

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет комп'ютерної інженерії та управління
(повна назва)

Кафедра електронних обчислювальних машин
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

Рівень вищої освіти другий (магістерський)

Метод прийняття рішень для планування на основі
штучного інтелекту для мікромереж

(тема)

Виконав:

студент II курсу, групи СПМ-22-6
Тухтаров В.Б
(прізвище, ініціали)

Спеціальність 123 «Комп'ютерна інженерія»
(код і повна назва спеціальності)

Тип програми освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системне програмування
(повна назва освітньої програми)

Керівник: доц. Ляшенко О.С
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри ЕОМ

(підпис)

Коваленко А.А.

(прізвище, ініціали)

2024 р.

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерної інженерії та управління _____

Кафедра _____ електронних обчислювальних машин _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 123 «Комп'ютерна інженерія» _____
(код і повна назва)

Тип програми _____ освітньо-наукова _____
(освітньо-професійна або освітньо-наукова)

Освітня програма _____ Системне програмування _____
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

“ _____ ” _____ 20__ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ

студенту _____ Тухтарову Владиславу Борисовичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи Метод прийняття рішень для планування на основі штучного інтелекту для мікромереж

затверджена наказом по університету від “ 01 ” квітня 2024 р. № 257 Ст

2. Термін подання студентом роботи до екзаменаційної комісії 15 червня 2024 р.

3. Вхідні дані до роботи Мікромережа, система планування, Нейронна мережа, штучний інтелект

Метод прийняття рішень щодо оптимального планування на основі DNN

4. Перелік питань, що потрібно опрацювати у роботі Мікромережі

Оптимальна модель планування Microgrid

Глибокий метод внутрішньоденної оптимізації

Аналіз моделювання та порівняння

Висновки

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) 13

6. Консультанти розділів роботи (заповнюється за наявності консультантів згідно з наказом, зазначеним у п.1)

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Постановка задачі	1.04.24	
2	Аналіз літературних джерел	2.04-12.04.24	
3	Підготовка теоретичних аспектів за темою дослідження	12.04-30.04	
4	Побудова методу	1.05-18.05.24	
5	Розробка системи	18.05-22.05	
6	Тестування оцінка системи	23.05-31.05	
7	Підготовка публікації за темою дослідження	1.06-13.06.24	
8	Формування презентації	3.06.24	
9	Перевірка на антиплагіат	13.06.24	
10	Відправка на рецензування	14.06	

Дата видачі завдання 01 квітня 2024 р.

Студент _____
(підпис)

Керівник роботи _____
(підпис)

доц. Ляшенко О.С.
(посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 54 с., 10 рис., 4 табл., 1 дод., 34 джерела.

МІКРОМЕРЕЖА; ЗГОРТКОВА НЕЙРОННА МЕРЕЖА; ГЛИБОКА ДВОНАПРАВЛЕНА НЕЙРОМЕРЕЖА ДОВГОЇ КОРОТКОЇ ПАМ'ЯТІ; ШТУЧНИЙ ІНТЕЛЕКТ.

Метою кваліфікаційної роботи є дослідження методу прийняття рішень для планування роботи мікромережі на основі штучного інтелекту.

У ході виконання кваліфікаційної роботи пропонується дворівневий метод прийняття рішень щодо оптимального планування на основі DNN для MG, який усуває обмеження традиційних методів на основі математичної моделі. Замість вивчення внутрішнього механізму проблеми оптимізації метод базується на мережі DNN, яка використовує масове історичне навчання даних прийняття рішень для безпосередньої побудови зв'язку відображення між відомими вхідними даними та результатами прийняття рішень. Цей підхід порушує традиційне мислення про рішення оптимального планування та забезпечує новий спосіб оптимального планування мікромережі.

ABSTRACT

Master's thesis: 54 pages, 10 figures, 4 tables, 1 appendices, 34 sources.

MICROGRID; CONVOLUTIONAL NEURAL NETWORK; DEEP
BIDIRECTIONAL LONG-SHORT MEMORY NEURAL NETWORK;
ARTIFICIAL INTELLIGENCE

In the course of the qualification work, a two-level DNN-based optimal scheduling decision-making method for MG is proposed, which overcomes the limitations of traditional mathematical model-based methods. Instead of learning the internal mechanism of the optimization problem, the method is based on a DNN network that uses massive historical learning of decision data to directly construct a mapping relationship between known inputs and decision outcomes. This approach disrupts traditional thinking about optimal scheduling decisions and provides a new way to optimally schedule a microgrid.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ.....	8
ВСТУП	9
1 МІКРОМЕРЕЖІ.....	10
1.1 Теоретичні відомості про мікромережі.....	10
1.1.1 Історія виникнення мікромереж	10
1.1.2 Розвиток мікромереж.....	11
1.1.3 Застосування	11
1.1.4 Технології та компоненти мікромереж.....	12
1.2 Огляд сучасних підходів функціонування мікромереж.....	13
2 ОПТИМАЛЬНА МОДЕЛЬ ПЛАНУВАННЯ MICROGRID	19
2.1 Загальна композиційна структура мікромережі	19
2.2 Цільова функція.....	20
2.3 Обмеження.....	21
2.3.1 Обмеження балансу потужностей	21
2.3.2 Контрольовані робочі обмеження установки.....	21
2.3.3 Експлуатаційні обмеження акумуляторної батареї.....	22
2.3.4 Обмеження контактної лінії живлення.....	23
3 ГЛИБОКИЙ МЕТОД ВНУТРІШНЬОДЕННОЇ ОПТИМІЗАЦІЇ НА ОСНОВІ НЕЙРОННОЇ МЕРЕЖІ.....	24
3.1 Форми поточної оптимізації MPC протягом дня.....	24
3.2 Загальна структура методу прийняття рішень щодо внутрішньоденного планування на основі DNN	25
3.3 Вступ до глибоких нейронних мереж	26
3.3.1 Згорткові нейронні мережі.....	26
3.3.2 Двонаправлені мережі довгострокової та короткочасної пам'яті	27

3.4	Мережа прийняття рішень щодо внутрішньоденного планування CNN-Bi LSTM	29
3.4.1	Вхід і вихід CNN-Bi LSTM	29
3.4.2	Структура CNN-Bi LSTM.....	30
3.4.3	Налаштування CNN-Bi LSTM	31
3.5	Алгоритм корекції балансу потужностей.....	32
4	АНАЛІЗ МОДЕЛЮВАННЯ ТА ПОРІВНЯННЯ	34
4.1	Введення прикладів параметрів і системи тестування.....	34
4.2	Аналіз ефективності запропонованого методу	34
4.3	Порівняльний аналіз різних методів	36
4.3.1	Порівняння з традиційними методами	36
4.3.2	Вплив ємності набору даних навчання.....	37
4.3.3	Вплив кластеризації даних.....	38
4.3.4	Вплив різних моделей DNN відображення серверної частини	40
	ВИСНОВКИ.....	41
	ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	43
	ДОДАТОК А Графічний матеріал кваліфікаційної роботи.....	47

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ
І ТЕРМІНІВ

AR – штучний інтелект (англ., Artificial Intelligence)

BLSM – довга короткочасна пам'ять (англ., Bidirectional Long-Short
Memory)

CNN – згорткова нейронна мережа (англ., Convolutional Neural Network)

NN – нейронна мережа (англ., Neural Network)

MG – мікромережа (англ., Microgrid)

ВСТУП

Зі швидким зростанням частки доступу до відновлюваної енергії та структурною складністю розподілених енергетичних систем традиційні методи планування мікромережі (MG), які спираються на математичні моделі оптимізації та експертний досвід, стикаються зі значними проблемами. Таким чином, важливо представити нову техніку планування з високим інтелектом і здатністю швидкого прийняття рішень для реалізації автоматичної роботи та регулювання MG. У цій роботі пропонується оптимальний метод прийняття рішень щодо планування для MG на основі глибоких нейронних мереж (DNN). По-перше, представлено типову математичну модель планування, що використовується для роботи MG, і проаналізовано обмеження поточних методів. Потім представлено двоетапну схему оптимального планування, що включає етапи на добу наперед і всередині дня. Частина на добу наперед розв'язується за допомогою змішаного цілочисельного лінійного програмування (MILP), а внутрішньоденна частина використовує згортову нейронну мережу (CNN) – двонаправлену довготривалу короткочасну пам'ять (Bi LSTM) для високошвидкісного послідовного прийняття рішень, з виходу, скориговані за допомогою алгоритму корекції балансу потужності. Нарешті, достовірність моделі та алгоритму цієї роботи перевіряється арифметичним аналізом випадків.

1 МІКРОМЕРЕЖІ

1.1 Теоретичні відомості про мікромережі

Microgrid (мікромережа) – це локальна енергосистема, яка може функціонувати незалежно від традиційної електричної мережі або взаємодіяти з нею. Вона включає в себе джерела виробництва енергії, системи накопичення енергії та навантаження, і має здатність забезпечувати енергією певну територію або групу споживачів. Основна мета microgrid – підвищення надійності електропостачання, зниження витрат на енергію та сприяння використанню відновлюваних джерел енергії.

1.1.1 Історія виникнення мікромереж

Перші концепції мікромереж з'явилися ще на початку ХХ століття, коли місцеві генератори забезпечували електроенергією окремі підприємства та громади. Проте з розвитком централізованих електричних мереж необхідність у мікромережах зменшилась. Відновлення інтересу до мікромереж почалося в кінці ХХ століття з розвитком відновлюваних джерел енергії, технологій зберігання енергії та необхідності підвищення стійкості енергосистем до природних катастроф.

У 2000-х роках почали з'являтися перші сучасні мікромережі, зокрема в США та Європі. Вони використовували комбінацію сонячних панелей, вітряних турбін, акумуляторних систем та керованих навантажень. Перші успішні проекти продемонстрували переваги мікромереж у підвищенні енергетичної стійкості та зниженні витрат.

1.1.2 Розвиток мікромереж

З розвитком технологій відновлюваної енергії та зберігання енергії, а також із зростанням потреби у підвищенні стійкості енергосистем, мікромережі стали більш поширеними. Основні етапи розвитку мікромереж включають:

- інтеграція відновлюваних джерел енергії: використання сонячних та вітрових електростанцій дозволило зменшити залежність від викопного палива;
- розвиток систем зберігання енергії: сучасні акумуляторні системи дозволяють зберігати надлишок виробленої енергії для використання в години пікового споживання або у випадку відключення основної мережі;
- інтелектуальні системи управління: впровадження технологій інтернету речей (IoT) та штучного інтелекту для оптимізації виробництва та споживання енергії;
- економічні моделі: розробка нових бізнес-моделей та фінансових механізмів для підтримки розвитку мікромереж.

1.1.3 Застосування

Мікромережі мають широке застосування в різних сферах, включаючи:

- житлові райони. Мікромережі можуть забезпечувати житлові райони енергією від відновлюваних джерел, знижуючи витрати на електроенергію та підвищуючи надійність електропостачання. Вони також дозволяють інтегрувати електромобілі та зарядні станції;
- промислові підприємства. Промислові підприємства використовують мікромережі для забезпечення безперебійної роботи у випадку відключення основної мережі, а також для оптимізації енергоспоживання та зниження витрат на енергію;

- віддалені та ізольовані території. Мікромережі особливо корисні для віддалених або ізольованих територій, де будівництво традиційних електромереж є економічно недоцільним або технічно складним. Вони забезпечують місцеве виробництво енергії та знижують залежність від імпорту палива;

- військові бази. Військові бази використовують мікромережі для забезпечення автономності та надійності енергопостачання, що особливо важливо в умовах бойових дій або надзвичайних ситуацій;

- громадські заклади. Школи, лікарні та інші громадські заклади можуть використовувати мікромережі для забезпечення стабільного електропостачання, особливо в критичні моменти. Це дозволяє зберігати важливі функції навіть при відключенні основної мережі.

1.1.4 Технології та компоненти мікромереж

Мікромережі включають різні технології та компоненти, що забезпечують їх ефективне функціонування:

- джерела енергії: сонячні панелі, вітряні турбіни, біомасові установки, мікро-ГЕС;

- системи зберігання енергії: акумуляторні батареї, системи накопичення енергії на основі гідроенергетики (наприклад, гідроакумулюючі станції);

- інтелектуальні системи управління: системи моніторингу та управління енергоспоживанням, що використовують алгоритми штучного інтелекту та технології IoT;

- інфраструктура: локальні електричні мережі, зарядні станції для електромобілів, розподільчі щити та інші компоненти електричної інфраструктури.

Виклики та перспективи. Попри значні переваги, розвиток мікромереж стикається з певними викликами, серед яких:

- фінансування: висока початкова вартість створення мікромереж може бути перешкодою для багатьох потенційних користувачів;
- регуляторні бар'єри: відсутність чітких регуляторних норм може ускладнювати інтеграцію мікромереж в існуючі енергосистеми;
- технічні проблеми: складність інтеграції різних джерел енергії та систем зберігання енергії в єдину ефективну систему.

Однак, попри ці виклики, перспективи розвитку мікромереж є дуже обнадійливими. Зі зростанням інтересу до відновлюваних джерел енергії та технологій зберігання енергії, мікромережі стають важливою складовою сучасних енергосистем.

Мікромережі представляють собою важливу інновацію в енергетичній сфері, забезпечуючи надійність, стійкість та ефективність енергопостачання. З їх допомогою можна знизити залежність від викопного палива, сприяти екологічно чистому виробництву енергії та забезпечити енергетичну безпеку навіть у найскладніших умовах. Подальший розвиток технологій та вдосконалення регуляторних механізмів сприятиме ще більш широкому впровадженню мікромереж у всьому світі.

1.2 Огляд сучасних підходів функціонування мікромереж

MG, що характеризуються чистотою, низьким рівнем викидів вуглецю та відкритістю, привернули значну увагу через швидкий розвиток відновлюваної енергетики в останні роки [1]. Як важливе рішення для покращення споживання розподілених джерел енергії та надійності електропостачання, MGs стали важливими для зменшення забруднення викопною енергією та сприяння сталому розвитку [2]. Однак переривчастий, мінливий і невизначений характер відновлюваних джерел енергії створює значні проблеми для стабільної роботи МГ [3]. Крім того, розширення системи MG і збільшення кількості її компонентів також висуває більш жорсткі вимоги до оптимального методу планування. Традиційний метод планування,

заснований на оптимізації чисельної моделі, узгодженні сценаріїв і комплектуванні персоналом вручну, ускладнює задоволення попиту. Отже, вивчення швидких, точних і інтелектуальних методів планування має величезну практичну цінність і значення [4]. В даний час переважаючим методом розв'язання задач оптимального планування МГ є чисельний метод розрахунку, заснований на теорії оптимізації. Загальні моделі оптимального планування охоплюють МІЛР [5], динамічне програмування [6], розподілену оптимізацію [7] тощо. Подібним чином, загальні алгоритми розв'язування моделей включають інтелектуальні алгоритми [8], методи кінчної релаксації другого порядку [9], релаксацію Лагранжа методи тощо. Проте, оскільки невизначеності двостороннього джерело-навантаження в межах МГ зростають, розв'язання задачі оптимального планування за таких невизначеностей стає більш реалістичною та складною дослідницькою проблемою [10]. Деякі дослідники будують моделі планування невизначеності. Основними методами моделювання та вирішення є стохастичне планування [11], планування з випадковими обмеженнями [12] тощо. Серед них методи надійної оптимізації [13, 14] доведено як ефективний метод вирішення невизначених задач оптимізації МГ. Вони спрямовані на оптимальну роботу за найгіршого сценарію. Однак їх надто песимістичний погляд на невизначені змінні може призвести до результатів рішення, які є занадто консервативними, щоб бути економними. Математичні моделі цих методів є відносно складними та обчислювально дорогими. Інші дослідники використовували багаточасову оптимальну стратегію планування [15], яку можна класифікувати на планування на добу наперед і внутрішньоденний етап відповідно до шкали часу. Серед них техніка прогнозного керування моделлю (MPC) є широко використовуваним підходом до моделювання [16]. Як підвищити обчислювальну ефективність планування в режимі реального часу всередині дня, все ще залишається проблемою.

Таким чином, традиційні методи планування, засновані на теорії оптимізації, покладаються на суворе математичне виведення, вимагаючи

участі дослідників. Оскільки MG розвивається в нову систему, що характеризується підвищеною невизначеністю та складністю, традиційні методи планування оптимізації поступово стають неадекватними для задоволення вимог роботи MG [17]. Кілька критичних проблем цього методу:

- традиційні математичні методи оптимізації не можуть змоделювати компоненти MG швидким і чітким способом, але важко описати фізичні характеристики фактичної роботи компонентів за допомогою спрощеної моделі [18];

- традиційні математичні моделі планування MG часто є нелінійними та неопуклими, що є типовою недетермінованою поліноміальною проблемою (NP-складною). Задача вимоглива до алгоритму розв'язання, і знайти оптимальне рішення нелегко;

- обчислювальний процес традиційних математичних методів оптимізації є складним і неефективним, і його важко адаптувати до вирішення в реальному часі задач планування оптимізації з невизначеністю в складних і змінних умовах роботи системи [19];

- традиційні методи математичної оптимізації ігнорують важливість історичних даних і історичних планів прийняття рішень і не використовують цінну інформацію про історичні дані прийняття рішень, накопичену під час роботи системи.

Останнім часом швидкий розвиток комп'ютерних технологій зробив нейронні мережі (NN) важливим рушієм нової технологічної революції та промислових змін [20]. Новий інтелектуальний метод прийняття рішень з використанням мережевих мереж на основі технології великих даних може бути більш ефективним способом мислення, який може допомогти подолати обмеження математичних методів оптимізації рішень. На відміну від традиційних методів оптимізації, метод прийняття рішень на основі НМ більше не залежить від конкретних математичних моделей або алгоритмів; натомість він навчається з використанням великих реальних даних [21]. Цей метод може значно спростити процес і складність моделювання та вирішення

задачі оптимального планування, а також впоратися з різними теоретичними проблемами та проблемами, які постійно виникають у процесі його самонавчання та саморозвитку. Це потенційно може полегшити перехід від ручного нагляду до моніторингу на основі машинного інтелекту в області планування MG. Крім того, коли дані ускладнюють централізоване навчання моделей через такі фактори, як конфіденційність і розмір, ідея розподілених фреймворків [22 , 23] також може бути використана для децентралізованого навчання малих моделей, а потім об'єднана у велику модель. Це забезпечує велику гнучкість у реалізації методу. На рисунку 1.1 показано перехід від традиційного методу оптимізації до методу на основі НМ.

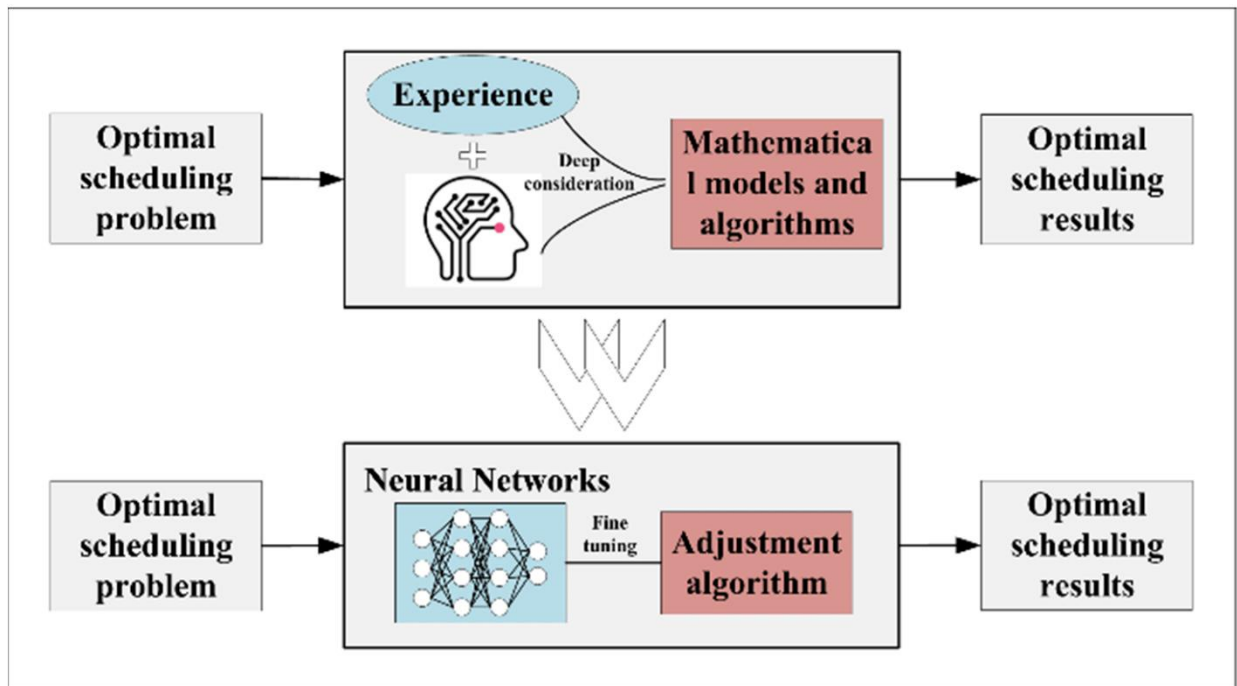


Рисунок 1.1 – порівняння між традиційним методом оптимізації та методом на основі NN

Кілька вчених намагалися використати методи штучного інтелекту (AI) у сфері планування рішень. У [24] використовувалася довгострокова та короткочасна пам'ять (LSTM), щоб встановити відображення від завантаження системи до виходу пристрою. Проте побудована мережева структура є

відносно простою, а результати необмеженими. У [25] використовується багатошаровий перцептрон (MLP) для вивчення та імітації рішення щодо планування інтелектуальної електромережі, а ітераційний алгоритм використовується для виправлення виходу NN так, щоб він задовольняв фактичні обмеження. В [26] використовується нейронна мережа прямого зв'язку (FNN) для оптимального планування систем комбінованого виробництва тепла та електроенергії (CHP), що підвищує ефективність обчислень приблизно в 7000 разів, дозволяючи субоптимальні витрати. Незважаючи на те, що попередні дослідження показали, що НМ є здійсненними та ефективними для оптимального планування енергії, поточні дослідження все ще стикаються з деякими проблемами:

- тільки дані про навантаження використовуються як вхідні дані для навчання без урахування впливу інших даних про стан системи на результати рішення щодо планування. Цей підхід не може повністю витягти інформацію про функції, вбудовану в цінні історичні дані про операції;

- лише використання неглибокої або єдиної мережевої моделі для побудови відношення відображення розкладу точність вихідних результатів є низькою;

- рішення, отримане за допомогою методу планування на основі мережевих мереж, неминуче порушить деякі фактичні обмеження, і немає розумного та ефективного вирішення цієї проблеми.

Для вирішення вищезазначених проблем у цьому документі пропонується двоетапний оптимальний метод планування для MG. Запропонований метод має на меті підвищити ефективність методу планування, керованого мережевими мережами, і здатність MG справлятися з невизначеними коливаннями та подолати обмеження традиційних методів планування участі, керованих математичною моделлю, і ручних методів. У частині на добу наперед (часовий масштаб 1 год), яка не вимагає високої своєчасності, для отримання плану роботи MG використовується модель MILP. У частині на добу наперед (15-хвилинний часовий масштаб) мережа

рішень щодо планування DNN використовується для швидкої оптимізації.

Основні внески цієї роботи такі:

- пропонується внутрішньоденна змінна модель оптимізації, заснована на DNN і великих даних, яка навчається за допомогою набору даних, кластеризованого алгоритмом K-середніх, для покращення узагальненості та точності;

- запропоновано нову мережу планування CNN-Bi LSTM, яка глибоко копає інформацію про функції в даних про роботу системи за допомогою CNN і встановлює точне відображення між входом і виходом за допомогою Bi LSTM;

- пропонується алгоритм корекції балансу потужності для точного налаштування виходів DNN, щоб швидко задовольнити всі практичні обмеження.

Запропонований метод дозволяє ефективно зменшити складність розв'язання задачі оптимального планування та значно підвищити обчислювальну ефективність (скорочуючи час розв'язання внутрішньоденної оптимізації з переміщенням до мілісекунд), що також покращує рівень інтелектуальності MG. Ця робота організована таким чином: Розділ 2 представляє основну математичну модель оптимізації для планування MG на добу наперед. У розділі 3 представлено метод оптимального планування, що базується на DNN. Розділ 4 представляє експерименти моделювання та аналізу.

2 ОПТИМАЛЬНА МОДЕЛЬ ПЛАНУВАННЯ MICROGRID

2.1 Загальна композиційна структура мікромережі

Конкретна композиційна структура MG, що вивчається в цій роботі, показана на рисунку 2.1, де стрілка вказує напрямок потоку потужності.

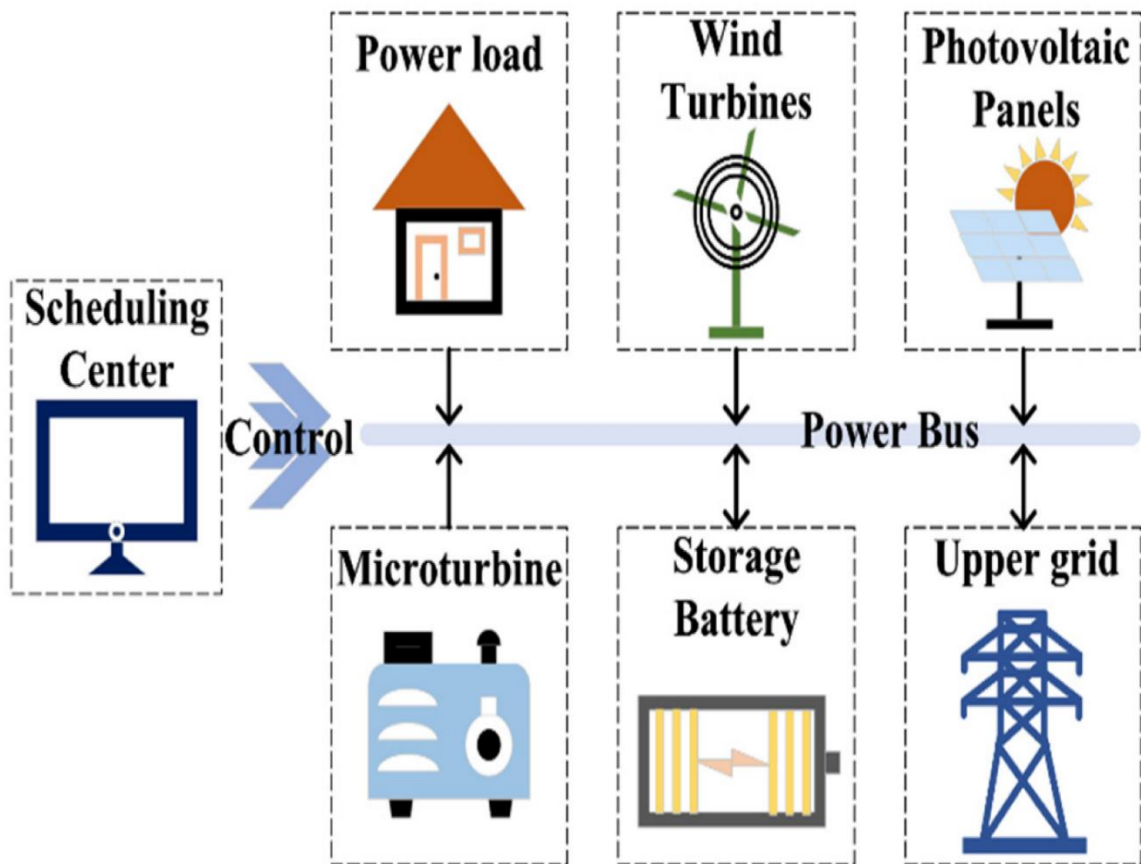


Рисунок 2.1 – Структура MG

Цей MG складається з фотоелектричних панелей (PVs), вітрових турбін (WTs), мікротурбіни (MT), верхньої мережі (UG), акумуляторної батареї (SB) і силового навантаження. Шина живлення є носієм усіх взаємодій живлення пристрою. Розподіл потужності всього MG встановлюється центром диспетчеризації та надсилається кожному керованому пристрою.

2.2 Цільова функція

Метою оптимального планування MG на добу наперед є мінімізація загальних щоденних операційних витрат. Загальні експлуатаційні витрати системи включають експлуатаційні та пускові витрати MT, а також витрати на зарядку/розрядку SB та вартість купівлі/продажу UG. Вищезазначене можна виразити так:

$$\text{Min} \sum_{i=1}^T \sum_{i=1}^N (C_{MT,i,t} + U_{MT,i,t}) + \sum_{i=1}^T (C_{SB,t} + C_{UG,t})$$

$$\left\{ \begin{array}{l} C_{MT,i,t} = a_i P_{MT,i,t}^2 + b_i P_{MT,i,t} + c_i u_{on,,i,t} \\ U_{MT,i,t} = CU_i u_{su,i,t} \\ C_{SB,t} = CS_{SB} P_{SB,t} \\ C_{UG,t} = P_{UG,t} e_t \end{array} \right. ,$$

де $C_{MT,i,t}$, $C_{SB,t}$, $C_{UG,t}$ є експлуатаційними витратами MT, SB та UG на час t , відповідно. $U_{MT,i,t}$ це початкова вартість i -го MT на час t . Рівняння (2) є детальним виразом вартості кожного пристрою, де a_i , b_i , c_i є факторами витраті го MT, і CU_i це початкова вартість i -го MT. CS_{SB} і e_t є факторами витрат SB і ціною електроенергії UG на час t . $P_{MT,i,t}$, $P_{SB,t}$, $P_{UG,t}$ є силою i -го MT, SB та UG одночасно t , відповідно. $u_{on,,i,t}$ і $u_{su,i,t}$ є двійковими змінними для i робочий та пусковий стани МП на час t , відповідно.

Квадратична функція вартості MT лінійно апроксимується шляхом її поділу на S-сегментовані лінійні функції за допомогою методів сегментованої лінеаризації [27], що зменшує складність вирішення загальної моделі. Результати лінеаризації такі:

$$\tilde{C}_{MT,i,t} = c_i u_{on,,i,t} + \sum_{s=1}^S a_s P_{MT,i,t,s}^2$$

$$a_s = \frac{C_{MT,i,s+1} - C_{MT,i,s}}{P_{MT,i,s+1} - P_{MT,i,s}},$$

де $\tilde{C}_{MT,i,t}$ – функція вартості МТ після сегментів лінеаризації, S – загальна кількість сегментів, a_s – нахил кожного сегмента, $P_{MT,i,s}$ є результатом i го МТ в s -го сегмента.

2.3 Обмеження

Обмеження оптимального планування МГ на добу наперед включають обмеження балансу потужності, обмеження роботи контрольованого блоку, обмеження роботи SB та обмеження роботи UG.

2.3.1 Обмеження балансу потужностей

Рівняння (5) показує, що виробництво та споживання електроенергії збалансовані в усі моменти МГ.

$$\sum_{i=1}^N P_{MT,i,t} + P_{SB,t} + P_{UG,t} + P_{WT,t} + P_{PV,t} = P_{Load,t}, \quad \forall t$$

де $P_{WT,t}$, $P_{PV,t}$, і $P_{Load,t}$ є потужністю WT, PV та потужністю навантаження в момент часу t , відповідно.

2.3.2 Контрольовані робочі обмеження установки

Робочі обмеження керованого агрегату (МТ) включають обмеження потужності, швидкості зміни та статусу блоку. Наведені вище обмеження виражаються таким чином:

$$P_{MT,i}^{min} u_{on,i,t} \leq P_{MT,i,t} \leq P_{MT,i}^{max}, \quad \forall i, t$$

$$-P_{MT,i}^{down} \leq P_{MT,i,t} - P_{MT,i,t-1} \leq P_{MT,i}^{up}, \quad \forall i, t$$

$$u_{su,i,t} - u_{sd,i,t} = u_{on,i,t} - u_{on,i,t-1}, \quad \forall i, t$$

$$u_{su,i,t} + u_{sd,i,t} \leq 1, \quad \forall i, t$$

де $P_{MT,i}^{min}$, $P_{MT,i}^{max}$ мінімальна і максимальна вихідна потужність i -го МТ. $P_{MT,i}^{down}$ і $P_{MT,i}^{up}$ є обмеженнями швидкості підвищення та зниження i -го МТ. $u_{sd,i,t}$ є двійковими змінними для i -го МТ стану зупинки в момент часу t .

2.3.3 Експлуатаційні обмеження акумуляторної батареї

Робочі обмеження SB включають обмеження стану заряджання та розряджання, обмеження вихідної потужності, обмеження ємності та обмеження циклу ємності. Наведені вище обмеження виражаються таким чином:

$$u_{cha,t} + u_{dis,t} \leq 1, \forall t$$

$$0 \leq P_{SB,t}^{dis} \leq P_{max}^{dis} u_{dis,t}, \forall t$$

$$P_{max}^{char} u_{char,t} \leq P_{SB,t}^{char} \leq 0, \forall t$$

$$P_{SB,t} = \eta_{SB} (P_{SB,t}^{dis} u_{dis,t} + P_{SB,t}^{char} u_{char,t}), \forall t$$

$$E_{SB,t} = E_{SB,t-1} + P_{SB,t}, \quad \forall t$$

$$E_{min} \leq E_{SB,t} \leq E_{max}, \forall t$$

$$E_0 = E_{end},$$

де $u_{char,t}$ і $u_{dis,t}$ є двійковими змінними заряджання та розряджання в момент часу t , відповідно. $P_{SB,t}^{char}$, $P_{SB,t}^{dis}$, P_{max}^{char} і P_{max}^{dis} є потужністю заряджання та розряджання за один раз t та його обмеження відповідно. η_{SB} це ефективність перетворення потужності. $E_{SB,t}$ це ємність на час t і E_{min} , E_{max} є мінімальна і максимальна місткість.

2.3.4 Обмеження контактної лінії живлення

Обмеження на UG в основному відображаються на лінії електропередачі, яка з'єднує його з MG. Обмеження лінії електропередачі включають обмеження випуску та обмеження стану купівлі та продажу електроенергії. Наведені вище обмеження виражаються таким чином:

$$u_{buy,t} + u_{sell,t} \leq 1, \forall t$$

$$0 \leq P_{UG,t}^{buy} \leq P_{max}^{buy} u_{buy,t} \forall t$$

$$P_{max}^{sell} u_{sell,t} \leq P_{UG,t}^{sell} \leq 0, \forall t$$

$$P_{UG,t} = P_{UG,t}^{buy} u_{buy,t} + P_{UG,t}^{sell} u_{sell,t}, \forall t$$

де $u_{buy,t}$ і $u_{sell,t}$ є двійковими змінними купівлі та продажу електроенергії в момент часу t , відповідно. $P_{UG,t}^{buy}$, $P_{UG,t}^{sell}$, P_{max}^{buy} , P_{max}^{sell} є купівля потужності, час продажу t , та його обмеження відповідно.

На даний момент модель оптимального планування на добу наперед для MG на основі MILP повністю побудована.

3 ГЛИБОКИЙ МЕТОД ВНУТРІШНЬОДЕННОЇ ОПТИМІЗАЦІЇ НА ОСНОВІ НЕЙРОННОЇ МЕРЕЖІ

У цій роботі пропонується керований даними метод планування на основі DNN для усунення недоліків і труднощів традиційних методів внутрішньоденної оптимізації. Замість того, щоб покладатися на конкретні математичні моделі, він навчається з великими обсягами реальних даних і приймає рішення щодо планування за допомогою багатовимірного множення матриці [28]. Цей метод дозволяє зменшити складність вирішення задачі оптимального планування та значно підвищити ефективність обчислень.

3.1 Форми поточної оптимізації MPC протягом дня

У цьому роботі мережа рішень щодо планування DNN використовується як оптимізатор для MPC (model predictive control) для виконання оптимізації в межах дня. MPC – це чергування процесів безперервної локальної оптимізації та безперервної реалізації ролей контролю. Завдяки отриманню ультракороткострокової прогнозової інформації про потужність у режимі реального часу під час внутрішньоденного планування та використанню фактичних результатів планування та нової прогнозової інформації як зворотного зв'язку, форми постійної оптимізації MPC можуть значно зменшити вплив невизначеностей MG на оптимальне робоче планування. Загальні кроки оптимізації MPC можна виразити наступним чином:

Крок 1. На основі поточного моменту та поточного стану системи за певною моделлю прогнозування отримується стан системи в майбутньому періоді.

Крок 2. На основі стану системи в майбутньому періоді вирішується задача оптимізації в цьому періоді для отримання послідовності керування в цьому періоді.

Крок 3. До системи застосовується лише дія першого моменту керуючої послідовності, а вищевказані кроки повторюються для наступного моменту.

3.2 Загальна структура методу прийняття рішень щодо внутрішньоденного планування на основі DNN

Загальна структура методу внутрішньоденного планування на основі DNN показана на рисунку 3.1, який в основному включає: етап створення навчального набору даних, етап навчання в автономному режимі та етап прийняття рішення в режимі онлайн.

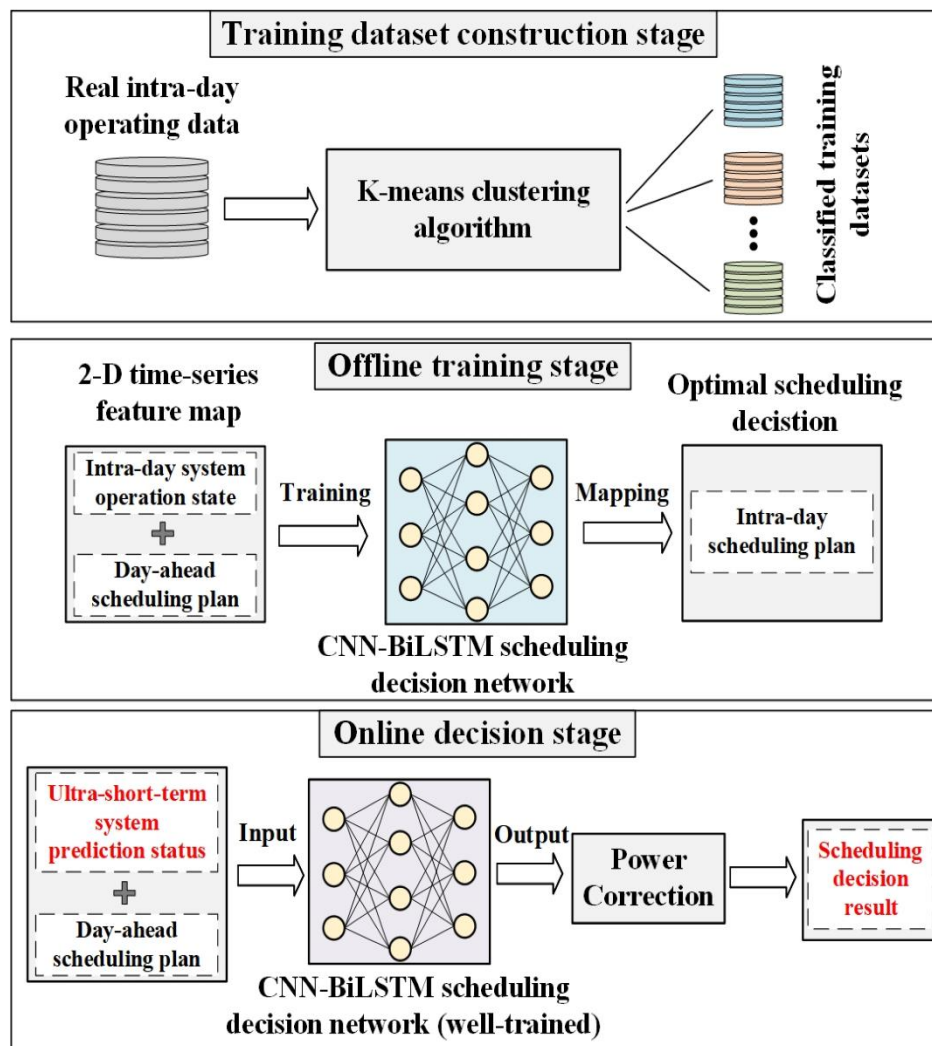


Рисунок 3.1 – Структура запропонованого внутрішньоденного методу

Етап побудови навчального набору даних. Щоб підвищити точність і зменшити тиск на можливість узагальнення мережі, численні реальні робочі дані MG, зібрані в кластеризації за допомогою алгоритму K-середніх [29], розділяючи на різні навчальні набори. Потреба чистого навантаження системи P_{Load}^{net} , яке є 96-вимірним часовим рядом, представленим як $P_{Load}^{net} = P_{Load} - P_{Wind} - P_{PV}$, використовується як індекс кластеризації.

Офлайн етап навчання. Двовимірний часовий ряд функцій, що містить стан роботи системи, будується як вхідні дані для мережі CNN-Bi LSTM. Оптимальний план планування — це вихід мережі, який навчає кілька мереж рішень щодо планування з різними навчальними наборами даних.

Етап прийняття рішення онлайн. Стан надкороткострокового прогнозування системи поєднується з планом роботи на добу наперед і передається в добре навчену мережу CNN-Bi LSTM. Виходи мережі точно налаштовуються за допомогою алгоритму корекції потужності, щоб отримати остаточне рішення щодо планування.

3.3 Вступ до глибоких нейронних мереж

3.3.1 Згорткові нейронні мережі

Ефективна здатність CNN виділяти ознаки робить її найбільш широко використовуваною моделлю в області глибокого навчання. CNN в основному складається з згорткового рівня та рівня об'єднання. Згортковий рівень виконує ефективне нелінійне виділення локальних ознак за допомогою згорткових ядер, тоді як рівень об'єднання стискає витягнуті ознаки та генерує більш значущу інформацію про ознаки для підвищення можливостей узагальнення [30]. Базова структура CNN показана на рисунку 3.2.

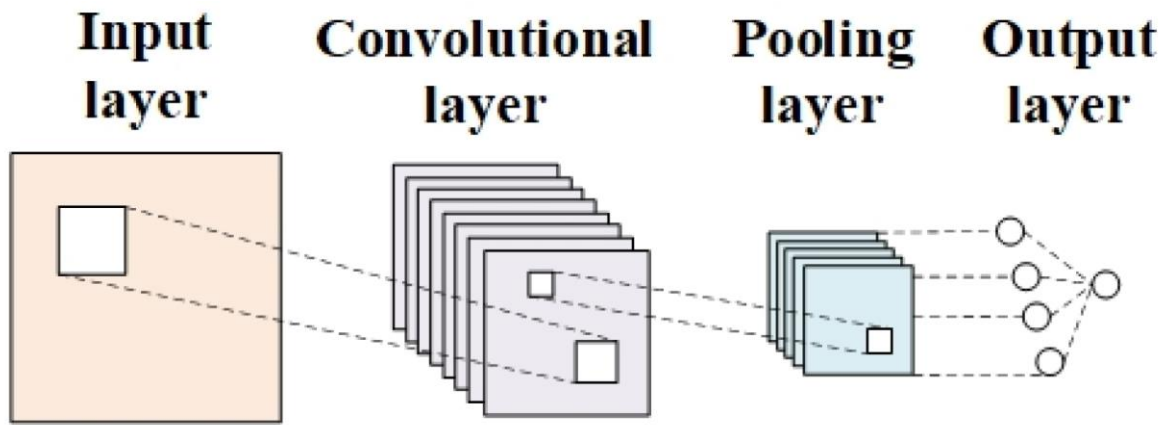


Рисунок 3.2 – Базова структура CNN

3.3.2 Двонаправлені мережі довгострокової та короткочасної пам'яті

Ми починаємо з представлення мережі LSTM, яка містить пропускі ворота, вхідні та вихідні ворота, а базову структуру показано на рисунку 3.3.




Рисунок 3.3 – Базова структура LSTM

На рисунку 3.3 σ представляють функції активації Sigmoid і Tanh відповідно. Розрахунок даних у LSTM виглядає наступним чином:

$$f_t = \delta(W_f[h_{t-1}, x_t] + b_f),$$

$$i_t = \delta(W_i[h_{t-1}, x_t] + b_i),$$

$$Z_t = \tanh(W_c[h_{t-1}, x_t] + b_c),$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes Z_t,$$

$$o_t = \delta(W_o[h_{t-1}, x_t] + b_o),$$

$$h_t = o_t \otimes \tanh(C_t),$$

де W_{\square} і b_{\square} позначають вагову матрицю та вектор зміщення відповідно. \otimes являє собою скалярний добуток. h_{t-1} і h_t позначають вихід минулого та поточного моментів відповідно. C_{t-1} і C_t позначають стан пам'яті останнього та поточного моментів відповідно. Z_t є проміжним станом мережі. i_t і o_t означають, що поточні стани додають градуси та вихідні градуси відповідно. x_t є входом поточного моменту. σ представляють функції активації sigmoid і tanh відповідно. Структура LSTM збирає інформацію про функції лише з поточного вхідного та минулого часових рядів кожного разу, не враховуючи інформацію про особливості з майбутніх часових рядів.

У цій роботі двонаправлений LSTM використовується як мережа внутрішнього відображення мережі прийняття рішень щодо планування для підвищення точності результатів прийняття рішень і продуктивності вилучення тимчасових ознак. Bi LSTM є варіантом структури LSTM, який включає як прямий, так і зворотний рівні LSTM [31]. Структура Bi LSTM дозволяє збирати інформацію як у прямому, так і в зворотному напрямках,

дозволяючи мережі враховувати минулі та майбутні дані. Це покращує можливості вилучення функцій моделі без необхідності додаткових даних. Структура Bi LSTM проілюстрована на рисунку 3.4.




Рисунок 3.4 – Структура Bi LSTM

3.4 Мережа прийняття рішень щодо внутрішньоденного планування CNN-Bi LSTM

Навчена великою кількістю реальних операційних даних, мережа прийняття рішень щодо внутрішньоденного планування CNN-Bi LSTM може вивчати закономірність між станом системи та результатом рішення щодо планування. Як тільки параметри зафіксовані в мережі, він може забезпечити оптимальний план планування надзвичайно швидко за будь-якого робочого сценарію.

3.4.1 Вхід і вихід CNN-Bi LSTM

Мережа прийняття рішень щодо планування CNN-Bi LSTM імітує ідею MPC для внутрішньоденної постійної оптимізації з доменом прогнозування,

встановленим на 2 години, а контрольним – на 15 хвилин. Для глибокого аналізу неявної інформації про значення в операційних даних системи ми встановлюємо вхідні дані X цієї мережі у формі двовимірного графіка часових рядів у градаціях сірого. Вихід Y мережі є оптимальним планом планування. Конкретний вираз такий:

$$X = [P_{Load}(t, t + \tau), P_{Wind}(t, t + \tau), P_{PV}(t, t + \tau), P_{SB}^{ahead}(t, t + \tau), P_{UG}^{ahead}(t, t + \tau), P_{MT}^{ahead}(t, t + \tau)]'$$

$$Y = [P_{SB}^*(t, t + \tau), P_{UG}^*(t, t + \tau), P_{MT}^*(t, t + \tau)]'$$

X це $9*(\tau+1)$ матриця, що складається з внутрішньодобового вектора стану системи (енергетичне навантаження, WT і PV) у період t до $t + \tau$ та вектор плану роботи керованих пристроїв (SB, UG, MT) на добу наперед у відповідний час. Цифра 9 позначає кількість вхідних ознак. Y це $1*6(\tau + 1)$ вектор, що складається з внутрішньодобового оптимального плану роботи керованих пристроїв у періоді t до $t + \tau$. Число 6 вказує кількість керованих пристроїв у функціях виведення. P_{\square}^{ahead} це операційний план на день вперед, і P_{\square}^* є внутрішньодобовим оптимальним планом роботи. Оскільки область передбачення MPC встановлена на 2 години, τ встановлено як 7 у цьому документі, і всі перераховані вище змінні є реальними.

3.4.2 Структура CNN-Bi LSTM

Оскільки зв'язок відображення між робочим станом системи та рішенням щодо планування є складним, у цій роботі використовується багаторівнева мережа CNN-Bi LSTM для глибокого аналізу даних. Ця мережа в основному складається з тришарового CNN і тришарового Bi LSTM і пов'язана шаром Flatten. CNN в основному виділяє функцію кореляції

потужності, тоді як Bi LSTM зосереджується на вилученні функції часового ряду потужності. Рівень пакетної нормалізації (BN) може вирішити проблему чисельної нестабільності в DNN, роблячи розподіл окремих функцій в одній партії подібним. У цьому документі рівень BN вставляється між кожним шаром згортки та шаром об'єднання, щоб нормалізувати функції в мережі та прискорити навчання. Рівень вилучення — це рівень, який використовується після кожного Bi LSTM для підвищення ефективності узагальнення мережі. Нарешті, дані налаштовуються на векторний вихід у вказаному розмірі через повністю зв'язаний (щільний) шар. Конкретна структура запропонованого CNN-Bi LSTM у цьому документі показана на рисунку 3.5.

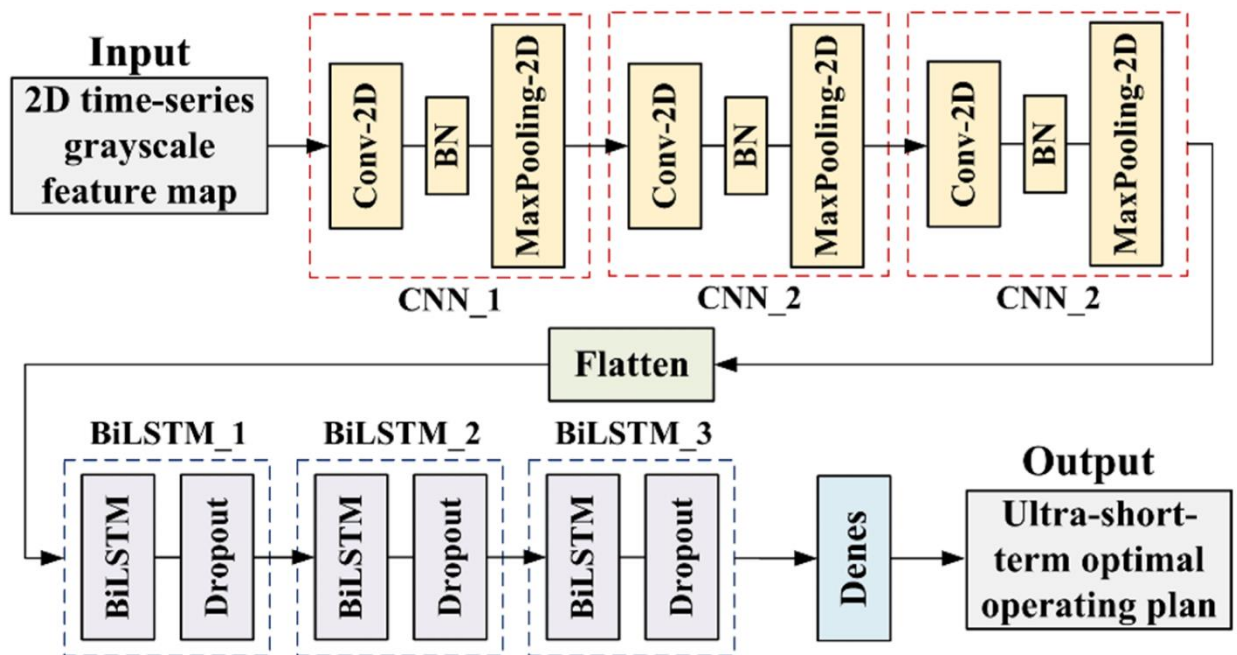


Рисунок 3.5 – Структура CNN-Bi LSTM

3.4.3 Налаштування CNN-Bi LSTM

Щоб краще виділити та абстрагувати вхідну функцію, кількість згорткових ядер встановлено на 64, 128 і 256, а розмір згорткових ядер встановлено на 7×7 , 5×5 і 3×3 . Кількість нейронів Bi LSTM встановлюється на

256, 128 і 64 відповідно, а швидкість падіння шару випадання рівномірно встановлюється на 0,25. Нормалізуйте навчальні дані мережі до значень від 0 до 1, використовуючи метод максимальної–мінімальної нормалізації. Мережа навчається за допомогою алгоритму оптимізації Адама [32], а середня квадратична помилка (RMSE) встановлюється як функція втрат мережі, яка визначається наступним чином:

$$RMSE = \sqrt{\sum_{i=1}^M \sum_{t=1}^T (y_{i,t}^* - y_{i,t})^2 / T},$$

де $y_{i,t}^*$ і $y_{i,t}$ є справжніми та прогнозованими планами розкладу для i -й пристрій за раз t , відповідно. M – кількість керованих пристроїв в МГ.

3.5 Алгоритм корекції балансу потужностей

Як і прогнозування навантаження, метод планування на основі DNN є принципово процесом нелінійної регресії. Отже, результат неминуче не відповідає певним практичним обмеженням. Щоб вирішити цю проблему, ми використовуємо алгоритм корекції балансу потужності (РВС), щоб налаштувати вихід, що робить його практичним у використанні. Натхненний алгоритмом середньої узгодженості, ми використовуємо різницю між загальним споживанням електроенергії та загальним виробленням за певний час як показник узгодженості. Вихідні дані з DNN оновлюються шляхом повторення (рівняння (30) і (31)). Будь-які оновлені результати, які порушують робочі обмеження пристрою, потребують додаткової корекції (Рівняння (32)). Цей алгоритм позначається так:

$$\delta_t^{[n]} = \left(P_{Load,t}^{net} - \sum_{i=1}^K P_{i,t}^{[n]} / K \right)$$

$$P_{i,t}^{[n+1]} = P_{i,t}^{[n]} + \delta_t^{[n]}$$

$$P_{i,t}^{[n+1]} = \begin{cases} P_i^{max}, P_{i,t}^{[n+1]} > P_i^{max} \\ P_i^{min}, P_{i,t}^{[n+1]} < P_i^{min} \\ P_{i,t}^{[n+1]} + P_i^{up}, P_{i,t}^{[n+1]} - P_{i,t-1}^{[n+1]} > P_i^{up} \\ P_{i,t}^{[n+1]} - P_i^{down}, P_{i,t}^{[n+1]} - P_{i,t-1}^{[n+1]} < P_i^{down} \\ P_{i,t}^{[n+1]}, otherwise \end{cases},$$

де n це кількість ітерацій. $P_{i,t}^{[n]}$ і K є силою i -го генератора електроенергії за один раз t та загальна кількість генераторів у MG відповідно. Поки що внутрішньоденна модель оптимального планування MG на основі CNN-Ві LSTM-PBC повністю побудована.

4 АНАЛІЗ МОДЕЛЮВАННЯ ТА ПОРІВНЯННЯ

4.1 Введення прикладів параметрів і системи тестування

Для перевірки ефективності запропонованого методу для імітаційного тестування використовується типова мережева система MG. Цей MG складається з однієї лінії електропередач WT, PV, SB, UG та MT. Налаштування параметрів наведено в Додатку А.

Дані про вітер, сонце та навантаження в цьому документі були взяті з датасету електростанції, загалом за 356 днів. Дані рішення щодо планування для навчання мережі були створені та розв'язані за допомогою Yalmip із вирішувачем Cplex. DNN було створено, навчено та оцінено на основі платформи Matlab R2020a. Налаштування на 300 раундів навчання зі змінною швидкістю навчання та початковою швидкістю навчання 0,01. Симуляційні тести проводилися під процесором Intel(R) Core (TM) i5-11300H 3,10 ГГц 3,11 ГГц 11-го покоління.

4.2 Аналіз ефективності запропонованого методу

Оптимальна кількість кластерів K-середніх була визначена «методом ліктя» як 3. Випадково вибраний день у кожній категорії даних використовується як тестовий сценарій. 3 типи сценаріїв протестовано в таблиці 4.1 . В якості показників оцінки ефективності запропонованого методу в даній роботі використовуються експлуатаційні витрати та RMSE. Чим менше ці два показники, тим кращий план розкладу.

Таблиця 4.1 – Результати 3 типів методу планування на основі DNN.

Тип сцени	Розмір навчальної вибірки/день	Час навчання/с	RMSE	Час прийняття рішення протягом повного дня
1	165	278,18	5,7683	0,3599
2	91	171,54	8,9152	0,3761
3	106	196,42	7,3725	0,3698

З метою ілюстрації сценарій 1 аналізується як приклад сценарію. Оптимальна вартість експлуатації MG на добу наперед на основі MILP становить 12 621 юань. Оптимальна операційна вартість MG протягом дня на основі CNN-Ві LSTM-PBC становить 15320 гривень, а час розв'язання оптимізації MPC за весь день становить 0,4636 с. Оптимальний план планування можна побачити на рисунку 4.1.

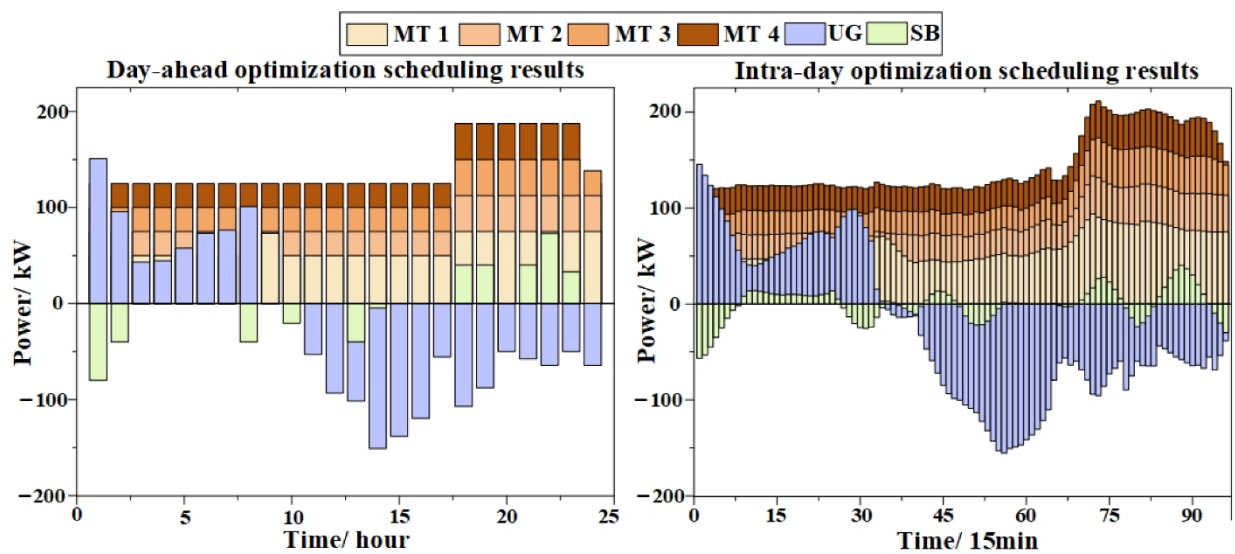


Рисунок 4.1 – Результати дворівневого оптимального планування MG

Форми кривих планування на добу наперед і кривих планування всередині дня приблизно подібні, що вказує на те, що CNN-Ві LSTM-PBC може завершити виведення розумних і ефективних рішень щодо планування

за дуже короткий час. Метод прийняття рішення про планування на основі DNN використовує інтенсивне навчання з історичними даними прийняття рішень для встановлення прямого зв'язку між відомими входами та результатами рішень. Після того, як ємність і якість вибірки можуть бути гарантовані, метод може відповідати будь-якій моделі планування рішень з високою застосовністю.

4.3 Порівняльний аналіз різних методів

4.3.1 Порівняння з традиційними методами

У частині оптимізації протягом дня порівнюються традиційні математичні моделі MPC, CNN-Bi LSTM і CNN-Bi LSTM-PBC. Результати наведені в таблиці 4.2.

Таблиця 4.2 – Порівняння ефективності кожного внутрішньоденного методу.

Метод	Розрахунок час/с	Операційні витрати/CNY	RMSE	Чи порушує це обмеження?
Traditional MPC	125.4531	14,973	0	ні
CNN-Bi LSTM	0.3599	15,779	5.7683	так
CNN-Bi LSTM-PBC	0.4636	15,320	3.6411	ні

Експлуатаційні витрати, розраховані за допомогою CNN-Bi LSTM і CNN-Bi LSTM-PBC, лише на 5,38% і 2,32% вищі, ніж традиційний метод MPC, відповідно, але ефективність розрахунку покращена приблизно в 300 разів. Це вказує на те, що мережа прийняття рішень щодо планування на основі DNN буде імітувати фактичний план роботи оптимального планування та значно

зменшити складність вирішення проблеми оптимального планування за допомогою навчання та нелінійного відображення великої розмірності.

4.3.2 Вплив ємності набору даних навчання

Змінюючи кількість зразків у навчальних даних для навчання керованої даними моделі рішення про планування, результуюча модель тестується з використанням тих самих типових денних тестових зразків. Результати наведені в таблиці 4.3.

Таблиця 4.3 – Результати тестування різних ємностей наборів даних.

Потужність/день	Час навчання/с	RMSE
30	79,71	16,5679
60	133,47	11,4329
90	184,55	8,9458
120	223,78	7,3893
150	251,72	6,0256

Збільшення часу навчання та зменшення RMSE вказують на те, що продуктивність і точність прийняття рішень моделі, керованої даними, зростають зі збільшенням ємності вибірки, тобто DNN постійно розвивається та самокоригується в міру збільшення кількості вибірок. На рисунку 4.2 показано порівняння поточних витрат за цілий день модифікованої моделі на основі даних і реальних поточних витрат за цілий день. Зі збільшенням об'єму вибірки операційні витрати на результати прийняття рішень на основі даних наближаються до оптимальних операційних витрат планування, керованих традиційним методом MPC.

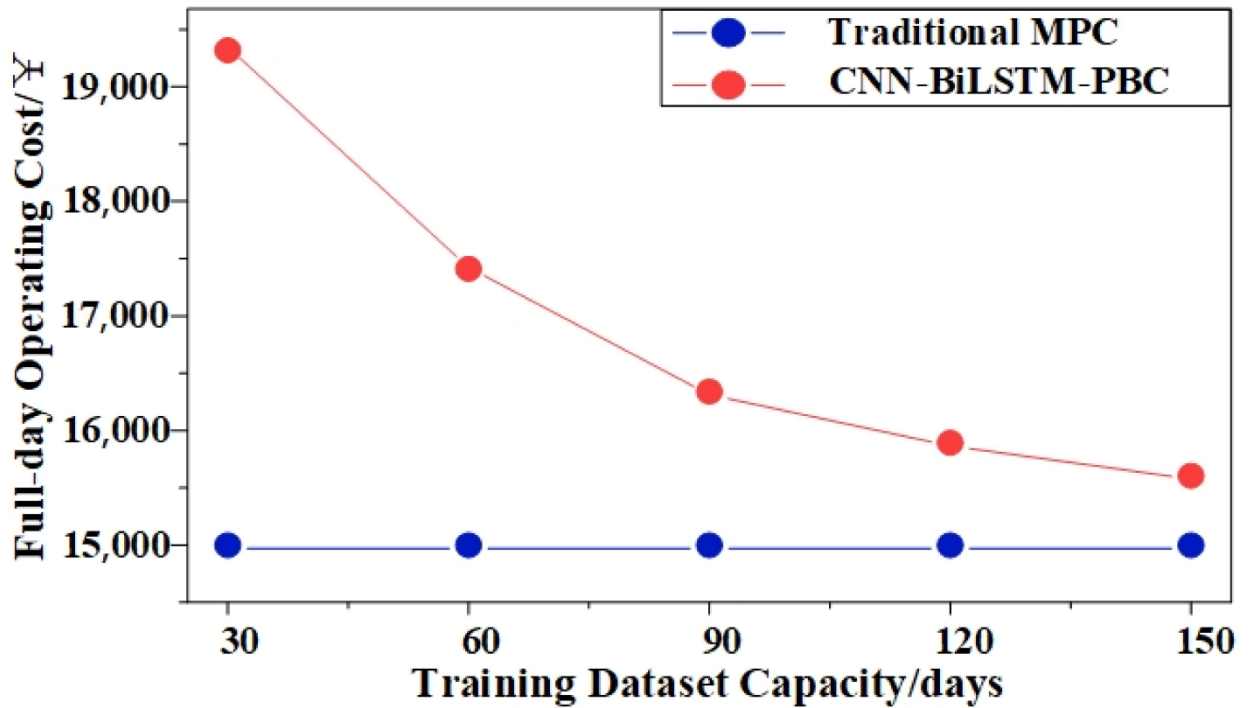


Рисунок 4.2 – Порівняння операційних витрат за різних можливостей набору даних для навчання

4.3.3 Вплив кластеризації даних

Порівнюючи два сценарії, кластеризований і некластеризований, з однаковими іншими параметрами, некластеризований сценарій випадковим чином вибирає 160 неповторюваних днів із даних за цілий рік як навчальні зразки. Щоб більш інтуїтивно проілюструвати вплив кластеризації на точність остаточного рішення щодо планування, вихід DNN не коригується за допомогою PBC. Баланс потужності для обох випадків показано на рисунку 4.3.

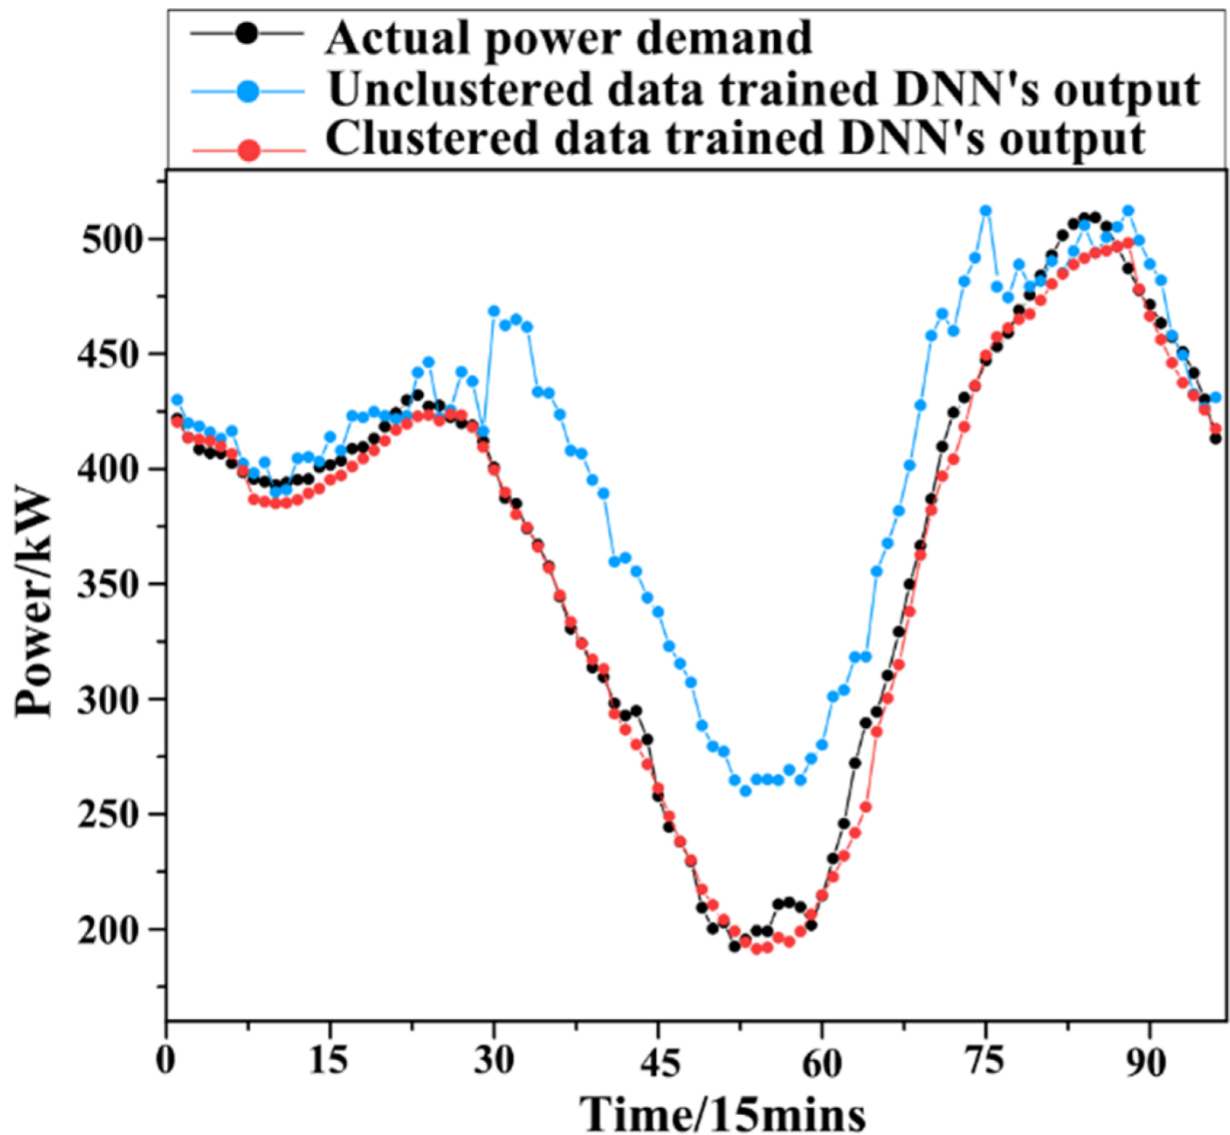


Рисунок 4.3 – Порівняння кластеризованих даних навчання з некластеризованими даними навчання

Вихід мережі планування на основі DNN, навченої некластеризованими даними, більше відхиляється від реального попиту на електричне навантаження, тобто вказує на низьку точність її рішення. Це тому, що узагальнення поточної моделі глибокого навчання не може впоратися з такими великими розбіжностями сценаріїв. Якщо DNN використовується для навчання, він генеруватиме унікальну компромісну модель відображення під час процесу навчання в умовах дуже різних історичних вибірових даних, що ускладнює гарантію точності прийняття рішень.

4.3.4 Вплив різних моделей DNN відображення серверної частини

Різні серверні мережі відображення були навчені, а потім протестовані для порівняння на тих самих зразках, а решта налаштувань були однаковими. Результати наведені в таблиці 4.4.

Таблиця 4.4 – Результати тестування різних DNN.

Тип мережі	Час навчання/с	RMSE
Single RNN	172.92	16.8767
Single LSTM	186.33	13.0241
Single Bi LSTM	213.45	10.4537
Double RNN	207.78	13.8254
Double LSTM	212.22	9.3126
Double Bi LSTM	231.89	7.8772
Triple RNN	247.55	10.6133
Triple LSTM	253.34	7.4122
Triple Bi LSTM	278.18	6.0256

Серед них точність рішення RNN завжди відстає від LSTM і Bi LSTM через його просту структуру, яка призводить до його нездатності відкидати неважливу інформацію, і його схильність страждати від проблеми градієнтного вибуху під час процесу навчання. Точність рішення Bi LSTM завжди вища, ніж у LSTM, тому що Bi LSTM має як прямий LSTM, так і зворотний LSTM одночасно в неявному рівні, який має ще два параметри і до, і після 2- часові вузли впливають на його вихідні результати, тому він має більше енергії для аналізу інформації.

ВИСНОВКИ

У цій кваліфікаційній роботі пропонується дворівневий метод прийняття рішень щодо оптимального планування на основі DNN для MG, який усуває обмеження традиційних методів на основі математичної моделі. Замість вивчення внутрішнього механізму проблеми оптимізації метод базується на мережі DNN, яка використовує масове історичне навчання даних прийняття рішень для безпосередньої побудови зв'язку відображення між відомими вхідними даними та результатами прийняття рішень. Цей підхід порушує традиційне мислення про рішення оптимального планування та забезпечує новий спосіб оптимального планування MG.

Аналіз розрахункових прикладів дозволяє зробити такі висновки:

- використання секретних даних для окремого навчання різних моделей DNN може ефективно підвищити точність рішення щодо планування CNN-Ві LSTM і запобігти зближенню моделей до компромісного рішення з меншою точністю.

- метод планування на основі DNN досягає оптимального рішення щодо планування шляхом відображення, тим самим зменшуючи складність і підвищуючи ефективність вирішення проблеми оптимального планування. Крім того, у міру збільшення ємності навчального набору даних точність рішення методу продовжує покращуватися.

- щоб вирішити проблему, коли вихідні результати методу DNN не відповідають практичним обмеженням, модель PBC ефективно виправляє вихідні результати, що значно покращує практичну застосовність методу планування на основі DNN.

На завершення, будучи новим та ефективним алгоритмом рішення, метод, запропонований у цьому документі, може забезпечити практичну та надійну довідку для центрів планування MG, щоб допомогти прийняти рішення. Це значно підвищить надійність операцій у невизначеному

середовищі планування MG та економічність рішень щодо планування. У майбутніх дослідженнях ми далі досліджуватимемо зв'язок між станом роботи системи та рішеннями щодо планування та спробуємо побудувати складні моделі DNN із «механізмами уваги», щоб підвищити точність прийняття рішень методами, керованими даними. Крім того, також буде розглянуто вирішення проблеми оптимального планування для кількох взаємопов'язаних MG.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Zheng, B.; Wu, X. Integrated capacity configuration and control optimization of off-grid multiple energy system for transient performance improvement. *Appl. Energy* 2022, 311, 118638.
2. Ляшенко О.С. Модель безпечного функціонування розумних розподільчих мереж, Ляшенко О.С., Філімончук Т.В., Заєць В.А. / Проблеми інформатизації. Тези доповідей одинадцятої міжнародної науково-технічної конференції (16 – 17 листопада 2023 року) Том 3. С. 103.
3. Ляшенко О.С., Тухтаров В.Б. Метод прийняття рішень для планування роботи мікромережі за допомогою штучного інтелекту. Сучасний стан наукових досліджень і технологій в промисловості. 2(73). 2024 (подана в редакцію)
4. Chang, L.U.; Li, G.; Yixin, L.; Shuang, G.; Bin, X.U. Distributed Optimal Dispatching Method for Independent Microgrids Based on Flexible Interconnection. *Power Syst. Technol.* 2019, 43, 1512–1519.
5. Корнієнко, Є., Ляшенко, О. і Торба, А. (2023) «Метод керування системою генерації електроенергії з використанням бездротових технологій», Сучасний стан наукових досліджень та технологій в промисловості, (2(24), с. 80–89. doi: 10.30837/ITSSI.2023.24.080.
6. Li, B.; Roche, R.; Miraoui, A. Microgrid sizing with combined evolutionary algorithm and MILP unit commitment. *Appl. Energy* 2017, 188, 547–562.
7. Zhu, J.; Mo, X.; Zhu, T.; Guo, Y.; Liu, M. Real-time stochastic operation strategy of a microgrid using approximate dynamic programming-based spatiotemporal decomposition approach. *IET Renew. Power Gener.* 2019, 13, 3061–3070.
8. Duan, Y.; Zhao, Y.; Hu, J. An initialization-free distributed algorithm for dynamic economic dispatch problems in microgrid: Modeling, optimization and

analysis. *Sustain. Energy Grids Netw.* 2023, 34, 101004.

9. Li, P.; Xu, D.; Zhou, Z.; Lee, W.J.; Zhao, B. Stochastic Optimal Operation of Microgrid Based on Chaotic Binary Particle Swarm Optimization. *IEEE Trans. Smart Grid* 2017, 7, 66–73.

10. Zhang, F.; Shen, Z.; Xu, W.; Wang, G.; Yi, B. Optimal Power Flow Algorithm Based on Second-Order Cone Relaxation Method for Electricity-Gas Integrated Energy Microgrid. *Complexity* 2021, 2021, 2073332.

11. Lu, J.; Liu, T.; He, C.; Nan, L.; Hu, X. Robust day-ahead coordinated scheduling of multi-energy systems with integrated heat-electricity demand response and high penetration of renewable energy. *Renew. Energy* 2021, 178, 466–482.

12. Guo, L.; Liu, W.; Jiao, B.; Hong, B.; Wang, C. Multi-objective stochastic optimal planning method for stand-alone microgrid system. *IET Gener. Transm. Distrib.* 2014, 8, 1263–1273.

13. Ляшенко О.С. Модель управління розподілом електроенергії на базі ієрархічної архітектури Cloud-Fog. Ляшенко О.С., Знайдюк В.Г, Гладченко Ю.В // Проблеми інформатизації Тези доповідей одинадцятої міжнародної науково-технічної конференції (16 – 17 листопада 2023 року) Том 1. С. 44.

14. Ding, Y.F.; Morstyn, T.; Mcculloch, M.D. Distributionally Robust Joint Chance-Constrained Optimization for Networked Microgrids Considering Contingencies and Renewable Uncertainty. *IEEE Trans. Smart Grid* 2022, 13, 2467–2478.

15. Melhem, F.Y.; Grunder, O.; Hammoudan, Z.; Moubayed, N. Energy Management in Electrical Smart Grid Environment Using Robust Optimization Algorithm. *IEEE Trans. Ind. Appl.* 2018, 54, 2714–2726.

16. Hosseini, S.M.; Carli, R.; Dotoli, M. Robust Day-ahead Energy Scheduling of a Smart Residential User under Uncertainty. In Proceedings of the 2019 18th European Control Conference (ECC): 18th European Control Conference (ECC), Naples, Italy, 25–28 June 2019; IEEE: Piscataway, NJ, USA; pp. 935–940.

17. Pourmousavi, S.A.; Nehrir, M.H.; Sharma, R.K. Multi-Timescale Power

Management for Islanded Microgrids Including Storage and Demand Response. *IEEE Trans. Smart Grid* 2015, 6, 1185–1195.

18. Acevedo-Arenas, C.Y.; Correcher, A.; Sanchez-Diaz, C.; Ariza, E.; Alfonso-Solar, D.; Vargas-Salgado, C.; Petit-Suarez, J.F. MPC for optimal dispatch of an AC-linked hybrid PV/wind/biomass/H₂ system incorporating demand response. *Energy Convers. Manag.* 2019, 186, 241–257.

19. Peng, Y.H.; Jolfaei, A.; Yu, K.P. A Novel Real-Time Deterministic Scheduling Mechanism in Industrial Cyber-Physical Systems for Energy Internet. *IEEE Trans. Ind. Inform.* 2022, 18, 5670–5680.

20. Wang, W.; Yang, D.; Huang, N.; Lyu, C.; Zhang, G.; Han, X. Irradiance-to-power conversion based on physical model chain: An application on the optimal configuration of multi-energy microgrid in cold climate. *Renew. Sustain. Energy Rev.* 2022, 161, 112356.

21. Dong, G.Z.; Chen, Z.H. Data-Driven Energy Management in a Home Microgrid Based on Bayesian Optimal Algorithm. *IEEE Trans. Ind. Inform.* 2019, 15, 869–877.

22. Khalil, R.A.; Saeed, N.; Masood, M.; Fard, Y.M.; Alouini, M.S.; Al-Naffouri, T.Y. Deep Learning in the Industrial Internet of Things: Potentials, Challenges, and Emerging Applications. *IEEE Internet Things J.* 2021, 8, 11016–11040.

23. Liu, H.Z.; Shen, X.W.; Guo, Q.L.; Sun, H.B. A data-driven approach towards fast economic dispatch in electricity-gas coupled systems based on artificial neural network. *Appl. Energy* 2021, 286, 116480.

24. Tushar, M.; Zeineddine, A.W.; Assi, C. Demand-Side Management by Regulating Charging and Discharging of the EV, ESS, and Utilizing Renewable Energy. *IEEE Trans. Ind. Inform.* 2018, 14, 117–126.

25. Mignoni, N.; Carli, R.; Dotoli, M. Distributed Noncooperative MPC for Energy Scheduling of Charging and Trading Electric Vehicles in Energy Communities. *IEEE Trans. Control Syst. Technol.* 2023, 31, 2159–2172.

26. Yang, N.; Yang, C.; Xing, C.; Ye, D.; Jia, J.J.; Chen, D.J.; Shen, X.;

Huang, Y.H.; Zhang, L.; Zhu, B.X. Deep learning-based SCUC decision-making: An intelligent data-driven approach with self-learning capabilities. *IET Gener. Transm. Distrib.* 2022, 16, 629–640.

27. Guo, F.H.; Xu, B.W.; Xing, L.T.; Zhang, W.A.; Wen, C.Y.; Yu, L. An Alternative Learning-Based Approach for Economic Dispatch in Smart Grid. *IEEE Internet Things J.* 2021, 8, 15024–15036.

28. Kim, M.J.; Kim, T.S.; Flores, R.J.; Brouwer, J. Neural-network-based optimization for economic dispatch of combined heat and power systems. *Appl. Energy* 2020, 265, 114785.

29. Hu, H.; Sotirov, R. The linearization problem of a binary quadratic problem and its applications. *Ann. Oper. Res.* 2021, 307, 229–249.

30. Dong, S.; Wang, P.; Abbas, K. A survey on deep learning and its applications. *Comput. Sci. Rev.* 2021, 40, 100379.

31. Li, M.; Xu, D.C.; Zhang, D.M.; Zou, J. The seeding algorithms for spherical k-means clustering. *J. Glob. Optim.* 2020, 76, 695–708.

32. Gu, J.X.; Wang, Z.H.; Kuen, J.; Ma, L.Y.; Shahroudy, A.; Shuai, B.; Liu, T.; Wang, X.X.; Wang, G.; Cai, J.F.; et al. Recent advances in convolutional neural networks. *Pattern Recognit.* 2018, 77, 354–377.

33. Shahid, F.; Zameer, A.; Muneeb, M. Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM. *Chaos Solitons Fractals* 2020, 140, 110212.

34. Barakat, A.; Bianchi, P. Convergence and Dynamical Behavior of the Adam Algorithm for Nonconvex Stochastic Optimization. *SIAM J. Optim.* 2021, 31, 244–274.