

УДК 004.5

DOI <https://doi.org/10.32689/maup.it.2025.4.28>

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
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
ORCID: 0000-0003-0991-6405

**АНАЛІЗ СЦЕНАРІЇВ КАСКАДНИХ ЕФЕКТІВ В КРИТИЧНІЙ ІНФРАСТРУКТУРІ
НА ОСНОВІ ГРАФОВИХ НЕЙРОННИХ МЕРЕЖ**

Анотація. Складність критичної інфраструктури зростає, що збільшує потенційні негативні наслідки каскадних ефектів, тому проводяться дослідження сценаріїв каскадних ефектів в критичній інфраструктурі, щоб визначити дії для зменшення негативного впливу збоїв на систему. Оскільки дані про роботу електромереж є обмеженими, тому для дослідження проводяться моделювання та симуляція сценаріїв роботи електромережі із різними значеннями параметрів компонентів. При обробці сценаріїв про роботу електромережі в сценаріях каскадних ефектів виникає необхідність пошуку подібних сценаріїв або визначення патернів сценаріїв для формування рекомендацій на основі існуючих даних та прийняття рішень. Методи машинного навчання (графові нейронні мережі) є перспективним напрямком аналізу роботи електромережі у різних сценаріях. Сучасні технології надають можливість створювати програмне забезпечення для обробки даних в режимі реального часу, що підвищує швидкість реакції на потенційно небезпечні події.

Метою статті є розробка методу та архітектури програмного забезпечення для формування представлення про електромережу в сценаріях каскадних ефектів для порівняння, визначення подібних та альтернативних шляхів розвитку сценаріїв.

Методологія. У статті описано метод визначення подібних альтернативних сценаріїв каскадних ефектів в електромережі, що використовує модель автоенкодера із графовими шарами для формування представлення про вершини та ребра графу в кроці чи послідовності кроків сценарію. Натренована модель використовується для формування представлень про роботу електромережі в сценаріях та подібності на основі значення косинуса подібності. Для визначення патернів сценаріїв використовується алгоритм кластеризації DBSCAN. Описана архітектура програмного забезпечення надає інструмент для взаємодії із сценаріями каскадних ефектів в роботі електромережі та нейронною мережею.

Наукова новизна роботи полягає у розробці методу, що покращує процес пошуку подібних сценаріїв каскадних ефектів, патернів та формування рекомендацій для прийняття рішень на основі існуючих сценаріїв. Архітектура програмного забезпечення надає можливість оброблювати дані в режимі реального часу та швидко реагувати на аномалії в даних.

Висновки. Розроблено метод та архітектуру програмного забезпечення для формування представлення про електромережу в сценаріях каскадних ефектів для порівняння, визначення подібних та альтернативних шляхів розвитку сценаріїв. Розроблений метод використовує модель автоенкодера на основі графової нейронної мережі для формування представлення про електромережу в сценаріях каскадних ефектів, косинус подібності для визначення подібності сценаріїв, алгоритм кластеризації DBSCAN для пошуку патернів в сценаріях. Розроблений метод покращує процес порівняння кроку чи послідовності кроків в сценаріях каскадних ефектів електромережі, визначення подібних станів електромережі та патернів для прийняття рішень на основі існуючих сценаріїв. Розроблена архітектура програмного забезпечення надає можливість оброблювати дані в режимі реального часу для швидкого реагування на події в системі.

Ключові слова: критична інфраструктура, машинне навчання, нейронна мережа, коефіцієнт подібності, графи, каскадний ефект, кластерний аналіз.

Oleksandr KHOMENKO, Oleksandr KOVAL. ANALYSIS OF CASCADE EFFECT SCENARIOS IN CRITICAL INFRASTRUCTURE BASED ON GRAPH NEURAL NETWORKS

Abstract. The complexity of critical infrastructure is increasing, which increases the potential negative consequences of cascading effects, so studies of cascading effects scenarios in critical infrastructure are being conducted to determine actions

© О. Хоменко, О. Коваль, 2025

Стаття поширюється на умовах ліцензії CC BY 4.0

to reduce the negative impact of failures on the system. Since data on the operation of power grids are limited, modeling and simulation of power grid operation scenarios with different values of component parameters are being conducted for research. When processing power grid operation scenarios in cascading effects scenarios, there is a need to search for similar scenarios or identify scenario patterns to generate recommendations based on existing data and make decisions. Machine learning methods (graph neural networks) are a promising direction for analyzing power grid operation in various scenarios. Modern technologies provide the opportunity to create software for real-time data processing, which increases the speed of response to potentially dangerous events.

The aim of the article is to develop a method and software architecture for forming a representation of the power grid in cascading effects scenarios for comparison, identification of similar and alternative paths of scenario development.

Methodology. The article describes a method for identifying similar alternative scenarios of cascading effects in the power grid, which uses a graph-layered autoencoder model to form a representation of the vertices and edges of the graph in a step or sequence of steps of the scenario. The trained model is used to form representations of the power grid operation in the scenarios and similarities based on the cosine of similarity value. The DBSCAN clustering algorithm is used to identify scenario patterns. The described software architecture provides a tool for interacting with cascading effects scenarios in the power grid operation and a neural network.

The scientific novelty of the work lies in the development of a method that improves the process of searching for similar scenarios of cascading effects, patterns and generating recommendations for decision-making based on existing scenarios. The software architecture provides the ability to process data in real time and quickly respond to anomalies in the data.

Conclusions. A method and software architecture have been developed to form a representation of the power grid in cascade effects scenarios for comparison, identification of similar and alternative paths of scenario development. The developed method uses an autoencoder model based on a graph neural network to form a representation of the power grid in cascade effects scenarios, cosine similarity to determine the similarity of scenarios, and the DBSCAN clustering algorithm to search for patterns in scenarios. The developed method improves the process of comparing a step or sequence of steps in cascade effects scenarios of the power grid, identification of similar power grid states and patterns for decision-making based on existing scenarios. The developed software architecture provides the ability to process data in real time for rapid response to events in the system.

Key words: critical infrastructure, machine learning, neural network, similarity coefficient, graphs, cascading effect, cluster analysis.

Вступ. Критична інфраструктура – важлива, складна система, яка забезпечує умови для функціонування множини об'єктів в різних сферах людської діяльності, наприклад: електропостачання, водопостачання, логістика. Порушення в роботі об'єктів критичної інфраструктури може мати негативні короточасні та довгострокові наслідки. Оскільки системи є взаємопов'язаними, мають зв'язки між суміжними секторами, тому збій в одній частині об'єктів може спричинити збої в залежних об'єктах, виникає каскадний ефект. Відключення електроенергії впливає на функціонування залежної інфраструктури, наприклад: водопостачання, транспортної. Зменшення потужності електромережі впливає на роботу насосних станцій, що використовуються для транспортування води до кінцевих споживачів, а використання резервного живлення має обмеження на робочі потужності та час функціонування насосів. Після певного часу насоси перестають працювати, відбувається зниження тиску води, що призводить до перебоїв водопостачання в населених пунктах. Також відключення електроенергії впливає на функціонування транспортної інфраструктури: змінюється організація та регулювання руху на дорогах, збільшується ризик виникнення аварій, утворюються затори із автомобілів, що збільшує час пересування містом та ускладнюють екстреним службам виконувати свою роботу при виникненні надзвичайних ситуацій. Затримка в логістиці негативно впливає на роботу об'єктів в різних секторах економіки, наприклад: збільшується час доставки товару, який є необхідним для людей чи виробництва.

Збої в роботі критичної інфраструктури можуть бути спричинені: природними, техногенними, антропогенним подіями [12]. Більшість збоїв електроенергії починаються з природних явищ, приблизно третина виникає через неприродні події [11]. В роботі критичної інфраструктури збої можуть впливати на роботу залежних об'єктів, що зменшує продуктивність системи або призводить до повної її деградації. Електромережі мають захисні механізми для обробки збоїв, крім того оператори намагаються підтримувати функціонування системи. Але електромережі все ще є вразливими до збоїв, каскадних ефектів, що негативно впливають на роботу об'єктів залежної критичної інфраструктури. Складність електромереж із часом зростає, що потребує розробки методів аналізу роботи системи при різних умовах, особливо при виникненні та розвитку каскадних ефектів [1].

Аналіз останніх досліджень та публікацій. В загальному вигляді електромережа складається з елементів: джерела електроенергії, передача та розподіл, навантаження (кінцеві споживачі). В дослідженнях роботи електромережі використовують модель потоку потужності (Power Flow Analysis), оптимальний потік потужності (Optimal Power Flow). Метою аналізу потоку потужності є обчислення для кожної шини: величини напруги, кута напруги, реальної потужності, реактивної потужності. Оптимальний потік потужності (Optimal Power Flow) – задача оптимізації, яка визначається

за допомогою цільової функції, множини обмежень, змінних [16]. Дані про роботу електромережі є обмеженими, тому виникає необхідність у генерації синтетичних сценаріїв роботи електромережі та сценаріїв розвитку збоїв. Значення параметрів компонентів електромережі змінюються на основі рівномірного, нормального розподілів, а при моделюванні сценаріїв каскадних збоїв в електромережі використовується каскадна модель збоїв на основі потоку потужності змінного струму [9]. При моделюванні сценаріїв розвитку збоїв у великих та складних електромережах використовується модель каскадних відмов змінного струму, що застосовує захисні механізми [17].

Електромережа в сценаріях може бути представлена у вигляді графу, який складається з вузлів (bus), що містять підключені елементи, та гілок (branches). Для аналізу графів використовуються метрики, які поділяються на класи: Відстань (Distance), Зв'язність (Connection), Спектри (Spectra) [10]. При виборі метрики для оцінки характеристик графу потрібно врахувати обмеження, наприклад: тип графу, складність обчислення. Графові спектральні методи (Graph Spectral Techniques) використовуються в аналізі водопровідної мережі для: виявлення вузьких місць (bottlenecks), вимірювання міцності (strength) мережі, розбиття на підмережі [6], визначення надмірності шляху та існування циклічних альтернативних шляхів водопостачання за допомогою коефіцієнта кластеризації (clustering coefficient) [21]. Теорія графів застосовується для аналізу вразливостей транспортних мереж: Середня відстань (Average distance), Ефективність (Efficiency) [14].

Стійкість та вразливість в електромережах визначається за допомогою концепцій теорії складних мереж та складається з двох різних підходів: топологічний та гібридний (наприклад, net-ability, electrical betweenness, entropic degree) [4]. При визначенні критичних компонентів в електромережі використовується ефективний опір графа (effective graph resistance), який враховує електричні властивості електромереж [13]. Метрики графів можуть використовуватися для моделювання атак та методів для зменшення їхніх наслідків у мережах. При атаці на мережу є два можливі підходи: видалення вершин і видалення ребер, які є критичними, важливими для функціональності мережі: Initial degree removal, Initial betweenness removal, Recalculated degree removal, Recalculated betweenness removal [7]. Для покращення захисту мережі використовуються техніки: Edge addition, Edge rewiring, Node monitoring [7].

Машинне навчання (machine learning) та глибоке навчання (deep learning) впроваджуються у різних сферах людської діяльності, з'являються нові підходи, методи, які можуть бути використані для аналізу каскадних збоїв в енергосистемах [15]. Графові нейронні мережі (Graph Neural Networks) – перспективний підхід аналізу каскадних ефектів в електромережах [19]. Графові нейронні мережі надають можливість прогнозувати значення компонентів та їхній статус в електромережі, враховуючи структуру мережі. Графові нейронні мережі використовують фреймворк передачі повідомлень (message-passing neural network), який складається із двох кроків [8]: агрегація повідомлень; оновлення представлення вершин графу на основі агрегованого повідомлення.

При аналізі сценаріїв каскадних ефектів в електромережі є потреба в порівнянні сценаріїв чи фрагментів сценаріїв, використовуючи інформацію про стан електромережі, її компонентів та значення параметрів в певний момент часу для визначення подібних та альтернативних шляхів розвитку сценаріїв.

Метою статті є розробка методу та архітектури програмного забезпечення для формування представлення про електромережу в сценаріях каскадних ефектів для порівняння, визначення подібних та альтернативних шляхів розвитку сценаріїв.

Виклад основного матеріалу дослідження. Метод визначення подібних альтернативних сценаріїв каскадних ефектів в електромережі, який складається із наступних кроків:

1. Формування представлення про крок чи послідовність кроків сценарію.
2. Визначення подібності сценаріїв на основі значення косинуса подібності.
3. Визначення патернів сценаріїв на основі алгоритму кластеризації DBSCAN.

Формування представлення про крок сценарію. Для формування представлення про електромережу в кроці сценарію була розроблена модель автоенкодера, яка складається з наступних компонентів:

1) Енкодер (Encoder) – блок, де формується представлення про компоненти електромережі в певний крок сценарію.

- 1.1) Шари для формування представлення про вершини графу електромережі.
- 1.2) Шари для формування представлення про ребра графу електромережі.

2) Декодер (Decoder) – блок, де відбувається реконструкція ознак вершин, ребер та структури графу електромережі в певний крок сценарію.

- 1.3) Шари для відтворення ознак вершин графу електромережі.
- 1.4) Шари для відтворення ознак ребер графу електромережі.

При обробці даних графу було розроблено шари для формування представлення про вершини та ребра. Шари для формування представлення про вершини та ребра графу електромережі використовує фреймворк передачі повідомлень, який враховує інформацію про з'єднані вершини, ребра та статуси компонентів електромережі. Оскільки компоненти електромережі можуть бути виведені із ладу чи відключені в процесі розвитку каскадного ефекту, тому важливо враховувати ці особливості при обробці даних графу.

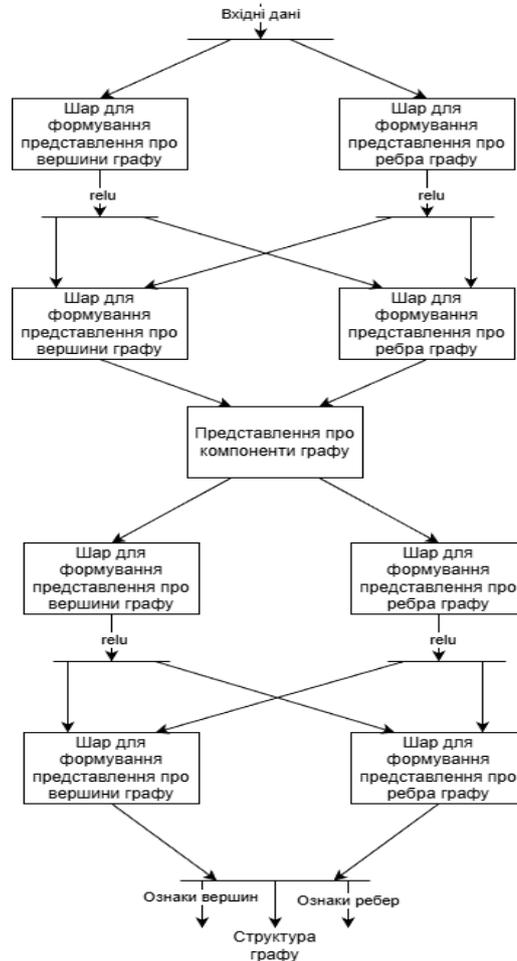


Рис. 1. Структура автоенкодера для формування представлення про вершини та ребра електромережі в кінці сценарію

Вхідні дані шару для формування представлення про вершини графу:

- Ознаки вершин графу x (кожна шина має ознаки: активна потужність, реактивна потужність, величина напруги, кут напруги).

- Ознаки ребер графу $edge_attr$ (реальна потужність, яка походить від шини i на початку гілки; реальна потужність, яка надходить на шину j в кінці гілки; реактивна потужність, яка походить від шини i на початку гілки; реактивна потужність, яка надходить на шину j в кінці гілки).

- Структура графу $edge_index$.

- Маска $node_mask$, яка визначає активні та неактивні вершини графу.

- Маска $edge_mask$, яка визначає активні та неактивні ребра графу.

Процес обробки даних в шарі складається із наступних етапів:

1. Формування повідомлення.

- Застосувати маску до ознак ребер графу.

$$edge_attr = edge_attr * edge_mask \tag{1}$$

- Застосувати маску до вихідних ознак вершин графу.

$$x_j = x_j * node_mask \tag{2}$$

- Об'єднати ознаки вихідної вершини x_j та ребра $edge_attr$

$$combined_features = x_j \parallel node_mask \quad (3)$$

- Застосувати лінійне перетворення, яке трансформує розмірність об'єднаних ознак до вхідної розмірності ознак вершин графу.

$$message = \bar{mlp_message}(combined_features) \quad (4)$$

- Сформувати повідомлення для агрегації.

2. Агрегація повідомлень.

- Застосувати маску для повідомлень, які отримують цільові вершини x_i .

$$input_message = message * node_mask[x_i] \quad (5)$$

- Застосувати функцію агрегації «сума», що підсумовує повідомлення для кожного цільового вузла.

$$aggregated_message = sum(input_message, x_i) \quad (6)$$

3. Оновлення представлення вершини.

- Поєднати агреговане повідомлення з оригінальними ознаками вершини.

$$node_embedding = x + aggregated_message \quad (7)$$

- Застосувати лінійне перетворення, яке трансформує розмірність отриманого представлення до визначеної вихідної розмірності.

$$final_node_embedding = mlp_embedding(node_embedding) \quad (8)$$

Вхідні дані шару для формування представлення про ребра графу:

- Ознаки вершин графу x .
- Ознаки ребер графу $edge_attr$.
- Структура графу $edge_index$.
- Маска $node_mask$, яка визначає активні та неактивні вершини графу.
- Маска $edge_mask$, яка визначає активні та неактивні ребра графу.

Процес обробки даних в шарі складається із наступних етапів:

1. Формування повідомлення.

- Застосувати маску до ознак вершин графу.

$$x = x * node_mask \quad (9)$$

- Застосувати маску до ознак ребер графу.

$$edge_attr = edge_attr * edge_mask \quad (10)$$

- Об'єднати ознаки вихідної вершини x_j та цільової вершини x_i .

$$combined_features = x_j \parallel x_i \quad (11)$$

- Застосувати лінійне перетворення, яке трансформує розмірність об'єднаних ознак до вхідної розмірності ознак ребер графу.

$$message = \bar{mlp_message}(combined_features) \quad (12)$$

2. Оновлення представлення ребра.

- Поєднати повідомлення з оригінальними ознаками ребра.

$$edge_embedding = edge_attr + message \quad (13)$$

- Застосувати лінійне перетворення, яке трансформує розмірність отриманого представлення до визначеної вихідної розмірності.

$$final_edge_embedding = mlp_embedding(edge_embedding) \quad (14)$$

Графові шари використовуються для відтворення ознак та структури графу із представлення, яке формується в середині автоенкодера (embedding). Для відтворення структури графу в декодері використовується сума добутку ознак вихідних вершин, ознак цільових вершин, ознак ребер, що використовується для порівняння із вхідною структурою ребер $edge_index$.

$$edges = sum(x_j * x_i * edge_attr) \quad (15)$$

Під час тренування моделі використовується функція втрат (loss function), яка складається з: функції втрат ознак вершин графу (mse_loss), функції втрат структури графу (binary_cross_entropy_with_logits), функції втрат ознак ребер графу (mse_loss).

При значенні Epoch = 100 були отримані значення Training Loss=0.0006940, Validation Loss = 0.0004601, Test Loss = 0.0003720. Коефіцієнт детермінації для вершин $R^2(nodes) = 0.9955$, коефіцієнт детермінації для ребер $R^2(edges) = 0.9350$.

Формування представлення про послідовність кроків в сценаріях. При формуванні представлення про послідовність кроків в сценаріях потрібно враховувати різну довжину сценаріїв, тому є необхідність у створенні маски послідовності сценаріїв, що доповнює послідовність до визначеної довжини.



Рис. 2. Зміни значення функції втрат під час навчання моделі автоенкодера для формування представлення про крок сценарію

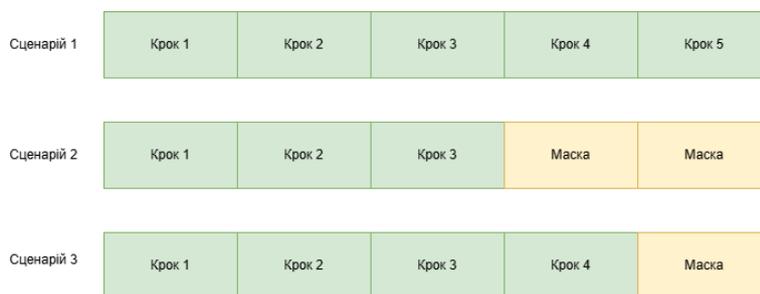


Рис. 3. Приклад сценаріїв із різною кількістю кроків в сценаріях

Для обробки послідовності кроків сценарію була розроблена модель автоенкодера, яка складається із компонентів:

1) Енкодер (Encoder) – блок, де формується представлення про компоненти електромережі в послідовності кроків сценарію.

- 1.1) Шари для формування представлення про вершини графу електромережі.
- 1.2) Шари для формування представлення про ребра графу електромережі.
- 1.3) Шар рекурентної нейронної мережі LSTM для обробки послідовності кроків сценарію.
- 1.4) Механізм уваги MultiheadAttention для вивчення комплексних зв'язків.
- 1.5) Лінійне перетворення ознак до встановленої розмірності.

2) Декодер (Decoder) – блок, де відбувається реконструкція ознак вершин, ребер та структури графу електромережі в послідовності кроків сценарію.

- 2.1) Лінійне перетворення ознак до встановленої розмірності.
- 2.2) Шар рекурентної нейронної мережі LSTM для відтворення послідовності кроків сценарію.
- 2.3) Шари для відтворення ознак вершин графу електромережі.
- 2.4) Шари для відтворення ознак ребер графу електромережі.

Вхідні дані для моделі представлені у вигляді послідовності кроків сценарію X та маски $Mask$, що допомагає розрізняти реальні та доповнені дані при формуванні послідовності із розмірністю n .

$$scenario_sequence = \{X, Mask\} \quad (16)$$

Обробка графів у сценаріях відбувається із врахування маски та розроблених шарів для формування представлень про вершини та ребра графу. В кожному кроці послідовності застосовується механізм `global_mean_pool` для представлень вершин та ребер графу.

$$scenario_sequence = global_mean_pool(node_embedding) * global_mean_pool(edge_embedding) \quad (17)$$

Шар LSTM використовується для обробки послідовностей представлень про кроки сценарію, що були сформовані в графових шарах. LSTM використовує маску для визначення актуальних та доповнених даних. Додатково для вивчення контексту та комплексних зв'язків використовується шар MultiheadAttention із механізмом уваги [20]. Лінійний шар використовується для перетворення даних у задану розмірність – формується представлення про послідовність кроків у сценарії. В декодері відбувається відтворення графів в кроках в сценарію. Для покращення процесу навчання моделі використовуються skip connections.

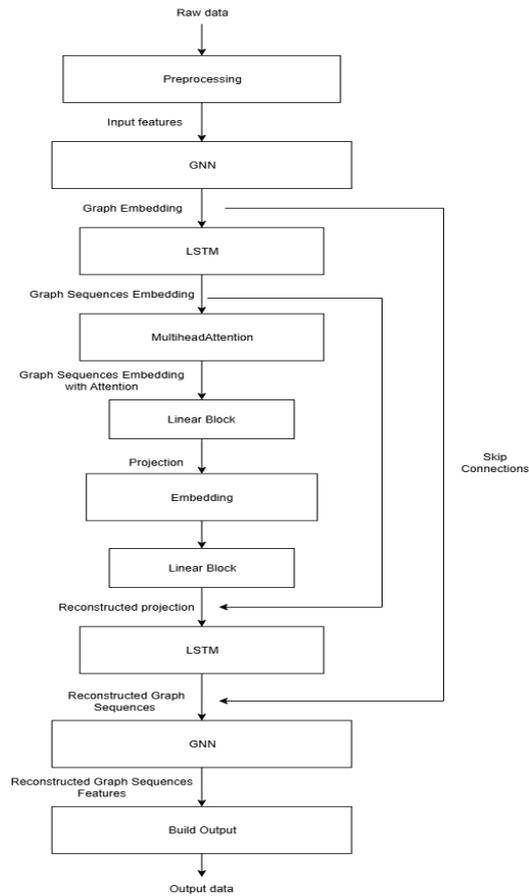


Рис. 4. Структура автоенкодера для формування представлення про послідовність кроків сценарію

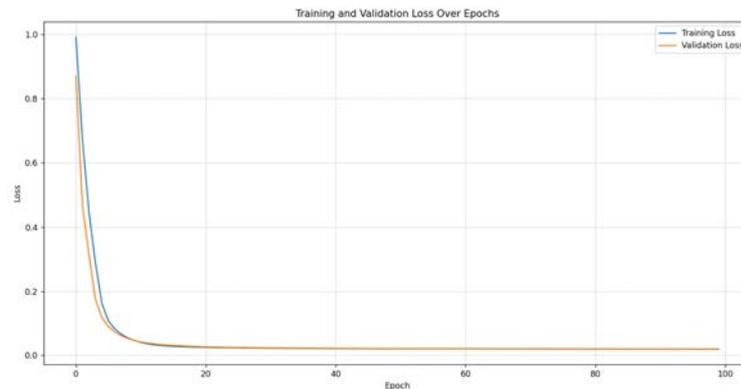


Рис. 5. Зміни значення функції втрат під час навчання моделі автоенкодера для формування представлення про послідовність кроків сценарію

При значенні Epoch = 100 були отримані значення Training Loss= 0.0195245, Validation Loss = 0.0195685, Test Loss = 0.0126826. Коефіцієнт детермінації для вершин $R^2(nodes) = 0.9174$, коефіцієнт детермінації для ребер $R^2(edges) = 0.9866$.

Визначення подібності сценаріїв на основі значення косинуса подібності. Для визначення подібності представлень кроку чи послідовності кроків сценарію каскадного ефекту в електромережі використовується косинус подібності [3]. Користувач визначає інтервал значень косинуса подібності $[lower_similarity, upper_similarity]$ для пошуку подібних представлень та оцінює альтернативні сценарії, які були рекомендовані. Рекомендації надають додаткову інформацію для користувача при прийнятті рішення.

Визначення патернів сценаріїв на основі алгоритму кластеризації DBSCAN. Енкодер натренованої моделі обчислює представлення про роботу електромережі в кроці чи в послідовності кроків сценарію, які

використовуються для кластеризації за допомогою алгоритму DBSCAN [5]. Для візуалізації результатів кластеризації було використано зменшення розмірності n-вимірних даних до 2 вимірів за допомогою PCA [18].

В результаті були визначені кластери:

- Cluster 0 – процес каскадного ефекту в електромережі.
- Cluster 1 – представлення про крок сценарію, де електромережа стабілізувала роботу.
- Cluster 2 – представлення про крок сценарію, де електромережа була знеструмлена.
- Noise – представлення, які були визначені як шуми. Використання кластеризації надає можливість визначити патерни роботи електромережі в сценаріях.

Інформація про визначені патерни та подібність кроків в сценаріях, надає користувачу можливість визначити можливий розвиток каскадного ефекту в електромережі, його наслідки, альтернативні шляхи для зменшення його впливу на систему.

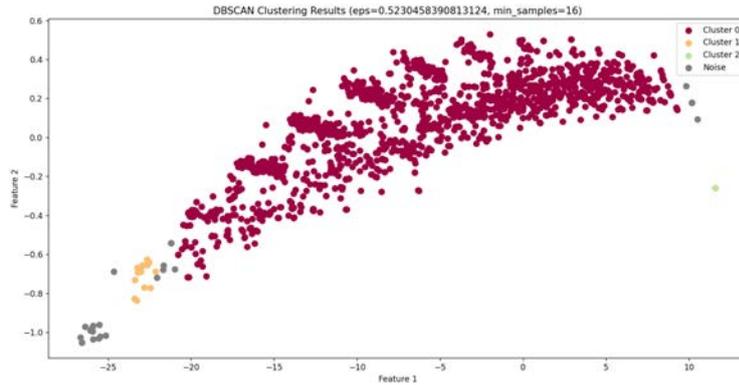


Рис. 6. Візуалізація результатів кластеризації

Архітектура програмного забезпечення обробки та аналізу сценаріїв каскадних ефектів в електромережі. Архітектура програмного забезпечення розроблена на основі мікросервісної архітектури: кожен мікросервіс виконує визначену бізнес-логіку, розгортається та масштабується відповідно до навантаження. В даній архітектурі програмного забезпечення використовується два типи мікросервісів: Auth мікросервіс, Grid мікросервіс.

Користувач чи пристрій надсилає дані про компоненти електромережі до API Gateway, який є вхідною точкою системи, фільтрує та балансує трафік.

Користувач отримує JWT токен в Auth мікросервісі для роботи з Grid мікросервісом: користувачу потрібно створити обліковий запис та ввести облікові дані. Дані про користувача зберігаються в базі даних «User DB».

Для роботи із функціоналом для налаштування та аналізу роботи електромережі використовується Grid мікросервіс. Налаштування та дані про електромережу зберігаються в базі даних «Grid DB». За допомогою механізму cdc [2] зміни в таблицях бази даних надсилаються у брокер повідомлень. Потоків в режимі реального часу оброблюються: відбувається перевірка допустимих значень, пошук аномалій у вікні даних. Сповіщення зберігаються в базі даних «Grid DB» для подальшого відображення користувачу. Користувач може візуалізувати дані про сценарій та порівняти дані, використовуючи навчену модель нейронної мережі.

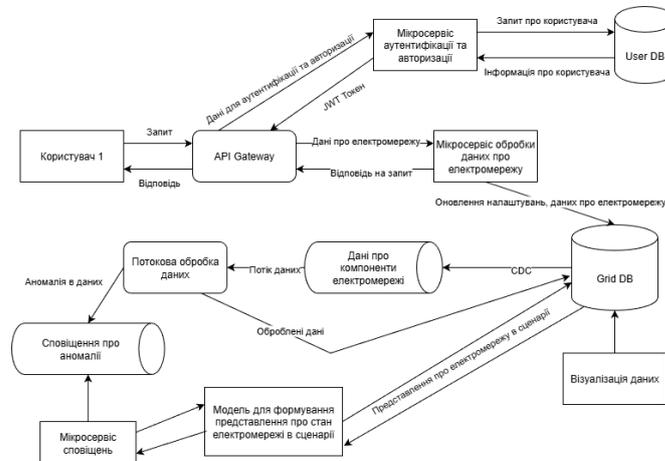


Рис. 7. Архітектура програмного забезпечення

Висновки. Розроблено метод та архітектуру програмного забезпечення для формування представлення про електромережу в сценаріях каскадних ефектів для порівняння, визначення подібних та альтернативних шляхів розвитку сценаріїв. Розроблений метод використовує модель автоенкодера на основі графової нейронної мережі для формування представлення про електромережу в сценаріях каскадних ефектів, косинус подібності для визначення подібності сценаріїв, алгоритм кластеризації DBSCAN для пошуку патернів в сценаріях. Розроблений метод покращує процес порівняння кроку чи послідовності кроків в сценаріях каскадних ефектів електромережі, визначення подібних станів електромережі та патернів для прийняття рішень на основі існуючих сценаріїв. Розроблена архітектура програмного забезпечення надає можливість оброблювати дані в режимі реального часу для швидкого реагування на події в системі.

Список використаних джерел:

1. 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
2. Change data capture. URL: https://en.wikipedia.org/wiki/Change_data_capture
3. Cosine similarity. URL: https://en.wikipedia.org/wiki/Cosine_similarity
4. 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>
5. DBSCAN. URL: <https://uk.wikipedia.org/wiki/DBSCAN>
6. Di Nardo A., Giudicianni C., Greco R., Herrera M., Santonastaso, G.F. Applications of Graph Spectral Techniques to Water Distribution Network Management. *Water*. 2018, 10, 45. <https://doi.org/10.3390/w10010045>
7. Freitas S., Yang D., Kumar S., Tong H., Chau D. H. Graph Vulnerability and Robustness: A Survey. <https://doi.org/10.48550/arXiv.2105.00419>
8. 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>
9. Gjorgiev B., David A.E., Sansavini G. Cascade-risk-informed transmission expansion planning of AC electric power systems. *Electric Power Systems Research*, Volume 204, 2022, 107685, ISSN 0378-7796, <https://doi.org/10.1016/j.epsr.2021.107685>
10. Hernandez J. M., Van Mieghem P. Classification of graph metrics. November 2011. URL: https://www.nas.ewi.tudelft.nl/people/Piet/papers/TUDreport20111111_MetricList.pdf
11. Hines P., Balasubramaniam K., Sanchez E. C. "Cascading failures in power grids," in *IEEE Potentials*, vol. 28, no. 5, pp. 24–30, September–October 2009, doi: 10.1109/MPOT.2009.933498
12. Kadri F., Birregah B., Châtelet E. The Impact of Natural Disasters on Critical Infrastructures: A Domino Effect-based Study. *Homeland Security & Emergency Management*. 2014. 11(2), 217–241. <https://doi.org/10.1515/JHSEM-2012-0077>
13. Koç Y., Warnier M., Kooij R., Brazier F. Structural vulnerability assessment of electric power grids. <https://doi.org/10.48550/arXiv.1312.6606>
14. 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>
15. Md Sami N., Naeini M. Machine Learning Applications in Cascading Failure Analysis in Power Systems: A Review. <https://doi.org/10.48550/arXiv.2305.19390>
16. Nair A. S., Abhyankar S., Peles S., Ranganathan P. Computational and numerical analysis of AC optimal power flow formulations on large-scale power grids. URL: <https://www.osti.gov/servlets/purl/1846582>
17. 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
18. Principal component analysis. URL: https://en.wikipedia.org/wiki/Principal_component_analysis
19. 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>
20. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser L., Polosukhin I. Attention Is All You Need. <https://doi.org/10.48550/arXiv.1706.03762>
21. Yazdani A., Jeffrey P. Complex network analysis of water distribution systems. <https://doi.org/10.48550/arXiv.1104.0121>

Дата надходження статті: 10.11.2025

Дата прийняття статті: 10.12.2025

Опубліковано: 30.12.2025