

ПІДВИЩЕННЯ ЯКОСТІ КОРОТКОСТРОКОВОГО ПРОГНОЗУВАННЯ ОБСЯГІВ ГЕНЕРУВАННЯ ФОТОЕЛЕКТРИЧНИХ СТАНЦІЙ НА ОСНОВІ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ

¹Вінницький національний технічний університет

Проведено поглиблене дослідження сучасних підходів до прогнозування генерування електроенергії сонячними фотоелектричними станціями (ФЕС), що є важливим елементом розвитку відновлюваної енергетики в умовах децентралізованого енергопостачання та зростання частки «зеленої» енергії в енергобалансі. Особливу увагу приділено моделі Sensitivity-Enhanced Recurrent Neural Network (SERNN), яка поєднує переваги рекурентних нейронних мереж з адаптивною чутливістю до змін вхідних метеорологічних параметрів. Запропонований підхід базується на врахуванні ключових кліматичних факторів, що безпосередньо впливають на обсяги вироблення сонячної енергії, зокрема глобальної сонячної радіації, температури довкілля, ступеня хмарності, а також сезонних коливань. Показано, що на відміну від класичних моделей, таких як лінійна регресія або традиційні нейромережі типу LSTM, модель SERNN демонструє здатність до гнучкого реагування на швидкоплинні зміни погодних умов завдяки вбудованому механізму динамічної адаптації вагових коефіцієнтів. В дослідженні детально розглянуто етапи попередньої обробки вхідних даних, які є критично важливими для забезпечення якості навчання та точності прогнозу, зокрема: масштабування (нормалізація) показників, кодування часових ознак у вигляді синусоїдальних функцій для відображення добових та сезонних циклів, а також фільтрація або корекція аномальних значень, які можуть спотворювати результати моделі. На основі реальних даних спостережень з декількох фотоелектричних установок експериментально підтверджено високу ефективність застосування SERNN у задачах короткострокового прогнозування. Зокрема, зафіксовано істотне зниження середньої абсолютної похибки (MAE) та кореня середньоквадратичної похибки (RMSE) у порівнянні з альтернативними підходами. Запропонована модель також продемонструвала стабільність результатів у періоди з високою мінливістю погодних умов, що особливо важливо для енергетичного планування та оптимізації роботи мереж. Загалом дослідження підтверджує потенціал глибоких нейромереж з чутливим механізмом до метеоумов як перспективного інструменту для точного прогнозування генерування ФЕС. Це відкриває нові можливості для інтеграції відновлюваних джерел енергії в енергосистему з мінімізацією технічних і фінансових ризиків, пов'язаних з небалансами.

Ключові слова: фотоелектричні станції, прогнозування генерування, модель SERNN, машинне навчання, метеорологічні дані, короткострокове прогнозування.

Вступ

Інтеграція фотоелектричних станцій (ФЕС) у сучасні енергосистеми є ключовим фактором декарбонізації та розвитку відновлюваної енергетики. ФЕС забезпечують генерацію електроенергії без шкідливих викидів, знижуючи залежність від викопних палив. Проте їх масове впровадження супроводжується низкою технічних викликів, зокрема через високу залежність від погодних умов. На відміну від класичних енергогенерувальних джерел, генерування ФЕС має стохастичний характер: коливання сонячної радіації, зміни хмарності, температура повітря, а також сезонні цикли призводять до суттєвих флуктуацій у генеруванні.

Нестабільність генерування створює серйозні ризики для енергосистеми, особливо за умов ви-

сокої проникності ВДЕ. Хибно спрогнозоване зниження виробітку призводить до дисбалансів, змушує операторів залучати резервні потужності або обмежувати генерацію. Це не лише знижує економічну ефективність, а й ускладнює забезпечення надійності та гнучкості роботи мереж. Проблема посилюється в регіонах з високою кліматичною мінливістю, де відносна похибка прогнозу може досягати 20...30 %, а також у перехідні періоди року (весна, осінь), коли погодні зміни відбуваються швидко й непередбачувано [1].

З огляду на це, завдання короткострокового прогнозування генерування ФЕС (на горизонтах 1—24 години) набуває стратегічного значення. Якісні прогнози дають змогу оптимізувати балансування, зменшувати витрати на резерви, скорочувати вартість небалансів і, таким чином, підвищувати ефективність роботи об'єднаної енергосистеми. З практичної точки зору це також створює передумови для інтеграції більшого обсягу ВДЕ без шкоди для стабільності енергосистеми.

У відповідь на ці виклики, в останні роки активно розвиваються підходи до прогнозування з використанням методів машинного навчання. Ці методи дають змогу враховувати нелінійні та багатовимірні взаємозв'язки між метеорологічними параметрами та генерацією. Серед протестованих підходів (лінійна регресія, XGBoost, Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU)), модель Sensitivity-Enhanced Recurrent Neural Network (SERNN) продемонструвала найкращі результати завдяки здатності враховувати короткочасну мінливість і реагувати на швидкі зміни зовнішніх факторів. Механізм чутливості в SERNN забезпечує динамічну адаптацію до нових умов, зберігаючи стабільність моделі навіть у разі неочікуваних відхилень.

Таким чином, *метою роботи є дослідження та практична реалізація моделі SERNN як перспективного інструменту для короткострокового прогнозування генерації сонячної енергії*. Особливий акцент зроблено на перевірці її здатності адаптуватися до змін метеорологічних умов у реальному середовищі функціонування ФЕС, з урахуванням сезонної варіативності, хмарності, радіаційного фону та температурних коливань. Робота спрямована на оцінювання ефективності SERNN у порівнянні з іншими підходами та визначення її потенціалу для впровадження в задачах енергетичного прогнозування в Україні.

Для досягнення поставленої мети в межах дослідження сформульовано низку взаємопов'язаних завдань. Насамперед, передбачалося обґрунтувати вибір моделі SERNN серед альтернативних архітектур прогнозування генерації фотоелектричних станцій, враховуючи її потенціал до адаптації в умовах високої варіативності метеоданих. Наступним етапом стало технічне налаштування моделі: реалізовано розширений блок попередньої обробки даних, що забезпечує очищення, нормалізацію та формування структурованих вхідних ознак. Особливу увагу приділено включенню часових ознак — циклічних компонент добового та сезонного характеру для повнішого відображення природної динаміки генерації.

Після цього здійснено гіперпараметричну оптимізацію архітектури SERNN, яка охоплювала вибір кількості нейронів, рівня регуляризації, розміру навчальних пакетів та швидкості навчання. Для забезпечення об'єктивного оцінювання моделі сформовано набір погодних сценаріїв, що охоплювали як стандартні (ясні дні), так і складні (перемінна хмарність, температурні коливання) умови. На їх основі проведено обчислювальний експеримент з розрахунком ключових метрик точності прогнозування (MAE, RMSE). Завершальним етапом стало порівняння ефективності SERNN з базовими підходами — лінійною регресією, моделями LSTM та Random Forest — для виявлення її переваг у контексті різних кліматичних умов.

Аналіз публікацій у напрямку дослідження

Методи прогнозування генерування фотоелектричних станцій розвиваються в кількох напрямках: статистичне моделювання, машинне навчання та гібридні підходи. Кожен з них має специфіку застосування, рівень точності та обмеження.

На ранніх етапах розвитку тематики прогнозування сонячного генерування пріоритетними були статистичні методи, зокрема авторегресійні моделі (AR), ковзне середнє (MA), а також комбінації ARMA/ARIMA. Їхня перевага полягає у відносній простоті реалізації, хорошій інтерпретованості та здатності моделювати сезонні коливання. У роботі [2] розглянуто переваги ARIMA для задач з передбачуваними тенденціями генерування. Проте зазначені моделі припускають стаціонарність процесу та лінійність залежностей, що не відповідає реальній природі зміни метеорологічних умов. Тому точність їхніх прогнозів різко знижується за високої варіативності погодних факторів.

Поширеним напрямом є розширення ARIMA-архітектури за допомогою нейронних мереж. На-

приклад, [3] демонструє ефективність моделі ARIMA-ANN, де залишкові похибки ARIMA обробляються штучною нейронною мережею, що дає змогу врахувати нелінійні компоненти генерування. Такий підхід зменшує середню похибку прогнозу на 15...20 % у порівнянні з чисто статистичними моделями.

Інший напрям розвитку — методи машинного навчання, що не вимагають апріорного припущення про розподіл даних чи лінійність. Метод опорних векторів (SVM), дерева прийняття рішень, Random Forest, XGBoost, — усі вони забезпечують ефективну обробку великих масивів даних, зокрема метеодані, часові та топографічні фактори. У дослідженні [4] Random Forest забезпечує високу точність прогнозу в короткостроковій перспективі, зберігаючи стійкість до викидів і втрати певної кількості даних. Це забезпечує надійність моделі в умовах роботи з даними реальних інформаційно-вимірювальних систем.

Особливу категорію становлять часові нейронні мережі, зокрема рекурентні мережі (RNN), які враховують залежності між послідовними значеннями. Мережі LSTM, запропоновані в [5], довели свою здатність зберігати інформацію про довгі послідовності та забезпечувати точний прогноз у задачах енергетики. Вони мають переваги над класичними RNN завдяки контролю за передачею інформації через спеціальні «вікна пам'яті», що особливо актуально для моделювання добових/сезонних циклів генерування.

У роботі [6] порівнюється LSTM з іншими архітектурами (GRU, Feedforward Neural Network (FFNN), SVR), де LSTM продемонстрував найменше відхилення прогнозу в умовах змінної хмарності. Водночас, недоліком LSTM залишається відносно висока обчислювальна складність та потреба в великому обсязі навчальних даних.

Окремо варто відмітити інтеграцію погодних моделей NWP (Numerical Weather Prediction) з машинним навчанням. Як зазначено в [7], використання прогнозів погоди як вхідних параметрів (радіація, температура, хмарність) суттєво підвищує точність моделей, проте потребує складної попередньої обробки. Для згладжування шумів використовують методи експоненційного згладжування, фільтрацію аномалій, побудову циклічних змінних (добових, сезонних).

Комбінування підходів (гібридні моделі) є ще одним ефективним напрямом. У [8] автори розглядають поєднання ARIMA і LSTM як спосіб компенсації недоліків кожної моделі окремо: лінійна частина прогнозу моделюється ARIMA, а нелінійна — LSTM. Аналогічно, у [9] описано модель Random Forest + FFNN, де Random Forest виконує попередню селекцію ознак, а FFNN — кінцеве прогнозування. Це дозволяє зменшити перенавчання та покращити інтерпретованість.

У межах цієї роботи розглядається модель SERNN (Sensitivity-Enhanced Recurrent Neural Network). Вона комбінує архітектуру RNN з вбудованим механізмом чутливості до динаміки змін вхідних метеоданих. На відміну від LSTM, SERNN автоматично масштабує ваги параметрів залежно від змін у хмарності, температурі чи радіації без необхідності ручного втручання. У літературі модель згадується зрідка, проте її компоненти окремо розглянуті в [10] у контексті підвищення адаптивності прогнозу. З урахуванням цього, впровадження SERNN у контексті прогнозування генерування ФЕС для енергосистеми України є логічним продовженням попередніх досліджень [11].

Результати дослідження

Проблема точного прогнозування графіків генерування фотоелектричних станцій (ФЕС) на короткостроковий період є ключовим завданням для сучасних енергосистем. Одним з перспективних методів для її вирішення є використання адаптивної моделі Sensitivity-Enhanced Recurrent Neural Network (SERNN), яка поєднує в собі переваги рекурентних нейронних мереж і механізму чутливості до мінливих зовнішніх факторів. Завдяки цій особливості модель дозволяє не лише враховувати динаміку змін погоди, але й виділяти ключові фактори, що найбільше впливають на генерацію ФЕС.

Для побудови моделі використано набір даних, який включав ретроспективні значення сонячної радіації, температури повітря, хмарності, вологості та кількості опадів. Ці параметри відображають ключові фактори, що визначають продуктивність ФЕС у різних погодних умовах. Дані охоплювали період у 12 місяців з погодинним інтервалом, що дозволило моделі врахувати сезонні та добові коливання.

Першим кроком дослідження стала підготовка даних. Вхідні значення нормалізовано до діапазону $[0, 1]$, що забезпечило однакову вагу різним змінним. Додатково додано циклічні змінні, що представляли час доби, що дозволило моделі ефективніше враховувати періодичність змін освітленості. Для зменшення впливу аномальних значень застосовано методи очищення даних, такі як

тримінг екстремальних значень та фільтрація за критеріями консистентності.

Модель SERNN навчалася з використанням 80 % вибірки, тоді як решта 20 % даних використовувалася для тестування. Під час навчання використовувався механізм уваги, який дозволив виділяти найзначущі змінні для кожного періоду часу. Це забезпечило високий рівень адаптивності моделі до локальних кліматичних умов, що є критично важливим для експлуатації ФЕС.

Підготовка даних включала такі етапи:

1. *Нормалізація*. Значення всіх числових змінних приведено до діапазону $[0, 1]$. Це забезпечило рівний внесок кожної змінної у процес навчання.

2. *Фільтрація даних*. Використовувалися методи видалення аномалій, такі як тримінг п'яти відсотків крайніх значень та аналіз викидів за міжквартильним діапазоном.

3. *Перетворення часу доби*. Оскільки освітленість упродовж доби змінюється циклічно (з максимумом у полудень і мінімумом уночі), традиційне числове представлення часу (наприклад, у годинах від 0 до 23) є неоптимальним для моделей машинного навчання — між 23:00 та 00:00 виникає штучний «розрив». Щоб уникнути цього, час перетворено у дві окремі змінні:

$$\sin(2\pi t/24) \text{ та } \cos(2\pi t/24), \text{ де } t — \text{година доби.}$$

Таке подання дозволяє моделі сприймати час як безперервне коло, де початок і кінець (наприклад, 0:00 і 24:00) плавно переходять один в одного. Це особливо важливо для відображення добового профілю генерації сонячної енергії, який має виражену циклічну форму — відсутність генерації вночі, наростання вранці, пік у середині дня та спад у другій половині доби.

4. *Формування часових вікон*. Для прогнозування генерування на наступну годину використовувалися дані за попередні 24 години.

Навчання моделі здійснювалося протягом 100 епох із застосуванням регуляризації (dropout 0.2) для уникнення перенавчання. Модель також використовувала функцію ранньої зупинки для припинення навчання за відсутності покращень на валідаційних даних.

На рис. 1 показано процес формування часових вікон для навчання моделі SERNN, що є ключовим елементом у роботі з часовими рядами. Кожне прогнозоване значення (наприклад, потужність генерування на найближчу годину) обчислюється на основі історичних даних, отриманих з



Рис. 1. Процес формування часових вікон для навчання моделі

серії. Така структура навчання дозволяє SERNN ефективно захоплювати часові залежності, виявляти значущі патерни у даних і формувати точніші прогнози у складних умовах. Додаткове маркування «Training Data» вказує на інтервал, який безпосередньо використовується для оптимізації ваг моделі на кожному кроці навчання. Цей підхід є стандартом для побудови рекурентних моделей, що працюють у режимі онлайн-оновлення прогнозів. Модель побудована на основі рекурентних нейронних мереж (RNN) і включає кілька ключових компонентів: вхідний шар, блок LSTM (Long Short-Term Memory), механізм уваги (Attention Mechanism) та вихідний шар для формування прогнозу. Блок LSTM виступає основним елементом, що враховує довготривалі залежності у часових рядах — це особливо важливо для задач прогнозування генерування ФЕС.

Механізм уваги доповнює модель, дозволяючи зосереджуватися на найвпливовіших змінних для кожного періоду часу, що значно підвищує точність прогнозів. Вихідний шар забезпечує генерацію результатів у відносних одиницях, через що модель є гнучкою для роботи з різними масштабами даних.

Архітектура моделі, яка поєднує ці компоненти, подана на рис. 2. Вхідні дані, що складаються з

Архітектура моделі SERNN




Рис. 2. Архітектура моделі рекурентної нейронної мережі з підвищеною чутливістю




Рис. 3. Гіперпараметри нейромережі SERNN




Рис. 4. Зміна функції втрат на навчальній і валідаційній вибірках під час навчання моделі SERNN

часових рядів, спочатку обробляються блоком LSTM для аналізу залежностей, після чого проходять через механізм уваги для визначення найзначущіших змінних. Остаточний прогноз формується у вихідному шарі, адаптуючи модель до специфічних умов даних.

Для побудови моделі SERNN проведено оптимізацію налагоджувальних параметрів з метою досягнення максимальної точності прогнозування генерації сонячної енергії та забезпечення стабільної збіжності процесу навчання (рис. 3).

Відбір параметрів здійснювався експериментальним шляхом з використанням сіткового пошуку (Grid Search) та покрокового аналізу похибок на валідаційній вибірці (рис. 4). Для кожної конфігурації моделі оцінювалися ключові метрики (MAE, RMSE), а також поведінка втрат у процесі навчання для запобігання перенавчанню або деградації якості прогнозу.

У результаті відібрано таку конфігурацію параметрів, яка забезпечила найкращий баланс між точністю та стабільністю:

- *Розмірність входу*: 5 змінних (радіація, температура, хмарність тощо), представлених у вигляді окремих часових рядів;

- *Кількість вузлів LSTM*: 64 — дозволяє моделі ефективно враховувати як короткочасні, так і довготривалі залежності між значеннями;

- *Функції активації*: ReLU — для проміжних шарів, сигмоїдна (sigmoid) — для вихідного шару;

- *Функція втрат*: середньоквадратична відносна похибка (MSE), що мінімізує різницю між прогнозованими та фактичними значеннями;

- *Оптимізатор*: Adam з початковою швидкістю навчання 0,001, який забезпечує швидку та стабільну збіжність навіть за складних умов навчання.

На рис. 5 показано вплив основних гіперпараметрів (Dropout, кількість вузлів LSTM, розмір пакета, коефіцієнт навчання) на

помилку моделі SERNN під час навчання та валідації. Побудова таких кривих дозволила обґрунтовано підібрати оптимальні значення параметрів і запобігти перенавчанню.




Рис. 5. Чутливість моделі SERNN до гіперпараметрів

Для підвищення узагальненості моделі застосовані такі методи:

1. Dropout-регуляризація — ймовірність виключення вузлів під час навчання становила 20 %, що зменшило залежність моделі від окремих тренувальних прикладів.
2. Аналіз чутливості до гіперпараметрів — для кожного параметра побудовано залежність помилки від значення, що дозволило знайти стабільні налаштування моделі.
3. Крос-валідація — оцінювання моделі на кількох підмножинах даних дало змогу перевірити її узагальнювальну здатність.
4. Нормалізація вхідних змінних — приведення всіх параметрів до одного масштабу зменшило ризик домінування окремих ознак.

На рис. 6 показано порівняння фактичних та прогнозованих значень генерування для фотоелектричної станції ФЕС-1 за 10 днів квітня 2021 року.




Рис. 6. Фактичні та прогнозовані значення генерування для ФЕС-1 (6—15 квітня 2021 р.)

Фактичні значення (синя лінія) відображають реальний обсяг виробленої електроенергії, тоді як прогнозовані значення (помаранчева пунктирна лінія) є результатом моделювання за допомогою нейронної мережі SERNN. Графік демонструє, що модель ефективно відтворює загальні тенденції

генерування ФЕС-1, особливо в періоди з інтенсивною сонячною активністю, коли генерування досягає своїх максимальних значень. Це вказує на здатність SERNN адаптуватися до складних нелінійних залежностей між метеорологічними факторами та обсягами генерування. Водночас спостерігаються певні відхилення між фактичними та прогнозованими значеннями, які мають випадковий характер. Основними причинами таких відхилень можуть бути різкі зміни у погодних умовах, наприклад, раптовий прихід хмарності або локальні аномалії, які не завжди можуть бути точно передбачені навіть за наявності ретельної підготовки даних.

Графіки рис. 6 демонструють, що модель SERNN загалом коректно відтворює денний профіль генерування. Найкраща відповідність спостерігається у дні з чітко вираженою сонячною активністю, коли крива генерування має гладку, симетричну форму. Це свідчить про здатність моделі ефективно фіксувати загальні закономірності, характерні для типових безхмарних днів.

Водночас на окремих графіках помітні відхилення прогнозованих значень від фактичних — особливо в умовах хмарності або нестабільної радіації. Такі відхилення, здебільшого, є випадковими та пов'язані з локальними погодними аномаліями або змінами, що не завжди фіксуються в метеорологічних прогнозах (наприклад, тимчасова хмарність, туман, пил тощо).

За результатами прогнозування, відносна похибка становила 36,14 % за період квітня 2021 року (години, коли ФЕС-1 була обмежена, не враховані). Такий показник відображає відносно задовільну точність моделі SERNN для прогнозованого періоду. Аналіз відхилень показав:

- 51 % прогнозів завищені, тобто модель переоцінила генерацію;
- 49 % — занижені, що вказує на відсутність систематичного зсуву або тенденції в одну сторону.

Такий результат є задовільним для короткострокового прогнозування сонячної генерації, що підтверджує ефективність вибраної архітектури SERNN. Водночас спостерігаються певні відхилення між фактичними та прогнозованими значеннями, які мають випадковий характер. Основними причинами таких відхилень можуть бути різкі зміни у погодних умовах, наприклад, раптовий прихід хмарності або локальні аномалії, які не завжди можуть бути точно передбачені навіть за наявності ретельної підготовки даних.

Хоча в липні (рис. 7) модель показала нижчу відносну похибку (близько 23 %) порівняно з квітневими ~36 %, це значення не можна вважати задовільним у контексті специфіки літнього сезону. Влітку інсоляція зазвичай стабільніша, тривалість світлового дня максимальна, а добовий профіль генерації — чітко виражений і легко прогнозований. Саме тому навіть відносно низьке значення похибки в цьому випадку свідчить про певні недопрацювання моделі або обмеження вхідних даних.




Рис. 7. Фактичні та прогнозовані значення генерування для ФЕС-1 (6—15 липня 2021 р.)

Можливими причинами такої похибки є нерепрезентативність літніх сценаріїв у навчальній вибірці. Наприклад, модель могла бути недостатньо навчена на прикладах з різкими ранковими підйомами генерації або на ситуаціях, коли короткочасна хмарність накладається на період денного піку. Такі «порушення симетрії» у денному графіку є характерними саме для липня, коли спостерігається висока активність купчастих хмар у другій половині дня, що створює складні для передбачення провали чи флуктуації в генерації.

До того ж метеорологічні вхідні дані (особливо хмарність, прозорість атмосфери, локальні метеозміни) могли не відображати повною мірою реальні умови на рівні конкретної ФЕС. Наприклад, локальні грозові фронти чи повітряні маси з підвищеною вологістю, що не фіксуються прогнозною моделлю погоди, могли суттєво знизити фактичну генерацію, у той час як модель

SERNN, використовуючи загальні метеопараметри, прогнозувала значно вищі значення.

Таким чином, липнева похибка в 23 % попри зовнішню прийнятність має насторожувати, оскільки вказує на відсутність повної адаптації моделі до умов, які, за своєю природою, повинні були б бути найлегшими для прогнозування. Це підтверджує важливість сезонної перевірки якості навчальних даних і потребу у високоточних, просторово деталізованих метеоджерелах для літніх місяців, особливо в регіонах з частими локальними метеоявищами.

У жовтні (рис. 8) ситуація помітно погіршилася: відносна похибка сягнула 52 %, що є надто високим значенням і прямо вказує на проблеми з адаптацією моделі до осінніх умов. Особливість жовтня полягає не лише у зменшенні тривалості світлового дня, а й у надзвичайно високій погодній динаміці: великі добові коливання температури, поява туманів, швидке утворення низької хмарності, опади зранку й прояснення в обід, — усе це формує надзвичайно складний для моделювання фон.




Рис. 8. Фактичні та прогнозовані значення генерування для ФЕС-1 (6—15 жовтня 2021 р.)

На відміну від літніх місяців, де структура денного профілю генерації більш-менш стабільна, у жовтні часто трапляються асиметричні криві, денні «провали» в генерації та непередбачувані сплески. Модель, навчену переважно на літніх чи весняних прикладах, буквально «дезорієнтує» така нестабільність. У кількох випадках SERNN формує прогноз з класичною параболічною формою, яка зовсім не відповідає фактичному ходу генерації, наприклад, у дні з затяжними ранковими туманами чи раптовим затіненням у пікові години.

Ключовим обмеженням у цьому місяці стало те, що в навчальній вибірці практично відсутні осінні дні з нестандартним радіаційним профілем, такими як «платоподібне» генерування при тьмяному, але стабільному освітленні, або кількадевні послідовності зі слабкою активністю через щільну хмарність. Модель просто не мала подібних шаблонів у своїй історії, а отже не змогла сформулювати адекватні реакції на такі сценарії.

Окрім цього, осінь — період переходу між кліматичними режимами, коли алгоритми прогнозування погоди теж демонструють знижену точність. Якщо метеоалгоритм передбачає розсіяну хмарність, але фактично утворюється щільна завеса — навіть невелике відхилення в метеоданих призводить до критичних похибок у генерації. Тому в жовтні модель часто або переоцінює, або повністю «зрізає» денний максимум, оскільки не має чіткої вхідної інформації щодо динаміки затінення.

Таким чином, результат у жовтні свідчить не про слабкість самої SERNN, а радше про те, як важливо забезпечити рівномірне сезонне представлення навчальних даних, а також враховувати осінні сценарії як окрему категорію з власними закономірностями. Погіршення точності саме в цьому місяці є індикатором того, що система прогнозування має бути гнучкою не лише по відношенню до погодних змін, але й до структурної нестабільності сезонного контексту.

У січні 2021 року (рис. 9) відносна похибка прогнозу досягла 65 %, що є вкрай високим значенням і свідчить не стільки про обмеження самої моделі, скільки про недостатність якісних навчальних даних для зимового періоду. Навчальна вибірка, що використовувалася у цьому дослідженні, в основному складалася з прикладів весняно-літнього та частково осіннього сезонів. Тоді як зимові місяці (особливо січень) представлені лише фрагментарно або взагалі відсутні, що унеможливило належне навчання моделі на таких умовах.




Рис. 9. Фактичні та прогнозовані значення генерування для ФЕС-1 (1—15 січня 2021 р.)

У зимовий період генерування фотоелектричних станцій характеризується низьким та нестабільним рівнем, а також підвищеною чутливістю до незначних змін метеорологічних умов. Через недостатню представленість зимових даних у навчальній вибірці модель не здатна адекватно враховувати характерні для цього сезону фактори, зокрема коротку тривалість світлового дня, низькі кути падіння сонячного випромінювання та часті періоди суцільної хмарності. Як результат, похибка прогнозу у зимові місяці суттєво зростає, що зумовлено обмеженою можливістю моделі відтворювати складну динаміку генерації в цих умовах.

Таким чином, висока похибка в січні не є наслідком обмежень самої архітектури SERNN, а прямо пов'язана з нестачею повноцінної сезонної репрезентації вхідних даних. Для подальшого вдосконалення системи необхідно суттєво розширити навчальну вибірку шляхом включення повного зимового циклу з прикладами різної генераційної активності, що дозволить забезпечити реальну адаптивність моделі до умов будь-якого сезону.

Обговорення

Отримані результати свідчать про доцільність використання моделі Sensitivity-Enhanced Recurrent Neural Network (SERNN) для розв'язання задачі короткострокового прогнозування генерування електроенергії сонячними фотоелектричними станціями. Однією з головних переваг моделі є її здатність динамічно адаптуватися до змінних метеорологічних умов завдяки спеціальному механізму чутливості до вхідних параметрів. Це дозволяє враховувати не лише абсолютні значення таких факторів, як сонячна радіація чи температура, але й їх взаємозв'язок, змінність та сезонну структуру. Такий підхід особливо цінний у перехідні періоди (весна, осінь), коли погодна нестабільність значно ускладнює точне прогнозування.

У порівнянні з лінійною регресією та базовими нейромережами LSTM, SERNN забезпечує нижчі значення MAE та RMSE, що підтверджує її здатність відтворювати нелінійні залежності між вхідними змінними та цільовим параметром генерування. Модель демонструє стійкість до помірної зміни умов, зокрема, зберігає прийнятну точність у хмарні дні або у разі різкої зміни радіаційного профілю. Важливо й те, що SERNN не потребує індивідуального переналаштування під кожен ФЕС — універсальна схема попередньої обробки (нормалізація, побудова циклічних змінних, фільтрація аномалій) забезпечує достатню гнучкість у типових випадках.

Разом з тим, результати експериментів показали, що модель ще не є достатньо стабільною у складних сценаріях. Похибки влітку та особливо восени залишаються високими, що вказує на недостатню узагальненість моделі та обмеження обсягу/якості навчальної вибірки. У зимовий період, де генерування є мінімальною і дуже залежить від погодніх факторів, прогноз взагалі не був виконаний через відсутність достатніх навчальних прикладів. Ці обставини підкреслюють, що існує ризик деградації якості моделі за межами тренувальних сценаріїв, і тому SERNN наразі не можна вважати повністю універсальним рішенням.

Додаткові обмеження включають високу чутливість до точності вхідних метеорологічних даних, потребу в значних обчислювальних ресурсах та ризик погіршення результатів у разі зміщення погодніх трендів або нетипових кліматичних умов. Також виявлено, що прогноз суттєво погіршується в умовах браку добових/сезонних ознак, а модель має тенденцію до пере- або недооцінки в умовах, не охоплених навчанням. Недостатня якість прогнозу в жовтні та січні вказує на те, що навіть у разі використання архітектурно складних підходів, без глибокої та збалансованої нав-

чальної вибірки стабільно висока точність досягнута не буде.

У цьому контексті подальші дослідження мають бути зосереджені на:

- розширенні та якісному балансуванні навчальної вибірки з урахуванням сезонності;
- глибшій інтеграції моделей якості вхідних даних (наприклад, оцінка надійності прогнозу погоди);
- використанні механізмів активного перенавчання або змішаних підходів (гібридні моделі з фізичними обмеженнями);
- оптимізації обчислень для можливості використання SERNN у реальному часі в умовах обмежених обчислювальних ресурсів. Модель SERNN демонструє високий потенціал як інструмент короткострокового прогнозування сонячного генерування. Проте результати дослідження демонструють, що для досягнення стабільної та універсальної точності модель потребує подальшого вдосконалення, зокрема у частині адаптації до сезонних та нетипових сценаріїв.

Висновки

Проведене дослідження підтверджує доцільність і ефективність використання моделі Sensitivity-Enhanced Recurrent Neural Network (SERNN) для короткострокового прогнозування генерації електроенергії сонячними фотоелектричними станціями. На відміну від традиційних підходів, зокрема лінійної регресії та класичних нейромереж LSTM, SERNN демонструє підвищену чутливість до змін ключових метеорологічних параметрів: глобальної сонячної радіації, температури, хмарності та сезонних коливань. Саме це забезпечує гнучку адаптацію моделі до швидких змін погодних умов і дозволяє отримувати вищу точність прогнозу у порівнянні з альтернативними методами.

Модель SERNN забезпечила задовільні результати середньої абсолютної похибки (MAE) як у сприятливих, так і у складних погодних умовах, включно з періодами з різкою зміною хмарності чи температури. Особливо важливо, що модель впевнено відтворює денний профіль генерації у типові сонячні дні та демонструє здатність адаптуватися до нетипових погодних сценаріїв, що підвищує її практичну цінність для операторів мережі та власників СЕС.

Водночас дослідження виявило низку обмежень, головне з яких — це нестача якісно репрезентативних навчальних даних для окремих сезонів, особливо зимового періоду. Це призводить до зростання похибки прогнозу взимку, коли генерація є нестабільною і надто чутливою до локальних погодних коливань. Такий результат підкреслює необхідність доповнення навчальних вибірок реальними даними з усіх сезонів і типів погодних ситуацій, а також постійного оновлення моделей під актуальні кліматичні умови.

Ще одним важливим аспектом є залежність SERNN від точності та просторової деталізації вхідних метеоданих — локальні аномалії, які не враховані у даних, можуть суттєво впливати на якість прогнозу. Окрім цього, висока чутливість до гіперпараметрів вимагає ретельної оптимізації для кожного конкретного застосування.

Загалом модель SERNN продемонструвала високий потенціал для застосування в задачах оперативного енергетичного планування, оптимізації балансування та мінімізації фінансових втрат від небалансів у сучасних енергосистемах з великою часткою сонячної генерації. Подальші дослідження мають бути спрямовані на удосконалення сезонної репрезентативності навчальних даних, інтеграцію високоточних погодних прогнозів та розвиток гібридних підходів, що враховують фізичні обмеження реальних енергосистем.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] F. Fattori, and N. Anglani, "Review on the stochastic nature of photovoltaic generation and its impact on the energy systems: Why it matters," in *2015 IEEE Energy Conversion Congress and Exposition (ECCE)*, Montreal, QC, Canada, 2015, pp. 1122-1129. <https://doi.org/10.1109/ECCE.2015.7309816>.
- [2] Д. С. Матушкін, «Огляд сучасних методів прогнозування сонячної енергії», *Матеріали аспірантських читань пам'яті професора Артура Праховника*, 2021, с. 34-38. Київ, Україна. [Electronic resource]. Available: <https://ela.kpi.ua/handle/123456789/54577>.
- [3] А. Свердлова, «Прогнозування генерації сонячних панелей на основі погодних даних за допомогою машинного навчання», *Молодий вчений*, № 7 (131), с. 57-63, 2024. <https://doi.org/10.32839/2304-5809/2024-7-131-2>.
- [4] Д. С. Матушкін, «Короткострокове прогнозування генерування фотоелектричних станцій для задач зменшення небалансів в енергосистемі», с. 78-95. [Electronic resource]. Available: <https://ela.kpi.ua/items/352e0241-80bf-4ccb-81b5-1c28aab5bb7e>.
- [5] D. S. Zaruba, M. Y. Shvets, and Y. V. Khokhlov, "Machine Learning for Power Consumption and Generation Prediction," pp. 35-49. [Electronic resource]. Available: <https://ela.kpi.ua/server/api/core/bitstreams/e5129d6a-dfb9-4841-b37b-ca6de50c3603/content>.

- [6] П. О. Зінкевич, В. В. Шпак, і М. В. Маслій, «Порівняльний аналіз інтелектуальних методів прогнозування генерації електроенергії фотоелектричними станціями (ФЕС),» в *Сучасні методи, інформаційне, програмне та технічне забезпечення систем керування організаційно-технічними та технологічними комплексами*, Київ, Україна, 2024, pp. 61-62. [Electronic resource]. Available: <https://dspace.nuft.edu.ua/handle/123456789/46285>.
- [7] О. А. Ковальчук, П. Д. Лежнюк, В. О. Комар, і С. В. Кравчук, «Прогнозування графіка генерування фотоелектричних станцій на наступну добу,» с. 320-323. [Electronic resource]. Available: <https://ela.kpi.ua/handle/123456789/62592>.
- [8] C. Gerdenitsch, L. Deinhard, and P. Hold, "Cognitive Assistance to Support Maintenance and Assembly Tasks: Results on Technology Acceptance of a Head-Mounted Device," pp. 276-284. [Electronic resource]. Available: <https://www.researchgate.net/publication/350583456>.
- [9] E. Chodakowska, et al., "ARIMA Models in Solar Radiation Forecasting in Different Geographic Locations," *Energies*, vol. 16, no. 13, pp. 5029, 2023. <https://doi.org/10.3390/en16135029>.
- [10] M. Paturzo, "Optimized Random Forest for Solar Radiation Prediction Using Hyperparameter Tuning," *Sensors*, vol. 22, no. 18, 6912, 2022. <https://doi.org/10.3390/s22186912>.
- [11] J. Yu, X. Li, et al., "Deep Learning Models for PV Power Forecasting: Review," *Energies*, vol. 17, no. 16, 3973, 2024.
- [12] R. M. Rizk-Allah, et al., "Explainable AI and Optimized Solar Power Generation Forecasting Model Based on Environmental Conditions," *PLoS ONE*, vol. 19, no. 10, e0308002, 2023. <https://doi.org/10.1371/journal.pone.0308002>.

Рекомендована кафедрою електричних станцій та систем ВНТУ

Стаття надійшла до редакції 16.09.2025

Кулик Володимир Володимирович — д-р техн. наук, доцент, професор кафедри електричних станцій та систем, e-mail: volodymyrvkulyk@gmail.com ;

Затхей Максим Вікторович — аспірант кафедри електричних станцій та систем, e-mail: maxzathey@gmail.com

V. V. Kulyk¹
M. V. Zatkhei¹

Improving the Quality of Short-Term Forecasting of Photoelectric Power Plant Generation Volumes Based on Recurrent Neural Networks

¹Vinnitsia National Technical University

This paper presents an in-depth study of modern approaches to forecasting electricity generation by solar photovoltaic plants (PVPs), which is an important element of the development of renewable energy in the context of decentralized energy supply and the growth of the share of "green" energy in the energy balance. Particular attention is paid to the Sensitivity-Enhanced Recurrent Neural Network (SERNN) model, which combines the advantages of recurrent neural networks with adaptive sensitivity to changes in input meteorological parameters. The proposed approach is based on taking into account key climatic factors, directly affecting the volume of solar energy generation, in particular global solar radiation, ambient temperature, cloudiness, and seasonal fluctuations. It is shown that, unlike classical models such as linear regression or traditional neural networks such as LSTM, the SERNN model demonstrates the ability to flexibly respond to rapid changes in weather conditions due to the built-in mechanism for dynamic adaptation of weight coefficients. The study examines in detail the stages of input data preprocessing that are critical for ensuring the quality of training and forecast accuracy, in particular: scaling (normalization) of indicators, encoding time features in the form of sinusoidal functions to reflect daily and seasonal cycles, as well as filtering or correcting anomalous values that may distort the model results. Based on the real observation data from several photovoltaic installations, the high efficiency of using SERNN in short-term forecasting tasks was experimentally confirmed. In particular, a significant reduction in the mean absolute error (MAE) and root mean square error (RMSE) was recorded compared to alternative approaches. The proposed model also demonstrated the stability of results during periods of high variability in weather conditions, which is especially important for energy planning and network optimization. Overall, the study confirms the potential of deep neural networks with a weather-sensitive mechanism as a promising tool for accurate forecasting of PV power generation. This opens up new opportunities for integrating renewable energy sources into the power system while minimizing technical and financial risks associated with imbalances.

Keywords: photovoltaic plants, generation forecasting, SERNN, machine learning, meteorological data, short-term forecasting.

Kulyk Volodymyr V. — Dr. Sc. (Eng.), Associate Professor, Professor of the Chair of Power Stations and Systems, e-mail: volodymyrvkulyk@gmail.com ;

Zatkhei Maksym V. — Post-Graduate Student of the Chair of Electricity, Power Stations and Systems, e-mail: maxzathey@gmail.com