

УДК 004.5

DOI <https://doi.org/10.32689/maup.it.2025.3.24>

**Олександр ХОМЕНКО**

аспірант кафедри інженерії програмного забезпечення в енергетиці,  
Навчально-науковий інститут атомної та теплової енергетики,  
Національний технічний університет України  
«Київський політехнічний інститут імені Ігоря Сікорського»,  
[khomenkosasha99@gmail.com](mailto:khomenkosasha99@gmail.com)  
ORCID: 0000-0003-1964-1097

**Олександр КОВАЛЬ**

доктор технічних наук, професор, завідувач кафедри інженерії програмного забезпечення в енергетиці,  
Навчально-науковий інститут атомної та теплової енергетики,  
Національний технічний університет України  
«Київський політехнічний інститут імені Ігоря Сікорського»,  
[avkoval@gmail.com](mailto:avkoval@gmail.com)  
ORCID: 0000-0003-0991-6405

**АНАЛІЗ ТА ПОРІВНЯННЯ СЦЕНАРІЇВ КАСКАДНИХ ЕФЕКТІВ В КРИТИЧНІЙ ІНФРАСТРУКТУРІ**

**Анотація.** Дослідження сценаріїв каскадних ефектів в критичній інфраструктурі відіграє важливу роль для прийняття рішень, щоб зменшити негативні наслідки. Дані про роботу критичної інфраструктури є закритими або обмеженими, що ускладнює процес аналізу каскадних ефектів. Для генерування та аналізу сценаріїв каскадних ефектів використовуються різні підходи: графові моделі, моделі потоку потужності, гібридні підходи, які використовуються відповідно до поставлених задач. Розвиток машинного навчання супроводжується появою нових перспективних підходів, що використовуються для дослідження властивостей роботи електромереж в різних сценаріях.

**Метою статті** є дослідження каскадних ефектів в критичній інфраструктурі та створення методу для аналізу та порівняння сценаріїв каскадних ефектів в електромережі, використовуючи графову нейронну мережу та коефіцієнт подібності.

**Методологія.** У статті описано процес створення даних в сценаріях роботи електромережі при виведенні компонентів системи, що потенційно можуть призвести до каскадного ефекту. Розроблено модель автоенкодера на основі графової нейронної мережі, що використовується для формування представлення про крок сценарію (стан електромережі). Косинус подібності використано для порівняння кроків в різних сценаріях та пошуку подібних станів мережі. На основі подібності сценаріїв про стани електромережі можливо зробити висновки про можливий розвиток каскадного ефекту в сценарії.

**Наукова новизна** роботи полягає у розробці методу, що покращує процес аналізу сценаріїв каскадних ефектів, порівняння послідовностей подій в сценаріях, визначення подібних ситуацій для прийняття рішень на основі існуючого досвіду. Визначено можливості для розширення методу, використовуючи поєднання графової нейронної мережі та LSTM для формування комплексного представлення послідовності кроків в сценаріях.

**Висновки.** Проведено дослідження підходів для аналізу каскадних ефектів в електромережах. На основі проведеного дослідження було визначено перспективні напрямки, які потенційно можуть покращити процес порівняння сценаріїв каскадних ефектів. Для аналізу та порівняння сценаріїв каскадних ефектів в критичній інфраструктурі (електромережі) було розроблено метод, що використовує модель автоенкодера, що містить розроблений шар графової нейронної мережі, який покращує точність роботи моделі при вивченні зв'язків, впливу параметрів компонентів в електромережі та формує представлення стану електромережі в кроці сценарію. Використано косинус подібності для пошуку схожих сценаріїв, що потенційно можуть доповнити інформацію про стан електромережі в наступних кроках сценарію. Розроблений метод може працювати з різним рівнем деталізації сценаріїв, що забезпечує його адаптивність до вхідних даних.

**Ключові слова:** критична інфраструктура, машинне навчання, нейронна мережа, коефіцієнт подібності, графи, каскадний ефект, моделювання подій.

**Oleksandr KHOMENKO, Oleksandr KOVAL. ANALYSIS AND COMPARISON OF CASCADE EFFECT SCENARIOS IN CRITICAL INFRASTRUCTURE**

**Abstract.** The study of cascading effects scenarios in critical infrastructure plays an important role in decision-making to reduce negative consequences. Data on the operation of critical infrastructure is closed or limited, which complicates the process of analyzing cascading effects. Various approaches are used to generate and analyze cascading effects scenarios: graph models, power flow models, hybrid approaches that are used in accordance with the tasks. The development of machine learning is accompanied by the emergence of new promising approaches used to study the properties of power grids in various scenarios.

© О. Хоменко, О. Коваль, 2025

Стаття поширюється на умовах ліцензії CC BY 4.0

**The aim of the article** is to investigate cascading effects in critical infrastructure and to create a method for analyzing and comparing cascading effects scenarios in the power grid using a graph neural network and similarity coefficient.

**Methodology.** The article describes the process of generating data in power grid scenarios when deriving system components that can potentially lead to a cascade effect. An autoencoder model based on a graph neural network is developed, which is used to form a representation of the scenario step (power grid state). The cosine of similarity is used to compare steps in different scenarios and search for similar network states. Based on the similarity of scenarios about power grid states, it is possible to draw conclusions about the possible development of a cascade effect in the scenario.

**The scientific novelty of the work** lies in the development of a method that improves the process of analyzing cascading effects scenarios, comparing sequences of events in scenarios, and identifying similar situations for decision-making based on existing experience. Possibilities for expanding the method are identified, using a combination of a graph neural network and LSTM to form a complex representation of the sequence of steps in scenarios.

**Conclusions.** A study of approaches to the analysis of cascading effects in power grids was conducted. Based on the conducted study, promising directions were identified that could potentially improve the process of comparing cascading effect scenarios. To analyze and compare cascading effect scenarios in critical infrastructure (power grid), a method was developed that uses an autoencoder model containing a developed graph neural network layer, which improves the accuracy of the model when studying connections, the influence of component parameters in the power grid, and forms a representation of the power grid state in the scenario step. The cosine of similarity was used to search for similar scenarios that could potentially supplement information about the power grid state in subsequent steps of the scenario. The developed method can work with different levels of scenario detail, which ensures its adaptability to input data.

**Key words:** critical infrastructure, machine learning, neural network, similarity coefficient, graphs, cascading effect, event modeling.

**Постановка проблеми.** Критична інфраструктура – комплексна система, яка складається з множини об'єктів, зв'язків між ними та відіграє важливу роль для забезпечення надання послуг в сучасному суспільстві. Протягом останніх років складність критичної інфраструктури збільшується, а збій в роботі пов'язаних системах може призвести до небезпечного явища – каскадного ефекту. Важливим об'єктом критичної інфраструктури є електромережі, які забезпечують електроенергією побутових споживачів та промислові об'єкти. Електромережі є комплексними об'єктами, де використовуються інструменти моніторингу, захисту та стабілізації мережі при виникненні потенційних збоїв. Але попри існуючі підходи системи є вразливими до каскадних ефектів, що виникають внаслідок збоїв та призводять до повного чи часткового знеструмлення мережі (блекаут). На виникнення та розвиток каскадних ефектів впливають різні чинники, наприклад: природні умови, несправність в обладнанні, помилки операторів. Знеструмлення були в різних країнах світу та мали різні передумови та наслідки, наприклад:

- 30 і 31 липня 2012 року в Індії знеструмлення вплинуло на 400 мільйонів людей та 620 мільйонів людей відповідно [28].
- 14–16 серпня 2003 року в США та Канаді знеструмлення вплинуло приблизно на 55 мільйонів людей [20].
- 28 вересня 2003 року в Італії знеструмлення вплинуло на приблизно 56 мільйонів людей [27].
- 28 вересня 2016 року в Південній Австралії знеструмлення сталося у результаті шторму та вплинуло на 850 тисяч споживачів [29].

Пошкодження об'єктів критичної інфраструктури в Україні вплинуло на забезпечення користувачів електроенергією:

- 20 травня 2022 року без електропостачання залишилося приблизно 635,8 тисячі споживачів [2].
- 1 червня 2022 року без електропостачання залишилося приблизно 632 тисячі споживачів [3].
- 10 червня 2022 року без електропостачання залишилося приблизно 640,75 тисяч споживачів [4].

Відключення електроенергії зазвичай негативно впливають на залежні інфраструктури. Наприклад, транспортна інфраструктура: виникають проблеми з логістикою, утворюються затори із транспортних засобів на дорогах у населених пунктах, що ускладнює переміщення населення. Затори на дорогах ускладнюють екстреним службам виконувати свою роботу, що може бути критичним у певних обставинах. Крім того перебої в логістиці негативно впливають на залежні сектори економіки. Зменшення потужності роботи електромережі може вплинути на роботу водопостачання. Зниження тиску води або її відсутність в системі, потенційно може погіршити якість води. Цей процес є прикладом каскадного ефекту, що був породжений відключенням компонентів в електромережі, а наслідки з'явилися в інших секторах.

**Аналіз останніх досліджень та публікацій.** Об'єкти критичної інфраструктури та зв'язки між ними описуються за допомогою графу  $G=(V,E)$ , де  $|V|=n$  – кількість вершин,  $|E|=m$  – кількість ребер (дуг). Взаємозалежності в критичній інфраструктурі класифікуються як [22]:

- Фізичний. Наприклад, збій енергосистем впливає на роботу світлофорів для регулювання перехресть.

- Кібернетичний. Наприклад, відсутність електроенергії призводить до перебоїв зв'язку, погіршується комунікація між об'єктами системи.
- Географічний. Наприклад, при виникненні сильних поривів вітру можуть бути пошкоджені лінії електропередачі.
- Логічний. Наприклад, при обмеженні руху по деяким маршрутах зростає завантаженість доріг на альтернативних маршрутах.

Розвиток каскадних ефектів поділяється на фази [18]:

1. Попередня фаза. Відбувається повільний прогрес збоїв.
2. Фаза ескалації. Збої стрімко поширюються, запобігання відключень стає складнішим.
3. Фаза каскадного поетапного припинення роботи. Швидкість розповсюдження збоїв сповільнюється, значна кількість компонентів системи вже вийшли з ладу.

Оскільки негативний вплив каскадних ефектів може бути зменшений на початковому етапі, тому доцільно досліджувати існуючі та потенційні сценарії роботи інфраструктури при виникненні та розвитку каскадних ефектів [5–7].

Для дослідження властивостей графів (міцності мережі) використовуються метрики, які згруповано в шість категорій [21]:

- Кластеризація (Clustering).
- Зв'язність (Connectivity).
- Відстань (Distance).
- Пропускна здатність (Throughput).
- Спектральні методи (Spectral Methods).
- Географічні метрики (Geographical Metrics).

Графові спектральні методи (Graph Spectral Techniques) застосовуються для управління водопровідною мережею та можуть бути використані для [10]:

- Виявлення вузьких місць (bottlenecks) за допомогою значень спектрального розриву (spectral gap). Чим більше значення спектрального розриву, тим стійкішою є мережа.
- Вимірювання міцності (strength) мережі для розбиття на підмережі. Алгебраїчна зв'язність (Algebraic connectivity) визначає міцність з'єднань мережі і стійкість до збоїв: чим більше значення алгебраїчної зв'язності, тим стійкішою є мережа. Спектральний радіус або індекс (Spectral radius or Index) може використовуватися для оцінки рівня зв'язності мережі [10].

Теорія графів використовується для аналізу вразливостей транспортних мереж [17]:

1. Середня відстань між усіма парами вершин графу (Average distance): чим нижче значення метрики, тим сильніша зв'язність [12].
2. Ефективність (Efficiency): чим вище значення метрики, тим більша міцність мережі [12].

Для оцінки міцності мережі можливо використовувати Average Edge Betweenness та Average Vertex Betweenness: чим менше значення метрик, тим більша міцність мережі [12].

Топологічний та гібридний підхід на основі теорії складних мереж використовується для визначення стійкості та вразливості в електромережах [9]. Для оцінки характеристик об'єктів використовуються різні метрики, наприклад: average path length, node degree distribution, betweenness, size of the largest component та ефективність мережі [9]. В гібридному підході використовуються концепції з електротехніки для покращення топологічного підходу. При виникненні збоїв у функціонуванні компонентів електромережі електроенергія перенаправляється відповідно до законів Кірхгофа та Ома, які зазвичай ігноруються в топологічних моделях, що може призвести до помилкових висновків [15; 16], оскільки каскадні збої в електричних мережах поширюються не локально, що ускладнює процес аналізу каскадних ефектів.

Аналіз потоку потужності (Power Flow Analysis) використовується для аналізу роботи енергосистеми, відіграє важливу роль при проектуванні мережі, дослідженні роботи компонентів при різних вхідних даних. Електромережа моделюється за допомогою графу, який складається з: вузлів (nodes), що представляють навантаження (споживачами можуть бути пов'язані критичні інфраструктури), генератори, шунти; гілок (branches), що представляють трансформатори та лінії електропередачі. Для кожної шини обчислюються величини (задані дві з цих чотирьох величин, а інші дві є невідомими):

1. величини напруги (voltage magnitude,  $|V|$ );
2. кута напруги (voltage phase angle,  $\delta$ );
3. реальної потужності (injected real power,  $P$ );
4. реактивної потужності (injected reactive power,  $Q$ ).

На основі відомих величин кожна із шин може бути класифікована як [31]: Slack bus, PQ bus, PV bus.

Таблиця 1

## Категорії шин в електромережі при моделюванні

Тип шини	P	Q	V	$\delta$
Slack	Не задано	Не задано	Задано	Задано
PQ	Задано	Задано	Не задано	Не задано
PV	Задано	Не задано	Задано	Не задано

Рівняння для активної та реактивної потужності визначаються як:

$$P_i = \sum_{k=1}^N |V_i| |V_k| (G_{ik} \cos \delta_{ik} + B_{ik} \sin \delta_{ik}) \quad (1)$$

$$Q_i = \sum_{k=1}^N |V_i| |V_k| (G_{ik} \sin \delta_{ik} - B_{ik} \cos \delta_{ik}) \quad (2)$$

де  $\delta_{ik} = \delta_i - \delta_k$  – різниця фазових кутів між вузлом  $i$  та  $k$ .

Рівняння потоку потужності можуть бути розв'язані за допомогою чисельних методів. При збільшенні розмірності, складності мережі обчислювальна складність моделі зростає, що ускладнює процес аналізу сценаріїв.

В останні роки машинне навчання (machine learning) та глибоке навчання (deep learning) стрімко розвиваються, розроблюються нові підходи для аналізу каскадних збоїв в енергосистемах [18]. Одним із підходів для прогнозування каскадних збоїв є використання графових нейронних мережі (Graph Neural Networks) [8], які також можуть використовуватися для онлайн-прогнозування каскадних збоїв в електромережах [24]. Дослідження показують перспективи використання графових нейронних мереж для аналізу каскадних ефектів в електромережах та можливості для покращення результатів відповідно до поставлених задач. Для тренування та валідації роботи нейронних мереж потрібні набори даних, що описують сценарії каскадних ефектів в електромережах. Оскільки дані про роботу критичної інфраструктури (електромереж) є обмеженими або недоступними, то виникає необхідність у створенні штучних сценаріїв розвитку каскадних ефектів в електромережах. Для симуляції сценаріїв роботи електромережі (каскадних збоїв та їх розвиток) використовуються фізичні моделі та ймовірнісні моделі [14]. Для аналізу стійкості електромереж в роботі може використовуватися модель каскадних відмов змінного струму, яка включає динамічні явища, механізми захисту [19]. Ця модель може бути використана для генерації сценаріїв роботи електромережі при виникненні несправності в компонентах мережі, що потенційно призводить до каскадного ефекту. При аналізі сценаріїв каскадних ефектів в електромережах виникає необхідність в методах, що забезпечують аналіз та порівняння сценаріїв з допустимою похибкою для формування кроків для можливого зменшення наслідків каскаду на основі існуючих знань.

**Метою статті** є розробка методу для аналізу та порівняння сценаріїв каскадних ефектів в критичній інфраструктурі на прикладі електромережі, використовуючи графову нейронну мережу та коефіцієнт подібності. Розроблений метод покращує процес аналізу сценаріїв каскадних ефектів, порівняння послідовностей подій в сценаріях, визначення подібних ситуацій для прийняття рішень на основі існуючого досвіду.

**Виклад основного матеріалу дослідження.** Оскільки дані про роботу електромережі є обмеженими, то виникає потреба у створенні синтетичних сценаріїв роботи електромережі. Для генерації сценаріїв розвитку каскадних ефектів використовується алгоритм, що використовує модель [19] та складається з кроків:

1. Визначити початкові параметри електромережі.
2. Визначити множину об'єктів, що будуть виведені з ладу.
3. Запустити модель потоку потужності.
4. Запустити захисні механізми для компонентів.
5. Визначити статуси та параметри компонентів електромережі.
6. Зберегти результати сценарію.

Нейронні мережі використовуються для виявлення складних закономірностей в даних та складаються з множини нейронів, що утворюють шари: вхідний шар, приховані шари, вихідний шар. При навчанні нейронної мережі використовується пряме поширення (forward propagation) та зворотне поширення (backpropagation): на кожній ітерації ваги та зміщення мережі оновлюються, щоб мінімізувати похибку. При проектуванні нейронної мережі вибір функції активації відіграє важливу роль, оскільки кожна з них має свої особливості та використовується в залежності від задачі та архітектури [11].

Графові нейронні мережі використовуються для вивчення зв'язків в даних на основі графів. Завдання на основі графових даних можуть бути класифіковані у наступні категорії [25]: Node Level Task (Завдання рівня вузла), Edge Level Task (Завдання рівня ребра), Graph Level Task (Завдання рівня графа).

Завдання рівня вузла діляться на чотири категорії:

- Класифікація вузлів (Node classification) – визначення класів вузлів на основі їхніх ознак та зв'язків.
- Регресія вузлів (Node regression) – прогнозування числових значень для вузлів.
- Кластеризація вузлів (Node clustering) – поділ вузлів на класи та групування вузлів з подібними характеристиками.
- Виявлення аномалій вузлів (Node anomaly detection) – ідентифікація вузлів графа, які відрізняються від визначених характеристик.

Завдання рівня ребра поділяються на категорії:

- Прогнозування зв'язків (Link prediction) – визначення ймовірності створення ребра між двома вузлами на основі структури графа та характеристик вузлів.
- Класифікація ребер (Edge classification) – прогнозування класу для ребер в графі (наприклад, категорія або статус ребра).
- Регресія ребер (Edge regression) – завдання прогнозування числових значень для ребер у графі.
- Кластеризація ребер (Edge clustering) – групування подібних ребер у графі в кластери на основі їхніх характеристик.
- Виявлення аномальних ребер (Edge outlier detection) – визначення ребер у графі, які відрізняються від характеристик у графі (наприклад, незвичайні ознаки або зв'язки).

Завдання рівня графа визначаються на рівні цілих графів (регресія, класифікація, висновки для графу або підграфу).

Основою графових нейронних мереж (GNN) є фреймворк передачі повідомлень (message-passing neural network) – процес ітеративної передачі повідомлень між вузлами та агрегації інформації від їхніх сусідів, що дозволяє моделі розуміти комплексні зв'язки та залежності в даних на основі графів [13].

Фреймворк передачі повідомлень складається з наступних кроків:

1. Агрегація повідомлень (Aggregation of messages).

Кожен вузол використовує функцію для створення повідомлення для кожного сусіднього вузла. Для кожного вузла  $v$  збирається інформація від його сусідніх вузлів  $N(v)$ . Агреговане повідомлення  $m_v$  для вузла  $v$  обчислюється як агрегування інформації від сусідніх вузлів.

$$m_v = \text{aggregate}(\{h_u, u \in N(v)\}) \quad (3)$$

2. Оновлення (Update).

Оновлення представлення вузла  $h_v$  на основі агрегованого повідомлення  $m_v$  та поточного представлення вузла  $h_v$  виконується за допомогою функції:

$$h_v' = \text{update}(h_v, m_v) \quad (4)$$

Вибір функції aggregate, update та кількості ітерацій залежить від архітектури GNN. Існують різні архітектури графових нейронних мереж, які мають свої особливості [26]. При значному збільшенні глибини графової нейронної мережі (кількості шарів) виникає надмірне згладжування (oversmoothing) [23], яке негативно впливає на роботу моделі.

Метод визначення подібних ситуацій в електромережі для пошуку можливих сценаріїв розвитку каскадного процесу для прийняття рішень складається з наступних кроків:

1. Визначити вхідні дані мережі.
2. Використати модель автоенкодера для формування представлення електромережі в момент часу в сценарії.
3. Знайти подібні стани електромережі в сценаріях: порівняти дані за допомогою коефіцієнту подібності.

**Вхідні дані.** Кожна шина  $i$  має ознаки:

- Чиста активна потужність ( $P_i$ ) визначається як різниця між реальною потужністю ( $P_{gi}$ ), що генерується на цій шині, та реальною потужністю ( $P_{di}$ ), що споживається навантаженнями, які підключені до неї.

- Чиста реактивна потужність ( $Q_i$ ) визначається як різниця між реактивною потужністю ( $Q_{gi}$ ), що генерується на цій шині, та реактивною потужністю ( $Q_{di}$ ), що споживається навантаженнями, які підключені до неї.

- Величина напруги ( $Vm_i$ ).
- Кут напруги ( $Va_i$ ).

Кожна гілка, що з'єднує шини  $i$  та  $j$  має ознаки:

- Pf: реальна потужність, яка походить від шини  $i$  на початку гілки.
- Pt: реальна потужність, яка надходить на шину  $j$  в кінці гілки.
- Qf: реактивна потужність, яка походить від шини  $i$  на початку гілки.
- Qt: реактивна потужність, яка надходить на шину  $j$  в кінці гілки.

Додатково для аналізу можуть додаватися ознака, що відображає стан компонента системи.

**Модель автоенкодера для формування представлення кроку сценарію.** Для формування представлення про стан роботи електромережі в момент часу сценарію використовується модель автоенкодера. Енкодер складається з двох входів, що оброблюють дані про вершини та ребра графа:  $X \in R^D$  – інформація про ознаки вершин та  $E \in R^D$  – інформація про ознаки ребер:

- Інформація про вершини  $z_{ex} \in R^M, M < D$

$$z_{ex} = \sigma_{ex}(W_{ex}X + b_{ex}) \quad (5)$$

- Інформація про ребра  $z_{ee} \in R^M, M < D$

$$z_{ee} = \sigma_{ee}(W_{ee}E + b_{ee}) \quad (6)$$

Після попередньої обробки та зменшення даних дані про вершини та ребра об'єднуються для обробки в спільному шарі та вивчення закономірностей:

$$z_{shared} = z_{ex} || z_{ee} \quad (7)$$

Дані поступово стискаються до визначеного розміру  $z_{emb}$  за допомогою послідовного зменшення розмірності шарів.

Декодер відновлює стиснене представлення  $z_{emb}$  до початкових даних через поступове збільшення розмірності даних:

- Інформація про вершини  $\hat{X}$ :

$$\hat{X} = \sigma_{dx}(W_{dx}z_{shared} + b_{dx}) \quad (8)$$

- Інформація про ребра  $\hat{E}$ :

$$\hat{E} = \sigma_{de}(W_{de}z_{shared} + b_{de}) \quad (9)$$

Результати оцінюються за допомогою функції втрат (loss function), яка складається з двох функцій втрат:

Помилка при відновленні ознак вершин та ребер:

$$Mean Squared Error = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \quad (10)$$

Помилка при відновленні статусів вершин та ребер:

$$Binary Cross Entropy Loss = -[y_i * \log(x_i) + (1 - y_i) * \log(1 - x_i)] \quad (11)$$

Модель автоенкодера, яка складається з лінійних шарів, може мати складнощі при вивченні зв'язків та взаємовпливу компонентів електромережі. Для навчання, валідації та тестування моделі були згенеровані сценарії роботи електромережі, що складається з 9 шин.

При встановлених значеннях параметрів: розмір представлення Embedding\_Size = 80, Epoch = 500 помилка на даних для тренування (Train Loss) = 0.2530, помилка на даних для валідації (Val Loss) = 0.2699, помилка на даних для тестування (Test Loss) = 0.2702. Коефіцієнт детермінації для вершин  $R^2(nodes) = 0.7830$ , коефіцієнт детермінації для ребер  $R^2(edges) = 0.6755$ .

Для роботи з даними у вигляді графу використовуються графові мережі, які потенційно можуть краще оброблювати ознаки графів. В моделі використовується комбінація із лінійних шарів та шарів для обробки графів.

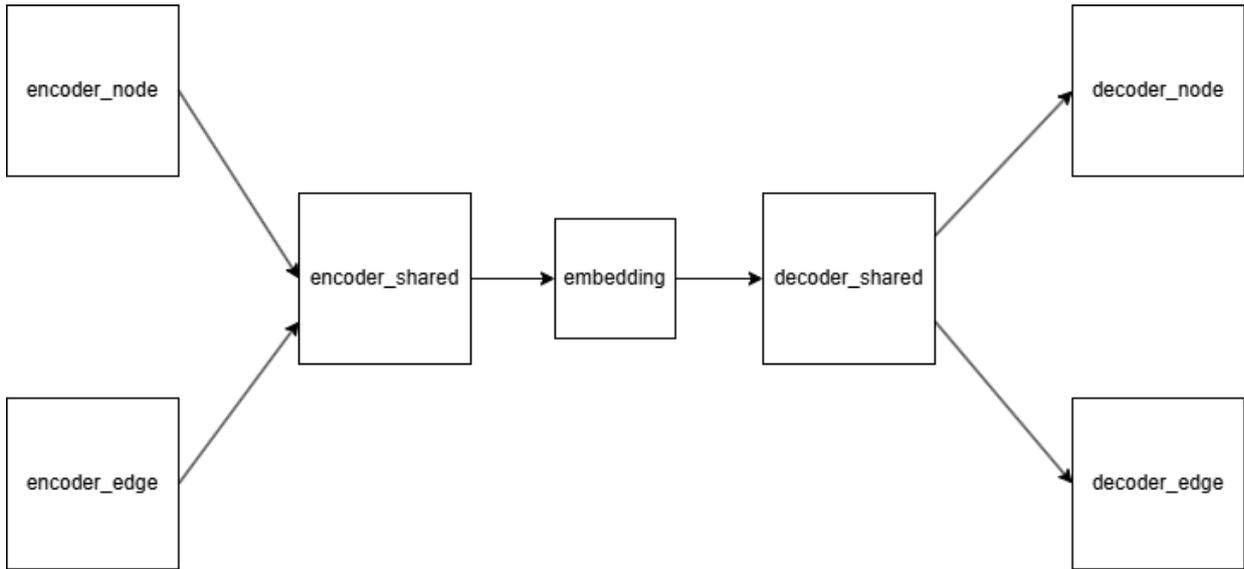


Рис. 1. Архітектура автоенкодера, що оброблює вершини та ребра електромережі

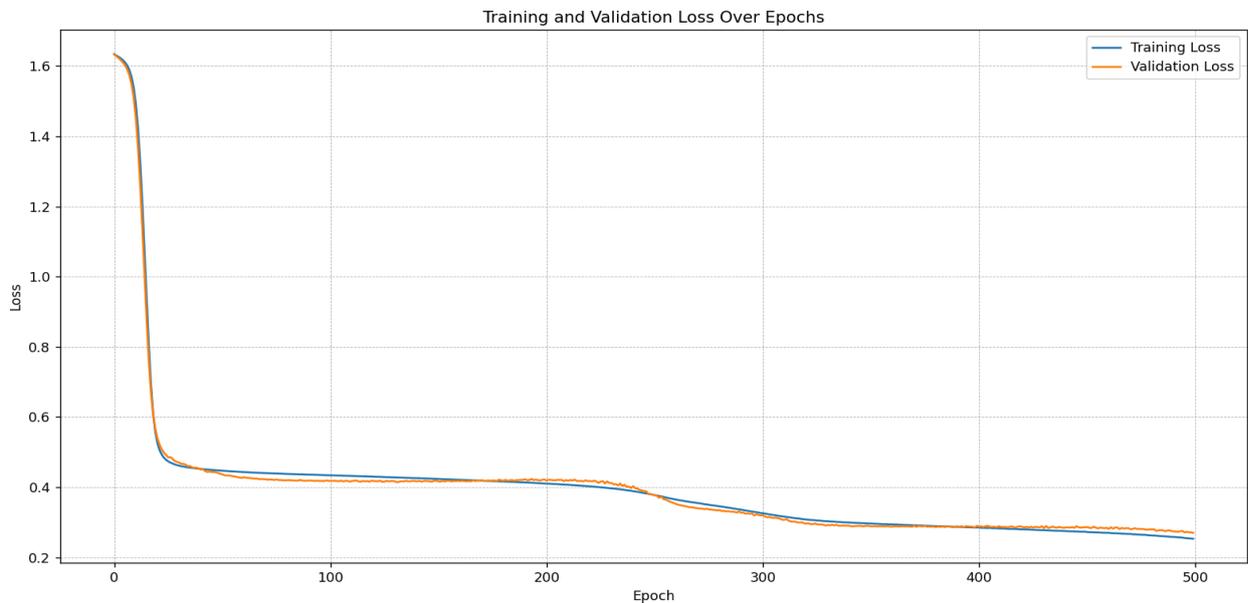


Рис. 2. Графік зміни помилки під час тренування моделі на даних для тренування та валідації (Embedding\_Size=80)

На вхід автоенкодера подається граф, що характеризується:

1. Ознаками вершин, що визначається матрицею.
2. Ознаками ребер, що визначається матрицею.
3. Список ребер, які з'єднують вершини.

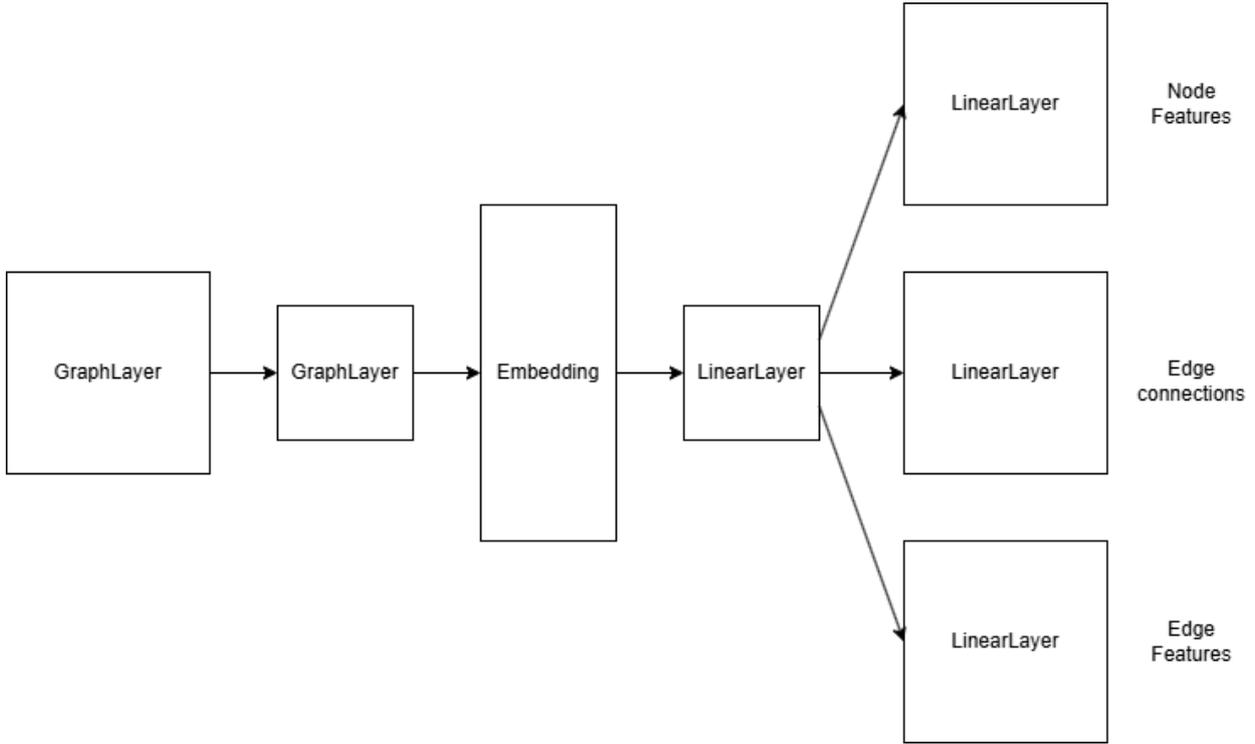
Дані проходять через шари, які адаптовані для роботи з графами. В результаті отримане представлення даних через декодер відтворює граф, що складається з ознак вершин, зв'язків між ребрами, ознак ребер. При дослідженні роботи параметрів об'єктів електромережі доцільно створити шар, який може поєднати інформацію про взаємодію вершин та ребер в графі. Розроблений графовий шар складається з наступних кроків:

**Крок 1.** Визначити множину ознак  $x_j$ , які будуть передані до цільових вершин  $x_i$ .

**Крок 2.** Визначити множину ознак ребер  $edge\_attr$ , які з'єднують вершини  $j$  та  $i$ .

**Крок 3.** Застосувати лінійне перетворення до множини ознак вершин та ребер.

$$lin\_node = X_{nodes} * W_{nodes}^T + b_{nodes} \tag{12}$$



**Рис. 3. Архітектура автоенкодера з шарами для обробки інформації про електромережу, яка визначена за допомогою графа**

де  $lin\_node$  – матриця лінійного перетворення ознак вершин графу,  $X_{nodes}$  – вхідна матриця ознак вершин,  $W_{nodes}$  – вагова матриця із параметрами для навчання,  $b_{nodes}$  – вектор зміщення.

$$lin\_edge = X_{edges} * W_{edges}^T + b_{edges} \quad (13)$$

де  $lin\_edge$  – матриця лінійного перетворення ознак вершин графу,  $X_{edges}$  – вхідна матриця ознак вершин,  $W_{edges}$  – вагова матриця із параметрами для навчання,  $b_{edges}$  – вектор зміщення.

**Крок 4.** Сформувані повідомлення, які об'єднують перетворені ознаки вершин та ребер.

$$Messages = X_{nodes} * W_{nodes}^T + b_{nodes} + X_{edges} * W_{edges}^T + b_{edges} \quad (14)$$

**Крок 5.** Агрегація повідомлень для кожної вершини і від сусідніх вершин.

$$Aggregate_i (Messages) = \sum Messages_i \quad (15)$$

**Крок 6.** Об'єднати агреговані повідомлення з початковими ознаками вершини.

$$Concat\_data = X_{nodes} || Aggregate_i (Messages) \quad (16)$$

**Крок 7.** Застосувати лінійне перетворення для формування результуючого представлення.

$$Embedding\_Nodes = Concat\_data * W_{Embedding\_Nodes}^T + b_{Embedding\_Nodes} \quad (17)$$

При необхідності із вихідного представлення можливо виокремити представлення ребер для передачі та обробки в наступному шарі:

$$Edges\_Features = Embedding\_Nodes[source\_index] || Embedding\_Nodes[destination\_index] \quad (18)$$

$$Embedding\_Edges = Edges\_Features * W_{Edges\_Features}^T + b_{Edges\_Features} \quad (19)$$

При використанні комплексного представлення інформації про вершини та ребрах у вершинах та використанні в наступному шарі при значенні Epoch = 1000 помилка на даних для тренування (Train Loss) = 0.0003, помилка на даних для валідації (Val Loss) = 0.0001, помилка на даних для тестування (Test Loss) = 0.0001. Для вершин  $R^2(nodes) = 0.9981$ , для ребер  $R^2(edges) = 0.9719$ .

Для обчислення представлення про граф в момент сценарію застосовується механізм пулінгу (graph-level pooling) для агрегації ознак вершин, що були отримані в Embedding шарі. Наприклад, `global_mean_pool` обчислює усередненні значення ознак вершин графів в пакеті (batch).

**Порівняння стану електромережі в моментах сценаріїв.** Для визначення подібності представлень графів використовується косинус подібності, який обчислюється як косинус кута між ненульовими векторами. При значенні кута 0 градусів косинус подібності дорівнює 1 – однаковий напрямок, максимальна подібність; при значенні кута 90 градусів косинус подібності дорівнює 0 – вектори ортогональні, відсутність подібності; діаметрально направлені вектори мають подібність -1 [1].

$$\cos(\theta) = \frac{A \cdot B}{\|A\| * \|B\|} \quad (20)$$

де  $A \cdot B$  – добуток векторів,  $\|A\|$ ,  $\|B\|$  – довжина векторів  $A$ ,  $B$  відповідно.

При визначенні подібності станів електромережі в сценаріях можливо ввести граничні значення для визначення рівня подібності.

При виявленні подібних станів електромережі в існуючих сценаріях експерт може зрозуміти можливий розвиток каскадного ефекту, подивитися, які дії були виконані, характеристики компонентів та прийняти рішення. Представлення про характеристики електромережі можуть бути використані для формування бази знань, що полегшить процес розуміння предметної області та створить можливість для подальшого аналізу.

**Обробка послідовності станів електромережі.** При формалізації сценаріїв каскадних ефектів в електромережі у вигляді послідовностей графів з часовою складовою використовуються статичні графи – структура графу не змінюється із часом, але ознаки змінюються. При аналізі послідовностей станів електромережі до графової нейронної мережі додається блок LSTM (Long Short-Term Memory). Оскільки сценарії можуть складатися з різної кількості кроків, то доцільно використовувати маску при вирівнюванні довжини послідовностей та ігнорувати доповнені дані при роботі моделі. Це доповнення дозволяє формувати представлення про послідовність станів електромережі.

**Висновки.** В результаті проведення дослідження було розроблено метод для аналізу та порівняння сценаріїв каскадних ефектів в критичній інфраструктурі на прикладі електромережі. Для вивчення зв'язків та впливу параметрів компонентів в електромережі було розроблено шар графової нейронної мережі, що покращує точність роботи моделі автоенкодера формування представлення про стан роботи електромережі. Пошук схожих сценаріїв, використовуючи косинус подібності, потенційно дозволяє покращити процес прийняття рішень на основі існуючого досвіду. Розроблений метод може працювати з різним рівнем деталізації сценаріїв: порівнювати один конкретний крок сценаріїв чи послідовності кроків в сценаріях, що забезпечує його адаптивність до вхідних даних в залежності від цілей користувача.

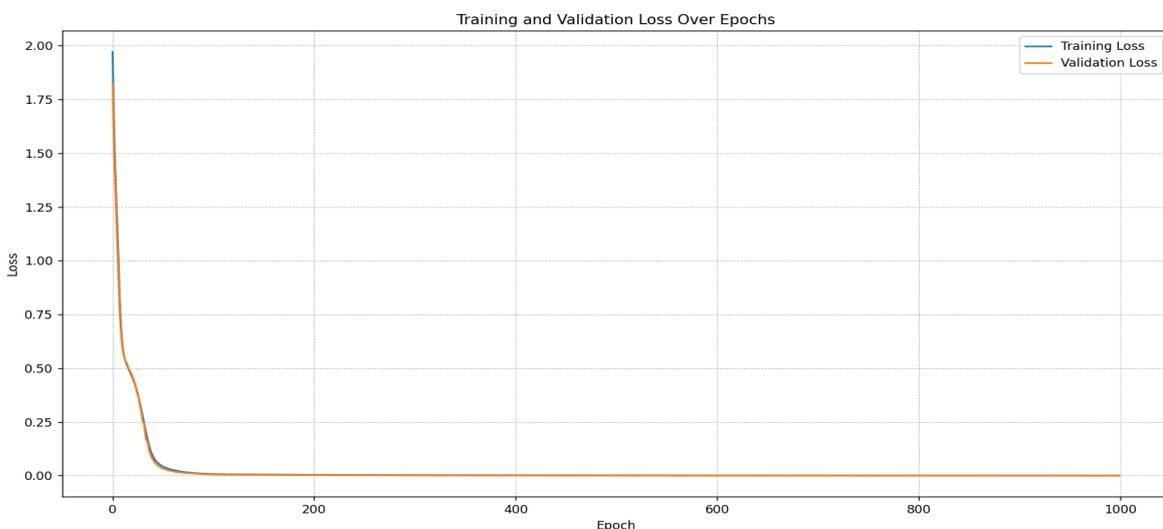


Рис. 4. Графік зміни помилки під час тренування моделі (Embedding Size = 45) на даних для тренування та валідації, використовуючи розроблений шар для графової мережі в енкодері

**Список використаних джерел:**

1. Косинус подібності. URL: [https://uk.wikipedia.org/wiki/Косинус\\_подібності](https://uk.wikipedia.org/wiki/Косинус_подібності)
2. Робота енергосистеми України станом на 20 травня 2022 року. URL: <https://www.kmu.gov.ua/news/robota-energosistemi-ukrayini-stanom-na-20-travnja-2022-roku>
3. Робота енергосистеми України на 1 червня 2022 року. URL: <https://www.kmu.gov.ua/news/robota-energosistemi-ukrayini-na-1-cheravnja-2022-roku>
4. Робота енергосистеми України на 10 червня 2022 року. URL: <https://mstu.gov.ua/news/robota-energosistemi-ukrayini-na-10-cheravnja-2022-roku>
5. Сенченко В. Р., Бойченко А. В., Коваль О. В., Бисько Р. М., Хоменко О. М. Огляд методів і технологій сценарного аналізу каскадних ефектів. Реєстрація, зберігання і обробка даних, 2024. Том 26. № 1. С. 24–54. DOI 10.35681/1560-9189.2024.26.2.316908
6. Сенченко В. Р., Бойченко А. В., Коваль О. В., Хоменко О. М. Методологія і архітектура платформи моделювання взаємозалежностей у критичних інфраструктурах при виникненні каскадних ефектів. Реєстрація, зберігання і обробка даних, ІПРІ НАН України, 2025. Том 27. № 1. С. 28–41. DOI: 10.35681/1560-9189.2025.27.1.335624
7. Хоменко О. М., Сенченко В. Р., Коваль О. В. Мережевий підхід при дослідженні каскадних ефектів критичних інфраструктур. Реєстрація, зберігання і обробка даних, 2024. Том 26. № 2. С. 44–72. DOI 10.35681/1560-9189.2024.26.2.316908
8. Chadaga S., Wu X., Modiano E. Power Failure Cascade Prediction using Graph Neural Networks. <https://doi.org/10.48550/arXiv.2404.16134>
9. Cuadra L, Salcedo-Sanz S, Del Ser J, Jiménez-Fernández S, Geem ZW. A Critical Review of Robustness in Power Grids Using Complex Networks Concepts. *Energies*. 2015. 8(9), 9211–9265. <https://doi.org/10.3390/en8099211>
10. Di Nardo A, Giudicianni C, Greco R, Herrera M, Santonastaso GF. Applications of Graph Spectral Techniques to Water Distribution Network Management. *Water*. 2018. 10(1), 45. <https://doi.org/10.3390/w10010045>
11. Dubej S. R., Singh S. K., Chaudhuri B. B. Activation Functions in Deep Learning: A Comprehensive Survey and Benchmark. <https://doi.org/10.48550/arXiv.2109.14545>
12. Ellens W., Kooij R. E., Graph measures and network robustness. <https://doi.org/10.48550/arXiv.1311.5064>
13. Gilmer J., Schoenholz S. S., Riley P. F., Vinyals O., Dahl G. E. Neural Message Passing for Quantum Chemistry. <https://doi.org/10.48550/arXiv.1704.01212>
14. Guo Z., Sun K., Su X., Simunovic S., “A review on simulation models of cascading failures in power systems,” in *iEnergy*, vol. 2, no. 4, pp. 284–296, December 2023, doi: 10.23919/1EN.2023.0039
15. Hines P., Cotilla-Sanchez E., Blumsack S., Do topological models provide good information about electricity infrastructure vulnerability? <https://doi.org/10.48550/arXiv.1002.2268>
16. Korkali M., Veneman J. G., Tivnan B. F., Hines P. D. H. Reducing Cascading Failure Risk by Increasing Infrastructure Network Interdependency. <https://doi.org/10.48550/arXiv.1410.6836>
17. Mattsson L.-G., Jenelius E. Vulnerability and resilience of transport systems a discussion of recent research. *Transportation Research Part A: Policy and Practice*, vol. 81, pp. 16–34, 2015. <https://doi.org/10.1016/j.tra.2015.06.002>
18. Naem Md Sami, Mia Naeni. Machine Learning Applications in Cascading Failure Analysis in Power Systems: A Review. <https://doi.org/10.48550/arXiv.2305.19390>
19. Noebels M., Preece R., Panteli M., “AC Cascading Failure Model for Resilience Analysis in Power Networks,” in *IEEE Systems Journal*, vol. 16, no. 1, pp. 374–385, March 2022, doi: 10.1109/JSYST.2020.3037400
20. Northeast blackout of 2003. URL: [https://en.wikipedia.org/wiki/Northeast\\_blackout\\_of\\_2003](https://en.wikipedia.org/wiki/Northeast_blackout_of_2003)
21. Oehlers M, Fabian B. Graph Metrics for Network Robustness—A Survey. *Mathematics*. 2021. 9(8), 895. <https://doi.org/10.3390/math9080895>
22. Rinaldi S. M., Peerenboom J. P., Kelly T. K., “Identifying, understanding, and analyzing critical infrastructure interdependencies,” in *IEEE Control Systems Magazine*, vol. 21, no. 6, pp. 11–25, Dec. 2001, doi: 10.1109/37.969131
23. Rusch T. K., Bronstein M. M., Mishra S. A Survey on Oversmoothing in Graph Neural Networks. <https://doi.org/10.48550/arXiv.2303.10993>
24. Varbella A., Gjorgiev B., Sansavini G. Geometric deep learning for online prediction of cascading failures in power grids. *Reliability Engineering & System Safety*, Volume 237, 2023. <https://doi.org/10.1016/j.ress.2023.109341>
25. Waikhom L., Patgiri R. Graph Neural Networks: Methods, Applications, and Opportunities. <https://doi.org/10.48550/arXiv.2108.10733>
26. Wu Z., Pan S., Chen F., Long G., Zhang C., Yu P. S. A Comprehensive Survey on Graph Neural Networks. <https://doi.org/10.48550/arXiv.1901.00596>
27. 2003 Italy blackout. URL: [https://en.wikipedia.org/wiki/2003\\_Italy\\_blackout](https://en.wikipedia.org/wiki/2003_Italy_blackout)
28. 2012 India blackouts. URL: [https://en.wikipedia.org/wiki/2012\\_India\\_blackouts](https://en.wikipedia.org/wiki/2012_India_blackouts)
29. 2016 South Australian blackout. URL: [https://en.wikipedia.org/wiki/2016\\_South\\_Australian\\_blackout](https://en.wikipedia.org/wiki/2016_South_Australian_blackout)

Дата надходження статті: 25.09.2025

Дата прийняття статті: 20.10.2025

Опубліковано: 04.12.2025