

ТЕХНОЛОГІЇ ТА ОБЛАДНАННЯ В ЕНЕРГЕТИЦІ

TECHNOLOGIES AND EQUIPMENT IN ENERGY

УДК 620.9+621.3+519.2

DOI 10.20535/1813-5420.2.2025.327376

А.О. Запорожець^{1,2}, д-р техн. наук, ORCID 0000-0002-0704-4116

В.С. Єременко^{1,2}, д-р техн. наук, ORCID 0000-0002-4330-7518

А.П. Щербань^{1,2}, канд. техн. наук, ORCID 0000-0002-2643-5024

В.О. Верпета¹, аспірант, ORCID 0009-0001-3572-0388

¹Інститут загальної енергетики національної академії наук України

²Національний технічний університет України

«Київський політехнічний інститут імені Ігоря Сікорського»

АНАЛІЗ МЕТОДІВ ПРОГНОЗУВАННЯ ШВИДКОСТІ ВІТРУ ДЛЯ ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ ФУНКЦІОНУВАННЯ ВІТРОВИХ ЕЛЕКТРОСТАНЦІЙ

Розвиток вітроенергетики в Україні є важливим стратегічним напрямом, що сприяє енергетичній безпеці, зниженню залежності від імпортованих енергоносіїв та зменшенню негативного впливу на довкілля. В умовах нестабільності ринку та змін клімату точне прогнозування швидкості вітру є критичним фактором для ефективного функціонування вітрових електростанцій (ВЕС). Метою роботи є комплексний аналіз сучасних методів прогнозування швидкості вітру з метою підвищення ефективності експлуатації ВЕС та формування рекомендацій щодо оптимізації процесів прогнозування. У статті розглянуто фізичні (числові) методи, що базуються на рівняннях Нав'є–Стокса та моделюванні динаміки атмосфери, зокрема моделі WRF і ECMWF. Визначено їхню перевагу у середньо- та довгостроковому прогнозуванні, а також основні обмеження, пов'язані з обчислювальною складністю та необхідністю точних вхідних даних. Досліджено статистичні методи, такі як ARIMA, які ефективні для короткострокового прогнозування, проте мають обмежену здатність враховувати нелінійні процеси та раптові зміни вітрового потоку. Окрему увагу приділено застосуванню методів машинного навчання та гібридних підходів, що поєднують фізичне моделювання зі статистичним аналізом і алгоритмами глибокого навчання. Такі методи дозволяють адаптувати прогнозні моделі до конкретних умов експлуатації ВЕС та підвищувати точність прогнозів. Зроблено висновок про необхідність подальшого вдосконалення методів прогнозування, зокрема розвитку адаптивних моделей, що використовують великі масиви даних та враховують регіональні особливості вітрових ресурсів. Запропоновані рекомендації можуть бути корисними для операторів ВЕС, інвесторів та науковців, які займаються аналізом вітрових ресурсів та розвитком алгоритмів прогнозування.

Ключові слова: вітроенергетика, прогнозування швидкості вітру, числове моделювання, статистичні методи, машинне навчання, гібридні підходи.

1. Вступ

У сучасних умовах, коли економіка України прагне до стабільного зростання, а енергетичний сектор постає перед новими викликами, відновлювана енергетика набуває особливої ваги [1, 2]. Причини цього очевидні: по-перше, залежність від імпортованих викопних палив підвищує вразливість енергетичної системи й формує додаткове навантаження на платіжний баланс держави; по-друге, глобальні зміни клімату диктують необхідність зменшувати викиди парникових газів та переходити на чисті джерела енергії; по-третє, розвиток відновлюваної енергетики відкриває нові можливості для децентралізації та модернізації енергосистеми, особливо в регіонах, які прагнуть бути більш енергонезалежними. Усе це робить «зелену» енергетику важливим чинником сталого розвитку України. Серед відновлюваних джерел енергії — сонячних, вітрових, гідро- та біоенергетичних — дедалі більшого значення в українських реаліях набуває саме вітрова енергетика [3].

Україна володіє значним вітровим потенціалом, особливо у приморських районах (Одеська, Миколаївська, Херсонська області, Приазов'я) та на відкритих степових ділянках півдня і сходу. Попри військові дії та економічні виклики останніх років, розвиток вітрової енергетики у державі не зупиняється:

будуються нові вітрові парки, модернізуються існуючі станції, запроваджуються «зелені» тарифи для стимулювання інвестицій. Важливість вітрових станцій для України полягає не лише у виробництві «чистої» електроенергії, а й у сприянні надійності та диверсифікації енергетичної системи. У перспективі це знижує залежність від імпортованих енергоносіїв та робить національну енергетику більш стійкою до зовнішніх шоків [4,5].

Кожна вітротурбіна має граничні швидкості: при нижчій за мінімально допустиму (3–4 м/с) вона не виробляє електроенергії, а при перевищенні максимальної (часто 25–30 м/с) – зупиняється задля запобігання пошкодженням [6]. Таким чином, для раціональної експлуатації необхідно чітко розуміти динаміку швидкості вітру, обирати оптимальні місця встановлення і враховувати сезонні та добові коливання [5].

Для України це особливо актуально, оскільки вибір майданчиків для нових вітропарків або модернізації старих потужностей часто залежить від наявності інфраструктури та стабільного фінансування. Усе більше інвесторів звертає увагу на те, щоб потенційна ВЕС могла працювати з максимальною віддачею упродовж мінімум 20–25 років. Більше того, наша держава поступово входить до європейського енергетичного простору, тож питання адаптації ВЕС до єдиної мережі, встановлення відповідних систем обліку та регулювання стають дедалі важливішими.

Складність широко впровадження об'єктів вітроенергетики полягає в тому, що атмосферні процеси мають як регулярну, так і випадкову природу. Вітер підпорядковується великому комплексу динамічних явищ, починаючи від глобальних циркуляційних систем і закінчуючи локальними турбулентними відхиленнями. Саме тому з'явилося кілька різних підходів до його прогнозування: фізичні числові моделі, статистичні алгоритми, нейронні мережі та, зрештою, гібридні рішення, що будуть розглянуті далі [7].

Метою даної роботи є проведення комплексного аналізу сучасних методів прогнозування швидкості вітру з метою підвищення ефективності функціонування вітрових електростанцій.

2. Огляд методів прогнозування швидкості вітру

2.1. Фізичне (числове) моделювання

Фізичні або числові моделі прогнозування вітру описують динаміку атмосфери за допомогою системи рівнянь Нав'є–Стокса, а також рівнянь збереження маси, енергії та імпульсу. У загальному вигляді ці рівняння відображають рух повітряних мас з урахуванням різних чинників, як тертя, теплообмін, вплив сонячної радіації тощо [8]. Окрім базових рівнянь, фізичне моделювання включає процедури параметризації – це спосіб «спростити» складні процеси (наприклад, турбулентність у прикордонному шарі або конвекцію) до ефективних описів, придатних для обчислювальних розрахунків. У світовій практиці найчастіше використовують моделі типу WRF (Weather Research and Forecasting) або ECMWF (European Centre for Medium-Range Weather Forecasts). Їх використовують не лише для прогнозування швидкості вітру, а й для передбачення температури, тиску, вологості, й інших метеорологічних параметрів.

Для атмосферного руху повітря загальна система в наближенні нестисливого середовища має вигляд:

$$\begin{cases} \frac{\partial \mathbf{u}}{\partial t} + (\mathbf{u} \cdot \nabla) \mathbf{u} = -\frac{1}{\rho} \nabla \mathcal{P} + \nu \nabla^2 \mathbf{u} + \mathbf{F}, \\ \nabla \cdot \mathbf{u} = 0, \end{cases}$$

де $\mathbf{u}$ – вектор швидкостей повітря за осями x, y, z , $\mathcal{P}$ – тиск, ρ – густина повітря, ν – коефіцієнт кінематичної вязкості, $\mathbf{F}$ – додаткові сили [9].

Під час запуску такої моделі обчислювальну область (зазвичай це певний регіон на карті) розбивають на тривимірну сітку з вузлами, де будуть обчислюватися значення швидкості вітру, температури, тиску тощо через певні кроки часу. Важливо, що зменшення розміру елемента цієї сітки різко підвищує обчислювальну складність, але дає змогу точніше враховувати локальні особливості рельєфу: гори, лісистість, водні поверхні. До даних, які задають у вихідних (початкових) умовах, належать результати супутникових спостережень, вимірювання з метеостанцій, радіозонди та інші. Якщо в початкових умовах є значна похибка або недостатня точність, то будь-яка модель почне поступово «дрейфувати» і давати менш достовірні прогнози [10-12].

Сильною стороною числових моделей є те, що вони враховують реальні фізичні процеси в атмосфері. Це робить їх особливо придатними для середньо- та довгострокових прогнозів у масштабах від кількох годин до кількох діб і навіть тижнів. У разі збільшення потужностей обчислювального обладнання можна досягти вищої просторової роздільності, детальніше «побачити» мікрокліматичні явища й отримувати прогнози з кроком у кількасот метрів, що актуально для складного рельєфу. Водночас такий високий рівень деталізації є високозатратним з точки зору часу розрахунку і потребує якісних даних на вході. Серед недоліків часто згадують систематичні помилки, коли модель, наприклад, хронічно завищує або занижує швидкість вітру в певному регіоні [13]. Це трапляється через спрощені схеми параметризації

турбулентності, недоліки в описі теплообміну над водною поверхнею або складним рельєфом, а також через обмежений набір реальних вимірювань. Виходом із такої ситуації є застосовування методів пост-опрацювання (англ. statistical downscaling), коли отримані числові прогнози проходять корекцію на основі емпіричних даних за минулі періоди.

Ще однією важливою складовою є врахування взаємодії між регіонами. У глобальних моделях, які охоплюють великі території, інформація про стан атмосфери, наприклад, на півночі Європи може впливати на прогноз у Центральній чи Східній Європі [14, 15]. Таким чином, фізичне моделювання пропонує системний погляд на динаміку атмосфери й гарантує, що фундаментальні закони гідродинаміки не будуть порушені. Проте для локального оперативного прогнозу (наприклад, на 2–6 годин для конкретної вітрової турбіни) числові методи можуть бути або надто «важкими» в обчисленні, або недостатньо детальними без додаткової статистичної корекції. Тому в останнє десятиліття дослідники все частіше говорять про гібридизацію числових моделей із методами машинного навчання, які дають змогу «підлаштувати» загальну фізичну картину під локальні особливості конкретної електростанції чи вітропарку [16]. Тим не менше, залишається аксіомою, що у середньо- та довгострокових прогнозах (від кількох діб і більше) фізичні моделі поки що не мають рівноцінних конкурентів, адже жоден інший підхід не відтворює на стільки детально глобальну та регіональну атмосферну циркуляцію [17-19].

2.2. Статистичні методи (на прикладі ARIMA)

Статистичні методи прогнозування швидкості вітру відрізняються від фізичних числових моделей, оскільки вони не намагаються моделювати атмосферні процеси безпосередньо на основі рівнянь гідродинаміки та теплообміну [20-22]. Проте вони працюють з часовими рядами, де швидкість або потужність вітру розглядаються як послідовність спостережень у часі з певною кореляційною структурою. Один із найвідоміших представників цього ряду — модель ARIMA (AutoRegressive Integrated Moving Average).

Головна ідея статистичної моделі полягає в тому, що для передбачення майбутніх значень потрібно детально проаналізувати минулі спостереження. Якщо за умов стаціонарності процесу існує залежність між поточним і попередніми станами, її можна описати лінійними комбінаціями та відобразити у регресійному рівнянні.

Якщо $\{X_t\}$ — часовий ряд, то модель ARIMA(p, d, q) можна представити у вигляді:

$$(1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p)(1 - B)^d X_t = (1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q) \varepsilon_t,$$

де B — оператор зсуву, тобто $B(X_t) = X_{t-1}$, φ_i та θ_i — параметри моделі, d — порядок диференціювання (для усунення тренду), ε_t — випадкова складова (білий шум) [23-25].

При практичному застосуванні ARIMA може бути корисною для короткострокових прогнозів (від кількох хвилин до кількох годин). Її основна перевага — в мінімальних вимогах до обчислювальних ресурсів і в доволі простій інтерпретації результатів. Якщо оператор вітроелектростанції бачить у прогнозі певний «сплеск» або зниження, він може звернутися до коефіцієнтів моделі, аби з'ясувати, чи це пов'язано з внутрішньою динамікою ряду (автогресія) чи, можливо, зі специфічними «хвостами» шуму (ковзне середнє). Відповідно, це дозволяє краще розуміти природу тих коливань, що передбачає модель [26-28].

Однак статистичний підхід має й суттєві обмеження [25, 29, 30]. По-перше, ARIMA допускає відносну стаціонарність часового ряду після операції диференціювання, а вітер, особливо в регіонах з вираженою мінливістю, може не відповідати цим припущенням. По-друге, якщо в ряді наявні сильні нелінійні коливання, різкі пориви або екстремальні події (шторми), лінійні моделі надто «просідають». Тому в багатьох випадках дослідникам доводиться ускладнювати базову модель, переходячи до SARIMA (з урахуванням сезонності), ARIMAX (з екзогенними змінними — наприклад, температура, тиск), чи поєднувати статистику з машинним навчанням. Ще одна особливість полягає в тому, що ARIMA зазвичай не дає прямого фізичного пояснення щодо причини та процесу зміни вітру. Вона працює чисто емпірично: якщо в минулому була певна закономірність, то прогноз базується саме на повторенні цієї закономірності [31-33].

Незважаючи на всі ці обмеження, ARIMA часто застосовують у реальному секторі вітроенергетики, особливо коли йдеться про оперативний прогноз, де не потрібна дуже велика просторово-часова деталізація і де систему можна швидко перенавчати за кілька хвилин чи годин. В операційній діяльності такий прогноз може допомогти краще керувати балансуванням або наперед «передбачити» короткі провали в генерації, плануючи увімкнення резервів. Таким чином, ARIMA доречно використовувати у ситуаціях, коли необхідний швидкий, енергоощадний і достатньо точний у відносно спокійні метеорологічні періоди метод прогнозу, але при цьому в сильно змінних погодних умовах (буревії, різкі фронти) вона може давати помітні неточності [34-37].

2.3. Нейронні мережі на прикладі LSTM

Нейронні мережі, і особливо глибинні рекурентні їх різновиди, наприклад LSTM (Long Short-Term Memory), стали одним із популярних інструментів у прогнозуванні вітрових потоків. На відміну від суто статистичних підходів (наприклад, ARIMA) або фізичних (числових) моделей, LSTM не має закладеного априорного твердження про внутрішню природу атмосферних явищ. Вона «вчиться» безпосередньо на

наявних даних, виокремлюючи приховані закономірності та патерни, які складно описати традиційними рівняннями чи лінійними функціями [38-41]. Саме здатність до виявлення складних, часто нелінійних залежностей робить LSTM привабливою для вітроенергетики, де різні метеофактори можуть взаємодіяти непередбачуваним чином. У загальному вигляді її можна описати набором рівнянь :

$$\begin{aligned}f_t &= \sigma(W_f[h_{t-1}, x_t] + b_f); \\i_t &= \sigma(W_i[h_{t-1}, x_t] + b_i); \\\tilde{C}_t &= \tanh(W_C[h_{t-1}, x_t] + b_C); \\C_t &= f_t \odot C_{t-1} + i_t \odot \tilde{C}_t; \\o_t &= \sigma(W_o[h_{t-1}, x_t] + b_o); \\h_t &= o_t \odot \tanh(C_t),\end{aligned}$$

де x_t – вектор вхідних даних у момент часу t (наприклад, швидкість вітру, температура, додаткові метеопараметри), h_t – вихідний стан мережі, C_t – стан комірки пам'яті, f_t, i_t, o_t – «ворота» (forget, input, output) із сигмоїдною активацією $\sigma(\cdot)$, $\tilde{C}_t$ – параметр оновлення в комірці пам'яті, W_f, W_i, W_C, W_o і b_f, b_i, b_C, b_o – треновані матриці вагових коефіцієнтів і вектори зсуву, $\odot$ – покомпонентне множення, $\tanh(\cdot)$ – гіперболічний тангенс [42].

В основі LSTM лежить ідея покращеної рекурентної архітектури. У класичних рекурентних нейронних мережах (RNN) вихідний результат на кожному кроці часу залежить як від поточного вхідного вектора (наприклад, швидкість і напрям вітру на момент t), так і від стану мережі з попереднього кроку (h_{t-1}). Проте при довгих часових послідовностях у таких мережах виникає проблема «зникання» або «вибуху» градієнта під час навчання [43]. LSTM запобігає цьому, вводячи спеціальну структуру — «комірку пам'яті», у якій накопичується та за потреби модифікується інформація, що надходить на різних етапах. Це дозволяє моделі «пам'ятати» важливі події, що трапилися багато кроків тому, і водночас забувати непотрібну інформацію. Завдяки цій властивості LSTM добре працює з часовими рядами, де певні зміни, наприклад, різкий ріст швидкості вітру, можуть бути зумовлені ситуаціями, що почалися кількома годинами (або навіть днями) раніше [44].

Навчання LSTM-мережі зазвичай відбувається за схемою зворотного поширення похибки в часі. Модель ініціюють випадковими ваговими коефіцієнтами й подають на вхід довгу послідовність спостережень швидкості та напрямку вітру (а також інших метеорологічних параметрів: температури, тиску, вологості та ін.). Під час ітераційного проходження навчальної вибірки мережа поступово налаштовує свої внутрішні параметри, зменшуючи різницю між прогнозованими та фактичними значеннями. Для оптимізації часто застосовують стохастичний градієнтний спуск, зокрема алгоритми «Adam» і «RMSprop», що добре працюють із великими наборами даних [45, 46].

Однією з головних переваг LSTM є здатність одночасно опрацьовувати кілька вхідних змінних. Наприклад, якщо доступні дані з декількох метеорологічних станцій або супутникові знімки, які вказують на можливий розвиток шторму, мережа може навчитися враховувати таку інформацію паралельно з локальним часовим рядом швидкості вітру. Крім того, LSTM добре витримує «шум» у даних, адже її пам'ять уможливорює відокремлення стійких закономірностей від випадкових коливань.

Проте при застосуванні LSTM є і складнощі. Передусім LSTM має значну кількість параметрів, а отже потребує великих масивів ретроспективної інформації, щоб врахувати суттєві залежності й не перенавчитися на несуттєвих фактах. Це означає, що експлуатант вітрової електростанції має забезпечити потужну мережу збору даних (наприклад, системи диспетчерського керування і збору даних, метеостанції, супутниковий моніторинг) або отримувати відповідну інформацію з інших джерел упродовж тривалого періоду. Крім того, чим більший обсяг і складність моделі, то вищі вимоги до обчислювальних ресурсів: навчання глибокої LSTM-архітектури може тривати від кількох годин до кількох діб, залежно від розміру вибірки та масштабності мережі [47-50].

Ще один вагомий фактор, що потрібно враховувати, «прозорість» прогнозування. Якщо оператору потрібно з'ясувати, чому мережа спрогнозувала різке зростання швидкості вітру, LSTM, як правило, не дає прямого пояснення (на відміну від багатьох регресійних моделей, де можна безпосередньо інтерпретувати вагові коефіцієнти). Хоча нині розвивається напрям тлумачного штучного інтелекту, загалом результат LSTM часто сприймають як «чорну скриньку» — дуже гнучку й потужну, проте малозрозумілу з точки зору внутрішніх принципів роботи.

Попри ці складнощі, у короткострокових і середньострокових задачах прогнозування вітру LSTM дедалі частіше визнають одним із найсильніших рішень [51]. Це особливо помітно тоді, коли дані оновлюються часто (скажімо, раз на кілька секунд чи хвилин з різних сенсорів або вітрових генераторів) і коли потрібно враховувати багато чинників одночасно. Такі ситуації постійно виникають у процесі динамічного керування станцією або в разі необхідності спрогнозувати різкі коливання потужності.

Поєднання LSTM із іншими методами, наприклад числовими моделями прогнозу погоди чи статистичними корекціями, може ще підвищити точність [52-53]. У підсумку LSTM забезпечує високу гнучкість і адаптивність у проблемі прогнозування вітрових потоків, але разом з тим потребує ретельної підготовки даних, надійного обчислювального середовища й усвідомлення її складності для користувача.

2.4. Гібридні (енсемблеві) методи

Гібридні або енесемблеві методи представляють собою поєднання кількох різних моделей прогнозування, що взаємодіють у рамках однієї системи. Ідея полягає в тому, щоб усунути обмеження, властиві кожному окремому підходу, і скористатися їхніми перевагами. Цей підхід можна описати прикладом, коли використовують результати фізичної (числової) моделі, що забезпечує загальний огляд динаміки атмосфери, та доповнюють їх швидким статистичним або нейронним методом, який «локально» уточнює вихідні значення:

$$\hat{y}_t = \alpha \hat{y}_t^{(phys)} + \beta \hat{y}_t^{(stat)} + \gamma \hat{y}_t^{(LSTM)},$$

де $\hat{y}_t$ – підсумковий результат (гібридний) прогнозу, $\hat{y}_t^{(phys)}$, $\hat{y}_t^{(stat)}$, $\hat{y}_t^{(LSTM)}$ – результати прогнозів відповідних методів, α, β, γ – вагові коефіцієнти, що можуть визначатися емпірично (наприклад, шляхом мінімізації середньоквадратичної помилки на валідаційному наборі) і $\alpha + \beta + \gamma = 1$ (якщо виконується умова нормованості коефіцієнтів) [54-55].

У загальному вигляді гібридна система працює наступним чином. Спочатку формується результат попереднього прогнозу (наприклад, від NWP-моделі WRF), що може включати дані про швидкість вітру, температуру, вологість і напрям повітряних потоків у певній точці або регіоні [56]. Далі застосовується «коригувальний» блок, у якому може бути використана ARIMA-модель чи нейронна мережа, що зіставляє дані реальних вимірювань за минулі періоди з поточним результатом фізичної моделі. Якщо система помічає, що WRF регулярно робить похибку в конкретному діапазоні швидкостей, вона здатна вносити поправку, аби наблизити прогноз до реальних показників. Часто до цієї схеми додають і третій компонент (наприклад, LSTM) або зовсім іншу статистичну модель, аби «зважено» синтезувати результат від кількох джерел [57-60].

Одне з найважливіших питань у гібридизації — це спосіб, яким різні прогнози об'єднуються між собою [61]. Це можна зробити шляхом усереднення з певними ваговими коефіцієнтами. Наприклад, якщо ретроспективно встановлено, що фізична модель дає кращі результати при помірних швидкостях вітру, а нейронна мережа добре реагує на екстремальні значення, їм призначають різні вагові коефіцієнти залежно від поточної ситуації. У складніших випадках використовують різні алгоритми, наприклад байєсівське зважування (Bayesian model averaging), або методи еволюційної оптимізації (наприклад, генетичні алгоритми, метод рою часток), що підбирають найкраще співвідношення між виходами кількох моделей на історичних даних [62-64]. Така модель може суттєво зменшити підсумкову похибку:

$$p(y|D) = \sum_{k=1}^K p(y|M_k, D)p(M_k|D),$$

де D – доступні ретроспективні дані, M_k – k -та модель, $p(M_k|D)$ – імовірність того, що модель M_k «більше правильна» з погляду опису даних D [65].

Гібридні підходи особливо корисні в реальних умовах експлуатації вітрових електростанцій із кількох причин. По-перше, вони унеможливають створення стану, коли одна з моделей згенерує систематичне відхилення в певних режимах (наприклад, якщо числова NWP-модель якісно передбачить зростання швидкості вітру, але недооцінить її під час різких штормових фронтів). У такій ситуації коригувальна модель (статистична чи нейронна) згладжує цю похибку. По-друге, коли є декілька незалежних каналів інформації, можна більш точно оцінювати невизначеність (якщо результати прогнозів сильно відрізняються, це сигнал для оператора, що умови нестабільні й потрібне додаткове уточнення) [66-70].

Також слід враховувати, що гібридна система зазвичай складніша зі сторони налаштування і обчислення. Треба оперувати двома, трьома чи більше моделями, кожна з яких має свої вимоги. Якщо, наприклад, залучено фізичну модель WRF, то необхідно забезпечити значну обчислювальну потужність. Якщо додано LSTM, то потрібні досить великий об'єм даних й час на навчання нейронної мережі. Такий комплекс також вимагає більше уваги до сформованих результатів – необхідно відстежувати, чи не почала відхилятися якась складова, чи не застаріли граничні умови, чи правильно оновлюється інформація з метеорологічних сенсорів [71-72].

Ще одним важливим аспектом є з'ясування, в який момент і яким чином дані додавали в гібридну систему. Існує підхід, коли NWP-прогноз додає контекст для LSTM на рівні вхідних ознак, тобто нейромережа отримує не тільки ретроспективні дані щодо швидкості вітру, а й спрогнозовані WRF значення на кілька годин уперед, і вчиться коригувати їх. У протилежній схемі нейронна мережа спочатку формує свій прогноз, а потім цей результат зважується з результатом фізичної моделі. Ще можна комбінувати прогноз ARIMA та LSTM, де перша швидко формує лінійну оцінку, а друга – нелінійне уточнення. Можливих комбінацій формування гібридних моделей дійсно багато, і обрати оптимальний можна здебільшого експериментально, аналізуючи ретроспективний ряд помилок і оптимізуючи метрики, наприклад середньоквадратичну похибку (RMSE) чи середню абсолютну помилку (MAE) [73-74].

Незалежно від всіх особливостей, гібридні методи визнані одними з найперспективніших у задачах прогнозування вітропотенціалу. У багатьох публікаціях і практичних кейсах вони демонструють кращу стійкість до «викидів» і різких погодних змін, ніж окремі незалежні моделі. Якщо є достатні ресурс та інфраструктура, саме гібридні системи дозволяють максимально ефективно використовувати всі доступні джерела інформації – від великих обсягів історичних даних і локальних метеоспостережень до складних обчислень на основі моделей атмосферної фізики [75-76]. Для реального оператора вітрового парку такий підхід часто означає більш надійний спектр прогнозів, вчасне попередження про піки або провали швидкості вітру, а також зменшення загальних витрат, пов'язаних із резервними потужностями та позаплановими простоями обладнання.

2.5. Порівняння описаних методів

Фізичні, статистичні, нейронні й гібридні методи формують різні перспективи на задачу прогнозування швидкості вітру. Кожен підхід вирізняється власними сильними й слабкими сторонами, а їхній вибір залежить від поточних цілей, технічних можливостей і наявності даних. У деяких випадках досить запускати лише фізичний модуль, якщо потрібен глобальний чи середньостроковий прогноз для великої території. Проте така модель може «просідати» на локальних особливостях рельєфу або частих різких змінах вітру, особливо на коротких горизонтах.

Якщо ж підприємство чи оператор ВЕС орієнтуються на швидкі рішення і мають у розпорядженні значний обсяг ретроспективних даних локальних вимірювань, то статистичний підхід, наприклад ARIMA, може бути оптимальним. Він досить простий у реалізації, швидко навчається та формує оперативні прогнози з помірною точністю. Своєю чергою, нейронні мережі, передусім LSTM, є більш вигідними у випадках, коли потрібно моделювати складні, часто нелінійні залежності та коли є змога збагатити систему даними з багатьох джерел (спутникові знімки, дані про температуру й тиск, інші дані з метеорадарів). Такий метод здатний виокремлювати глибинні патерни і передбачати стрімкі стрибки або «довгі хвости» в динаміці швидкості вітру, хоча й вимагає великих ресурсів і не завжди формує пояснення передбачень.

Гібридні методи поєднують переваги одразу кількох моделей і здатні компенсувати їхні слабкі сторони. Як правило, у реальних системах управління ВЕС такий підхід знаходить найширше застосування, адже дає змогу формувати гнучкі, адаптивні й більш надійні прогнози. Сучасні мережеві архітектури й обчислювальні платформи (зокрема хмарні) дозволяють паралельно обробляти дані фізичних NWP-моделей, статистичних алгоритмів і нейромереж, а потім інтегрувати їх у єдиний результат.

Загалом, визначення «найкращого» методу залежить від того, наскільки тривалий прогноз необхідний, у яких географічних умовах розміщена ВЕС, якими даними володіє оператор і які апаратні ресурси доступні. Відповідно, для кожного конкретного сценарію доцільно проводити тестування (бенчмаркінг) кількох підходів і з'ясовувати, який із них формує кращі результати. У багатьох випадках саме комбінований підхід, що використовує інформацію з різних джерел і працює за принципом зважування чи коригування результатів, стає оптимальним вибором.

3. Обговорення результатів дослідження

У даному дослідженні було обрано Миколаївську область як одну з найперспективніших зон України для розвитку вітрової енергетики. За попередніми оцінками, саме в приморських та степових районах цього регіону спостерігаються високі та відносно стабільні швидкості вітру, що потенційно підвищує економічну доцільність встановлення ВЕС. Для аналізу було взято дані за 2016 рік на висоті 50 м над землею.

Дані про швидкість вітру отримано з проекту NASA POWER (Prediction of Worldwide Energy Resources), що є відкритим джерелом супутникових і модельних метеорологічних та сонячних даних. Цей проект надає інформацію про широкий спектр кліматичних параметрів, придатних для аналізу й планування в енергетичній галузі [77].

Авторами обрано статистичний підхід аналізу даних, тобто побудова часової характеристики зміну вітру за отриманими даними. Такий підхід дозволяє на основі бібліотеки даних побудувати часові залежності зміни вітру, що в подальшому слугуватимуть основою для прогнозних характеристик.

Часова характеристика описується залежністю:

$$y_i = F(x_i),$$

де x_i - порядковий номер часової точки, y_i - амплітуда швидкості вітру в контрольній точці.

З масиву точок у підсумку будується фінальна часова характеристика. Аналіз часової залежності дає змогу побачити циклічність зміни швидкості вітру, а також відслідкувати типові зміни з подальшою побудовою моделі вітрової генерації.

За отриманими даними побудовано часову характеристику зміни вітру протягом року (рис. 1).




Рисунок 1 - Графік швидкості вітру протягом 2016 року на висоті 50 метрів над землею

Рис. 1 демонструє динаміку зміни швидкості вітру залежно від часу протягом одного року, охоплюючи період з січня по грудень. На ньому видно значні коливання, що нерегулярно змінюються. Максимальні значення досягають приблизно 16 м/с, що спостерігається лише в кілька окремих днів, тоді як більшість даних лежить у діапазоні від 2 до 8 м/с. У деякі періоди швидкість вітру майже наближається до нуля, що вказує на штиль.

Хоча графік не демонструє явної сезонної закономірності, можна помітити, що восени та навесні частота пікових значень збільшується. Це свідчить про зміну погодних умов у ці періоди, які супроводжуються нестабільністю атмосфери. Зазвичай осінь і весна є сезонами посилення циклогенезу, що може пояснити сплески вітрової активності. Літні та зимові періоди, навпаки, характеризуються стабільнішими умовами, з нижчою частотою піків.

Для наочності варто проаналізувати зміну швидкості вітру в кожен окремий сезон (рис. 2-5).



Рисунок 2 - Графік швидкості вітру протягом зими 2015/2016рр. на висоті 50 метрів над землею




Рисунок 3 - Графік швидкості вітру протягом весни 2016р. на висоті 50 метрів над землею




Рисунок 4 - Графік швидкості вітру протягом літа 2016р. на висоті 50 метрів над землею




Рисунок 5 - Графік швидкості вітру протягом зими 2016р. на висоті 50 метрів над землею

Представлені графіки (рис. 2-5) дають змогу визначити більш «стабільні» місяці в сезоні та місяці з досить активною зміною швидкості вітру, проте не дають чіткої підстави для побудови прогнозних характеристик прийнятної достовірності.

Тому необхідно аналізувати отримані характеристики на базі кожного місяця. Відсутність великого масиву даних і нагромадження пікових точок дає змогу провести фільтрацію набору даних для отримання чіткої характеристики.

На графіках нижче наведені часові залежності зміни швидкості вітру для найбільш нестабільних місяців міжсезоння – вересня і квітня (рис. 6 та 7 відповідно).




Рисунок 6 - Графік швидкості вітру протягом квітня 2016р. на висоті 50 метрів над землею




Рисунок 7 - Графік швидкості вітру протягом вересня 2016р. на висоті 50 метрів над землею

Методи статистичного аналізу на прикладі зазначених місяців (рис. 6 і 7) показують, що пікові зміни швидкості вітру протягом місяця відповідають періоду 6-8 днів.

Також на зазначених графіках можна побачити випадкові складові часової залежності, які можна скорегувати для аналізу фільтрацією, тобто брати не всі відліки, а їх усереднені групи за певний період. Наприклад, для квітня цей період становить порядка 6-8 відліків. Така фільтрація дає змогу виокремити часову залежність і побудувати прогнозований графік зміни швидкості вітру для подальших цілей прогнозування.

Далі розглянемо графік за одну добу – 20 січня 2016 р. (рис. 8).

Як бачимо з рис. 8, добова залежність не є досить інформативною з точки зору прогнозування. Але ми не маємо відкидати аналіз добової залежності, адже використання інших підходів, таких як автокореляційний аналіз або методів спектрального аналізу може дати досить інформативні результати.

Якщо проаналізувати часові залежності посезонної зміни швидкості вітру, можна підтвердити теорію про більш стабільні показники швидкості вітру влітку і взимку – з графіків видно, що діапазон зміни вітру знаходиться в межах 0-17 м/с для зими і 0-13 м/с для літа. Для весняних і осінніх місяців ця зміна відбувається в діапазоні 0-18(20)м/с.

Але це не говорить про більшу або меншу ефективність роботи систем вітрової генерації – це лише дає підстави для необхідності проведення аналізу і побудови прогнозних характеристик для кожної пори року окремо.




Рисунок 8 - Графік швидкості вітру протягом вересня 2016р. на висоті 50 метрів над землею за 20 січня 2016 року

4. Висновки

У статті розглянуті поширені методи для прогнозування швидкості вітру, наведені їх переваги, недоліки та потреби.

Встановлено, що фізичні методи забезпечують високу точність за умов стабільних атмосферних процесів, тоді як статистичні методи ефективні при наявності великої кількості історичних даних. Гібридні моделі, що поєднують елементи різних підходів, демонструють найкращі результати за рахунок їхньої адаптивності та здатності враховувати різноманітні фактори впливу.

Особливу увагу приділено застосуванню алгоритмів машинного навчання, таких як нейронні мережі, метод опорних векторів та ансамблеві методи, які показують високу точність при достатньому обсязі навчальних даних. Використання цих алгоритмів у поєднанні з сучасними технологіями збору та обробки метеорологічної інформації сприяє покращенню якості прогнозів та забезпечує стабільну роботу вітроенергетичних систем.

Подальші дослідження можуть бути спрямовані на вдосконалення існуючих алгоритмів прогнозування шляхом інтеграції новітніх методів глибинного навчання, а також на оптимізацію комбінованих моделей для конкретних географічних регіонів. Це дозволить підвищити точність прогнозів і сприятиме більш ефективному використанню вітрової енергії.

Авторами запропонований підхід прямого статистичного аналізу бібліотеки даних з побудовою часових характеристик зміни швидкості вітру як один з перспективних для подальшого прогнозування. Зазначено, що найкращий період для аналізу – в межах місяця, за умови наявності масиву попередніх даних з кроком в одну годину, так як аналіз в межах року не дає змогу визначити основні пікові точки через великий об'єм інформації.

A. Zaporozhets^{1,2}, Dr. Sc. (Eng.), ORCID 0000-0002-0704-4116

V. Yeremenko^{1,2}, Dr. Sc. (Eng.), ORCID 0000-0002-4330-7518

A. Shcherban^{1,2}, Cand. Sc. (Eng.), ORCID 0000-0002-2643-5024

V. Verpeta¹, Ph. D. student, ORCID 0009-0001-3572-0388

¹General Energy Institute of National Academy of Sciences of Ukraine

²National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute"

ANALYSIS OF WIND SPEED FORECASTING METHODS TO IMPROVE THE EFFICIENCY OF WIND POWER PLANTS

The development of wind energy in Ukraine is an important strategic direction that contributes to energy security, reducing dependence on imported energy sources and reducing the negative impact on the environment. In conditions of market instability and climate change, accurate wind speed forecasting is a critical factor for the effective functioning of wind power plants (WPPs). The aim of the work is a comprehensive analysis of modern

wind speed forecasting methods in order to increase the efficiency of WPP operation and formulate recommendations for optimizing forecasting processes. The article considers physical (numerical) methods based on the Navier–Stokes equations and atmospheric dynamics modeling, in particular the WRF and ECMWF models. Their advantages in medium- and long-term forecasting are determined, as well as the main limitations associated with computational complexity and the need for accurate input data. Statistical methods, such as ARIMA, are studied, which are effective for short-term forecasting, but have limited ability to take into account nonlinear processes and sudden changes in wind flow. Special attention is paid to the application of machine learning methods and hybrid approaches that combine physical modeling with statistical analysis and deep learning algorithms. Such methods allow adapting forecasting models to specific operating conditions of wind farms and increasing the accuracy of forecasts. The conclusion is made about the need for further improvement of forecasting methods, in particular, the development of adaptive models that use large data sets and take into account regional features of wind resources. The proposed recommendations may be useful for wind farm operators, investors and scientists involved in the analysis of wind resources and the development of forecasting algorithms.

Keywords: wind energy, wind speed forecasting, numerical modeling, statistical methods, machine learning, hybrid approaches.

References

1. Nam'yasenکو, V. (2024). Review of the Priority Directions for Post-war Development of Ukraine's Economy. *Naukovi perspektivi (Scientific Perspectives)*, (10), 52. [http://dx.doi.org/10.52058/2708-7530-2024-10\(52\)-603-613](http://dx.doi.org/10.52058/2708-7530-2024-10(52)-603-613)
2. Ryabtsev, G., & Omelchenko, V. (2024). Review of the Energy Sector's Performance in September 2024: October 2024.
3. Oberemok, D. O. et al. (2024). Analysis of the State of Electrical Networks and Review of Current Issues: Prospects for the Integration of Solar Power Plants and Energy Storage Systems.
4. Stogniy, B. S., & Sopel, M. F. (2013). Fundamentals of Monitoring in Power Engineering: On the Concept of Monitoring. *Technical Electrodynamics*.
5. Chair of the Board of the Ukrainian Wind Energy Association. (2024). On the State and Prospects of the Industry. <https://ua-energy.org/uk/posts/andrii-konechenkov-za-dva-roky-viiny-vvedeno-blyzko-230-mvt-vitrogeneratsii>
6. Pape, M., & Kazerani, M. (2020). Turbine startup and shutdown in wind farms featuring partial power processing converters. *IEEE Open Access Journal of Power and Energy*, 7, 254–264. <https://doi.org/10.1109/OAJPE.2020.3006352>
7. Bilyavskiy, M. (2021). *Ukraine and Global Decarbonization Policy*. Razumkov Centre. <https://doi.org/10.32782/2524-0072/2023-54-76>
8. Hoksbergen, N., Akkerman, R., & Baran, I. (2022). The Springer model for lifetime prediction of wind turbine blade leading edge protection systems: A review and sensitivity study. *Materials*, 15(3), 1170. <https://doi.org/10.3390/ma15031170>
9. Ackermann, T. (2005). *Wind Power in Power Systems*. Wiley. <https://doi.org/10.1002/0470012684>
10. Venkatramakrishnan, R. та ін. (2020). Low speed wind turbines for power generation: A review. <https://doi.org/10.56532/mjsat.v4i3.352>
11. Babak, V. P. та ін. (2021). Models and Measures in Measurements and Monitoring. Springer International Publishing. <https://doi.org/10.1007/978-3-030-70783-5>
12. Babak, V. P. та ін. (2021). Problems and features of measurements. *Studies in Systems, Decision and Control*, 360, 1–31. https://doi.org/10.1007/978-3-030-72361-3_1
13. Application of material measure in measurements: Theoretical aspects. http://dx.doi.org/10.1007/978-3-030-69189-9_15
14. Babak, V., Zaporozhets, A., Kuts, Y., Scherbak, L., & Eremenko, V. (2021). *Studies in Systems, Decision and Control*, 346, 261–269. https://doi.org/10.1007/978-3-030-69189-9_15
15. Manwell, J. F., McGowan, J. G., & Rogers, A. L. (2010). *Wind Energy Explained: Theory, Design and Application*. John Wiley & Sons. <http://dx.doi.org/10.1002/9781119994367>
16. Burton, T., Jenkins, N., Sharpe, D., & Bossanyi, E. (2011). *Wind Energy Handbook*. Wiley. <https://doi.org/10.1002/0470846062>
17. Archer, C. L., & Jacobson, M. Z. (2005). Evaluation of global wind power. *Journal of Geophysical Research*, 110, D12104. <https://doi.org/10.1029/2004JD005462>
18. Sørensen, J. D. (2011). *Reliability of Wind Turbines – Standards, Modeling, and Management*. Springer. <http://dx.doi.org/10.3390/en8042908>
19. Hansen, M. O. L. (2015). *Aerodynamics of Wind Turbines*. Routledge. <http://dx.doi.org/10.4324/9781315769981>
20. Chodakowska, E. та ін. (2023). ARIMA models in solar radiation forecasting in different geographic locations. *Energies*, 16(13), 5029. <https://doi.org/10.3390/en16135029>
21. Kavasseri, R. G., & Seetharaman, K. (2009). Day-ahead wind speed forecasting using f-ARIMA models. *Renewable Energy*, 34(5), 1388–1393. <https://doi.org/10.1016/j.renene.2008.09.006>
22. Singh, S. N. et al. (2019). Repeated wavelet transform based ARIMA model for very short-term wind speed forecasting. *Renewable Energy*, 136, 758–768. <https://doi.org/10.1016/j.renene.2019.01.031>
23. Nayak, A. K. et al. (2015). ARIMA based statistical approach to predict wind power ramps. 2015 IEEE Power & Energy Society General Meeting, 1–5. <https://doi.org/10.1109/PESGM.2015.7286237>
24. Sim, S. K., Maass, P., & Lind, P. G. (2018). Wind speed modeling by nested ARIMA processes. *Energies*, 12(1), 69. <https://doi.org/10.3390/en12010069>
25. Fara, L. та ін. (2021). Forecasting of energy production for photovoltaic systems based on ARIMA and ANN advanced models. *International Journal of Photoenergy*, 2021(1), 6777488. <https://doi.org/10.1155/2021/6777488>

26. Tawn, R., & Browell, J. (2022). A review of very short-term wind and solar power forecasting. *Renewable and Sustainable Energy Reviews*, 153, 111758. <https://doi.org/10.1016/j.rser.2021.111758>
27. Zhu, X., & Genton, M. G. (2012). Short-term wind speed forecasting for power system operations. *International Statistical Review*, 80(1), 2–23. <https://doi.org/10.1111/j.1751-5823.2011.00168.x>
28. Khosravi, A., Machado, L., & Nunes, R. O. (2018). Time-series prediction of wind speed using machine learning algorithms: A case study Osorio wind farm, Brazil. *Applied Energy*, 224, 550–566. <https://doi.org/10.1016/j.apenergy.2018.05.043>
29. Palomares-Salas, J. C. et al. (2009). ARIMA vs. Neural networks for wind speed forecasting. 2009 IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, 129–133. <https://doi.org/10.1109/CIMSA.2009.5069932>
30. Zhao, P. et al. (2010). Wind speed forecasting using support vector regression. 2010 5th IEEE Conference on Industrial Electronics and Applications, 882–886. <http://dx.doi.org/10.1109/ICIEA.2010.5515626>
31. Elsaraiti, M., & Merabet, A. (2021). A comparative analysis of the ARIMA and LSTM predictive models and their effectiveness for predicting wind speed. *Energies*, 14(20), 6782. <https://doi.org/10.3390/en14206782>
32. Grigonytė, E., & Butkevičiūtė, E. (2016). Short-term wind speed forecasting using ARIMA model. *Energetika*, 62(1-2). <http://dx.doi.org/10.6001/energetika.v62i1-2.3313>
33. Shi, J., Guo, J., & Zheng, S. (2012). Evaluation of hybrid forecasting approaches for wind speed and power generation time series. *Renewable and Sustainable Energy Reviews*, 16(5), 3471–3480. <https://doi.org/10.1016/j.rser.2012.02.044>
34. Shukur, O. B., & Lee, M. H. (2015). Daily wind speed forecasting through hybrid KF-ANN model based on ARIMA. *Renewable Energy*, 76, 637–647. <https://doi.org/10.1016/j.renene.2014.11.084>
35. Campbell, P. R. J. (2007). Short-term wind energy forecasting. *Proceedings of the 2007 IEEE Canada Electrical Power Conference*, October 25–26, Montreal, Canada, 342–346. <http://dx.doi.org/10.1109/CIEM52821.2021.9614935>
36. Efthimiou, G. C., et al. (2017). A statistical model for the prediction of wind-speed probabilities in the atmospheric surface layer. *Boundary-Layer Meteorology*, 163, 179–201. <https://doi.org/10.1007/s10546-016-0221-2>
37. González-Sopeña, J. M., Pakrashi, V., & Ghosh, B. (2021). An overview of performance evaluation metrics for short-term statistical wind power forecasting. *Renewable and Sustainable Energy Reviews*, 138, 110515. <https://doi.org/10.1016/j.rser.2020.110515>
38. Krakovna, V., & Doshi-Velez, F. (2016). Increasing the interpretability of recurrent neural networks using hidden Markov models. *arXiv preprint arXiv:1606.05320*. <https://arxiv.org/abs/1606.05320>
39. Mishra, A. K., & Ramesh, L. (2009). Application of neural networks in wind power (generation) prediction. *Proceedings of the 2009 International Conference on Sustainable Power Generation and Supply*, April 6–7, Nanjing, China, 1–5. <http://dx.doi.org/10.14569/IJACSA.2016.070336>
40. Wu, Q., et al. (2021). Ultra-short-term multi-step wind power forecasting based on CNN-LSTM. *IET Renewable Power Generation*, 15(5), 1019–1029. <https://doi.org/10.1049/rpg2.12085>
41. Ata, R. (2015). RETRACTED: Artificial neural networks applications in wind energy systems: A review. *Renewable and Sustainable Energy Reviews*. <https://doi.org/10.1016/j.rser.2015.04.166>
42. Sherstinsky, A. (2020). Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network. *Physica D: Nonlinear Phenomena*, 404, 132306. <https://doi.org/10.1016/j.physd.2019.132306>
43. Cao, Q., Ewing, B. T., & Thompson, M. A. (2012). Forecasting wind speed with recurrent neural networks. *European Journal of Operational Research*, 221(1), 148–154. <https://doi.org/10.1016/j.ejor.2012.02.042>
44. Li, S. (2003). Wind power prediction using recurrent multilayer perceptron neural networks. *Proceedings of the 2003 IEEE Power Engineering Society General Meeting*, July 13–17, Toronto, Canada, 4, 2325–2330. <http://dx.doi.org/10.1109/PES.2003.1270992>
45. Chen, G., et al. (2022). Short-term wind speed forecasting based on long short-term memory and improved BP neural network. *International Journal of Electrical Power & Energy Systems*, 134, 107365. <https://doi.org/10.1016/j.ijepes.2021.107365>
46. Xin, Z., et al. (2024). An enhanced feature extraction based long short-term memory neural network for wind power forecasting via considering the missing data reconstruction. *Energy Reports*, 11, 97–114. <https://doi.org/10.1016/j.egyr.2023.11.040>
47. Fukuoka, R., et al. (2018). Wind speed prediction model using LSTM and 1D-CNN. *Journal of Signal Processing*, 22(4), 207–210. <https://doi.org/10.2299/jsp.22.207>
48. Wang, H. Z., et al. (2016). Deep belief network based deterministic and probabilistic wind speed forecasting approach. *Applied Energy*, 182, 80–93. <https://doi.org/10.1016/j.apenergy.2016.08.108>
49. Gao, F., & Li, X. (2020). Improved forecasting of wind speed using deep belief networks. *Renewable Energy*, 148, 421–430. <http://dx.doi.org/10.1002/tee.22802>
50. Sarangi, S., Dash, P. K., & Bisoi, R. (2024). Short-term prediction of wind power using an improved kernel based optimized deep belief network. *Energy Conversion and Management*, 316, 118821. <https://doi.org/10.1016/j.enconman.2024.118821>
51. Wei, D., et al. (2021). Wind speed forecasting system based on gated recurrent units and convolutional spiking neural networks. *Applied Energy*, 292, 116842. <https://doi.org/10.1016/j.apenergy.2021.116842>
52. Wang, Y., et al. (2021). A review of wind speed and wind power forecasting with deep neural networks. *Applied Energy*, 304, 117766. <https://doi.org/10.1016/j.apenergy.2021.117766>
53. Shin, H., Rüttgers, M., & Lee, S. (2022). Neural networks for improving wind power efficiency: A review. *Fluids*, 7(12), 367. <https://doi.org/10.3390/fluids7120367>

- 54.Ye, X. W., Ding, Y., & Wan, H. P. (2019). Machine learning approaches for wind speed forecasting using long-term monitoring data: A comparative study. *Smart Structures and Systems*, 24(6), 733–744. <http://dx.doi.org/10.12989/sss.2019.24.6.733>
- 55.Zhang, W., et al. (2013). Short-term wind speed forecasting based on a hybrid model. *Applied Soft Computing*, 13(7), 3225–3233. <https://doi.org/10.1016/j.asoc.2013.02.016>
- 56.Tiwari, S., & Ling, J. M. (2021). A review of wind energy forecasting techniques. *Proceedings of the 2021 International Conference on Technology and Policy in Energy and Electric Power (ICT-PEP)*, October 19-21, Jakarta, Indonesia, 213–218. <https://doi.org/10.1109/ICT-PEP53949.2021.9600993>
- 57.Deng, X., et al. (2020). Wind power forecasting methods based on deep learning: A survey. *Computer Modeling in Engineering & Sciences*, 122(1), 273–302. <http://dx.doi.org/10.32604/cmes.2020.08768>
- 58.Tascikaraoglu, A., & Uzunoglu, M. (2014). A review of combined approaches for prediction of short-term wind speed and power. *Renewable and Sustainable Energy Reviews*, 34, 243–254. <https://doi.org/10.1016/j.rser.2014.03.033>
- 59.Bazonis, I. K., & Georgilakis, P. S. (2021). Review of deterministic and probabilistic wind power forecasting: Models, methods, and future research. *Electricity*, 2(1), 13–47. <https://doi.org/10.3390/electricity2010002>
- 60.Tang, M., et al. (2021). Review and perspectives of machine learning methods for wind turbine fault diagnosis. *Frontiers in Energy Research*, 9, 751066. <https://doi.org/10.3389/fenrg.2021.751066>
- 61.Arora, P., et al. (2022). Probabilistic wind power forecasting using optimized deep auto-regressive recurrent neural networks. *IEEE Transactions on Industrial Informatics*, 19(3), 2814–2825. <http://dx.doi.org/10.1109/TII.2022.3160696>
- 62.Yousuf, M. U., Al-Bahadly, I., & Avci, E. (2021). Short-term wind speed forecasting based on hybrid MODWT-ARIMA-Markov model. *IEEE Access*, 9, 79695–79711. <http://dx.doi.org/10.1109/ACCESS.2021.3084536>
- 63.Nookesh, V. M., et al. (2021). Comparative study of wind speed forecasting using machine learning. *Proceedings of the 2021 2nd International Conference on Smart Electronics and Communication (ICOSEC)*, October 7-9, Trichy, India, 1121–1126. <http://dx.doi.org/10.1109/ICOSEC51865.2021.9591767>
- 64.Okumus, I., & Dinler, A. (2016). Current status of wind energy forecasting and a hybrid method for hourly predictions. *Energy Conversion and Management*, 123, 362–371. <https://doi.org/10.1016/j.enconman.2016.06.053>
- 65.de Mattos Neto, P. S. G., et al. (2021). An adaptive hybrid system using deep learning for wind speed forecasting. *Information Sciences*, 581, 495–514. <http://dx.doi.org/10.1016/j.ins.2021.09.054>
- 66.Aly, H. H. H. (2020). A novel deep learning intelligent clustered hybrid models for wind speed and power forecasting. *Energy*, 213, 118773. <https://doi.org/10.1016/j.energy.2020.118773>
- 67.Hu, H., Wang, L., & Tao, R. (2021). Wind speed forecasting based on variational mode decomposition and improved echo state network. *Renewable Energy*, 164, 729–751. <https://doi.org/10.1016/j.renene.2020.09.109>
- 68.Lipu, M. S. H., et al. (2021). Artificial intelligence based hybrid forecasting approaches for wind power generation: Progress, challenges and prospects. *IEEE Access*, 9, 102460–102489. <http://dx.doi.org/10.1109/ACCESS.2021.3097102>
- 69.Chen, J., et al. (2018). Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization. *Energy Conversion and Management*, 165, 681–695. <http://dx.doi.org/10.1016/j.enconman.2018.03.098>
- 70.Lv, S. X., & Wang, L. (2023). Multivariate wind speed forecasting based on multi-objective feature selection approach and hybrid deep learning model. *Energy*, 263, 126100. <https://doi.org/10.1016/j.energy.2022.126100>
- 71.Song, D., et al. (2024). Review of AI-based wind prediction within recent three years: 2021–2023. *Energies*, 17(6), 1270. <https://doi.org/10.3390/en17061270>
- 72.Wang, J., & Hu, J. (2015). A robust combination approach for short-term wind speed forecasting and analysis – Combination of the ARIMA, ELM, SVM and LSSVM forecasts using a GPR model. *Energy*, 93, 41–56. <https://doi.org/10.1016/j.energy.2015.08.045>
- 73.Suárez-Cetrulo, A. L., et al. (2022). Wind power forecasting using ensemble learning for day-ahead energy trading. *Renewable Energy*, 191, 685–698. <http://dx.doi.org/10.1016/j.renene.2022.04.032>
- 74.Du, P., et al. (2019). A novel hybrid model for short-term wind power forecasting. *Applied Soft Computing*, 80, 93–106. <https://doi.org/10.1016/j.asoc.2019.03.035>
- 75.da Silva, R. G., et al. (2021). A novel decomposition-ensemble learning framework for multi-step ahead wind energy forecasting. *Energy*, 216, 119174. <https://doi.org/10.1016/j.energy.2020.119174>
- 76.Ghorbani, M. A., et al. (2016). Short-term wind speed predictions with machine learning techniques. *Meteorology and Atmospheric Physics* <https://doi.org/10.1007/s00703-015-0398-9>
- 77.NASA POWER [Electronic resource]. Accessed: <https://power.larc.nasa.gov/> (10.01.2025)

Надійшла: 27.02.2025

Received: 27.02.2025