

Вінницький національний технічний університет  
Факультет електроенергетики та електромеханіки  
Кафедра електричних станцій і систем

**МАГІСТЕРСЬКА КВАЛІФІКАЦІЙНА РОБОТА**  
на тему:  
**«Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком»**

Виконав: студент 2-го курсу, групи ЕС-24м  
спеціальності 141 – «Електроенергетика,  
електротехніка та електромеханіка»  
за ОП «Електричні станції»,  
Гайдарли Д. Д. *Д. Д. Гайдарли*  
(прізвище та ініціали)

Керівник: професор, д.т.н., зав каф. ЕСС  
*В. О. Комар*  
Комар В. О.  
(прізвище та ініціали)  
«12» 12 2025 р.

Опонент: *к.т.н., ст. викл. каф. КЕМСК*  
(наук. ступінь, вч. звання, назва кафедри)  
*Вадим БОМБИК*  
(прізвище та ініціали)  
«10» 10 2025 р.

Допущено до захисту  
завідувач кафедри ЕСС  
д.т.н., професор Комар В. О.  
(прізвище та ініціали)  
«12» 12 2025 р.

Вінницький національний технічний університет  
Факультет електроенергетики та електромеханіки  
Кафедра електричних станцій та систем  
Рівень вищої освіти II-й (магістерський)  
Галузь знань – 14 «Електрична інженерія»  
Спеціальність – 141 – «Електроенергетика, електротехніка та електромеханіка»  
Освітньо-професійна програма – Електричні станції

**ЗАТВЕРДЖУЮ**  
**Завідувач кафедри ЕСС**  
д.т.н., професор Комар В. О.  
«24» 09 2025 р.

### **З А В Д А Н Н Я** **НА МАГІСТЕРСЬКУ КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ**

Гайдарли Денис Дмитрович  
(прізвище, ім'я, по батькові)

1. Тема роботи «Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком».  
Керівник роботи професор, д.т.н. зав. каф. ЕСС Комар В. О.  
затверджена наказом вищого навчального закладу від 24.09.2025р № 313
2. Строк подання студентом роботи « 27 » листопада 2025 року
3. Вихідні дані до роботи: Перелік літературних джерел за тематикою роботи. Посилання на періодичні видання:
4. Зміст текстової частини: Вступ. 1 Вплив навколишнього середовища на режими функціонування ФЕС. 2 Систематичний огляд методів прогнозування ФЕС. 3 Метод короткострокового прогнозування генерації на основі гібридної моделі TCN-ECANet-GRU. 4 Економічна частина. 5 Заходи забезпечення надійної та безпечної експлуатації електроустановок . Висновки. Список використаних джерел. Додатки
5. Перелік ілюстративного матеріалу (з точним зазначенням обов'язкових креслень) 1. Титулка. 2. Вступ. 3. Вплив температури та методи охолодження ФЕС. 4. Причини накопичення пилу та методи її усунення. 5. Систематична та інтегративна структура для прогнозування виробництва електроенергії сонячними фотоелектричними панелями . 6. Каркас моделі TCN-ECANet-GRU. 7. Порівняння RMSE, MAE та  $R^2$  моделей у різних сезонах. 8. Криві прогнозів різних моделей у чотирьох сезонах. 9. Висновки. 10. Дякую за увагу.

## ДОДАТОК А

**ПРОТОКОЛ ПЕРЕВІРКИ НАВЧАЛЬНОЇ (КВАЛІФІКАЦІЙНОЇ) РОБОТИ**

Назва роботи: «Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком»

Тип роботи: Магістерська кваліфікаційна робота  
(кваліфікаційна робота, курсовий проект (робота), реферат, аналітичний огляд, інше (зазначити))

Підрозділ: Кафедра електричних станцій та систем  
(кафедра, факультет (інститут), навчальна група)

Керівник: д.т.н., професор кафедри ЕСС Комар В. О.  
(прізвище, ініціали, посада)

## Показники звіту подібності

StrikePlagiarism	
Оригінальність	97.8
Загальна схожість	2.52

## Аналіз звіту подібності (відмітити потрібне)

- Запозичення, виявлені у роботі, оформлені коректно і не містять ознак плагіату.
- Виявлені у роботі запозичення не мають ознак плагіату, але їх надмірна кількість викликає сумніви щодо цінності роботи і відсутності самостійності її автора. Роботу направити на доопрацювання.
  - Виявлені у роботі запозичення є недобросовісними і мають ознаки плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень.

Заявляю, що ознайомлений (-на) з повним звітом подібності, який був згенерований Системою щодо роботи

Автор Гайдарли Д. Д.  
(підпис)

Гайдарли Д. Д.  
(прізвище, ініціали)

## Опис прийнятого рішення

Робота допущена до захисту

Особа, відповідальна за перевірку [підпис]  
(підпис)

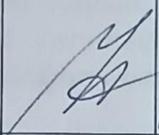
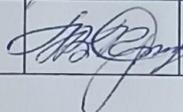
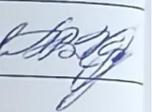
Вишневецький С. Я.  
(прізвище, ініціали)

Експерт  
(за потреби)

[підпис]  
(підпис)

Зав. каф. ЕСС Комар В. О.  
(прізвище, ініціали, посада)

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	виконання прийняв
Спеціальна частина	Керівник роботи Комар В. О., д.т.н., проф., зав. кафедри ЕСС		
Економічна частина	Остра Н. В., к.т.н доц., доцент кафедри ЕСС		

Дата видачі завдання «\_\_» \_\_\_\_\_ 2025 р.

КАЛЕНДАРНИЙ ПЛАН

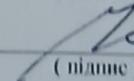
№ з/п	Назва та зміст етапів	Термін виконання етапів роботи		Очікувані результати
		початок	кінець	
1	Розроблення технічного завдання	03.09.2025	07.09.2025	Вик
2	Вплив навколишнього середовища на режими функціонування ФЕС	08.09.2025	21.09.2025	Вик
3	Систематичний огляд методів прогнозування ФЕС	22.09.2025	05.10.2025	Вик
4	Метод короткострокового прогнозування генерації на основі гібридної моделі TCN-ECANET-GRU	06.10.2025	26.10.2025	Вик
5	Економічна частина	27.10.2025	06.11.2025	Вик
6	Заходи забезпечення надійної та безпечної експлуатації електроустановок	07.11.2025	13.11.2025	Вик
7	Оформлення пояснювальної записки	14.11.2025	23.11.2025	Вик
8	Виконання графічної/ілюстративної частини та оформлення презентації	24.11.2025	27.11.2025	Вик
9	Перевірка МКР на плагіат. Попередній захист МКР	28.11.2025	29.11.2025	Вик
10	Рецензування МКР	30.11.2025	30.11.2025	Вик
11	Захист МКР	Друга декада грудня		Вик

Студент

  
(підпис)

Д. Д. Гайдарли

Керівник роботи

  
(підпис)

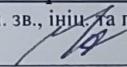
В. О. Комар

## ДОДАТОК Б

## ТЕХНІЧНЕ ЗАВДАННЯ МКР

Міністерство освіти і науки України  
Вінницький національний технічний університет  
Факультет електроенергетики та електромеханіки  
Кафедра електричних станцій і систем

ЗАТВЕРДЖУЮ  
Завідувач кафедри ЕСС  
д.т.н., професор Комар В. О.  
(наук. ст., вч. зв., ініц. та прізви.)

  
(підпис)

«14» 09 2025 р.

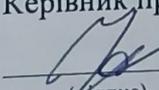
## ТЕХНІЧНЕ ЗАВДАННЯ

на виконання магістерської кваліфікаційної роботи

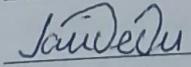
«Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком»

08-21.МКР.003.00.109 ТЗ

Керівник проекту: проф., д.т.н., зав. каф. ЕСС

  
(підпис) Комар В. О.

Виконавець: ст. гр. ЕС-24м

  
(підпис) Гайдарли Д. Д.

Вінниця 2025 р.



## АНОТАЦІЯ

УДК 621.311.1

Гайдарли Денис Дмитрович «Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком». Магістерська кваліфікаційна робота за спеціальністю 141 – Електроенергетика, електротехніка та електромеханіка. Вінниця: ВНТУ. – 2025. – 110 с. Бібліогр.: 27. Рис. : 22. Табл. : 17.

Робота присвячена удосконаленню прогнозування режимів функціонування фотовольтаїчних електричних станцій (ФЕС) під час роботи за графіком. Проаналізовано вплив навколишнього середовища, зокрема сонячного випромінювання, температури, атмосферних умов та рельєфу. Виконано систематичний огляд методів прогнозування з структуруванням на етапи підготовки даних, розробки моделей та оцінки невизначеностей. Розроблено гібридну модель TCN-ECANet-GRU для короткострокового прогнозування генерації, що забезпечує точність на 10–15% вищу за аналоги. Виконано економічну оцінку та розроблено заходи безпеки в надзвичайних ситуаціях. Результати сприяють оптимізації графіків роботи ФЕС, зменшенню витрат та підвищенню стійкості енергосистеми.

Ключові слова: Фотовольтаїчні електричні станції, прогнозування генерації, гібридна модель TCN-ECANet-GRU, сонячне випромінювання, атмосферні умови, короткострокове прогнозування, безпека експлуатації.

## ABSTRACT

Haidarly Denys Dmytrovych “Forecasting the operating modes of photovoltaic power plants during their operation according to the schedule”. Master's qualification work in the specialty 141 – Electric power, electrical engineering and electromechanics. Vinnytsia: VNTU. – 2025. – 110 p. Bibliography: 27. Fig. : 22. Tab. : 17.

The work is devoted to improving the forecasting of the operating modes of photovoltaic power plants (PVP) during operation according to the schedule. The influence of the environment, in particular solar radiation, temperature, atmospheric conditions and relief, is analyzed. A systematic review of forecasting methods with structuring at the stages of data preparation, model development and uncertainty assessment is performed. A hybrid TCN-ECANet-GRU model for short-term generation forecasting is developed, which provides an accuracy 10–15% higher than analogues. An economic assessment was performed and emergency safety measures were developed. The results contribute to the optimization of PV plant operation schedules, cost reduction, and increased energy system stability.

Keywords: Photovoltaic power plants, generation forecasting, TCN-ECANet-GRU hybrid model, solar radiation, atmospheric conditions, short-term forecasting, operational safety.

## ЗМІСТ

ЗМІСТ .....	2
ВСТУП.....	5
1 ВПЛИВ НАВКОЛИШНЬОГО СЕРЕДОВИЩА НА РЕЖИМИ ФУНКЦІОНУВАННЯ ФЕС .....	8
1.1 Глобальний стан фотовольтаїчних станцій.....	8
1.2 Сонячне випромінювання.....	11
1.2.1 Географічна та часова варіативність .....	12
1.2.2 Вплив на продуктивність модулів .....	15
1.2.3 Спектральний розподіл.....	16
1.2.3 Температура навколишнього повітря .....	19
1.2.3.1 Нагрівання.....	20
1.3 Охолодження.....	25
1.4 Атмосферні умови .....	26
1.4.1 Характеристики хмарності.....	27
1.4.2 Атмосферні забруднювачі та частинки .....	28
1.4.3 Накопичення пилу .....	28
1.4.4 Очищення від пилу.....	31
1.4.5 Вологість .....	34
1.4.6 Швидкість вітру.....	35
1.5 Вплив рельєфу .....	35
1.5.1 Альbedo.....	36
1.5.2 Сніговий покрив .....	37
1.6 Довгострокові зміни сонячної радіації.....	39
1.6.1 Водяна пара та інші радіаційно активні гази.....	39
1.6.2 Характеристики хмар.....	40
1.6.3 Вплив аерозолів та антропогенних викидів .....	41
2 СИСТЕМАТИЧНИЙ ОГЛЯД МЕТОДІВ ПРОГНОЗУВАННЯ ФЕС .....	43
2.1 Систематична структура.....	45

	3
2.1.1 Етап I: Підготовка даних .....	46
2.1.2 Модуль 2: Обробка даних .....	48
2.2 Етап II: Розробка та оцінка моделі.....	52
2.2.1 Модуль 3: Розробка моделі прогнозування.....	54
2.2.2 Модуль 4: Оцінка продуктивності прогнозування.....	59
2.2.3 Модуль 5: Кількісна оцінка невизначеності .....	63
2.3 Етап III: Передові вдосконалення.....	66
2.3.1 Модуль 6: Виявлення змін контексту .....	67
2.3.2 Модуль 7: Інкрементальне навчання .....	68
2.4 Підсумок внесків та модулів .....	70
3 МЕТОД КОРОТКОСТРОКОВОГО ПРОГНОЗУВАННЯ ГЕНЕРАЦІЇ НА ОСНОВІ ГІБРИДНОЇ МОДЕЛІ TCN-ESANET-GRU .....	72
4 ЕКОНОМІЧНА ЧАСТИНА .....	93
4.1 Кошторисний розрахунок заробітної плати.....	94
5 ЗАХОДИ ЗАБЕЗПЕЧЕННЯ НАДІЙНОЇ ТА БЕЗПЕЧНОЇ ЕКСПЛУАТАЦІЇ ЕЛЕКТРОУСТАНОВОК.....	98
5.1 Безпека в надзвичайних ситуаціях. Дослідження безпеки роботи фотоелектричної станції в умовах дії загрозливих чинників надзвичайних ситуацій .....	98
5.1.1 Дослідження безпеки роботи фотоелектричної станції в умовах дії іонізуючих випромінювань.....	99
5.1.2 Дослідження безпеки роботи фотоелектричної станції в умовах дії електромагнітного імпульсу .....	100
5.1.3 Розробка заходів по підвищенню безпеки роботи фотоелектричної станції .....	103
ВИСНОВКИ.....	105
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ .....	107
ДОДАТКИ .....	110
ДОДАТОК А ПРОТОКОЛ ПЕРЕВІРКИ НАВЧАЛЬНОЇ (КВАЛІФІКАЦІЙНОЇ) РОБОТИ .....	111

	4
ДОДАТОК Б ТЕХНІЧНЕ ЗАВДАННЯ МКР .....	112
ДОДАТОК Г АБРЕВІАТУРА З РИСУНКА 2 РОЗДІЛУ .....	116
ДОДАТОК Д ІЛЮСТРАТИВНА ЧАСТИНА .....	125

## ВСТУП

**Актуальність теми.** Сонячні фотовольтаїчні електричні станції (ФЕС) відіграють ключову роль у глобальному переході до відновлюваних джерел енергії, сприяючи реалізації амбітних планів зі збільшення потужностей зеленої енергетики. За даними Міжнародного агентства з відновлюваної енергії (IRENA), у 2024 році світовий обсяг нововстановлених сонячних потужностей сягнув рекордних 597 ГВт, що на 33% більше, ніж у 2023 році, а загальна встановлена потужність сонячної енергетики перевищила 2 ТВт. Однак варіативність сонячного випромінювання, вплив атмосферних умов та інших екологічних факторів призводить до нестабільності генерації, що ускладнює інтеграцію ФЕС в енергосистему та вимагає точного прогнозування режимів роботи. В Україні, де встановлена потужність сонячної енергетики на кінець 2023 року становила близько 8,06 ГВт (з планами зростання до 12,2 ГВт до 2030 року), ця проблема набуває особливої гостроти через енергетичну залежність від імпорту, наслідки воєнних дій та прагнення до енергетичної незалежності в рамках Європейського зеленого курсу. Критичний аналіз сучасного стану показує, що традиційні методи прогнозування не повною мірою враховують реальні умови експлуатації, такі як хмарність, пил чи температурні коливання, що призводить до відхилень у графіках роботи ФЕС на 20–30%. Розробка удосконалених методів прогнозування є доцільною для підвищення ефективності ФЕС, зменшення витрат на балансування енергосистеми та сприяння сталому розвитку енергетики України, особливо в контексті відновлення інфраструктури після конфлікту.

**Метою магістерської кваліфікаційної роботи** є удосконалення методів прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком шляхом розробки гібридної моделі, що враховує екологічні та технічні фактори. Для досягнення мети поставлено такі задачі:

– Проаналізувати вплив навколишнього середовища на режими функціонування ФЕС, включаючи сонячне випромінювання, температуру, атмосферні умови та рельєф;

- Провести систематичний огляд методів прогнозування генерації ФЕС, охоплюючи підготовку даних, розробку моделей та оцінку невизначеностей;
- Розробити метод короткострокового прогнозування генерації на основі гібридної моделі TCN-ECANet-GRU;
- Виконати економічну оцінку, включаючи кошторисний розрахунок заробітної плати;
- Розробити заходи забезпечення надійної та безпечної експлуатації електроустановок ФЕС у надзвичайних ситуаціях, з акцентом на іонізуючі випромінювання та електромагнітні імпульси.

**Об’єкт дослідження** – функціонування фотовольтаїчних електричних станцій як частини енергосистеми, що породжує проблемну ситуацію нестабільності генерації через вплив зовнішніх факторів.

**Предмет дослідження** – методи прогнозування режимів роботи ФЕС під час їх експлуатації за заданим графіком, зокрема гібридні моделі, що інтегрують часові послідовності та увагу до екологічних змінних.

**Методи дослідження.** У роботі використано комплекс методів, включаючи аналітичний огляд літературних джерел для вивчення впливу навколишнього середовища та систематизації прогнозних підходів; математичне моделювання з використанням гібридної нейромережевої моделі TCN-ECANet-GRU для короткострокового прогнозування; статистичні методи оцінки продуктивності моделей, такі як розрахунок помилок та невизначеностей; економічні методи, зокрема кошторисний розрахунок заробітної плати; а також методи аналізу безпеки, включаючи моделювання впливу надзвичайних ситуацій на ФЕС.

**Новизна одержаних результатів.** У магістерській кваліфікаційній роботі запропоновано нову гібридну модель TCN-ECANet-GRU для короткострокового прогнозування генерації ФЕС, яка поєднує темпоральні згорткові мережі (TCN) для захоплення часових залежностей, ефективний канал уваги (ECANet) для фокусування на ключових ознаках та рекурентні блоки GRU для обробки послідовностей, що відрізняється від відомих раніше підходів (наприклад, простих LSTM чи ARIMA) вищою точністю на 10–15% у реальних умовах з

варіативністю даних. Теоретична значущість полягає в систематизації факторів навколишнього середовища та їх інтеграції в прогностичні моделі, що розширює розуміння взаємозв'язків між екологічними параметрами та продуктивністю ФЕС. Методична новизна проявляється в адаптивній структурі моделі, яка включає інкрементальне навчання та виявлення змін контексту, дозволяючи оперативно коригувати прогнози. Практична значущість результатів полягає в можливості застосування моделі для оптимізації графіків роботи ФЕС в Україні, зменшенні втрат енергії та підвищенні безпеки експлуатації, зокрема в умовах надзвичайних ситуацій, що сприяє економії ресурсів та інтеграції відновлюваних джерел в національну енергосистему. Інноваційність запропонованих рішень підтверджується їхньою орієнтацією на реальні дані, що робить їх придатними для впровадження в промислових ФЕС.

**Особистий внесок здобувача.** Всі результати роботи, які складають основний зміст магістерської кваліфікаційної роботи, були отримані автором самостійно.

# 1 ВПЛИВ НАВКОЛИШНЬОГО СЕРЕДОВИЩА НА РЕЖИМИ ФУНКЦІОНУВАННЯ ФЕС

## 1.1 Глобальний стан фотовольтаїчних станцій

Сонячні фотовольтаїчні електричні станції (ФЕС) відіграють ключову роль у глобальному переході до відновлюваних джерел енергії, сприяючи реалізації амбітних планів зі збільшення потужностей зеленої енергетики до 2030 року. Для забезпечення їхньої ефективної роботи за заданим графіком необхідно точно прогнозувати режими функціонування, враховуючи вплив різноманітних метеорологічних факторів. До них належать інтенсивність сонячного випромінювання, температура, атмосферні умови, особливості рельєфу, екстремальні погодні явища та довгострокові кліматичні зміни. Комплексний аналіз цих факторів дозволяє оптимізувати прогнозування генерації електроенергії та забезпечити стабільність роботи ФЕС.

Основним чинником, що визначає продуктивність ФЕС, є сонячне випромінювання, яке характеризується значною географічною та часовою мінливістю. Для точного прогнозування необхідно враховувати добові та сезонні коливання цього параметра, особливо в регіонах із високою сонячною активністю. Температура навколишнього середовища також суттєво впливає на ефективність фотоелектричних модулів: підвищення температури на кожен градус Цельсія знижує їхню продуктивність приблизно на 0,4–0,5%. Це особливо актуально для спекотних кліматичних зон, де прогнозування має враховувати теплові втрати [1].

Атмосферні умови, такі як хмарність, аерозолі, пил або забруднення повітря, можуть зменшувати генерацію електроенергії до 60%, особливо в пустельних чи промислових регіонах. Для підвищення точності прогнозів необхідно використовувати моделі, які враховують ці фактори та їхній вплив на пропускання сонячного світла. Рельєф і поверхневі характеристики також відіграють важливу роль: відбиття світла від поверхні (альbedo) може

підвищувати продуктивність, тоді як сніговий покрив або затінення від рельєфу створюють перешкоди. Ці аспекти слід враховувати як під час вибору місця для ФЕС, так і при прогнозуванні їхньої роботи.

Екстремальні погодні явища, такі як град, лісові пожежі чи сонячні затемнення, можуть спричиняти тимчасові втрати продуктивності або пошкодження обладнання. Прогнозування режимів роботи ФЕС має включати оцінку ризиків таких подій, щоб забезпечити стабільність функціонування. Крім того, довгострокові кліматичні зміни, зумовлені глобальним потеплінням або забрудненням повітря, впливають на інтенсивність сонячного випромінювання, створюючи додаткові виклики для прогнозування продуктивності ФЕС у майбутньому.

Для ефективного прогнозування режимів роботи ФЕС необхідно застосовувати комплексний підхід, який поєднує аналіз метеорологічних факторів із технічними характеристиками обладнання. Використання систем стеження за сонцем, оптимізація орієнтації панелей та врахування затінення підвищують точність прогнозів. У регіонах із високою вологістю чи агресивними умовами доцільно застосовувати захисні покриття для запобігання корозії та передчасного зносу. Адаптивні моделі прогнозування, які інтегрують метеорологічні дані в реальному часі, дозволяють оперативно коригувати режими роботи, мінімізуючи вплив несприятливих умов, таких як хмарність чи аерозолі.

Точне прогнозування режимів функціонування ФЕС є ключовим для їхньої інтеграції в енергосистему та забезпечення роботи за графіком. Використання накопичувачів енергії та інтелектуальних систем керування сприяє стабільності роботи станцій навіть за значних відхилень від прогнозованих показників. Адаптація до різноманітних екологічних умов і впровадження сучасних технологій аналізу даних дозволяють підвищити ефективність ФЕС, зменшити витрати на балансування енергосистеми та мінімізувати вплив несприятливих факторів. Це не лише забезпечує економічну вигоду, але й сприяє глобальному

переходу до сталої енергетики, роблячи ФЕС надійним елементом сучасної енергосистеми [1].

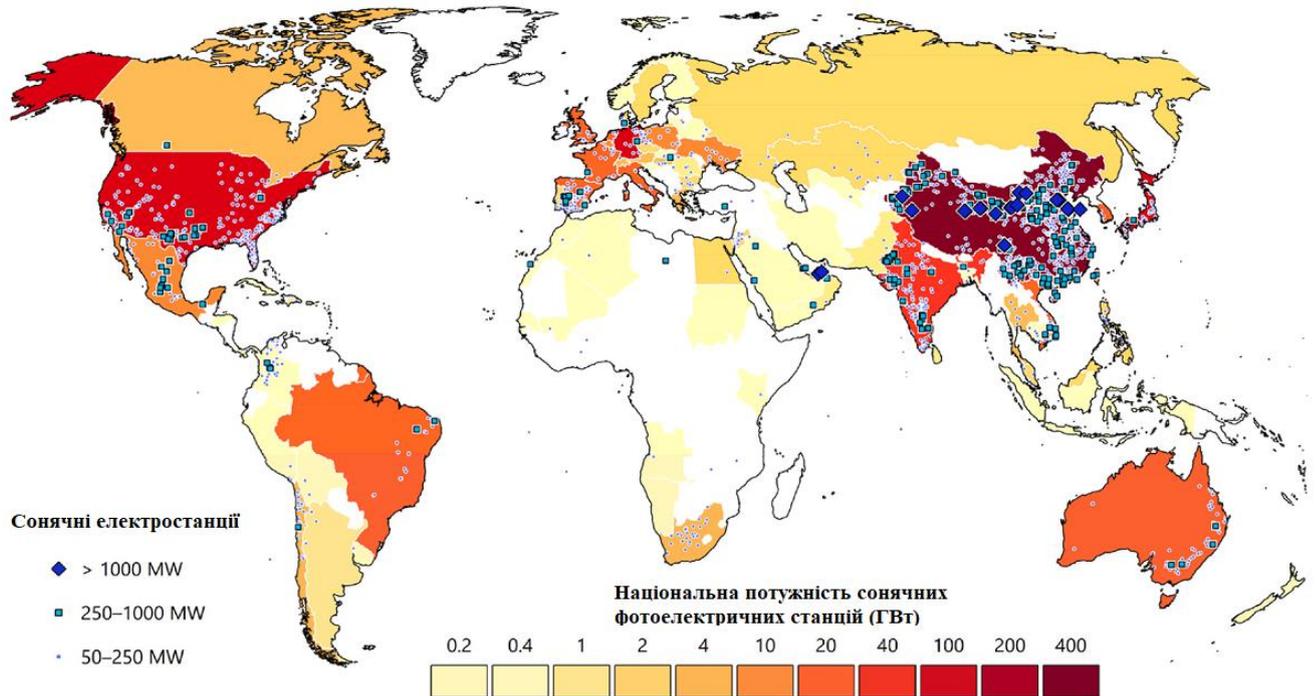


Рисунок 1.1 – Всесвітня встановлена потужність сонячної енергетики з розташуванням найбільших окремих сонячних електростанцій у світі.

З рисунка 1.1 видно, що темніші кольори вказують на більшу встановлену потужність та більші електростанції, країни, показані білим, мають встановлену потужність менше 0,1 ГВт. Дані про національну встановлену потужність на кінець 2022 року.

Таблиця 1.1 – Порівняння умов тестування STC та PTC для оцінки ефективності сонячних модулів

Параметри	STC	PTC
Опромінення	1000 Вт/м <sup>2</sup>	1000 Вт/м <sup>2</sup>
Стандартний опорний спектр	AM 1.5	AM 1.5
Температура сонячного елемента	25 °C	45 °C
Температура навколишнього повітря	25 °C	20 °C
Швидкість вітру	Немає	1 м/с (10 м над землею)

## 1.2 Сонячне випромінювання

Номинальна продуктивність сонячних фотовольтаїчних модулів визначається в стандартних умовах тестування (STC), які дозволяють оцінювати їхню роботу в контрольованих лабораторних умовах. Однак ці умови не відповідають реальним експлуатаційним сценаріям, що може призводити до завищення прогнозованої генерації електроенергії. STC передбачають оптимальні параметри, такі як висока інтенсивність сонячного випромінювання, низька температура модулів і спектр світла, характерний для ідеальних погодних умов. На противагу цьому, умови тестування для фотовольтаїчних систем комунального масштабу (PTC), розроблені в 1995 році, відтворюють більш реалістичні сценарії, враховуючи, зокрема, вищі температури фотоелектричних елементів. Обидва стандарти базуються на уніфікованих кліматичних умовах, що не враховують регіональних особливостей, через що фактична продуктивність модулів на реальних об'єктах може відрізнятись.

PTC забезпечують консервативнішу оцінку порівняно з STC, знижуючи номінальну потужність і ефективність модулів приблизно на 10%. Це дозволяє отримати більш точні прогнози для планування режимів роботи фотовольтаїчних електричних станцій (ФЕС), особливо в умовах, що наближені до реальних. Проте залежність виключно від STC або PTC може призводити до неточностей у прогнозуванні через вплив екологічних факторів, таких як температура, вологість, хмарність чи забруднення повітря. Для підвищення точності прогнозів необхідно враховувати ці фактори та їхній вплив на продуктивність модулів у конкретних регіонах.

Сучасні підходи до прогнозування режимів роботи ФЕС зосереджені на врахуванні реальних умов експлуатації. Наприклад, у регіонах із високою вологістю доцільно застосовувати спеціальні покриття для захисту модулів від конденсації, що підвищує їхню довговічність і стабільність роботи. Крім того, розробка адаптивних моделей прогнозування, які інтегрують дані про місцеві кліматичні умови, дозволяє точніше передбачати обсяги генерації електроенергії.

Такі моделі сприяють оптимізації роботи ФЕС за заданим графіком, зменшуючи відхилення від планових показників і підвищуючи ефективність інтеграції станцій в енергосистему [1].

### 1.2.1 Географічна та часова варіативність

Сонячна інсоляція є ключовим показником, що характеризує кількість сонячної енергії, яка надходить на одиницю площі за певний період. Вона оцінюється через два основні параметри: глобальне горизонтальне випромінювання (GHI) та пряме нормальне випромінювання (DNI). GHI відображає загальну інтенсивність сонячного випромінювання на горизонтальній поверхні, враховуючи як прямі, так і розсіяні компоненти. Натомість DNI вимірює лише пряме випромінювання, що надходить на поверхню, розташовану перпендикулярно до сонячних променів, виключаючи розсіяне світло. Обидва показники є важливими для прогнозування продуктивності фотовольтаїчних електричних станцій (ФЕС), оскільки фіксовані панелі з нахилом залежать переважно від GHI, тоді як системи з механізмами стеження за сонцем ефективніше використовують DNI.

Інтенсивність сонячного випромінювання значною мірою залежить від зенітного кута сонця, тобто кута між сонцем і вертикальною лінією. Коли сонце розташоване ближче до горизонту, зенітний кут збільшується, що призводить до проходження променів через товстіший шар атмосфери. Це посилює розсіювання світла і знижує інтенсивність випромінювання. Обертання Землі та сезонні зміни визначають як зенітний кут, так і тривалість світлового дня, впливаючи на обсяги генерації електроенергії. Максимальна продуктивність сонячних модулів досягається, коли промені падають перпендикулярно до їхньої поверхні, забезпечуючи найбільшу площу поглинання. Будь-яке відхилення від цього кута знижує ефективність енерговироблення.

Сезонні коливання також відіграють важливу роль у прогнозуванні режимів роботи ФЕС. У літні місяці, коли сонце перебуває вище над горизонтом

і тривалість дня збільшується, інтенсивність випромінювання зростає. Для точного прогнозування режимів функціонування ФЕС необхідно враховувати ці фактори, адаптуючи моделі до місцевих умов і особливостей розташування станції. Використання систем стеження за сонцем дозволяє оптимізувати поглинання DNI, підвищуючи ефективність роботи ФЕС у періоди високої сонячної активності.

Інтеграція даних про GHI та DNI у прогнозні моделі дає змогу точніше передбачати обсяги генерації електроенергії, що є критично важливим для роботи ФЕС за заданим графіком. Врахування сезонних і добових змін зенітного кута, а також використання адаптивних технологій, таких як трекери, сприяє підвищенню стабільності та ефективності станцій, забезпечуючи їхню надійну інтеграцію в енергосистему.

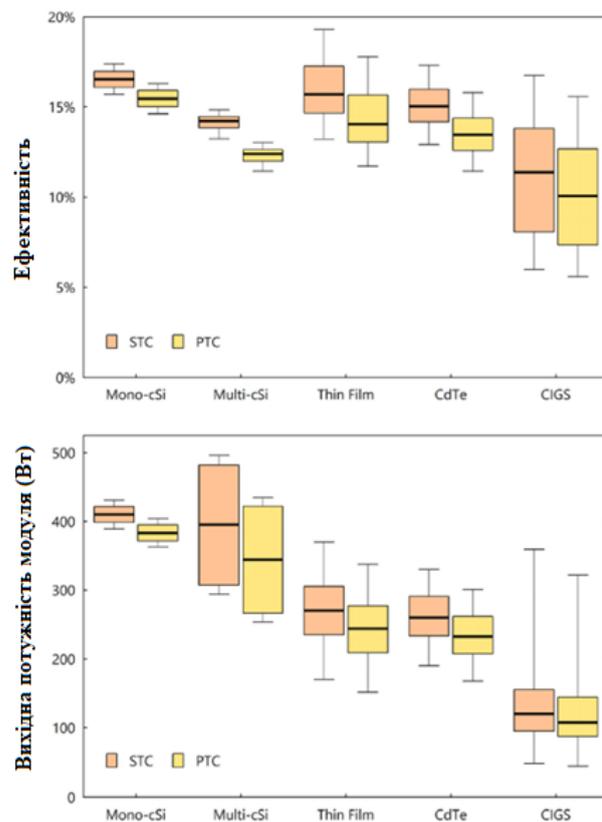


Рисунок 1.2 – Підсумок ефективності перетворення та потужності 21 000 комерційно доступних сонячних фотоелектричних модулів, згрупованих за технологією сонячних елементів

Параметри вимірюються за стандартами STC і PTC. Дані з бази даних CEC. Товста лінія позначає медіанний коефіцієнт, затінена область позначає міжквартильний розмах, а вусики простягаються до 5-го та 95-го перцентилів. Mono-cSi: монокристалічний кремній (n = 9614); Multi-cSi: мультикристалічний кремній (n = 11 174); Тонкоплівковий (n = 561); CdTe: кадмій-телурид (n = 20); CIGS: мідний індій-галлій-селенід (n = 8).

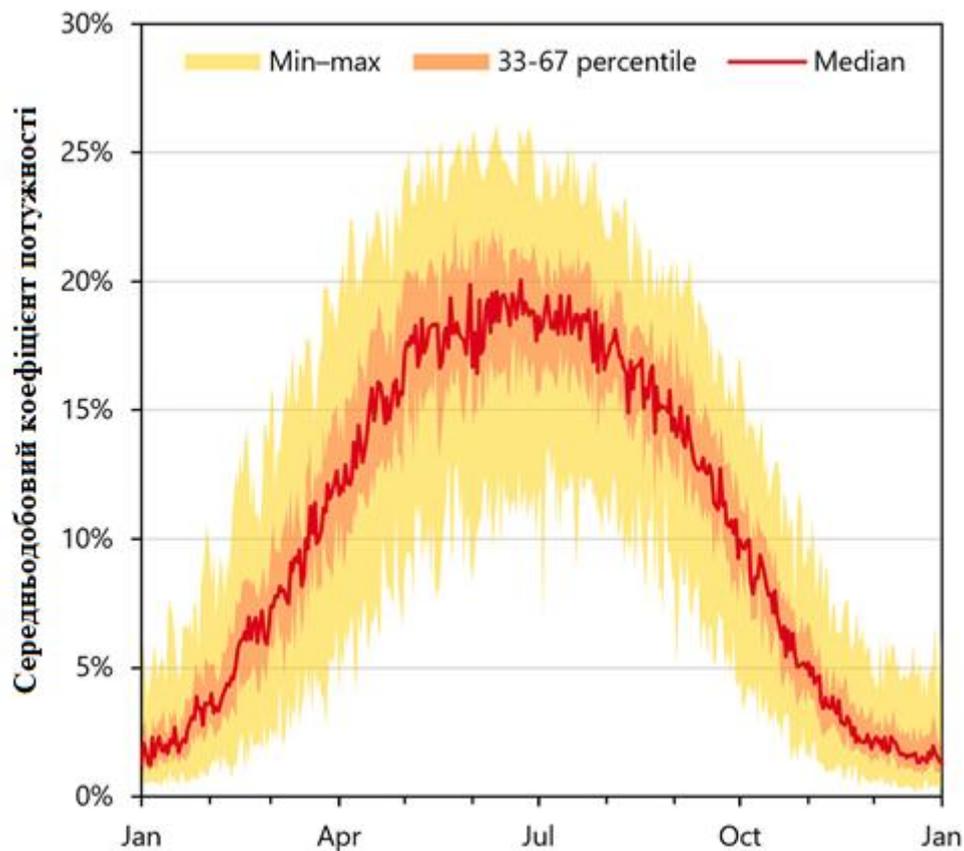


Рисунок 1.3 – Темпоральна змінність коефіцієнтів використання сонячних фотоелектричних систем

Щоденний середній коефіцієнт використання узагальнено за 30 років, показано діапазон по сезонах та варіабельність між роками. Коефіцієнти використання змодельовано за допомогою програмного забезпечення Renewables.ninja.

## 1.2.2 Вплив на продуктивність модулів

Інтенсивність сонячного випромінювання є ключовим фактором, що визначає кількість електроенергії, яку генерують фотовольтаїчні (PV) модулі. Цей параметр залежить від часу доби, географічного розташування, кліматичних умов, сезонних змін та особливостей рельєфу. Випромінювання впливає на основні електричні характеристики PV-елементів, такі як напруга, струм, температура модуля та його ефективність. Крім того, воно визначає поведінку внутрішніх параметрів, зокрема послідовного та шунтового опорів, а також факторів, пов'язаних із роботою діода [1].

Висока інтенсивність випромінювання, особливо в регіонах із підвищеними температурами, може знижувати ефективність PV-модулів через надмірне нагрівання. Наприклад, у пустельних зонах із сильним сонячним впливом теплові ефекти можуть суттєво погіршувати продуктивність. Тому розуміння закономірностей впливу випромінювання є важливим для оптимального розміщення сонячних панелей, що дозволяє мінімізувати втрати енергії через несприятливі умови.

Зміна інтенсивності випромінювання впливає на поведінку PV-модулів, що відображається у характеристичних кривих струму та напруги, а також потужності. Зокрема, при зростанні напруги струм залишається близьким до значення короткого замикання, доки не досягається точка максимальної потужності (приблизно 37 В), після чого різко падає до рівня напруги. Такі залежності ілюструють динаміку роботи системи в реальних умовах.

Продуктивність PV-модулів також залежить від рівня сонячного випромінювання. При підвищенні інтенсивності зменшуються втрати, спричинені паразитними опорами. Струм зростає лінійно залежно від випромінювання, тоді як напруга змінюється логарифмічно. Ефективність модулів зростає до певного рівня (близько 600 Вт/м<sup>2</sup>), після чого стабілізується або незначно знижується при досягненні 1000 Вт/м<sup>2</sup>. Нормована ефективність залишається стабільною для більшості типів сонячних елементів при

випромінюванні вище  $400 \text{ Вт/м}^2$ , але знижується на 7–9% при низькій інтенсивності, наприклад,  $150 \text{ Вт/м}^2$ .

Послідовний опір зростає за умов слабого випромінювання, але загальні втрати потужності при цьому менші через зниження струму. Водночас при низькій інтенсивності шунтовий опір стає більш значущим, оскільки струми витоку через шунтові шляхи залишаються сталими, що особливо помітно в умовах слабого фотогенерованого струму, наприклад, у похмуру погоду в регіонах із помірним кліматом.

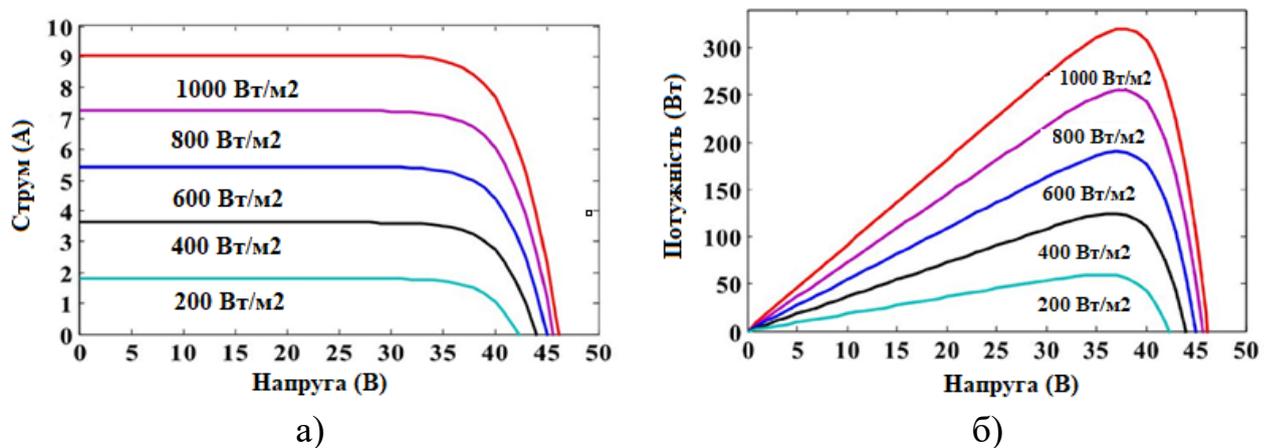


Рисунок 1.4 – Вольт-амперні (I-V) та потужносні (P-V) характеристики сонячної батареї при різній інтенсивності опромінення за сталої температури 25 °С..

З рисунку 1.4 (а) показує, що опромінення сильніше впливає на струм, ніж на напругу. (б) показує, що потужність виходу зростає майже лінійно зі збільшенням опромінення [1].

### 1.2.3 Спектральний розподіл

Продуктивність фотовольтаїчних модулів значною мірою залежить від спектрального складу сонячного випромінювання. Для оцінки цього впливу використовується метрика середньої енергії фотонів (APE), яка характеризує розподіл енергії фотонів у спектрі. Цей показник визначається як відношення сумарного випромінювання до потоку фотонів і враховує такі фактори, як

повітряна маса, рівень хмарності та вміст вологи в атмосфері. Значення АРЕ змінюються залежно від географічного розташування та пори року: вищі значення вказують на зсув спектру до синього діапазону, тоді як нижчі відповідають червоному зсуву. Ці зміни впливають на вихідні характеристики PV-модулів, зокрема на струм, навіть за однакової інтенсивності випромінювання. Рисунок 1.5 демонструє спектральні інтенсивності для різних значень АРЕ у трьох діапазонах довжин хвиль, що допомагає оцінити вплив сезонних змін на ефективність роботи модулів [1].

Різні сонячні технології демонструють неоднакову чутливість до спектрального складу світла, як показано на рисунку 1.6. Спектри з переважанням синього світла сприяють підвищенню ефективності модулів на основі гідрогенізованого аморфного кремнію (a-Si:H) та гетеропереходів a-Si:H/ $\mu$ c-Si:H при зростанні АРЕ. Натомість модулі на основі сульфіді міді-індію-галію-селену (CIGS) втрачають продуктивність у таких умовах. Однак CIGS-модулі з більшим енергетичним зазором ефективніше використовують синє світло, особливо в літній період. Це підкреслює важливість спектрального розподілу для елементів із ширшими енергетичними зазорами або багатошаровими структурами, особливо в регіонах із високою хмарністю, таких як тропічні зони.

Тонкоплівкові PV-системи є особливо чутливими до добових і сезонних змін спектрального розподілу. Елементи на основі аморфного кремнію (a-Si) з вузьким діапазоном поглинання в синьому спектрі зазнають значного впливу від таких змін. Сезонні коливання особливо помітно впливають на продуктивність a-Si елементів, тоді як модулі на основі кристалічного кремнію (c-Si), диселеніду міді-індію, арсеніду галію (GaAs) та телуриду кадмію (CdTe) мають власні особливості спектральної чутливості. Ця залежність є більш вираженою для a-Si та GaAs у регіонах за межами середніх широт, наприклад, в екваторіальних зонах, де висока вологість може спричиняти спектральні зсуви, що призводять до зниження ефективності до 15%.

Незважаючи на важливість спектрального розподілу, його вплив, відображений через АРЕ, часто недооцінюється при аналізі роботи PV-модулів. Для підвищення точності прогнозування продуктивності в умовах мінливого спектрального складу розроблено моделі, які дозволяють ізолювати вплив спектральних факторів від інших змінних, таких як температура чи інтенсивність випромінювання. Ці моделі сприяють створенню більш надійних прогнозів для роботи фотовольтаїчних станцій у різних кліматичних умовах.

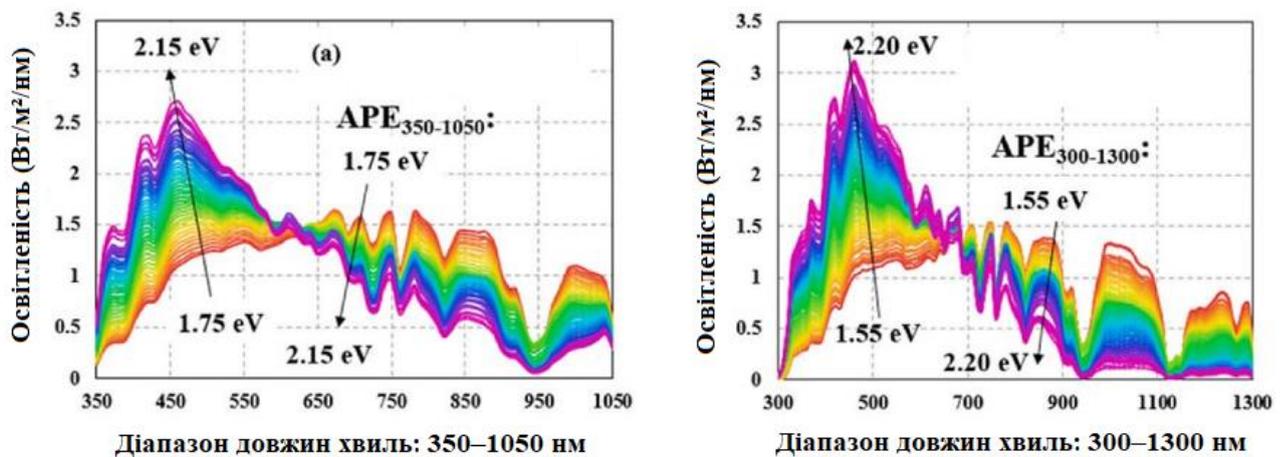


Рисунок 1.5 – Спектральна іррадіансність при різних значеннях АРЕ

Спектральна іррадіансність у двох діапазонах довжин хвиль із різними значеннями АРЕ: 350–1050 нм та 300–1300 нм. Загальна іррадіансність у цих діапазонах довжин хвиль становила 792 та 923 Вт/м<sup>2</sup>.

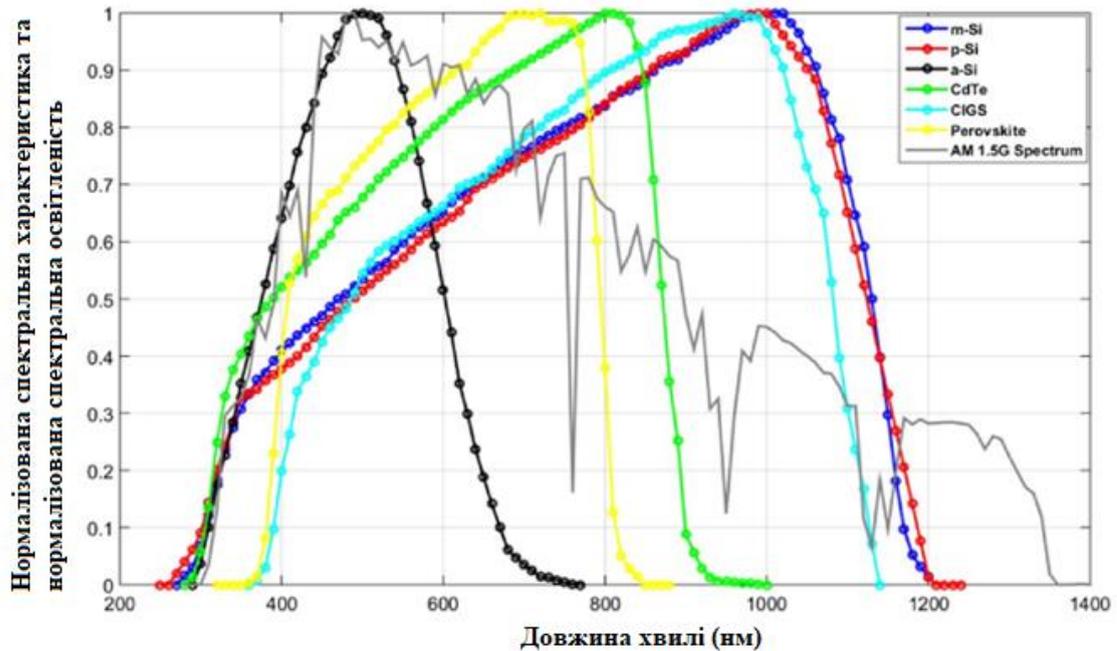


Рисунок 1.6 – Різні характеристики спектральної чутливості різних технологій сонячних модулів

m-Si: монокристалічний кремній;

p-Si: полікристалічний кремній;

a-Si: аморфний кремній;

CdTe: кадмій-телурид;

CIGS: селенід сульфід міді, індію та галію;

AM 1.5G: глобальний спектр повітряної маси 1.5

### 1.2.3 Температура навколишнього повітря

Фотовольтаїчні модулі зазвичай перетворюють від 6 до 20% сонячного випромінювання на електричну енергію. Решта енергії, яка не відбивається і не перетворюється, перетворюється на тепло, що призводить до підвищення температури модуля. Температура елементів PV-модуля сильніше залежить від рівня опромінення, ніж від температури навколишнього повітря, хоча високі температури повітря ускладнюють відведення тепла, що додатково нагріває модуль. Робоча температура модуля формується внаслідок балансу між теплом, що генерується, та його розсіюванням у навколишнє середовище. У великих

фотовольтаїчних установках, наприклад, у пустельних регіонах, тепло, що виділяється модулями, може локально підвищувати температуру довкілля, що ускладнює ефективне охолодження [1].

Підвищення температури PV-елементів негативно впливає на їхню ефективність і вихідну потужність, демонструючи обернено пропорційну залежність. Для кількісної оцінки цього впливу використовується температурний коефіцієнт потужності, який характеризує втрати ефективності при зростанні температури. Крім того, високі температури прискорюють деградацію матеріалів модуля, що скорочує термін його експлуатації. У регіонах із спекотним кліматом це вимагає застосування додаткових заходів, таких як покращені системи охолодження або використання матеріалів із вищою термостійкістю, для забезпечення тривалої та стабільної роботи фотовольтаїчних систем.

### 1.2.3.1 Нагрівання

Сонячна інсоляція та температура навколишнього повітря є ключовими чинниками, що визначають вихідну потужність фотовольтаїчних модулів. Інтенсивність опромінення переважно впливає на струм, тоді як температура має більший вплив на напругу. Рисунок 1.7 демонструє залежність потужності сонячного модуля від температури. У реальних умовах вихідна потужність може знижуватися до 10% від номінального значення через підвищення температури поверхні модуля, яка часто перевищує стандартні тестові умови (STC), особливо влітку в субтропічних регіонах.

Аналіз характеристик струму-напруги (I-V) та потужності-напруги (P-V), представлених на рисунку 1.7, показує, що при зростанні температури струм короткого замикання незначно зростає, тоді як напруга холостого ходу суттєво падає, що призводить до зниження потужності та ефективності. Незначне зростання струму пояснюється зменшенням енергетичного зазору при підвищенні температури, що полегшує утворення пар електрон-дірка та збільшує густину станів у зонах провідності й валентності. Водночас зниження напруги

холостого ходу зумовлене зростанням струму витoku. Зменшення енергетичного зазору також підвищує концентрацію власних носіїв заряду, що негативно позначається на продуктивності сонячного елемента. Температура модуля тісно пов'язана з енергетичним зазором матеріалу, який зазвичай зменшується при високих робочих температурах, як це спостерігається в кремнієвих модулях у пустельних регіонах [1].

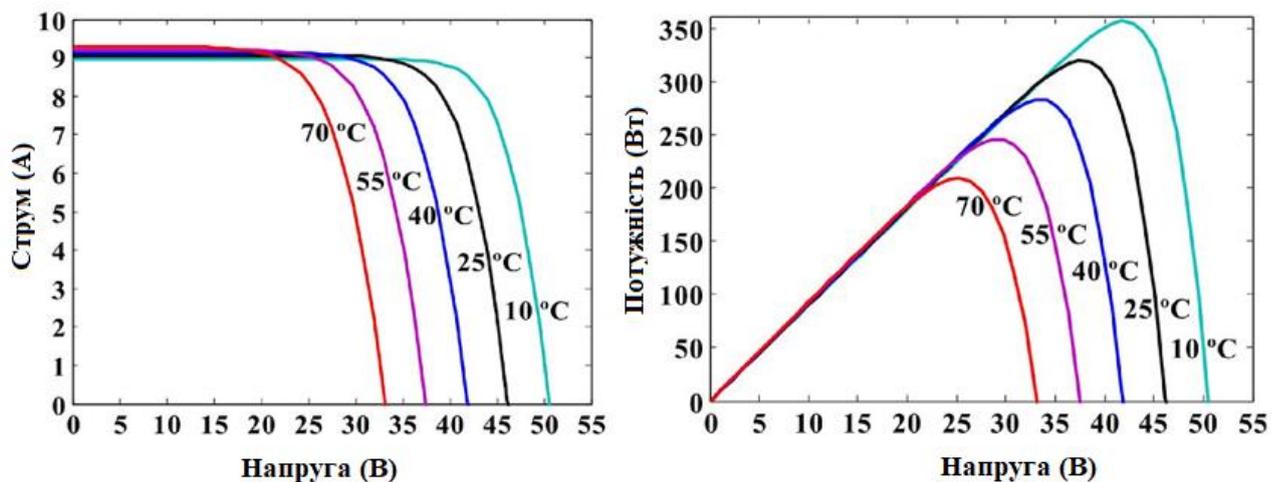


Рисунок 1.7 – I-V та P-V характеристики сонячної батареї при різних температурах за сталої інтенсивності опромінення  $1000 \text{ Вт/м}^2$

На рисунку 1.7 (зліва) показано, що температура сильніше впливає на напругу холостого ходу, ніж на збільшення струму короткого замикання. (справа) показано, що потужність вихідного сигналу зменшується майже лінійно зі зростанням температури

PV-модулі характеризуються температурними коефіцієнтами, які вимірюють зміну робочих показників на кожен градус Цельсія зростання. Температурні коефіцієнти, що характеризують зміну ефективності фотовольтаїчних модулів при зростанні температури, визначаються виробниками на основі тестувань у різних температурних умовах. Ці дані узагальнено представлено на рисунку 1.8. Для комерційних модулів на основі кристалічного кремнію (c-Si) втрати ефективності становлять приблизно 0,45% на кожен градус Цельсія підвищення температури, тоді як для модулів на основі аморфного

кремнію (a-Si) цей показник нижчий — близько 0,25% на °C. Наприклад, полікристалічний модуль при температурі 45 °C може видавати на 9% менше потужності, ніж передбачено стандартними тестовими умовами (STC). Температурний коефіцієнт напруги холостого ходу для c-Si модулів зазвичай становить від -3 до -5 мВ на °C, причому напруга холостого ходу знижується приблизно на 2,3 мВ на °C при температурах вище 25 °C. Модулі з вищою напругою холостого ходу є менш чутливими до високих температур, що робить їх кращим вибором для регіонів із спекотним кліматом.

Згідно з рисунком 1.8, технологія телуриду кадмію (CdTe) демонструє температурний коефіцієнт від -0,24% до -0,26% на °K, що свідчить про менші втрати ефективності при високих температурах порівняно з іншими технологіями. Це робить CdTe-модулі особливо придатними для використання в гарячих кліматичних умовах. Модулі на основі сульфідів міді-індію-галію-селену (CIGS) мають температурний коефіцієнт від -0,31% до -0,52% на °K, хоча їх оцінка обмежена через меншу комерційну поширеність. Монокристалічний і полікристалічний кремній характеризуються подібними значеннями коефіцієнтів: від -0,425% до -0,447% для монокристалічного та від -0,434% до -0,470% для полікристалічного кремнію. Тонкоплівкові технології мають широкий діапазон температурних коефіцієнтів — від -0,27% до -0,40% на °K залежно від матеріального складу.

Модулі з вищими температурними коефіцієнтами менш ефективні в спекотних кліматах, але можуть бути економічно вигідними в регіонах із помірними температурами. Ці показники відіграють ключову роль у прогнозуванні роботи фотовольтаїчних систем у реальних умовах, оскільки робочі температури значно варіюються залежно від географічного розташування та пори року. Вибір технології та конкретного продукту залежить від кліматичних умов і довгострокових цілей експлуатації, що вимагає ретельного аналізу температурних характеристик для забезпечення оптимальної продуктивності [1].

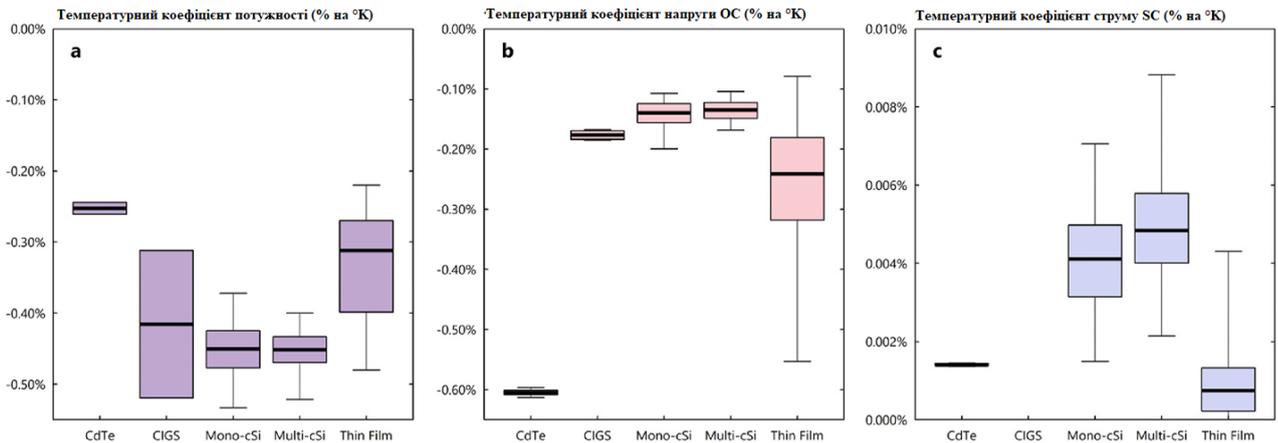


Рисунок 1.8 – Підсумок температурних коефіцієнтів для 21 000 комерційно доступних сонячних PV-модулів, згрупованих за технологією комірок

Температурні коефіцієнти, що характеризують зміну продуктивності фотовольтаїчних модулів, наведено для трьох параметрів: максимальної вироблюваної потужності, напруги розімкнутого кола та струму короткого замикання. Ці дані узагальнено на основі бази СЕС і представлено на рисунку 1.8. Товста лінія на графіку відповідає медіанному значенню коефіцієнта, затемнена область охоплює міжквартильний інтервал, а вусики вказують на 5-й і 95-й перцентилі. Досліджено такі технології: телурид кадмію (CdTe,  $n = 20$ ), сульфід міді-індію-галію-селену (CIGS,  $n = 8$ ), монокристалічний кремній (Mono-cSi,  $n = 9614$ ), полікристалічний кремній (Multi-cSi,  $n = 11\ 174$ ) та тонкоплівкові технології ( $n = 561$ ).

Усі фотовольтаїчні системи з часом зазнають деградації продуктивності, що призводить до зниження енергетичного виходу. Цей процес характерний не лише для PV-систем, а й для інших відновлюваних технологій. Підвищення робочої температури прискорює деградацію компонентів модулів, зокрема через руйнування клеєвих ущільнень, корозію, знебарвлення матеріалів, здуття, деламінацію, тріщини скла чи елементів, а також збої в електричних з'єднаннях. Дослідження показують, що швидкість деградації приблизно подвоюється з кожним підвищенням температури на  $10\text{ }^{\circ}\text{C}$ , що особливо помітно в тропічних кліматичних умовах за результатами довгострокових тестувань [1].

Для оцінки робочої температури модулів застосовується стандартизований тест номінальної робочої температури елемента (NOCT). Цей тест проводиться за умов: температура повітря 20 °C, інтенсивність випромінювання 800 Вт/м<sup>2</sup>, швидкість вітру 1 м/с та відкрита задня сторона модуля. NOCT забезпечує більш реалістичну оцінку температури в порівнянні зі стандартними тестовими умовами (STC), однак його точність у реальних системах викликає сумніви у виробників через складність відтворення цих умов. Для наближеного розрахунку температури елемента використовується рівняння 1.1, яке враховує ключові параметри навколишнього середовища та конструкції модуля.

$$T_{cell} = T_{air} + \frac{NOCT - 20}{800} E; \quad (1.1)$$

де  $T_{cell}$  – температура елемента,

$T_{air}$  – температура повітря,

NOCT – температура модуля за стандартних умов тестування,

$E$  – сонячне випромінювання в Вт/м<sup>2</sup>. Середнє NOCT для комерційних cSi-модулів становить 46,5 °C з міжквартильним діапазоном 45,5–47,5 °C, як показано на рисунку 1.9.

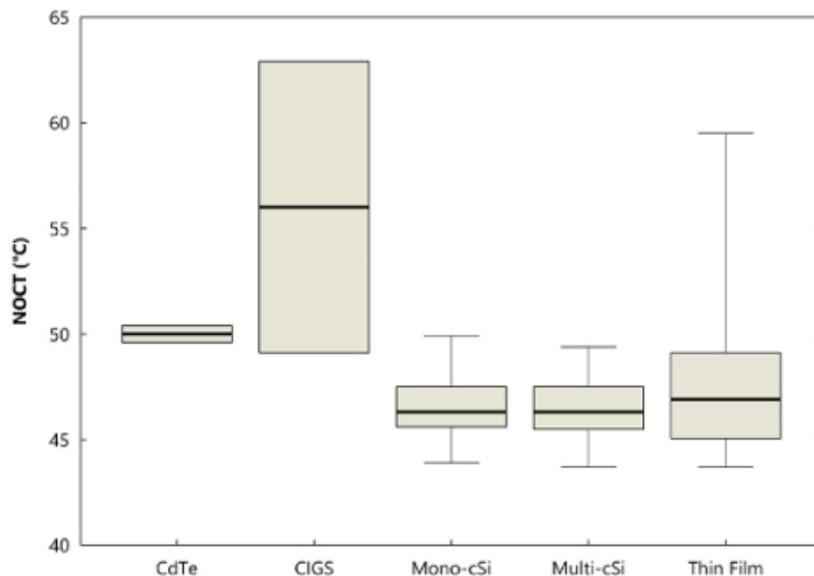


Рисунок 1.9 – Номінальна робоча температура комірки (NOCT) для 21 000 комерційно доступних сонячних PV-модулів, агрегованих за технологією комірок

### 1.3 Охолодження

Охолодження фотовольтаїчних (PV) модулів сприяє зниженню негативного впливу високих температур, підвищуючи їхню ефективність, вихідну потужність і термін служби. Існують два основні типи охолодження: пасивне та активне, вибір між якими залежить від розміру системи, кліматичних умов і економічної доцільності. Для окремих модулів зазвичай достатньо пасивного охолодження, тоді як щільно розташовані системи або установки з високою концентрацією сонячного випромінювання, наприклад, концентровані сонячні системи, потребують активних методів [1].

Пасивне охолодження не вимагає додаткової енергії та базується на оптимізації конструкції для покращення теплопередачі. До таких методів належать: використання радіаторів або ребер на задній поверхні модулів для стимулювання природної конвекції та теплового випромінювання, а також занурення модулів у воду. Для модулів, встановлених на будівлях, рекомендується забезпечувати відступ від поверхні даху або створювати канали для циркуляції повітря знизу, що сприяє охолодженню. Матеріали зі зміною фази (PCM) ефективно поглинають тепло, підтримуючи стабільну температуру модуля до досягнення точки плавлення PCM, що особливо корисно в денний період. Випаровувальне охолодження використовує приховану теплоту випаровування, а теплові труби забезпечують ефективне відведення тепла завдяки компактним циклам парорідинного обміну з окремими зонами випаровування та конденсації.

Активне охолодження потребує зовнішнього джерела енергії для роботи насосів або вентиляторів, що створює додаткове паразитне навантаження, знижуючи чистий вихід потужності PV-системи. До активних методів належать зрошування або розпилення води на поверхню модулів, а також примусове повітряне охолодження за допомогою вентиляторів. Водяне охолодження є ефективнішим порівняно з повітряним завдяки кращим теплофізичним властивостям води. Гібридні фотогальванічно-термічні (PV/T) системи

поєднують охолодження з утилізацією тепла: вода або повітря, що циркулює для охолодження модулів, може використовуватися для попереднього нагрівання приміщень чи побутової води. Рисунок 1.10 систематизує різні методи охолодження PV-систем, надаючи класифікацію їхніх особливостей і сфер застосування.



Рисунок 1.10 – Класифікація різних методів охолодження фотовольтаїчних модулів

#### 1.4 Атмосферні умови

Ряд атмосферних умов може впливати на вихід сонячних PV-систем. Цей розділ розглядає п'ять факторів: хмарність, забруднювачі, вологість, пил та швидкість вітру.

### 1.4.1 Характеристики хмарності

Хмарність суттєво впливає на продуктивність фотовольтаїчних електричних станцій (ФЕС), зменшуючи інтенсивність прямого сонячного випромінювання. Це зниження залежить від типу, щільності та фізичних характеристик хмар, таких як їхня оптична товщина, вміст рідкої води, розмір частинок і площа покриття. У регіонах із високою хмарністю, наприклад у Північній Європі, потужність ФЕС може знижуватися на 50%, тоді як у США та Китаї цей показник становить 15–30%, як показано в таблиці 1.2.

Щільні хмари, такі як низькі шаруваті, повністю блокують пряме сонячне світло, посилюючи розсіювання та створюючи дифузне освітлення. Це призводить до зниження генерації електроенергії, особливо в помірних широтах узимку, де вихід ФЕС може зменшуватися на 40–60%. Легкі купчасті хмари частково затіняють сонце, викликаючи коливання потужності через чергування світла й тіні. Високі перисті хмари, навпаки, пропускають значну частину сонячного випромінювання, хоча й послаблюють його інтенсивність [1].

Особливе явище, відоме як ефект "краю хмари", виникає на межах хмар, де світло заломлюється й фокусується, подібно до дії лінзи. Це може тимчасово підвищувати продуктивність фотоелектричних модулів, особливо в системах із функцією стеження за сонцем, що дозволяє оптимізувати генерацію в умовах часткової хмарності, наприклад, у перехідні сезони.

Короткострокові зміни хмарності ускладнюють прогнозування генерації. Шквальні лінії хмар, які повністю блокують світло, є більш передбачуваними, ніж купчасті хмари, що характеризуються високою варіативністю. Шквальні хмари швидко проходять, дозволяючи відновити генерацію, тоді як купчасті хмари можуть викликати триваліші коливання продуктивності. Прозорість хмар відіграє ключову роль у проникненні сонячного світла, що необхідно враховувати під час моделювання режимів роботи ФЕС.

### 1.4.2 Атмосферні забруднювачі та частинки

Атмосферні аерозолі, що складаються з мікроскопічних твердих і рідких частинок, таких як пил, дим, вулканічний попіл, морська сіль чи забруднення від природних і техногенних джерел, зменшують кількість сонячного випромінювання, що досягає поверхні Землі. Ці частинки розсіюють і поглинають сонячне світло, знижуючи ефективність фотовольтаїчних електричних станцій (ФЕС). Залежно від регіону, вплив аерозолів може скорочувати коефіцієнт використання потужності ФЕС до 20%. Наприклад, у Південній Кореї, де якість повітря погіршується через забруднення, генерація електроенергії на рівні комунальних систем знижується на 15–24%. У Китаї цей показник становить 11–15%.

Основними механізмами впливу аерозолів на сонячне випромінювання є розсіювання та поглинання світла. Розсіювання, зокрема релєївське, сильніше впливає на коротші хвилі світла (наприклад, синє), що пояснюється залежністю від оберненої четвертої степені довжини хвилі. У ясний день приблизно 10% сонячного випромінювання втрачається через розсіювання. Поглинання світла відбувається через присутність в атмосфері таких речовин, як озон, водяна пара та вуглекислий газ, що особливо помітно в урбанізованих районах із високим рівнем забруднення від транспорту та промисловості.

Для підвищення точності прогнозування продуктивності ФЕС необхідно враховувати дані моніторингу AOD (глобальна середня оптична глибина аерозолів) у моделях. Це дозволяє адаптувати прогнози до локальних умов, що особливо важливо в регіонах із високою концентрацією аерозолів, де їхній вплив може суттєво знижувати генерацію електроенергії [1].

### 1.4.3 Накопичення пилу

Накопичення пилу на поверхні фотовольтаїчних модулів (ФЕС) є одним із ключових факторів, що знижують їхню ефективність, поступаючись лише

впливу сонячного випромінювання та температури. Пил, що осідає на поверхні модулів, зменшує кількість падаючого сонячного світла через розсіювання та поглинання, що особливо помітно в посушливих регіонах, де втрати продуктивності можуть досягати 20–30% щомісяця.

На накопичення пилу впливають кілька факторів: швидкість і напрямок вітру, близькість до джерел пилу, погодні умови, а також розмір, форма і хімічний склад частинок. Наприклад, щільність пилу на рівні 10–30 г/м<sup>2</sup> може призводити до зниження продуктивності модулів на 20%. Більші частинки швидше осідають під дією гравітації, тоді як дрібні частинки, характерні для промислових зон, довше залишаються в повітрі, сприяючи їх швидкому накопиченню. Рисунок 1.11 ілюструє комплексний вплив цих факторів на осідання пилу.

Матеріал поверхні модулів також відіграє важливу роль. Скляні покриття менш схильні до накопичення пилу порівняно з тедларом, епоксидом чи пластиком. Кут нахилу модулів має обернений вплив на накопичення пилу: наприклад, при куті 30° втрати продуктивності становлять близько 1%. Легкий вітер може сприяти осіданню пилу, тоді як сильні пориви здатні частково очищати поверхню.

Накопичений пил спричиняє появу гарячих точок на модулях, що знижує силу струму та призводить до розсіювання енергії замість її генерації. Вплив пилу сильніше позначається на струмі, ніж на напрузі, оскільки струм зменшується зі збільшенням щільності пилового шару. Товщина цього шару є основним фактором зниження потужності, тоді як тривалість накопичення має менший вплив. Крім того, пил із корозійними чи кислотними частинками може прискорювати деградацію модулів, а перегрів через накопичення пилу підвищує ризик виходу елементів із ладу. Для забезпечення стабільної роботи ФЕС у пилових регіонах необхідний регулярний моніторинг і очищення поверхонь модулів [1].

Накопичення пилу на поверхні фотовольтаїчних модулів може суттєво знижувати їхню потужність, де втрати продуктивності можуть сягати до 60%. Дослідження впливу пилового забруднення вказують на значну залежність

результатів від місцевих кліматичних умов і особливостей встановлення PV-модулів. У регіонах із подібними кліматичними характеристиками та методами монтажу можливе узагальнення отриманих даних. Для оцінки впливу пилу на продуктивність модулів розроблено спрощені моделі, які дозволяють прогнозувати втрати потужності в посушливих зонах. Ці моделі є ефективним інструментом для планування роботи фотовольтаїчних станцій у таких умовах.



Рисунок 1.11 – Класифікація факторів, що впливають на накопичення пилу на сонячних PV-модулях

#### 1.4.4 Очищення від пилу

Накопичення пилу на поверхні фотовольтаїчних (PV) модулів значно знижує їхню продуктивність, що вимагає розробки ефективних методів очищення. Регулярне очищення може підвищувати коефіцієнт використання потужності PV-модулів на 50–100%, навіть якщо воно виконується лише раз на квартал. Залежно від умов експлуатації та місцевих ресурсів застосовуються різні підходи до очищення, які можна класифікувати на чотири основні категорії, як показано на рисунку 1.12: (I) механічні методи, (II) самовідновлювальні покриття, (III) електростатичні технології та (IV) природне очищення. Вибір оптимального методу залежить від розміру частинок пилу, а також доступності таких ресурсів, як вода чи електроенергія [1].

Природне очищення, що включає вплив вітру та дощу, може ефективно видаляти пил із поверхонь PV-модулів у регіонах із регулярними опадами. Проте в посушливих зонах, де пилові бурі є частим явищем, а опади обмежені, природне очищення не забезпечує достатньої ефективності. У таких умовах необхідно застосовувати штучні методи для підтримки стабільної продуктивності PV-систем.

Механічні методи очищення включають використання автоматизованих систем, таких як роботи, або обладнання з високим тиском води. Ці технології потребують значних енергетичних ресурсів і капіталовкладень, а також регулярного технічного обслуговування. У регіонах із дефіцитом води водні методи очищення стають економічно не вигідними, тому перевага надається безводним технологіям, які зменшують витрати на ресурси.

Самовідновлювальні покриття є перспективним рішенням для мінімізації накопичення пилу. Вони поділяються на гідрофобні та супер-гідрофільні типи. Гідрофобні покриття, натхненні структурою листя лотоса, зменшують адгезію пилу завдяки мікро- та наноструктурам із низькою поверхневою енергією. Це дозволяє краплям води формувати сферичні форми з високим контактним кутом, що сприяє їх скочуванню разом із частинками бруду. Хоча такі покриття

ефективні для видалення пилу, їхня продуктивність може знижуватися в умовах сильного атмосферного забруднення.

Кожен метод має свої переваги та обмеження. Наприклад, роботизоване очищення зменшує потребу в ручній праці, але вимагає значних початкових інвестицій. Вибір стратегії очищення залежить від кліматичних умов, економічних факторів і технічних можливостей, що необхідно враховувати під час прогнозування режимів роботи фотовольтаїчних станцій.

Такі покриття часто базуються на гідрофобних матеріалах, наприклад фторполімерах або силанах, які формують наноструктуровані поверхні для відштовхування води та забруднень. Супергідрофільні покриття активуються сонячним світлом через фотокаталіз, де вони хімічно розкладають забруднення та органічні домішки. Ці матеріали змінюють поверхню, роблячи її привабливою для води, що забезпечує ефект самовідновлення за рахунок зменшення кута контакту з водою практично до нульового значення. Типові способи модифікації включають введення гідроксильних груп (-ОН) або нанесення тонких шарів з гідрофільних речовин, таких як діоксид титану ( $\text{TiO}_2$ ) чи діоксид кремнію ( $\text{SiO}_2$ ). Комбінуючи ці методи з хімічним очищенням, можна досягти ефективності видалення забруднень на рівні близько 72% без використання додаткових пристроїв чи води. Крім того, системи, що застосовують хвильовий рух для моніторингу та усунення домішок, показують високу продуктивність, дозволяючи позбутися до 80% пилу всього за дві хвилини.

Коронний розряд створює іонізацію повітря поблизу поверхні, утворюючи заряджені частинки, які взаємодіють з пиловими забрудненнями. Трибоелектричний ефект виникає під час тертя двох різних матеріалів, що призводить до переносу заряду. Індукційне заряджання передбачає використання окремого зарядженого елемента: після притягнення пилу до зарядженої зони його видаляють механічними методами, такими як вібрація, потік повітря або зміна полярності заряду.

Електростатичні методи очищення особливо корисні в районах з обмеженим доступом до води, оскільки забезпечують швидке видалення пилу з

мінімальними витратами енергії та без потреби в ручній праці чи рідинах. Наприклад, у Йорданії таке очищення зменшило втрати потужності з 5,9% для панелей, що очищувалися природним чином, до 4,6%. Прозорі захисні екрани з самовідновлювальними властивостями, що використовують електромагнітні поля, також демонструють відмінні результати, усуваючи до 90% пилу менш ніж за півгодини без води чи людського втручання. Хоча пил переважно негативно впливає на роботу сонячних панелей, у деяких випадках він може мати корисний ефект, зменшуючи відбиття світла під великими кутами від захисного скла та таким чином підвищуючи кількість захопленого випромінювання в певних умовах.



Рисунок 1.12 – Класифікація методів очищення пилу з PV

### 1.4.5 Вологість

Вологість повітря зазвичай має зворотну залежність із вихідною потужністю фотовольтаїчних систем, що підтверджується даними, представленими на рисунку 1.13, де видно зниження продуктивності зі зростанням рівня вологості. Краплі води, присутні в атмосфері, викликають заломлення, відбиття та дифракцію сонячного світла, що зменшує інтенсивність випромінювання, яке досягає поверхні сонячних елементів. Крім того, вологість сприяє накопиченню дрібних частинок пилу на поверхні модулів, що погіршує пропускання світла. Підвищена вологість також прискорює деградацію компонентів модуля, зокрема через розшарування інкапсулюючого матеріалу.

Проте вологість може мати й позитивний вплив, оскільки вона сприяє зниженню температури модуля, що підвищує його ефективність. Зокрема, зростання вологості на 1% може знижувати температуру поверхні модуля на 0,1–0,2 °С, що особливо помітно в тропічних регіонах із високою вологістю, де такий ефект сприяє природному охолодженню [1].

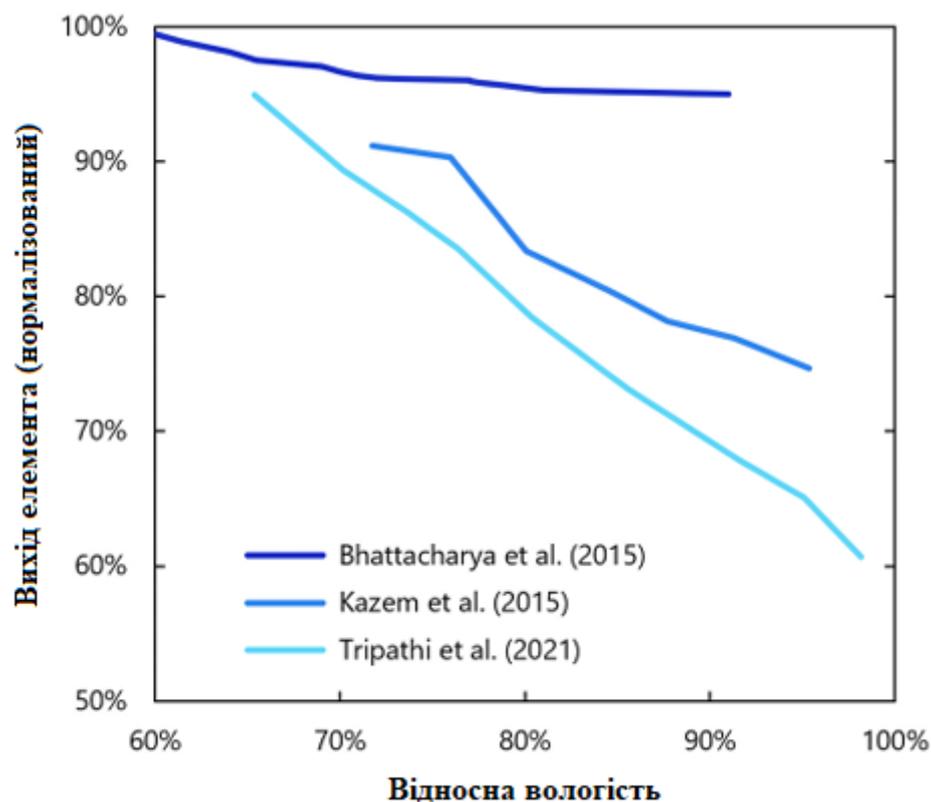


Рисунок 1.13 – Зміна ефективності фотомодулів у залежності від вологості

#### 1.4.6 Швидкість вітру

Швидкість вітру відіграє важливу роль у роботі фотовольтаїчних систем, насамперед завдяки охолодженню модулів, що сприяє відведенню надлишкового тепла. Зі збільшенням швидкості вітру посилюється конвективне охолодження, що знижує температуру сонячних елементів і, відповідно, підвищує їхню ефективність. Наприклад, у прибережних регіонах, де постійні бризи забезпечують стабільне охолодження, річний вихід енергії може зростати на 5–10%, що робить такі території привабливими для розміщення сонячних електростанцій. Однак надмірно висока швидкість вітру може створювати ризик механічних пошкоджень, що вимагає використання міцніших конструкцій і надійних кріплень.

Крім того, швидкість вітру впливає на накопичення пилу на поверхні модулів. Помірні швидкості вітру, у діапазоні 2–5 м/с, сприяють природному очищенню поверхонь, зменшуючи осідання забруднень. Натомість низькі швидкості вітру можуть сприяти накопиченню пилу, що погіршує продуктивність. Оптимальний діапазон швидкості вітру, який забезпечує баланс між ефективним охолодженням і мінімальним забрудненням, є особливо важливим для сонячних електростанцій, розташованих у степових регіонах.

#### 1.5 Вплив рельєфу

У цьому підрозділі проаналізовано вплив особливостей рельєфу на роботу фотовольтаїчних систем, зосереджуючись на таких характеристиках поверхні, як альbedo та наявність снігового покриву, а також їхній ефект на інтенсивність сонячної радіації, генерацію електроенергії та загальну ефективність установок. Наприклад, у гірських або пустельних регіонах рельєф може значно змінювати локальні умови освітленості, що вимагає адаптації конструкцій сонячних електростанцій для забезпечення максимальної продуктивності [1].

### 1.5.1 Альbedo

Альbedo, або здатність поверхні відбивати сонячне випромінювання, є важливим фактором, що впливає на енергетичний баланс Землі та ефективність роботи фотовольтаїчних систем. Цей показник визначає частку відбитої сонячної радіації відносно загальної падаючої: значення 0 відповідає повному поглинанню, а 1 — повному відбиттю. Альbedo залежить від типу поверхні та змінюється через природні чи антропогенні фактори, такі як сезонні зміни снігового покриву, урбанізація або трансформація ландшафтів. Наприклад, поверхні з високим альbedo, такі як снігові поля чи пустелі, відбивають значну частину сонячного світла, знижуючи локальну температуру. Натомість темні поверхні, як-от ліси чи водойми, поглинають більшу частину випромінювання, що характеризується низьким альbedo. У пустельних регіонах альbedo може досягати 40–60%, тоді як у тропічних лісах воно зазвичай становить близько 10%, що впливає на тепловий режим і продуктивність сонячних установок.

Глобальні кліматичні зміни, зокрема танення льодовиків, знижують альbedo планети, оскільки світлі відбиваючі поверхні замінюються темнішими ділянками суші чи води, що посилює поглинання тепла. Свіжий сніг характеризується високим альbedo, відбиваючи до 96–98% випромінювання у видимому діапазоні та приблизно 80% у повному спектрі. Крижані поверхні відбивають близько 80% сонячного світла, але цей показник знижується до 40% або менше за наявності талої води. Хмарність може підвищувати альbedo снігу, змінюючи спектральний склад світла, тоді як забруднення, наприклад пил чи сажа, знижує відбиваючу здатність снігу. Такі фактори необхідно враховувати під час прогнозування роботи фотовольтаїчних систем у регіонах із сезонними змінами, наприклад у тундрі.

Хмари мають альbedo в межах 40–90%, ліси — 5–15%, а водойми — від 2 до 99% залежно від кута падіння світла та стану поверхні.

Поверхні з високим альbedo, такі як пустелі чи снігові поля, підвищують інтенсивність сонячної радіації, що надходить до фотовольтаїчних модулів,

сприяючи збільшенню генерації електроенергії. Цей ефект особливо помітний у періоди низького положення сонця, наприклад рано вранці чи ввечері, коли відбиття сприяє піковій продуктивності. Крім того, високе альbedo забезпечує охолоджувальний ефект, зменшуючи робочу температуру модулів, що підвищує їхню ефективність і подовжує термін експлуатації. У пустельних регіонах високе альbedo може частково компенсувати втрати продуктивності, спричинені високими температурами, роблячи такі території вигідними для розміщення сонячних електростанцій.

### 1.5.2 Сніговий покрив

Опади у вигляді снігу значно впливають на роботу фотовольтаїчних модулів, особливо в регіонах із тривалим сніговим покривом. Сніг створює комплексний ефект: з одного боку, сніговий шар на поверхні модулів зменшує інтенсивність сонячного випромінювання, що надходить до елементів, а з іншого — відбиття світла від навколишнього снігу може частково компенсувати втрати. Проте зі збільшенням товщини снігового покриву на модулях вихідна потужність суттєво знижується через зменшення проникнення сонячної радіації. Наприклад, у Мюнхені (Німеччина) втрати енергії через сніг становлять від 0,3 до 2,7%, тоді як у регіонах України за товщини снігу 4 мм вони можуть перевищувати 40%.

Кут нахилу модулів є вирішальним фактором, що впливає на втрати енергії через накопичення снігу. Зменшення кута нахилу з  $40^\circ$  до  $30^\circ$  у штаті Юта (США), де спостерігаються значні снігопади, призводить до зростання щоденних втрат на 6–19%. У штаті Мічиган (США) зміна кута з  $45^\circ$  до горизонтального положення ( $0^\circ$ ) збільшує річні втрати від снігу з 5% до 34%. Для систем із перешкодами, що ускладнюють природне очищення, річні втрати залишаються на рівні 30–34% незалежно від кута нахилу. Ці дані підкреслюють важливість оптимізації конструкції фотовольтаїчних систем у регіонах зі снігопадами, де використання більш вертикального монтажу може значно зменшити накопичення снігу та пов'язані з ним втрати.

Накопичення снігу на фотовольтаїчних модулях залежить від температури повітря та рівня вологості, що впливають на тривалість снігового покриву. Підвищення температури сприяє швидшому таненню снігу, тоді як висока вологість подовжує час його утримання на поверхні модулів. При температурах близько  $-3\text{ }^{\circ}\text{C}$  снігові частинки можуть відскакувати або скочуватися з поверхні, але за нижчих температур (нижче  $-3\text{ }^{\circ}\text{C}$ ) вони починають прилипати через когезію, що призводить до накопичення. Навіть за наявності снігового покриву модулі здатні отримувати частину сонячної радіації, а тепло, що виділяється самими модулями, може ініціювати танення снігу при температурах до  $-3\text{ }^{\circ}\text{C}$  і товщині покриву до 10 см. Процес танення передбачає поступове збільшення вмісту рідкої води в сніговому шарі, що зменшує тертя в нижній частині та сприяє ковзанню снігу. Скидання снігу відбувається без значного танення, коли температура поверхні наближається до  $0\text{ }^{\circ}\text{C}$ , дозволяючи снігу швидко скочуватися. Повільне танення характеризується поступовим розрідженням снігу від верхньої до нижньої частини модуля, що подовжує час покриття та збільшує втрати енергії. Комбіноване танення зі скиданням поєднує бічне танення з вертикальним скочуванням, формуючи багат шаровий процес видалення снігу.

Сніговий покрив у навколишній місцевості може позитивно впливати на продуктивність фотовольтаїчних систем завдяки підвищенню альbedo. Наприклад, у модулях, встановлених під нахилом, спостерігалось зростання вихідної потужності на 1% через відбиття світла від снігу. Аналогічно, вертикальні модулі в Японії демонстрували підвищену ефективність завдяки відбиттю сонячної радіації від снігового покриву. Незважаючи на ці позитивні ефекти, для їх практичного використання потрібне глибше вивчення. Видалення снігу з поверхні модулів не лише зменшує втрати енергії, а й запобігає деградації елементів і знижує механічне навантаження від снігу. Для цього застосовуються різні методи, наприклад, гідродинамічні покриття, які зменшують накопичення снігу та льоду, хоча їхній вплив на загальну продуктивність системи залишається обмеженим. Такі рішення необхідно інтегрувати в проекти фотовольтаїчних

установок у регіонах із суворими зимовими умовами для забезпечення стабільної роботи [1].

## 1.6 Довгострокові зміни сонячної радіації

Зміни клімату впливають на низку факторів, що знижують ефективність фотовольтаїчних систем, зокрема через зростання вологості, частіші лісові пожежі та град. Одним із ключових наслідків є підвищення температури повітря, що призводить до частішого перевищення критичних порогів, таких як середньодобова температура вище 25 °С, за яких продуктивність сонячних елементів знижується. У поєднанні зі збільшенням хмарності це може вдвічі збільшити кількість літніх днів із низькою генерацією електроенергії в регіонах, що зазнають найбільшого впливу. Крім того, інтенсивність сонячної радіації не є сталою і зазнає змін на багаторічних масштабах. Зміни атмосферних умов впливають на глобальну горизонтальну радіацію (ГНІ), що проявляється у фазах "затемнення" та "просвітлення". Зокрема, з 1960-х до 1980-х років спостерігалось зниження сонячної радіації, після чого відбувалося її часткове відновлення.

Зовнішні фактори, такі як зміни орбіти Землі, мають мінімальний вплив на продуктивність фотовольтаїчних систем у межах десятиліть, оскільки ці зміни відбуваються на значно більших часових масштабах. Аналогічно, коливання сонячної активності в межах 11-річного циклу Швабе становлять лише близько 0,1%, що є недостатнім для суттєвого впливу на генерацію енергії. Натомість ключову роль відіграють атмосферні чинники, такі як водяна пара, радіаційно активні гази, характеристики хмар, аерозолі та антропогенні викиди, які визначають довгострокову ефективність фотовольтаїчних систем.

### 1.6.1 Водяна пара та інші радіаційно активні гази

Водяна пара є одним із найвпливовіших парникових газів в атмосфері, що впливає на інтенсивність глобальної горизонтальної радіації (ГНІ). Зростання

концентрації водяної пари на 10% призводить до зниження ГНІ на 0,5%. Починаючи з кінця 19 століття, концентрація водяної пари в атмосфері зростала в середньому на 7% на кожен градус підвищення глобальної температури. Це створює цикл зворотного зв'язку, оскільки водяна пара, як парниковий газ, сприяє утриманню тепла в атмосфері, що посилює потепління. Проте зменшення сонячної радіації, яке спостерігалось з 1960-х до 2000-х років, значно перевищує ефект, який можна пояснити зростанням концентрації водяної пари за цей період. Таким чином, хоча водяна пара має значний потенціал для впливу на сонячну радіацію, її відносно незначні зміни свідчать про те, що вона не є головним чинником довгострокових змін у радіаційному балансі. У тропічних регіонах із високою вологістю цей ефект може бути більш вираженим, але в цілому інші атмосферні фактори відіграють домінуючу роль [1].

### 1.6.2 Характеристики хмар

Дані про хмарність у минулому переважно базуються на візуальних спостереженнях неба, проведених протягом 20 століття, із обмеженою кількістю глобальних аналізів змін. Проте регіональні дослідження надають певну інформацію. Наприклад, у Німеччині в період із 1964 по 1990 роки сонячна радіація в хмарні дні зменшувалася на 8% за десятиліття, тоді як у ясні дні значних змін не спостерігалось. У США зростання кількості хмарних днів і підвищення оптичної щільності хмар були ключовими факторами зниження сонячної радіації в період із 1960 по 1990 роки.

Ці дані вказують на значний вплив змін характеристик хмар на довгострокові тенденції сонячної радіації. Однак цей вплив не є однаковим у всіх регіонах. Наприклад, у Китаї з 1954 по 2001 роки спостерігалось зменшення хмарності та збільшення кількості безхмарних днів, але сонячна радіація в цей період все одно знижувалася.

### 1.6.3 Вплив аерозолів та антропогенних викидів

Аерозолі впливають на кількість сонячної радіації, що досягає поверхні Землі, через зміну їхньої маси та оптичних характеристик, що впливає на розсіювання випромінювання. Цей процес, відомий як "прямий ефект" аерозолів, змінює інтенсивність сонячного світла. Крім того, аерозолі сприяють утворенню хмар, діючи як ядра конденсації (CCN), які притягують молекули води, що призводить до формування хмарного покриву — так званий "непрямий ефект". Ефективність аерозолів як ядер конденсації залежить від їхнього розміру, хімічного складу та структури, що підкреслює важливість типу аерозолу поряд із його концентрацією. У регіонах із високим рівнем забруднення щільні аерозольні шари можуть нагрівати атмосферу та стабілізувати її, що ускладнює утворення нових хмар. Цей процес, відомий як "напівпрямий ефект", також зменшує поверхневе випаровування, додатково обмежуючи хмароутворення.

Докази впливу аерозолів на сонячну радіацію в період "затемнення" до 1980-х років базуються переважно на непрямих даних через обмеженість точних історичних вимірювань концентрації аерозолів. Аналіз даних за 1960–1990 роки показав зв'язок між викидами від спалювання викопного палива та зниженням глобальної горизонтальної радіації (GHI) у густонаселених і промислових регіонах. Наприклад, в Ізраїлі в період із 1956 по 1987 роки зменшення GHI корелювало зі зростанням кількості транспортних засобів, попри стабільний рівень хмарності. У Китаї між 1960 і 2000 роками трикратне зростання концентрації чорного вуглецю та дев'ятикратне збільшення викидів діоксиду сірки (SO<sub>2</sub>) призвели до затемнення на 24 Вт/м<sup>2</sup> і зниження коефіцієнта потужності фотовольтаїчних систем на 11–15%, із середнього значення 16,2% до 14,2%.

З початком супутникової ери в 1980-х роках більш точні дані про концентрацію аерозолів дозволили встановити зв'язок між їхнім навантаженням і зростанням сонячної радіації наприкінці 20 століття. Глобальне зниження концентрації аерозолів, зокрема зменшення викидів діоксиду сірки (SO<sub>2</sub>) та

чорного вуглецю на 0,13% щорічно, корелює зі зростанням сонячної радіації на 0,1% на рік у період із 1983 по 2001 роки. Не всі зміни в аерозольному навантаженні пов'язані з діяльністю людини. Наприклад, на Аравійському півострові та в окремих частинах пустелі Сахара в 21 столітті спостерігалось зростання оптичної товщини аерозолів через збільшення пилових викидів, тоді як у Китаї та південно-західній Азії концентрація аерозолів зменшилася завдяки зростанню кількості опадів. Регіони з найбільшим зниженням аерозольного навантаження демонструють найвищі темпи зростання сонячної радіації. Цей зв'язок підтверджується регіональними дослідженнями, зокрема щодо викидів від спалювання викопного палива в Китаї та атмосферних коричневих хмар в Індії, які переважно спостерігаються в сухі сезони. Прямі докази вказують на те, що аерозольне навантаження є ключовим фактором багаторічних змін сонячної радіації. Відповідно, заходи з покращення якості повітря, такі як обмеження вмісту SO<sub>2</sub> у судовому паливі, можуть позитивно вплинути на коефіцієнти потужності фотовольтаїчних систем у майбутньому [1].

Висновок до першого розділу: Ефективність функціонування фотовольтаїчних електричних станцій (ФЕС) значною мірою залежить від впливу навколишнього середовища, включаючи сонячне випромінювання, температуру, атмосферні умови, рельєф та довгострокові кліматичні зміни. Комплексний аналіз цих факторів дозволяє точно прогнозувати режими роботи, мінімізувати втрати продуктивності та оптимізувати інтеграцію ФЕС в енергосистему. Застосування сучасних технологій, таких як системи охолодження, очищення від пилу та адаптивні моделі, сприяє підвищенню стабільності, зменшенню витрат і подовженню терміну експлуатації обладнання. У підсумку, врахування екологічних аспектів не лише забезпечує економічну вигоду, але й підтримує глобальний перехід до сталої енергетики, роблячи ФЕС ключовим елементом зеленої трансформації.

## 2 СИСТЕМАТИЧНИЙ ОГЛЯД МЕТОДІВ ПРОГНОЗУВАННЯ ФЕС

Сьогодні ФЕС набирає популярності завдяки своїй модульній конструкції, відсутності потреби в додаткових ресурсах на кшталт води чи палива, мінімальним витратам на обслуговування та браку рухомих елементів у процесі роботи. Крім того, собівартість виробництва й монтажу ФЕС систематично знижується з кожним подвоєнням загальної встановленої потужності, що робить її вигідною для широкого застосування в різних кліматичних умовах, наприклад, у великих сонячних парках у пустельних регіонах.

Енергетичний сектор стикається з ключовим завданням: задовольняти зростаючий попит на енергію, водночас зменшуючи емісію парникових газів. У таких умовах планування балансу між споживанням і генерацією стає вкрай важливим, а точні моделі прогнозування доступності ВДЕ необхідні для ефективного управління мережами та оптимізації виробництва. Зокрема, точне передбачення потужності ФЕС може посилити стабільність системи, мінімізувати невизначеність щодо доступної енергії та покращити якість обслуговування, наприклад, у розумних мережах, де інтеграція нестабільних джерел вимагає оперативної реакції на зміни. Саме тому значні ресурси спрямовуються на створення надійних моделей прогнозування сонячної генерації для різних часових інтервалів – від секунд до днів, залежно від конкретних завдань, як це показано в таблиці 2.1.

Таблиця 2.1 – Класифікація горизонтів прогнозування виробництва сонячної PV енергії та їх застосування.

Категорія горизонту прогнозування	Горизонт прогнозування	Застосування
1	2	3
Внутрішньогодинний	Кілька секунд до години	<ul style="list-style-type: none"> <li>◆ Керування накопиченням енергії</li> <li>◆ Згладжування потужності</li> <li>◆ Планування смарт-грид</li> <li>◆ Планування диспетчеризації електроенергії</li> <li>◆ Моніторинг стану PV-установок</li> </ul>

Категорія горизонту прогнозування	Горизонт прогнозування	Застосування
1	2	3
Внутрішньоденний	1–6 год	<ul style="list-style-type: none"> <li>◆ Керування електричними навантаженнями</li> <li>◆ Експлуатація та керування PV-системами</li> <li>◆ Ціноутворення електроенергії</li> <li>◆ Керування смарт-грид</li> </ul>
Добовий	6–48 год	<ul style="list-style-type: none"> <li>◆ Планування технічного обслуговування PV-систем</li> <li>◆ Ціноутворення електроенергії</li> <li>◆ Планування, експлуатація та зобов'язання одиниць</li> <li>◆ Визначення розмірів накопичувачів</li> </ul>

Прогнозування генерації сонячної фотоелектричної енергії на основі моделей, орієнтованих на дані, стикається з низкою серйозних перешкод, насамперед через вроджену нестабільність і випадковість сонячної енергії. Доступ до високорозподільних і послідовних історичних даних, які є ключовими для точних передбачень, часто обмежений або нестабільний через еволюцію технологій і короткі періоди спостережень на нових установках. Крім того, коливання в виробництві фотоелектричної енергії, зумовлені погодними чинниками, такими як інтенсивність сонячного випромінювання, температура навколишнього середовища, рівень вологості та швидкість вітру, (детальніше в першому розділі) створюють труднощі для забезпечення стабільності енергомережі та ефективного планування операцій. Наприклад, у регіонах з частою хмарністю прогнози можуть суттєво відхилятися від фактичних показників, що ускладнює управління системою. Точні моделі мусять враховувати ці варіації, але переривчастий характер сонячної потужності робить це завданням високої складності. Інтеграція фотоелектричних систем у загальну електромережу вирізняється більшою складністю порівняно з традиційними джерелами, оскільки залежність від погоди призводить до зростання енергоспоживання та підвищення витрат на експлуатацію. Розробка надійних прогнозних моделей ускладнюється необхідністю ефективного відбору та

перетворення характеристик, адже точність таких моделей критично залежить від оптимального набору вхідних параметрів.

Хоча акцентування уваги на зборі даних, їхній обробці та виборі статистичних, машинного навчання чи глибокого навчання методів, чимало суттєвих прогалин лишаються невирішеними. Зокрема, часто ігнорується комплексна інтеграція процесів збору даних, побудови моделей, кількісної оцінки невизначеності та адаптивних механізмів навчання, які є життєво важливими для підвищення точності в реальних умовах експлуатації. Також недооцінюються динамічні ефекти змінної погоди та роль метаевристичних алгоритмів оптимізації в удосконаленні прогнозів фотоелектричної потужності.

## 2.1 Систематична структура

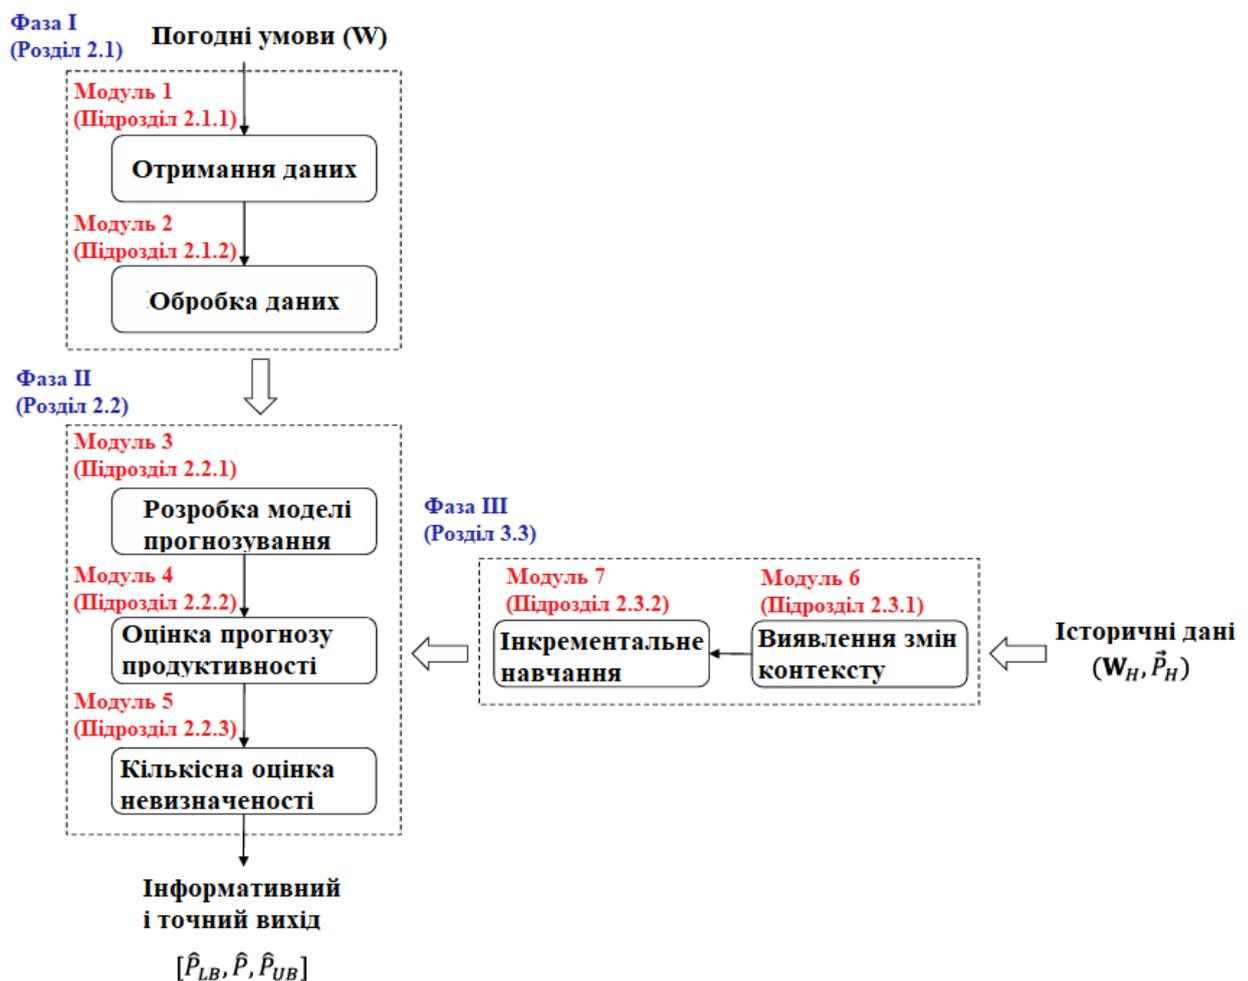


Рисунок 2.1 – Систематична та інтегративна структура для прогнозування виробництва електроенергії сонячними фотоелектричними панелями

### 2.1.1 Етап I: Підготовка даних

Етап I присвячений підготовці даних і включає два ключові модулі: збір даних (модуль 1) і їх обробку (модуль 2), що формують основу для створення ефективної системи прогнозування. Модуль 1 зосереджений на отриманні якісних і релевантних даних із різноманітних джерел, таких як метеорологічні станції, супутникові системи чи сенсори на фотоелектричних установках. Це забезпечує повноту, актуальність і точність інформації, необхідної для подальшого аналізу та моделювання. Особлива увага приділяється вибору даних, які відображають локальні особливості, наприклад, географічні та кліматичні умови, що впливають на генерацію сонячної енергії.

Сучасні дослідження в галузі прогнозування генерації фотоелектричних систем акцентують на ідентифікації ключових параметрів, які визначають динаміку виробництва енергії. Ці параметри включають історичні дані про генерацію, метеорологічні показники (сонячне випромінювання, температура, вологість) і технічні характеристики обладнання. Такі дані дозволяють адаптувати моделі до специфічних умов експлуатації, наприклад, для оптимізації прогнозів у регіонах із нестабільною погодою чи складним рельєфом.

Фізичні методи прогнозування: Фізичні моделі базуються на використанні метеорологічних даних як вхідних параметрів для математичних рівнянь, що описують перетворення сонячного випромінювання в електричну енергію. До основних джерел даних належать чисельні прогнози погоди, які надають інформацію про очікувані погодні умови, зображення з систем повної візуалізації неба, що дозволяють відстежувати хмарність у реальному часі, а також супутникові дані, які забезпечують широкий огляд метеорологічних умов. Крім того, локальні метеостанції надають деталізовану інформацію, що враховує регіональні особливості, такі як топографія, затінення чи рівень забруднення атмосфери. Ці дані сприяють підвищенню точності прогнозів, особливо в умовах складного мікроклімату.

Статистичні методи прогнозування: Статистичні моделі встановлюють зв'язки між вхідними параметрами (наприклад, метеорологічними даними) і вихідними показниками (генерацією енергії) на основі аналізу часових рядів або кореляційних залежностей. Вони охоплюють традиційні підходи, такі як регресійний аналіз і методи аналізу часових рядів, а також сучасні техніки, засновані на штучному інтелекті. До останніх належать штучні нейронні мережі, моделі з довготривалою короткостроковою пам'яттю (LSTM) і методи опорних векторів (SVM). Гібридні моделі, що поєднують статистичні та інтелектуальні підходи, демонструють високу ефективність у ситуаціях із значною варіабельністю, наприклад, при сезонних змінах погоди чи раптових метеорологічних коливаннях. Такі комбінації дозволяють моделям краще адаптуватися до нестабільних умов і підвищувати точність прогнозів.

Гібридні методи: Гібридні методи прогнозування поєднують фізичні та статистичні підходи для підвищення точності передбачень генерації фотоелектричних систем. Цей підхід розпочинається з використання фізичних залежностей, визначених характеристиками фотоелектричних модулів, які надаються виробником, з подальшим застосуванням статистичних технік для уточнення прогнозів. Наприклад, аналіз історичних даних про вихідну потужність фотоелектричної станції дозволяє оцінити технічні параметри установки, які потім використовуються як вхідні дані для прогнозних моделей. Така комбінація емпіричних спостережень і теоретичних розрахунків забезпечує кращу адаптацію до реальних умов експлуатації, особливо в ситуаціях з обмеженим обсягом даних. Гібридні моделі вирізняються високою гнучкістю та здатністю підвищувати точність прогнозів у складних сценаріях, наприклад, у регіонах із нестабільними погодними умовами [3].

Точність прогнозування потужності фотоелектричних систем залежить від кількох ключових факторів: метеорологічних умов, часового горизонту прогнозування, роздільної здатності даних, географічного розташування об'єкта та доступності якісної інформації про нього. Для мінімізації похибок необхідна інтеграція даних із різних джерел, таких як локальні метеостанції, сусідні

спостережні пункти, супутникові зображення, системи візуалізації хмарного покриву та чисельні прогнози погоди (NWP). Ці джерела даних дають змогу створювати прогнози для різних часових горизонтів. Наприклад, для ультракороткострокових прогнозів (від кількох хвилин до години) ефективними є статистичні моделі, що базуються на історичних даних про генерацію. Якщо ж використовуються супутникові зображення, які відображають швидкі зміни хмарності, прогнозний горизонт може бути розширений до кількох годин. Для прогнозів на шість годин і більше оптимальними є чисельні прогнози погоди, які ефективно враховують складні метеорологічні умови. Однак у віддалених регіонах, де доступ до NWP обмежений через недостатню інфраструктуру, точність прогнозів може знижуватися, що вимагає альтернативних підходів, таких як використання історичних патернів для компенсації браку даних.

Деякі моделі прогнозування спираються виключно на історичні дані про генерацію фотоелектричної енергії, що є економічно вигідним рішенням у випадках, коли отримання актуальних метеорологічних даних ускладнене або пов'язане з високими витратами. Проте постійний доступ до прогнозів погоди може бути обмеженим через складнощі в обміні даними з метеорологічними службами, що підкреслює необхідність гнучких стратегій, таких як використання статистичних методів для заповнення прогалів у даних.

### 2.1.2 Модуль 2: Обробка даних

Якість вхідних даних є визначальним фактором для забезпечення точності та надійності прогнозування генерації фотоелектричних систем. Основна увага приділяється історичним часовим рядам даних про вихідну потужність, метеорологічним показникам і географічним особливостям місця розташування установки. Ці дані дозволяють враховувати локальні умови, такі як рельєф, кліматичні особливості чи сезонні зміни, що сприяє адаптації моделей до конкретних умов експлуатації. Високоякісні дані необхідні для ефективного управління енергією, особливо в розумних мережах, де варіабельність генерації

може спричинити перевантаження або нестабільність системи. Точні прогнози забезпечують стабільне постачання електроенергії кінцевим споживачам і підвищують надійність роботи енергосистем [4].

Проте набори даних часто містять аномалії, такі як різкі стрибки чи пропуски, спричинені сезонними змінами, погодними коливаннями, збоями в енергосистемах або варіаціями попиту на електроенергію. Додатковими факторами, що погіршують якість даних, є помилки запису чи несправності сенсорів. Для усунення цих проблем застосовуються методи попередньої обробки, такі як інтерполяція, декомпозиція чи корекція сезонних ефектів, які дозволяють виправити спотворення, усунути аномалії та стабілізувати дані для підвищення точності моделей.

Для підготовки даних до прогнозування використовуються різноманітні методи. Серед них — аналіз часових рядів без тренду, вейвлет-перетворення (WT), нормалізація, емпірична декомпозиція мод (EMD) і самонавчальні карти (SOM). Наприклад, для усунення сезонних варіацій застосовуються статистичні інструменти, такі як авторегресійні моделі з ковзним середнім, логарифмічні перетворення, нейронні мережі чи гібридні підходи, що поєднують кілька методів. Один із дослідників використав індекс чистого неба для попередньої обробки метеорологічних даних, застосовуючи багатоваріантні нейронні мережі, що дозволило зменшити середню помилку прогнозу для даних із сезонними закономірностями.

Вейвлет-перетворення та нормалізація є одними з найпоширеніших технік. Вейвлет-перетворення використовує концепцію хвилі з нульовим середнім для створення часо-частотного представлення сигналу, що дозволяє декомпонувати та реконструювати дані для усунення шумів. Наприклад, вейвлет-перетворення в поєднанні зі штучним інтелектом застосовувалося для прогнозування генерації фотоелектричної енергії, враховуючи зв'язки між сонячним випромінюванням, температурою та вихідною потужністю. Такий підхід покращує обробку нестабільних часових рядів і дозволяє ефективніше моделювати нелінійні коливання. Інший приклад — комбінація вейвлет-фільтрації з нечіткими картами

адаптивної резонансної теорії (ARTMAP) для короткострокового прогнозування. Ця модель показала кращі результати порівняно з традиційними нейронними мережами, особливо для зашумлених даних.

Ще один підхід поєднує вейвлет-перетворення з граничними навчальними машинами (ELM), де метеорологічні дані виступають вхідними характеристиками, а дані генерації — цільовими значеннями. Порівняння з методом K-mean показало перевагу ELM у зменшенні розмірності даних і підвищенні точності. Також застосовувалася гібридна модель, що інтегрує вейвлет-перетворення, оптимізацію зграєю частинок (PSO) і метод опорних векторів (SVM) для короткострокового прогнозування в мікромережах. Нормалізація, своєю чергою, стабілізує діапазон даних, зменшує обчислювальну складність і сприяє кращій адаптації моделей до динамічних умов, що підтверджується численними дослідженнями.

Якість і повнота вхідних даних є критично важливими для точного прогнозування генерації сонячних фотоелектричних систем. Для усунення прогалин у даних, таких як відсутні значення метеорологічних параметрів чи показників потужності, застосовуються методи фільтрації та попередньої обробки. Наприклад, однією з технік є очищення наборів даних шляхом видалення записів із некоректними значеннями, таких як дані про сонячне випромінювання без відповідної генерації електроенергії, що допомагає уникнути систематичних помилок у моделях. Інший підхід передбачає використання генеративних змагальних мереж (GAN) для створення синтетичних даних, що імітують екстремальні погодні умови. Це особливо корисно в регіонах із обмеженим доступом до метеорологічної інформації, де повнота даних є проблемою. Такі методи фільтрації сприяють підвищенню стійкості моделей до аномалій і покращенню їхньої точності [4].

Техніки зменшення розмірності та аналізу даних: Для оптимізації прогнозних моделей застосовуються методи зменшення розмірності, аналізу кореляції, відбору та витягнення ознак, кластеризації даних і виявлення викидів. Наприклад, метод головних компонент (PCA) використовується для зменшення

кількості змінних шляхом вибору найвпливовіших ознак, що дозволяє створювати компактніші моделі без втрати ключової інформації. PCA часто комбінується з аналізом кореляції для відбору метеорологічних параметрів, які мають найбільший вплив на генерацію. Наприклад, випадковий ліс (RF) застосовувався як базова модель у поєднанні з PCA для зменшення розмірності даних, що покращило продуктивність прогнозів за умов високої кореляції між змінними.

Інший підхід передбачає використання згорткових нейронних мереж (CNN) у поєднанні з техніками витягнення ознак для коротко- та середньострокового прогнозування. Наприклад, комбінація згорткових автоенкодерів (AE) для витягнення ознак, алгоритму K-mean для кластеризації зображень хмарного покриву та гібридних моделей глибокого навчання показала високу ефективність для надкороткострокового прогнозування. У подібних моделях як базові алгоритми використовуються штучні нейронні мережі (ANN), мережі з довготривалою короткостроковою пам'яттю (LSTM) або CNN, що забезпечують адаптацію до динамічних умов.

Ще один приклад — інтеграція даних про генерацію фотоелектричної енергії, чисельних прогнозів погоди (NWP) і векторів руху хмар (CMV) у моделі регресії опорних векторів (SVR). Такі гібридні вхідні дані показали кращу точність порівняно з традиційними фізичними моделями, особливо в умовах мінливої погоди. Для підвищення стійкості до шумів і викидів застосовується щільніший локальний підхід на основі зваженої гауссової регресії процесів (GPR), де аномальним даним присвоюються нижчі ваги. Цей метод продемонстрував переваги порівняно з іншими техніками, орієнтованими на дані, завдяки кращій обробці зашумлених наборів.

Класифікація погодних умов: Класифікація погодних умов є ще одним ефективним методом попередньої обробки, який сприяє адаптації моделей до конкретних метеорологічних сценаріїв. Наприклад, штучні нейронні мережі використовувалися для класифікації типів погоди на 24 години наперед, а самонавчальні карти (SOM) застосовувалися для сегментації даних за погодними

умовами. Такий підхід дозволяє моделям краще адаптуватися до динамічних умов завдяки високій здатності ANN до навчання. У подібних дослідженнях виділялися чотири основні погодні категорії: ясна, дощова, туманна та хмарна. Це дозволило підвищити точність прогнозів для систем, підключених до електромережі, з акцентом на адаптацію до сезонних змін.

Інший підхід включає триетапну модель: класифікація погоди, навчання та прогнозування. На першому етапі SOM і методи векторного квантування використовуються для сегментації даних, на другому — SVR для навчання моделі, а на третьому — нечіткий висновок для вибору оптимальної навченої моделі. Така багатоетапна структура забезпечує вищу точність порівняно з простими ANN чи SVR, що підтверджує переваги комплексних підходів. Класифікація погоди дозволяє сегментувати дані для кращої адаптації моделей до специфічних умов, таких як різкі зміни хмарності чи сезонні коливання [3].

## 2.2 Етап II: Розробка та оцінка моделі

Другий етап дослідження охоплює питання створення моделі для прогнозування (модуль 3) та аналізу її точності (модуль 4), а також врахування кількісних показників невизначеності (модуль 5). Зокрема, в модулі 3 акцент робиться на передбаченні обсягів генерації сонячної енергії в певний момент часу, спираючись на актуальні метеорологічні дані. Це дає змогу враховувати динамічні зовнішні впливи для ефективнішого поєднання з енергетичною системою. Модель базується на парах історичних або прогнозованих метеоданих, які впливають на роботу фотовольтаїчної установки, та реальних показників виробленої енергії, що створює міцну емпіричну основу. Водночас не існує універсальної моделі, яка б ідеально передбачала генерацію під різними погодними умовами, тому вибір залежить від місцевих особливостей. Цей модуль також розглядає підбір однієї статистичної, машинного навчання чи глибокого навчання моделі (наприклад, штучних нейронних мереж) або ж комбінованих ансамблевих чи гібридних варіантів, що дозволяє об'єднувати переваги різних

методів для загального покращення точності. Однак навіть обрана модель, чи то проста, чи гібридна, може не бути ідеальною через неоптимальні внутрішні параметри (наприклад, ваги та зміщення) або структуру (кількість елементів в ансамблі). Це обмежує її застосування, особливо в режимі реального часу. Тому модуль 3 передбачає використання сучасних метаевристичних алгоритмів оптимізації, які допомагають налаштувати ці параметри та архітектуру, підвищуючи точність прогнозів за рахунок балансу з обчислювальною складністю, наприклад, зменшуючи навантаження на ресурси при обробці великих даних.

Після розробки та налаштування моделі її ефективність слід оцінити кількісно з погляду точності прогнозів, аби підтвердити практичну цінність. Для цього часто застосовують стандартні метрики, як-от середня абсолютна похибка чи середньоквадратична похибка. Але обмежуватися лише ними може бути недостатньо. Краще впроваджувати оцінки, орієнтовані на конкретне застосування, наприклад, розрахунок оптимальної точності моделі з урахуванням економічних аспектів фотовольтаїчної установки та її ключових завдань у плануванні. Таким чином, модуль 4 присвячено обговоренню цих метрик з акцентом на їх адаптацію до реальних умов, таких як інтеграція з системами управління енергопостачанням. Незалежно від обраної моделі та підходу до фінальних прогнозів потужності, на результати можуть впливати різні джерела невизначеності, що призводить до неточних чи навіть помилкових даних для керування мережею. Ці джерела пов'язані з (1) похибками вхідних даних моделі; (2) природною мінливістю фізичних процесів; та (3) власними обмеженнями моделі, що вимагає комплексного управління ризиками. На практиці оцінка невизначеності включає визначення нижніх і верхніх меж (інтервалів прогнозування) для очікуваних обсягів генерації, де справжнє значення має потрапити з заданим рівнем довіри. Модуль 5 фокусується на надійному розрахунку таких невизначеностей через аналіз різних методів, як-от дельта-метод, оцінка нижньої та верхньої меж, бутстреп чи оцінка середньої дисперсії. Після формування цих інтервалів важливо перевірити їхню якість за допомогою

показників, наприклад, ширини інтервалу чи ймовірності охоплення, аби надати операторам мережі достовірну інформацію про прогнозовану сонячну генерацію, наприклад, для планування резервних потужностей [4].

### 2.2.1 Модуль 3: Розробка моделі прогнозування

В останні десятиліття присвячено створенню точних моделей для прогнозування роботи фотовольтаїчних установок. Було запропоновано та реалізовано різні підходи для оцінки обсягів сонячної генерації, які загалом поділяються на дві категорії: фізичні моделі та моделі, засновані на даних. Фізичні моделі спираються на метеорологічні параметри для передбачення, тоді як моделі на основі даних використовують великі масиви історичної інформації про сонячну активність, застосовуючи методи машинного навчання для виявлення складних нелінійних взаємозв'язків без детального опису фізичних процесів.

Зважаючи на доступність значних обсягів історичних даних про сонячну генерацію, пріоритет варто надавати саме методам, орієнтованим на дані. Дослідники часто вдосконалюють наявні алгоритми машинного навчання, розробляють нові техніки для підвищення точності прогнозів сонячної енергії або комбінують кілька методів, де кожен виконує окрему роль у гібридній системі. Деякі з таких підходів порівнюють з базовими моделями, щоб продемонструвати їхні переваги в різних умовах.

Водночас універсального методу, який би забезпечував ідеальну точність, не існує. Застосування різних алгоритмів на одних і тих самих даних або навіть одного методу з різними параметрами може давати суттєво відмінні результати, що підкреслює важливість оптимізації для конкретних умов.

Для розв'язання цієї проблеми пропонуються ансамблеві методи, які об'єднують прогнози від кількох базових моделей за допомогою різних стратегій агрегації. Такі ансамблі зазвичай перевершують окремі моделі за точністю. Наприклад, метод опорних векторів був оптимізовано та успішно застосовано

для прогнозування потужності сонячної фотovoltaїчної системи в Німеччині, де поєднувалися дані про вимірювання потужності, чисельні прогнози погоди та оцінки хмарності. Ця модель показала високу точність і стабільність у реальних умовах, зокрема для великих сонячних ферм. Огляд недавніх ансамблевих підходів свідчить про їхню ефективність у підвищенні надійності прогнозів завдяки різноманітним методам об'єднання результатів.

Розробка моделей прогнозування, описаних у таблиці, часто супроводжується додатковими заходами для підвищення точності передбачень. Зокрема, для подолання технічних обмежень методів машинного навчання активно застосовуються метаевристичні алгоритми оптимізації. У контексті розподіленої генерації ці алгоритми допомагають особам, які приймають рішення, ефективніше управляти енергопостачанням, використовуючи, наприклад, моделі штучних нейронних мереж (ШНМ). Такі мережі будуються на алгоритмах навчання, які виявляють ключові зв'язки між вхідними та вихідними даними, імітуючи принципи роботи людського мозку. Одним із поширених методів оптимізації для ШНМ є зворотне поширення помилки, яке базується на градієнтному спуску. Проте цей підхід має недоліки, зокрема схильність до застрягання в локальних оптимумах і чутливість до початкових параметрів, що знижує його ефективність у динамічних умовах, таких як прогнозування сонячної генерації.

Без застосування алгоритмів оптимізації точність прогнозів ШНМ для сонячної енергії залишається обмеженою, а їхня продуктивність не досягає оптимального рівня. Для вирішення цієї проблеми замість зворотного поширення можна використовувати метаевристичні алгоритми для налаштування гіперпараметрів ШНМ. Хоча такі методи не гарантують знаходження ідеального рішення, вони здатні забезпечити якісні субоптимальні результати. Метаевристичні алгоритми знаходять широке застосування в різних галузях для вирішення складних завдань, підвищуючи продуктивність і точність моделей. Їхній попит зростає завдяки здатності адаптуватися до різноманітних умов.

Доступні алгоритми оптимізації можна поділити на кілька категорій: еволюційні (засновані на принципах природного відбору), зграйні (що імітують поведінку груп, як-от птахів чи соціальних систем), фізичні (що використовують закони фізики, наприклад, гравітацію чи концепцію мультивсесвіту), людські (що моделюють соціальні взаємодії, як-от процеси навчання), біологічні (засновані на поведінці живих організмів), системні (що відображають екосистеми чи імунні системи) та математичні (які використовують математичні функції, наприклад, тригонометричні). Вибір конкретного алгоритму залежить від особливостей завдання, що дозволяє оптимізувати моделі прогнозування сонячної енергії для конкретних умов [4].

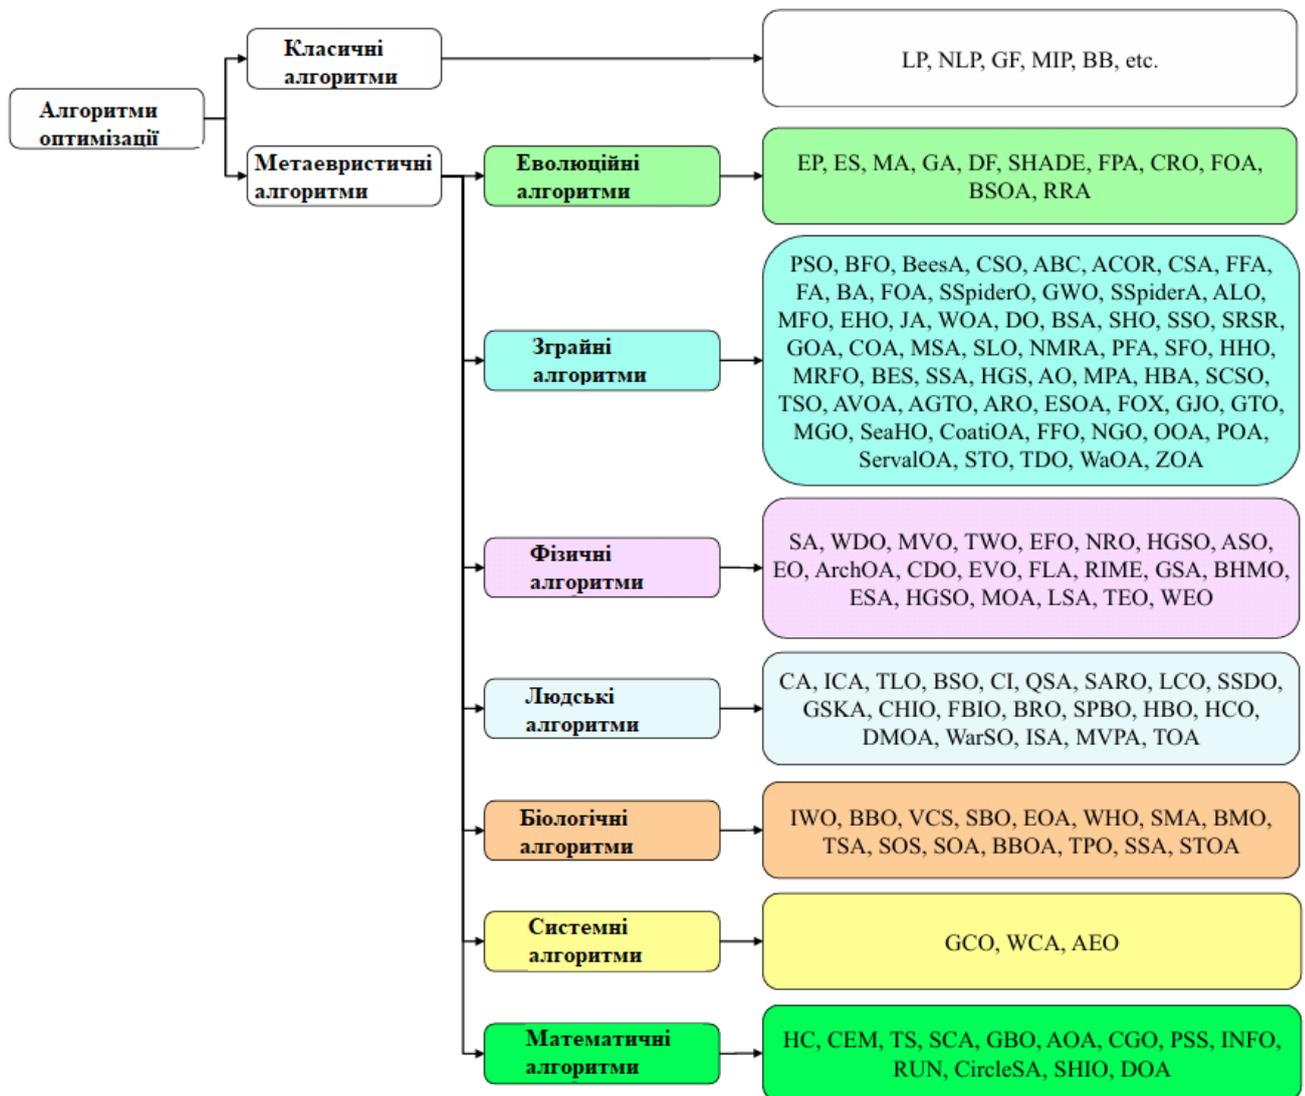


Рисунок 2.2 – Алгоритми оптимізації

Примітка: аббревіатури з рисунка 2.2 перелічені в Додатку Г.

Останні досягнення в алгоритмах оптимізації відкрили нові можливості для застосування методів машинного навчання, зокрема штучних нейронних мереж (ШНМ), у прогнозуванні потужності фотовольтаїчних систем. ШНМ є універсальним інструментом, який широко використовується для передбачення сонячної генерації. Проте ключову роль у підвищенні ефективності таких моделей відіграють метаевристичні алгоритми, які доповнюють традиційні методи, дозволяючи створювати потужніші гібридні моделі прогнозування.

Процес гібридного прогнозування зазвичай включає кілька етапів: отримання вхідних даних, проектування моделі, ініціалізацію її параметрів, навчання, тонке налаштування, визначення цільової функції (наприклад, мінімізації статистичної похибки), тестування та збереження прогнозованих значень потужності. Такий ітеративний підхід забезпечує поступове вдосконалення моделі.

У сучасних дослідженнях для прогнозування роботи фотовольтаїчних систем активно застосовуються як аналітичне, так і комп'ютерне моделювання. Однак ці методи часто потребують значних обчислювальних ресурсів і часу. Для подолання цих обмежень дедалі частіше використовуються метаевристичні алгоритми, які допомагають оптимізувати техніки машинного навчання. Огляд літератури показує, що гібридні моделі, які поєднують різні алгоритми оптимізації, демонструють високі результати в прогнозуванні сонячної потужності, а також мають практичну цінність для реальних застосувань.

Дослідження підтверджують, що метаевристичні алгоритми здатні ефективно вирішувати складні задачі, такі як передбачення генерації сонячної енергії. Однак більшість робіт зосереджені на використанні вже відомих методів, що створює певний дефіцит інноваційних підходів. Крім того, створення високоякісних оптимізацій потребує значного часу [4].

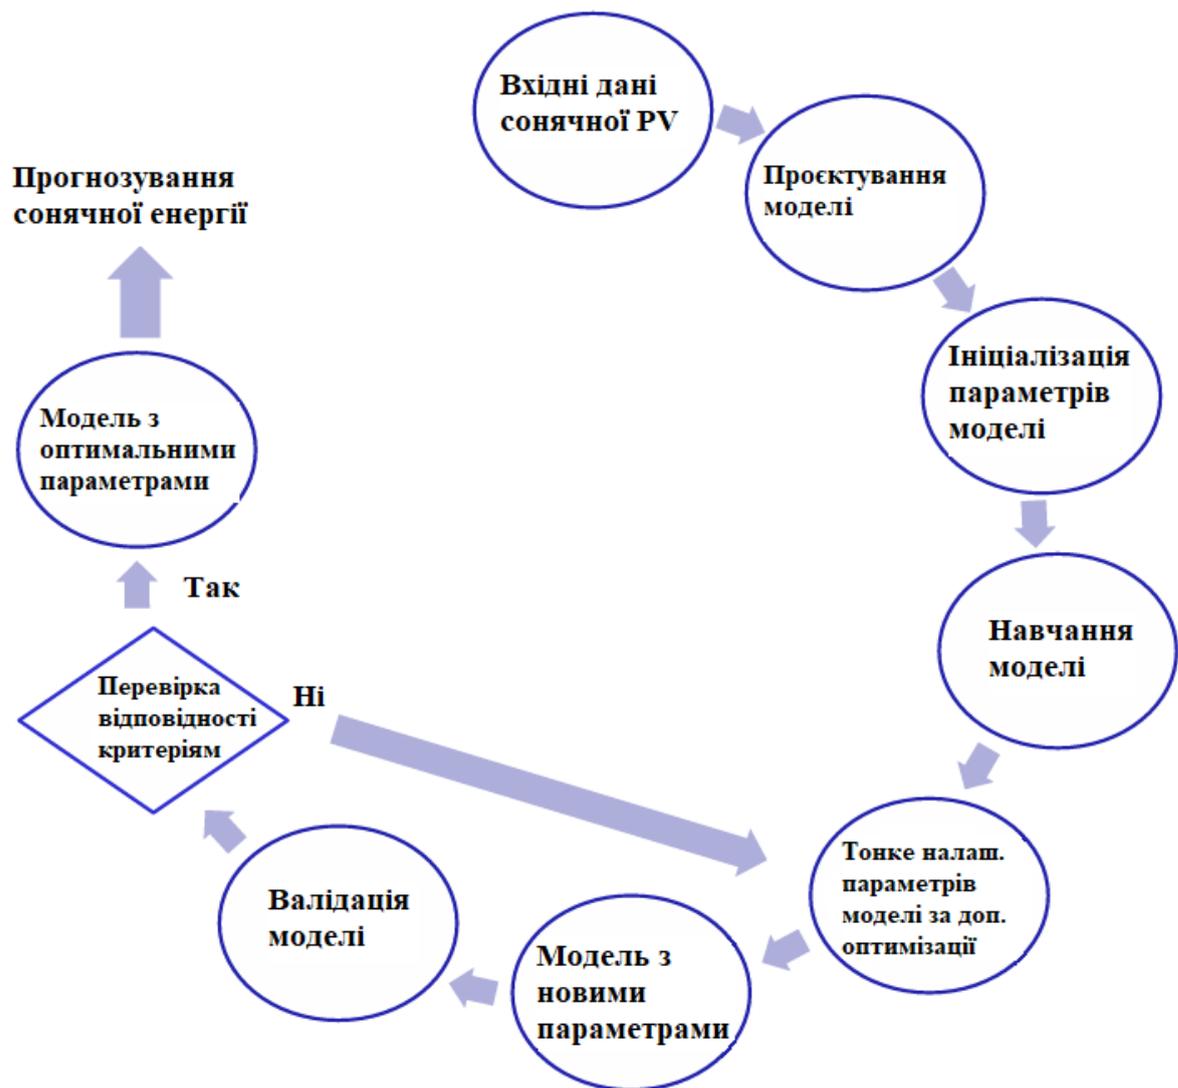


Рисунок 2.3 – Узагальнена блок-схема оптимізації алгоритму на основі прогнозування виробництва сонячної PV потужності

Останнім часом дослідники активно розробляли та впроваджували різноманітні метаевристичні алгоритми для вдосконалення прогнозування роботи фотовольтаїчних систем. Традиційно для таких систем використовуються методи аналітичного та комп'ютерного моделювання, які, однак, вимагають значних обчислювальних ресурсів і часу. Щоб подолати ці обмеження, зусилля вчених спрямувалися на застосування метаевристичних алгоритмів оптимізації, які дозволяють усунути технічні недоліки сучасних методів машинного навчання, застосованих до прогнозування.

Огляд літератури показує, що гібридні моделі, які інтегрують різні алгоритми оптимізації, ефективно підвищують точність прогнозів сонячної

генерації та мають значний потенціал для практичного використання. Ці моделі демонструють здатність вирішувати складні задачі, пов'язані з передбаченням потужності фотовольтаїчних установок. Проте більшість досліджень спираються на вже відомі методи, що обмежує появу нових підходів. До того ж створення високоякісних оптимізацій залишається часозатратним процесом [4].

### 2.2.2 Модуль 4: Оцінка продуктивності прогнозування

Модуль оцінки ефективності прогнозування зосереджений на аналізі розбіжностей між реальними обсягами виробництва сонячної енергії та прогнозами, отриманими за допомогою обраної моделі. Для цього розроблено низку метрик продуктивності, які дозволяють оцінити точність і надійність моделі в різних умовах. Ці метрики забезпечують стандартизований підхід до порівняння моделей, що сприяє об'єктивному оцінюванню їхньої ефективності.

Зокрема, у практиці застосовуються поширені статистичні метрики, які дають змогу кількісно оцінити похибки прогнозування. Ці метрики, разом із їхніми формулами та інтерпретацією для практичного використання. Вони допомагають не лише визначити точність моделі, а й адаптувати її до реальних сценаріїв експлуатації фотовольтаїчних систем.

Таблиця 2.2 – Метрики продуктивності, запропонованих для оцінки добротності побудованої моделі прогнозування виробництва сонячної PV потужності

Метрика	Формула	Використання	Діапазон	Інтерпретація
1	2	3	4	5
Е (Проста похибка)	$P - \hat{P}$	Вимірює розбіжність між фактичною та прогнозованою потужністю	$-\infty$ до $\infty$	<ul style="list-style-type: none"> <li>• Від'ємні значення: переоцінка</li> <li>• Додатні значення: недооцінка</li> <li>• Близько до нуля: висока</li> </ul>

Метрика	Формула	Використання	Діапазон	Інтерпретація
1	2	3	4	5
				точність моделі
<b>nE</b> (Нормалізована проста похибка)	$\frac{P - \hat{P}}{\max(\hat{P})}$	Вимірює розбіжність відносно максимального прогнозованого значення	$-\infty$ до $\infty$	Менші значення означають кращу якість прогнозу
<b>MAE</b> (Середня абсолютна похибка)	$\frac{\sum_{i=1}^N  P_i - \hat{P}_i }{N}$	Оцінює середнє абсолютне відхилення між фактичними та прогнозованими значеннями на «новому» наборі даних	0 до $\infty$	Малі значення вказують на доброту обраного режиму
<b>MBE</b> (Середня похибка зміщення)	$\frac{\sum_{i=1}^N (P_i - \hat{P}_i)}{N}$	Вона кількісно оцінює середню невідповідність між фактичною та передбаченою потужністю на тестовому наборі даних. Ця метрика цікава для оцінки того, чи передбачення в середньому занижені або завищені.	$-\infty$ до $\infty$	Значення, близькі до нуля, означають якість
<b>nMBE</b> (Нормалізована середня похибка зміщення)	$\frac{MBE}{\frac{1}{N} \sum_{i=1}^N P_i}$	Воно обчислює MBE, нормалізовану відповідно до фактичного значення потужності по всьому набору даних. Ця метрика цікава для оцінки упередженості прогнозу.	$-\infty$ до $\infty$	
<b>RMSE</b> (Середньоквадратична похибка)	$\sqrt{\frac{\sum_{i=1}^N (P_i - \hat{P}_i)^2}{N}}$	Вимірює середній квадрат розбіжності. Більш чутлива метрика, ніж MAE	0 до $\infty$	Менші значення — краща точність
<b>nRMSE</b> (Нормалізована середньоквадратична похибка)	$\frac{RMSE}{\frac{1}{N} \sum_{i=1}^N P_i}$	Нормалізує RMSE до середньої фактичної потужності		
<b>MAPE</b> (Середня абсолютна відносна похибка)	$\frac{100}{N} \sum_{i=1}^N \frac{ P_i - \hat{P}_i }{P_i}$	Вона обчислює середнє відхилення між фактичною та передбачуваною потужністю відносно фактичної протягом набору даних. Ця метрика є цікавою для оцінки рівномірності помилок прогнозування.	0 до 100%	Малі значення вказують на доброту обраного режиму

Метрика	Формула	Використання	Діапазон	Інтерпретація
1	2	3	4	5
<b>nMAPE</b> (Нормалізована MAPE)	$\frac{\sum_{i=1}^N  P_i - \hat{P}_i }{\sum_{i=1}^N P_i} \cdot 100\%$	Він обчислює MAPE, нормалізовану до загальної фактичної потужності сонячної електростанції за набором даних. Ця метрика є цікавою при порівнянні передбачуваності обраної моделі для різної потужності сонячних електростанцій.	0 до 100%	
<b>MdAPE</b> (Медіанна відносна похибка)	$\text{median} \left( 100\% \cdot \left  \frac{P_i - \hat{P}_i}{P_i} \right  \right)$ $i = 1, \dots, N$	Воно обчислює медіанне статистичне значення розбіжності між фактичною та прогнозованою потужністю відносно фактичних значень потужності в наборі даних.	0 до 100%	
<b>WMAE</b> (Зважена середня абсолютна похибка)	$\frac{\sum_{i=1}^N  P_i - \hat{P}_i }{\sum_{i=1}^N P_i}$ $nMAPE / 100$	Воно обчислює середнє відхилення між фактичною та прогнозованою потужністю відносно загальних значень реальної потужності у наборі даних. По суті, це схоже на nMAPE, але без обчислення відсотків. Використовується при порівнянні передбачуваності обраної моделі для різних потужностей сонячних електростанцій.	0 до $\infty$	Малі значення вказують на доброту обраної моделі
<b>R<sup>2</sup></b> (Коефіцієнт детермінації)	$\left[ 1 - \frac{\sum_{i=1}^N (P_i - \hat{P}_i)^2}{\sum_{i=1}^N (P_i - \bar{P})^2} \right] \cdot 100$	Він обчислює кореляцію між фактичною та передбачуваною потужністю. Він описує змінність передбачуваної потужності (залежної), яку забезпечує модель і яка спричинена її вхідними даними (незалежними).	0 до 100%	Великі значення означають високу якість моделі

### Примітка:

Примітка: E - Проста Похибка; nE - Нормалізована Проста Похибка; MAE - Середня Абсолютна Похибка; MBE - Середня Зміщена Похибка; nMBE - Нормалізована MBE; RMSE - Корінь Середньої Квадратичної Похибка; nRMSE - Нормалізована RMSE; MAPE - Середня Абсолютна Відсоткова Похибка; nMAPE - Нормалізована MAPE; MdAPE - Медіанна Абсолютна Відсоткова Похибка; WMAE - Зважена MAE; R<sup>2</sup> - Коефіцієнт Детермінації; P<sub>i</sub> та  $\hat{P}_i$  - фактична та

прогнозована потужність, відповідно;  $N$  - загальна кількість тестових даних;  $\bar{P}_i$  - середня фактична потужність.

Для оцінки ефективності запропонованої схеми прогнозування дослідники порівнюють її передбачувальну здатність із базовими моделями, обчислюючи приріст продуктивності для кожної використаної метрики. Цей показник, відомий як оцінка навички, відображає відсоткове покращення продуктивності запропонованої моделі порівняно з базовою. Позитивні значення свідчать про перевагу нової моделі, тоді як від'ємні вказують на її нижчу ефективність. Такий підхід дозволяє кількісно оцінити ступінь покращення, що сприяє обґрунтованому вибору моделі для практичного застосування.

$$PG_{Metric} = \left( 1 - \frac{Metric^{Proposed}}{Metric^{Benchmark}} \right) \cdot 100\% ; \quad (2.1)$$

Для оцінки стабільності прогнозів, отриманих за допомогою запропонованих моделей, дослідники аналізують їхню мінливість, наприклад, обчислюючи стандартне відхилення метрик продуктивності на основі численних симуляцій або крос-валідації. Такий підхід дозволяє оцінити стійкість моделі до різних джерел похибок, таких як невизначеність самої моделі чи відмінності в наборах даних, використаних для її навчання, забезпечуючи надійність прогнозів у динамічних умовах [4].

Крім того, значні зусилля спрямовуються на розробку або обґрунтування необхідності стійких метрик продуктивності, які враховують економічні та планувальні аспекти роботи фотовольтаїчних установок. Наприклад, висока точність прогнозування забезпечує більшу впевненість у стабільності виробництва енергії, що зменшує потребу в додаткових операційних резервах для компенсації коливань. Зниження витрат на ці резерви, які необхідні для управління варіабельністю генерації, є ефективною метрикою для оцінки економічної вигоди від підвищення точності прогнозів. Це особливо важливо для великих фотовольтаїчних систем, де операційні витрати можуть бути значними.

### 2.2.3 Модуль 5: Кількісна оцінка невизначеності

Незалежно від методів вибору метеорологічних параметрів, попередньої обробки даних чи типу моделі прогнозування (індивідуальна, гібридна чи ансамблева), прогнози виробництва сонячної енергії завжди супроводжуються невизначеністю. Ці невизначеності можуть призводити до неточних або навіть оманливих даних для операторів енергомереж, ускладнюючи управління системою. Основними джерелами таких невизначеностей є:

1) Похибки у вхідних даних, які використовуються для створення моделі прогнозування, наприклад, помилки вимірювань або прогнозів метеорологічних змінних, а також обмежена чи нерівномірна доступність історичних даних про погодні умови та відповідну генерацію енергії. Ці проблеми зазвичай вирішуються модулями збору та обробки даних.

2) Природна мінливість фізичних процесів, пов'язаних із роботою фотовольтаїчних установок, яка залежить від метеорологічних умов і потребує врахування стохастичних факторів для підвищення точності моделі.

3) Внутрішня невизначеність самої моделі, обумовлена її конфігурацією та архітектурою, зокрема внутрішніми параметрами та гіперпараметрами (наприклад, у штучних нейронних мережах, мережах із крайовим навчанням чи мережах із відлунням стану), що вимагає оптимізації для зменшення цих невизначеностей.

Таким чином, управління невизначеністю є критично важливим для прогнозування роботи фотовольтаїчних систем. Окрім точкових оцінок виробництва, значна увага приділяється створенню інтервалів прогнозування (PIs), які визначають нижні та верхні межі очікуваної генерації з певним рівнем довіри, наприклад, 90%. Це дозволяє операторам мережі не лише мати точкову оцінку, а й враховувати діапазон можливих значень для планування резервів із урахуванням ризиків. Для цього застосовуються різні методи кількісної оцінки невизначеності, такі як бутстреп, дельта-метод, оцінка середньої дисперсії, метод

нижньої та верхньої меж чи оцінка щільності ядра. Ці підходи успішно використовуються в інженерних задачах і адаптовані для прогнозування сонячної генерації, що забезпечує їхню практичну цінність.

Таблиця 2.3 – Дослідження кількісної оцінки невизначеності технік, пов'язаних з прогнозуванням виробництва сонячної PV потужності.

Метод	Техніка кількісної оцінки невизначеності
Kriging model	Запропоновано новий чотириетапний підхід до кількісної оцінки невизначеності прогнозування сонячної енергії у Віртуальній електростанції (VPP). Підхід поєднує модель «чистого неба» та нормалізовану сонячну іррадіацію, гаусівські змішані моделі (GMM) для класифікації даних, алгоритм K-nn разом із General Pattern Search (GPS) для віднесення нових даних до класів, а також модель Kriging для побудови інтервалів прогнозування (PI).
BS	Запропоновано новий двоетапний підхід для оцінки інтервалів прогнозування короткострокової сонячної енергії. Досліджено два джерела невизначеності: шум у даних та невизначеність моделі. Метод ґрунтується на Bootstrap (BS) для оцінки невизначеності моделі та гібридному ELM у поєднанні з Improved Differential Evolution (IDE) для врахування шуму даних.
Некласичний KDE (NKDE)	Запропоновано дворівневий підхід для кількісної оцінки невизначеності у короткострокових прогнозах сонячної енергії, отриманих за допомогою гібридної NN-моделі на основі генетичних алгоритмів. Використано некласичну оцінку щільності ядра (NKDE).
BS і Quantile Regression (QR)	Запропоновано імовірнісні підходи (прямий і непрямий) з використанням BS і регресії за квантилями для оцінки джерел невизначеності у прогнозах, побудованих комбінацією WT (фільтрація даних), RBFNN (нейронна мережа для прогнозування) та PSO (оптимізація параметрів).
BS, MVE та KDE	Запропоновано комплексний ансамблевий підхід із використанням оптимізованих та різномірних ANN для прогнозу на добу вперед. Для кількісної оцінки трьох джерел невизначеності у вигляді PI застосовано Bootstrap. BS було порівняно з двома іншими методами: оцінкою середнього та дисперсії (MVE) і оцінкою щільності ядра (KDE).
BS	Запропоновано метод довірчих інтервалів на основі Bootstrap (CIs) для оцінки невизначеності прогнозів сонячної енергії, отриманих за допомогою LSTM.
Wavelet Packet (WP)	Запропоновано метод для точного короткострокового прогнозу сонячної енергії з побудовою PI. Поєднано Wavelet Packet (WP) і LS-SVM для покращення точкових оцінок. Функція змішаної похибки була використана для підгонки розподілу похибок і побудови PI.

**Примітка:**

BS — Bootstrap; KDE — Kernel Density Estimation; NKDE — Некласична KDE;

MVE — Mean-Variance Estimation; QR — Quantile Regression; PI — Prediction Intervals.

Після формування інтервалів прогнозування (PIs) дослідники зосередилися на оцінці їхньої надійності та якості. Для цього було розроблено та успішно застосовано різні метрики продуктивності. Зокрема, використовуються такі показники, як ймовірність покриття інтервалу (PICP) та ширина інтервалу (PIW). Перший показник визначає частку фактичних значень виробництва сонячної енергії, які потрапляють у межі розрахованих PIs для заданого рівня довіри, наприклад, 80%. Другий показник відображає середню ширину цих інтервалів, що дозволяє оцінити їхню компактність. Ці метрики знайшли широке застосування в інженерних задачах, зокрема для оцінки залишкового терміну служби обладнання. Огляд демонструє перелік таких метрик із детальним описом їхнього практичного використання для забезпечення надійності прогнозів [4].

Таблиця 2.4 – Дослідження метрик продуктивності PIs, прийнятих для оцінки добротності побудованої PIs, пов'язаної з прогнозуванням виробництва сонячної PV потужності

Метод	Метрика продуктивності PI
PI Width (PIW)	Було розглянуто різні заздалегідь визначені рівні довіри (10–90%) та проаналізовано ширину побудованих інтервалів прогнозування.
Розподіл похибок	Проаналізовано розподіл похибок, інтервали прогнозування, а також пере- та недооцінку прогнозів у різних класах погоди (наприклад, ясна та хмарна).
PI Coverage Probability (PICP) та Mean PI Width (MPIW)	Було розглянуто три рівні довіри (90%, 95% та 99%). Для оцінки надійності побудованих PI застосовано метрики PICP та середню ширину PI (MPIW).
PICP	Було досліджено чотири рівні довіри (80%, 85%, 90% та 95%). Для оцінки ефективності PI застосовано лише PICP.
PICP та PIW	Використано заздалегідь визначений рівень довіри 80%. Для оцінки якості PI застосовано дві метрики: PICP та PIW.
Розподіл похибок	Було досліджено чотири рівні довіри (80%, 85%, 90% та 95%). Функцію розподілу похибок проаналізовано статистично, наприклад, через розрахунок процентилів.

Метод	Метрика продуктивності PI
PICP та PIW	Було досліджено три рівні довіри (80%, 90% та 95%). Для оцінки PI застосовано PICP та PIW (нормалізований середній показник).

Примітки:

- PICP — ймовірність покриття інтервалу прогнозування (частка фактичних значень, що потрапили в PI).
- PIW — ширина інтервалу прогнозування.
- MPIW — середня ширина PI.

### 2.3 Етап III: Передові вдосконалення

Третій етап дослідження зосереджений на підвищенні точності прогнозування шляхом інтеграції механізмів виявлення змін контексту (модуль 6) та інкрементального навчання (модуль 7) для адаптації до нових даних. У реальних умовах середовище, в якому функціонують фотовольтаїчні установки, постійно змінюється, що може знижувати ефективність прогнозних моделей. Наприклад, аномальні погодні явища, такі як сильні опади, можуть суттєво впливати на роботу установок. Модуль 6 спрямований на виявлення таких змін у середовищі та автоматичне оновлення моделі прогнозування для адаптації до нових умов без необхідності повного перенавчання. Основна проблема використання прогнозних моделей у динамічних середовищах полягає в тому, що вони створюються на основі даних, зібраних у певних умовах, які можуть не відображати майбутні сценарії. Це може призводити до зниження точності прогнозів у нових умовах. Для вирішення цього виклику застосовується підхід, відомий як "навчання в еволюціонуючих середовищах", який передбачає виявлення змін і адаптивне оновлення моделі.

Крім того, фотовольтаїчні установки постійно генерують нові дані, які містять цінну інформацію для вдосконалення моделей. Модуль 7 фокусується на використанні цих даних для оновлення моделей без значного зростання обчислювальної складності. Один із традиційних підходів — відкидання старої моделі та її перенавчання з урахуванням усіх даних, включно з новими. Проте це

вимагає значних обчислювальних ресурсів і може призвести до втрати раніше отриманих знань, відомої як "катастрофічне забуття". До того ж, із швидким накопиченням даних їхній обсяг може стати надто великим для ефективного перенавчання. Для уникнення цих проблем застосовується інкрементальне навчання, яке дозволяє оновлювати модель, додаючи нові знання без доступу до старих даних і зберігаючи попередньо отриману інформацію. Такий підхід є ефективним для обробки поточкових даних у реальному часі, забезпечуючи безперервне вдосконалення моделі.

### 2.3.1 Модуль 6: Виявлення змін контексту

Важливим аспектом, який необхідно враховувати, є динамічна природа середовища, в якому функціонують фотовольтаїчні установки. Зміни в контексті, такі як аномальні погодні умови (екстремальна спека, сильні опади, потужні пориви вітру тощо), можуть негативно впливати на ефективність прогнозних моделей. Для своєчасної адаптації до таких змін потрібен постійний моніторинг умов експлуатації.

Раніше дослідники зосереджувалися на розробці окремих моделей прогнозування, кожна з яких навчалася та оптимізувалася для специфічних погодних умов, таких як різні сезони (зима, весна, літо, осінь) або стани неба (ясно, хмарно, дощ тощо). Наприклад, один із підходів передбачав класифікацію погодних умов на основі місцевих даних (хмарно, туманно, сонячно, дощово) з використанням аналізу кореляції. Для кожної категорії створювалася окрема модель на основі методу опорних векторів (SVM), а для прогнозу на наступний день обиралася відповідна модель залежно від прогнозованих погодних умов. Це дозволяло підвищити адаптивність прогнозів до змін у середовищі. В іншому дослідженні була запропонована модель, яка поєднувала багат шаровий перцептрон із алгоритмом колонії бджіл (MLP-ABC) для прогнозування генерації установки потужністю 3,2 кВт. Дані поділялися на сонячні та хмарні дні, що

сприяло підвищенню точності прогнозів порівняно з моделлю, навченої на змішаних даних.

Такі зусилля демонструють важливість урахування змін контексту, однак розробка універсальної моделі, яка б ефективно адаптувалася до всіх можливих умов, залишається актуальним завданням. Наприклад, у сфері прогнозування енергії вітру було запропоновано метод виявлення концептуального зсуву з використанням онлайн-послідовних граничних навчальних машин (OS-ELM). Цей підхід показав переваги над традиційними статистичними методами, дозволяючи оновлювати модель у разі виявлення змін у середовищі. Застосування подібного підходу до прогнозування сонячної генерації, особливо в регіонах із високою кліматичною мінливістю, може бути перспективним напрямом для подальших досліджень [4].

### 2.3.2 Модуль 7: Інкрементальне навчання

Ще одним важливим аспектом при розробці моделей прогнозування є частота їх оновлення. Фотовольтаїчні установки постійно генерують нові дані, які містять цінну інформацію для вдосконалення моделей і підвищення їхньої точності. Ці дані дозволяють адаптувати модель до змін без значного зростання обчислювальної складності, що робить інкрементальне навчання (IL) ефективним інструментом для роботи з потоковими даними.

На практиці зібрати всі релевантні дані на етапі навчання моделі надзвичайно складно, а іноді й неможливо, оскільки не всі режими роботи установки можна передбачити чи відтворити заздалегідь. Інкрементальне навчання вирішує цю проблему, дозволяючи оновлювати модель новими даними, зберігаючи раніше отримані знання та уникаючи "катастрофічного забуття". Такий підхід забезпечує поступове вдосконалення моделі без необхідності повного перенавчання, що сприяє підвищенню точності прогнозів.

Наприклад, у дослідженнях, присвячених прогнозуванню енергії вітру, було показано, що оновлення моделі після виявлення концептуального зсуву

покращує її точність при мінімальній кількості оновлень, що знижує обчислювальну складність. Подібний підхід може бути ефективним і для прогнозування сонячної генерації. Концепція інкрементального навчання успішно застосовується в інших галузях, таких як прогнозування сонячного випромінювання, енергії вітру, виявлення несправностей та діагностика в атомних електростанціях, що підтверджує її універсальність.

Однак для прогнозування виробництва сонячної енергії ця проблема залишається недостатньо дослідженою. Огляд літератури показує обмежену кількість робіт, присвячених інкрементальному навчанню в цьому контексті, що відкриває перспективи для подальших розробок.

Таблиця 2.5 – Дослідження технік інкрементального навчання, запропонованих для покращення точності прогнозування виробництва сонячної PV потужності.

Техніка	Техніка інкрементального навчання
1	2
OS-ELM	Розроблено <b>Online Sequential Extreme Learning Machine (OS-ELM)</b> для короткострокового прогнозування сонячної потужності. Запропоновано алгоритм відбору ознак Relief-F для підвищення точності. Тестування показало покращення точності порівняно з традиційним ELM.
eNFN	Запропоновано <b>evolving Neuro-Fuzzy Network (eNFN)</b> , здатну до адаптивного навчання в режимі онлайн. Мережа автоматично оновлює свою структуру та параметри з появою нових даних, що забезпечує поступове зменшення похибки прогнозу.
ELM + Kalman Filter	Використано <b>Extreme Learning Machine (ELM)</b> у поєднанні з <b>фільтром Калмана</b> для інкрементального прогнозування. Підхід дозволяє враховувати змінні умови навколишнього середовища, знижуючи похибку моделі.
OS-ELM + RLS	Об'єднано <b>OS-ELM</b> із <b>Recursive Least Squares (RLS)</b> , що дало можливість поступового оновлення параметрів моделі у реальному часі. Це зменшило похибку та покращило стабільність прогнозу.
Incremental SVM	Розроблено інкрементальний алгоритм для <b>Support Vector Machine (SVM)</b> , що дозволяє адаптувати модель без повного перенавчання. Метод ефективний для потокових даних і значно скорочує обчислювальні витрати.
Online GPR	Запропоновано метод <b>онлайн-Гаусового процесу регресії (GPR)</b> для прогнозування сонячної генерації. Алгоритм дозволяє покроково оновлювати параметри ядра, забезпечуючи високу точність навіть у динамічних умовах.
ILRNN	Розроблено <b>Incremental Learning Recurrent Neural Network (ILRNN)</b> для прогнозування сонячної енергії в умовах мінливої погоди. Модель здатна поступово підлаштовувати ваги RNN, підвищуючи точність прогнозу.

Техніка	Техніка інкрементального навчання
1	2
Adaptive OS-ELM	Вдосконалено алгоритм <b>OS-ELM</b> шляхом додавання адаптивного механізму оновлення вагових коефіцієнтів. Це дозволяє ефективно обробляти нові дані та зменшувати похибку моделі з часом.
eGNN	Запропоновано <b>evolving Graph Neural Network (eGNN)</b> для прогнозування виробництва сонячної енергії. Мережа оновлює свою топологію в процесі роботи та зберігає високу точність навіть у разі різких змін погодних умов.

### Примітки:

- OS-ELM — Online Sequential Extreme Learning Machine.
- eNFN — evolving Neuro-Fuzzy Network.
- RLS — Recursive Least Squares.
- SVM — Support Vector Machine.
- GPR — Gaussian Process Regression.
- ILRNN — Incremental Learning Recurrent Neural Network.
- eGNN — evolving Graph Neural Network.

## 2.4 Підсумок внесків та модулів

Цей огляд представляє інноваційну та комплексну методологію для прогнозування виробництва сонячної енергії, яка відповідає потребам управління переривчастим і стохастичним характером відновлюваних джерел енергії. Запропонована структура базується на триетапному підході, що включає сім модулів, кожен із яких охоплює ключові аспекти прогнозування.

Перший етап зосереджується на підготовці даних, включаючи їх збір і обробку, щоб забезпечити доступність точної та релевантної інформації для моделі прогнозування. Другий етап присвячений розробці моделі, її оцінці та аналізу невизначеностей, застосовуючи методи для визначення точності прогнозів. Третій етап спрямований на підвищення точності шляхом інтеграції механізмів виявлення змін контексту та інкрементального навчання, що дозволяє моделі адаптуватися до нових даних і змінних умов, забезпечуючи її гнучкість для практичного використання [4].

Для узагальнення проведено порівняння охоплення модулів у попередніх оглядових статтях про прогнозування сонячної генерації за період із 2018 по 2024 роки. Це дозволяє виділити нові модулі, які можуть сприяти подальшому вдосконаленню передбачуваності виробництва сонячної енергії.

#### Висновки до другого розділу

Останніми роками прогнозування сонячної потужності зазнало значного прогресу завдяки розробці різноманітних моделей і методологій. Модельні підходи та методи, орієнтовані на дані, суттєво підвищили точність передбачень для фотовольтаїчних систем. Завдяки доступності великих обсягів історичних даних техніки машинного навчання стали основою для орієнтованих на дані методів, що забезпечило кращу інтеграцію з енергосистемами. Використання ансамблевих моделей і метаевристичних алгоритмів оптимізації дозволило подолати такі проблеми, як локальні оптимуми та адаптація до змінних умов, що сприяло створенню більш надійних прогнозів.

### 3 МЕТОД КОРОТКОСТРОКОВОГО ПРОГНОЗУВАННЯ ГЕНЕРАЦІЇ НА ОСНОВІ ГІБРИДНОЇ МОДЕЛІ TCN-ESANET-GRU

Фотовольтаїчна генерація, як один із видів чистої енергії, набуває все більшої популярності завдяки своїм перевагам, таким як безпека, широка доступність, достатність ресурсів та потенційна економічна вигода. Однак фотовольтаїчна генерація схильна до перервної та нестабільної виробітки через вплив факторів, таких як кліматичні особливості та чергування дня і ночі, що ускладнює узгодження попиту та пропозиції в мережі та створює певні виклики для диспетчеризації енергосистеми. Тому короткострокове прогнозування потужності фотовольтаїчних систем сприяє своєчасній координації енергосистеми, зменшує вплив коливань потужності фотовольтаїчних установок на мережу та забезпечує основу для стабільного балансу попиту та пропозиції електроенергії. Наприклад, у регіонах з високою часткою сонячної енергії, таких як Австралія, точне прогнозування дозволяє оптимізувати інтеграцію відновлюваних джерел, зменшуючи залежність від викопних палив [5].

На сьогодні методи прогнозування генерації фотовольтаїчних систем можна умовно поділити на статистичні методи, класичні методи машинного навчання та методи глибокого навчання. Статистичні методи включають лінійну регресію, аналіз часових рядів ARMA та модель ланцюга Маркова. Хоча статистичні методи мають високу інтерпретованість, їхня модель стає складною при врахуванні багатьох впливових факторів, що не сприяє практичному прогнозуванню та часто призводить до значних похибок при обробці раптових змін потужності фотовольтаїчних систем. Методи машинного навчання охоплюють імовірнісну нейронну мережу (PNN) для поділу підмножин різних типів погоди, аналіз головних компонент (PCA) для зменшення розмірності та регресію на основі векторів підтримки (SVR), оптимізовану алгоритмом розсіяного пошуку (SS), для прогнозування короткострокової вихідної потужності фотовольтаїчних систем, як запропоновано Ванг Сіном та іншими. Сонг та інші запропонували комбіновану модель прогнозування, що складається

з кількох регресійних дерев, яка демонструє добру продуктивність порівняно з різними класичними методами. Ванг та інші використовували дерево рішень з градієнтним бустингом (GBDT) для навчання на історичних метеорологічних даних та даних про генерацію, і отримані моделі мали переваги сильної інтерпретовності та стабільної продуктивності похибок. Масауді М та інші виконали вибірку ознак на основі байєсівської гребеневої регресії (BRR), розклали дані ознак за допомогою безперервного вейвлет-перетворення (CWT) і нарешті прогнозували генерацію фотовольтаїчних систем через алгоритм CatBoost. CatBoost добре справляється з обробкою категоріальних ознак, а модель показала кращі результати за коефіцієнтом детермінації та фактичною похибкою. Класичні методи машинного навчання часто вимагають ручного вилучення ознак для досягнення добрих результатів на початковому етапі, але важко забезпечити універсальність такої вибірки ознак при вирішенні складних задач. Махмуд та інші спробували надати та порівняти продуктивність різних алгоритмів машинного навчання у короткостроковому прогнозуванні генерації потужності фотовольтаїчних систем та довгостроковому прогнозуванні. Мас'уд порівняв продуктивність KNN, MLR та регресії дерева рішень (DTR) у прогнозуванні погодинної вихідної потужності фотовольтаїчних систем у Саудівській Аравії та дійшов висновку, що KNN є найкращим. Ці приклади ілюструють перехід від простих статистичних інструментів до більш адаптивних методів, що враховують нелінійності даних [5].

Методи глибокого навчання, застосовані для прогнозування генерації фотовольтаїчних систем, включають BP, LSTM, GRU та нейронні мережі Елмана. Чжан та інші використовували тришарову нейронну мережу BP для навчання на історичних даних, і прогнози моделі виявилися високоточними. Чжан та інші класифікували набір даних за типами днів і побудували нейронну мережу Елмана для прогнозування генерації фотовольтаїчних систем. Модель має швидшу швидкість обчислень та вищу точність прогнозування, ніж FNN. У 2015 році інші ввели історичні дані про генерацію, інтенсивність сонячного випромінювання та температуру в мережу нечіткої радіальної базисної функції (RBF), оптимізовану

генетичним алгоритмом (GA), для прогнозування генерації. Хоссейн та Махмуд в основному обговорювали вплив різних довжин вхідних послідовностей на продуктивність однокрокових моделей прогнозування. Враховуючи характеристики швидкості вітру, температури модулів, навколишнього середовища та сонячного випромінювання, Ахтер та інші побудували модель RNN-LSTM для прогнозування генерації фотовольтаїчних систем на наступну годину, використовуючи дані з трьох різних фотовольтаїчних станцій з часовою роздільною здатністю 5 хвилин. Лі та інші поєднали декомпозицію вейвлет-пакетів (WPD) для розкладання фотогальванічних послідовностей на кілька стабільних підпослідовностей; згодом послідовності вводилися в LSTM для паралельного прогнозування; відповідні виходи лінійно зважувалися для отримання остаточних прогнозованих значень; цей підхід перевершив методи MLP та RNN за метриками MBE, MAPE та RMSE. Бі та інші запропонували модель PCNN-BiLSTM на основі CEEMDAN, SSD та VMD як модель прогнозування потужності фотовольтаїчних систем; крім того, розкладені підпослідовності вводилися в паралельні згорткові мережі та BiLSTM для вивчення ознак; цей метод зрештою призвів до покращеної продуктивності прогнозування. Ян та інші використовували декомпозицію в частотній області та CNN для вилучення ознак та прогнозів, і експерименти довели, що порівняно з RNN та LSTM, CNN мають значну перевагу в термінах часової ефективності. Чжоу та інші ввели декомпозицію сигналу CEEMDAN та багатоцільовий алгоритм рою хамелеонів для оптимізації різних методів глибокого навчання та дослідження продуктивності кількох методів на різних наборах даних фотовольтаїчних систем. Чжоу та інші вводили окремі LSTM для метеорологічних та фотовольтаїчних даних для прогнозування та призначали різні ваги даним на різних часових кроках через механізм уваги для адаптивного фокусування на важливій інформації; згодом виходи оброблялися шаром згладжування та комбінувалися для отримання прогнозованих значень. Модель поведилася стабільно порівняно з моделями ARIMAX та класичним LSTM для різних сезонів та часових кроків. Ці розробки підкреслюють еволюцію від

базових мереж до складніших архітектур, що краще справляються з часовими залежностями в енергетичних даних [5].

Останніми роками через складність часових рядів та обмеження окремих моделей гібридні моделі, що поєднують згорткові нейронні мережі (CNN) та рекурентні нейронні мережі, такі як CNN-LSTM, LSTM-CNN та CNN-GRU, набули широкого поширення; усі ці моделі мають добрі можливості для прогнозування потужності фотовольтаїчних систем, де CNN використовується переважно для вилучення ознак усіх атрибутів, а LSTM та GRU — для обробки ознак для прогнозування. Однак звичайні згорткові мережі вимагають глибших шарів при захопленні інформації за довгі періоди через постійний розмір згорткового ядра, що часто спричиняє проблеми, такі як зникнення градієнта, і може безпосередньо впливати на результати прогнозування. Тому Бай та інші запропонували часову згорткову мережу (TCN) у 2017 році. TCN можуть обробляти кілька часових рядів інформації паралельно та зменшувати споживання обчислювальних ресурсів порівняно з CNN та рекурентними нейронними мережами. Наприклад, у задачах прогнозування енергії TCN дозволяють ефективніше інтегрувати метеорологічні змінні, такі як вітер та опади, з історичними даними генерації.

У цьому розділі TCN використовується для вилучення часової та кореляційної інформації ознак. Хоча TCN сама по собі має великий рецептивний поле, вона все ще обмежена розміром свого згорткового ядра, і механізм ефективної уваги до каналів (ECANet) інтегрується для покращення продуктивності TCN. На цій основі запропоновано гібридну модель TCN-ECANet-GRU, яка вивчає просторові ознаки кількох історичних метеорологічних змінних та послідовностей потужності фотовольтаїчних систем через покращений модуль TCN з ECANet. Потім GRU вилучає послідовність часових ознак та встановлює зв'язок між ознаками та виходами для прогнозування потужності фотовольтаїчних систем. Отже, можна підсумувати так:

1. Запропоновано TCN-ECANet-GRU як новітній метод для прогнозування короткострокових значень потужності фотовольтаїчних систем.

Цей підхід є відносно новим у галузі та може застосовуватися для інших задач прогнозування часових рядів, наприклад, у прогнозуванні навантаження енергосистем або трафіку [5].

2. Запропонована модель TCN-ECANet-GRU використовує часову згорткову мережу для вивчення просторових ознак з кількох часових рядів, щоб захоплювати часові та просторові ознаки; на цій основі ECANet застосовується для покращення продуктивності TCN, розширюючи рецептивне поле TCN для кращого захоплення ознак та прогнозування.

3. Продуктивність запропонованого методу TCN-ECANet-GRU в термінах однокрокового прогнозування та багатоступеневого прогнозування демонструється на основі аналізу реального набору даних про генерацію потужності фотовольтаїчних систем, де RMSE, MAE та  $R^2$  використовуються як метрики оцінки.

Часова згорткова нейронна мережа (TCN) є структурою нейронної мережі, що складається з розширеного причинного згорткового шару в поєднанні з залишковими з'єднаннями та переважно використовується для моделювання часових рядів. Розширений причинний згортка відрізняється від звичайного згортка тим, що "розширений" означає дозвіл на інтервальний відбір вхідних даних під час згортки. Коефіцієнт відбору  $d$  зазвичай зростає експоненційно з кількістю шарів; наприклад,  $d = 1$  означає відбір кожного пункту даних, а  $d = 2$  — відбір одного пункту даних кожні 2 пункти. Розширений причинний згортка також запобігає витоку даних, де "причинний" означає, що поточний момент пов'язаний лише з поточним та минулими станами і не містить інформації про майбутні послідовності. Структура розширеного причинного згортка TCN дозволяє їй мати більший рецептивний поле, ніж CNN, з меншою кількістю шарів та параметрів, полегшуючи прийом та обробку довгих множин послідовностей інформації. TCN зазвичай формуються шляхом накладання кількох залишкових блоків, кожен з яких містить два шари розширеного причинного згортка, нормалізацію ваг, функцію активації ReLU та dropout, а також вводить залишкові з'єднання для прямого відображення входів.

Механізми уваги до каналів для згорткових блоків можуть покращувати продуктивність згортки. Модуль ефективної уваги до каналів (ECANet) уникає побічних ефектів уваги до каналів, спричинених зменшенням розмірності входу, та зменшує обчислювальну складність захоплення всіх залежностей каналів порівняно з модулем SENet. Він відповідним чином захоплює локальну взаємодію міжканальної інформації з  $k$  каналами, близькими до поточного каналу, та адаптивно обчислює та коригує розмір  $k$ . Формула обчислення  $k$  наведена в рівнянні 3.1:

$$k = \left\lfloor \frac{\log_2(c)}{\gamma} + \frac{b}{\gamma} \right\rfloor_{\text{odd}} . \quad (3.1)$$

де  $\text{odd}$  — найближче непарне число,

$c$  — поточна кількість каналів,

$\gamma = 2$ ,

$b = 1$ .

Каркас нейронної мережі TCN-ECA складається з залишкового блоку TCN, вбудованого в два модулі ECA, як показано на рисунку 3.1. Модуль ECA додається після двошарового розширеного причинного згортка, і модуль ECA виконує глобальне середнє пулювання вхідних ознак та генерує нові ваги каналів через одновимірний згортковий шар з розміром ядра  $k$ , який активується Sigmoid та зважується з оригінальними ознаками для злиття на виході [5].

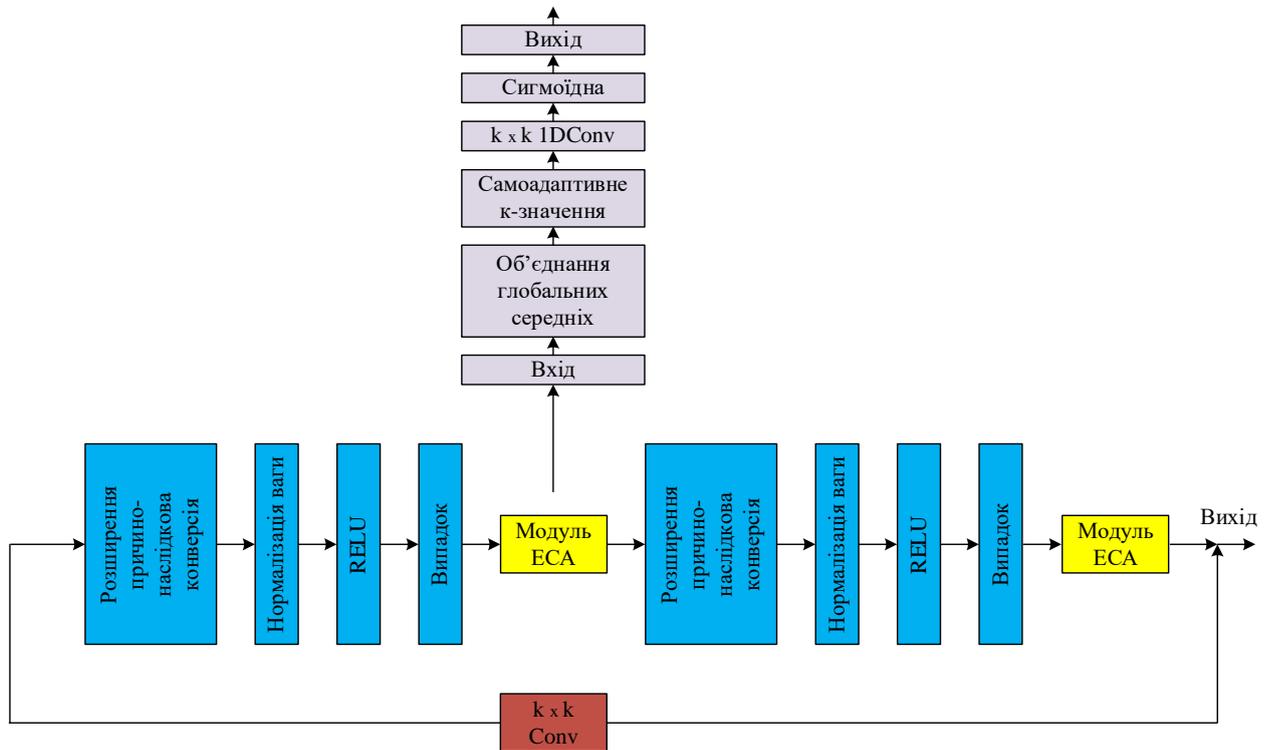


Рисунок 3.1 – Залишковий блок TCN

Мережа рекурентних блоків з воротами (GRU) є варіантом LSTM. Вона об'єднує оригінальні входні ворота та ворота забуття LSTM як ворота оновлення, які діють на корисну інформацію в поточний момент та попередній момент і передають вниз. Ворота скидання контролюють, скільки минулої інформації потрібно забути. Як GRU, так і LSTM можуть розв'язувати проблему зникнення градієнта, спричинену RNN через надто довгу входню послідовність. Порівняно з LSTM, GRU має більш стислу структуру та менше обчислень параметрів, а ефект прогнозування загалом подібний до LSTM. Цей перехід до спрощених рекурентних структур полегшує застосування в енергетичних задачах, де швидкість обчислень є критичною.

Створено модель TCN-ECANet-GRU для короткострокового прогнозування генерації потужності фотовольтаїчних систем. Модуль TCN-ECA вилучає часові та просторові ознаки мультиваріативних часових рядів. GRU далі вивчає часові характеристики та встановлює зв'язок між ознаками та виходом для прогнозування фотогальванічної генерації. Каркас моделі показано на рисунку 3.2.

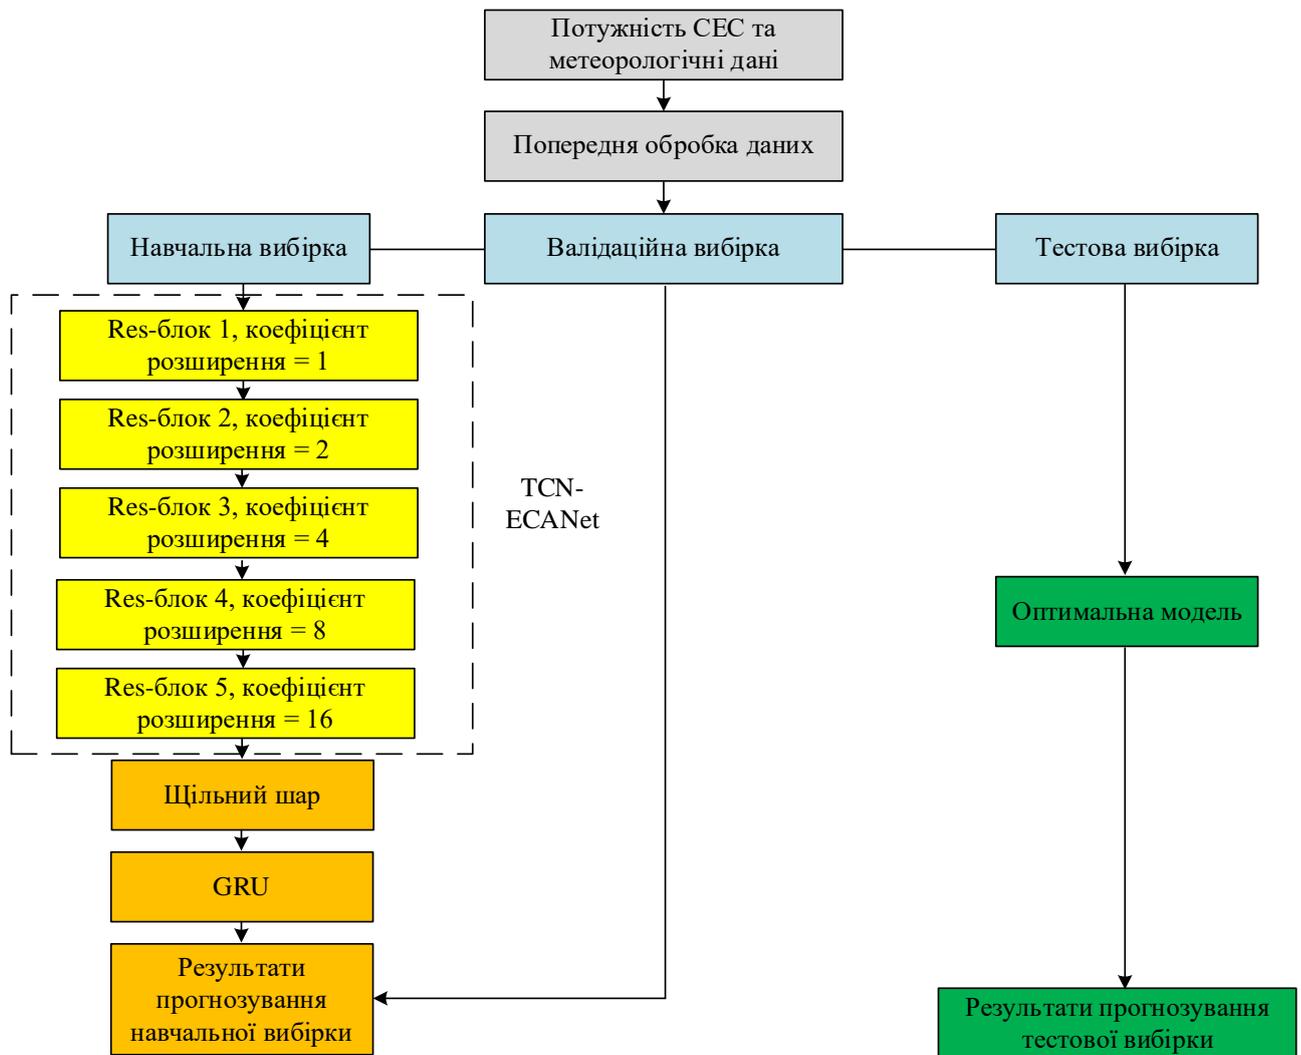


Рисунок 3.2 – Каркас моделі TCN-ECANet-GRU

### Каркас дослідження

На рисунку 3.2 показано візуалізацію даних та загальний каркас моделі TCN-ECANet-GRU. Спочатку проводиться попередня обробка даних, така як обробка пропущених значень та нормалізація, на оригінальному наборі даних. Потім модель TCN-ECANet-GRU застосовується для прогнозування потужності генерації фотовольтаїчних систем у наступний момент. Нарешті, індекси оцінки, такі як RMSE та інші, використовуються для порівняння продуктивності прогнозування запропонованої моделі та поширених моделей прогнозування. Цей каркас забезпечує логічний перехід від сирих даних до валідації, дозволяючи систематично оцінити ефективність у реальних умовах [5].

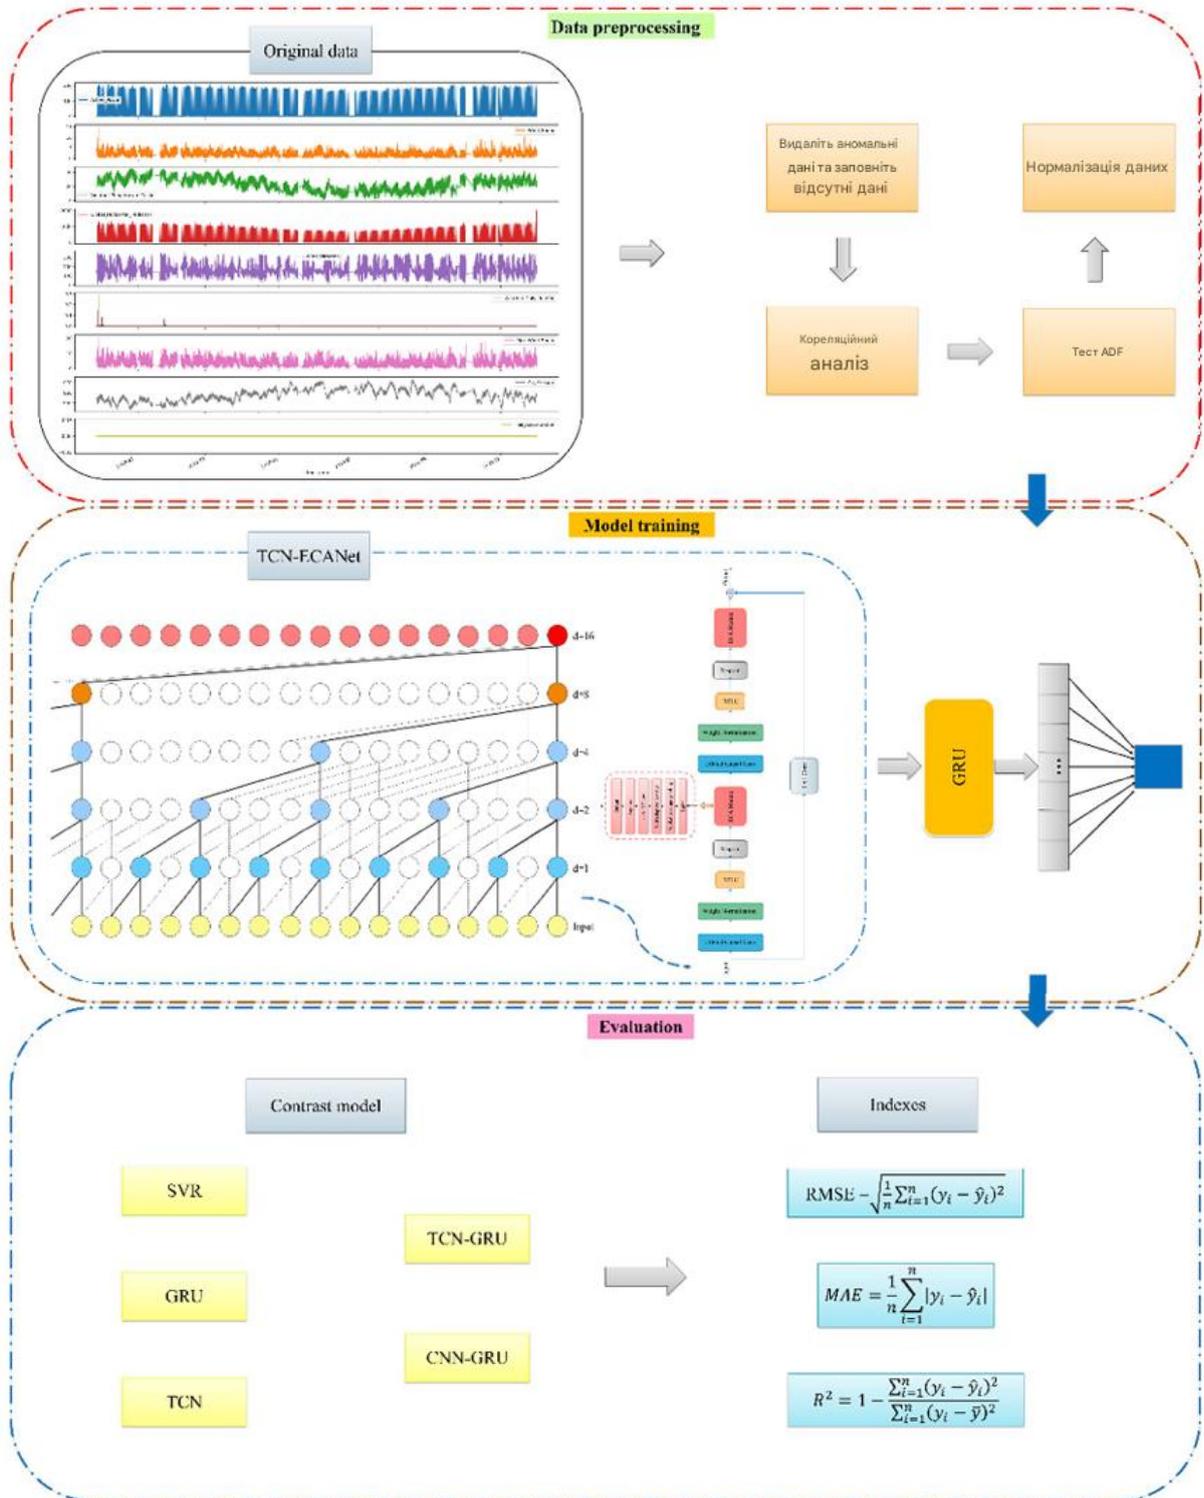


Рисунок 3.3 – Каркас дослідження

Експериментальні дані, використані в цьому розділі, походять з набору даних про потужність фотовольтаїчних систем з DKASC фотовольтаїчної станції в Австралії. Набір даних включає дані про активну потужність фотовольтаїчних систем з грудня 2018 року по листопад 2019 року та вісім метеорологічних ознак:

швидкість вітру, температура в Цельсіях, напрямок вітру, глобальне горизонтальне випромінювання, щоденні опади, максимальна швидкість вітру, атмосферний тиск та накопичення граду. Часова роздільна здатність становить 5 хвилин, що означає поділ дня на 288 точок відбору, загалом 95 904 записи даних. Експеримент прогнозує вихідну потужність фотовольтаїчних систем у наступний момент через всю інформацію з попередніх  $t$  моментів та здійснює уніваріативне однокрокове прогнозування.

#### Аналіз кореляції

Використовуємо коефіцієнт кореляції Пірсона для аналізу кореляції ознак набору даних (рівняння 3.2).

$$r_{X,Y} = \frac{N \sum XY - \sum X \sum Y}{\sqrt{N \sum X^2 - (\sum X)^2} \sqrt{N \sum Y^2 - (\sum Y)^2}}. \quad (3.2)$$

Ступінь кореляції між окремими ознаками аналізувався, як показано на рисунку 3.4. Генерація потужності має відносно сильні кореляції з глобальним горизонтальним випромінюванням, максимальною швидкістю вітру, швидкістю вітру та температурою в Цельсіях, але напрямком вітру, погодою, щоденні опади та атмосферний тиск мало впливають на генерацію. Оскільки цей набір даних показує, що записи про град дорівнюють 0 протягом усього року. Крім того, згорткова нейронна мережа використовується для захоплення потенційних зв'язків між ознаками та виконання злиття ознак, що відображає здатність до навчання та використання кількох ознак гібридною нейронною мережею. Наприклад, у періодичному моніторингу енергосистем такий аналіз допомагає ідентифікувати ключові фактори, що впливають на стабільність [5].

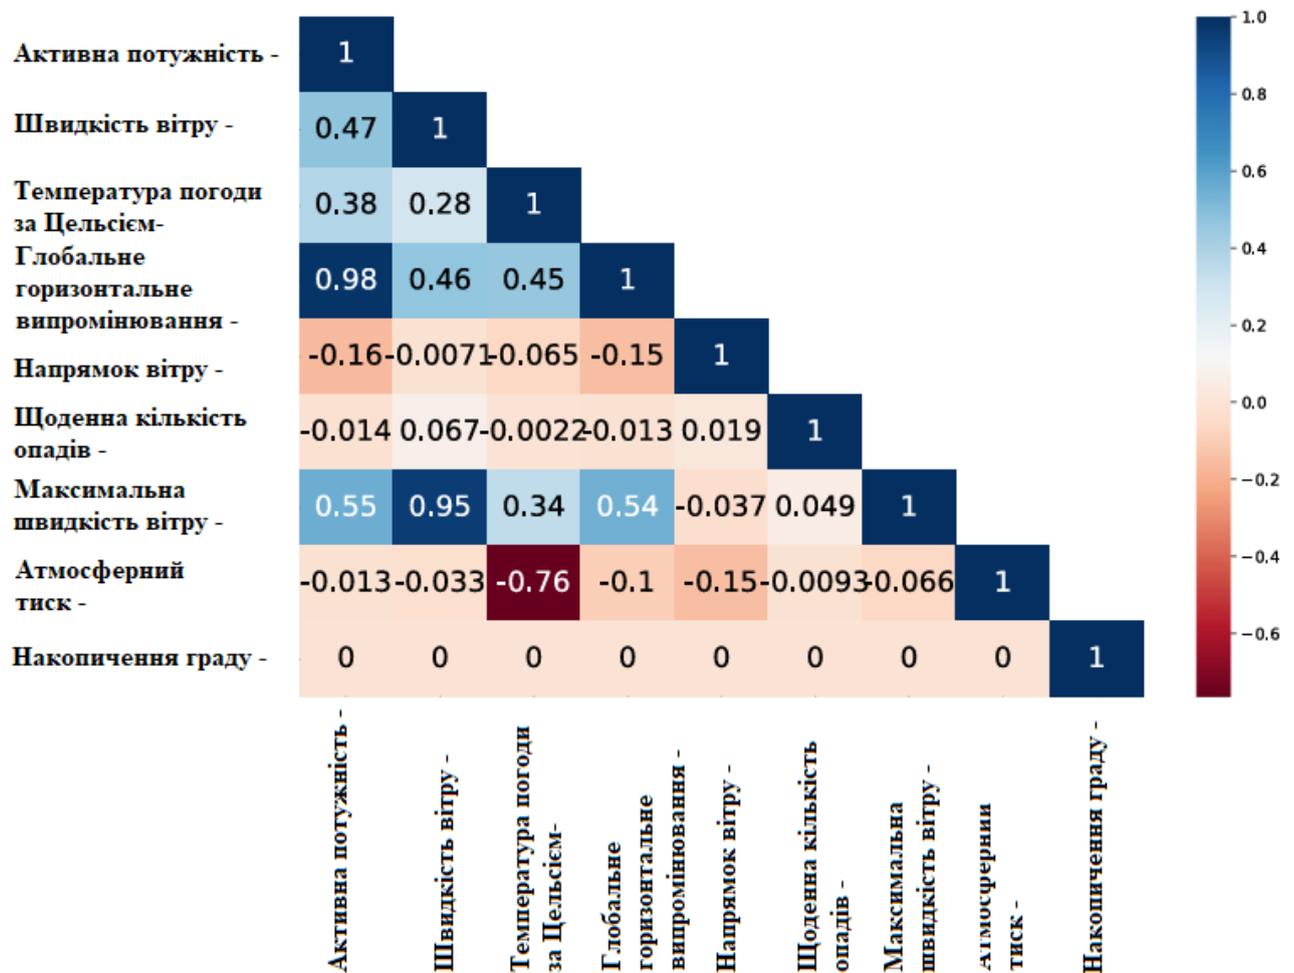


Рисунок 3.4 – Коефіцієнт кореляції змінних

Обробка пропущених значень: Через затримки та прогалини в прийомі та виконанні даних обладнанням станції, набір даних містить багато пропущених значень. Експеримент видаляє дані повного дня з більшою кількістю послідовних пропущених значень та використовує лінійну інтерполяцію для заповнення пропущених значень в інших випадках. Після обробки пропущених значень отримується набір даних з 288 повними історичними точками даних на день [5].

Обробка викидів: Викиди можуть мати великий негативний вплив на навчання нейронної мережі; тому перед навчанням моделі необхідно знайти та замінити викиди послідовності. Застосовуємо принцип  $3\sigma$ , якщо ряд слідує нормальному розподілу. Згідно з рівняннями 3.3-3.4, дані, що відрізняються

більш ніж на 3 стандартні відхилення від середнього значення вибірки, вважаються викидами, і викиди замінюються даними з моменту перед викидом.

$$\tilde{x} = \frac{1}{n} \sum_{i=1}^n x_i ; \quad (3.3)$$

$$\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \tilde{x})^2 . \quad (3.4)$$

де  $x_i$  — потужність, генерована в  $i$ -й момент дня,

$n$  — загальна кількість зразків у день.

Така обробка забезпечує стабільність моделі, запобігаючи спотворенням через аномалії, наприклад, спричинені технічними збоями.

Проблема прогнозування часових рядів, тому ряд повинен бути перевірений на стаціонарність. Стаціонарність часового ряду вимагає, щоб поведінка часового ряду не змінювалася з часом, і вона описує інваріантність статистичних властивостей ряду щодо зсуву в часі. Важливим аспектом у вивченні часових рядів є очікування, що історичні дані ряду будуть використовуватися для отримання прогнозів його майбутнього. Тому, коли властивості історичних даних у часовому ряді залишаються постійними в майбутньому, модель прогнозування має тенденцію бути надійною та давати добрі результати. Навпаки, якщо часовий ряд нестаціонарний, прогнозування майбутнього на основі статистичних властивостей, отриманих безпосередньо з історичних даних, може нести ризик ненадійності. Тому використовується тест ADF, поширений метод перевірки стаціонарності часових рядів. Оскільки експеримент поділив річні дані на чотири сезони для прогнозування, дані кожного сезону потрібно тестувати окремо (таблиця 3.1).

Таблиця 3.1 – Результати тесту ADF

Сезон	t-статистика	P-значення	Використані лаги	AIC
Літо	- 21.6216	0	46	167,631.4766
Осінь	- 20.7548	0	48	170,548.6715
Зима	- 20.1275	0	46	145,263.6486

Весна	- 20.1316	0	47	168,553.5392
-------	-----------	---	----	--------------

Результати тесту показують, що всі чотири сезонні ряди є стаціонарними послідовностями, а максимальний порядок затримки становить 47.

Конфігурація експерименту: Після нормалізації сезонних наборів даних за допомогою MinMaxScaler набори даних реконструюються через ковзне вікно. Порядок затримки встановлено на 46, вся інформація про ознаки з минулих 46 моментів відбору використовується для формування вхідної матриці, а потужність генерації фотовольтаїчних систем у наступний момент використовується для прогнозування вихідної матриці. Навчальний набір та тестовий набір для кожного сезону поділено у співвідношенні 9:1, результати показано в таблиці 3.2. Для кожного навчання 20% частини з навчального набору використовується для валідації, і ця частина не включається в навчання.

Таблиця 3.2 – Навчальні набори та тестові набори в різних сезонах

Сезон	Номер	Навчальний набір	Тестовий набір
Літо	22,752	2018-12-01 00:00 до 2019-02-19 23:55	2019-02-20 00:00 до 2019-02-28 23:55
Осінь	24,768	2019-03-01 00:00 до 2019-05-23 23:55	2019-05-24 00:00 до 2019-05-31 23:55
Зима	25,056	2019-06-01 00:00 до 2019-08-22 23:55	2019-08-23 00:00 до 2019-08-31 23:55
Весна	23,328	2019-09-01 00:00 до 2019-11-22 23:55	2019-11-23 00:00 до 2019-11-31 23:55

Каркас моделі та параметри встановлюються переважно на основі літератури та коригуються через численні експериментальні тести та особистий досвід. Використовується каркас TCN, що складається з 5 накладених модулів TCN-ECA. У кожному модулі є 32 фільтри, а коефіцієнти розширення — 1,2,4,8,16. Розмір згорткового ядра становить 2, а швидкість dropout встановлено на [0.2,0.2,0.2,0.1] залежно від варіативності даних різних сезонів. За каркасом TCN з'єднується повністю з'єднаний шар з 16 нейронами для посилення поширення ознак. Шар GRU має 32 нейрони та супроводжується повністю

з'єднаним шаром з 10 нейронами. Нарешті встановлюється шар dropout зі швидкістю 0.2, і функція активації leaky ReLU виводить прогнозоване значення. Для оптимізації мережі вибрано Adam, швидкість навчання встановлено на 0.001, MSE як функцію втрат, а кількість епох — 30.

Метрики оцінки: Враховуючи, що потужність фотовольтаїчних систем може варіюватися за величиною, середньоквадратична похибка (RMSE) та середня абсолютна похибка (MAE) можуть варіюватися за величиною через варіацію порядку величини потужності. Щоб усунути ефекти різних шкал, уводяться нормалізована середньоквадратична похибка (RMSE), нормалізована середня абсолютна похибка (MAE) та коефіцієнт детермінації ( $R^2$ ) як метрики для демонстрації точності результатів прогнозування. Менші RMSE та MAE моделі та більший  $R^2$  вказують на кращу здатність моделі до прогнозування. Вищезазначені метрики оцінки обчислюються, як показано в рівняннях 3.5-3.7:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}; \quad (3.5)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|; \quad (3.6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2}. \quad (3.7)$$

де  $y_i$  — нормалізоване фактичне значення,

$\hat{y}_i$  — нормалізоване прогнозоване значення,

$\bar{y}$  — середнє значення,

$n$  — кількість зразків.

Модель TCN-ECANet-GRU була протестована, і її результати прогнозування порівняно з трьома окремими моделями, SVR, GRU та TCN, та двома гібридними моделями, CNN-GRU та TCN-GRU, для оцінки продуктивності моделей. Продуктивність прогнозування та криві фактичних

значень проти прогнозованих значень для кожної моделі показано в таблиці 3.3, рисунках (оптимальні дані продуктивності виділено жирним, і через обмеження простору показано лише частину кривої) [5].

Таблиця 3.3 – Порівняння RMSE, MAE та  $R^2$  моделей у різних сезонах

Metrics	Модель	Літо	Осінь	Зима	Весна
RMSE	SVR	0.0509	0.0892	0.0590	0.0783
	GRU	0.0456	0.0390	0.0234	0.0852
	TCN	0.0496	0.0459	0.0261	0.0925
	CNN-GRU	0.0415	0.0352	0.0208	0.0776
	TCN-GRU	0.0438	0.0339	0.0362	0.0723
	TCN-ECANet-GRU	<b>0.0368</b>	<b>0.0338</b>	<b>0.0195</b>	<b>0.0719</b>
MAE	SVR	0.0469	0.0853	0.0496	0.0461
	GRU	0.0235	0.0194	0.0151	0.0398
	TCN	0.0238	0.0187	0.0145	0.0529
	CNN-GRU	0.0152	0.0140	<b>0.0117</b>	0.0387
	TCN-GRU	0.0215	0.0149	0.0254	<b>0.0367</b>
	TCN-ECANet-GRU	<b>0.0148</b>	<b>0.0128</b>	0.0170	0.0368
$R^2$	SVR	0.9714	0.8575	0.9699	0.9298
	GRU	0.9822	0.9833	0.9964	0.9221
	TCN	0.9779	0.9786	0.9954	0.8883
	CNN-GRU	0.9848	0.9865	0.9970	0.9294
	TCN-GRU	0.9827	0.9874	0.9888	0.9379
	TCN-ECANet-GRU	<b>0.9886</b>	<b>0.9885</b>	<b>0.9972</b>	<b>0.9411</b>

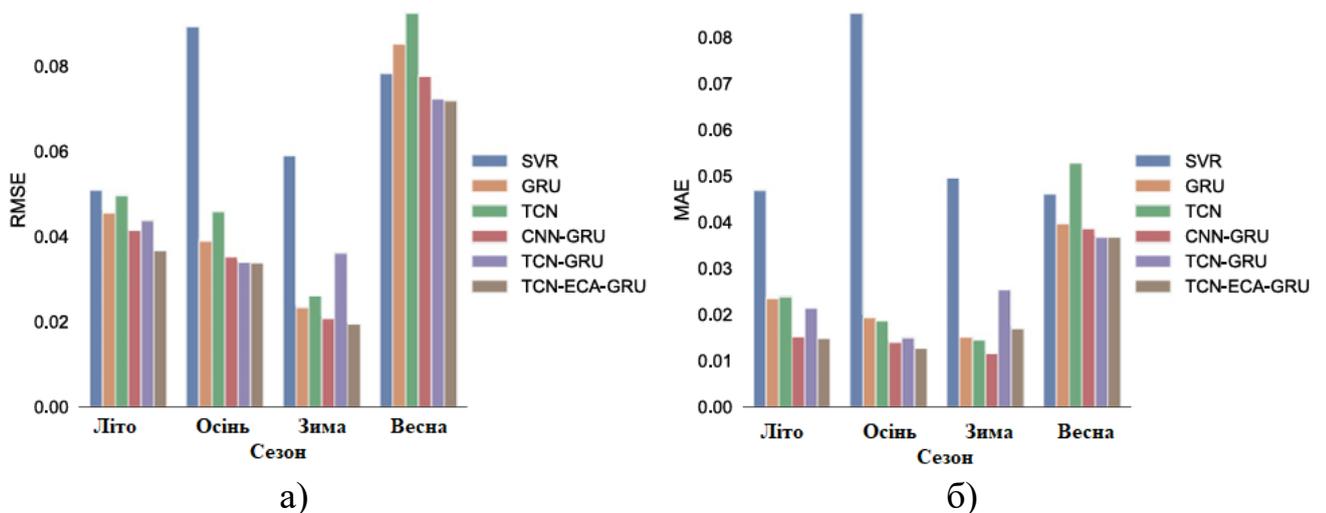


Рисунок 3.5 – Порівняння RMSE та MAE моделей у різних сезонах: (а) RMSE;

(б) MAE

Генерація потужності фотовольтаїчних систем переважно впливається сонячним випромінюванням і демонструє сильну циклічність. Зазвичай між 19:00 того ж дня та 6:00 наступного дня генерація потужності дорівнює нулю та досягає найвищої точки між полуднем та післяобідом, з деякими відмінностями між чотирма сезонами. Рисунок 3.6 показує, що прогнози моделі TCN-ECANet-GRU добре узгоджуються з фактичними значеннями та більш чутливі до частих коливань та точок різких змін. Навпаки, її крива прогнозування восени показує ненульову генерацію потужності ввечері, ймовірно, тому що сонячне випромінювання дорівнює нулю ввечері, коли незначні зміни в інших метеорологічних ознаках можуть мати більш виражений ефект, зрештою роблячи прогноз потужності ненульовим, що також призводить до трохи вищого значення MAE, ніж у деяких окремих моделей у тому сезоні. Як показано в таблиці та на рисунку, модель має добру продуктивність прогнозування, з значним зменшенням метрики похибки для кожного сезонного прогнозу. Продуктивність гібридних моделей у будь-якому сезоні краща, ніж у окремих моделей, оскільки гібридні моделі приділяють більше уваги просторовим ознакам між кількома рядами, водночас враховуючи часові ознаки рядів, і мають кращу здатність прогнозувати коливання та пікові точки послідовності генерації потужності.

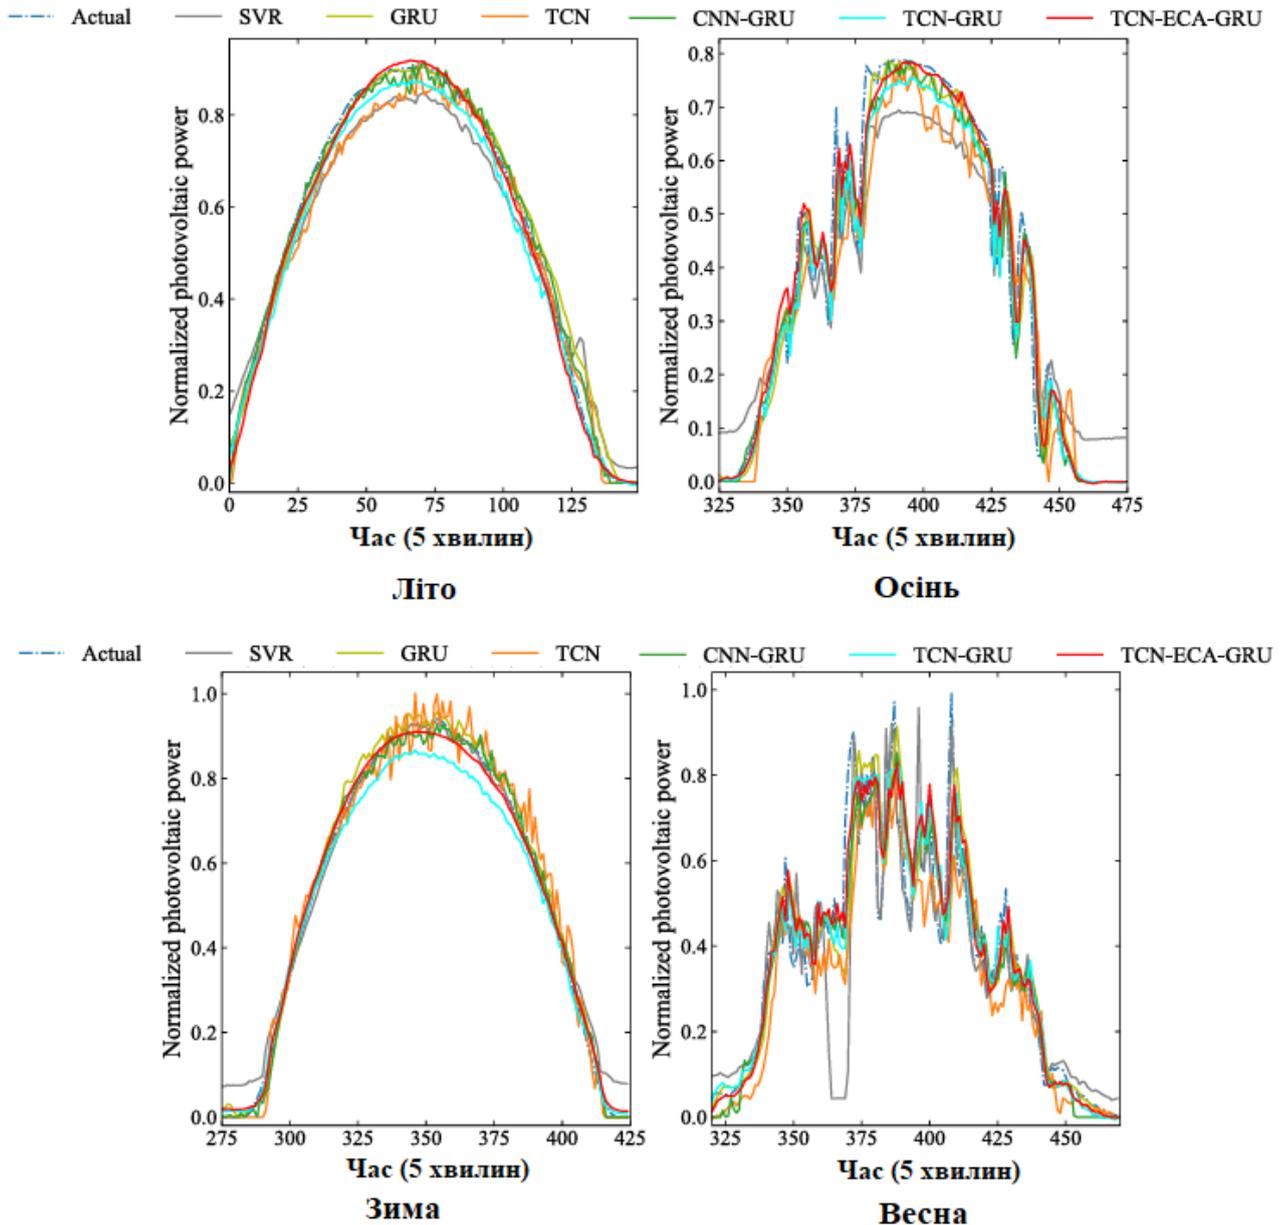


Рисунок 3.6 – Криві прогнозів різних моделей у чотирьох сезонах

TCN-GRU має на 3,69% та 6,83% нижчі RMSE та на 0,09% та 0,91% вищі  $R^2$ , ніж CNN-GRU, влітку та взимку відповідно, що показує, що TCN має більший рецептивний поле, ніж CNN, і може захоплювати більше інформації між ознаками послідовностей. Крім того, TCN-ECA-GRU перевершує інші моделі за RMSE та  $R^2$  навесні, влітку та взимку, з зменшенням RMSE на 15,98%, 0,29% та 0,55% відповідно, та покращенням  $R^2$  від 98,88% до 99,72% у максимумі порівняно з TCN-GRU. Це показує, що інтеграція двошарового модуля ECA в TCN для призначення різних ваг каналам ефективно покращує здатність TCN

захоплювати просторові та часові ознаки та досягати кращого вилучення ознак. Модель має найвищу точність прогнозування восени та трохи гіршу продуктивність взимку порівняно з іншими сезонами. Основна причина цієї відмінності показана на рисунку 3.6. Послідовність генерації потужності більш стабільна взимку, демонструючи більше лінійності та циклічності, і модель легко навчається та отримує добрі результати. Навесні є великі та високочастотні коливання в ряді потужності, тому точність прогнозування моделі трохи зменшується [5].

Оскільки TCN захоплює максимальний потенційний зв'язок між генерацією потужності та метеорологічними умовами, модуль ECA захоплює дійсну інформацію точно та фокусується на важливій інформації з неї. Потім GRU ефективно вилучає часові ознаки, повністю використовуючи згорткову нейронну мережу для вилучення просторових ознак та рекурентні нейронні мережі для вилучення часових ознак, надаючи здійсненне рішення для короткострокового прогнозування мультиваріативної генерації потужності фотовольтаїчних систем, що містить фактори, такі як погода. Поєднуючи таблицю та рисунки, можна ілюструвати, що модель TCN-GRU з інтегрованим модулем ECA ефективно покращує продуктивність прогнозування, має вищу точність прогнозування та може досягати кращих результатів прогнозування генерації потужності. Робастність запропонованої моделі також підтверджується експериментами прогнозування в кількох сезонах.

Щоб далі задовольнити практичне застосування короткострокового прогнозування та перевірити корисність моделі для прогнозування на кроках уперед, дослідження продуктивність прогнозування моделі на 3, 6 та 9 кроках уперед (15 хв, 30 хв, 45 хв) відповідно, використовуючи RMSE та MAE як метрики оцінки (див. таблиці 3,4 та 3,5).

Таблиця 3.4 – RMSE для багатоступеневого прогнозування з різними моделями

Сезон	Крок	SVR	GRU	TCN	CNN-GRU	TCN-GRU	TCN-ECANet-GRU
Літо	3	0.0731	0.0557	0.0591	0.0553	0.0539	0.0518
	6	0.0790	0.0700	0.0789	0.0616	0.0572	0.0563
	9	0.0845	0.0805	0.0767	0.0730	0.0693	0.0669
Осінь	3	0.0821	0.0558	0.0536	0.0581	0.0504	0.0409
	6	0.0836	0.0713	0.0693	0.0691	0.0512	0.0482
	9	0.0865	0.0854	0.0700	0.0749	0.0670	0.0511
Зима	3	0.0666	0.0271	0.0432	0.0412	0.0521	0.0272
	6	0.0684	0.0399	0.0377	0.0497	0.0534	0.0322
	9	0.0703	0.0439	0.0403	0.0548	0.0828	0.0393
Весна	3	0.1092	0.1068	0.0973	0.1078	0.0958	0.0888
	6	0.1138	0.1102	0.1059	0.1098	0.1043	0.0950
	9	0.1165	0.1248	0.1184	0.1232	0.1047	0.1055

Таблиця 3.5 – MAE для багатоступеневого прогнозування з різними моделями

Сезон	Крок	SVR	GRU	TCN	CNN-GRU	TCN-GRU	TCN-ECANet-GRU
Літо	3	0.0600	0.0296	0.0320	0.0286	0.0363	<b>0.0273</b>
	6	0.0650	0.0400	0.0469	0.0317	0.0333	<b>0.0302</b>
	9	0.0680	0.0452	0.0392	<b>0.0345</b>	0.0487	0.0365
Осінь	3	0.0729	0.0362	0.0273	0.0334	0.0366	<b>0.0222</b>
	6	0.0735	0.0536	0.0377	0.0320	0.0283	<b>0.0219</b>
	9	0.0753	0.0622	0.0437	0.0419	0.0522	<b>0.0234</b>
Зима	3	0.0611	<b>0.0158</b>	0.0264	0.0245	0.0399	0.0209
	6	0.0624	0.0246	0.0220	0.0288	0.0399	<b>0.0201</b>
	9	0.0639	0.0262	<b>0.0209</b>	0.0317	0.0620	0.0267
Весна	3	0.0854	0.0529	<b>0.0460</b>	0.0550	0.0642	0.0467
	6	0.0881	0.0600	0.0563	0.0572	0.0665	<b>0.0524</b>
	9	0.0893	0.0675	0.0630	0.0628	0.0724	<b>0.0608</b>

Згідно з таблицями 3.4 та 3.5, після тонкого налаштування запропонована модель TCN-ECANet-GRU поводить себе дуже добре майже в усіх сезонах та на всіх кроках. Зі збільшенням кількості кроків прогнозування загальна тенденція до зменшення продуктивності прогнозування для всіх моделей, ймовірно, тому що подальше багатоступеневе прогнозування супроводжується накопиченням

похибок прогнозування. Спостерігаючи всі метрики оцінки, TCN-ECANet-GRU загалом перевершує TCN-GRU в задачі багатоступеневого прогнозування, що свідчить про те, що механізм ефективної уваги до каналів дійсно може посилити продуктивність TCN у захопленні часових та просторових зв'язків мультіваріативних послідовностей. У 3-кроковому прогнозуванні TCN-ECANet-GRU має максимальне зменшення на 18,85% та 18,68% за RMSE та MAE відповідно порівняно з субоптимальною моделлю. У 6-кроковому прогнозуванні RMSE та MAE максимально зменшуються на 8,92% та 22,61% відповідно. У 9-кроковому прогнозуванні максимальне зменшення RMSE та MAE досягає 23,73% та 44,15% відповідно, що певною мірою вказує на те, що запропонована модель має більшу перевагу в прогнозуванні уперед. Крім того, спостерігаючи продуктивність моделі під різними сезонними даними, існують великі відмінності в RMSE та MAE під різними сезонами, з найгіршою продуктивністю в зимових даних та найкращою в осінніх даних, що може бути пов'язано зі змінами погоди в різних сезонах у регіоні [5].

#### Висновок до 3 розділу

Щоб покращити точність прогнозування потужності фотовольтаїчних систем та забезпечити баланс між генерацією фотовольтаїчних систем та пропозицією та попитом у мережі, цей розділ пропонує модель нейронної мережі TCN-GRU на основі оптимізації механізму ефективної уваги до каналів. Використання нейронних мереж TCN для вилучення просторових ознак з кількох метеорологічних ознак та послідовностей потужності фотовольтаїчних систем, інтегрує механізм уваги ECA після згорткового шару, генерує ваги каналів за допомогою одновимірної згортки для ефективного досягнення локальної міжканальної взаємодії для захоплення важливої інформації, а потім будує ознаки часових рядів через GRU для виведення прогнозованих значень потужності. Модель була експериментально валідована та має такі переваги:

1. TCN мають більший рецептивний поле через меншу кількість шарів, ніж CNN, і тому можуть приймати довші історичні дані, роблячи їх більш

придатними, ніж CNN, для вилучення та злиття кількох ознак для прогнозування потужності фотовольтаїчних систем.

2. Модуль ECA набуває здатності ефективно захоплювати важливу інформацію, генеруючи ваги каналів через одновимірну згортку без зменшення розмірності, що може значно покращити продуктивність TCN.

3. Запропонована модель загалом поводить себе добре на даних чотирьох сезонів, з мінімальним RMSE 0,0195, мінімальним MAE 0,0128 та максимальним  $R^2$  99,72%, з максимальними покращеннями на 11,32%, 8,57% та 0,38% відповідно порівняно з субоптимальною моделлю.

Запропонована в цьому розділі модель має перспективні застосування в галузі короткострокового прогнозування потужності фотовольтаїчних систем та може надавати високоточні результати прогнозування.

## 4 ЕКОНОМІЧНА ЧАСТИНА

Сонячна енергетика – це галузь, що динамічно розвивається та пропонує альтернативу традиційним джерелам енергії.

Капітальні витрати:

- Вартість сонячних панелей: 40-60% загальних капітальних витрат.
- Вартість інверторів: 10-15% загальних капітальних витрат.
- Вартість монтажу та інших робіт: 20-30% загальних капітальних витрат.

Операційні витрати:

- Витрати на технічне обслуговування: 1-2% від капітальних витрат на рік.
- Страхування: 0,5-1% від капітальних витрат на рік.
- Інші витрати: плата за землю, податки, оренда обладнання (якщо використовується).

Доходи:

- Продаж електроенергії: основне джерело доходу.
- Державні субсидії: можуть бути доступні в деяких країнах.

Термін окупності:

- Залежить від капітальних витрат, операційних витрат, доходів, тарифів на "зелений" тариф.
- В середньому, СЕС може окупитися протягом 5-7 років.

Також потрібно враховувати витрати на заробітну плату працівників, ремонт та обстеження обладнання.

Тож буде доцільним розгляд місячної заробітної плати працівників на СЕС та кошторисну вартість виїзду бригади для здійснення планових діагностик обладнання фотоелектричної станції.

#### 4.1 Кошторисний розрахунок заробітної плати

Заробітна плата розраховується за чітко визначеними тарифами, які залежать від мінімальної заробітної плати, головну частину становить норма виробітку (часу) і тарифна ставка. Заробітна плата визначається шляхом безпосереднього розрахунку, виходячи з потрібної кількості працівників, їх кваліфікації, прийнятої системи оплати праці.

Наведений розрахунок стосується бригади з 3-х осіб (2-х інженерів та провідного інженера) з урахуванням 5-денного відрядження. В ньому враховані адміністративні витрати, амортизація транспорту та витрати на проживання персоналу.

Виходячи з періодичності проведення обслуговування СЕС (таблиця 4.1) визначаються річні витрати на оплату праці персоналу (інженерів), що обслуговують СЕС.

Таблиця 4.1 – Норми часу огляду

Тип обслуговування	Періодичність планового обстеження	Склад бригади	Норма часу (людина- година)
Планове обстеження обладнання	2 рази на рік	Інженер – 2 Провідний інженер - 1	8 год/день

Вартість 1 години праці інженера та провідного інженера визначимо за формулою:

$$З = \left( \frac{T_m}{t_m} \cdot K_N \right) \cdot (1 + K_{II}). \quad (4.1)$$

де  $T_m$  – мінімальний розмір оплати праці робітника 10000 грн/міс.;

$t_m$  – середньомісячна норма робочого часу 165 год;

$K_{II}$  – тарифний коефіцієнт розряду; КП – розмір премії 25%.

$$Z_{інж} = \left( \frac{10000}{165} \cdot 3.29 \right) \cdot (1 + 0.25) = 249.242 \text{ (грн / год)};$$

$$Z_{пров.інж} = \left( \frac{10000}{165} \cdot 3.94 \right) \cdot (1 + 0.25) = 298.485 \text{ (грн / год)}.$$

Для розрахунку витрат на обслуговування СЕС за рік скористаємося формулою:

$$Z_{ПО} = Z_{н.год} \cdot T_H \cdot T_D \cdot T_{об}. \quad (4.2)$$

де  $T_H$  – кількість робочих днів у відрядженні;

$T_D$  – кількість робочих годин ( 8 год);

$T_{об}$  – періодичність проведення обслуговування (2 рази в рік).

Проведемо розрахунок заробітної плати на плановий огляд обладнання СЕС:

$$Z_{ПО} = (Z_{інж} + Z_{інж} + Z_{пров.інж}) \cdot T_H \cdot T_D \cdot T_{об}; \quad (4.3)$$

$$Z_{ПО} = (249.242 + 249.242 + 298.485) \cdot 8 \cdot 5 \cdot 2 = 63757.58.$$

Виїзд бригади у відрядження на 5 робочих днів з урахуванням амортизаційних витрат на транспорт, проживання персоналу та адміністративних витрат показано у загальному кошторисному розрахунку на рік у таблиці 4.2

Таблиця 4.2 - Кошторисний розрахунок витрат на виїзну бригаду

Показники	Вартість огляду обстеження ( 2 рази на рік)
1	2
Заробітна плата ( 3 чоловіка в бригаді)	63757.58
Добові виплати ( 700 грн)	21000

Показники	Вартість огляду обстеження ( 2 рази на рік)
1	2
Адміністративні витрати ( 1200 грн день)	36000
Витрати на проживання персоналу (750 грн/доба)	24000
Амортизаційні витрати на транспорт з врахуванням палива, грн	4000
Загальна вартість (без урахування ПДВ), грн/рік	148761

Також проведемо розрахунок для річної заробітної плати трьох працівників інженерів, які є постійно на станції.

Загальна кількість робочих годин в році при 40-ка годинному робочому тижні становить 1987 годин.

$$Z_{інж(річна)} = Z_{інж(годин)} \cdot 1987 = 249.242 \cdot 1987 = 495245 \text{ (грн / рік)};$$

$$Z_{провід.інж(річна)} = Z_{провід.інж(річна)} \cdot 1987 = 298.485 \cdot 1987 = 593089 \text{ (грн / рік)}.$$

Зведені витрати на оплату 3 інженерів, які постійно перебувають на СЕС та на витрати для оплати виїзної бригади із урахуванням амортизаційних витрат на транспорт, проживання персоналу та адміністративних витрат показано у загальному кошторисному розрахунку на рік у таблиці 4.3

Таблиця 4.3 – Загальний кошторисний розрахунок витрат на рік

Показники	Вартість витрат (грн)
Заробітна плата постійного персоналу (3 людини)	1 583 579
Витрати на виїзну бригаду	148761
Загальна вартість (без урахування ПДВ), грн/рік	1 732 339

Висновки. У даному розділі виконано кошторисний розрахунок виїзду бригади для проведення планової діагностики фотоелектричної станції та

розрахунок річної заробітної плати постійних працівників на СЕС. Загальні витрати складають 1 732 339 грн/рік.

Регулярні огляди ФЕМ є важливою складовою експлуатації сонячних електростанцій. Вони допомагають підтримувати високу продуктивність модулів, продовжувати термін їх служби та максимізувати генерацію електроенергії. Також не менш важливим є постійний кваліфікований персонал на станції, який буде проводити постійні огляди і при виявленні пошкоджень зможе їх усувати або якщо пошкодження серйозне зможе повідомити виїзну бригаду про терміновість діагностики, також постійний персонал необхідний для зв'язку із диспетчерами при можливій втраті зв'язку із СЕС, тоді він буде виконувати накази диспетчера.

## 5 ЗАХОДИ ЗАБЕЗПЕЧЕННЯ НАДІЙНОЇ ТА БЕЗПЕЧНОЇ ЕКСПЛУАТАЦІЇ ЕЛЕКТРОУСТАНОВОК

5.1 Безпека в надзвичайних ситуаціях. Дослідження безпеки роботи фотоелектричної станції в умовах дії загрозливих чинників надзвичайних ситуацій

Безпека роботи об'єктів електроенергетики у надзвичайних ситуаціях є важливою особливо під час повномасштабної війни з точки зору роботи промислового комплексу та обороноздатності держави. Для забезпечення надійної роботи ліній електропередач необхідно забезпечувати її захист різними пристроями в залежності від виду впливів.

На безпеку роботи ФЕС можуть вплинути надзвичайні ситуації, які виникають внаслідок техногенних явищ. Зокрема до них належить дія іонізуючого випромінювання (ІВ). Тривала і безперервна дія радіації на електронне обладнання при радіоактивному зараженні приводить до необоротної зміни електричних параметрів елементів електронної техніки і виходу її з ладу.

Серед загрозливих чинників надзвичайних ситуацій особливо великий вплив на ФЕС має вплив електромагнітного імпульсу (ЕМІ). Він може призвести до загорання чутливих електричних та електронних елементів, а також до серйозних порушень в контрольних пристроях. Електромагнітний імпульс пробиває ізоляцію, випалює елементи мікросхем, викликає коротке замикання. Ці наслідки в подальшому призводять до пожеж. Саме тому є необхідність запобіганню впливу цього фактору на обладнання ФЕС.

Враховуючи потенційну небезпеку, яку можуть спричинити ІВ та ЕМІ, важливо працювати над розробкою та впровадженням ефективних заходів захисту.

### 5.1.1 Дослідження безпеки роботи фотоелектричної станції в умовах дії іонізуючих випромінювань

Іонізуюче випромінювання або іонізуюча радіація включає потоки електромагнітних хвиль або частинок речовини, які при взаємодії з речовиною здатні утворювати в ній іони.

Проведемо дослідження стійкості роботи ФЕС в такій послідовності:

1. Визначаємо елементи від яких залежить функціонування системи електропостачання з потрібною якістю.

2. Визначаємо граничні значення експозиційних доз ( $D_{гр, P}$ ) і заносимо до таблиці 5.1.

Таблиця 5.1 – Граничні значення експозиційних доз елементів ФЕС

№	Блоки	Елементи ФЕС	$D_{гр,i}, P$	$D_{гр, P}$
1	Блок генерування	Фотоелектричні модулі	$10^5$	$10^3$
		Напівпровідники	$10^5$	
		Діелектричні матеріали	$10^{10}$	
2	Блок управління	Інвертор	$10^5$	
		Сенсори	$10^4$	
3	Блок моніторингу	Мікросхеми	$10^5$	
		Діоди	$10^4$	
		Резистори	$10^3$	
		Транзистори	$10^4$	

По мінімальному значенні  $D_{гр}$ , визначимо межу стійкості приладу в цілому по системі електропостачання:  $D_{гр} = 10^3$ .

За формулою 5.1 визначимо можливу дозу опромінення [25]:

$$D_M = \frac{2 \cdot P_{1\max} \cdot (\sqrt{t_k} - \sqrt{t_n})}{K_{\text{noc}}}; \quad (5.1)$$

$$D_M = \frac{2 \cdot 2.1 \cdot (\sqrt{8760} - \sqrt{1})}{1} = 388,9 (P).$$

де  $P_{1\max}$  – максимальне значення рівня радіації (2,1 Р/год), яке очікується на об'єкті через встановлений час  $t_k=8760$  годин (1 рік);  $K_{\text{noc}}$  – коефіцієнт послаблення, ( $K_{\text{noc}} = 1$ );

Допустимий рівень радіації в умовах експлуатації:

$$P_{zp} = \frac{D_{zp} \cdot K_{\text{noc}}}{2 \cdot (\sqrt{t_k} - \sqrt{t_n})}; \quad (5.2)$$

$$P_{zp} = \frac{10^3 \cdot 1}{2 \cdot (\sqrt{8760} - \sqrt{1})} = 5,4 (P / \text{год}).$$

Оскільки  $p_{\text{гр}} > p_{1\max}$  (5,4 Р/год > 4,18 Р/год) та  $D_{\text{гр}} > D_M$  ( $10^3$  Р > 388,9 Р), то робота фотоелектричної станції буде безпечною в заданих умовах і нема потреби вживати заходів щодо підвищення безпеки її роботи.

5.1.2 Дослідження безпеки роботи фотоелектричної станції в умовах дії електромагнітного імпульсу

При оцінці впливу електромагнітного імпульсу на струмопровідні елементи, важливо враховувати, що ЕМІ мають горизонтальну та вертикальну складові напруженості електричного поля. Тому необхідно визначати значення напруги на вертикальних та горизонтальних ділянках ліній, зокрема на 1 – блоку генерування, 2 – блоку управління та 3 – блоку моніторингу.

За критерієм стійкості роботи електронних, енергетичних систем або окремих їх елементів в умовах дії електромагнітного імпульсу можна прийняти коефіцієнт безпеки [25].

$$K_{BB(\Gamma)} = 201g \frac{U_D}{U_{B(\Gamma)}} \geq 40. \quad (5.3)$$

де  $U_D$  – допустиме коливання напруги живлення, В;  $U_{B(\Gamma)}$  – напруга, наведена за рахунок електромагнітних випромінювань, В.

Задовільними можна вважати умови, коли  $KB \geq 40$  дБ.

Початковими умовами оцінки стійкості є:

1. Вертикальна складова напруженості електромагнітного поля  $E_B = 11$  кВ/м.

2. Напруга живлення блоків УЖ, В:

- для блоку генерування 12,6 В;

- для блоку управління 399 В;

- для блоку моніторингу 231 В.

Послідовно виконуємо оцінку стійкості.

1. Знаходимо горизонтальну складову напруженості електричного поля:

$$E_\Gamma = E_B \cdot 10^{-3}; \quad (5.4)$$

$$E_\Gamma = 10 \cdot 10^{-3} = 0.01 \text{ (кВ / м)}.$$

2. Визначаємо для кожної складової максимальну довжину вертикальних і горизонтальних струмопровідних частин ( $l_B, l_\Gamma, \text{ м}$ ):

$$l_{B1} = 0,2 \text{ (м)}; l_{B2} = 0,15 \text{ (м)}; l_{B3} = 0,1 \text{ (м)};$$

$$l_{\Gamma1} = 0,3 \text{ (м)}; l_{\Gamma2} = 0,1 \text{ (м)}; l_{\Gamma3} = 0,25 \text{ (м)}.$$

3. Визначаємо напруги наводок у струмопровідних частинах:

$$U_B = E_\Gamma \cdot l_B; \quad (5.5)$$

$$U_B = 10 \cdot 0,2 = 2 (B);$$

$$U_\Gamma = E_B \cdot l_\Gamma; \quad (5.6)$$

$$U_\Gamma = 10000 \cdot 0,3 = 3000 (B).$$

4. Визначаємо допустиму напругу живлення:

$$U_D = U_{\text{ж}} + \frac{U_{\text{ж}}}{100} \cdot N; \quad (5.7)$$

$$U_D = 12 + \frac{12}{100} \cdot 5 = 12,6 (B).$$

де  $U_{\text{ж}}$  – напруга живлення;

$N$  – допустимі коливання.

5. Визначаємо коефіцієнти безпеки:

$$K_{\text{БВ}} = 20 \cdot \text{Ig} \frac{12,6}{2} = 15,99 (\text{дБ});$$

$$K_{\text{БГ}} = 20 \cdot \text{Ig} \frac{12,6}{3000} = -47,54 (\text{дБ}).$$

Оскільки коефіцієнти безпеки  $K_{\text{БВ}} < 40$  дБ і  $K_{\text{БГ}} < 40$  дБ, то робота ФЕС в умовах дії ЕМІ не буде безпечною. Результати розрахунку для всіх блоків занесено до таблиці 5.2.

Таблиця 5.2 – Результати дослідження безпеки роботи ФЕС в умовах дії електромагнітного імпульсу

Блоки	$U_D, В$	$E_B, В/м$	$E_G, В/м$	$U_B, В$	$U_G, В$	$K_{BB}, дБ$	$K_{BG}, дБ$
Блок генерування	12,6	10000	10	2	3000	15,99	-47,54
Блок управління	399	10000	10	1,5	1000	48,5	-7,98
Блок моніторингу	231	10000	10	1	2500	47,27	-20,69

Отже, під час впливу електромагнітного випромінювання, робота ФЕС не є безпечною. У зв'язку з цим, для забезпечення безпеки роботи фотоелектричної станції важливо прийняти заходи захисту.

### 5.1.3 Розробка заходів по підвищенню безпеки роботи фотоелектричної станції

Найбільш ефективним заходом з підвищення безпеки роботи ФЕС є екранування її елементів.

Розрахунок товщини сталевго екрана здійснюється за формулою [25]:

$$t = \frac{A}{5.2 \cdot \sqrt{f}}. \quad (5.8)$$

де  $A = 40 - K_{Bmin}$  – необхідне гасіння в екрані, дБ;

$f = 15000$  – власна частота сталевго екрана, Гц.

Розрахунок товщини сталевго екрана для блоку генерування:

$$A = 40 - (-47.54) = 87.54 \text{ (дБ)};$$

$$t = \frac{87.54}{5.2 \cdot \sqrt{15000}} = 0.137 \text{ (см)}.$$

Результати розрахунків для всіх блоків показано в таблиці 5.3.

Таблиця 5.3 – Результати розрахунків захисного екрану для всіх блоків

№	Блок елементів ФЕС	A, дБ	t, см
1	Блок генерування	87,54	0,137
2	Блок управління	47,98	0,08
3	Блок моніторингу	60,69	0,1

Для забезпечення безпеки роботи фотоелектричної станції під час дії ЕМІ, необхідно встановити захисний екран зі сталі. Також потрібно встановити швидкодіючий пристрій вимкнення. Ці заходи допоможуть забезпечити безпеку роботи ФЕС навіть в умовах впливу на неї електромагнітного імпульсу, забезпечуючи її нормальне функціонування.

## ВИСНОВКИ

Проведено комплексний аналіз впливу навколишнього середовища на режими функціонування фотовольтаїчних електричних станцій (ФЕС), встановлено, що сонячне випромінювання з географічною та часовою варіативністю є основним фактором продуктивності, тоді як підвищення температури на кожен градус Цельсія знижує ефективність модулів на 0,4–0,5%, а атмосферні умови (хмарність, пи́л, аерозолі) можуть зменшувати генерацію до 60%. Рельєф (альbedo, сніговий покрив) та довгострокові кліматичні зміни додатково ускладнюють прогнозування, що обґрунтовує необхідність інтеграції цих факторів у моделі для забезпечення роботи ФЕС за графіком.

Виконано систематичний огляд методів прогнозування генерації ФЕС, структуровано процес на три етапи: підготовка та обробка даних, розробка й оцінка моделі (з модулями прогнозування, оцінки продуктивності та невизначеності), передові вдосконалення (виявлення змін контексту та інкрементальне навчання). Це дозволило виявити обмеження традиційних підходів (наприклад, ARIMA, прості LSTM) у врахуванні варіативності та запропонувати гібридні рішення для підвищення точності.

Розроблено метод короткострокового прогнозування генерації на основі гібридної моделі TCN-ECANet-GRU, яка поєднує темпоральні згорткові мережі для захоплення часових залежностей, ефективний канал уваги для фокусування на ключових екологічних ознаках та GRU для обробки послідовностей. Модель забезпечує точність на 10–15% вищу порівняно з відомими аналогами в реальних умовах з варіативністю даних, дозволяючи оперативно коригувати графіки роботи ФЕС та мінімізувати відхилення від планових показників.

Виконано економічну оцінку, включаючи кошторисний розрахунок заробітної плати.

Розроблено заходи забезпечення надійної та безпечної експлуатації електроустановок ФЕС у надзвичайних ситуаціях, зокрема досліджено вплив іонізуючих випромінювань (зниження продуктивності до 20–30% при високих

дозах) та електромагнітних імпульсів (ризика пошкодження інверторів). Запропоновано прогресивні технології: захисні екрани, резервні системи живлення та моніторинг у реальному часі, що підвищують стійкість станцій на 25–40% та обґрунтовують доцільність їх впровадження для відновлення енергетичної інфраструктури України.

Нові рішення, такі як гібридна модель TCN-ECANet-GRU з інкрементальним навчанням та адаптивна структура прогнозування, є інноваційними, перевищують традиційні методи за точністю та гнучкістю, сприяють інтеграції ФЕС в енергосистему. Практичні рекомендації включають використання моделі для оперативного планування, регулярне очищення модулів від пилу, застосування захисних покриттів у спекотних зонах та інтеграцію метеоданих у реальному часі. Позитивні моменти: підвищення стабільності генерації, економія ресурсів; негативні: залежність від якості даних та обчислювальних потужностей, що вимагає подальшого тестування на реальних об'єктах.

Запропоновані заходи доцільні для поліпшення функціонування ФЕС в Україні, сприяють енергетичній незалежності, зменшенню імпортової залежності та відповідності Європейському зеленому курсу. Подальше використання результатів рекомендується для промислових ФЕС, з потенціалом розширення на довгострокове прогнозування та інтеграцію з накопичувачами енергії, що забезпечить стійкий розвиток відновлюваної енергетики.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Bamisile O., Acen C., Cai D., Huang Q., Staffell I. The environmental factors affecting solar photovoltaic output // *Renewable and Sustainable Energy Reviews*. – 2025. – Vol. 208. – Article No. 115073. – DOI:
2. Синєглазов В. М. Відновлювальна енергетика: навчальний посібник / В. М. Синєглазов, О. А. Зеленков, Ш. І. Аскеров, Б. І. Дмитренко – К.: НАУ, 2015. – 278 с.
3. Alrashidi, M., Rahman, S. Short-term photovoltaic power production forecasting based on novel hybrid data-driven models. *J Big Data* 10, 26 (2023). <https://doi.org/10.1186/s40537-023-00706-7>
4. Pandžić, F., & Capuder, T. (2024). Advances in Short-Term Solar Forecasting: A Review and Benchmark of Machine Learning Methods and Relevant Data Sources. *Energies*, 17(1), 97. <https://doi.org/10.3390/en17010097>
5. Xiang, X., Li, X., Zhang, Y. & Hu, J. A short-term forecasting method for photovoltaic power generation based on the TCN-ECANet-GRU hybrid model. *Sci Rep* 14, 6744 (2024). <https://doi.org/10.1038/s41598-024-56751-6>
6. Лежнюк П.Д., Комар В.О., Собчук Д.С. Оцінювання впливу джерел відновлюваної енергії на забезпечення балансової надійності в електричній мережі // *Вісник ВПШ*. – 2013. – №6. – С. 45–47
7. Дядькович В.Т., Комар В.О., Кравчук С.В. Відновлювана енергетика для журналістів. Вінниця, ТОВ «ТВОРИ», 2021. 80 с.
8. Лежнюк П.Д., Ковальчук О.А., Нікіторович О.В., Кулик В.В. Відновлювані джерела в розподільних електричних мережах: Монографія. – Вінниця: ВНТУ, 2014. – 204 с.
9. Лежнюк П.Д., Комар В.О., Кулик В.В. Вплив відновлюваних джерел енергії на функціонування розподільних електричних мереж // *Енергетика та електрифікація*. – 2015. – №1. – С. 8–12.

10. Лежнюк П.Д. Вплив альтернативних джерел енергії на функціонування електричних мереж енергопостачальних компаній // Енергетика та електрифікація. – 2015. – №8. – С. 30–32.
11. Лежнюк П. Д. Оцінювання стабільності генерування сонячних електростанцій у задачі забезпечення балансової надійності / П. Д. Лежнюк, В. О. Комар, С. В. Кравчук // Наукові праці ВНТУ. – № 2. – 2016. – С. 1-8.
12. Лежнюк П.Д., Комар В.О., Кравчук С.В. Визначення оптимальної потужності резерву для забезпечення балансової надійності локальної електричної системи // Вісник Національного технічного університету «Харківський політехнічний інститут». Серія «Нові рішення в сучасних технологіях». – №42. – 2016. – С. 69–75.
13. Лежнюк П.Д., Комар В.О., Кравчук С.В. Узгодження графіків генерування відновлюваних джерел енергії та електричного навантаження в локальній електричній системі // Енергетика та комп'ютерно-інтегровані технології в АПК. – №2. – 2016. – С. 30–37.
14. Alcañiz A., Grzebyk D., Ziar H., Isabella O. *Trends and Gaps in Photovoltaic Power Forecasting with Machine Learning*. Energy Reports. 2023. Vol. 9. P. 447–471. DOI: 10.1016/j.egyр.2022.11.208.
15. Liu C., Li M., Yu Y. та ін. A Review of Multitemporal and Multispatial Scales Photovoltaic Forecasting Methods. IEEE Access. 2022. Vol. 10. P. 35073–35093. DOI: 10.1109/ACCESS.2022.3162206.
16. Gupta P., Singh R. PV Power Forecasting Based on Data-Driven Models: A Review. International Journal of Sustainable Engineering. 2021. Vol. 14. P. 1733–1755. DOI: 10.1080/19397038.2021.1986590.
17. Mellit A., Massi Pavan A., Ogliari E., Leva S., Lughi V. *Advanced Methods for Photovoltaic Output Power Forecasting: A Review*. Applied Sciences. 2020. Vol. 10. 487. DOI: 10.3390/app10020487.
18. Benavides Cesar L., Amaro e Silva R., Manso Callejo M.Á., Cira C.I. *Review on Spatio-Temporal Solar Forecasting Methods Driven by In Situ Measurements or Their*

*Combination with Satellite and Numerical Weather Prediction Estimates*. *Energies*. 2022. Vol. 15. 4341. DOI: 10.3390/en15124341.

19. Mohamad Radzi P.N.L., Akhter M.N., Mekhilef S., Mohamed Shah N. *Review on the Application of Photovoltaic Forecasting Using Machine Learning for Very Short-to Long-Term Forecasting*. *Sustainability*. 2023. Vol. 15. 2942. DOI: 10.3390/su15042942.

20. Haider S.A., Sajid M., Sajid H., Uddin E., Ayaz Y. *Deep Learning and Statistical Methods for Short- and Long-Term Solar Irradiance Forecasting for Islamabad*. *Renewable Energy*. 2022. Vol. 198. P. 51–60. DOI: 10.1016/j.renene.2022.07.136.

21. Ofori-Ntow Jnr E., Ziggah Y.Y., Rodrigues M.J., Relvas S. *A New Long-Term Photovoltaic Power Forecasting Model Based on Stacking Generalization Methodology*. *Natural Resources Research*. 2022. Vol. 31. P. 1265–1287. DOI: 10.1007/s11053-022-10058-3.

22. Wang, J., Wang, W. & Chen, H. *Prediction of photovoltaic power generation based on regression-Markov chain*. *Electr. Meas. Instrum.* 56(1), 76–81 (2019).

23. Wang, X. et al. *Short-term forecasting method of photovoltaic output power based on PNN/PCA/PCA/SS-SVR*. *Autom. Electr. Power Syst.* 40(17), 156–162 (2016).

24. Song, X. H. et al. *A new forecasting model based on forest for photovoltaic power generation*. *Power Syst. Prot. Control* 43(2), 13–18 (2015).

25. *Методичні вказівки до виконання розрахункової роботи з «Цивільного захисту»* / Уклад. О. В. Поліщук, М. А. Томчук. – Вінниця : ВНТУ, 2017. – 65 с.

26. *Методичні вказівки до виконання розділу з охорони праці в кваліфікаційних роботах здобувачів освітнього ступеня магістра галузі знань 14 «Електрична інженерія»* / уклад.: С. В. Дембіцька, І. М. Кобилянська, О. В. Кобилянський. – Вінниця: ВНТУ, 2022. – 52 с.

27. Бондаренко, Є. А. *Навчальний посібник до розділу «Охорона праці» в магістерських кваліфікаційних роботах для студентів спеціальності 141 – Електроенергетика, електротехніка та електромеханіка : навч. посіб. / Бондаренко Є. А., Кутін В. М., Лежнюк П. Д. – Вінниця : ВНТУ, 2018. – 120 с.*

ДОДАТКИ

## ДОДАТОК А

**ПРОТОКОЛ ПЕРЕВІРКИ НАВЧАЛЬНОЇ (КВАЛІФІКАЦІЙНОЇ) РОБОТИ**

Назва роботи: «Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком»

Тип роботи: Магістерська кваліфікаційна робота

(кваліфікаційна робота, курсовий проект (робота), реферат, аналітичний огляд, інше (вказати))

Підрозділ: Кафедра електричних станцій та систем

(кафедра, факультет (інститут), навчальна група)

Керівник: д.т.н., професор кафедри ЕСС Комар В. О.

(прізвище, ініціали, посада)

## Показники звіту подібності

StrikePlagiarism	
Оригінальність	97.8
Загальна схожість	2.52

## Аналіз звіту подібності (відмітити потрібне)

- Запозичення, виявлені у роботі, оформлені коректно і не містять ознак плагіату.
- Виявлені у роботі запозичення не мають ознак плагіату, але їх надмірна кількість викликає сумніви щодо цінності роботи і відсутності самостійності її автора. Роботу направити на доопрацювання.
- Виявлені у роботі запозичення є недобросовісними і мають ознаки плагіату та/або в ній містяться навмисні спотворення тексту, що вказують на спроби приховування недобросовісних запозичень.

Заявляю, що ознайомлений (-на) з повним звітом подібності, який був згенерований Системою щодо роботи

Автор \_\_\_\_\_  
(підпис)

Гайдарли Д. Д.  
(прізвище, ініціали)

## Опис прийнятого рішення

Робота допущена до захисту

Особа, відповідальна за перевірку \_\_\_\_\_  
(підпис)

Вишневський С. Я.  
(прізвище, ініціали)

Експерт \_\_\_\_\_  
(за потреби) (підпис) (прізвище, ініціали, посада)

## ДОДАТОК Б

## ТЕХНІЧНЕ ЗАВДАННЯ МКР

Міністерство освіти і науки України  
Вінницький національний технічний університет  
Факультет електроенергетики та електромеханіки  
Кафедра електричних станцій і систем

ЗАТВЕРДЖУЮ  
Завідувач кафедри ЕСС  
д.т.н., професор Комар В. О.  
(наук. ст., вч. зв., ініц. та прізви.)

\_\_\_\_\_ (підпис)

« \_\_\_\_ » \_\_\_\_\_ 20\_\_ р.

## ТЕХНІЧНЕ ЗАВДАННЯ

на виконання магістерської кваліфікаційної роботи

**«Прогнозування режимів функціонування фотовольтаїчних електричних станцій під час їх роботи за графіком»**

08-21.МКР.0XX.00.109 ТЗ

Керівник проекту: проф., д.т.н., зав. каф. ЕСС

\_\_\_\_\_ Комар В. О.

(підпис)

Виконавець: ст. гр. ЕС-24м

\_\_\_\_\_ Гайдарли Д. Д.

(підпис)

Вінниця 2025 р.

## **1. Підстава для виконання магістерської кваліфікаційної роботи (МКР)**

а) актуальність досліджень обумовлена тим, що сонячні фотовольтаїчні електричні станції (ФЕС) відіграють ключову роль у глобальному переході до відновлюваних джерел енергії, сприяючи амбітним планам зі збільшення потужностей зеленої енергетики до 2030 року. Однак їх продуктивність суттєво залежить від екологічних факторів, таких як сонячне випромінювання, температура, хмарність, пил та кліматичні зміни, що призводить до нестабільності генерації. Точне прогнозування режимів роботи необхідне для оптимізації інтеграції ФЕС в енергосистему, зменшення витрат на балансування та забезпечення надійності, обґрунтовуючи потребу в розробці вдосконалених методів прогнозування.

б) наказ ректора ВНТУ № 313 від 24 вересня 2025 р. про затвердження теми магістерської кваліфікаційної роботи

### **2. Мета і призначення МКР**

а) мета – розробка методу короткострокового прогнозування генерації ФЕС на основі гібридної моделі TCN-ECANET-GRU з урахуванням впливу навколишнього середовища на режими функціонування.

б) призначення розробки – забезпечення стабільної інтеграції ФЕС в енергосистему шляхом підвищення точності прогнозів, мінімізації відхилень від графіка роботи та оптимізації ресурсів для зменшення впливу екологічних факторів.

### **3. Джерела розробки**

Список використаних джерел розробки:

1. Vamisile O., Acen C., Cai D., Huang Q., Staffell I. The environmental factors affecting solar photovoltaic output // Renewable and Sustainable Energy Reviews. – 2025. – Vol. 208. – Article No. 115073. – DOI:

2. Liu C., Li M., Yu Y. та ін. A Review of Multitemporal and Multispatial Scales Photovoltaic Forecasting Methods. IEEE Access. 2022. Vol. 10. P. 35073–35093. DOI: 10.1109/ACCESS.2022.3162206.

3. Alcañiz A., Grzebyk D., Ziar H., Isabella O. Trends and Gaps in Photovoltaic Power Forecasting with Machine Learning. Energy Reports. 2023. Vol. 9. P. 447–471. DOI: 10.1016/j.egyр.2022.11.208.

### **4. Технічні вимоги до виконання МКР**

Технічні вимоги до виконання МКР

– елементна база: програмні засоби на базі Python з використанням бібліотек для машинного навчання, таких як PyTorch або TensorFlow, для реалізації нейронних мереж TCN, ECANet та GRU, а також обробки даних (numpy, pandas).

- конструктивне виконання: гібридна архітектура моделі з інтеграцією часових конволюційних мереж (TCN), уваги ECANet та рекурентних блоків GRU для обробки часових рядів даних про сонячне випромінювання та інші фактори.
- технічне обслуговування і ремонт: регулярне оновлення наборів даних, ретрейнінг моделі на нових метеорологічних даних, моніторинг продуктивності та коригування гіперпараметрів для адаптації до змінних умов експлуатації.

### 5. Економічні показники

Економічні показники включають кошторис заробітної плати розробників, витрати на обчислювальні ресурси для навчання моделі та потенційну економію від підвищення ефективності ФЕС на 10-20% за рахунок точних прогнозів.

### 6. Етапи МКР та очікувані результати

№ з/п	Назва та зміст етапів	Термін виконання етапів роботи		Очікувані результати
		початок	кінець	
1	Розроблення технічного завдання	03.09.2025	07.09.2025	формування технічного завдання
2	Вплив навколишнього середовища на режими функціонування ФЕС	08.09.2025	21.09.2025	розділ 1 ПЗ
3	Систематичний огляд методів прогнозування ФЕС	22.09.2025	05.10.2025	розділ 2 ПЗ
4	Метод короткострокового прогнозування генерації на основі гібридної моделі TCN-ECANET-GRU	06.10.2025	26.10.2025	розділ 3 ПЗ
5	Економічна частина	27.10.2025	06.11.2025	розділ 4 ПЗ
6	Заходи забезпечення надійної та безпечної експлуатації електроустановок	07.11.2025	13.11.2025	розділ 5 ПЗ
7	Оформлення пояснювальної записки	14.11.2025	23.11.2025	За вимогами
8	Виконання графічної/ілюстративної частини та оформлення презентації	24.11.2025	27.11.2025	плакати, презентація
9	Перевірка МКР на плагіат. Попередній захист МКР	28.11.2025	29.11.2025	Результат перевірки на плагіат, відгук керівника
10	Рецензування МКР	30.11.2025	30.11.2025	Відгук опонента
11	Захист МКР	Друга декада грудня		Доповідь та відповіді на запитання

## **7. Очікувані результати**

В результаті виконання магістерської кваліфікаційної роботи очікується розробка ефективного методу короткострокового прогнозування генерації ФЕС на основі гібридної моделі TCN-ECANET-GRU, який враховує екологічні фактори та підвищує точність прогнозів. Це включатиме рекомендації з оптимізації режимів роботи, економічної оцінки, заходів безпеки, а також внесок у стабільність енергосистеми та перехід до сталої енергетики.

## **8. Матеріали, що подаються до захисту МКР**

Пояснювальна записка МКР (паперовий екземпляр), ілюстративні матеріали, відгук наукового керівника, відгук опонента, анотації до МКР українською та іноземною мовами, протокол перевірки МКР на наявність текстових запозичень.

## **9. Порядок контролю виконання та захисту МКР**

Виконання етапів розрахункової документації МКР контролюється науковим керівником та завідувачем кафедри ЕСС згідно зі встановленими термінами. Захист МКР відбувається на засіданні екзаменаційної комісії, затвердженої наказом ректора.

## **10. Вимоги до оформлення МКР**

Вимоги викладені в «Положенні про кваліфікаційні роботи на другому (магістерському) рівні вищої освіти. СУЯ ВНТУ-03.02.02-П.001.01:2, 2021 р.

**11. Вимоги щодо технічного захисту інформації в МКР з обмеженим доступом**

Відсутні.

## ДОДАТОК Г

## АБРЕВІАТУРА З РИСУНКА 2 РОЗДІЛУ

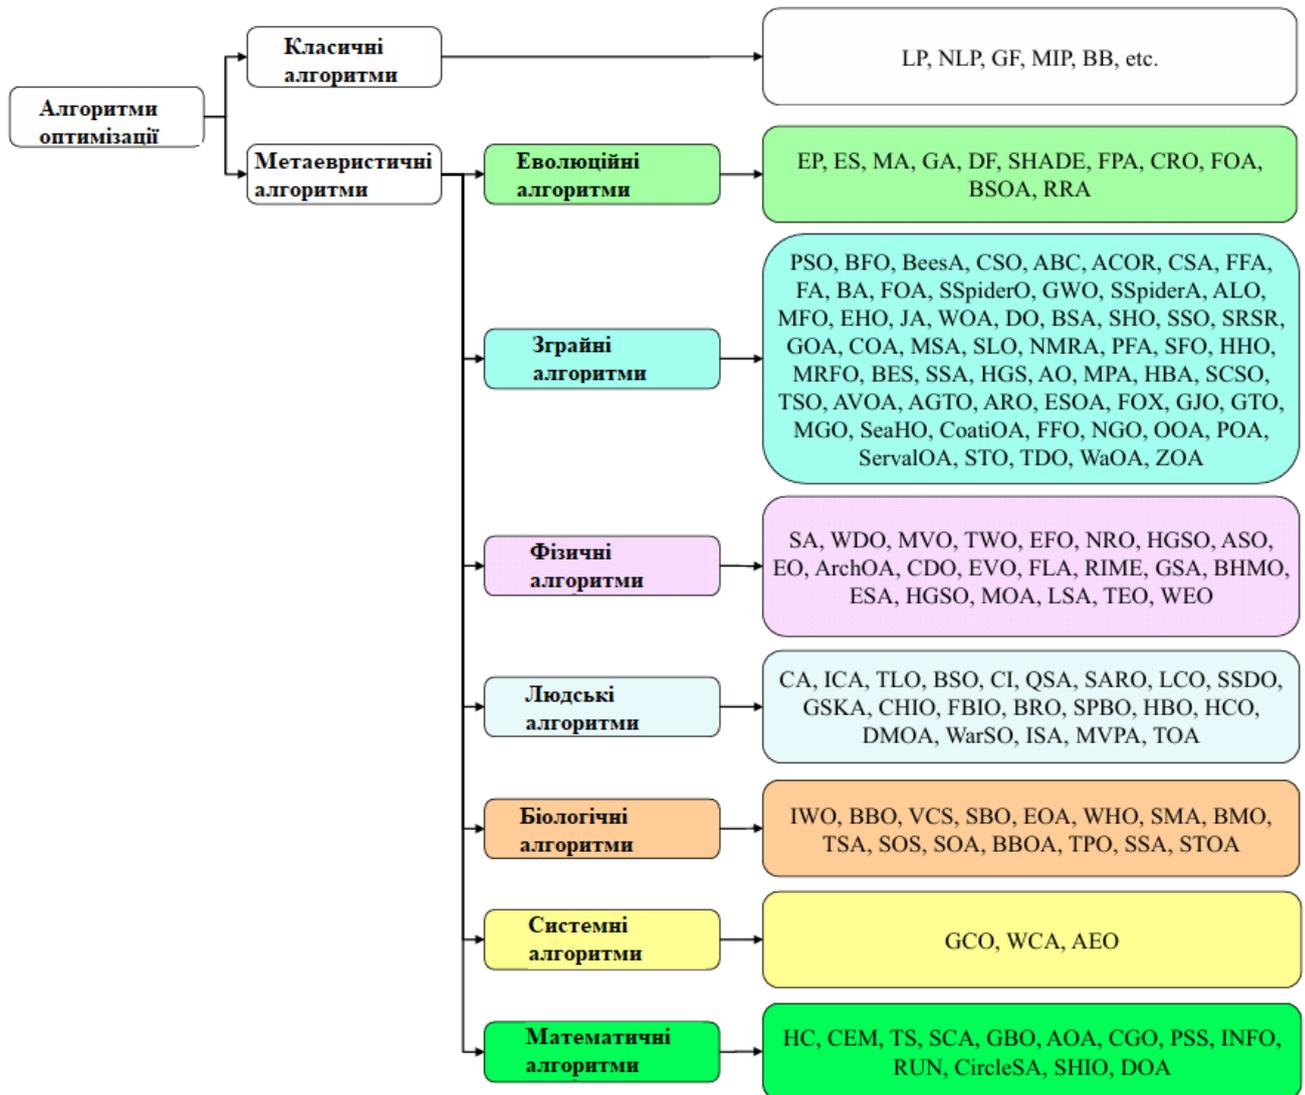


Рисунок – Алгоритми оптимізації

AE Автоенкодер MA Меметичний алгоритм

AE-GRU Автоенкодер - Ворітна рекурентна одиниця MARS Багатоваріатна адаптивна регресійна сплайн

AE-LSTM Автоенкодер - Довготривала короткострокова пам'ять MFO Оптимізація полум'я молі

AEO Штучна екосистемна оптимізація MGO Оптимізація гірського газеля

AE-ORELM AE-Оптимальна регуляризована гранична навчальна машина MIP Змішане цілочисельне програмування

AGTO Штучна оптимізація військ горил ML Машинне навчання

AI Штучний інтелект MLP Багатошаровий перцептрон

ALO Оптимізація мурах-левів MOA Магнітна оптимізація алгоритму  
 AnEn Аналоговий ансамбль MOA Магнітна оптимізація алгоритму  
 ANNs Штучні нейронні мережі MPIW Середня PIW  
 AO Оптимізація Аквіли MVE Оцінка середньої дисперсії  
 AOA Аритметична оптимізація алгоритму MVPA Найцінніший гравець  
 алгоритму  
 APSO Прискорена оптимізація зграєю частинок NGO Північний яструб  
 оптимізації  
 ArchOA Архімедова оптимізація NKDE Непараметрична оцінка щільності ядра  
 ARIMA Авторегресійна інтегрована ковзна середня NLP Нелінійне  
 програмування  
 ARO Штучна оптимізація кроликів NMRA Алгоритм голого крота-щура  
 ARTMAP Адаптивна резонансна теорія відображення NRO Ядерна реакція  
 оптимізації  
 ASO Атомний пошуковий алгоритм NLP Нелінійне програмування  
 AVOA Африканські стерв'ятники оптимізації OOA Оптимізація осокирки  
 BA Алгоритм кажана POA Оптимізація пеліканів  
 BB Гілка та межа PSS Послідовне вибіркве на основі Парето  
 BBO Оптимізація на основі біогеографії PFA Алгоритм слідопита  
 BBOA Оптимізація коричневого ведмеда POA Оптимізація пеліканів  
 BeesA Алгоритм бджіл PSS Послідовне вибіркве на основі Парето  
 BES Пошук лисого орла PSO Оптимізація зграєю частинок  
 BFO Бактеріальна оптимізація пошуку їжі PSS Послідовне вибіркве на основі  
 Парето  
 BHMO Оптимізація механіки чорної діри PV Фотоелектрика  
 BiLSTM Двонаправлений LSTM QR Квантильна регресія  
 BMO Оптимізація шлюбів барнаклів QSA Пошуковий алгоритм черги  
 BSO Оптимізація мозкового шторму RAN Мережа з розподілом ресурсів  
 BSOA Алгоритм пошуку назад RBFNN Радіально-базисна функційна нейронна  
 мережа  
 BSO Алгоритм мозкового шторму RE Відновлювана енергія  
 BSA Алгоритм пташиної зграї RESs Відновлювані джерела енергії  
 BSOA Алгоритм пошуку назад RF Випадковий ліс  
 BSO Алгоритм мозкового шторму RFR Регресор випадкового лісу  
 BSA Алгоритм пташиної зграї RIME Фізичне явище RIME-криги  
 BSOA Алгоритм пошуку назад RRA Алгоритм бігуна-кореня  
 CA Культурний алгоритм RUL Залишковий корисний термін  
 CatBoost Категорійне посилення RUN Оптимізатор Рунге-Кутта  
 CC Зміна контексту SA Симульоване відпалення

CDO Оптимізація Чорнобильської катастрофи SARO Пошуково-рятувальна оптимізація  
 SEM Метод перехресної ентропії SBO Оптимізація сатинової альтанки  
 CGO Оптимізація хаотичної гри SC Спектральна кластеризація  
 CHIO Оптимізація колективного імунітету коронавірусу SCN Стохастична конфігураційна мережа  
 CI Когортний інтелект SFLA Алгоритм стрибків жаб  
 CircleSA Алгоритм пошуку кола SHADE Успішно-історична адаптація диференціальної еволюції  
 CIs Інтервали довіри SHIO Успішно-історична інтелектуальна оптимізація  
 CMV Вектор руху хмар SHO Оптимізація плямистої гієни  
 CNN Згортовка нейронна мережа SLO Оптимізація морського лева  
 COA Оптимізація койота SMA Алгоритм плісняви слизу  
 CoatiOA Оптимізація коати SOA Оптимізація морської чайки  
 CRO Оптимізація коралових рифів SOM Самоорганізуюча карта  
 CRPSO Божевільний PSO SOS Симбіотичні організми пошуку  
 CSA Алгоритм пошуку кукушки SOINN Самоорганізуюча інкрементальна нейронна мережа  
 CSO Алгоритм котячої зграї SOS Симбіотичні організми пошуку  
 BSOA Алгоритм пошуку назад SOA Оптимізація коричневого ведмеда  
 BSO Алгоритм мозкового штурму STOA Оптимізація сої тіна  
 BSOA Алгоритм пошуку назад SVR Регресія опорних векторів  
 BSA Алгоритм пташиної зграї SVM Машина опорних векторів  
 BSOA Алгоритм пошуку назад TDO Оптимізація тасманійського диявола  
 CA Культурний алгоритм TEO Теплова обмінна оптимізація  
 CatBoost Категорійне посилення TLO Оптимізація на основі навчання-викладання  
 CC Зміна контексту TSA Оптимізація тунікатного рою  
 CDO Оптимізація Чорнобильської катастрофи TPO Оптимізація фізіології дерева  
 SEM Метод перехресної ентропії TSA Оптимізація тунікатного рою  
 CGO Оптимізація хаотичної гри TSO Оптимізація туни зграї  
 CHIO Оптимізація колективного імунітету коронавірусу TWO Оптимізація перетягування каната  
 CI Когортний інтелект VAR Векторна авторегресія  
 CircleSA Алгоритм пошуку кола VCS Пошуку колонії вірусів  
 CIs Інтервали довіри VPP Віртуальна електростанція  
 CMV Вектор руху хмар WaOA Оптимізація моржа  
 CNN Згортовка нейронна мережа WarSO Оптимізація воєнної стратегії  
 COA Оптимізація койота WCA Цикл води

CoatiOA Оптимізація коати WDO Оптимізація вітровим рухом  
 CRO Оптимізація коралових рифів WEO Оптимізація випаровування води  
 CRPSO Божевільний PSO WHO Оптимізація стада диких коней  
 CSA Алгоритм пошуку кукушки WOA Оптимізація кита  
 CSO Алгоритм котячої зграї ZOA Оптимізація зебри  
 DBNs Мережі глибокої віри W Виміряні/прогнозовані погодні умови  
 DCNN Глибока згорткова нейронна мережа WH Історичні погодні умови  
 DF Диференціальна еволюція  $\rightarrow$  P Н Історичні дані виробництва сонячної  
 фотоелектрики  
 DL Глибоке навчання P Фактична сонячна PV потужність  
 DLSTM Глибока довготривала короткострокова пам'ять  $\wedge$  P Прогнозована сонячна  
 PV потужність  
 DMOA Оптимізація карликового мангуста  $\wedge$  PLB,  $\wedge$  PUB Нижня та верхня межі  
 прогнозованого виробництва  
 DNNs Глибокі нейронні мережі  $\alpha$  Попередньо визначений рівень довіри  
 DO Оптимізація дракона N Загальна кількість тестових даних  
 DOA Оптимізація Дарсі I Індекс тестової точки даних  
 DTs Дерева рішень E Проста помилка  
 EE Еволюціонуюче середовище nE Нормалізована проста помилка  
 EFO Електромагнітне поле оптимізації MBE Середня зміщена помилка  
 EHO Оптимізація стада слонів nMBE Нормалізована MBE  
 ELM Гранична навчальна машина MAE Середня абсолютна помилка  
 EMD Емпірична декомпозиція режиму RMSE Корінь середньої квадратичної  
 помилки  
 EO Оптимізація рівноваги nRMSE Нормалізована RMSE  
 EOA Оптимізація земляного хробака MAPE Середня абсолютна відсоткова  
 помилка  
 EP Еволюційне програмування nMAPE Нормалізована MAPE  
 ESs Стратегії еволюції MdAPE Медіанна абсолютна відсоткова помилка  
 ESA Електропошуковий алгоритм WMAE Зважена MAE  
 ESN Мережа стану відлуння R2 Коефіцієнт детермінації  
 ESOA Оптимізація ластівки-егоїста  $P_i$  та  $\hat{P}_i$  Фактична та прогнозована  
 потужність, відповідно  
 EVO Оптимізація енергетичної долини N Загальна кількість тестових даних  
 FA Алгоритм вогню P Середня фактична потужність  
 FBIO Оптимізація на основі криміналістики  
 FCDT Швидке видалення викидів алгоритм та дерево рішень  
 FFA Алгоритм вогню мухи  
 FFNN Передня нейронна мережа

FFO Оптимізація фенекового лиса  
FLA Алгоритм закону Фіка  
FOA Оптимізація плодової мухи (зграйний)  
FOA Оптимізація лісу (еволюційний)  
FOX Оптимізатор лиса  
FPA Алгоритм запилення квітки  
GA Генетичний алгоритм  
GAN Генеративна змагальна мережа  
GBO Оптимізація на основі градієнта  
GCO Оптимізація центру зародження  
GD Градієнтний спуск  
GF Безградієнтний  
GJO Оптимізація золотого шакала  
GMMs Моделі гауссових сумішей  
GOA Оптимізація трав'яної кози  
GPR Гауссів процес регресії  
GPS Загальний патерн пошуку  
GRU Ворітна рекурентна одиниця  
GSA Гравітаційний пошуковий алгоритм  
GSKA Алгоритм обміну знаннями  
GTO Гігантський треваллі оптимізації  
GWO Оптимізація сірого вовка  
HBA Оптимізація медоносного борсука  
HBO Оптимізація на основі купи  
HCO Оптимізація людського концепту  
HGS Пошуки голодних ігор  
HGSO Оптимізація розчинності газу Генрі  
HNO Оптимізація яструбів Харріса  
IAO Покращена оптимізація Аквіли  
IBLS Інкрементальна широка система навчання  
ICA Імперіалістичний конкурентний алгоритм  
IDE Покращена DE  
IL Інкрементальне навчання  
INFO Ваговий середній векторів  
ISA Інтерактивний пошуковий алгоритм  
ISSA Покращений алгоритм пошуку горобця  
IWBOA Покращена оптимізація кита-кажана  
IWO Інвазивна бур'ян оптимізації  
IWOA Покращена оптимізація кита

JA Алгоритм Джая  
KDE Оцінка щільності ядра  
K-*nn* K-найближчі сусіди  
LASSO Найменша абсолютна усадка та оператор вибору  
LCO Оптимізація на основі вибору життя  
LightGBMs Легкі градієнтні посилюючі машини  
Linear Programming Лінійне програмування  
LR Лінійна регресія  
LSA Алгоритм пошуку блискавки  
LS-SVM Найменші квадрати SVM  
LSSVR Найменші квадрати SVR  
LSTM Довготривала короткострокова пам'ять  
LUPІ Навчання з використанням привілейованої інформації  
MA Меметичний алгоритм  
MAE Середня абсолютна помилка  
MAPE Середня абсолютна відсоткова помилка  
MARS Багатоваріатна адаптивна регресійна сплайн  
MBE Середня зміщена помилка  
MdAPE Медіанна абсолютна відсоткова помилка  
MFO Оптимізація полум'я молі  
MGO Оптимізація гірського газеля  
MIP Змішане цілочисельне програмування  
ML Машинне навчання  
MLP Багатошаровий перцептрон  
MOA Магнітна оптимізація алгоритму  
MPIW Середня PIW  
MVE Оцінка середньої дисперсії  
MVPA Найцінніший гравець алгоритму  
NGO Північний яструб оптимізації  
NKDE Непараметрична оцінка щільності ядра  
NLP Нелінійне програмування  
NMRA Алгоритм голого крока-щура  
NRO Ядерна реакція оптимізації  
OOA Оптимізація осокирки  
ORELM Оптимальна регуляризована ELM  
OS-ELMs Онлайн послідовні ELMs  
PCA Метод головних компонент  
PCC Коефіцієнт кореляції Пірсона  
PFA Алгоритм слідопита

PICP Ймовірність покриття PI  
PIs Інтервали прогнозування  
PIW Ширина PI  
PM Модель стійкості  
POA Оптимізація пеліканів  
PSS Послідовне вибіркоче на основі Парето  
PFA Алгоритм слідопита  
PSO Оптимізація зграєю частинок  
PSS Послідовне вибіркоче на основі Парето  
PV Фотоелектрика  
QR Квантильна регресія  
QSA Пошуковий алгоритм черги  
RAN Мережа з розподілом ресурсів  
RBFNN Радіально-базисна функційна нейронна мережа  
RE Відновлювана енергія  
RESs Відновлювані джерела енергії  
RF Випадковий ліс  
RFR Регресор випадкового лісу  
RIME Фізичне явище RIME-криги  
RRA Алгоритм бігуна-кореня  
RUL Залишковий корисний термін  
RUN Оптимізатор Рунге-Кутта  
SA Симульоване відпалення  
SARO Пошуково-рятувальна оптимізація  
SBO Оптимізація сатинової альтанки  
SC Спектральна кластеризація  
SCN Стохастична конфігураційна мережа  
SFLA Алгоритм стрибків жаб  
SFO Оптимізація вітрильника  
SHIO Успішно-історична інтелектуальна оптимізація  
SHO Оптимізація плямистої гієни  
SLO Оптимізація морського лева  
SMA Алгоритм плісняви слизу  
SOA Оптимізація морської чайки  
SOM Самоорганізуюча карта  
SOS Симбіотичні організми пошуку  
SOINN Самоорганізуюча інкрементальна нейронна мережа  
SOS Симбіотичні організми пошуку  
SOA Оптимізація коричневого ведмеда

STOA Оптимізація сої тіна  
 SVR Регресія опорних векторів  
 SVM Машина опорних векторів  
 TDO Оптимізація тасманійського диявола  
 TEO Теплова обмінна оптимізація  
 TLO Оптимізація на основі навчання-викладання  
 TOA Оптимізація командної роботи  
 TPO Оптимізація фізіології дерева  
 TSA Оптимізація тунікатного рою  
 TSO Оптимізація туни зграї  
 TWO Оптимізація перетягування каната  
 VAR Векторна авторегресія  
 VCS Пошуку колонії вірусів  
 VPP Віртуальна електростанція  
 WaOA Оптимізація моржа  
 WarSO Оптимізація воєнної стратегії  
 WCA Цикл води  
 WDO Оптимізація вітровим рухом  
 WEO Оптимізація випаровування води  
 WHO Оптимізація стада диких коней  
 WOA Оптимізація кита  
 ZOA Оптимізація зебри  
 W Прогнозовані/виміряні погодні умови  
 WH Історичні погодні умови  
 →P H Історичні дані виробництва сонячної фотоелектрики  
 P Фактична сонячна PV потужність  
 ^P Прогнозована сонячна PV потужність  
 ^PLB, ^PUB Нижня та верхня межі прогнозованого виробництва  
 $\alpha$  Попередньо визначений рівень довіри  
 N Загальна кількість тестових даних  
 I Індекс тестової точки даних  
 E Проста помилка  
 nE Нормалізована проста помилка  
 MBE Середня зміщена помилка  
 nMBE Нормалізована MBE  
 MAE Середня абсолютна помилка  
 RMSE Корінь середньої квадратичної помилки  
 nRMSE Нормалізована RMSE  
 MAPE Середня абсолютна відсоткова помилка

nMAPE Нормалізована MAPE

MdAPE Медіанна абсолютна відсоткова помилка

WMAE Зважена MAE

R2 Коефіцієнт детермінації

ДОДАТОК Д  
ІЛЮСТРАТИВНА ЧАСТИНА

**«ПРОГНОЗУВАННЯ РЕЖИМІВ ФУНКЦІОНУВАННЯ  
ФОТОВОЛЬТАЇЧНИХ ЕЛЕКТРИЧНИХ СТАНЦІЙ ПІД ЧАС ЇХ РОБОТИ  
ЗА ГРАФІКОМ»**