (зв'язний граф),  $\lambda_2 = 0, 39$  (ступінь зв'язності),  $\lambda_3 = 1, 27$ ,  $\lambda_4 = 1, 85$ . Для графу  $G_{l-1}$  на попередньому інтервалі отримано такі значення:  $\lambda_1 = 0$ ,  $\lambda_2 = 0, 52$ ,  $\lambda_3 = 1, 15$ ,  $\lambda_4 = 1, 83$ .

Зменшення  $\lambda_2$  означає зменшення зв'язності графу, зазвичай внаслідок появи нових груп товарів, а зростання  $\lambda_3$  – збільшення кластерів товарів.

За результатами етапу 4  $KL(P||Q)$  становить 0,45, що свідчить про значний структурний дрейф і необхідність зменшити інтервал часу згідно (5).

### Висновки.

Виконано структурування підходів до рівня деталізації часу при формуванні графів темпоральних графових нейронних мереж. Обґрунтовано використання адаптивного підходу на основі аналізу швидкості редагування графів та спектральне вбудовування.

Запропоновано метод вибору інтервалу часу для побудови графів графових нейронних мереж. Метод містить етапи початкового формування графів з базовою деталізацією, обчислення швидкості редагування графа між послідовними у часі графами, виявлення структурного дрейфу через спектральне вбудовування та автоматичної адаптації інтервалу часу в залежності від швидкості змін структури графу.

У практичному аспекті розроблений метод дає можливість знизити обчислювальні витрати на формування графів в графових нейронних мережах шляхом адаптивної деталізації часу, забезпечуючи розширенню інтервалів часу для побудови графу в періоди несуттєвих змін у вхідних даних.

### Список використаної літератури

- Rossi E., Chamberlain B., Frasca F., Eynard D., Monti F., Bronstein M. Temporal Graph Networks for Deep Learning on Dynamic Graphs. *Proceedings of the 37th International Conference on Machine Learning (ICML 2020)*. Vienna, Austria, PMLR 119, 2020. P. 8230–8240.
- Xu K., Hu W., Leskovec J., Jegelka S. How Powerful are Graph Neural Networks? *Proceedings of the 7th International Conference on Learning Representations (ICLR 2019)*. 2019. P. 1–17.
- Чалий С. Ф., Лещинський В. О. Темпоральне представлення каузальності при побудові пояснень в інтелектуальних системах. *Сучасні інформаційні системи*. 2020. Т. 4, № 3. С. 8–13. DOI: 10.20998/2522-9052.2020.3.02.
- Чала О. В. Побудова темпоральних правил для представлення знань в інформаційних системах управління. *Сучасні інформаційні системи*. 2018. Т. 2, № 3. С. 54–58. DOI: 10.20998/2522-9052.2018.3.09.
- Pareja A., Domeniconi G., Chen J., Ma T., Suzumura T., Kanezashi H., Kaler T., Schardl T., Leiserson C. EvolveGCN: Evolving Graph Convolutional Networks for Dynamic Graphs. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020. Vol. 34, no. 04. P. 5363–5370. DOI: 10.1609/aaai.v34i04.5984.

- Trivedi R., Farajtabar M., Biswal P., Zha H. DyRep: Learning Representations over Dynamic Graphs. *Proceedings of the 7th International Conference on Learning Representations (ICLR 2019)*. 2019.
- Zhang Y., Liu Q., Chen E. Gaia: Graph Neural Network with Temporal Shift-Aware Attention for E-commerce GMV Forecasting. *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD 2024)*. 2024. P. 3421–3430. DOI: 10.1145/3580305.3599456.
- Riesen K., Bunke H. Approximate Graph Edit Distance Computation by Means of Bipartite Graph Matching. *Image and Vision Computing*, 2009. Vol. 27, no. 7. P. 950–959. DOI: 10.1016/j.imavis.2008.04.004.
- Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. A Survey on Concept Drift Adaptation. *ACM Computing Surveys*. 2014. Vol. 46, no. 4. Article 44. P. 1–37. DOI: 10.1145/2523813.
- Hamilton W. L., Ying R., Leskovec J. Inductive Representation Learning on Large Graphs. *Advances in Neural Information Processing Systems (NeurIPS 2017)*. 2017. Vol. 30. P. 1024–1034.
- Bifet A., Holmes G., Kirkby R., Pfahringer B. MOA: Massive Online Analysis. *Journal of Machine Learning Research*. 2010. Vol. 11. P. 1601–1604.
- Sankar A., Wu Y., Gou L., Zhang W., Yang H. DySAT: Deep Neural Representation Learning on Dynamic Graphs via Self-Attention Networks. *Proceedings of the 13th International Conference on Web Search and Data Mining (WSDM 2020)*. 2020. P. 519–527. DOI: 10.1145/3336191.3371845.
- Von Luxburg U. A Tutorial on Spectral Clustering. *Statistics and Computing*. 2007. Vol. 17, no. 4. P. 395–416. DOI: 10.1007/s11222-007-9033-z.
- Robles-Kelly A., Hancock E. R. Graph Edit Distance from Spectral Seriation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2005. Vol. 27, no. 3. P. 365–378. DOI: 10.1109/TPAMI.2005.56.
- Чала О. В. Модель узагальненого представлення темпоральних знань в інтелектуальних інформаційних системах управління. *Сучасні інформаційні системи*. 2020. Т. 4, № 2. С. 30–35. DOI: 10.20998/2522-9052.2020.2.05.
- Чалий С. Ф., Лещинський В. О. Модель пояснення в інтелектуальній системі на основі станів процесу прийняття рішень. *Сучасні інформаційні системи*. 2023. Т. 7, № 1. С. 5–11. DOI: 10.20998/2522-9052.2023.1.01.
- Чалий С. Ф., Лещинський В. О. Декларативно-темпоральний підхід до побудови пояснення в інтелектуальній інформаційній системі. *Сучасні інформаційні системи*. 2020. Т. 4, № 4. С. 5–10. DOI: 10.20998/2522-9052.2020.4.01.
- Huang S., Hitti Y., Rabusseau G., Rabbany R. Laplacian Change Point Detection for Dynamic Graphs. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2020)*. Virtual Event, CA, USA, 2020. P. 349–358. DOI: 10.1145/3394486.3403077.

### References (transliterated)

- Rossi E., Chamberlain B., Frasca F., Eynard D., Monti F., Bronstein M. Temporal Graph Networks for Deep Learning on Dynamic Graphs. *Proceedings of the 37th International Conference on Machine Learning (ICML 2020)*. Vienna, Austria, PMLR 119, 2020, pp. 8230–8240.
- Xu K., Hu W., Leskovec J., Jegelka S. How Powerful are Graph Neural Networks? *Proceedings of the 7th International Conference on Learning Representations (ICLR 2019)*, 2019. P. 1–17.
- Chaliy S. F., Leshchynskiy V. O. Temporalne predstavleniya kauzalnosti pry pobudovi poiasnen v intelektualnykh systemakh [Temporal representation of causality in the construction of explanations in intelligent systems]. *Suchasni informatsiini systemy [Advanced Information Systems]*. 2020, vol. 4, no. 3, pp. 8–13. DOI: 10.20998/2522-9052.2020.3.02. (In Ukr.)
- Chala O. V. Pobudova temporalnykh pravyl dlia predstavleniya znan v informatsiynykh systemakh upravlinnia [Construction of temporal rules for the representation of knowledge in information control systems]. *Suchasni informatsiini systemy [Advanced Information Systems]*. 2018, vol. 2, no. 3, pp. 54–58. DOI: 10.20998/2522-9052.2018.3.09. (In Ukr.)
- Pareja A., Domeniconi G., Chen J., Ma T., Suzumura T., Kanezashi H., Kaler T., Schardl T., Leiserson C. EvolveGCN: Evolving Graph Convolutional Networks for Dynamic Graphs. *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020, vol. 34, no. 04, pp. 5363–5370. DOI: 10.1609/aaai.v34i04.5984.

6. Trivedi R., Farajtabar M., Biswal P., Zha H. DyRep: Learning Representations over Dynamic Graphs. *Proceedings of the 7th International Conference on Learning Representations (ICLR 2019)*, 2019.
7. Zhang Y., Liu Q., Chen E. Gaia: Graph Neural Network with Temporal Shift-Aware Attention for E-commerce GMV Forecasting. *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining (KDD 2024)*. 2024, pp. 3421–3430. DOI: 10.1145/3580305.3599456.
8. Riesen K., Bunke H. Approximate Graph Edit Distance Computation by Means of Bipartite Graph Matching. *Image and Vision Computing*. 2009, vol. 27, no. 7, pp. 950–959. DOI: 10.1016/j.imavis.2008.04.004.
9. Gama J., Žliobaitė I., Bifet A., Pechenizkiy M., Bouchachia A. A Survey on Concept Drift Adaptation. *ACM Computing Surveys*. 2014, vol. 46, no. 4, article 44, pp. 1–37. DOI: 10.1145/2523813.
10. Hamilton W. L., Ying R., Leskovec J. Inductive Representation Learning on Large Graphs. *Advances in Neural Information Processing Systems (NeurIPS 2017)*. 2017, pp. 1024–1034.
11. Bifet A., Holmes G., Kirkby R., Pfahringer B. MOA: Massive Online Analysis. *Journal of Machine Learning Research*. 2010, vol. 11, pp. 1601–1604.
12. Sankar A., Wu Y., Gou L., Zhang W., Yang H. DySAT: Deep Neural Representation Learning on Dynamic Graphs via Self-Attention Networks. *Proceedings of the 13th International Conference on Web Search and Data Mining (WSDM 2020)*. 2020, pp. 519–527. DOI: 10.1145/3336191.3371845.
13. Von Luxburg U. A Tutorial on Spectral Clustering. *Statistics and Computing*. 2007, vol. 17, no. 4, pp. 395–416. DOI: 10.1007/s11222-007-9033-z.
14. Robles-Kelly A., Hancock E. R. Graph Edit Distance from Spectral Seriation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2005, vol. 27, no. 3, pp. 365–378. DOI: 10.1109/TPAMI.2005.56.
15. Chala O. V. Model uzahalnenoho predstavlennia temporalnykh znan v intelektualnykh informatsiynykh systemakh upravlinnia [Model of generalized representation of temporal knowledge in intelligent information control systems]. *Suchasni informatsiini systemy [Advanced Information Systems]*. 2020, vol. 4, no. 2, pp. 30–35. DOI: 10.20998/2522-9052.2020.2.05. (In Ukr.)
16. Chalyi S. F., Leshchynskyi V. O. Model poiasnennia v intelektualnii systemi na osnovi staniv protsesu pryiniattia rishen [An explanation model in an intelligent system at the basis of the states of the decision-making process]. *Suchasni informatsiini systemy [Advanced Information Systems]*. 2023, vol. 7, no. 1, pp. 5–11. DOI: 10.20998/2522-9052.2023.1.01. (In Ukr.)
17. Chalyi S. F., Leshchynskyi V. O. Deklaratyvno-temporalnyi pidkhid do pobudovy poiasnennia v intelektualnii informatsiini systemi [Declarative-temporal approach to the construction of an explanation in an intelligent information system]. *Suchasni informatsiini systemy [Advanced Information Systems]*. 2020, vol. 4, no. 4, pp. 5–10. DOI: 10.20998/2522-9052.2020.4.01. (In Ukr.)
18. Huang S., Hitti Y., Rabusseau G., Rabbany R. Laplacian Change Point Detection for Dynamic Graphs. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD 2020)*. Virtual Event, CA, USA, 2020, pp. 349–358. DOI: 10.1145/3394486.3403077.

Надійшло (received) 14.11.2025

UDC004.8:004.9

**S. F. CHALYI**, Doctor of Technical Sciences, Full Professor, Kharkiv National University of Radio Electronics, Professor of the Department of Information Control System, Kharkiv; e mail: serhii.chalyi@nure.ua, ORCID: <https://orcid.org/0000-0002-9982-9091>

**R. V. KRAVCHENKO**, Kharkiv National University of Radio Electronics, Postgraduate Student of the Department of Information Control Systems, Kharkiv, Ukraine; e-mail: rostyslav.kravchenko1@nure.ua, ORCID: <https://orcid.org/0009-0009-0324-3597>

## METHOD FOR ADAPTIVE SELECTION OF TIME INTERVALS FOR CONSTRUCTING GRAPHS OF TEMPORAL GRAPH NEURAL NETWORKS

The subject of research is the process of forming graph structures for temporal graph neural networks with adaptive selection of time interval granularity level. The aim of the work is to develop an approach to forming graph structures with adaptive granularity for temporal graph neural networks. Research tasks include: structuring approaches to selecting the granularity level of time intervals when forming graphs of temporal graph neural networks considering changes in the structure of these graphs; developing a method for adaptive selection of time intervals based on graph editing metrics and spectral analysis of graph structure. The developed method includes five stages: graph formation based on co-occurrence frequency of entities; calculation of editing rate between sequential graphs; spectral embedding of graphs through normalized symmetric Laplacian; computation of Kullback – Leibler divergence between spectral densities to detect structural drift; adaptive adjustment of time interval duration considering editing rate criteria and divergence magnitude. The method combines local graph editing metric and global metrics of spectral density, Kullback – Leibler divergence to detect not only the quantity of changes in the graph but also their impact on graph topology. This allows distinguishing noise from significant structural changes in the graph. The method provides automated selection of time granularity without using expert knowledge about threshold values for graph structure changes; reduction of computational costs for graph formation during periods of structure stability; specified accuracy of temporal dependency detection during periods of sharp graph structure changes. The practical significance of the obtained results lies in the possibility of representation and further analysis of dynamic processes in intelligent systems that operationally adapt to changes in relationship structure, for tasks of building explanations, recommendations, monitoring, analysis and forecasting in e-commerce systems, social networks, financial analysis, transportation monitoring.

**Keywords:** temporal graphs, adaptive time granularity, spectral analysis, structural drift, dynamic graphs, graph neural networks, edit metric, Laplacian eigenvalues, temporal dependencies.

Повні імена авторів / Author's full names

**Автор 1 / Author 1:** Чалий Сергій Федорович / Chalyi Serhii Fedorovich

**Автор 2 / Author 2:** Кравченко Ростислав Вікторович / Kravchenko Rostyslav Viktorovich