

ПІДВИЩЕННЯ ТОЧНОСТІ БАГАТОФАКТОРНИХ КОРОТКОСТРОКОВИХ ПРОГНОЗІВ ГЕНЕРАЦІЇ СОНЯЧНИХ ЕЛЕКТРОСТАНЦІЙ НА ОСНОВІ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ

В.О. Мірошник*, канд.техн.наук, **С.С. Лоскутов****.

Інститут електродинаміки НАН України,
пр. Берестейський, 56, Київ, 03057, Україна.

E-mail: miroshnyk.volodymyr@gmail.com

Статтю присвячено розвитку моделей прогнозування відпуску електроенергії промисловими сонячними електростанціями на основі штучних нейронних мереж та використання числового прогнозу погоди. Актуальність дослідження обумовлена необхідністю зменшення витрат, пов'язаних з небалансами виробників з відновлюваних джерел енергії (ВДЕ), які іноді сягають 50% відпущеної електроенергії, а також зростанням небалансів таких виробників в ОЕС України. Загальні небаланси виробників з ВДЕ сьогодні зумовлені падінням на 45% виробництва зеленої електроенергії, зокрема і внаслідок того, що у південних і південно-східних регіонах бойові дії пошкодили або знищили 75% вітрових електростанцій і 15% сонячних станцій. Підвищення та стабільності прогнозування відпуску електроенергії такими виробниками можуть значно скоротити витрати на небаланси. Розроблено різні методи агрегації для 15-хвилинних значень вироблення зеленої енергії, щоб підвищити точність прогнозування для 1, 2 та 24-годинних інтервалів. Досліджено потенційні переваги використання значень числового прогнозу погоди (NWP) задля підвищення точності прогнозу. Проаналізовано вплив зовнішніх факторів на точність прогнозів з різною глибиною. У процесі дослідження використовувалися дві сучасні моделі рекурентної нейронної мережі, LSTM і GRU, з різними часовими послідовностями. Бібл. 14, рис. 5, табл. 2.

Ключові слова: короткострокове прогнозування, нейронні мережі, рекурентні нейронні мережі, сонячні електростанції, СЕС.

Вступ. Загальна потужність всіх об'єктів «зеленої» енергетики України на початок 2022 року сягнула 9,6 ГВт, у тому числі промислові сонячні електростанції (СЕС) – 6,4 ГВт, вітрові електростанції (ВЕС) – 1,7 ГВт. Більшість промислових електростанцій з відновлюваних джерел енергії (ВДЕ), а саме до 60% СЕС та понад 85% ВЕС зосереджені у південних та південно-східних областях України, де наразі відбуваються активні бойові дії, через що близько 75% (1,3 ГВт) ВЕС та 15% (1 ГВт) СЕС знищено, пошкоджено або знаходяться під окупацією. Відтак, у 2022 році в енергетичну систему України поставлено лише 7,6 млрд кВт·год замість 13,6 млрд кВт·год «зеленої» електроенергії, тобто падіння виробництва електроенергії з ВДЕ складе близько 45%.

Також, важливим питанням є моделювання нормальних та аномальних режимів роботи енергосистеми в умовах вимушеної зміни топології мережі та аварійного відключення генеруючого обладнання ТЕС [1]. На додачу до стохастичного характеру генерації з ВДЕ подібні ефекти створюють додаткову невизначеність стосовно майбутніх параметрів режиму роботи енергосистеми. Тому врахування прогнозів обсягу генерації СЕС є необхідною умовою під час розробки квазідинамічної моделі ОЕС України [2]. Для виробників електричної енергії з СЕС питання зниження витрат, пов'язаних з небалансами, є вкрай актуальним. За даними Асоціації сонячної енергетики України в деякі місяці 2022 року витрати на покриття небалансів сягали 50% від вартості відпущеної електроенергії. Вдосконалення моделей та методів прогнозування обсягів генерації СЕС дасть змогу суттєво знизити дані витрати. Згідно чинного законодавства для учасників балансуєної групи ДП «Гарантований покупець» відповідальність за небаланси настає у разі відхилення фактичної генерації від прогнозу на 5% для СЕС та на 10% для ВЕС. Станції з встановленою потужністю вище 1 МВт відшкодовують повну вартість витрат, які несе ДП «Гарантований покупець» через врегулювання їхніх небалансів.

Метою статті є аналіз результатів використання запропонованої багатофакторної моделі прогнозування генерації СЕС, дослідження впливу метеорологічних факторів на точність прогнозу та

формування рекомендацій щодо підвищення точності короткострокових прогнозів генерації СЕС на основі виконаних досліджень.

Задля розробки моделі та оцінювання її ефективності було використано дані СЕС, розміщених в Китаї [3, 4,] з дискретністю в 15 хвилин. Для кожної станції наведено значення метеорологічних факторів, а саме: повне сонячне випромінювання (*nwp_globalirrad*), пряме сонячне випромінювання (*nwp_directirrad*), температуру повітря (*nwp_temperature*), вологість (*nwp_humidity*), швидкість (*nwp_windspeed*) та напрямок вітру (*nwp_winddirection*), тиск (*nwp_pressure*). Інформація про метеорологічні фактори отримано за допомогою числового прогнозу погоди (*nwp*, numerical weather prediction). Дані про метеорологічні фактори та генерацію представлено у вигляді матриці $\square^{k \times l}$. Додатково введено змінну, яка відображає час доби. Станції стаціонарного типу, без відстеження оптимального кута нахилу.

На рис. 1 зображено «теплову карту» матриці кореляцій генерації, часу доби та метеорологічних факторів. Чим світліший колір тим ближче значення коефіцієнту кореляції Пірсона до 1.




Рис. 1.

Розрахунок матриці кореляцій очікувано показав найвищий рівень взаємозв'язку між сонячним випромінюванням на потужність генерації. Значна антикореляція між часом та навантаженням пояснюється особливістю кодування змінної часу. В подальшому змінну прямого сонячного випромінювання було виключено з аналізу та не враховано в моделі, оскільки вона є складовою повного сонячного випромінювання, що підтверджується значенням кореляції близьким до 1. Перед використанням значення метеорологічних факторів було стандартизовано

рологічних факторів було стандартизовано

$$z_{i,j} = (x_{i,j} - m_j) / s_j, \quad i \in (1..k), \quad j \in (1..l), \quad (1)$$

де $x_{i,j}$ – i -й елемент j -ого стовбця; m_j – середнє арифметичне значення випадкової величини j ; s_j – стандартне відхилення випадкової величини j .

Значення потужності також масштабується відносно встановленої потужності, тобто прогнозною величиною є коефіцієнт використання потужності. Такий підхід дає змогу пришвидшити процес навчання нейронної мережі, підвищити робастність моделі, оскільки за функцію можна використовувати логістичну сигмоїду. Прогнозування коефіцієнту використання потужності надає можливість використовувати нейронну мережу, навчену на даних однієї станції, для прогнозування генерації іншої станції. Додатково об'єднання даних з різних СЕС задля розширення навчальної вибірки дає можливість підвищити точність прогнозів для станцій, які працюють відносно недовго або тільки запустилися.

Для входу в мережу дані було трансформовано у тривимірний тензор (n, s, k) , де n – кількість спостережень, s – кількість часових послідовностей, k – кількість факторів у кожній часовій послідовності. За оцінку похибки прогнозу використовується величина

$$RSMEp = \frac{RMSE}{p} 100\%, \quad (2)$$

де $RMSE$ – середньоквадратична похибка, МВт; P – встановлена потужність станції, МВт.

Точність в такому випадку може бути виражена як $1 - RMSEp/100$.

Багатофакторна модель для короткострокового прогнозування генерації СЕС на базі рекурентної нейронної мережі. З набуттям популярності теорії машинного навчання розроблено

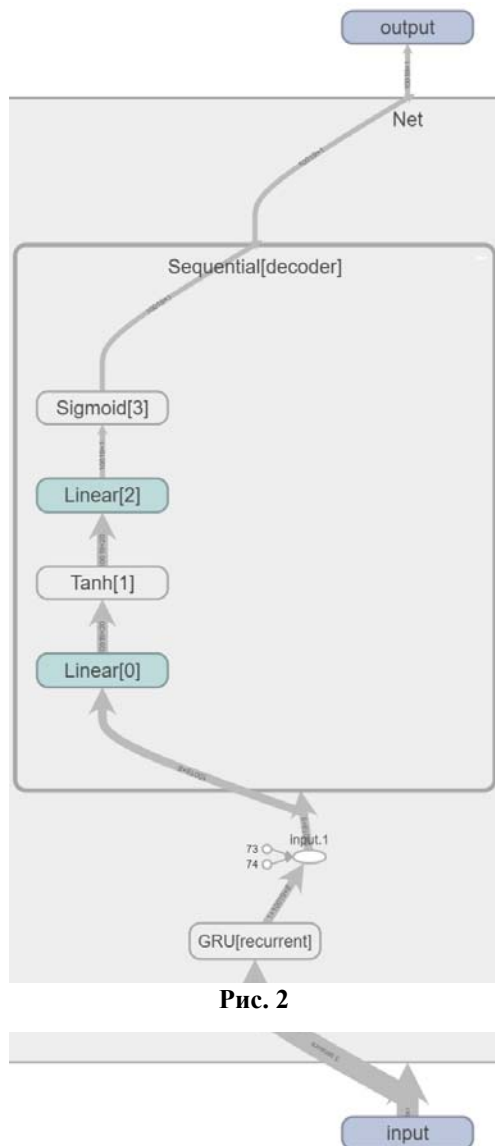


Рис. 2

досить багато моделей для прогнозування генерації СЕС на основі штучних нейронних мереж (НМ). В роботі [5] запропоновано гібридну модель, яка включає елементи НМ та класичної авторегресійної моделі. В [6] результати прогнозу декількох нейронних мереж глибинного навчання порівнюються з прогнозами, отриманими за допомогою математичної фізичної моделі СЕС, яка відображає фізику процесу. Для порівняння використали багатосаровий перцептрон, LSTM-модель, DBN, Auto-LSTM та як математичну модель – P-PVFM. Методи глибинного навчання показали кращі результати у порівнянні з P-PVFM. В [7] досліджувалася ефективність застосування найпоширеніших на практиці методів машинного навчання, а саме багатосарового перцептрон та градієнтного бустингу (LightGBM). В [8] запропоновано архітектуру штучної нейронної мережі глибинного навчання для прогнозування генерації СЕС (eResNet) з використанням модулів автокодування з обхідними з'єднаннями. Запропонована НМ порівнюється з класичними методами прогнозування часових рядів. Аналіз результатів дослідження показує, що похибка прогнозу eResNet є значно нижчою, ніж похибка класичних моделей.

Для прогнозування було використано два типи нейронних мереж з рекурентними шарами GRU [9, 10] та LSTM [11, 12]. В обох мережах після рекурентного шару послідовно йде два шари лінійної трансформації, з'єднаних між собою через функцію активації гіперболічний тангенс. Виходом нейронних мереж є функція логістичної сигмоїди. «Навчання» проводилося впродовж 100 епох алгоритмом оптимізації ADAM з кроком навчання 0.001. На рис. 2 наведено схему нейронної мережі на базі GRU, написаної мовою програмування Python з використанням пакету Pytorch.

Структура LSTM-мережі дуже схожа на рекурентну, але замість одного шару нейронної мережі є цілих чотири, які взаємодіють між собою певним чином. Відповідно, детальний процес розрахунку починається з вибору інформації, яку можна замінити згідно умов сигмоїдного шару (або шар фільтру забування), що описаний рівнянням (3). Після чого наступний шар визначає значення, які потрібно обновити (4), і буде вектор значень \tilde{C}_τ , який можна додати в стан комірки (5). Потім необхідно замінити старий стан комірки $C_{\tau-1}$ на новий C_τ у відповідності до рівняння (6). Останній крок полягає в розрахунку вихідної інформації за допомогою декількох фільтрів (7, 8).

$$f_\tau = \sigma(W_f \cdot [h_{\tau-1}, x_\tau] + b_f), \quad (3)$$

$$i_\tau = \sigma(W_i \cdot [h_{\tau-1}, x_\tau] + b_i), \quad (4)$$

$$\tilde{C}_\tau = \tanh(W_c \cdot [h_{\tau-1}, x_\tau] + b_c), \quad (5)$$

$$C_\tau = f_\tau \cdot C_{\tau-1} + i_\tau \cdot \tilde{C}_\tau, \quad (6)$$

$$o_\tau = \sigma(W_o \cdot [h_{\tau-1}, x_\tau] + b_o), \quad (7)$$

$$h_\tau = o_\tau \cdot \tanh(C_\tau), \quad (8)$$

де σ – активаційна функція; W_f, W_i, W_c, W_o – вагові коефіцієнти; b_f, b_i, b_c, b_o – коефіцієнти зсуву; x_t – вхідні дані; h_{t-1}, h_t – прогнознi значення; \tilde{C}_t – вектор корекції комірки пам'яті; C_t, C_{t-1} – стан комірки пам'яті; $[\cdot, \cdot]$ – операція конкатенації.

Вектори пам'яті (C) та вихід LSTM попереднього кроку (h) ініціалізуються нульовими значеннями на кожному кроці прогнозування x_t . Вектор \tilde{C}_t представляє новий варіант значень пам'яті, а вектори f_t та i_t регулюють ступінь оновлення вектору пам'яті новими значеннями. За рахунок того, що значення W_f, W_i і b_f, b_i оцінюються в процесі навчання, нейронна мережа регулює динаміку оновлення C оптимальним чином з точки зору мінімізації функції втрат. Крім того, наявність вектору пам'яті дає змогу зменшити ефект розмиття або вибуху градієнту у разі зворотного розповсюдження похибки, що наряду з використанням обхідного з'єднання, яке згладжує поверхню похибки нейронної мережі, суттєво прискорює навчання та дає змогу досягти меншої похибки прогнозування.

В свою чергу GRU відрізняється меншою кількістю матриць вагових коефіцієнтів – 3 проти 4 у LSTM.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f), \quad (9)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i), \quad (10)$$

$$\tilde{h}_t = \tanh(W_h \cdot [i_t \square h_{t-1}, x_t] + b_h), \quad (11)$$

$$h_t = f_t \square \tilde{h}_t + (1 - f_t) \square h_{t-1}, \quad (12)$$

де \square – операція поелементного множення.




Рис 3.

Прогнозування проводилося з горизонтом упередження (Δt) на 15 хв, 2 години та 24 години. Для тренування було взято 70% даних з кінця червня по початок березня наступного року, а в тестовій вибірці використано дані з березня по середину червня. Для кожного варіанту рекурентного шару будувалося чотири варіанти нейромережі, які відрізнялися глибиною передісторії, що використовувалася для одного кроку прогнозування (кількість часових послідовностей). Метеорологічні фактори також беруться з лагом відносно прогнозної години. Таким чином моделюється ситуація, в якій недоступні прогнози метеорологічних факторів.

Прогнози з упередженням 15 хв можуть бути використані диспетчерськими службами та системами керування обмеженнями ВДЕ. Також дані прогнози необхідні для подальшого дослідження темпів деградації точності прогнозування зі збільшенням горизонту. Крім цього, проводилося прогнозування з горизонтами 2 год або 8 кроків (актуально для роботи в рамках внутрішньодобового ринку) та 24 год або 96 кроків (для роботи в ринку «на добу наперед»). На рис. 3 наведено розподіл похибки прогнозів в залежності від горизонту прогнозування. Рисунок представляє коробкову діаграму розподілу похибок моделей. Лінія в середині прямокутника відповідає медіанному значенню, нижня грань прямокутника встановлена на рівні значення 1 квантиля розподілу, верхня грань встановлена на рівні значення 3 квантилю. Різниця між значеннями 1 та 3 квантиля називається міжквартильною відстанню (IQR). «Вуса» встановлено на рівні максимального та мінімального значення, які лежать в межах $1.5 \cdot IQR$. Точками позначено аномальні значення, які більші/менші за $1.5 \cdot IQR$.

Очікувано, що за збільшення горизонту прогнозування збільшується похибка та дисперсія похибки, що вказує на зниження стабільності прогнозів. Шкала часу на даному та наступних рисунках є логарифмічною. Це означає, що в більшості випадків має місце ефект насичення та за подальшого збільшення горизонту прогнозування швидкість зростання похибки буде меншою.

Таблиця 1

G	Модель	N	Error1	Error2
2	GRU	20	8.92	8.32
		10	9.15	8.46
		7	8.74	8.46
		5	8.66	8.54
	LSTM	20	8.41	8.53
		10	8.30	8.84
		7	8.82	8.59
		5	7.27	8.11
24	GRU	20	9.59	9.05
		10	9.67	8.41
		7	9.09	9.38
		5	9.56	8.85
	LSTM	20	9.62	8.96
		10	10.13	8.94
		7	10.05	8.64
		5	9.44	8.85

В табл. 1 використовуються наступні позначення: G – горизонт прогнозування, год; N – кількість часових послідовностей; Error1 – похибка при агрегуванні прогнозів (варіант 1), %; Error2 – похибка при агрегуванні даних (варіант 2), %.

Для більшості задач управління енергосистемою та роботи на оптовому ринку необхідні погодинні значення прогнозів генерації та споживання [13]. За наявності даних з меншою дискретністю є декілька варіантів їхнього агрегування. Варіант 1 означає побудову моделі на даних з 15 хв дискретністю з подальшим агрегуванням результатів прогнозування. Варіант 2 полягає в агрегації вхідних даних та побудові моделі на даних з дискретністю 1 год. За такого підходу значення метеорологічних факторів усереднюються. В рамках даного дослідження використовується інформація щодо потужності

генерації, тому при агрегуванні її значення також усереднюються.

В табл. 1 наведено похибки обох варіантів для тестової вибірки даних. Для обох горизонтів (2 та 24 год) середня похибка прогнозу при агрегації результатів (варіант 1) виявилася вищою, ніж похибка прогнозу на агрегованих даних (варіант 2). При цьому мінімальної похибки прогнозу для горизонту 2 год досягнуто при агрегуванні прогнозів (варіант 1). Загалом можна зробити висновок, що агрегування даних до годинної дискретності з послідуочим прогнозуванням дає нижчу похибку прогнозу, ніж агрегація прогнозів з 15 хв дискретністю, особливо для прогнозування на 24 години.

Використання прогнозних значень метеофакторів. На разі доступ до результатів числових прогнозів погоди є широкодоступним практично для будь-якого регіону світу. Його наявність повинна суттєво покращити прогнози генерації у порівнянні з використанням фактичних даних, які до того ж надходять з затримкою [14]. Сучасні системи числового прогнозування погоди можуть надавати дані з дискретністю від 5 хв з горизонтом до 14 діб з частотою оновлення до 5 хв.

В наступних моделях значення зовнішніх факторів було взято для прогнозної години ($t + \Delta t$), у попередніх розрахунках використовувалися ретроспективні дані (до моменту t). Іншими словами, моделюється наявність прогнозних даних з нульовою похибкою. На рис. 4 показано розподіл похибки прогнозів на тестовій вибірці.

Прогнози без лагу метеорологічних факторів несуттєво зменшили похибку на горизонті прогнозування 2 години та значно зменшили її на горизонті 24 години. Для прогнозування на 15 хвилин покращень не відбулося, що пояснюється інерційністю метеорологічних факторів. Тому на даному проміжку часу суттєвих змін в їхніх значеннях нема.

На рис. 5 наведено результати прогнозування при агрегуванні даних (варіант 2) та використанні прогнозних значень метеорологічних факторів. В даному випадку суттєвого зниження похибки прогнозу не спостерігається.

Визначення ступеню впливу різних факторів на похибку прогнозу. Задля визначення важливості факторів використаємо метод MDA (середнє зниження точності). Суть методу полягає в тому, що після навчання моделі на тренувальному наборі даних значення факторів в тестовій вибірці по черзі перемішуються або замінюються на 0. Далі розраховується значення показника похибки на тестовій вибірці, який порівнюється з базовим значенням. В даному випадку від'ємні значення говорять про зменшення точності, а позитивні – про збільшення. В табл. 2 показано ступінь впливу факторів для кожного горизонту прогнозування. Для кожного дослідження, відображеного в табл. 2, взято одну нейронну мережу GRU з найнижчою похибкою прогнозу для даного горизонту.

Обидва розрахунки вказують на те, що у разі прогнозування з невеликим упередженням (15 хв, 2 год) найбільший вплив на точність спричиняють попередні значення генерації та фактор години

доби. У разі прогнозування з більшим упередженням на передній план виходять значення метеорологічних факторів, серед яких найбільший вплив спричиняє повне сонячне випромінювання. Вплив фактору години доби також залишається суттєвим.




Рис.4




Рис. 5

Таблиця 2

Тип зміни	Горизонт прогнозування	Повне сонячне випромінювання	Темп. повітря	Вологість	Шв. вітру	Напрямок вітру	Тиск	Ретроспективні значення генерації	Година доби
Перемішування	15 хвилин	-0.22	-0.07	-0.04	0.006	-0.001	-0.03	-5.39	-1.27
Перемішування	2 години	-0.68	-0.02	-0.03	0.007	0.019	-0.02	-1.22	-1.32
Перемішування	24 години	-1.06	-0.05	0.01	-0.04	-0.007	0.0008	-0.16	-0.87
Нулі	15 хвилин	-0.18	-0.06	0.01	0.008	-0.001	-0.004	-4.03	-0.89
Нулі	2 години	-0.28	-0.02	-0.008	0.01	0.0004	-0.005	-1.06	-1.67
Нулі	24 години	-0.88	-0.10	-0.02	0.04	-0.06	-0.11	-0.08	-0.65

Також, варто відзначити, що два методи дають різні оцінки важливості температури повітря та тиску. У разі заміни значень цих факторів на 0 точність падає значно сильніше, ніж у разі перемішування. Даний факт можна пояснити тим, що під час перемішування незмінним залишається середнє значення фактору. Значна зміна оцінки важливості цих факторів при двох методах заміни говорить про те, що коефіцієнт варіації даних факторів досить невеликий, і їхнє середнє значення спричиняє значно більший вплив на точність, ніж їх коливання. Це може бути пов'язано з

локальними особливостями даної СЕС, що розміщена в регіоні, для якого непритаманна значна сезонна зміна температури.

Висновки. За результатами виконаних досліджень показано, що використання нейронної мережі на базі рекурентного блоку GRU дає змогу в середньому досягти не гірших показників якості прогнозу, ніж у разі використання LSTM. При цьому за рахунок меншої кількості вагових коефіцієнтів навчання нейронної мережі з GRU потребує меншої кількості обчислювальних ресурсів. Агрегування даних до годинної дискретності з послідовним прогнозуванням дає нижчу похибку прогнозу, ніж агрегація прогнозів з 15 хв дискретністю, особливо у разі збільшення горизонту прогнозування. Використання прогнозних значень метеорологічних факторів дає можливість суттєво знизити похибку прогнозування, особливо під час прогнозування з горизонтом 24 год та більше. Враховуючи відносно невисоку вартість отримання числових прогнозів погоди, їхнє використання є повністю виправданим для промислових СЕС у разі прогнозування на декілька годин вперед і більше. Визначено, що серед наявних метеорологічних факторів найбільший вплив обумовлює повне/пряме сонячне випромінювання. Під час збільшення горизонту прогнозування важливість метеорологічних факторів зростає. За будь-якого горизонту прогнозування важливим є використання інформації про годину доби. Попередні значення генерації мають вирішальний вплив під час прогнозування з горизонтами до декількох годин, а вже під час прогнозування на 24 год вперед їхній вплив на точність відносно невеликий за умови використання метеорологічних та часових факторів.

Роботу виконано за бюджетною темою «Забезпечення стійкості та надійності національної електроенергетики в умовах синхронної роботи ОЕС України з континентальною європейською енергетичною системою ENTSO-E» (РЕЖИМ-2), КПКБК 6541230.

INCREASING THE ACCURACY OF SHORT-TERM FORECASTS OF PVSPG GENERATION BASED ON ARTIFICIAL NEURAL NETWORKS AND TAKING ADDITIONAL FACTORS INTO ACCOUNT

V.O. Miroshnyk, S.S. Loskutov

Institute of Electrodynamics National Academy of Sciences of Ukraine,

Beresteiskyi Ave., 56, Kyiv, 03057, Ukraine.

E-mail: miroshnyk.volodymyr@gmail.com

The paper focuses on the development of models for forecasting the electricity generation of industrial solar power plants using artificial neural networks and numerical weather prediction. The relevance of the research is driven by the need to reduce costs related to imbalances in electricity generation from renewable sources, which can sometimes reach 50% of the released electricity. Additionally, the imbalances of such producers are increasing in Ukraine's power system. Currently, the general imbalances of renewable energy producers in Ukraine have led to a 45% reduction in green electricity production, especially due to the damage or destruction of 75% of wind power plants and 15% of solar power plants in southern and southeastern regions as a result of hostilities. Increasing the accuracy and stability of electricity generation forecasts for such producers could significantly reduce costs associated with imbalances.. Various aggregation methods have been developed for 15-minute values of green energy generation to enhance forecasting accuracy for 1, 2, and 24-hour intervals. The study investigated the potential benefits of using numerical weather prediction (NWP) forecast values to enhance forecasting accuracy. The study revealed the significance of different factors for forecasting at each bias interval. The study employed two modern recurrent neural network models, LSTM and GRU, with varying time sequences. References 14, figures 5, table 2.

Keywords: short-term forecasting, neural networks, recurrent neural networks, photovoltaic solar power plant, PVSPG.

1. Kyrylenko O.V., Blinov I.V., Parus E.V. Operation evaluation of power plants in the provision of ancillary services of primary and secondary frequency control in the ukrainian power system. *Tekhnichna Elektrodynamika*. 2013. No 5. Pp. 55–60. (Ukr)
2. Kyrylenko O.V., Pavlovsky V.V., Blinov I.V. Scientific and technical support for organizing the work of the IPS of Ukraine in synchronous mode with the European continental energy system ENTSO-E. *Tekhnichna Elektrodynamika*. 2022. No 5. Pp. 59–66. DOI: <https://doi.org/10.15407/techned2022.05.059>. (Ukr)
3. Tiechui Yao, Jue Wang, Haoyan Wu, Pei Zhang, Shigang Li, Yangang Wang, Xuebin Chi, Min Shi. A photovoltaic power output dataset: Multi-source photovoltaic power output dataset with Python toolkit. *Solar Energy*. 2021. Vol. 230. Pp. 122–130. DOI: <https://doi.org/10.1016/j.solener.2021.09.050>.

4. Tiechui Yao, Jue Wang, Haoyan Wu, Pei Zhang, Shigang Li, Yangang Wang, Xuebin Chi, Min Shi. PVOD v1.0: A photovoltaic power output dataset. *Science Data Bank*. DOI: <https://doi.org/10.11922/sciencedb.01094>
5. Mariam AlKandari, Imtiaz Ahmad. Solar power generation forecasting using ensemble approach based on deep learning and statistical methods. *Applied Computing and Informatics*. 2020. DOI: <https://doi.org/10.1016/j.aci.2019.11.002>.
6. André Gensler, Janosch Henze, Bernhard Sick, Nils Raabe. Deep Learning for solar power forecasting – An approach using AutoEncoder and LSTM Neural Networks. *IEEE International Conference on Systems, Man, and Cybernetics (CMS)*. Budapest, Hungary, 09-12 October 2016. DOI: <https://doi.org/10.1109/SMC.2016.7844673>.
7. Loskutov S., Blinov I., Miroshnyk V. Comparison of widely-used models for multifactorial short-term photovoltaic generation forecast. *IEEE 8th International Conference on Energy Smart Systems (ESS)*. Kyiv, Ukraine, 12-14 October 2022. Pp. 123–126. DOI: <https://doi.org/10.1109/ESS57819.2022.9969270>.
8. Miroshnyk V., Shymaniuk P., Sychova V. Short Term Renewable Energy Forecasting with Deep Learning Neural Networks. In: Kyrlylenko O., Zharkin A., Butkevych O., Blinov I., Zaitsev I., Zaporozhets A. (eds) *Power Systems Research and Operation. Studies in Systems, Decision and Control*. 2021. Vol. 388. Springer, Cham. DOI: https://doi.org/10.1007/978-3-030-82926-1_6.
9. Kyunghyun Cho, Bart van Merriënboer, Dzmitry Bahdanau, Yoshua Bengio. On the Properties of Neural Machine Translation: Encoder–Decoder Approaches. *Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation (SSST-8)*. Doha, Qatar, 2014. Pp. 103–111. DOI: <https://doi.org/10.3115/v1/W14-4012>
10. Xifeng Guo, Yi Zhan, Di Zheng, Lingyan Li, Qi Qi. Research on short-term forecasting method of photovoltaic power generation based on clustering SO-GRU method. *Energy Reports*. 2023. Vol. 9. Supplement 10. Pp. 786–793. DOI: <https://doi.org/10.1016/j.egyr.2023.05.208>.
11. Sepp Hochreiter, Jürgen Schmidhuber. Long Short-term Memory. *Neural computation*. 1997. Vol. 9. Pp. 1735–80.
12. Tae-Young Kim, Sung-Bae Cho. Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*. 2019. Vol. 182. Pp. 72–81. DOI: <https://doi.org/10.1016/j.energy.2019.05.230>.
13. Ivanov H., Blinov I., Parus Y. Simulation Model of New Electricity Market in Ukraine. *IEEE 6th International Conference on Energy Smart Systems (ESS)*. Kyiv, Ukraine, 17-19 April 2019. DOI: <https://doi.org/10.1109/ESS.2019.8764184>.
14. Loskutov, S., Miroshnyk, V., Blinov, I. (2022). Comparison of widely-used models for multifactorial short-term photovoltaic generation forecast. *IEEE 8th International Conference on Energy Smart Systems (ESS)*. Kyiv, Ukraine, 12-14 October 2022. Pp. 123–126. DOI: <https://doi.org/10.1109/ESS57819.2022.9969270>.

Надійшла 02.03.2023
Остаточний варіант 20.11.2023