

УДК 621.316.13

## МОЖЛИВОСТІ ІМПЛЕМЕНТАЦІЇ В РЕЛЕЙНОМУ ЗАХИСТІ АЛГОРИТМУ ПОШУКУ ПЕРЕД АВАРІЙНИХ ЕКСПЛУАТАЦІЙНИХ УМОВ ШЛЯХОМ ВИКОРИСТАННЯ НЕЙРОННОЇ МЕРЕЖІ З ПІДКРІПЛЮВАНИМ НАВЧАННЯМ

ЦЮПА В.М.

аспірант кафедри передачі електричної енергії, Національний технічний університет «Харківський політехнічний інститут»; м. Харків, Україна; ORCID: <https://orcid.org/0000-0002-4269-1941>; e-mail: [vladyслав.tsiupa@iee.khpi.edu.ua](mailto:vladyслав.tsiupa@iee.khpi.edu.ua) ;

ДАНИЛЬЧЕНКО Д.О.

професор кафедри передачі електричної енергії, Національний технічний університет «Харківський політехнічний інститут»; м. Харків, Україна; ORCID: <https://orcid.org/0000-0001-7912-1849>; e-mail: [dmytro.danylchenko@khpi.edu.ua](mailto:dmytro.danylchenko@khpi.edu.ua) ;

**Мета роботи.** Метою статті є розробка та апробація нового методу пошуку граничних та перед аварійних режимів в енергосистемах для задачі розрахунку уставок релейного захисту. Запропонований підхід базується на інтеграції графових нейронних мереж із глибинним навчанням з підкріпленням (ГНП) та спрямований на суттєве скорочення часу обчислень при збереженні високої точності та забезпеченні селективності захисту.

**Методи дослідження.** У роботі використано методологію марковських процесів прийняття рішень для формалізації задачі пошуку граничних та передаварійних режимів. Для вилучення структурної інформації з енергосистеми застосовано графові нейронні мережі, а оптимальні стратегії дій агента сформовано за допомогою глибинного навчання з підкріпленням. Додатково розроблено дворівневу навчальну схему **GLFE** (керуване навчання та вільне дослідження), яка забезпечує стабільну збіжність алгоритму та прискорює навчання. Експерименти проведено на тестовій системі ІБЕЕ 39-шин з використанням сценарного моделювання.

**Отримані результати.** Показано, що застосування графової нейронної мережі з ГНП дозволяє скоротити обчислювальні витрати у 10–1000 разів порівняно з традиційними методами перебору. Точність прогнозування досягає понад 90%, а е-точність перевищує 98%. Запропонований метод демонструє високу ефективність як у задачах визначення максимальних струмів короткого замикання для миттєвого струмового захисту, так і у масштабованих сценаріях на великих системах.

**Наукова новизна.** Уперше запропоновано інтеграцію графових нейронних мереж для вирішення задачі пошуку граничних та передаварійних режимів у релейному захисті. Розроблено унікальну дворівневу навчальну схему **GLFE**, яка поєднує елементи контрольованого та неконтрольованого навчання. Це дозволило досягти високої точності при значному зменшенні кількості навчальних прикладів.

**Практична цінність.** Результати дослідження можуть бути використані при розробці інтелектуальних систем релейного захисту та автоматизації електроенергетичних мереж. Запропонований метод здатний адаптуватися до умов швидкозмінних режимів роботи енергосистем із високою часткою відновлюваних джерел. Крім того, архітектура може бути легко адаптована для розв'язання інших задач оптимізації та управління у складних енергетичних середовищах.

**Ключові слова:** граничні та передаварійні режими, релейний захист, графові нейронні мережі, глибинне навчання з підкріпленням, енергосистеми, електроенергетика.

### I. ВСТУП

Захист обладнання на всіх ланках від виробництва та передачі до споживання є критично важливим пунктом для забезпечення стабільної та безпечної експлуатації енергетичної системи. Саме тому релейному захисту приділяється стільки значення, бо у випадку, коли ділянка із наявною аварією чи помилкою не буде ізольована, обладнання в найпростішому випадку буде пошкоджено, а в найскладнішому це призведе до каскадних обвалів і неконтрольованих процесів в енергетичній системі. Саме заради забезпечення надійного та своєчасного відключення пошкодженого

обладнання існують і постійно вдосконалюються технології релейного захисту.

В електромеханічному виконанні системи релейного захисту часто мали сталі налаштування, що попередньо розраховувались. В сучасних релейних терміналах, за рахунок цифровізації алгоритмів захисту з'являється можливість адаптувати режими роботи під умови експлуатації, що постійно змінюються.

Для того, щоб релейний захист в усіх умовах відповідав нормованим вимогам та запобігав проблем з неправильним спрацюванням (наприклад передчасним або неселективним) слід урахувати при роз-

© Цюпа В.М., Данильченко Д.О., 2025

Creative Commons Attribution-ShareAlike 4.0 International License (CC-BY-SA 4.0)

<https://doi.org/10.15588/1607-6761-2025-3-6>

рахунках налаштувань режими близькі до граничних (екстремальні) а також передаварійні. На даному етапі розвитку релейних систем ця проблема є одною з найважливіших, оскільки вищеописані умови є складними для регулювання, однак важливими через вплив цих режимів на стан обладнання.

Їх пошук складається з дискретного простору, в якому існує оптимальне рішення, а значить дана проблема відноситься до комбінаторної оптимізації. Вирішення даної задачі можливо багатьма способами але всі вони є часозатратними через розмірність простору пошуку. Серед розповсюджених методів: послідовний перебор, евристичні алгоритми та математичне програмування.

Оскільки в якості вузлів для даної задачі виступають підстанції, а в якості ребр – лінії, то невпинне збільшення масштабу енергосистеми призводить до масштабування кількості можливих режимів експлуатації для прорахунку.

Неконтрольованість та складність в прогнозуванні альтернативних джерел енергії також значно впливає на режими експлуатації електричної мережі.

Таким чином, сума вищевказаних факторів значно збільшує швидкість розрахунків в існуючих методах, що не дає змогу навіть наблизитися до створення On-time системи. Для швидкої обробки даних задача потребує більш ефективних методів.

Перспективним рішенням може стати використання рішення глибокого навчання з підкріпленням (ГНП або DRL). В практиці воно активно використовується в різних застосунках для енергетичних систем, наприклад, для аварійного керування, оптимізації розподілу потужності, тощо.

Ключовою відмінністю від стандартних методик є те, що при використанні ГНП зменшується кількість затримок. ГНП можна попередньо навчити в офлайн-фазі, після чого пул оптимальних рішень буде передаватися для використання в онлайн-фазі, скорочуючи час реакції.

## II. МЕТА РОБОТИ

Метою роботи є розробка та апробація нового методу пошуку граничних та перед аварійних режимів в енергосистемах для задачі розрахунку уставок релейного захисту. Запропонований підхід базується на інтеграції графових нейронних мереж із глибоким навчанням з підкріпленням (ГНП) та спрямований на суттєве скорочення часу обчислень при збереженні високої точності та забезпеченні селективності захисту.

## III. ПРОПОНОВАНА СТРУКТУРА НЕЙРОННОЇ МЕРЕЖІ З ГНП

Алгоритм нейронної мережі з ГНП, що належить до зрілих методів у класі reinforced learning (RL) на основі функцій цінності, добре підходить для розв'язання задач із дискретними просторами станів

та дій [1]. При цьому енергосистеми природно описуються у вигляді графових структур, де вузли та гілки мають довільну індексацію й не впорядковані за своєю природою. Через це моделі, здатні навчатися лише у традиційному евклідовому просторі, менш придатні для таких задач. Натомість графові нейронні мережі (GNN) однаково обробляють усі вузли та ребра і безпосередньо працюють у топологічному просторі, що дає змогу отримувати знання про структуру мережі. Тому у цій роботі пропонується інтегрувати GNN і нейронної мережі з ГНП у єдину схему — графової нейронної мережі з ГНП. У ній GNN виконує вилучення ознак енергосистеми, а агент DRL використовує отриману інформацію для вибору граничних та передаварійних режимів. Далі розглянуто побудову такої архітектури для задачі EOCS у розрахунках уставок релейного захисту.

**Математична постановка задачі граничних та передаварійних режимів.** У цій роботі застосовано перший підхід до розрахунку уставок, тобто спочатку визначаються підготовчі величини, а вже потім виконуються власне розрахунки. У практиці енергосистем використовують різні типи захистів: максимальний струмовий [2-5], дистанційний [6,7], нульової послідовності [8-10] тощо. Серед них струмова відсічка є простим, надійним і широко поширеним способом локалізації коротких замикань на лініях електропередачі.

Розглянемо приклад системи, приведеної на рис.1. При виникненні короткого замикання в зеленій зоні рисунку 1, струм  $I_k$ , що проходить по лінії, визначається виразом

$$I_k = \frac{E_s}{X_s + X_k} = \frac{E_s}{X_s + X_{ul}}$$

де  $E_s$  та  $X_s$  — це відповідно ЕРС і реактивний опір джерела живлення, а  $X_{ul}$  — реактивний опір одиницю довжини лінії.




Рисунок 1. Принцип налаштування струмового захисту

Для забезпечення селективності захисту відключення реле P1 має відбуватися лише тоді, коли коротке замикання виникає безпосередньо на лінії L1 [11-

13]. Однак через похибки трансформаторів струму можливе змішування подій у кінці захищеної лінії з подіями на початку суміжної. Щоб уникнути помилкових спрацювань, струм спрацювання задається трохи вищим за максимальний струм КЗ у хвостовій точці лінії. Тоді уставка струму  $I_{set}$  та критерій дії визначаються як:

$$I_{set} = K \cdot I_k^{tail.max}, I > I_{set}$$

де  $I_k^{tail.max}$  - максимальний струм КЗ у кінці захищеної ділянки, а коефіцієнт  $K > 1$  зазвичай береться у межах 1.2–1.3.

У результаті зона дії захисту R охоплює відрізок лінії, позначений зеленим на рис. 1. Таким чином, задача пошуку екстремальних умов у цьому випадку зводиться до виявлення таких режимів роботи іншого обладнання, за яких струм у хвостовій точці досягає глобального максимуму. Відповідно, саме величин  $I_k^{tail.max}$  виступає необхідною підготовчою змінною для налаштування миттєвого струмового захисту. Для спрощення аналізу далі розглядаються лише комбінації вмикання та вимикання інших ліній у системі.

Практичний досвід показує, що чим далі від точки пошкодження відбувається зміна стану обладнання, тим менший її вплив на величину аварійного струму. Це так званий принцип оберненої залежності відстані. Саме він лежить в основі традиційних методів визначення граничних та передаварійних режимів при розрахунку уставок реле. Найбільш характерним прикладом є локальне дослідження шляхом прямого перебору варіантів [14-16]: спочатку задається зона пошуку R довкола місця пошкодження на радіус r, у

якій враховується не більше ніж k відключених елементів із можливих N. Далі методом повного перебору [17] аналізуються всі комбінації станів обладнання у цій зоні, щоб знайти такі режими, що формують максимальний струм КЗ i, відповідно, екстремальні умови експлуатації. Недоліком цього підходу є те, що вибір області R робиться здебільшого емпірично: занадто вузька зона не гарантує виявлення глобальних граничних режимів, а надто широка — значно збільшує витрати часу на розрахунок [18-20].

Щоб подолати описаний вище недолік, пропонується швидкий метод визначення граничних та передаварійних режимів для розрахунку уставок миттєвого струмового захисту, заснований на підході графової нейронної мережі з ГНП. У практичних умовах трифазні короткі замикання зазвичай спричиняють найсерйозніші наслідки, причому величина струму КЗ обернено пропорційна опорю заземлення. Тому запропонований підхід спрямований на пошук такого граничного чи передаварійного стану, за якого струм короткого замикання набуває максимального значення у випадку трифазного КЗ із нульовим опором заземлення в кінцевій точці лінії. На цій основі може бути сформульована математична модель задачі визначення граничних та передаварійних режимів для миттєвого струмового захисту як:

$$I_k^{tail.max} = \max_{\tau \in T} I_{k,t,z,f}^{tail.max} = \max_{\tau \in T} SCC(x_1, \dots, x_m, z, f)$$

$$\tau = \{x_1, \dots, x_m\}$$

$$s, t \{x_i \in \{0, 1\}, i \in \{1, 2, \dots, m\}\}$$

$$z = 0, f = f^{(3)}$$

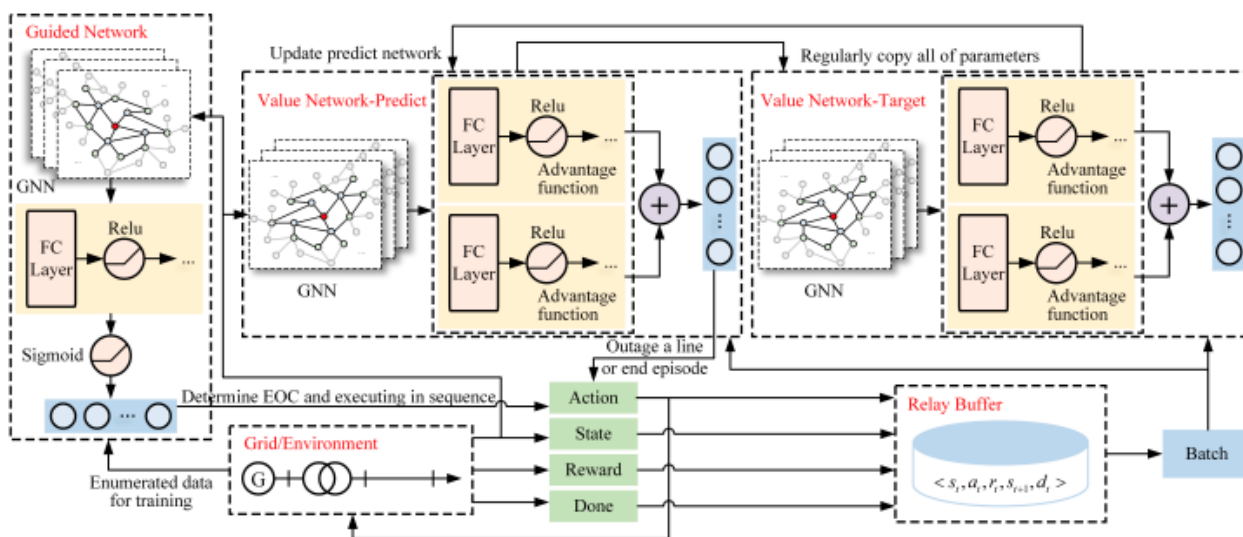


Рисунок 2. Загальна архітектура графової нейромережі з ГНП.

**Архітектура графової нейронної мережі з ГНП.** Застосування методів глибинного навчання з підкріпленням потребує представлення задачі у вигляді мар-

ковського процесу прийняття рішень. Тому задачу пошуку граничних та передаварійних режимів слід розбити на покроковий процес виконання. На почат-



Мережа цінності тренується у напівконтрольованому режимі за допомогою прямої мережі. Частина дій задається прямою мережею:  $k$  послідовних кроків формують прогнозований граничний чи перед аварійний режим. Інша частина дій визначається самою мережею цінності із застосуванням стратегій дослідження. На початкових етапах роль прямої мережі є вагомою, але поступово її вплив зменшується зі зростанням точності моделі. Функція втрат обчислюється як середньоквадратична помилка. Додатково застосовується стратегія повторного використання досвіду: усі результати зберігаються у буфері у вигляді кортежів  $\langle st, at, rt, st+1, dt \rangle$ . Коли буфер заповнюється, з нього вибираються батчі для подальшого тренування. Важливо відзначити, що елементи граничного чи перед аварійного режиму є рівнозначними, незалежними від послідовності дій, тому коефіцієнт затухання  $\gamma$  встановлюється рівним 1, щоб уникнути впливу порядку вибору дій.

---

**Algorithm 1** Extended Exploration Strategy
 

---

Set the Number  $n$  of Actions to Explore.  
**Initialization:** the state  $s$  of the environment.  
 Get values of actions by **Value Network**.  
 Sort the values and select the top  $n$  actions.  
**For**  $a$  in actions:  
   **do**  $a$   
     Environment updated to  $s'$ .  
     Return reward  $r$  and done  $d$ .  
     Record  $(s, a, s', r, d)$  in Memory Buffer.  
   **If** not  $d$ :  
      $n = n - 1$   
     **If**  $n > 0$ :  
       **Execute** this Strategy under  $s'$ .  
     **End If**  
**End If**  
**End for**

---

**Рисунок 4.** Алгоритм стратегії розширеного дослідження перед аварійних режимів в енергосистемах

Для додаткового прискорення навчання застосовується розширена стратегія дослідження. Традиційні методи дозволяли виконувати лише одну дію у заданому стані, що значно подовжувало процес. Нова стратегія, описана в алгоритмі (рис.4), передбачає перевірку кількох дій в одному стані середовища. Це особливо ефективно для задач із короткими епізодами, коли завершення настає після кількох кроків. Однак зі зростанням довжини епізоду час пошуку значно збільшується. Кількість досліджуваних дій  $n$  виступає критичним гіперпараметром; у даній роботі обрано близько 10% від розмірності простору дій.

У процесі навчання мережі цінності в режимі реального часу підлягають корекції такі параметри: частка дій, що задаються прямою мережею, швидкість навчання та необхідність оновлення параметрів цільової Q-мережі. У цій роботі зазначені операції

виконуються після завершення кожного циклу навчання. Відповідно, вся навчальна структура графової нейронної мережі з ГНП формалізована так, як показано на рис.б 7, де ключовим компонентом є саме GLFE, виділений червоним (див. рис.5).

---

**Algorithm 2** Guided Learning and Free Exploration
 

---

Assign Ratios to Guided Learning and Free Exploration.  
**Initialization:** randomize the state  $s$  of the environment.  
**If** Guided Learning:  
   Get actions by **Guide Network**.  
   **For** action  $a$  in actions:  
     **do**  $a$   
       Environment updated to  $s'$ .  
       Return reward  $r$  and done  $d$ .  
        $d = \text{TRUE}$  if  $a$  is the final else **FALSE**.  
       Record  $(s, a, s', r, d)$  in the buffer.  
     **End For**  
**Else** Free Exploration:  
   **While**  $d$ :  
     **Execute** Extended Exploration Strategy under  $s$ .  
   **End While**  
**End If**

---

**Рисунок 5.** Алгоритм для керованого навчання та вільного дослідження перед аварійних режимів в енергосистемах

Варто наголосити, що пряма мережа безпосередньо видає прогнозований граничний чи передаварійний режим на основі вхідного стану системи, тоді як мережа цінності діє інакше: вона послідовно відключає по одній лінії, кожного разу враховуючи оновлений стан середовища, доки не буде досягнуто фінального стану епізоду. Це означає, що мережа цінності реалізує рекурсивний пошук граничних та передаварійних режимів.

**Експерименти та обговорення.** У цьому розділі проведено перевірку запропонованої графової нейронної мережі з ГНП на практичній задачі визначення граничних та передаварійних режимів для розрахунку уставок миттєвих струмових реле. Для цього виконано три типи досліджень: експерименти на ефективність, порівняльні тести та абляційний аналіз, реалізовані на еталонній системі IEEE 39-шин.

Експерименти спочатку проведено на тестовій системі IEEE 39-шин, щоб перевірити ефективність запропонованої графової нейронної мережі з ГНП у вирішенні задачі пошуку граничних та передаварійних режимів. Система включає 39 шин і 34 лінії електропередачі. Початковий режим роботи задавався випадково у діапазоні  $N - 3$ , тобто з 0 до 3 ліній виведених із роботи. Максимальна кількість одночасно відключених ліній  $k$  була обмежена трьома. Відповідно, область пошуку в експерименті охоплювала всі режими в межах  $N - 6$ .

Для тестів ефективності пряма мережа була реалізована у вигляді двох графових згорткових шарів, двох повнозв'язних шарів та вихідного шару з

функцією активації сигмоїда. Мережа цінності містила два графові згорткові та три повнозв'язні шари. Гіперпараметри моделі графової нейронної мережі з ГНП були визначені методом сіткового пошуку і надалі використовувались також у наступних ітераціях тестування.

Криві втрат і точності для прямої та ціннісної мереж подано на рис. 7. Точність прямої мережі склала 80,3%, що свідчить про її здатність певною мірою прогнозувати граничні та передаварійні режими. У сценарії з алгоритму за рис.5 екстремальні струми короткого замикання було розраховано для всіх захистів у 20 початкових комбінаціях увімкнення/вимкнення ліній, що дало 630 початкових станів системи. Результати підтвердили, що точність мережі цінності перевищує 90%, а показник е-точності сягає понад 98%. Це підтверджує дієвість запропонованого методу на основі ГНП для знаходження граничних та передаварійних режимів.




Рисунок 6. Точність і криві втрат мережі направляючих у системі з 39 шинами




Рисунок 7. Точність і криві втрат мережі цінності в системі з 39 шинами

Крім того, загальна кількість можливих режимів у діапазоні  $N - 6$  дорівнює 47 322 628. Проте напівконтрольована навчальна структура GLFE потребувала лише 12 000 зразків, отриманих повним перебором, для тренування прямої мережі та 129 601 різного стану в межах  $N - 6$  для навчання мережі цінності. Таким чином, було використано лише 0,273% від усіх можливих випадків, але при цьому запропонована графова нейронна мережа з ГНП досягла понад 90% точності. Це ще раз демонструє ефективність розроб-

леного методу визначення граничних та передаварійних режимів.

#### IV. ВИСНОВКИ

У цій роботі запропоновано новий метод на основі глибинного навчання з підкріпленням для швидкого пошуку граничних та передаварійних режимів при розрахунку уставок релейного захисту. Розроблена архітектура, названа графова нейронна мережа з ГНП, поєднує можливості графових нейронних мереж для вилучення структурної інформації енергосистеми та механізми глибинного підкріплювального навчання для формування оптимальної стратегії дій. Додатково було створено дворівневу навчальну структуру GLFE (кероване навчання та вільне дослідження), яка підвищує стабільність збіжності.

Ефективність і масштабованість запропонованого підходу підтверджено на тестових системах IEEE з 39 шинами. Порівняння з наявними методами пошуку граничних та передаварійних режимів показало, що розроблена графова нейронна мережа з ГНП забезпечує прийнятний рівень точності, відповідає вимогам селективності захисту та водночас суттєво прискорює обчислення. Варто відзначити, що цей підхід може бути легко адаптований і до інших задач пошуку граничних та передаварійних режимів, достатньо лише коректно побудувати середовище та функції винагороди відповідно до специфіки задачі.

Напрямами подальших досліджень є підвищення узагальнюваності та масштабованості методу, а також його застосування до ширшого кола задач, що потребують пошуку граничних та передаварійних режимів..

#### СПИСОК ЛІТЕРАТУРИ

- [1] Mishra A., Shukla S. A comprehensive review on deep learning techniques in power system protection: Trends, challenges, applications and future directions // *Electric Power Systems Research*. – 2025. – Vol. 229. – P. 110163. DOI: 10.1016/j.eprsr.2025.110163.
- [2] Fang J., Zhang X. Research on power system relay protection method based on machine learning algorithm // *E3S Web of Conferences*. – 2019. – Vol. 118. – P. 01038. DOI: 10.1051/e3sconf/201911801038.
- [3] López-Cardona A., Bernardez G., Barlet-Rose P., Cabellos-Aparicio A. Proximal policy optimization with graph neural networks for optimal power flow // *Proceedings of 14th International Conference on Data Science (DATA 2025)*. – 2025. – P. 45–56. DOI: 10.5220/0013462700003763.
- [4] Kulikov A., Kryukov A., Malygin I., Bystrov D., Shandarova E. Relay protection and automation algorithms of electrical networks based on simulation and machine learning methods // *Energies*. – 2022. – Vol. 15(18). – P. 6525. DOI: 10.3390/en15186525.
- [5] Zhou L., Li J., Wang S. Optimal power flow for high

- spatial and temporal resolution with GNN-DRL in systems with renewables // *Energies*. – 2025. – Vol. 18(7). – P. 1809. DOI: 10.3390/en18071809.
- [6] Murugesan A., Rao A., Zhang Y. Machine learning-driven intelligent voltage control in RES-integrated systems // *Electric Power Systems Research*. – 2025. – Vol. 233. – P. 110269. DOI: 10.1016/j.epsr.2025.110269.
- [7] Shobole A.A., Hassan K., Ahmed R. Multi-agent system based adaptive numerical relay design // *International Journal of Electrical Power & Energy Systems*. – 2024. – Vol. 155. – P. 109540. DOI: 10.1016/j.ijepes.2024.109540.
- [8] Sarajcev P., Dujic D., Baric A. Machine learning classifier for supporting generator's underimpedance (21G) and out-of-step (78) protection functions // *Energies*. – 2024. – Vol. 17(8). – P. 1820. DOI: 10.3390/en17081820.
- [9] Porawagamage G., Dharmapala K., Chaves J.S., Villegas D., Rajapakse A. A review of machine learning applications in power system protection and emergency control: Opportunities, challenges, and future directions // *Frontiers in Smart Grids*. – 2024. – Vol. 1. – P. 1371153. DOI: 10.3389/frsgr.2024.1371153.
- [10] Chen Y., Zhang L., Li M. Artificial Intelligence/Machine Learning Technology in Power System Applications. – PNNL Technical Report PNNL-35735. – 2024. – 112 p. DOI: 10.2172/2334567.
- [11] Ghamizi S., Bojchevski A., Ma A., Cao J. SafePowerGraph: Safety-aware evaluation of graph neural networks for transmission power grids // *arXiv preprint*. – 2024. – arXiv:2407.12421.
- [12] Hansen J.B., Anfinson S.N., Bianchi F.M. Power flow balancing with decentralized graph neural networks // *arXiv preprint*. – 2021. – arXiv:2111.02169.
- [13] Maiti S., Dey S. Smart grid security: A verified deep reinforcement learning framework to counter cyber-physical attacks // *arXiv preprint*. – 2024. – arXiv:2409.15757.
- [14] Pei Y., Wang Q., Liu H. An emergency control strategy for undervoltage load shedding based on a graph deep reinforcement learning method named GraphSAGE-D3QN // *IET Generation, Transmission & Distribution*. – 2023. – Vol. 17(5). – P. 789–799. DOI: 10.1049/gtd2.12795.
- [15] Yuan Y., Li T., Wang Y. Deep reinforcement learning for power system transient stability control // *IEEE Transactions on Power Systems*. – 2020. – Vol. 35(4). – P. 3130–3140. DOI: 10.1109/TPWRS.2019.2963725.
- [16] Liu Z., Zhao J., Zhang Y. Graph convolutional networks for fault location in power distribution systems // *IEEE Transactions on Smart Grid*. – 2022. – Vol. 13(1). – P. 789–799. DOI: 10.1109/TSG.2021.3098361.
- [17] Karimi H., Li Z., Hong S.H. A hybrid machine learning and optimization approach for adaptive protection in microgrids // *International Journal of Electrical Power & Energy Systems*. – 2021. – Vol. 125. – P. 106458. DOI: 10.1016/j.ijepes.2020.106458.
- [18] Wang J., Sun Y., Chen C. Reinforcement learning-based optimal control for power system frequency regulation // *IEEE Access*. – 2021. – Vol. 9. – P. 14567–14577. DOI: 10.1109/ACCESS.2021.3053456.
- [19] Zhang X., Zhou M., Li H. Fault diagnosis in smart grids using graph neural networks // *Applied Energy*. – 2023. – Vol. 341. – P. 121037. DOI: 10.1016/j.apenergy.2023.121037.
- [20] Xu K., He Y., Tang F. Deep Q-learning for adaptive overcurrent relay coordination in distribution systems // *Electric Power Components and Systems*. – 2022. – Vol. 50(15). – P. 1689–1701. DOI: 10.1080/15325008.2022.2106765.

Надійшла (Received) 02.08.2025;

Прийнята (Accepted) 18.09.2025;

Опублікована (Published) 22.10.2025;

## WAY TO IMPLEMENTATION IN RELAY PROTECTION OF THE ALGORITHM FOR SEARCHING FOR PRE-FAULT OPERATING CONDITIONS BY USING A NEURAL NETWORK WITH BACKPROPAGATION SPOT TRAINING

TSIUPA V.M.

Postgraduate student, Department of Electrical Power Transmission, National Technical University 'Kharkiv Polytechnic Institute'; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0002-4269-1941>; e-mail: [vladyslav.tsiupa@ieee.khpi.edu.ua](mailto:vladyslav.tsiupa@ieee.khpi.edu.ua) ;

DANYLCHENKO D.O.

Professor, Department of Electrical Power Transmission, National Technical University 'Kharkiv Polytechnic Institute'; Kharkiv, Ukraine; ORCID: <https://orcid.org/0000-0001-7912-1849>; e-mail: [dmytro.danylchenko@khpi.edu.ua](mailto:dmytro.danylchenko@khpi.edu.ua) ;

**Purpose.** The purpose of this paper is to develop and validate a novel method for searching critical and pre-fault operating conditions in power systems for relay protection setting calculation. The proposed approach is based on the integration of graph neural networks with deep reinforcement learning (GNN-DRL) and aims to significantly reduce computational time while maintaining high accuracy and ensuring protection selectivity.

**Findings.** It is demonstrated that the proposed GNN-DRL method achieves a 10–1000 times reduction in computational overhead compared to traditional brute-force approaches. The prediction accuracy exceeds 90%, while e-accuracy surpasses 98%. The method proves to be highly effective both in determining maximum fault currents for instantaneous overcurrent protection and in large-scale scenarios on extended test systems.

**Originality.** For the first time, the integration of graph neural networks with the Dueling Double Deep Q Network algorithm is proposed to solve the problem of searching for critical and pre-fault operating conditions in relay protection. A unique two-stage training framework, GLFE, is developed, combining elements of supervised and unsupervised learning. This enables high prediction accuracy while requiring significantly fewer training samples.

**Practical value.** The results of this study can be applied in the design of intelligent relay protection and automation systems for electric power networks. The proposed method is capable of adapting to fast-changing conditions in power systems with high penetration of renewable energy. Furthermore, the architecture can be extended to other optimization and control problems in complex energy environments.

**Keywords:** limit and pre-emergency modes, relay protection, graph neural networks, reinforcement learning, power systems, electric power engineering.

## REFERENCES

- [1] Mishra, A., & Shukla, S. (2025). A comprehensive review on deep learning techniques in power system protection: Trends, challenges, applications and future directions. *Electric Power Systems Research*, 229, 110163. <https://doi.org/10.1016/j.epsr.2025.110163>
- [2] Fang, J., & Zhang, X. (2019). Research on power system relay protection method based on machine learning algorithm. *E3S Web of Conferences*, 118, 01038. <https://doi.org/10.1051/e3sconf/201911801038>
- [3] López-Cardona, A., Bernardez, G., Barlet-Rose, P., & Cabellos-Aparicio, A. (2025). Proximal policy optimization with graph neural networks for optimal power flow. In *Proceedings of the 14th International Conference on Data Science (DATA 2025)* (pp. 45–56). <https://doi.org/10.5220/0013462700003763>
- [4] Kulikov, A., Kryukov, A., Malygin, I., Bystrov, D., & Shandarova, E. (2022). Relay protection and automation algorithms of electrical networks based on simulation and machine learning methods. *Energies*, 15(18), 6525. <https://doi.org/10.3390/en15186525>
- [5] Zhou, L., Li, J., & Wang, S. (2025). Optimal power flow for high spatial and temporal resolution with GNN-DRL in systems with renewables. *Energies*, 18(7), 1809. <https://doi.org/10.3390/en18071809>
- [6] Murugesan, A., Rao, A., & Zhang, Y. (2025). Machine learning-driven intelligent voltage control in RES-integrated systems. *Electric Power Systems Research*, 233, 110269. <https://doi.org/10.1016/j.epsr.2025.110269>
- [7] Shobole, A. A., Hassan, K., & Ahmed, R. (2024). Multi-agent system based adaptive numerical relay design. *International Journal of Electrical Power & Energy Systems*, 155, 109540. <https://doi.org/10.1016/j.ijepes.2024.109540>
- [8] Sarajcev, P., Dujic, D., & Baric, A. (2024). Machine learning classifier for supporting generator's underimpedance (21G) and out-of-step (78) protection functions. *Energies*, 17(8), 1820. <https://doi.org/10.3390/en17081820>
- [9] Porawagamage, G., Dharmapala, K., Chaves, J. S., Villegas, D., & Rajapakse, A. (2024). A review of machine learning applications in power system protection and emergency control: Opportunities, challenges, and future directions. *Frontiers in Smart Grids*, 1, 1371153. <https://doi.org/10.3389/frsgr.2024.1371153>
- [10] Chen, Y., Zhang, L., & Li, M. (2024). Artificial Intelligence/Machine Learning Technology in Power System Applications (PNNL Technical Report PNNL-35735). <https://doi.org/10.2172/2334567>
- [11] Ghamizi, S., Bojchevski, A., Ma, A., & Cao, J. (2024). SafePowerGraph: Safety-aware evaluation of graph neural networks for transmission power grids. *arXiv preprint*, arXiv:2407.12421.
- [12] Hansen, J. B., Anfinsen, S. N., & Bianchi, F. M. (2021). Power flow balancing with decentralized graph neural networks. *arXiv preprint*, arXiv:2111.02169.
- [13] Maiti, S., & Dey, S. (2024). Smart grid security: A verified deep reinforcement learning framework to counter cyber-physical attacks. *arXiv preprint*, arXiv:2409.15757.
- [14] Pei, Y., Wang, Q., & Liu, H. (2023). An emergency control strategy for undervoltage load shedding based on a graph deep reinforcement learning method named GraphSAGE-D3QN. *IET Generation, Transmission & Distribution*, 17(5), 789–799. <https://doi.org/10.1049/gtd2.12795>
- [15] Yuan, Y., Li, T., & Wang, Y. (2020). Deep reinforcement learning for power system transient stabil-



- ity control. *IEEE Transactions on Power Systems*, 35(4), 3130–3140.  
<https://doi.org/10.1109/TPWRS.2019.2963725>
- [16] Liu, Z., Zhao, J., & Zhang, Y. (2022). Graph convolutional networks for fault location in power distribution systems. *IEEE Transactions on Smart Grid*, 13(1), 789–799.  
<https://doi.org/10.1109/TSG.2021.3098361>
- [17] Karimi, H., Li, Z., & Hong, S. H. (2021). A hybrid machine learning and optimization approach for adaptive protection in microgrids. *International Journal of Electrical Power & Energy Systems*, 125, 106458. <https://doi.org/10.1016/j.ijepes.2020.106458>
- [18] Wang, J., Sun, Y., & Chen, C. (2021). Reinforcement learning-based optimal control for power system frequency regulation. *IEEE Access*, 9, 14567–14577.  
<https://doi.org/10.1109/ACCESS.2021.3053456>
- [19] Zhang, X., Zhou, M., & Li, H. (2023). Fault diagnosis in smart grids using graph neural networks. *Applied Energy*, 341, 121037.  
<https://doi.org/10.1016/j.apenergy.2023.121037>
- [20] Xu, K., He, Y., & Tang, F. (2022). Deep Q-learning for adaptive overcurrent relay coordination in distribution systems. *Electric Power Components and Systems*, 50(15), 1689–1701.  
<https://doi.org/10.1080/15325008.2022.210676>