

УДК 004.8

DOI <https://doi.org/10.32782/tnv-tech.2025.1.6>

ОЦІНКА ПРОДУКТИВНОСТІ НЕЙРОМЕРЕЖ ДЛЯ ІДЕНТИФІКАЦІЇ АНОМАЛІЙ У БІЗНЕС-ПРОЦЕСАХ

Коротенко С. А. – аспірант Приватного вищого навчального закладу
«Європейський університет»
ORCID ID: 0009-0003-9236-4775

Метою дослідження є оцінка ефективності різних архітектур глибоких нейронних мереж (DNN) для ідентифікації аномалій у бізнес-процесах, що є критичним завданням у контексті цифрової трансформації та автоматизації управлінських рішень. У роботі розглядаються та порівнюються такі архітектури: графові нейронні мережі (GNN) для виявлення структурних аномалій, рекурентні нейронні мережі (LSTM, RNN) та трансформери (Transformers) для аналізу часових рядів і прогнозування, а також автоенкодерів (Autoencoders) для роботи з атрибутивними даними. Запропоновано адаптивний підхід, що поєднує переваги різних моделей залежно від типу бізнес-процесу та його характеристик. Дослідження базується на великому наборі даних, отриманому з BPMS-системи, який включає графи процесів, збагачені бізнес-параметрами. Розглянуто чотири основні типи аномалій: пропущені кроки (Missing Steps), дублювання кроків (Duplicate Steps), неправильні маршрути (Wrong Route) та аномальну тривалість виконання завдань (Abnormal Duration). В експериментальній частині досліджено продуктивність моделей за ключовими метриками, включаючи Precision, Recall, F1-score, AUC-ROC, AUPRC, ADR (Anomaly Detection Rate), FAR (False Alarm Rate), FNR (False Negative Rate), а також час навчання моделей та матрицю плутанини для детального аналізу розподілу прогнозованих класів. Результати показують, що Transformers демонструють найвищу точність у виявленні складних послідовностей подій, GNN найкраще справляється зі структурними аномаліями, а Autoencoders ефективні при роботі з атрибутивними наборами даних. Запропоновано рекомендації щодо вибору архітектури залежно від специфіки бізнес-процесу та обмежень щодо обчислювальних ресурсів. Отримані результати можуть бути використані для оптимізації процесного моніторингу, автоматизації виявлення порушень та підвищення ефективності управління бізнес-процесами в умовах мінливого цифрового середовища.

Ключові слова: BPM, Anomaly Detection, DNN, GNN, CNN, RNN, LSTM, Autoencoder, Transformers.

Korotenko S. A. Performance evaluation of neural networks for anomaly detection in business processes

The of this study is to evaluate the effectiveness of various deep neural network (DNN) architectures for anomaly detection in business processes, which is a critical task in the context of digital transformation and automation of managerial decisions. The study examines and compares different architectures: graph neural networks (GNN) for detecting structural anomalies, recurrent neural networks (LSTM, RNN) and transformers (Transformers) for time series analysis and forecasting, as well as autoencoders (Autoencoders) for processing attribute-based data. An adaptive approach is proposed, integrating the advantages of different models depending on the type and characteristics of a business process. The research is based on a large dataset extracted from a BPMS system, including enriched process graphs with business parameters. Four main types of anomalies are considered: Missing Steps, Duplicate Steps, Wrong Route, and Abnormal Duration. The experimental part of the study evaluates model performance using key metrics, including Precision, Recall, F1-score, AUC-ROC, AUPRC, ADR (Anomaly Detection Rate), FAR (False Alarm Rate), and FNR (False Negative Rate), as well as training time and a confusion matrix for a detailed analysis of predicted class distributions. The results indicate that Transformers achieve the highest accuracy in detecting complex event sequences, GNNs excel in identifying structural anomalies, and Autoencoders perform effectively when working with attribute-based datasets. Recommendations are provided for selecting an appropriate architecture based on the specific characteristics of a business process and computational resource constraints. The findings can be applied to optimize process monitoring, automate anomaly detection, and enhance the efficiency of business process management in a rapidly evolving digital environment.

Key words: BPM, Anomaly Detection, DNN, GNN, CNN, RNN, LSTM, Autoencoder, Transformers.

Вступ. Цифрова трансформація радикально змінює управління бізнес-процесами, породжуючи значні виклики, зокрема, зростання обсягів даних, підвищення складності їх обробки, поява гетерогенних структур, а також необхідність інтеграції децентралізованих і динамічних процесів у реальному часі. Як зазначають Galanti et al. (2020), класичні методи, такі як процесний майнінг і регресійні моделі, демонструють обмеження у швидкості обробки даних і точності виявлення аномалій, особливо у випадках зростання обсягів інформації [10].

У відповідь на ці виклики, глибокі нейронні мережі (DNN), відкривають нові можливості для адаптивного моніторингу бізнес-процесів. Вони забезпечують здатність обробляти складні та багатовимірні дані, що є ключовим для своєчасного виявлення аномалій у таких процесах, як управління ресурсами (ERM), HR-процеси, фінансові операції, документообіг та логістика [7] [17] [19]. DNN пропонують рішення цих проблем завдяки адаптивності, можливості обробляти значні обсяги даних і аналізувати складні взаємозв'язки [10] [19]. Проте впровадження таких рішень вимагає не лише обчислювальних ресурсів, але й глибокого аналізу для вибору відповідної архітектури DNN, залежно від специфіки процесу, його домену та типів аномалій в виявленні яких зацікавлений бізнес. Важливим є порівняння продуктивності різних архітектур (GNN, CNN, RNN, LSTM, Autoencoders, Transformers) для забезпечення їхньої ефективності в конкретних умовах.

Аналіз останніх досліджень і публікацій. Galanti et al. (2020) – зосереджуються на викликах цифрової трансформації у бізнес-процесах, підкреслюючи обмеження класичних методів, таких як процесний майнінг і регресійні моделі. Автори досліджують потенціал глибоких нейронних мереж (DNN) у вирішенні цих проблем [10]. Weinzierl et al. (2024) – Провели систематичний огляд літератури про роль машинного навчання у життєвому циклі управління бізнес-процесами. Вони акцентують на ефективності DNN у моніторингу, прогнозуванні та редизайні процесів, наголошуючи на важливості індивідуального підходу до кожного типу процесу [23]. Ariyaluran Habeeb et al. (2019) – Розглядають підходи до обробки великих даних у реальному часі для виявлення аномалій на основі автоенкодерів. Автори визначають ключові проблеми, пов'язані зі швидкістю обробки даних та складністю адаптації моделей до нових процесів [4]. Bezerra et al. (2008) – Спеціалізуються на алгоритмах виявлення аномалій у бізнес-процесах, та наголошують на необхідності адаптації нових підходів, таких як DNN [5]. Alizadeh et al. (2015) – Досліджують проблеми методів перевірки відповідності (conformance checking), обґрунтовуючи необхідність поєднання DNN із традиційними алгоритмами [3]. Mili H. та ін. (2009) – зазначають важливим елементом успішного впровадження сучасних підходів є класифікація бізнес-процесів [23]. Landauer (2022) – пропонує використовувати CNN для ідентифікації аномалій у складних послідовностях [16]. Дослідження Al-Jebrni et al. (2024) – демонструє ефективність CNN у прогнозуванні наступних подій у бізнес-процесах [2]. Chen et al. (2017) – акцентують увагу на використанні автоенкодерів для виявлення аномалій у великих наборах даних [7]. Дослідження, Guan et al. (2024), показують переваги використання Transformer з Autoencoders для багатомодального аналізу даних бізнес-процесів, що підвищує ефективність виявлення нелінійних аномалій [12].

Виділення невирішених раніше частин проблеми. Вибір оптимальної архітектури DNN для виявлення аномалій у бізнес-процесах залишається складним завданням. Це зумовлено значною різноманітністю процесів, типів даних

(графових, часових, атрибутивних) та вимог до масштабованості. Відсутність єдиних рекомендацій чи порівнять використання DNN у різних доменах ускладнює адаптацію моделей до унікальних особливостей бізнес-процесів [15] [22].

Метою дослідження є оцінка ефективності різних архітектур нейронних мереж для виявлення аномалій у бізнес-процесах різними метриками з урахуванням специфіки даних, складності процесів та вимог до масштабованості. Особлива увага приділяється порівнянню таких архітектур, як RNN, GNN, Autoencoders, LSTM та Transformers, а також їх адаптації до специфічних типів бізнес-процесів. Стаття спрямована на визначення найбільш ефективних підходів для моніторингу та ідентифікації аномалій у реальному часі, що дозволить підвищити продуктивність і точність аналізу в умовах цифрової трансформації.

Постановка завдання. Огляд сучасних підходів до виявлення аномалій за допомогою глибоких нейронних мереж, з акцентом на порівняння ефективності різних архітектур для різних типів бізнес-процесів, таких як ERM, HR, фінансові операції, документообіг і логістика. Аналіз переваг і обмежень кожної архітектури, а також їх здатності до адаптації та застосування в реальних бізнес-сценаріях. Оцінка можливостей кожної архітектури для покращення внутрішнього управління бізнесом та своєчасного виявлення аномалій у процесах.

Виклад основного матеріалу дослідження. Набір даних для дослідження було отримано з BPMS-системи, що функціонує на базі платформи Camunda для управління бізнес-процесами. Були вилучені не лише базові журнали подій (event logs), а й повноцінні цикли виконання процесів, включаючи взаємозв'язки між підпроцесами та зовнішніми викликами. Використовувались сучасні підходи до автоматичного відновлення прихованих потоків даних у бізнес-процесах [24]. Отримані графи були додатково збагачені бізнес-параметрами, такими як бюджет, категорії завдань, тривалість виконання та інші характеристики, що забезпечило можливість аналізувати їх як реальні бізнес-процеси [24], забезпечуючи релевантність отриманих даних для задач виявлення аномалій.

В рамках дослідження були сформовані графи бізнес-процесів на основі наступного підходу:

1. Завантаження даних про виконання завдань з бази даних та співставлення їх з BPMN діаграмами.

2. Побудова маршрутів виконання, враховуючі ієрархію вкладених підпроцесів і зовнішніх викликів, з включенням їх в основний граф.

3. Бізнес-процеси моделювалися як орієнтовані графи $G=(V,E)$, де: V – множина вузлів (активності); $E \subseteq V \times V$ – множина зв'язків між вузлами. Кожному вузлу $v_i \in V$ і зв'язку $e_{ij} \in E$ відповідає набір атрибутів: Атрибути вузлів: $A_v(v_i) = \{a_1, a_2, \dots, a_k\}$, де a_k – тривалість виконання, час початку, тип активності тощо.

Атрибути зв'язків: $A_e(e_{ij}) = \{b_1, b_2, \dots, b_m\}$

4. Маршрут виконання моделювався як послідовність подій:

$R_p = \{(v_1, t_1), (v_2, t_2), \dots, (v_n, t_n)\}$, де t_i – часовий штамп виконання v_i .

5. Для забезпечення репрезентативності з аналізу виключалися графи з малою кількістю вузлів або зв'язків $|V| \leq 10$ або $|E| \leq 10$:

$$G_p = (V_p, E_p, A_v(V_p), A_e(E_p), D_p), \text{ де } |V_p| > 10 \wedge |E_p| > 10.$$

6. Фінальний набір включає 1000 графів, кожен із яких представляє завершений або незавершений бізнес-процес із багатозаровою структурою. Кожен вузол

графів відповідає окремій активності або задачі, а зв'язки описують послідовність виконання завдань та виклики між підпроцесами. Документ містить загальні характеристики процесів, що використовуються для побудови графів, забезпечуючи основу для аналізу аномалій у бізнес-процесах.

Таблиця 1

Основні статистичні показники вузлів та зв'язків

Тип	Мінімум, шт	Максимум, шт	Середнє значення, шт	Стандартне відхилення, шт
Вузли	11	323	136,31	85,88
Зв'язки	12	372	145,14	93,34

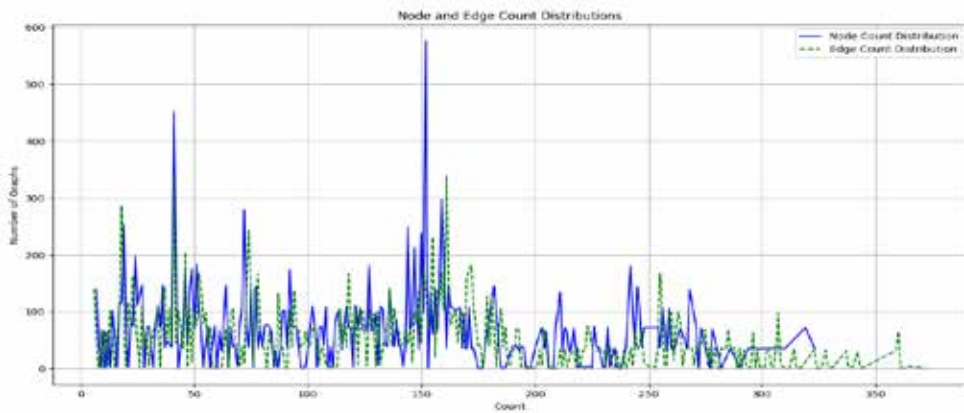


Рис. 1. Розподіл вузлів і зв'язків вказує на значну варіативність складності процесів

Графи бізнес-процесів включають такі атрибути:

Вузли – 8 атрибутів: тип активності, час початку/завершення, тривалість, кількість викликів, час прострочення.

Зв'язки – 3 атрибути: код дії, тривалість переходу, прострочення переходу.

Документи – 9 атрибутів: бюджет, ціна, дати, класифікаційні атрибути.

Для забезпечення глибокого аналізу бізнес-процесів, ключові характеристики визначались, базуючись на рекомендаціях Aalst W. (2016) Process Mining: Data Science in Action [1]. При побудові промислового рішення, інтеграція з Camunda та BPMS дозволяє використовувати ці дані для прогнозування продуктивності та покращення виконання завдань у реальному часі [20].

Для побудови навчальної бази, було згенеровано 15,000 графів шляхом автоматизованої модифікації графів реальних бізнес-процесів. Для кожного вихідного графа $G = (V, E)$ створювалося до 15 нормальних варіацій за допомогою модифікації атрибутів вузлів і зв'язків (тривалість виконання, частота викликів тощо) у межах допустимого діапазону [14]. Реконфігурації топології, включаючи додавання нових вузлів або зв'язків із параметрами, що відповідають середнім значенням вихідних графів [9]. Цей підхід, базувався на сучасних методах аналізу графів [6], забезпечив репрезентативність і збалансованість вибірки для навчання моделей.




Рис. 2. Приклади отриманих графів бізнес-процесів.

Для створення бази з аномальними даними – було сформовано 8,000 графів із чотирма типами аномалій: *Missing Steps*, *Duplicate Steps*, *Wrong Route*, *Abnormal Duration*. Вибір цих типів ґрунтується на їхній поширеності у бізнес-процесах та значному впливі на ефективність управління [11] [25]. Для кожного вихідного графа $G=(V, E)$, використовуюваного як основа, створювалися аномальні графи $G'=(V', E')$ по 2,000 графів на тип. Нижче наведено опис кожного типу аномалій:

- **Missing Steps (Пропущені кроки).** Видалення одного або кількох вузлів із графа, що порушує логіку виконання процесу, призводячи до втрати важливих етапів. Такий тип аномалій поширений у контексті аналізу змін у потоках даних [8]. Для графа $G=(V, E)$:

$$G'=(V', E'), \quad V'=V \setminus \{v_i : v_i \in V\}, \quad E'=\{e_{ij} : v_i, v_j \in V'\}.$$

- **Duplicate Steps (Дублювання кроків).** Додавання дубльованих вузлів або циклічних елементів, що спричиняє надмірну кількість виконань завдань, впливаючи на ефективність процесу [9]. Для графа $G=(V, E)$:

$$G'=(V', E'), \quad V'=V \cup \{v'_i : v'_i = v_i, i \in \mathcal{I} \subseteq V\}, \quad E'=E \cup \{e_{ij} : i, j \in \mathcal{I}\}.$$

- **Wrong Route (Неправильний маршрут).** Порушення логічного потоку виконання завдань шляхом зміни напрямку зв'язків у графі. Це може відображати помилки у послідовності виконання [21]. Для графа $G=(V, E)$:

$$G'=(V, E'), \quad E'=E \setminus \{e_{ij}\} \cup \{e_{ji} : e_{ij} \in E, i \neq j\}.$$

- **Abnormal Duration (Аномальна тривалість).** Зміна тривалості виконання вузлів за межами допустимого діапазону для моделювання впливу таких відхилень на загальну продуктивність процесу [18]. Для атрибутів вузла $a(v)$:

$$a'(v)=a(v) \cdot (1+\epsilon), \quad \epsilon \in [-\delta, \delta], \quad \delta=0.5.$$

Для коректної обробки даних графи були попередньо нормалізовані з урахуванням числових і текстових атрибутів вузлів, зв'язків і документів. Методика

нормалізації базувалася на підходах, описаних у Data Mining: Concepts and Techniques [13]. Часові атрибути переведені у числовий формат (кількість секунд від початку епохи). Числові атрибути нормалізовані за формулою мінімакс-скей-

лінгу: $x_{norm} = \frac{x - \min(X)}{\max(X) - \min(X)}$, де x – значення атрибута, X – множина значень

атрибута для всіх графів. Текстові атрибути: кодувалися у числові індекси на основі глобального словника: $x_{text_norm} = \text{Index}(x)$, де x – значення текстового атрибута.

Опис експерименту. Експеримент спрямовано на порівняння п'яти архітектур глибоких нейронних мереж (GNN, CNN, RNN (зокрема LSTM), Transformers, Autoencoders) у задачі виявлення аномалій, характерних для бізнес-процесів. Основна мета полягала у визначенні їхньої відносної продуктивності за узгодженими параметрами, встановленими відповідно до сучасних досліджень [13] [6]. Результати дослідження використовуються для визначення сильних і слабких сторін кожної архітектури та формулювання рекомендацій щодо вибору моделей залежно від специфіки домену, складності даних і вимог до продуктивності.

Обмеження:

- Для дослідження використовувались лише графові дані з платформи BPMS Camunda, що обмежує застосування результатів до інших типів вхідних даних (наприклад, текстових документів чи зображень);

- Хоча були досліджені різні метрики, не було проведено достатнього аналізу впливу сильної нерівномірності класів;

- Аномалії створювались синтетичним шляхом;

- Не було досліджено, як моделі адаптуються до змінних або динамічних умов бізнес-процесів, коли з часом йде корегування бізнес процесів, міняються структури даних або типи;

- У дослідженні не було вивчено, як зміна різних гіперпараметрів впливає на продуктивність моделей.

Параметри експериментального середовища: operating system – Win10 21H2; Programming language – Python 3.10; Development framework – PyTorch 2.5.1; CPU – IntelCore i7-1265; RAM – 32G; Training Hardware – CPU with AVX2.

Гіперпараметри:

- Кількість епох: максимум 100 (або до досягнення умов ранньої зупинки при $patience = 10, \delta = 1 \times 10^{-4}$).

- Розподіл даних: 70% – тренування, 20% – валідація, 10% – тестування.

- Learning rate: обране значення 0.001 (логарифмічна сітка значень 0.1, 0.01, 0.001).

- Розмір батча: 64.

- Hidden_dim: для Transformer – 256, для інших архітектур – 64.

- Оптимізатор: AdamW.

- Функція втрат: BCEWithLogitsLoss та MSELoss для Autoencoders.

- Кількість шарів: GNN – 3, RNN (LSTM) – 2, CNN – 3, Autoencoders – 3, Transformers – 4.

Кожна модель навчалась п'ять разів для кожного типу аномалії з фіксованими наборами тестових даних. При кожному розподілі дані в наборі перемішувались випадковим чином. Після кожного навчання вираховувались метрики продуктивності, як середні значення по п'яти результатам.

- Основні метрики: Precision, Recall, Loss, AUPRC, ROC-AUC, F1-score.

- Аномалієспецифічні метрики: ADR (Anomaly Detection Rate), FPR (False Positive Rate), FAR (False Alarm Rate), FNR (False Negative Rate).

• Додаткові показники: час розрахунку кожної епохи, матриця плутанини.
Усі архітектури були реалізовані за єдиним підходом, що враховує два типи вхідних даних:

• Графові дані: Вузли та ребра з відповідними атрибутами подавалися у форматі, специфічному для кожної архітектури. Цей тип даних використовувався для моделювання взаємозв'язків між компонентами процесу.

• Загальні ознаки процесу: Характеристики, пов'язані з графом, які забезпечують додатковий контекст для аналізу (атрибути, не прив'язані до конкретних вузлів чи зв'язків).

Обробка обох типів даних виконувалася окремими підсистемами. Результати комбінувалися через операцію конкатенації та передавалися у повнозв'язний шар, який формував єдине передбачення. Цей підхід забезпечив універсальність і рівність умов обробки для всіх моделей.

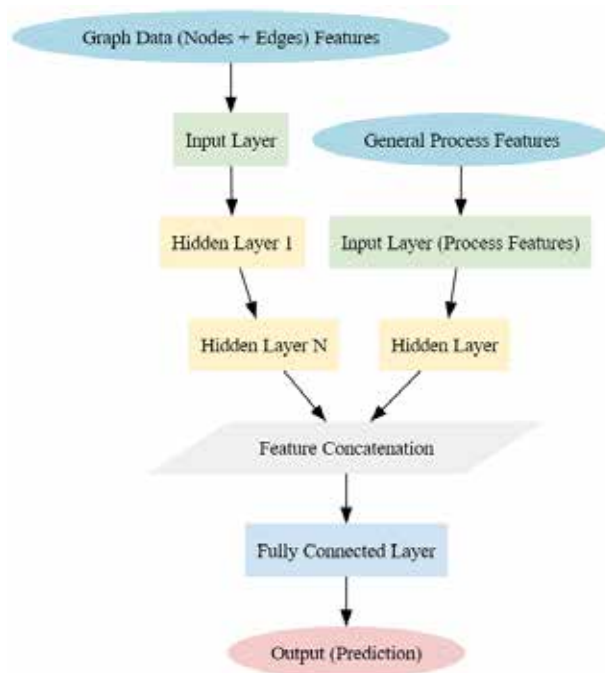


Рис. 3. Узагальнена топологія нейронних мереж для обробки графових даних та загальних ознак

Результати експерименту та аналіз. У цьому розділі представлено результати експериментального дослідження, спрямованого на оцінку ефективності різних архітектур глибоких нейронних мереж для виявлення аномалій у бізнес-процесах.

Precision показує частку правильно виявлених аномалій серед усіх виявлених аномалій: $\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$. Архітектури Autoencoder та Transformers демонструють високу точність і стабільність, зокрема для аномалії «Wrong Route», що робить їх найбільш ефективними для задач виявлення аномалій. Архітектура GNN

показує хороші результати для аномалії «Duplicate Steps», але менш ефективна в інших випадках. Водночас CNN виявляє значну варіативність у результатах, що свідчить про її обмежену придатність для даного типу задач.

Таблиця 2

Середні значення тестових метрик по аномаліям

Тип аномалії	Метрика	GNN	CNN	RNN	Transformers	Auto-encoder
Missing Steps	Precision	0,8143	0,7677	0,7909	0,8049	0,8158
Duplicate Steps		0,8267	0,8053	0,7807	0,7919	0,8143
Wrong Route		0,8143	0,7796	0,8004	0,8449	0,8533
Abnormal Duration		0,7988	0,7835	0,8051	0,8160	0,8098
Missing Steps	Recall	1	1	1	0,9668	0,7949
Duplicate Steps		1	0,7398	1	1	0,8814
Wrong Route		1	0,9975	1	0,9614	0,6432
Abnormal Duration		0,9975	0,9015	1	0,9951	0,7602
Missing Steps	ROC AUC	0,9850	0,9802	0,9876	0,9837	0,9781
Duplicate Steps		0,9847	0,9816	0,9835	0,9864	0,9786
Wrong Route		0,9868	0,9798	0,9811	0,9886	0,9496
Abnormal Duration		0,9813	0,9826	0,9832	0,9822	0,9766
Missing Steps	F1-Score	0,8794	0,8686	0,8920	0,8839	0,8052
Duplicate Steps		0,8914	0,7817	0,8918	0,9178	0,8465
Wrong Route		0,8977	0,8761	0,8992	0,9028	0,7335
Abnormal Duration		0,8889	0,8414	0,8795	0,8938	0,7842
Missing Steps	AUPRC	0,8223	0,7273	0,8082	0,8053	0,8197
Duplicate Steps		0,8438	0,7619	0,7537	0,7877	0,7952
Wrong Route		0,8105	0,7278	0,8169	0,8366	0,7261
Abnormal Duration		0,8638	0,7164	0,7758	0,8015	0,7647
Missing Steps	ADR	0,9803	0,9949	1	1	0,7770
Duplicate Steps		1	0,7293	1	1	0,8582
Wrong Route		1	0,9975	1	0,9614	0,6537
Abnormal Duration		0,9455	0,9975	1	0,9951	0,7955
Missing Steps	FAR	0,0309	0,0328	0,0310	0,0321	0,0241
Duplicate Steps		0,0207	0,0321	0,0368	0,0329	0,0237
Wrong Route		0,0335	0,0311	0,0319	0,0259	0,0214
Abnormal Duration		0,0295	0,0372	0,0364	0,0313	0,0257
Missing Steps	FNR	0,0051	0,0197	0,3947	0	0,2230
Duplicate Steps		0	0,2707	0	0	0,1418
Wrong Route		0,0025	0,0015	0	0	0,3463
Abnormal Duration		0,0025	0,0545	0	0	0,2045

Recall показує частку виявлених аномалій серед усіх аномалій: $\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$.

GNN, Transformers та Autoencoder показують високу ефективність у виявленні аномалій, зокрема для «Missing Steps» та «Wrong Route». CNN демонструє значно

нижчі значення Recall у всіх випадках, що вказує на її непридатність для таких задач. RNN показує середні результати і може бути менш ефективним порівняно з іншими архітектурами. Таким чином, GNN і Autoencoder є найбільш підходящими для виявлення аномалій у бізнес-процесах.




Рис. 4. Показники Precision по кожній аномалії




Рис. 5. Показники Recall по кожній аномалії

F1-Score відображає баланс між точністю та повнотою виявлення:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$
 GNN та Transformers показують найкращі результати по метриці F1-Score, ефективно знижуючи як хибні позитивні, так і хибні негативні спрацьовування, забезпечуючи баланс точності і відтворюваності для всіх аномалій. CNN має нижчі показники, що свідчить про його неефективність у зменшенні цих спрацьовувань. RNN і Autoencoder демонструють середні результати, але не досягають такого балансу, як GNN та Transformers.




Рис. 6. Показники F1-Score по кожній аномалії

ROC AUC показує, наскільки добре модель розрізняє два класи. Усі архітектури демонструють дуже високі значення для всіх аномалій, що свідчить про їх

ефективність у класифікації. Autoencoder показує дещо більші варіації, що свідчить про менш стабільні результати, ймовірно через слабший підхід до виявлення аномалій у дисбалансованих наборах даних.




Рис. 7. Показники ROC AUC по кожній аномалії

AUPRC відображає здатність моделі справлятися з рідкісними аномаліями: $AUPRC = \int_0^1 \text{Precision}(r) \cdot dr$. GNN та Transformers показують найкращі результати, що свідчить про їх здатність ефективно виявляти аномалії, зокрема для «Missing Steps» та «Wrong Route». Autoencoder також демонструє хорошу ефективність, але з більшими варіаціями. CNN має стабільно нижчі значення, що вказує на неефективність для цих задач.




Рис. 8. Показники AUPRC по кожній аномалії

ADR показує здатність моделі ефективно виявляти аномалії: $ADR = \frac{TP}{TP + FN}$. GNN показує найкращі результати для всіх аномалій, що свідчить про ефективність виявлення аномалій. Transformers також демонструють добрі результати, але з деякими варіаціями. RNN та CNN мають більш низькі результати, з особливими спадами для «Duplicate Steps» та «Wrong Route», що свідчить про меншу ефективність цих моделей.

FAR – частка об'єктів, помилково визначених як аномалії: $FAR = \frac{FP}{FP + TN}$. Хоча Autoencoder показує варіації, усі моделі, включаючи GNN, CNN, і RNN, демонструють дуже низькі показники, що свідчить про мінімальні хибні позитивні спрацювання.

FNR визначає частоту пропуску аномалій моделлю: $FNR = \frac{FN}{FN + TP}$. GNN та Transformers показує найкращі результати з найменшим рівнем хибних негативних

спрацьовувань для всіх аномалій, що свідчить про високу ефективність цієї архітектури. CNN демонструє значне збільшення FNR, особливо для «Wrong Route» та «Duplicate Steps», що вказує на її низьку здатність до виявлення цих аномалій. RNN може пропускати аномалії «Missing Steps».




Рис. 9. Показники ADR по кожній аномалії




Рис. 10. Показники FAR по кожній аномалії




Рис. 11. Показники FNR по кожній аномалії

Більш детальне розподілення тестових результатів відображено на матриці плутанини.

При аналізі записувався час навчання кожної епохи. Середні показники виконання кожної епохи відображені на діаграмі. Transformers показали найвищий час обробки, що вказує на високу обчислювальну складність, тоді як GNN, CNN і Autoencoders мають значно менші витрати часу на навчання.

Висновки. Аналізуючи всі метрики з різних аспектів, можна зробити висновок, що різні архітектури нейронних мереж демонструють відмінну ефективність у виявленні специфічних типів аномалій. Зокрема, GNN досягли найвищих показників точності у виявленні «Duplicate Steps» та «Missing Steps», тоді як Transformers показали найкращі результати для «Wrong Route» та «Abnormal Duration».

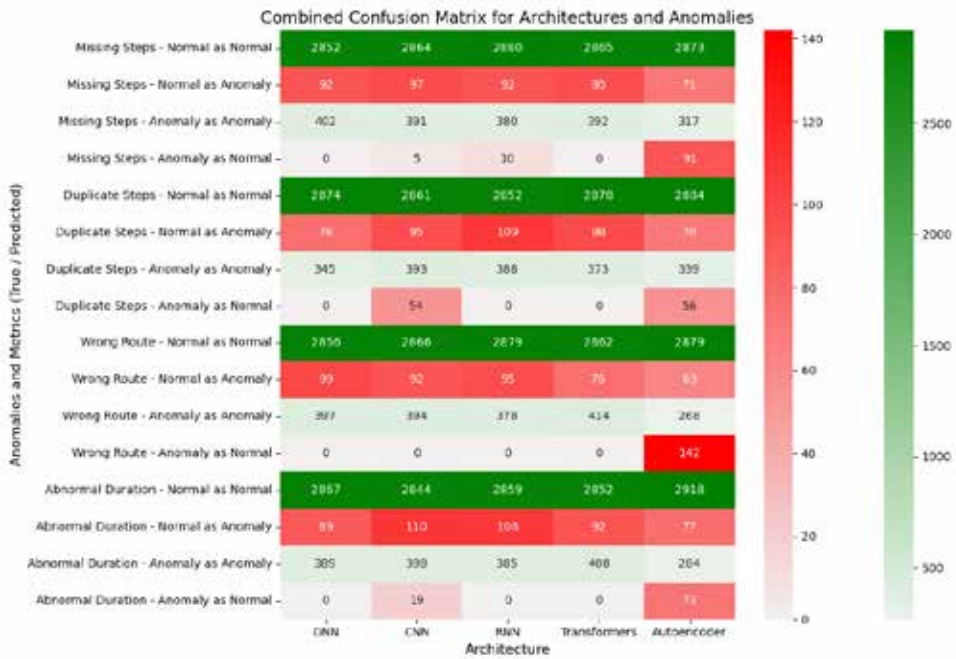


Рис. 12. Матриця плутанини по кожній аномалії

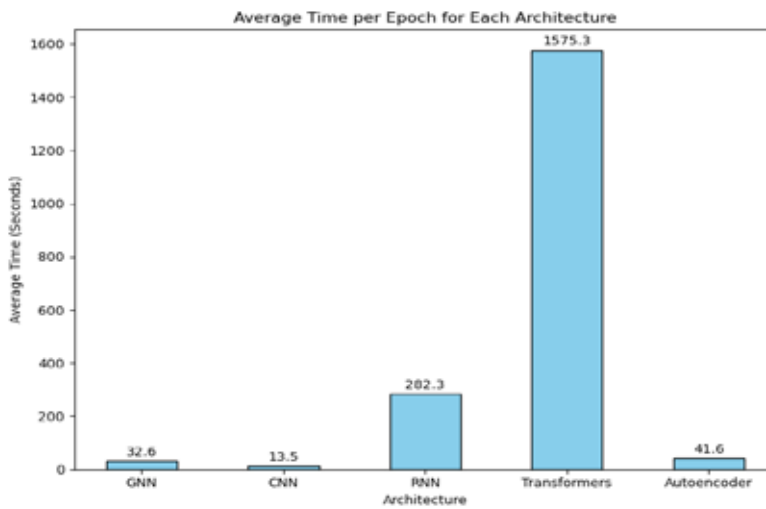


Рис. 13. Порівняння середнього часу навчання по архітектурам на епоху

GNN, Transformers та LSTM демонструють відмінні результати за такими критеріями, як точність і відтворюваність, що робить їх дуже ефективними для складних бізнес-процесів, таких як управління ресурсами та фінансові операції. Однак LSTM та Transformers є дуже вимогливими до ресурсів, що може стати обмеженням для їх впровадження в організації з обмеженими обчислювальними потужностями.

Таблиця 3

Рейтинг здатності виявляти аномалії за типами аномалій

Тип аномалії	GNN	CNN	RNN	Transformers	Autoencoders
Missing Steps	1	5	3	2	4
Duplicate Steps	1	4	3	2	5
Wrong Route	3	5	2	1	4
Abnormal Duration	3	5	2	1	4

Таблиця 4

Загальний висновок та рекомендації по використанню архітектур

Архітектура	Сильні сторони	Слабкі сторони	Рекомендоване застосування
GNN	Висока точність виявлення складних структурних аномалій	Вимогливість до підготовки даних (графів)	Виявлення структурних аномалій у логістичних процесах та документообігу.
CNN	Мінімальні вимоги до обчислювальних ресурсів при достатньо високій продуктивності	Обмежена ефективність для складних взаємозв'язків бізнес-процесів	Просторові аномалії, задачі з чітко визначеними межами вхідних даних.
RNN	Добра продуктивність для часових рядів	Висока обчислювальна складність	Прогнозування часових рядів, де потрібна адаптація до довгих залежностей.
Transformers	Висока точність і стабільність	Дуже високі вимоги до обчислювальних ресурсів.	Складні багатовимірні процеси, де важливі точність та гнучкість.
Autoencoders	Ефективність для атрибутивних даних	Низька ефективність для графових структур, варіативність метрик	Процеси та управління документацією, де переважають атрибутивні дані.

Архітектура Autoencoders не продемонструвала високої ефективності для задач, де є складні графові зв'язки, однак вони можуть бути корисними у випадках, де переважають атрибутивні дані, наприклад, для HR-процесів чи управління документообігом.

CNN показує варіативність у результатах, що може обмежити його застосування в складних бізнес-процесах, особливо в процесах, де важливо не пропустити аномалію, таких як комплаєнс чи юридичні процеси. Проте, CNN може бути корисним у бізнес-процесах, що вимагають обробки складних послідовностей або зображень. Враховуючи менші вимоги до обчислювальних ресурсів порівняно з Transformers та LSTM, CNN може бути оптимальним вибором для організацій з обмеженими обчислювальними можливостями.

GNN має здатність працювати з графовими даними, що робить її особливо ефективною для виявлення структурних аномалій у складних мережах, таких як логістичні процеси або документообіг, де важливо виявляти неочевидні зв'язки

між підпроцесами. Це дозволяє швидше виявляти системні порушення та покращувати управлінські рішення, що в свою чергу сприяє підвищенню ефективності бізнесу.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ:

1. Aalst W. Van der Process Mining. Berlin, Heidelberg : Springer Berlin Heidelberg, 2016. 1-467 p. DOI:10.1007/978-3-662-49851-4.
2. Al-Jebrni A., Cai H., Jiang L. Predicting the Next Process Event Using Convolutional Neural Networks. *2018 IEEE International Conference on Progress in Informatics and Computing (PIC)*(12.2018). IEEE, 2018. DOI:10.1109/PIC.2018.8706282. P. 332–338.
3. Alizadeh M., Leoni M. de, Zannone N. History-Based Construction of Alignments for Conformance Checking: Formalization and Implementation. 2015. P. 58–78. DOI:10.1007/978-3-319-27243-6_3.
4. Ariyaluran Habeeb R. A., Nasaruddin F., Gani A. et al. Real-time big data processing for anomaly detection: A Survey. *International Journal of Information Management*. Vol. 45, 01.04.2019. P. 289–307. DOI:10.1016/j.ijinfomgt.2018.08.006.
5. Bezerra F., Wainer J. Anomaly Detection Algorithms In Business Process Logs. *Proceedings of the Tenth International Conference on Enterprise Information Systems*(2008). SciTePress – Science and Technology Publications, 2008. DOI:10.5220/0001674700110018. P. 11–18.
6. Cai J., Zhang Y., Fan J. Self-Discriminative Modeling for Anomalous Graph Detection. 09.10.2023. URL: <http://arxiv.org/abs/2310.06261>
7. Chen J., Sathe S., Aggarwal C. et al. Outlier Detection with Autoencoder Ensembles. *Proceedings of the 2017 SIAM International Conference on Data Mining*. Philadelphia, PA : Society for Industrial and Applied Mathematics, 2017. P. 90–98. DOI :10.1137/1.9781611974973.11.
8. Darmawan H., Sarno R., Ahmadiyah A. S. et al. Anomaly detection based on control-flow pattern of Parallel Business Processes. *Telkomnika (Telecommunication Computing Electronics and Control)*. Vol. 16, Issue 6. P. 2809–2816. DOI:10.12928/TELKOMNIKA.v16i6.10568.
9. Eberle W., Holder L. Discovering Structural Anomalies in Graph-Based Data. *Seventh IEEE International Conference on Data Mining Workshops (ICDMW 2007)* (10.2007). IEEE, 2007. DOI:10.1109/ICDMW.2007.91. P. 393–398.
10. Galanti R., Coma-Puig B., Leoni M. de et al. Explainable Predictive Process Monitoring. *2020 2nd International Conference on Process Mining (ICPM)*(10.2020). IEEE, 2020. DOI:10.1109/ICPM49681.2020.00012. P. 1–8.
11. Gong Z., Fang X., Wu P. Anomaly Correction of Business Processes Using Transformer Autoencoder. 2024. P. 1–16. Also available online, URL: <http://arxiv.org/abs/2404.10211>
12. Guan W., Cao J., Yao Y. et al. COMB: Interconnected Transformers-Based Autoencoder for Multi-Perspective Business Process Anomaly Detection. *2024 IEEE International Conference on Web Services (ICWS)*(07.07.2024). IEEE, 2024. DOI:10.1109/ICWS62655.2024.00134. P. 1115–1124.
13. Ha J., Kambe M., Pe J. Data Mining: Concepts and Techniques. 2011. 1-703 p. DOI:10.1016/C2009-0-61819-5.
14. Ioannidis V. N., Berberidis D., Giannakis G. B. GraphSAC: Detecting anomalies in large-scale graphs. 21.10.2019. P. 1–13. Also available online, URL: <http://arxiv.org/abs/1910.09589>
15. Ji Y., Wang J., Li S. et al. An Anomaly Event Detection Method Based on GNN Algorithm for Multi-data Sources. *Proceedings of the 3rd ACM International Symposium on Blockchain and Secure Critical Infrastructure*(24.05.2021). New York, NY, USA : ACM, 2021. DOI:10.1145/3457337.3457846. P. 91–96.

16. Landauer M., Onder S., Skopik F. et al. Deep learning for anomaly detection in log data: A survey. *Machine Learning with Applications*. Vol. 12, Issue March. P. 100470. DOI:10.1016/j.mlwa.2023.100470.
 17. Ni W., Zhao G., Liu T. et al. Predictive Business Process Monitoring Approach Based on Hierarchical Transformer. *Electronics*. Vol. 12, Issue 6. P. 1273. DOI:10.3390/electronics12061273.
 18. Nolle T., Luetgten S., Seeliger A. et al. Analyzing business process anomalies using autoencoders. *Machine Learning*. Vol. 107, Issue 11. P. 1875–1893. DOI:10.1007/s10994-018-5702-8.
 19. Nolle T., Luetgten S., Seeliger A. et al. BINet: Multi-perspective business process anomaly classification. *Information Systems*. Vol. 103, 01.2022. P. 101458. DOI:10.1016/j.is.2019.101458.
 20. Park G., Song M. Predicting performances in business processes using deep neural networks. *Decision Support Systems*. Vol. 129, Issue November 2019. P. 113191. DOI:10.1016/j.dss.2019.113191.
 21. Vidacic T., Strahonja V. Taxonomy of Anomalies in Business Process Models. *Information System Development*. Cham : Springer International Publishing, 2014. P. 283–294. DOI:10.1007/978-3-319-07215-9_23.
 22. Wang Z., Chen Z., Ni J. et al. Multi-Scale One-Class Recurrent Neural Networks for Discrete Event Sequence Anomaly Detection. *Proceedings of the 27th ACM SIGKDD Conference on Knowledge Discovery & Data Mining*(14.08.2021). New York, NY, USA : ACM, 2021. DOI:10.1145/3447548.3467125. P. 3726–3734.
 23. Weinzierl S., Zilker S., Dunzer S. et al. Machine learning in business process management: A systematic literature review. *Expert Systems with Applications*. Vol. 253, 01.11.2024. P. 124181. DOI:10.1016/j.eswa.2024.124181.
 24. Ye S., Wang J., Ali S. et al. Recovering Latent Data Flow from Business Process Model Automatically. *Wireless Communications and Mobile Computing*. ed. Y. Wang. Vol. 2022, 20.06.2022. P. 1–11. DOI:10.1155/2022/7579515.
 25. Zhao D., Zhou Z. Anomaly and Interestingness Detection in Timed Hierarchical Business Processes. *IEEE Transactions on Engineering Management*. Vol. 71, 2024. P. 12619–12634. DOI:10.1109/TEM.2022.3182413.
-