

А.Ю. Дорошенко, В.М. Шпиг, Р.В. Кушніренко

УТОЧНЕННЯ ЧИСЕЛЬНИХ МЕТЕОРОЛОГІЧНИХ ПРОГНОЗІВ ЗА ДОПОМОГОЮ ГЛИБОКОГО НАВЧАННЯ

Зроблено короткий огляд розвитку чисельного прогнозування погоди. Описано проблеми, які мають місце в моделюванні атмосферних процесів, їхню природу та можливі шляхи подолання. Запропоновано архітектуру нейронної мережі, яка дозволяє коригувати помилки прогнозу приземної температури повітря чисельної регіональної моделі COSMO. Показано, що запропонована архітектура дає можливість покращити прогноз у понад 50% випадків, що підкріплюється також зменшенням кореня середнього квадратичного відхилення.

Ключові слова: “глибоке навчання”, чисельний прогноз, COSMO, температура повітря.

Вступ

Атмосферні процеси та явища можуть значно вплинути на різні сфери людської життєдіяльності, починаючи від сільського господарства і закінчуючи цивільною та військовою авіацією. Щобільше, такі природні явища як повені, сильні зливи, урагани тощо можуть завдавати великих збитків господарству, ба навіть гірше - становити загрозу життю багатьох людей. Тому дуже важливою науковою задачею є все більше вдосконалення якості метеорологічного прогнозування, адже це може дозволити попередити та зменшити негативні наслідки від надзвичайних ситуацій природного і техногенного характеру.

До будь-якого прогнозування, зокрема, до метеорологічного, логічно висунути дві основні вимоги: точність (правдивість) прогнозу і своєчасність його отримання. Як зазначено у [1], відбулася “тиха революція” чисельних гідродинамічних методів прогнозу погоди, що мала на меті якнайповніше задовольнити обидві вказані вимоги. Зокрема, розробка більш довершених і реалістичних математичних моделей, а також істотне збільшення обсягу початкових метеорологічних даних уможливило виконання першої вимоги. Друга ж вимога забезпечується передусім появою все більш потужних обчислювальних систем.

Проте попри величезний прогрес останніх років, ми не можемо назвати якість отриманих прогнозів абсолютною. Причи-

ною цього є складність будови атмосфери й різноманіття процесів та явищ, наявних у ній. Зокрема, одні процеси відбуваються на великій території протягом тривалого часу, інші ж можуть мати місце на незначній за площею території та впродовж короткого часового проміжку.

Найбільш розповсюдженою на сьогодні є шкала масштабів атмосферних процесів та об'єктів, згідно з якою вони поділяються на три типи [2]: мікромасштабні (до 200 м), мезомасштабні (від 200 м до 2000 км) та макромасштабні (понад 2000 км). Зрозуміло, що процеси всіх перерахованих вище масштабів впливають на формування явищ, що виникають в атмосфері в кожній конкретній області. Тимчасом роль кожного процесу в різних умовах буде неоднаковою. Так формування загальної циркуляції на територіях, співставних за розмірами з континентами, виникає переважно під впливом макромасштабних процесів. Водночас мезомасштабні процеси роблять менш важливий внесок.

Таким чином цілком зрозумілими є труднощі, що виникають під час спроб моделювання метеорологічних процесів різних масштабів з єдиних позицій, оскільки зв'язки між циркуляцією атмосфери та закономірностями обміну імпульсом, теплом і вологою у приземному / приповерховому шарі атмосфери безпосередньо проявляються під час розв'язання відповідних задач.

Складність математичних моделей, що описують циркуляційні процеси в атмосфері обумовлює реалізацію прогностичних систем за допомогою чисельних методів. Рівняння, з яких складаються такі моделі, є переважно нелінійними тривимірними рівняннями другого порядку з малим параметром у разі похідних другого порядку. Наявність малого параметра при старших похідних може зумовлювати зміну типу рівняння (до прикладу, з еліптичного на гіперболічний або параболічний) залежно від режиму руху в атмосфері, що моделюється. Наразі навіть ресурси дуже потужних комп'ютерних систем не дають змоги здійснювати просторову дискретизацію моделі атмосфери з високим розділенням. Водночас більш груба просторова дискретизація призводить до того, що багато мезомасштабних метеорологічних процесів не описуються цією моделлю, оскільки у такому разі опиняються у класі процесів підсіткового масштабу.

Оскільки прогноз погоди потрібно отримувати завчасно, значною проблемою у створенні прогнозів, що базуються на реалізації математичних моделей, є обмеження на час розв'язання. Як зазначено вище, навіть сучасні потужні обчислювальні системи не дозволяють використовувати дрібну просторову сітку в області розв'язання задачі, що дало б можливість підвищити точність прогнозу. Особливо актуальною дана проблема постає для України, тому що питання зменшення витрат машинного часу у розв'язанні задач динамічної метеорології стоїть особливо гостро у зв'язку з відсутністю в національній гідрометслужбі потужної обчислювальної техніки, яку використовують у світових і національних метеорологічних центрах розвинутих держав.

На щастя, існують альтернативні способи покращити якість метеорологічного прогнозування. Один з них використовує той факт, що задача моделювання метеорологічних процесів передбачає для свого розв'язання розщеплення рівнянь за координатами [3], що своєю чергою забезпечує так званий природний паралелізм виконання операцій [4], тобто такий паралелізм ви-

конання операцій, що зумовлений специфікацією задачі, а не впливає з алгоритму її розв'язання.

Отож, одним із перспективних напрямів покращення якості метеорологічного прогнозування є розробка і дослідження систем паралельних і розподілених обчислень. Зокрема, важливою метою є розвиток архітектурно- і мовно-незалежних засобів програмування мультипроцесорних обчислювальних систем, якого можна досягти за допомогою програмних абстракцій у вигляді алгебро-алгоритмічних мов і моделей. Зазначимо, що алгебро-алгоритмічний підхід до побудови структурованих абстракцій у моделях паралельних програм має на меті забезпечення високої продуктивності паралельних обчислень.

Іншим альтернативним способом покращення якості метеорологічного прогнозування є використання так званого "глибокого навчання" (deep learning, DL). Все більш успішне використання цієї техніки стало можливим завдяки збільшенню обчислювальної потужності систем, доступності великих наборів даних і швидкому розвитку нових архітектур нейронних мереж. Деякі з цих нових архітектур можуть виконувати певні задачі набагато ефективніше, аніж класичні повнозв'язні нейронні мережі прямого поширення.

Однією з таких особливо успішних концепцій, що має широке застосування, є концепція згорткової нейронної мережі (convolutional neural network, CNN) [5]. Ця архітектура нейронної мережі являє собою стек фільтрів малого розміру з невеликою кількістю параметрів, які власне "навчаються". Вона застосовується до зображень або інших даних на прямокутній сітці для отримання узагальнених характерних особливостей досліджуваного об'єкта. У царині метеорологічного і кліматичного прогнозування згорткові мережі можуть бути використані для виявлення просторових характеристик, як-от, під час аналізу супутникових зображень [6].

Іншою корисною і широко вживаною концепцією є рекурентні нейронні мережі (recurrent neural network, RNN). Цей вид нейромережевої архітектури був роз-

роблений для вивчення залежних від часу особливостей даних, до прикладу, тексту [7] та мовлення [8]. Рекурентність — це лише загальна ідея, яка полягає у тому, що топологічно така архітектура нейронної мережі може бути представлена орієнтованим у часі графом. Завдяки цьому утворюється “пам’ять” мережі (вектор внутрішнього стану), що і дозволяє виявляти динамічні (у часовому вимірі) характеристики досліджуваних даних. Двома найпопулярнішими видами рекурентних нейронних мереж є мережа довгої короткочасної пам’яті (long short-term memory, LSTM) [9] та вентильний рекурентний вузол (gated recurrent unit, GRU) [10]. Зокрема, GRU-шари будуть використані для розв’язання поставленої в даній статті задачі.

Зазначимо, що GRU- та LSTM-шари можуть бути вбудовані в складніші архітектури нейронних мереж. Наприклад, поєднання звичайної CNN з LSTM дає так звану мережу ConvLSTM [11].

Кількість задач, для розв’язання яких можуть використовуватися нейронні мережі, надзвичайно велика, навіть якщо брати до уваги тільки сферу метеорологічного прогнозування. Ось декілька прикладів. Класифікація метеорологічних супутникових знімків за допомогою CNN була здійснена в [12]. У [13] дослідники використовували LSTM для прогнозування зображень хмар. Беручи за основу принципи використання “глибокого навчання” для прогнозування відео, дослідники зробили короткострокове прогнозування зображень неба та радіолокаційних зображень [14]. Також здійснювалися деякі спроби створити прогноз погоди, використовуючи багатопартийний перцептрон, зокрема, у [15]. Дослідження [16] можна розглядати як перший крок до заміни динамічного ядра чисельної моделі погоди, оскільки у ньому “навчання без вчителя” застосовувалося до рівнянь Нав’є-Стокса для нестискуваної рідини.

Проте, як було показано у [17], ще рано говорити про повну заміну чисельних гідродинамічних методів прогнозу погоди на методи, що базуються лише на “глибокому навчанні” і спостережуваних даних.

Хоча “глибоке навчання” останнім часом показує себе успішно у різних сферах і попри те, що робляться спроби його застосування до метеорологічних задач, такі дослідження все ще знаходяться в зародковому стані. Це пов’язано передусім з тим, що характерні особливості метеорологічних даних вимагають розробки нових підходів поза межами класичних концепцій комп’ютерного зору, розпізнавання мовлення та інших типових задач, що ставляться перед “глибоким навчанням”. Попри те, що робота над цими новими підходами посувається та вже багато проблем успішно розв’язано, не існує єдиного методу, що вирішував би усі проблеми одночасно. А саме він і потрібен для успішної повної заміни чисельних методів метеорологічного прогнозування.

Однак, відповідно до [18], є тенденція до розробки гібридних підходів моделювання, які поєднали б моделі фізичних процесів з універсальністю інструментів “глибокого навчання” для досягнення кращих результатів. Зокрема, існують дослідження можливості успішного використання “глибокого навчання” на різних стадіях чисельного прогнозу: обробка спостережень [19], асиміляція даних [20], прогностична модель [21] та постпроцесинг отриманих результатів [22].

Власне, дана стаття пропонує підхід до застосування “глибокого навчання” до постпроцесингу результатів прогнозу приземної температури, отриманого за допомогою чисельних гідродинамічних методів метеорологічного прогнозування. Подальша розробка цього підходу може уможливити досягнення належного ступеня точності метеорологічних прогнозів, використовуючи відносно невелику обчислювальну потужність.

Опис даних

“Глибоке навчання” як техніка виокремлення характерних особливостей даних суттєво залежить від якості, репрезентативності та цілісності використовуваних даних. Тому правильний відбір і підготовка даних є важливими факторами для отримання хороших і узагальнюючих результатів.

Зокрема, відбір даних має бути спрямований на охоплення якнайповнішої варіативності значень змінних, на яких базуватиметься власне навчання нейромережевої моделі. Хороші дані мають дозволяти моделі охоплювати зв'язки між змінними, на основі яких робиться прогноз. Водночас важливим є уникнення надлишковості у даних.

Нижче поданий опис даних, використаних для дослідження, описаного у даній статті. Ці дані склалися з чотириелементних кортежів і містили наступну інформацію:

- дата,
- час за Гринвічем,
- прогнозоване значення температури (Fcst), завчасністю в одну добу від моменту ініціалізації чисельної регіональної моделі,
- спостережуване значення температури (Obs).

Чисельною регіональною моделлю прогнозу погоди, згаданою вище, є модель однойменного європейського консорціуму COSMO (Consortium for Small-scale Modelling). Ця модель використовується в Українському гідрометеорологічному інституті ДСНС України та НАН України для наукових та прикладних задач, починаючи із липня 2011 р. [23].

COSMO є негідростатичною моделлю, здатною ефективно відтворювати широкий спектр атмосферних процесів у масштабі мезо- β та мезо- γ . В основу динамічного ядра моделі покладено рівняння термо- та гідродинаміки, що описують потік у вологій атмосфері. Різноманітні фізичні процеси враховуються схемами параметризації [24].

Рис. 1 зображує розрахункову область чисельної регіональної моделі: кількість вузлів із заходу на схід – 209; кількість вузлів із півдня на північ – 101; кількість рівнів по вертикалі – 50; крок \sim 14 км.

Наявні дані охоплюють проміжок часу від 01.07.2012 до 31.03.2014, або 639 днів. Спостереження проводилися кожні три години, а саме о 00:00, 03:00, 06:00,

09:00, 12:00, 15:00, 18:00 і 21:00 за Гринвічем. Для цих же моментів часу обчислювався і прогноз регіональної моделі.

Таким чином, для кожної дати маємо по вісім кортежів. Відповідно 639 днів дають 5112 кортежів.



Рис. 1. Розрахункова область моделі прогнозу погоди COSMO

Що стосується просторової приналежності, то дані охоплюють спостережувані значення і прогнози для станцій “Біла Церква”, “Бориспіль”, “Київ”, “Миронівка”, “Тетерів”, “Фастів”, “Чорнобиль” та “Яготин”.

Рекурентні нейронні мережі

Як зазначалося вище, поточне дослідження використовує концепцію рекурентних нейронних мереж. Це зумовлено тим, що метеорологічні дані мають природу часового ряду, тобто містять залежні від часу особливості. А концепція рекурентних нейронних мереж була розроблена для роботи саме з даними такого роду.

З-поміж наявних видів рекурентних архітектур була обрана архітектура вентильного рекурентного вузла (GRU), оскільки вона містить небагато параметрів, а тому швидко навчається. Водночас вузол GRU дозволяє уникнути основних проблем, що виникають під час аналізу довгострокових залежностей. Цими проблемами є ефект зникнення градієнтів (vanishing gradient effect) і безпосередньо пов'язаний з ним ефект вибуху градієнтів (exploding gradients effect).

Вузол GRU працює наступним чином. У кожний момент часу йому на вхід подаються вхідний вектор x_t і вихідний вектор з попереднього моменту часу h_{t-1} . Вихідний вектор h_t обчислюється як лінійна інтерполяція між h_{t-1} і поточним кандидатом \tilde{h}_t :

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t,$$

де z_t – вектор вузла уточнення. Він визначає, які долі першого і другого векторів впливатимуть на поточне значення. \odot позначає добуток Адамара.

Вектор вузла уточнення обчислюється наступним чином:

$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z).$$

Поточний кандидат \tilde{h}_t обчислюється подібно до стандартної рекурентної нейронної мережі:

$$\tilde{h}_t = \sigma_h(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h),$$

де r_t – вектор вузла скидання, що обчислюється подібно до вектора вузла уточнення:

$$r_t = \sigma_g(W_r x_t + U_r h_{t-1} + b_r).$$

$W_z, U_z, W_h, U_h, W_r, U_r$ позначають матриці параметрів, а b_z, b_h, b_r позначають вектори параметрів. Вектори вузлів уточнення і скидання активуються сигмоїдною функцією, а вектор поточного кандидата – гіперболічним тангенсом.

Опис експерименту

Основна ідея даного дослідження полягає у перевірці можливості застосування рекурентних нейронних мереж до уточнення прогнозу приземної температури, отриманого за допомогою чисельної моделі прогнозу погоди COSMO.

Для кожної метеорологічної станції тренувалася власна нейромережева модель, яка мала б якнайкраще виокремити фізичні особливості конкретного пункту спостереження. Тож, ми маємо 8 натренованих моделей.

Нейромережева топологія та інші конфігураційні параметри були однаковими для всіх моделей. Першим шаром нейронної мережі (після вхідного) було

взято GRU-шар, що складається з 64 вузлів, оскільки менша і більша кількість давали гірші результати. Після нього було додано один прихований повнозв'язний шар з 64 вузлами. Останній шар запропонованої архітектури був також повнозв'язним і мав 8 вузлів, оскільки вихідний вектор повинен мати розмірність добового вектора прогнозу (8 значень).

Рис. 2 зображує описану топологію нейромережевих моделей.

8 вузлів 64 вузли 64 вузли 8 вузлів




Рис. 2. Запропонована архітектура нейронної мережі

Що ж до даних, то для кожної метеорологічної станції уся їх сукупність була розбита на три класи: тренувальні (період з 01.07.2012 до 30.06.2013; 365 днів), валідаційні (період з 01.07.2013 до 31.10.2013; 123 дні) і тестувальні (з 01.11.2013 до 01.04.2014; 151 день).

Усі експерименти проводилися з використанням відкритого нейромережевого інтерфейсу Keras [25] і відкритої програмної бібліотеки для “глибокого навчання” TensorFlow [26]. Програмний код був написаний мовою Python [27].

Отримані результати

Ефективність запропонованого підходу оцінювалася за двома критеріями. Перший з них — це корінь середнього квадратичного відхилення (RMSE), стандартний спосіб оцінювання похибок у метеорологічній науці. Інша метрика — відсоток випадків, в яких прогноз покращено (або, принаймні, не погіршено) порівняно з чисельним. Як бачимо з таблиці, значення нейронної мережі краще за значення чисельної моделі.

Таблиця. Порівняння нейронної мережі (NN) і чисельної моделі (COSMO)

Станція	RMSE (COSMO), °C	RMSE (NN), °C	Покращення, %
Біла Церква	1.9864	1.8865	54.81
Бориспіль	2.0007	1.9958	53.21
Київ	2.1888	1.9824	53.97
Миронівка	2.0945	2.0099	57.48
Тетерів	2.0457	2.0215	52.29
Фастів	1.9728	1.8565	54.68
Чорнобиль	1.9696	2.0094	50.59
Яготин	2.2437	2.1157	52.21

Висновки

На прикладі прогнозів моделі COSMO приземної температури повітря для восьми метеорологічних станцій Київської області та відповідних їм даних фактичних спостережень запропоновано архітектуру нейронної мережі, яка дозволяє покращувати прогноз чисельної регіональної моделі.

Показано, що запропонована архітектура дає можливість досягти покращення прогнозу приземної температури повітря більше, ніж у 50% випадків. Цей результат підкріплюється зменшенням значень кореня середнього квадратичного відхилення.

Отримані результати дають підстави для застосування нейромережевого підходу до коригування прогнозів інших неперервних метеорологічних величин.

Література

1. Bauer, P., Thorpe, A. and Brunet, G., 2015. The quiet revolution of numerical weather prediction. *Nature*, 525(7567), pp.47-55.
2. Orlandi, I., 1975. A rational subdivision of scales for atmospheric processes. *Bulletin of the American Meteorological Society*, pp.527-530.
3. Prusov, V.A., Doroshenko, A.E., Chernysh, R.I. and Guk, L.N., 2007. Efficient difference scheme for numerical solution of a convective diffusion problem. *Cybernetics and Systems Analysis*, 43, pp.368-376.
4. Прусов, В.А. and Дорошенко, А.Ю., 2006. Моделювання природних і техногенних процесів в атмосфері. *Київ: Наукова Думка*.

5. LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp.2278-2324.
6. Zhu, X.X., Tuia, D., Mou, L., Xia, G.S., Zhang, L., Xu, F. and Fraundorfer, F., 2017. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE geoscience and remote sensing magazine*, 5(4), pp.8-36.
7. Graves, A., Liwicki, M., Fernandez, S., Bertolami, R., Bunke, H. and Schmidhuber, J., 2009. A novel connectionist system for improved unconstrained handwriting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(5).
8. Sak, H., Senior, A. and Beaufays, F., 2014. Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition. *arXiv preprint arXiv:1402.1128*.
9. Hochreiter, S. and Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), pp.1735-1780.
10. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y., 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
11. Shi, X., Chen, Z., Wang, H., Yeung, D.Y., Wong, W.K. and Woo, W.C., 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
12. Zhou, Y., Wang, H., Xu, F. and Jin, Y.Q., 2016. Polarimetric SAR image classification using deep convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 13(12), pp.1935-1939.
13. Xu, Z., Du, J., Wang, J., Jiang, C. and Ren, Y., 2019, May. Satellite image prediction relying on GAN and LSTM neural networks. In *ICC 2019-2019 IEEE international conference on communications (ICC)* (pp. 1-6). IEEE.
14. Schmidt, V., Alghali, M., Sankaran, K., Yuan, T. and Bengio, Y., 2020. Modeling cloud reflectance fields using conditional generative adversarial networks. *arXiv preprint arXiv:2002.07579*.
15. Dueben, P.D. and Bauer, P., 2018. Challenges and design choices for global weather and climate models based on machine learning. *Geoscientific Model Development*, 11(10), pp.3999-4009.
16. Wandel, N., Weinmann, M. and Klein, R., 2020. Unsupervised deep learning of in-

- compressible fluid dynamics. *arXiv preprint arXiv:2006.08762*.
17. Schultz, M.G., Betancourt, C., Gong, B., Kleinert, F., Langguth, M., Leufen, L.H., Mozaffari, A. and Stadtler, S., 2021. Can deep learning beat numerical weather prediction?. *Philosophical Transactions of the Royal Society A*, 379(2194), p.20200097.
 18. Bauer, P., Dueben, P.D., Hoefler, T., Quintino, T., Schulthess, T.C. and Wedi, N.P., 2021. The digital revolution of Earth-system science. *Nature Computational Science*, 1(2), pp.104-113.
 19. Prudden, R., Adams, S., Kangin, D., Robinson, N., Ravuri, S., Mohamed, S. and Arribas, A., 2020. A review of radar-based nowcasting of precipitation and applicable machine learning techniques. *arXiv preprint arXiv:2005.04988*.
 20. Bonavita, M. and Laloyaux, P., 2020. Machine learning for model error inference and correction. *Journal of Advances in Modeling Earth Systems*, 12(12), p.e2020MS002232.
 21. Krasnopolsky, V.M., Fox-Rabinovitz, M.S. and Chalikov, D.V., 2005. New approach to calculation of atmospheric model physics: Accurate and fast neural network emulation of longwave radiation in a climate model. *Monthly Weather Review*, 133(5), pp.1370-1383.
 22. Rasp, S. and Lerch, S., 2018. Neural networks for postprocessing ensemble weather forecasts. *Monthly Weather Review*, 146(11), pp.3885-3900.
 23. Shpyg, V., Budak, I., Pishniak, D. and Poperechnyi, P., 2013, November. The application of regional NWP models to operational weather forecasting in Ukraine. In *CAS Technical Conference (TECO) on «Responding to the Environmental Stressors of the 21st Century» Available from: <http://www.wmo.int/pages/prog/arep/cas/documents/Ukraine-NWPMODELS.pdf> [Accessed 27/02/2020]*.
 24. Doms, G. and Baldauf, M., 2011. A description of the nonhydrostatic regional COSMO-Model Part I: dynamics and numerics. *Deutscher Wetterdienst, Offenbach*.
 25. <https://keras.io/>
 26. <https://www.tensorflow.org/>
 27. <https://www.python.org/>
 28. Prusov, V.A., Doroshenko, A.E., Chernysh, R.I. and Guk, L.N., 2007. Efficient difference scheme for numerical solution of a convective diffusion problem. *Cybernetics and Systems Analysis*, 43, pp.368-376.
 29. Prusov, V.A. and Doroshenko, A.Y., 2006. Modeling of Natural and Technogenic Processes in the Atmosphere [in Ukrainian].
 30. LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp.2278-2324.
 31. Zhu, X.X., Tuia, D., Mou, L., Xia, G.S., Zhang, L., Xu, F. and Fraundorfer, F., 2017. Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE geoscience and remote sensing magazine*, 5(4), pp.8-36.
 32. Graves, A., Liwicki, M., Fernandez, S., Bertolami, R., Bunke, H. and Schmidhuber, J., 2009. A novel connectionist system for improved unconstrained handwriting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(5).
 33. Sak, H., Senior, A. and Beaufays, F., 2014. Long short-term memory based recurrent neural network architectures for large vocabulary speech recognition. *arXiv preprint arXiv:1402.1128*.
 34. Hochreiter, S. and Schmidhuber, J., 1997. Long short-term memory. *Neural computation*, 9(8), pp.1735-1780.
 35. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. and Bengio, Y., 2014. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *arXiv preprint arXiv:1406.1078*.
 36. Shi, X., Chen, Z., Wang, H., Yeung, D.Y., Wong, W.K. and Woo, W.C., 2015. Convolutional LSTM network: A machine learning approach for precipitation nowcasting. *Advances in neural information processing systems*, 28.
 37. Zhou, Y., Wang, H., Xu, F. and Jin, Y.Q., 2016. Polarimetric SAR image classification using deep convolutional neural networks. *IEEE Geoscience and Remote Sensing Letters*, 13(12), pp.1935-1939.
 38. Xu, Z., Du, J., Wang, J., Jiang, C. and Ren, Y., 2019, May. Satellite image prediction relying on GAN and LSTM neural networks. In *ICC 2019-2019 IEEE international conference on communications (ICC)* (pp. 1-6). IEEE.
 39. Schmidt, V., Alghali, M., Sankaran, K., Yuan, T. and Bengio, Y., 2020. Modeling

References

1. Bauer, P., Thorpe, A. and Brunet, G., 2015. The quiet revolution of numerical weather prediction. *Nature*, 525(7567), pp.47-55.
2. Orlandi, I., 1975. A rational subdivision of scales for atmospheric processes. *Bulletin of the American Meteorological Society*, pp.527-530.

- cloud reflectance fields using conditional generative adversarial networks. *arXiv preprint arXiv:2002.07579*.
15. Dueben, P.D. and Bauer, P., 2018. Challenges and design choices for global weather and climate models based on machine learning. *Geoscientific Model Development*, 11(10), pp.3999-4009.
 16. Wandel, N., Weinmann, M. and Klein, R., 2020. Unsupervised deep learning of incompressible fluid dynamics. *arXiv preprint arXiv:2006.08762*.
 17. Schultz, M.G., Betancourt, C., Gong, B., Kleinert, F., Langguth, M., Leufen, L.H., Mozaffari, A. and Stadtler, S., 2021. Can deep learning beat numerical weather prediction?. *Philosophical Transactions of the Royal Society A*, 379(2194), p.20200097.
 18. Bauer, P., Dueben, P.D., Hoefler, T., Quintino, T., Schulthess, T.C. and Wedi, N.P., 2021. The digital revolution of Earth-system science. *Nature Computational Science*, 1(2), pp.104-113.
 19. Prudden, R., Adams, S., Kangin, D., Robinson, N., Ravuri, S., Mohamed, S. and Arribas, A., 2020. A review of radar-based nowcasting of precipitation and applicable machine learning techniques. *arXiv preprint arXiv:2005.04988*.
 20. Bonavita, M. and Laloyaux, P., 2020. Machine learning for model error inference and correction. *Journal of Advances in Modeling Earth Systems*, 12(12), p.e2020MS002232.
 21. Krasnopolsky, V.M., Fox-Rabinovitz, M.S. and Chalikov, D.V., 2005. New approach to calculation of atmospheric model physics: Accurate and fast neural network emulation of longwave radiation in a climate model. *Monthly Weather Review*, 133(5), pp.1370-1383.
 22. Rasp, S. and Lerch, S., 2018. Neural networks for postprocessing ensemble weather forecasts. *Monthly Weather Review*, 146(11), pp.3885-3900.
 23. Shpyg, V., Budak, I., Pishniak, D. and Poperechnyi, P., 2013, November. The application of regional NWP models to operational weather forecasting in Ukraine. In *CAS Technical Conference (TECO) on «Responding to the Environmental Stressors of the 21st Century» Available from: <http://www.wmo.int/pages/prog/arep/cas/documents/Ukraine-NWPMODELS.pdf> [Accessed 27/02/2020]*.
 24. Doms, G. and Baldauf, M., 2011. A description of the nonhydrostatic regional COSMO-Model Part I: dynamics and numerics. *Deutscher Wetterdienst, Offenbach*.

25. <https://keras.io/>
26. <https://www.tensorflow.org/>
27. <https://www.python.org/>

Одержано: 01.09.2023

Про авторів:

Дорошенко Анатолій Юхимович, доктор фізико-математичних наук, професор, завідувач відділу ІПС НАНУ, професор кафедри інформаційних систем та технологій КІП імен Ігоря Сікорського. Кількість наукових публікацій в українських виданнях – понад 200. Кількість наукових публікацій в зарубіжних виданнях – понад 90. <http://orcid.org/0000-0002-8435-1451>,

Шпиг Віталій Михайлович, кандидат географічних наук, завідувач відділу фізики атмосфери Українського гідрометеорологічного інституту ДСНС України та НАН України, експерт Комісії з атмосферних наук Всесвітньої метеорологічної організації. Кількість наукових публікацій в українських виданнях – понад 50. Кількість наукових публікацій в зарубіжних виданнях – понад 50. <https://orcid.org/0000-0003-1055-7120>,

Кушніренко Роман Владиславович, аспірант. Кількість наукових публікацій в українських виданнях – 2. <https://orcid.org/0000-0002-1990-8727>.

Місце роботи авторів:

Інститут програмних систем НАН України, 03187, м. Київ-187, проспект Академіка Глушкова, 40. Тел.: 38 044 526-60-33. Е-mail: doroshenkoanatoliy2@gmail.com, roman.kushnirenko@gmail.com.

Український гідрометеорологічний інститут ДСНС України та НАН України, 03028, м. Київ, проспект Науки, 37. Тел.: (38)(044) 525-86-30. Е-mail: vitold82@i.ua.