

Урум Н.С.

Дунайський інститут водного транспорту Державного університету інфраструктури та технологій

Трофименко І.В.

Дунайський інститут водного транспорту Державного університету інфраструктури та технологій

Іваненко В.М.

Дунайський інститут водного транспорту Державного університету інфраструктури та технологій

Федунов В.М.

Дунайський інститут водного транспорту Державного університету інфраструктури та технологій

Бажак О.В.

Дунайський інститут водного транспорту Державного університету інфраструктури та технологій

ДОСЛІДЖЕННЯ НАПРЯМІВ ПІДВИЩЕННЯ ЯКОСТІ ХВИЛЬОВИХ МОДЕЛЕЙ З ВИКОРИСТАННЯМ МЕТЕОРОЛОГІЧНИХ МОДЕЛЕЙ НА ОСНОВІ МЕТОДІВ МАШИННОГО НАВЧАННЯ

Загальним підходом у розвитку океанічних прогностичних систем натеper є інтегрування гідродинамічних моделей атмосфери, циркуляції океану, вітрового хвилювання та інших. У хвильових моделях глибокого моря розвиток хвиль переважно контролюється вітром. Вихідна інформація про вітри у розрахунках властивостей хвиль представляється як послідовності діагностичних і прогностичних полів векторів вітру. Більшість хвильових моделей, що застосовуються натеper для глибокого моря, засновані на чисельному вирішенні рівняння радіаційного балансу для двовимірного хвильового спектра. Важливу роль для підвищення якості хвильових моделей відіграє підвищення точності прогнозування швидкості підвищення вітру над водною поверхнею в рамках відповідних ансамблевих моделей. Одним з підходів до ефективного застосування на сучасному рівні оперативних прогностичних систем океану загалом та хвильових моделей зокрема є залучення надвеликих обсягів даних з використанням як прогностичних методів методів машинного навчання. У статті досліджуються напрями підвищення якості хвильових моделей з використанням метеорологічних моделей на основі методів машинного навчання. Однією із центральних проблем моделювання вітрового хвилювання є вивчення механізмів, що формують спектр підвищення якості хвильових моделей, та своєю чергою підвищення точності прогнозування швидкості підвищення вітру над водною поверхнею в рамках відповідних ансамблевих моделей. Результати досліджень показують, що ефективне застосування супутникових даних в оперативному прогнозі з допомогою методів машинного навчання має величезний потенціал. Своєю чергою підвищення точності прогнозування гідродинамічних моделей атмосфери на основі машинного навчання дозволить забезпечити підвищення точності прогнозування моделей вітрового хвилювання у рамках відповідних ансамблевих моделей у сучасних оперативних прогностичних системах океану.

Ключові слова: океан, хвильова модель, вітрове хвилювання, прогнозування хвилювання, метеорологічна модель, тропічний циклон, машинне навчання.

Постановка проблеми. У сучасних оперативних прогностичних системах океану реалізовано інтегрування технології математичної моделі спільно з процедурним засвоєнням даних спостережень, обробкою та поданням прогностичної інформації у зручній для користувачів формі у разі передачі їх у режимі реального часу. Загальним підходом у розвитку океанічних прогностичних систем натеper є інтегрування гідродинамічних

моделей атмосфери, циркуляції океану, вітрового хвилювання та інших.

Прогнозування хвилювання – це процес оцінки того, як змінюватимуться параметри хвилювання під впливом вітру на водну поверхню [1; 2]. Залежність полів хвилювання від полів вітру визначає тісний зв'язок між хвильовими та метеорологічними моделями. Тому за розвитком атмосферних моделей розвиваються і хвильові

моделі. З поліпшенням якості атмосферних моделей покращувалася якість хвильових моделей і, як наслідок, точність прогнозів, що випускаються. Крім того, у міру поглиблення розуміння фізичних процесів, що відбуваються в океані та атмосфері, які визначають механізми взаємодії хвиль з приводним шаром атмосфери, стає все більш зрозумілим, що ці взаємодії є складнішими та глибшими, ніж уявлялося досі. У хвильових моделях глибокого моря розвиток хвиль переважно контролюється вітром. Вихідна інформація про вітри у розрахунках властивостей хвиль представляється як послідовності діагностичних і прогностичних полів векторів вітру.

Більшість хвильових моделей, що застосовуються нині для глибокого моря, засновані на чисельному вирішенні рівняння радіаційного балансу для двовимірного хвильового спектра. Рівняння перенесення визначає поширення різних компонент хвиль у спектрі з різними частотами та напрямками поширення з відповідними груповими швидкостями. Зміна енергії цих компонентів відбувається під дією вітру, дисипації та нелінійних взаємодій високого порядку. За допомогою хвильових моделей розраховується повний двовимірний спектр хвиль на кожному тимчасовому кроці та у кожному вузлі сіткової області. Рівняння перенесення енергії має вигляд [2]:

$$\frac{\partial E}{\partial t} + \nabla \cdot (C_g E) = S, \quad (1)$$

де $E = E(f, \theta, x, t)$ – двовимірний спектр хвилювання (спектр коливань поверхні), що залежить від частоти f та напрямку хвиль θ ;

$C_g = C_g(f, \theta)$ – групова швидкість на глибокій воді;
 S – функція джерела, що включає різні процеси, такі як S_{in} – надходження енергії за рахунок вітру, S_{nl} – нелінійна передача енергії внаслідок взаємодії хвиль, S_{ds} – дисипація енергії за рахунок обвалення гребенів хвиль та внутрішнього турбулентного тертя.

Оцінки різних компонентів у правій частині рівняння (1) показують їх різні просторово-часові масштаби, в яких виявляються ті чи інші еволюційні механізми, що визначають поведінку поля вітрового хвилювання. Вивчення механізмів, що формують спектр, натепер є однією із центральних проблем моделювання вітрового хвилювання. У зв'язку з цим важливу роль для підвищення якості хвильових моделей відіграє підвищення точності прогнозування швидкості підвищення вітру над водною поверхнею в рамках відповідних ансамблевих моделей.

Одним з підходів до ефективного застосування на сучасному рівні оперативних прогностичних

систем океану загалом та хвильових моделей зокрема є залучення надвеликих обсягів даних з використанням як прогностичних методів методів машинного навчання.

Аналіз літературних джерел. У роботах [1; 2; 4; 6–8] розглядаються десятки різних моделей відтворення вітрового хвилювання. Їх можна поділити на чотири групи: спектральні дискретні; спектральні параметричні; інтегральні параметричні; інші (емпіричні, енергетичні, монохроматичні та різні їх комбінації). Але питання підвищення якості хвильових моделей з використанням метеорологічних моделей на основі методів машинного навчання в наявних роботах не розкриті, тому потребують додаткових досліджень.

Метою статті є дослідження напрямів підвищення якості хвильових моделей з використанням метеорологічних моделей на основі методів машинного навчання.

Виклад основного матеріалу дослідження. Машинне навчання (machine learning (ML)) – клас методів штучного інтелекту, характерною рисою яких є не пряме розв'язання задачі, а навчання за рахунок застосування рішень множини подібних задач. Для побудови таких методів використовуються засоби математичної статистики, чисельних методів, математичного аналізу, методів оптимізації, теорії ймовірностей, теорії графів, різноманітної техніки роботи з даними у цифровій формі [3].

У роботі [4] запропоновано алгоритм ML, що передбачає можливість швидкого посилення тропічного циклону.

Тропічний циклон – тип циклону, або погодної системи низького тиску, що виникає над теплою морською поверхнею та супроводжується потужними грозами, випаданням зливових опадів та вітрами штормової сили. Тропічні циклони здатні викликати як надзвичайної сили зливи, так і великі хвилі на поверхні моря, штормові припливи і смерчі. Тропічні циклони можуть виникати та підтримувати свою силу лише над поверхнею великих водойм [5].

Передбачити, чи тропічний циклон почне різко посилюватися, тобто чи збільшиться швидкість вітру більше ніж наприклад на 30 вузлів (або 55 кілометрів за годину) за добу, дуже складно. Багато в чому це пов'язане з тим, що зростання швидкості вітру залежить від умов навколишнього середовища, а також від процесів, що відбуваються всередині циклону.

На основі аналізу супутникових даних, зібраних у рамках проекту NASA та JAXA Tropical Rainfall Measuring Mission, який проводився з 1997 по

2015 рік, у роботі виділено кілька основних факторів, пов'язаних зі зміною швидкості руху вітру. Так, зафіксовано, що ефективним індикатором того, що сила циклону зросте протягом наступних 24 годин, є кількість опадів усередині ядра циклону – кільця гроз радіусом до 100 кілометрів, що оточує так зване око бурі. Чим сильніший дощ усередині цієї області, тим більша ймовірність того, що циклон посилиться. Крім того, зміна сили вітру також пов'язана з вмістом крижин у хмарах і температурою повітря, що піднімається з ока бурі.

Ці індикатори були додані до тих, що використовує програма Національного центру ураганів (National Hurricane Center (NHC)). Зокрема, до їх числа входить попередня 12-годинна зміна інтенсивності циклону, відсоток площі із загальною кількістю опадів менше 45 міліметрів та інші.

Щоб перевірити передбачувану ефективність різних вимірювань структурних елементів циклону, використовуються методи машинного навчання для прогнозу RI (Rapid Intensification) із предикторами SHIPS RII (Statistical Hurricane Intensity Prediction Scheme Rapid Intensification Index) та параметрами, що становлять внутрішні структурні елементи циклону. Щоб порівняти прогнози ML з моделями NHC, у моделі ML були включені лише випадки з Атлантики та EPAC. Моделі ML навчалися для басейнів Атлантики та EPAC окремо з використанням бази даних розвитку SHIPS, яка ґрунтується на даних повторного аналізу системи кліматичних прогнозів (CFSR) та даних GOES IR за період з 1998 по 2008 рр. Потім модель тестувалася у прогнозуванні RI з використанням архівних даних Національного центру екологічного прогнозування (NCEP) за період з 2009 по 2014 роки.

Результати прогнозу для детермінованого прогнозу RI оцінюються за допомогою трьох показників [4]:

– ймовірності виявлення (probability of detection (POD)):

$$POD = \frac{a}{a + c}; \quad (2)$$

– коефіцієнта хибних тривог (false alarm ratio (FAR)):

$$FAR = \frac{b}{a + b}; \quad (3)$$

– оцінки Пірса (Peirce Skill Score (PSS)):

$$PSS = \frac{ad - bc}{(a + c)(b + d)}, \quad (4)$$

де a, b, stad – відповідно позначення кількості істинно позитивних, хибнопозитивних, хибнонегативних, істинно негативних значень;

1, 0 та 1 – кращі оцінки відповідно до виразів (2–4).

Для ймовірнісних прогнозів використовувався також оцінка Брієра (Brier Skill Score (BSS)), яка є показником, що зазвичай використовується в ННС. Оцінка Брієра для моделі прогнозу визначається як:

$$BSM = \frac{1}{N} \sum_{i=1}^N (f_i - O_i), \quad (5)$$

де f_i – ймовірність прогнозу;

O_i – параметр, який набуває значення 1 або 0, якщо подія відповідно спостерігається чи ні.

BSS щодо кліматології визначається як:

$$BSS = \left(1 - \frac{BSM}{BSC}\right), \quad (6)$$

де BSC – оцінка кліматологічного прогнозу.

Позитивне значення BSS вказує на кращий прогноз ніж кліматологічний прогноз, а BSS, рівне 1, відповідає ідеальній моделі. У цьому дослідженні кліматологічна ймовірність RI у кожному басейні заснована на значеннях, перелічених у наборі даних прогнозу SHIPS RII для цунамі у 2009–2014 рр.

У роботі використовується ряд схем машинного навчання, включаючи логістичну регресію, випадковий прогноз, дерево рішень та додаткове дерево, доступні у стандартному пакеті Pythonscikit-learn та IBM Watson Studio, для побудови нашої схеми ML прогнозування інтенсивності циклонів (ML Hurricane Intensity Forecast Scheme (ML) HIFS)). Середньозважене значення ймовірностей RI із чотирьох схем ML будується для остаточної моделі, що забезпечує дихотомічний класифікатор RI та відповідну ймовірність RI.

На рис. 1 показано порівняльний аналіз результатів моделювання (сірі стовпці являють собою оцінки прогнозу на основі використання моделі NHC, а сині та червоні стовпці представляють результати прогнозування з використанням запропонованої моделі ML на основі предикторів SHIPS RII без та з урахуванням надлишкових опадів) [4]:

1. Рисунки 1a та 1e – результати оцінки за метрикою BSS для даних навчання з 1998 по 2008 рік для трьох порогових значень RI (25, 30 та 35 вузлів).

2. Рисунки 1b та 1f – результати оцінки за метрикою PSS для даних навчання з 2009 по 2014 роки.

3. Рисунки 1c та 1g – результати оцінки за метрикою POD для даних навчання з 2009 по 2014 роки.

4. Рисунки 1d та 1h – результати оцінки за метрикою FAR для даних навчання з 2009 по 2014 роки.

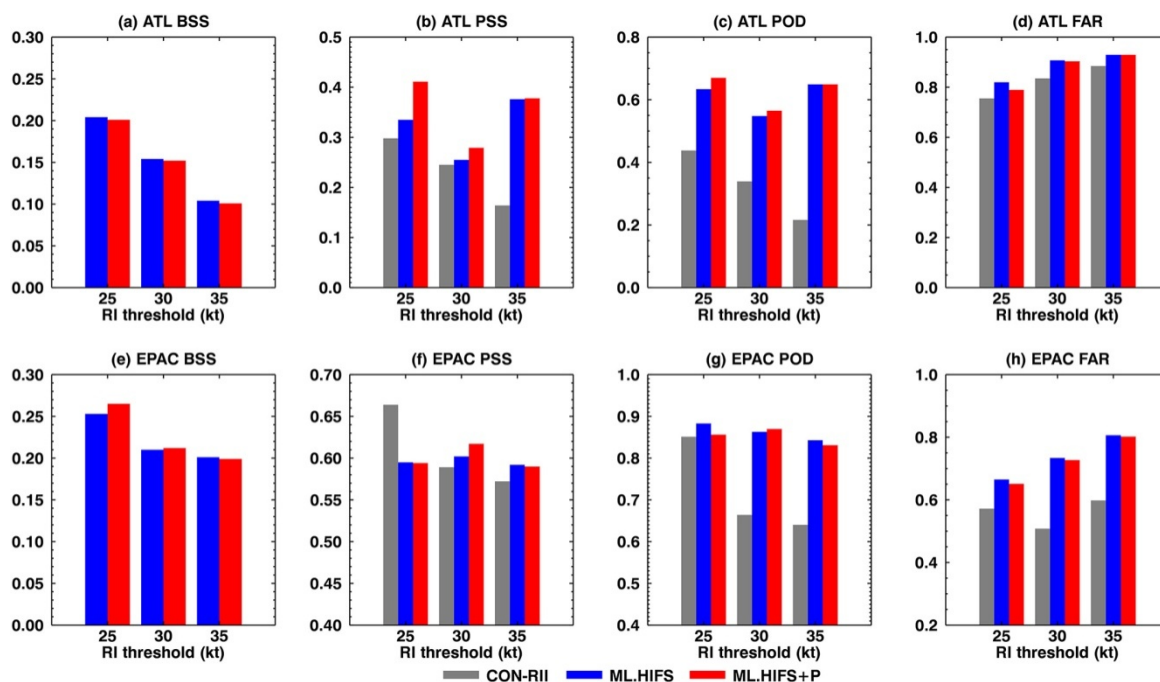


Рис. 1. Порівняльний аналіз результатів моделювання

При цьому тести показали, що у випадку із цунами, швидкість вітру яких збільшилася як мінімум на 56 кілометрів на годину протягом 24 годин, нова модель на основі використання ML показала на 60 відсотків найкращий результат порівняно з поточною. Для сильніших цунами, де швидкість вітру зростала не менше ніж на 64 кілометри на годину за добу, зростання прогнозованої точності становило понад 100 відсотків [4].

Висновки. Результати досліджень показують, що ефективне застосування супутникових даних у оперативному прогнозі з допомогою методів машинного навчання має величезний потенціал. У міру того, як на орбіту виходить усе більше і

більше угруповань мініатюрних супутників, стане можливим часте взяття зразків значень внутрішніх структурних елементів циклону та навколишнього середовища. Заснована на ML структура статистичного моделювання буде ефективна для переведення цих спостережень на оперативне використання та значно покращить прогнози інтенсивності тропічних циклонів. Своєю чергою підвищення точності прогнозування гідродинамічних моделей атмосфери на основі ML дозволить забезпечити підвищення точності прогнозування моделей вітрового хвилювання у рамках відповідних ансамблевих моделей у сучасних оперативних прогностичних системах океану.

Список літератури:

1. Абузаров З.К., Думанская И.О., Нестеров Е.С. Оперативное океанографическое обслуживание. Москва; Обнинск : Изд. «ИГ-СОЦИН», 2009. 288 с.
2. Ерёміна Т.Р., Софьина Е.В., Дайлидиене И. Оперативная океанография : учебное пособие. Санкт-Петербург : изд. РГГМУ, 2014. 99 с.
3. Contributors to Wikimedia projects. Машинное обучение. *Википедия: свободная энциклопедия*. URL: https://ru.wikipedia.org/wiki/Машинное_обучение (дата звернення: 22.12.2021).
4. Hui Su, Longtao Wu, Jonathan H. Jiang, Raksha Pai, Alex Liu, Albert J. Zhai, Peyman Tavallali, Mark De Maria. Applying Satellite Observations of Tropical Cyclone Internal Structures to Rapid Intensification Forecast With Machine Learning. *AGU Journals*. URL: <https://agupubs.onlinelibrary.wiley.com/doi/full/10.1029/2020GL089102> (дата звернення: 25.12.2021).
5. Contributors to Wikimedia projects. Тропический циклон. *Википедия: свободная энциклопедия*. URL: https://ru.wikipedia.org/wiki/Тропический_циклон (дата звернення: 15.12.2021).
6. Пустовойтенко В.В., Запелалов А.С. Оперативная океанография: современное состояние, перспективы и проблемы спутниковой альтиметрии. *Морской гидрофизический институт НАН Украины*. Севастополь, 2012. 218 с.
7. Schiller A., Brassington G.B. Operational Oceanography in the 21st Century. Springer, 2011. 450 p.

8. European Operational Oceanography: Present and Future : Proceedings of the Fourth International Conference on EuroGOOS (Brest, France, 6–9 June 2005). Norrköping, Sweden : EuroGOOS Office SVHI, 2006. 856 p.

Urum N.S., Trofymenko I.V., Ivanenko V.M., Fedunov V.M., Bazhak O.V. RESEARCH OF DIRECTIONS OF IMPROVEMENT OF QUALITY OF WAVE MODELS USING METEOROLOGICAL MODELS ON THE BASIS OF MACHINE LEARNING METHODS

The general approach in the development of ocean forecasting systems at present is the integration of hydrodynamic models of the atmosphere, ocean circulation, wind waves and others. In deep sea wave models, the development of waves is mostly controlled by wind. The initial information about the winds in the calculations of the properties of the waves is presented as a sequence of diagnostic and prognostic fields of wind vectors. Most of the wave models currently used for the deep sea are based on the numerical solution of the radiation balance equation for the two-dimensional wave spectrum. An important role in improving the quality of wave models is to increase the accuracy of predicting the rate of wind rise above the water surface in the relevant ensemble models. One of the approaches to the effective application at the current level of operational forecasting systems of the ocean in general and wave models, in particular, is to attract large amounts of data using as forecasting methods – machine learning methods. The aim of the article is to study the directions of improving the quality of wave models using meteorological models based on machine learning methods. One of the central problems of modeling wind waves is the study of mechanisms that form the spectrum of improving the quality of wave models, and, in turn, plays an increase in the accuracy of predicting wind speed above the water surface in the relevant ensemble models. The results of research show that the effective use of satellite data in operational forecasting using machine learning methods has great potential. In turn, improving the accuracy of forecasting hydrodynamic models of the atmosphere based on machine learning will improve the accuracy of forecasting models of wind waves in the relevant ensemble models in modern operational forecasting systems of the ocean.

Key words: ocean, wave model, wind wave, wave forecasting, meteorological model, tropical cyclone, machine learning.