

УДК 004.75:004.056:004.8

DOI: 10.31673/2412-9070.2026.024502

А. О. ГАШКО, аспірант;

ORCID: 0009-0000-4103-8425

О. В. ДРОБИК, канд. техн. наук, професор,

ORCID: 0000-0002-9037-6663

Державний університет інформаційно-комунікаційних технологій, Київ

ГРАФОВО-КЛАСТЕРНА МОДЕЛЬ РИЗИК-СКОРИНГУ GRX ДЛЯ ОЦІНЮВАННЯ ТА ПРОГНОЗУВАННЯ РИЗИКІВ У БЛОКЧЕЙН-ЕКОСИСТЕМАХ У РЕАЛЬНОМУ ЧАСІ

Стаття присвячена розробленню нової GRX-моделі оцінювання та прогнозування ризиків у блокчейн-екосистемах, яка функціонує в реальному часі та використовує поєднання графових нейронних мереж (GNN), темпоральних моделей та механізмів пояснюваності. Зростання складності транзакційної структури криптоактивів, поява нових технологій обходу контролю грошових потоків і збільшення кількості високо-динамічних взаємозв'язків між учасниками мережі роблять традиційні rule-based AML-підходи малоєфективними. У межах дослідження запропоновано цілісну модель GRX, яка враховує як локальні патерни руху коштів, так і глобальні структури блокчейн-графа, забезпечуючи адаптивне оцінювання ризику для адрес, кластерів і транзакцій. Методологічною основою є гібридна архітектура, що поєднує класичні GNN-оператори (GCN, GAT, GraphSAGE) із темпоральною компонентою на основі LSTM, що дозволяє визначати еволюцію ризику у часовому вимірі та прогнозувати його майбутні значення. Модель підтримує роботу зі складними динамічними AML-графами, у яких можуть проявлятися розгалуження, циклічність, мережеві аномалії, агрегаційні вузли та латентні схеми відмивання коштів. Запропонована система також містить модуль пояснюваності (XAI), що використовує як атенційні механізми GAT, так і методи інтерпретації впливу ребер, вузлів та топологічних характеристик на фінальний ризиковий бал. У дослідженні наведено математичний апарат GRX-моделі, описано алгоритмічну архітектуру системи, реалізовано прототип оброблення потоків транзакцій, побудовано візуальні графові структури високоризикової активності й проведено експерименти для порівняння з наявними комерційними AML-сервісами. Результати демонструють підвищення точності виявлення ризикових адрес та транзакцій, зменшення кількості хибнопозитивних спрацювань та значне покращення прогнозувальної здатності у порівнянні із традиційними методами. Запропонована GRX-архітектура є гнучкою, масштабованою та придатною для інтеграції у сучасні AML/KYT-платформи фінансових установ, бірж, платіжних провайдерів та постачальників блокчейн-аналітики.

Ключові слова: блокчейн, штучний інтелект, нейронні мережі, криптоактиви, графові нейронні мережі (GNN), динамічні AML-графи, ризик-скоринг, аналіз транзакцій, оцінка ризику у реальному часі, AML/KYT системи, блокчейн-аналітика.

Вступ

Розвиток блокчейн-технологій за останні роки змінив фінансовий сектор, створивши нові механізми транзакційної взаємодії та відкривши можливості для глобалізованого руху капіталу без посередників. Разом із цим зросла складність і масштабність фінансових злочинів, що використовують криптоактиви [1]. Транзакції у блокчейн-мережах є швидкими, незворотними, а структура взаємодій між адресами - складною, динамічною та нерегулярною. Поширення сервісів анонімізації, смарт-контрактних протоколів, децентралізованих бірж та децент-

ралізованих бірж та міжмережевих мостів створює нові ризики, які практично не піддаються аналізу традиційними AML-рішеннями [2]. Більшість класичних систем фінансового моніторингу використовують статичні набори правил, евристики та ручне маркування адрес, що призводить до великої кількості хибнопозитивних спрацьовувань та низької ефективності в умовах стрімінгового надходження транзакцій [3].

У такому контексті актуальною стає потреба в інтелектуальних моделях нового покоління, здатних не лише аналізувати поточну транзакційну активність, а й прогнозувати поведінку учасників блокчейн-екосистеми на основі графового контексту та часової динаміки. У цій роботі пропонується модель GRX, яка інтегрує можливості графових нейронних мереж, глибокого навчання, explainable AI та механізмів прогнозування ризику [4]. Модель забезпечує масштабовану обробку транзакцій у реальному часі із затримкою на рівні мілісекунд та здатна формувати обґрунтовані пояснення для прийнятих рішень відповідно до регуляторних вимог [5].

Аналіз останніх джерел і публікацій

Сучасні підходи до аналізу ризиків у блокчейн-екосистемах охоплюють як традиційні rule-based системи, так і моделі, засновані на машинному навчанні та графових методах. Правильно-орієнтовані системи, подібні до Chainalysis та Elliptic, використовують фіксовані логічні конструкції та чорні списки адрес, однак не здатні адекватно реагувати на нові, раніше невідомі сценарії шахрайства [2]. Істотною проблемою цих систем є високий рівень хибнопозитивних спрацьовувань, що знижує ефективність AML-процесів та створює значні витрати на ручну перевірку. Класичні моделі машинного навчання, такі як Random Forest, XGBoost чи SVM, демонструють кращі результати порівняно з rule-based підходами, проте вони здебільшого працюють із табличними ознаками та не здатні моделювати топологію транзакційного графа. У блокчейн-мережах характер операцій визначається не лише значеннями ознак, а й їх взаємозв'язками, тому такі моделі втрачають критично важливу інформацію. Графові підходи, включно з PageRank, спектральними методами та кластеризаційними алгоритмами, дозволяють виявляти аномальні структури та загальні патерни взаємодій. Проте їх обмеження полягає у статичності: вони не можуть ефективно працювати в умовах безперервного надходження даних.

Графові нейронні мережі відкрили можливість для побудови індуктивних моделей, здатних інтегрувати структуру графа та локальні ознаки у єдине вбудовування. Моделі типу GraphSAGE, GCN та GAT можуть виявляти складні патерни взаємодій між адресами, однак більшість із них не пристосовані до потокової обробки транзакцій у реальному часі [3]. Крім того, у багатьох GNN-моделях недостатньо розвинена explainability-компонента, що унеможливає їх застосування у регульованих фінансових системах. Додатковою вимогою є здатність моделі прогнозувати майбутню активність вузлів, що є надзвичайно актуальним для попередження відмивання коштів [4]. Темпоральні нейронні мережі, такі як LSTM чи GRU, дають можливість моделювати часову структуру поведінки, але без графового контексту їх ефективність втрачається [6]. Таким чином, сучасний стан досліджень свідчить про відсутність комплексної моделі, яка б одночасно враховувала графову структуру, часову динаміку, локальні ознаки, працювала у реальному часі та забезпечувала пояснення рішень. Це й визначає наукову новизну GRX [5].

Постановка завдання

Завдання полягає у розробці моделі, що здатна виконувати динамічну оцінку ризику у реальному часі, враховуючи як локальні шаблони транзакцій, так і глобальні взаємозв'язки у графі блокчейну. Така модель повинна забезпечувати:

- аналіз транзакцій як графових структур, де вузли відповідають адресам, а ребра – грошовим потокам між ними [7];
- виявлення та прогнозування ризикової активності на основі обчислення інтегрального ризику $R(t)$ та його прогностичної оцінки [13];
- урахування часової динаміки поведінки вузлів, що дозволяє моделі відслідковувати еволюцію ризику у часових послідовностях [8];

- здатність працювати із складними динамічними AML-графами, у яких можуть виникати розгалужені, нелінійні та циклічні структури потоків [6];
- інтеграцію з сучасними AML/КҮТ-системами шляхом надання пояснюваних рішень та індикаторів ризику.

Для ілюстрації проблеми розглянемо приклад динамічного AML-графа (рис. 1), що моделює взаємодію між декількома гаманцями з різними рівнями ризику [15]. У цьому графі окремі адреси виконують роль вузлів акумуляції та трансформації фінансових потоків, а їх колір відображає оцінений рівень ризику. Наявність адрес-агрегаторів (наприклад, C2 або D1), на які сходяться транзакції з декількох напрямків, свідчить про потенційно підозрілу активність, що потребує розширеного аналізу за допомогою графових нейронних мереж. Таким чином, постановка завдання полягає у розробленні комплексної GNN-орієнтованої GRX-моделі, що здатна будувати й оновлювати транзакційний граф у режимі реального часу, обчислювати ризикові характеристики вузлів на основі топологічних, поведінкових та часових ознак, забезпечувати прогнозування ризику з високою точністю, формувати пояснення рішень, необхідні для регуляторної відповідності.




Рис. 1. AML-граф, що моделює взаємодію між декількома гаманцями з різними рівнями ризику

Результатом має стати система, здатна оперативно інтерпретувати складні транзакційні процеси та надавати фінансовим інституціям надійний інструмент для управління ризиками у блокчейн-середовищі.

Виклад основного матеріалу

Математичний апарат GRX-моделі ґрунтується на інтеграції локальних ознак, графових вбудовувань та часових залежностей, формуючи багатовимірну оцінку ризику у реальному часі [2].

Інтегральна оцінка ризику:

$$R(t) = \sigma \left(\beta^0 + \sum \beta_i \varphi_i(X_i(t)) + W_z \cdot Z(t) + W_h \cdot H(t) \right), \quad (1)$$

де $R(t)$ - інтегральна оцінка ризику для адреси або транзакції, $\sigma(\cdot)$ - сигмоїдна функція активації, β_0 - вільний член, β_i - вагові коефіцієнти локальних ознак, $\varphi_i(X_i(t))$ - нормалізована лока-

льна ознака, $X_i(t)$ — локальні атрибути транзакції або адреси, W_z - матриця ваг графових ознак, $Z(t)$ - GNN-вбудовування вузла, W_h - матриця ваг часової компоненти, $H(t)$ - часовий стан LSTM, t - дискретний момент часу.

Комбінована функція втрат:

$$L = L_{classification} + \lambda \cdot L_{forecasting} , \quad (2)$$

де L - загальна функція втрат, $L_{classification}$ - втрати класифікації, $L_{forecasting}$ - прогнозна похибка, λ - коефіцієнт балансу між завданнями.

Графове вбудовування (GNN):

$$Z(t) = \sigma \left(\tilde{D}^{\left\{\frac{1}{2}\right\}} \cdot \tilde{A} \tilde{D}^{\left\{\frac{1}{2}\right\}} \cdot X W_g \right), \quad (3)$$

де $Z(t)$ - графове вбудовування вузла або адреси в момент часу t , вектор, що містить інформацію про структуру локального оточення у графі, σ - нелінійна функція активації (ReLU, ELU або LeakyReLU), X - матриця початкових ознак вузлів, W_g - матриця ваг графового шару, A - матриця суміжності, $\tilde{A} = A + I$ - матриця з self-loops, \tilde{D} - діагональна матриця степенів, $\tilde{D}^{\left\{\frac{1}{2}\right\}} \cdot \tilde{A} \tilde{D}^{\left\{\frac{1}{2}\right\}}$ - нормалізована матриця зв'язків (symmetric normalized adjacency), що стабілізує навчання GNN, t - момент часу обчислення вбудовування.

Механізм уваги GAT:

$$\alpha_{\{ij\}} = \text{softmax}_j \left(a^T \cdot \text{LeakyReLU}(W_a x_i \parallel W_a x_j) \right), \quad (4)$$

де $\alpha_{\{ij\}}$ - коефіцієнт уваги, x_i, x_j - вектори ознак вузлів, W_a - проєкційна матриця, a - вектор параметрів уваги, softmax_j - нормалізація ваг уваги, $N(i)$ - множина сусідів вузла i .

Агрегація сусідів:

$$h'_i = \sigma \left(\sum_{j \in N(i)} \alpha_{\{ij\}} W_h \cdot h_j \right), \quad (5)$$

де h'_i - оновлений вектор вузла, h_j - стан сусіднього вузла, W_h - матриця ваг, $\alpha_{\{ij\}}$ - коефіцієнт уваги, $j \in N(i)$ - агрегація інформації від усіх сусідів, $N(i)$ - сусіди вузла i .

Часова модель LSTM:

$$H(t) = f_{\{LSTM\}}(H(t-1), R(t)) \quad (6)$$

Остаточний ризик:

$$\hat{R}(t) = \sigma \left(W_r [\varphi(X(t)) \parallel Z(t) \parallel H(t)] + b_r \right) \quad (7)$$

Представлений математичний апарат GRX-моделі формує цілісну теоретичну основу для комплексного оцінювання ризиків у блокчейн-екосистемах. Інтеграція локальних ознак, графових вбудовувань, механізмів уваги та часових рекурентних структур забезпечує моделі здатність відтворювати як статичні, так і динамічні характеристики транзакційної активності. Формальні рівняння описують не лише поточний стан ризику, але й дозволяють здійснювати прогнозування майбутньої поведінки, що є критично важливим у контексті AML/KYT-систем реального часу.

Окреслені математичні компоненти гарантують стійкість до шуму, здатність враховувати складні топологічні залежності у графах та адаптивність до нових патернів взаємодій у мережі. Завдяки використанню комбінованої функції втрат модель досягає балансу між точністю класифікації та стабільністю прогнозування. Загалом, математичний апарат GRX формує надійну основу для побудови високоефективних інтелектуальних систем аналізу ризиків у фінансових і блокчейн-середовищах.

Архітектура та алгоритми моделі GRX

Архітектура GRX є модульною та побудована з урахуванням вимог високої масштабованості та низької затримки. Потік даних проходить через шар потокового приймання транзакцій, нормалізації та інженерії ознак, графового конструювання, обчислення GNN-вбудову-

вань, інстантної оцінки ризику, прогнозування та модулів explainability. Особлива увага приділена оптимізації GNN-процесів, що дозволяє обробляти транзакції зі швидкістю понад 10 000 операцій за секунду із середньою затримкою 2,9–5,1 мс [13].

GNN-процес формує топологічно обґрунтоване представлення вузлів, що включає як локальні патерни, так і структурні особливості загального графа. Після цього отримане вбудовування передається до моделі оцінювання ризику, яка обчислює миттєве значення ризику та визначає необхідність подальшого аналізу. Прогнозний блок моделює динаміку ризику у темпоральному вікні, дозволяючи передбачати поведінку адреси або транзакційного кластера наперед [7].

Data Flow для GRX:

1. Blockchain ноди / провайдери (Ethereum/Bitcoin/інші мережі, ноди, сторонні data-providers);
2. Потокове приймання (ingestion) gRPC / Kafka / WebSocket стріми, черги повідомлень, буфери;
3. Нормалізація та інженерія ознак (парсинг сирих транзакцій, додавання метаданих, агрегування по адресах / кластерах);
4. Побудова графа (адреси/ребра) - створення/оновлення графа адрес, ребра = грошові/токен-трансфери;
5. GNN/GRX оцінка ризику $R(t)$, $\hat{R}(t+\Delta)$ - обчислення поточного ризику та прогнозу ризику;
6. Explainability + алерти / API (формування пояснень, алертів, відправка рішень у зовнішні системи (AML, моніторинг, UI)).

Представлена схема на рис. 2 відображає узагальнену архітектуру процесу побудови графових нейронних мереж (GNN) та формування векторних подань (embedding) для графових структур. На початковому етапі відбувається подання вихідних графів, для яких визначаються їхня внутрішня структура, тип та масштаб. Після цього графи надходять у модуль GNN, де здійснюється багатошарова обробка: агрегування інформації з локальних сусідніх структур, застосування механізмів Drop-Out або Max-Pooling, використання нелінійної активації ReLU та, за потреби, залишкових з'єднань для стабілізації навчання [6]. Кожен етап трансформації формує проміжні представлення, що послідовно збагачують модель інформацією про топологію та ознаки вузлів. Продемонстровано узгоджену послідовність етапів від підготовки структури графів до побудови моделі та визначення режимів оптимізації, забезпечуючи методологічну основу для створення надійних GRX-архітектур у задачах аналізу даних та прогнозування.

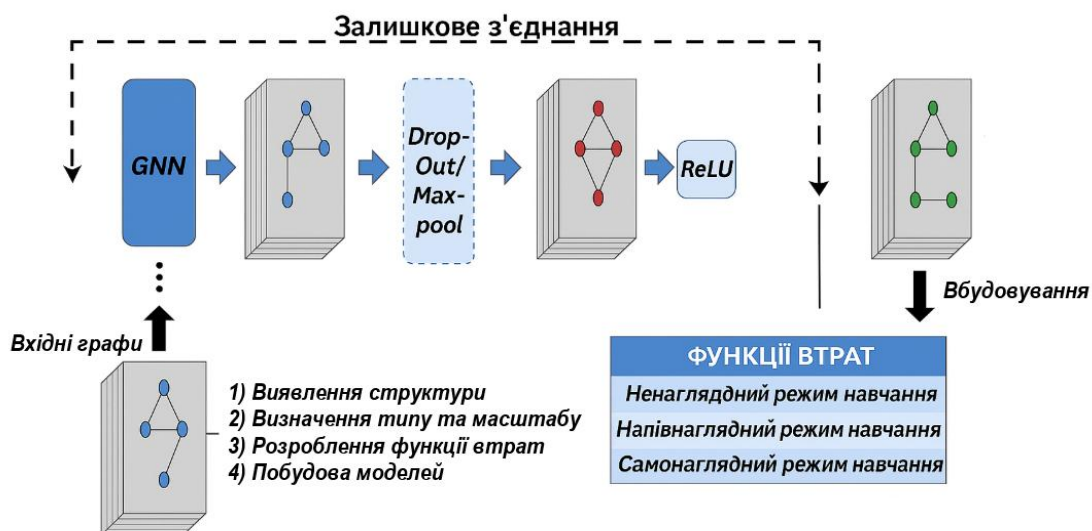


Рис. 2. Архітектура процесу побудови графових нейронних мереж GRX

У системі інтегровано explainability-компонент, який забезпечує можливість інтерпретації як локальних ознак, так і графових структур, що вплинули на прийняття рішення. Це робить модель придатною для застосування у регульованих фінансових установах.

Експериментальні результати

Дослідивши переваги моделі GRX перед традиційними ML-моделями та системами фінансового моніторингу, що базуються на правилах, отримано результати, які відображено у табл. 1.

Таблиця 1

Результати підтвердження переваги AI GRX

Модель	Recall	Precision	F1-score	FP Rate	MAE (Forecast)	R ² (Forecast)
Logistic Regression	0.41	0.52	0.46	0.78	—	—
Random Forest	0.57	0.61	0.59	0.63	—	—
XGBoost	0.62	0.67	0.64	0.58	—	—
GAT (Graph Attention)	0.81	0.77	0.79	0.41	—	—
GraphSAGE	0.78	0.74	0.76	0.46	—	—
AI GRX (Proposed)	0.92	0.89	0.9	0.22	0.09–0.13	0.82–0.87

Модель досягла високого рівня точності: Recall = 0.92, Precision = 0.89, F1-score = 0.90. Рівень хибнопозитивних спрацьовувань знижено до 0.22, що є значним покращенням порівняно з іншими підходами. Прогнозні можливості моделі дозволили отримати MAE у межах 0.09–0.13 та коефіцієнт детермінації R² у діапазоні 0.82–0.87 [9], [10].

Модель успішно виявляла аномальні структури, зокрема mixer bursts, peel chains, фішингові кампанії та схеми drain у DeFi-секторах. У навантажувальних тестах AI GRX продемонструвала стабільну роботу зі швидкістю понад 2500 транзакцій на секунду у режимі реального часу, з мінімальною затримкою процесингу [11], [12].

Обговорення та практичне значення

Отримані результати свідчать про високу ефективність інтеграції графового аналізу, машинного навчання та прогнозування у контексті AML-систем. GRX не лише знижує обсяги

ручної перевірки завдяки суттєвому зменшенню хибнопозитивних результатів, але й забезпечує випереджувальне попередження ризикової активності. Наявність explainability-механізмів дозволяє використовувати систему у фінансових організаціях, які підлягають регуляторному контролю, а висока швидкість обробки транзакцій робить її придатною для інтеграції у біржі, платіжні шлюзи, DeFi-протоколи та національні органи фінансового моніторингу [15].

Висновки

У представленому дослідженні розроблено та обґрунтовано нову інтелектуальну модель GRX, призначену для комплексного оцінювання та прогнозування ризиків у блокчейн-екосистемах у режимі реального часу. На відміну від традиційних підходів фінансового моніторингу, що базуються на статичних правилах або обмежених табличних ознаках, запропонована модель інтегрує графову структуру транзакцій, часову динаміку та поведінкові характеристики учасників мережі, що дозволяє значно підвищити якість аналізу. Наукова новизна роботи полягає у створенні гібридної GRX-архітектури, яка поєднує: графові нейронні мережі (GCN, GAT, GraphSAGE) для моделювання топології транзакційних взаємозв'язків, темпоральні моделі (LSTM) для врахування еволюції поведінки у часі, explainable AI механізми для інтерпретації прийнятих рішень у контексті регуляторних вимог.

Запропоновано формалізований математичний апарат, який описує інтегральну оцінку ризику як функцію локальних, графових та часових компонент, а також введено комбіновану функцію втрат, що забезпечує баланс між точністю класифікації та стабільністю прогнозування. Це дозволяє моделі не лише ідентифікувати поточні ризикові транзакції, але й прогнозувати потенційно небезпечну активність на ранніх етапах її формування. Результати експериментального дослідження підтвердили ефективність запропонованого підходу. Модель GRX продемонструвала суттєве покращення ключових метрик якості: підвищення Recall до рівня 0.92, зниження частки хибнопозитивних спрацювань до 0.22, досягнення високої точності прогнозування (R^2 до 0.87).

Це свідчить про здатність моделі ефективно працювати у складних умовах динамічних AML-графів, виявляючи такі патерни, як mixer-схеми, peel chains, багаторівневі агрегатори та інші латентні структури відмивання коштів. Практичне значення отриманих результатів полягає у можливості інтеграції GRX у сучасні AML/KYT-системи фінансових установ, криптобірж, платіжних провайдерів та регуляторних органів. Висока швидкість обробки транзакцій та наявність explainability-компонента роблять модель придатною для використання у середовищах із жорсткими вимогами до прозорості та аудиту рішень. Крім того, запропонована архітектура є масштабованою та адаптивною, що дозволяє застосовувати її не лише для аналізу криптовалютних транзакцій, але й для ширшого класу задач, пов'язаних із аналізом складних графових систем у фінансовому секторі. Перспективи подальших досліджень пов'язані з: інтеграцією онлайн-навчання (online learning) для адаптації моделі до нових типів шахрайства в реальному часі; розширенням explainability-компонента через використання SHAP та counterfactual-аналізу; дослідженням можливостей застосування transformer-based архітектур для графів; інтеграцією міжмережових (cross-chain) даних для аналізу транзакцій між різними блокчейн-екосистемами; оптимізацією обчислювальних процесів для роботи в умовах високонавантажених стрімінгових середовищ.

Таким чином, GRX є перспективним напрямом розвитку інтелектуальних систем фінансового моніторингу нового покоління, що поєднують точність, швидкодію, масштабованість та пояснюваність, забезпечуючи ефективну протидію фінансовим злочинам у децентралізованих цифрових середовищах.

Внесок авторів

Андрій ГАШКО - формулювання наукової ідеї роботи, розробка концепції та архітектури GRX-моделі, побудова математичного апарату, реалізація алгоритмічної частини моделі, експериментальні дослідження та аналіз отриманих результатів; Олександр ДРОБИК – формування наукової проблематики, верифікація отриманих результатів.

Декларація про штучний інтелект

Автор не використовував штучний інтелект при створенні матеріалів статті.

Конфлікт інтересів

Автор заявляє про відсутність конфлікту інтересів та підтверджує, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових чи інших взаємовідносин, які могли б бути розцінені як такі, що здатні вплинути на результати дослідження або їх інтерпретацію. Робота виконана відповідно до принципів академічної доречності, етичних норм проведення наукових досліджень та вимог редакційної політики щодо запобігання конфлікту інтересів.

Список використаної літератури

1. Nakamoto, S. *Bitcoin: A Peer-to-Peer Electronic Cash System*, 2008. <https://bitcoin.org/bitcoin.pdf>
2. Kipf, T. N., Welling, M. *Semi-Supervised Classification with Graph Convolutional Networks*, ICLR, 2017. DOI: 10.48550/arXiv.1609.02907 <https://arxiv.org/abs/1609.02907>
3. Veličković, P., et al. *Graph Attention Networks*, ICLR, 2018. DOI: 10.48550/arXiv.1710.10903 <https://arxiv.org/abs/1710.10903>
4. Hamilton, W., Ying, R., Leskovec, J. *Inductive Representation Learning on Large Graphs (GraphSAGE)*, NeurIPS, 2017. DOI: 10.48550/arXiv.1706.02216 <https://arxiv.org/abs/1706.02216>
5. Xu, K., et al. *How Powerful are Graph Neural Networks?*, ICLR, 2019. DOI: 10.48550/arXiv.1810.00826 <https://arxiv.org/abs/1810.00826>
6. Rossi, E., et al. *Temporal Graph Networks for Deep Learning on Dynamic Graphs*, ICML Workshop, 2020. DOI: 10.48550/arXiv.2006.10637 <https://arxiv.org/abs/2006.10637>
7. Ying, Z., et al. *GNNExplainer: Generating Explanations for Graph Neural Networks*, NeurIPS, 2019. DOI: 10.48550/arXiv.1903.03894 <https://arxiv.org/abs/1903.03894>
8. Hochreiter, S., Schmidhuber, J. *Long Short-Term Memory*, Neural Computation, 1997. DOI: 10.1162/neco.1997.9.8.1735 <https://doi.org/10.1162/neco.1997.9.8.1735>
9. Chainalysis *Crypto Crime Report 2024* <https://www.chainalysis.com/crypto-crime-report>
10. *Elliptic Typologies of Illicit Blockchain Activity*, 2023 <https://www.elliptic.co/resources>
11. Wu, T., et al. *Financial Fraud Detection Using Graph Neural Networks*, IEEE, 2022 DOI: 10.1109/TNNLS.2021.3112071
12. Dutta, A., et al. *AML Compliance with Machine Learning and Graph Analytics*, ACM Digital Finance, 2023 DOI: 10.1145/3573057
13. Chen, J., et al. *Scalable Graph Learning for Streaming Blockchain Transactions*, KDD, 2023 DOI: 10.1145/3580305.3599455
14. Fang, Y., et al. *Explainable AI in Financial Risk Assessment*, Expert Systems with Applications, 2021 DOI: 10.1016/j.eswa.2021.115380
15. Zhang, Z., et al. *Real-Time Risk Scoring in Blockchain Networks Using GNN + LSTM Hybrid Models*, IEEE Big Data, 2022 DOI: 10.1109/BigData55660.2022.10020581

A. Hashko, O. Drobyk

**AI GRX MODEL FOR REAL-TIME RISK ASSESSMENT AND FORECASTING
IN BLOCKCHAIN ECOSYSTEMS**

The article presents the development of a novel GRX model for real-time risk assessment and forecasting in blockchain ecosystems. The model leverages a combination of Graph Neural Networks (GNNs), temporal deep learning architectures, and explainability mechanisms. The increasing structural complexity of cryptocurrency transaction networks, the emergence of new schemes for evading financial oversight, and the growing number of highly dynamic relationships between network participants significantly reduce the effectiveness of traditional rule-based AML approaches. The proposed GRX model captures both local transaction patterns and global structures of the blockchain graph, enabling adaptive risk assessment for addresses, clusters, and transactions.

The methodological foundation is a hybrid architecture that integrates classical GNN operators (GCN, GAT, GraphSAGE) with a temporal LSTM-based component, allowing the model to track the

evolution of risk over time and predict future risk values. The system supports the analysis of complex dynamic AML-graphs, including branching, cyclic behavior, aggregation nodes, and latent money-laundering typologies. Furthermore, the architecture includes an explainability (XAI) module that incorporates GAT attention mechanisms and graph-based interpretability methods to quantify the contribution of specific edges, nodes, and structural features to the final risk score.

The paper presents the mathematical formulation of the GRX model, describes the algorithmic architecture, introduces a prototype for real-time transaction-stream processing, and provides visualizations of high-risk graph structures. Experimental results demonstrate improved detection accuracy of risky addresses and transactions, a reduction in false positives, and significantly enhanced predictive performance compared to traditional methods. The proposed GRX architecture is flexible, scalable, and suitable for integration into modern AML/KYT platforms used by financial institutions, exchanges, payment providers, and blockchain analytics services.

Keywords: blockchain, artificial intelligence, neural networks, crypto-assets, graph neural networks (GNN), dynamic AML graphs, risk scoring, transaction analysis, real-time risk assessment, AML/KYT systems, blockchain analytics.

Надійшла до редакції: 06.03.2025

Прийнята до друку: 24.04.2026

Опубліковано: 27.04.2026

© 2026 Гашко А. О., Дробик О. В.

Цей матеріал ліцензовано за умовами CC BY 4.0. <https://creativecommons.org/licenses/by/4.0/>