

А.Ю. Дорошенко, Р.В. Кушніренко

АВТОМАТИЗАЦІЯ ГЛИБОКОГО НАВЧАННЯ НА ПРИКЛАДІ УТОЧНЕННЯ ЧИСЕЛЬНИХ МЕТЕОРОЛОГІЧНИХ ПРОГНОЗІВ

Зроблено короткий огляд застосування “глибокого навчання” до науково-технічних задач. Перевірено можливість застосування нейроеволюційного підходу до проектування моделей “глибокого навчання”, призначених для постпроцесингу результатів метеорологічного прогнозування (на прикладі приземної температури), отриманого за допомогою чисельних гідродинамічних методів. Показано, що в половині випадків і значення стандартного середнього-квадратичного відхилення (RMSE), і відсотка покращених прогнозів для нейроеволюційного підходу є кращими (а в окремих випадках набагато кращими) за відповідні значення для підібраної вручну архітектури.

Ключові слова: “глибоке навчання”, автоматизація проектування нейромереж, нейроеволюція, метеорологічне прогнозування.

Вступ

Велика кількість даних, що стала доступною протягом останнього десятиліття, спричинила революцію в дослідницьких і оперативних схемах геонаукової обробки, уможлививши використання “глибокого навчання” для задач, що стосуються атмосфери, поверхні суші та океану. Окрім збільшення доступності даних спостережень, цьому процесу сприяло, поміж іншого, підвищення швидкості їхньої передачі, що вже перевищує сотні терабайт на день [1]. Ці дані надходять від безлічі датчиків, зокрема, вони включають дані дистанційного зондування на висоті від кількох метрів до сотень кілометрів над Землею, а також спостереження на місці (на поверхні та під нею) за допомогою автономних датчиків.

Використання “глибокого навчання” для розв’язання проблем, що постають перед геонаукою, знаходиться ще в зародковому стані (на відміну від помітних успіхів у моделюванні впорядкованих послідовностей і даних із просторовим контекстом у сферах комп’ютерного зору, систем розпізнавання мови та керування [2], а також у таких наукових галузях як фізика [3], хімія [4] та біологія [5]). Хоча, як показують дослідження, його застосування в геонауці є перспективним, особливо в задачах класифікації, регресії, виявлення аномалій та прогнозування залежного від простору або часу стану. До прикладу, в дослідженнях [6,7] демонструється застосування “глибокого навчання” до про-

блеми прогнозування екстремальних погодних умов, задачі, проблемної для традиційного машинного навчання. Зазначимо, що особливо успішним є застосування архітектур “глибокого навчання” до виокремлення просторових і часових характеристик для визначення та класифікації екстремальних ситуацій (зокрема, штормів) у вихідних даних числової моделі прогнозування погоди. Важливим є те, що виявлення цих подій та створення прогнозів відбувається без використання суб’єктивних суджень людини або методів, які покладаються на заздалегідь визначені порогові значення для швидкості вітру та інших метеорологічних величин.

Підходи “глибокого навчання” класично поділяються на просторові (наприклад, згорткові нейронні мережі [8] для класифікації об’єктів) і послідовні (наприклад, рекурентні нейронні мережі для розпізнавання мовлення [9]). Однак останнім часом спостерігається все більша зацікавленість у поєднанні цих двох підходів. Прикладом цього поєднання є прогнозування відео та руху [10], проблема, яка має різьчучу подібність до багатьох динамічних геонаукових проблем. Уже існують дослідження, що починають застосовувати комбіновані згортково-рекурентні підходи до таких геонаукових проблем як прогнозування опадів [11]. Моделювання динаміки атмосфери та океану, моделювання поширення вогню чи руху ґрунту також є прикладами проблем, де

важлива просторово-часова динаміка, але наразі вони не отримали переваг від застосування комбінованих згортково-рекурентних підходів “глибокого навчання”.

Коротко кажучи, подібність між типами даних, притаманних для класичних застосувань “глибокого навчання”, і даних, з якими працює геонаука, є переконливим аргументом на користь проникнення “глибокого навчання” в геонауку. Зображення є аналогом двовимірних полів даних, що містять певні змінні за аналогією з триплетами кольорів (значення RGB) на фотографіях, тоді як відео можна пов’язати з послідовністю зображень, тобто з двовимірними полями, які змінюються у часі. Так само, природна мова та мовлення мають такі ж характерні особливості динамічних часових рядів, що їх мають дані, притаманні геонауковій сфері. Крім того, класифікація, регресія, виявлення аномалій і динамічне моделювання є типовими проблемами як для класичних застосувань “глибокого навчання”, так і для геонаук.

Як бачимо, з розвитком “глибоких” нейронних мереж ми отримуємо все досконаліші архітектури, які можемо застосовувати у різних сферах, зокрема, в геонауці. Проте безплатний сир буває тільки в мишоловці, адже підвищення якості моделей є результатом усе більшої їх складності. Тому постає нова задача, а саме задача налаштування систем отримання рішень. Це налаштування полягає у підборі конфігураційних параметрів (гіперпараметрів). Якщо цих параметрів мало, то їх можна спробувати оптимізувати шляхом експериментів. Натомість сучасні “глибокі” нейронні мережі мають складну топологію та сотні гіперпараметрів. Окрім цього, як зазначалося вище, важить вибір архітектури нейромережових моделей, оскільки успішність отриманого рішення часто залежить від цього вибору. Власне, останнім часом велика частка робіт у галузі “глибокого” навчання була присвячена мануальній розробці різних архітектур для розв’язання нових проблем [12,13].

Зазначимо, що проблема складності не є притаманною лише для нейронних мереж. Загалом розробка програмного забез-

печення та багатьох інших інженерних систем стала надто складною для того, щоб люди могли її повністю оптимізувати. В результаті з’явився новий підхід до проектування програмного забезпечення. Цей підхід залишає людям високорівневе проектування, натомість з’ясування деталей лежить на оптимізаційних системах. Наприклад, люди проектують програмну систему, а параметри та код низького рівня оптимізуються автоматично [14].

Подібний підхід можна застосувати до проектування архітектур “глибоких” нейронних мереж. Для цього треба уміти давати раду трьом аспектам: проектуванню компонентів архітектури, об’єднанню компонентів (створення топології мережі) та підбору гіперпараметрів (для кожного з компонентів та для системи в цілому). Звісно, що для кожного нового завдання матимемо окрему оптимізацію вищеперахованого.

Це дослідження використовує підхід до автоматичного проектування “глибоких” нейронних мереж, описаний у [15]. Своєю чергою, цей підхід використовує техніку нейроеволюції доповнених топологій [16]. Ця техніка поширюється на коеволюційну оптимізацію компонентів, топологій і гіперпараметрів.

Власне, дана стаття присвячена застосуванню нейроеволюційного підходу до проектування моделей “глибокого навчання”, призначених для постпроцесингу результатів прогнозу приземної температури, отриманого за допомогою чисельних гідродинамічних методів метеорологічного прогнозування. В статті також виконане порівняння якості прогнозу з результатами, отриманими раніше за допомогою ручного підбору нейромережової архітектури [17,18]. Як буде видно, застосування нейроеволюційного підходу до задачі покращення чисельного метеорологічного прогнозування показує, що можна без особливих зусиль отримати результати кращі за отримані під час мануального проектування архітектури нейромережової моделі. Звісно, цей підхід є надзвичайно вимогливим до обчислювальної потужності, проте, враховуючи невеликий об’єм даних, він дає гарні результати.

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 узагальнюючих результатів.

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

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

- дата,
- час за Гринвічем,
- прогнозоване значення температури (F_{cst}), за одну добу до моменту ініціалізації чисельної регіональної моделі,
- спостережуване значення температури (Obs).

Чисельною моделлю прогнозу погоди, результат роботи якої ми хочемо покращити, є модель однойменного європейського консорціуму COSMO (Consortium for Small-scale Modelling). Ця модель використовується в Українському гідрометорологічному інституті ДСНС України та НАН України для наукових та прикладних задач, починаючи із липня 2011 р. [19]. Нагадаємо, що COSMO є негідростатичною моделлю, яка здатна ефективно відтворювати широкий спектр атмосферних процесів в 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 [20].

Рис. 1 зображує розрахункову область чисельної регіональної моделі: кіль-

кість вузлів із заходу на схід – 209; кількість вузлів із півдня на північ – 101; кількість рівнів по вертикалі – 50; крок ~ 14 км.



Рис. 1. Розрахункова область моделі прогнозу погоди COSMO

Наявні дані охоплюють проміжок часу від 01.07.2012 до 31.03.2014, або 639 днів. Спостереження здійснювалися 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.

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

Нейроеволюційний підхід

Нагадаємо, що термін “нейроеволюція” позначає процес використання генетичних алгоритмів для підбору архітектур нейромережевих моделей.

У цьому дослідженні ми будемо використовувати одну з модифікацій нейроеволюції доповнених топологій. Даний підхід, відповідно до [16], ставить собі за мету боротися із трьома основними викликами, що постають перед рішеннями, які базуються на еволюції топології. Ці виклики та запропоновані рішення наведені нижче:

- Чи існує генетичне представлення, яке дозволяє розрізненим топологіям схрещуватись значущим чином? Рішення: використання історичних міток для виокремлення генів однакового походження.

- Як захистити від передчасного зникнення з популяції топологічну інновацію, для оптимізації якої потрібно кілька поколінь? Рішення: розподілення інновації між різними видами.
- Як протягом процесу еволюції мінімізувати топологію без залучення спеціально створеної для цього цільової функції, яка вимірює складність? Рішення: усе починається з мінімальної структури, яка еволюціонує лише за необхідності.

Зазначимо, що застосування запропонованих рішень до кожного з викликів є необхідним, оскільки ефективність нейроеволюційного процесу знижується із видаленням будь-якого з основних компонентів. З іншого боку, злагоджена робота цих складових створює новий перспективний підхід до розв'язання складних задач навчання з підкріпленням і не тільки.

Таким чином, архітектура нейроеволюції доповнених топологій була розроблена з урахуванням перерахованих вище проблем. Опис цього підходу подається відповідно до [16].

Дана архітектура репрезентує геном як список генів зв'язку, кожному з яких відповідають два вузлових гени. Кожний ген зв'язку містить інформацію про вхідний та вихідний вузли, ваговий коефіцієнт зв'язку, прапорець активності, а також історичну мітку для пошуку генів однакового походження під час кросинговеру.

Нейроеволюція доповнених топологій використовує мутації, що можуть змінювати і вагові коефіцієнти, і структуру мережі. Вагові коефіцієнти з'єднання змінюються як і в будь-якій іншій нейроеволюційній системі. Водночас з'єднання не зобов'язане змінюватись, воно може лишитись незмінним. Структурні мутації розширюють геном і можуть відбуватися двома шляхами: додається або нове з'єднання, або новий вузол. Коли відбувається мутація першого типу, у геном додається новий ген зв'язку, який з'єднує два раніше не з'єднані вузли. Другий тип мутації зумовлює розрив наявного з'єднання, на місці якого розміщується новий вузол. Старе з'єднання стає неактивним, натомість два нові з'єднання додаються до геному. Такий спосіб додавання

вузлів уможливорює миттєву інтеграцію нових вузлів у мережу.

Мутації зумовлюють появу геномів різного розміру, іноді з абсолютно різними топологіями. Тут ми підходимо до першого виклику, означеного вище: знайти представлення геному, яке дозволить розрізненим топологіям схрещуватись значущим чином.

Схрещування (кросинговер) можливе лише тоді, коли система має можливість визначити, які гени є спільними для будь-яких двох особин в популяції. Ключове спостереження полягає в тому, що два гени з однаковим історичним походженням мають однакову структуру (хоча, можливо, із різними ваговими коефіцієнтами), оскільки вони обидва були отримані від одного гена-предка у певний момент у минулому. Отож, усе, що потрібно зробити системі, — це відстежувати історичне походження кожного гена.

На щастя, відстеження історичного походження потребує дуже мало обчислень. Щоразу, коли з'являється новий ген (через структурну мутацію), ми збільшуємо глобальний номер інновації та присвоюємо цьому гену. Таким чином, історичне походження кожного гена в системі відоме протягом еволюційного процесу, за це відповідають глобальні номери інновацій.

Історичні мітки дають системі, побудованій на основі нейроеволюції доповнених топологій, можливість визначати сумісні гени. Несумісні гени можуть бути або ексцесивними, або взагалі не перетинатися, залежно від того, чи їхні мітки лежать у межах, чи поза межами діапазону історичних міток кожного з батьків. У процесі кросинговеру в обох геномах впорядковуються гени з однаковими номерами інновації. Несумісні гени успадковуються від більш придатного батька або випадково, якщо кожен з батьків однаково придатний. Таким чином, історичні мітки дозволяють виконувати операцію кросинговеру без залучення дорогого топологічного аналізу.

Зазначимо, що описаний метод кросинговеру вирізняється своєю простотою і загальністю. Будь-які дві структури можуть бути об'єднані без необхідності жодного топологічного аналізу. Проблема поєднання то-

пологій перетворюється у проблему визначення відповідності історичних міток, а в такому вигляді її значно простіше розв'язувати.

Зазвичай зміна структури мережі призводить спочатку до зниження її ефективності. Тому необхідним є механізм захисту топологічних (структурних) інновацій від передчасного зникнення з популяції. Нейроеволюція доповнених топологій має такий механізм. Це досягається особливим чином: спочатку індивіди конкурують у межах власного виду, а не в рамках цілої популяції. Так, топологічні інновації захищені від передчасного зникнення та мають час для оптимізації своєї структури, перш ніж доведеться конкурувати з іншими видами в популяції.

Історичні мітки дають змогу системі розділити популяцію на види за топологічною подібністю. Кількість ексцесивних генів і генів, що взагалі не перетинаються, є природними параметрами для вимірювання міри близькості геномів. Чим меншу спільну еволюційну історію мають два геноми, тим більше вони розрізнені, а отже, менш сумісні. Тож, ми можемо виміряти міру сумісності різних структур як зважену лінійну комбінацію кількості ексцесивних генів та генів, що не перетинаються.

Це метричне співвідношення дозволяє нам ввести порогове значення для сумісності двох геномів. Ми тестуємо геноми один за одним. Якщо відстань від геному до навмання обраного представника виду менша за порогове значення, даний геном вважається приналежним до цього виду. При цьому кожний геном ми вважаємо приналежним до першого виду, де ця умова виконується, що гарантує те, що жоден геном не міститься більше, ніж в одному виді.

Декілька слів про третій виклик, що постає перед нейроеволюційними підходами: мінімізація топології отриманого рішення. Рішення, що його пропонує нейроеволюція доповнених топологій, — просте. Ми починаємо з найпростішої структури та ускладнюємо її лише за необхідності. Нова структура вводиться поступово в міру того, як відбуваються структурні мутації. В результаті виживають лише ті структури, які виявляються ефективними у сенсі значень цільової функції. Зазначимо, що такий підхід можливий завдяки описаному вище ме-

ханізму захисту інновацій. Без цього механізму нові структури не могли б виживати, оскільки, як зазначено вище, щойно утворена структура спочатку призводить до зниження ефективності.

Опис експерименту

Як було зазначено вище, основною ідеєю даного дослідження є перевірка можливості застосування нейроеволюційного підходу до проектування моделей “глибокого навчання”, призначених для постпроцесингу результатів прогнозу приземної температури, отриманого за допомогою чисельних гідродинамічних методів метеорологічного прогнозування.

Для кожної метеорологічної станції за допомогою нейроеволюції доповнених топологій тренувалася власна нейромережева модель, яка мала б якнайкраще виокремити фізичні особливості конкретного пункту спостереження. Таким чином, ми маємо 8 натренованих моделей.

Що 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).

Зауважимо, що цей поділ на три класи (набори) — це загальна практика для “глибокого навчання” [21]. Тренувальний набір є найбільшим і використовується для оновлення вагових коефіцієнтів моделі шляхом зворотного розповсюдження помилки або інших алгоритмів навчання. Другий набір, валідаційний, використовується виключно для налаштування гіперпараметрів: кількості шарів, типів шарів, функцій активації, цільових функцій, швидкості навчання тощо. Ключовою метою цього налаштування є підвищення здатності мережі до узагальнення, щоб гарантувати, що мережа добре функціонуватиме на невідомих для неї даних. Третій набір даних — це тестовий набір, раніше невідомі дані, які використовуються для оцінювання мережі після налаштування.

Зазначимо, що усі експерименти проводилися з використанням відкритого нейромережевого інтерфейсу Keras [22], відкри-

тої програмної бібліотеки для “глибокого навчання” TensorFlow [23] та фреймворку для нейроеволюції TFNE (Tensorflow-Neuroevolution Framework) [24]. Програмний код був написаний мовою Python [25].

Отримані результати

Ефективність запропонованого підходу оцінювалась 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, в більшості випадків і значення RMSE, і відсоток покращених прогнозів для нейроеволюційного підходу є кращими (не гіршими) за відповідні значення для підібраної вручну архітектури.

Таблиця. Порівняльна таблиця

Станція	RMS E (NN), °C	Покращення, %	RMSE (NE), °C	Покращення, %
Біла Церква	1.89	54.81	1.96	54.81
Бориспіль	2.00	53.21	1.70	54.56
Київ	1.98	53.97	1.85	56.84
Миронівка	2.01	57.48	1.84	58.42
Тетерів	2.02	52.29	2.03	50.79
Фастів	1.86	54.68	1.86	54.42
Чорнобиль	2.01	50.59	1.94	52.53
Яготин	2.12	52.21	2.05	49.40

Висновки

На прикладі прогнозів моделі COSMO приземної температури повітря для восьми метеорологічних станцій Київської області та відповідних їм даних фактичних спостережень було перевірено можливість застосування нейроеволюційного підходу до проектування моделей “глибокого навчання”, призначених для постпроцесингу результатів прогнозу приземної температури, отриманого за допомогою чисельних гідродинамічних методів метеорологічного прогнозування.

Було показано, що в половині випадків і значення кореня середнього квадратичного відхилення, і відсотка поліпшених прогнозів для нейроеволюційного підходу є кращими (а в окремих випадках набагато кращими) за відповідні значення для підібраної вручну архітектури.

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

References

1. Agapiou, A., 2017. Remote sensing heritage in a petabyte-scale: satellite data and heritage Earth Engine© applications. *International Journal of Digital Earth*, 10(1), pp.85-102.
2. LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *nature*, 521(7553), pp.436-444.
3. Bhimji, W., Farrell, S.A., Kurth, T., Paganini, M., Prabhat and Racah, E., 2018, September. Deep neural networks for physics analysis on low-level whole-detector data at the LHC. In *Journal of Physics: Conference Series* (Vol. 1085, p. 042034). IOP Publishing.
4. Schütt, K.T., Arbabzadah, F., Chmiela, S., Müller, K.R. and Tkatchenko, A., 2017. Quantum-chemical insights from deep tensor neural networks. *Nature communications*, 8(1), p.13890.
5. Alipanahi, B., Delong, A., Weirauch, M.T. and Frey, B.J., 2015. Predicting the sequence specificities of DNA-and RNA-binding proteins by deep learning. *Nature biotechnology*, 33(8), pp.831-838.
6. Liu, Y., Racah, E., Correa, J., Khosrowshahi, A., Lavers, D., Kunkel, K., Wehner, M. and Collins, W., 2016. Application of deep convolutional neural networks for detecting extreme weather in climate datasets. *arXiv preprint arXiv:1605.01156*.
7. Racah, E., Beckham, C., Maharaj, T., Ebrahimi Kahou, S., Prabhat, M. and Pal, C., 2017. Extremeweather: A large-scale climate dataset for semi-supervised detection, localization, and understanding of extreme weather events. *Advances in neural information processing systems*, 30.
8. 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.
9. 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*.
 10. Oh, J., Guo, X., Lee, H., Lewis, R.L. and Singh, S., 2015. Action-conditional video prediction using deep networks in atari games. *Advances in neural information processing systems*, 28.
 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. Che, Z., Purushotham, S., Cho, K., Sontag, D. and Liu, Y., 2018. Recurrent neural networks for multivariate time series with missing values. *Scientific reports*, 8(1), p.6085.
 13. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z., 2016. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2818-2826).
 14. Hoos, H.H., 2012. Programming by optimization. *Communications of the ACM*, 55(2), pp.70-80.
 15. Miikkulainen, R., Liang, J., Meyerson, E., Rawal, A., Fink, D., Francon, O., Raju, B., Shahrzad, H., Navruzyan, A., Duffy, N. and Hodjat, B., 2024. Evolving deep neural networks. In *Artificial intelligence in the age of neural networks and brain computing* (pp. 269-287). Academic Press.
 16. Stanley, K.O. and Miikkulainen, R., 2002. Evolving neural networks through augmenting topologies. *Evolutionary computation*, 10(2), pp.99-127.
 17. Doroshenko, A.Y., Shpyg, V.M. and Kushnirenko, R.V., 2023. Deep learning-based approach to improving numerical weather forecasts. *PROBLEMS IN PROGRAMMING*, (3), pp.91-98.
 18. Doroshenko, A.Y. and Kushnirenko, R.V., 2023. Recurrent neural networks for the problem of improving numerical meteorological forecasts. *PROBLEMS IN PROGRAMMING*, (4), pp.90-97.
 19. 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].
 20. Doms, G. and Baldauf, M., 2011. A description of the nonhydrostatic regional COSMO-Model Part I: dynamics and numerics. *Deutscher Wetterdienst, Offenbach*.
 21. Goodfellow, I., Bengio, Y. and Courville, A., 2016. *Deep learning*. MIT press.
 22. <https://keras.io/>
 23. <https://www.tensorflow.org/>
 24. <https://tfne.readthedocs.io/en/latest/>
 25. <https://www.python.org/>

Одержано: 03.03.2024

Про авторів:

Дорошенко Анатолій Юхимович, доктор фізико-математичних наук, професор, завідувач відділу ІПС НАНУ та професор кафедри інформаційних систем та технологій КПІ імені Ігоря Сікорського. Кількість наукових публікацій в українських виданнях – понад 200. Кількість наукових публікацій в зарубіжних виданнях – понад 90. Індекс Гірша — 7
<http://orcid.org/0000-0002-8435-1451>,

Кушніренко Роман Владиславович, аспірант. Кількість наукових публікацій в українських виданнях – 5.
<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.kushnirenk@gmail.com.