

**М.С. ЛАВРЕНЮК**

Інститут космічних досліджень НАН України та ДКА України, Київ, Україна,  
e-mail: [nick\\_93@ukr.net](mailto:nick_93@ukr.net).

**Л.Л. ШУМИЛО**

Університет Меріленду, Коледж Парк, США, e-mail: [shumilo.leonid@gmail.com](mailto:shumilo.leonid@gmail.com).

**Б.Я. ЯЙЛИМОВ**

Інститут космічних досліджень НАН України та ДКА України, Київ, Україна,  
e-mail: [yailymov@gmail.com](mailto:yailymov@gmail.com).

**Н.М. КУССУЛЬ**

Національний технічний університет України «Київський політехнічний інститут  
імені Ігоря Сікорського», Київ, Україна, e-mail: [natalia.kussul@gmail.com](mailto:natalia.kussul@gmail.com).

## ОГЛЯД МЕТОДІВ ГЛИБИННОГО НАВЧАННЯ У ПРИКЛАДНИХ ЗАДАЧАХ ЕКОНОМІЧНОГО МОНІТОРИНГУ НА ОСНОВІ ГЕОПРОСТОРОВИХ ДАНИХ<sup>1</sup>

**Анотація.** Розвиток сучасних технологій спостереження Землі, збільшення обсягу відкритих даних та розроблення нових підходів до їхнього оброблення відкривають нові можливості у проведенні прикладних досліджень економічної активності людства. Основним підходом у цій галузі є застосування методів глибинного навчання у процесах оброблення даних та аналізу їхніх часових рядів. У цій роботі виконано огляд базисних розділів глибинного навчання (з погляду геопросторового аналізу): підвищення рівня розрізнення графічних даних, використання трансферного навчання (transfer learning) для оптимізації процесів навчання, масштабування глибоких нейронно-мережевих моделей та аналізу часових рядів за допомогою рекурентних нейронних мереж.

**Ключові слова:** глибинне навчання, трансферне навчання (transfer learning), супутникovi данi, геопросторовi данi, рекурентнi нейроннi мережi.

### ВСТУП

Останні роки характеризуються появою у вільному доступі геопросторових даних, зокрема супутниковых даних високого просторового та часового розрізнення. Пентабайти супутникових знімків стали загальнодоступними, більшість алгоритмів здобування інформації з цих зображень сьогодні є широко застосовними, а сучасна обчислювальна техніка на основі хмарних технологій дає змогу застосовувати ці алгоритми у глобальному масштабі. Як наслідок, геопросторові дані нині ефективно використовують для розв'язання широкого кола прикладних задач.

Прикладом задачі, яку можна розв'язати на основі геопросторових даних, є економічний моніторинг діяльності в регіонах шляхом визначення таких індикаторів, як економічна активність та бідність населення [1]. У більшості сучасних досліджень у цьому напрямку розглядають агроеconomіку або економічну оцінку наслідків стихійних лих чи надзвичайних ситуацій. Зокрема у роботі [2] здійснено економічне оцінювання збитків, завданіх пожежею у м. Хайфа (Ізраїль) у 2016 р. Використання супутниковых даних Planet дало можливість оцінити загальну площу пошкоджених дерев та їхню кількість (за оцінкою обсяг збитків у міському лісі становив  $41 \pm 10$  млн дол. США). У [3] наведено підхід до оцінювання збитків від посухи, що ґрунтуються на технології злиття супутниковых даних різної природи та різних типів сенсорів. Оцінка економічного збитку в Одеській області від загибелі посівів зернових внаслідок несприятливих умов становила

<sup>1</sup> Робота виконується у межах проекту №2020.02/0292 «Методи і моделі глибинного навчання для прикладних задач супутникового моніторингу» за грантової підтримки Національного фонду досліджень України в межах конкурсу «Підтримка досліджень провідних та молодих учених».

у 2020 р. близько 338 тис. га посівів. Ще однією задачею на основі супутниковых даних є оцінювання економічних збитків від повеней. Ця інформація є дуже корисною під час розподілу ресурсів для відновлення та реконструкції або попереднього економічного оцінювання збитків від повені, що сприяє врегулюванню кризи після катастрофи [4]. Одним із найважливіших аспектів застосування цих підходів до аналізу супутниковых даних є можливість проведення ретроспективного аналізу стихійних лих для подальшої оцінки ризиків. У [5] наведено аналіз стихійних лих в Угорщині протягом 1998–2001 pp.

Сьогодні геопросторові дані є невід'ємним інструментом, що дає можливість прогнозувати та візуалізувати надзвичайні ситуації для систем підтримки прийняття рішень, що використовуються міжнародною спільнотою з управління надзвичайними ситуаціями [6], та у такий спосіб здійснювати економічне оцінювання. Сучасні методи оброблення та аналізу супутниковых даних дають можливість здійснювати оцінювання економічних показників валового внутрішнього продукту [7], впливу способів здійснення сільськогосподарської діяльності на продуктивність ґрунтів [8], вартості землі [9] або впливу воєнного конфлікту на ґрутовий покрив та землекористування [10]. Актуальною є задача визначення та моніторингу динаміки зміни показників у часі. Розв'язання цієї задачі наведено в [11], однак лише для випадку дуже специфічної задачі визначення вологості ґрунтів. Тому потрібно адаптувати цей підхід до класифікації геопросторових даних та забезпечення можливості застосування методів глибинного навчання для розв'язання задач економічного моніторингу на основі геопросторових даних.

У цій статті виконано аналіз наявних методів оброблення та аналізу супутниковых даних, які можна використати для розв'язання актуальних прикладних задач економічного моніторингу на основі глибинного навчання. Наведені методи роботи із супутниковими даними дають змогу розв'язати низку проблем, пов'язаних з обмеженнями класичних підходів геопросторового аналізу, проблеми Big Data і дають можливість покращити показники точності та якості результатів досліджень у сфері дистанційного зондування Землі. Ключовими технологіями у розвитку та розробленні цих підходів є підвищення розрізнення зображень, що дає змогу покращувати якість даних на етапі їхнього попереднього оброблення; трансферне навчання, що дає можливість оптимізувати процес навчання й масштабування моделей глибинного навчання; класифікація часових рядів багатовимірних даних.

#### **АНАЛІЗ НАЯВНИХ МЕТОДІВ ТА МОДЕЛЕЙ ГЛИБИННОГО НАВЧАННЯ ДЛЯ РОЗВ'ЯЗАННЯ ПРИКЛАДНИХ ЗАДАЧ**

Останніми роками для розв'язання прикладних задач на основі великих обсягів даних активно розвивають інтелектуальні методи оброблення інформації та методи глибинного навчання. Найбільш інтенсивно ці методи розробляють у галузі комп'ютерного зору й оброблення текстової інформації [12]. Сучасні методи інтелектуального аналізу супутниковых даних ґрунтуються на методах глибинного навчання з використанням згорткових або рекурентних нейронних мереж і дають змогу розв'язувати задачі класифікації та регресії супутниковых даних, а також здійснювати їхню семантичну розмітку. Важливим викликом у цій галузі є потреба у розробленні методів гармонізації супутниковых даних різної природи (оптичних та радарних) з різним просторовим і часовим розрізненням, а також формування рядів даних високого розрізнення, готових до подальшого аналізу (analysis ready data). Ці математичні методи розроблено для даних зображень іншого виду — звичайних фотографій [13, 14], текстів [15], звуків [16].

Протягом останніх років розроблено новий вид нейронних мереж, які мають великі перспективи у розв'язанні цих задач, а саме генеративні змагальні мережі (generative adversarial networks, GANs) [17]. Актуальною є задача розроблення та адаптації GANs для роботи із супутниковими даними з огляду на специфіку супутниківих знімків. Високу ефективність показали рекурентні нейронні мережі з короткостроковою та довгостроковою пам'яттю (LSTM), що вже також застосовуються для розв'язання задач класифікації супутниковых даних [18].

Під час розв'язання прикладних задач часто використовують гібридні нейронні мережеві моделі. Наприклад, у [19] застосовано методи глибинного навчання для оцінювання погодинної глобальної сонячної радіації (GSR) від геостаціонарного супутника, де для оцінювання GSR запропоновано гібридну глибинну мережу, яка складається зі згорткової нейронної мережі (CNN), багатошарового персептрона (MLP) для зв'язку моделей та додаткової інформації про час/місце розташування.

Однією з проблем під час розв'язання прикладних задач на основі супутниковых даних є те, що більшість із них мають низьке просторове розрізnenня. Як приклад у [20] використано супутникові продукти із просторовим розрізnenням від 250 м до 1 км для виявлення диму в лісовій пожежі за допомогою нейронної мережі зворотного поширення. Використання даних низького просторового розрізnenня зумовлено тим, що вони дають можливість оцінити поширення диму під час пожежі за рахунок свого частого оновлення та великого охоплення території, що знімається за один раз. Проте через низьке просторове розрізnenня складно виявити активні пожежі та їхнє поширення.

#### **АНАЛІЗ НАЯВНИХ МЕТОДІВ ДЛЯ ПІДВИЩЕННЯ РОЗРІЗНЕННЯ НА ЗНІМКАХ ТА ЗОБРАЖЕННЯХ**

Задача підвищення просторового розрізnenня зображення (super-resolution) виникає в багатьох прикладних сферах під час оброблення як зображень, так і відео [21]. Просторове розрізnenня характеризується щільністю пікселів на зображені та вимірюється в пікселях на одиницю площини [21]. Методи підвищення просторового розрізnenня зображення можуть використовувати декілька зображень низького просторового розрізnenня для створення одного зображення високого розрізnenня, або ж працювати виключно з одним вхідним зображенням низького просторового розрізnenня. Розв'язання задачі з використанням декількох вхідних зображень детально описано в [21]. Розглянемо розв'язання задачі за наявності лише одного вхідного зображення.

Найпростішим методом для збільшення просторового розрізnenня зображення є застосування інтерполяції (методу найближчого сусіда, білінійної інтерполяції, бікубічної інтерполяції, сплайнів тощо). Недоліком цього підходу є те, що він аж ніяк не враховує семантики зображення та контури об'єктів. Як наслідок, отримане зображення містить багато розмиття (blur). Інший підхід, застосований для збільшення просторового розрізnenня зображення, ґрунтуючись на розрідженному кодуванні [22]. У більшості розріджених методів припускається, що кожна пара фрагментів (patch) на зображеннях з низьким та високим розрізnenням має однакові коефіцієнти кодування у просторі фрагментів [23], і як наслідок фрагменти зображення з високим розрізnenням можна представити розрідженими кодовими фрагментами зображення з низьким розрізnenням. Тому спершу навчають пари словників для фрагментів зображень з низьким та високим розрізnenням. Після чого зображення з високим розрізnenням можна одержати за допомогою вивченого словника для фрагментів зображень з високим розрізnenням та кодуванням, що отримують за допомогою вивченого словника для фрагментів зображень з низьким розрізженням [23].

З настанням ери розвитку методів та моделей глибинного навчання для розв'язання різних прикладних проблем задачу підвищення просторового розрізнення зображення почали розв'язувати також з використанням методів глибинного навчання. Метод із застосуванням згорткових нейронних мереж до розв'язання цієї задачі запропоновано у 2015 р. Він має назву Super-Resolution Convolutional Neural Network (SRCNN) [24]. Проте у цій роботі запропоновано не «end-to-end» рішення, а рекомендовано спочатку збільшити зображення до необхідного розміру за допомогою стандартного методу бікубічної інтерполяції, а лише після цього застосовувати запропоновану нейронну мережу для покращення якості отриманого зображення. Як оцінку роботи моделі для підвищення розрізнення зображення використано стандартну оцінку пікового відношення сигналу до шуму Peak Signal to Noise Ratio (PSNR) [25].

Покращення методу SRCNN запропоновано у [26] з використанням Very Deep Super Resolution (VDSR) моделі. За основу взято модель SRCNN, проте згортки великого розміру ( $5 \times 5$  та  $9 \times 9$ ) замінено на послідовність згорток розміру  $3 \times 3$ , як це запропоновано у моделі VGG для класифікації зображень [27]. Ця VDSR модель складалася з 20 шарів, на відміну від SRCNN моделі, яка мала три шари. До того ж, модель VDSR намагається вивчити залишок між цільовим зображенням та інтерпольованим, а не вивчати повністю переведення з одного зображення в інше, як це було в моделі SRCNN.

Проблемою попередніх двох методів є застосування інтерполяції на початковому етапі. Це призводить до використання великої кількості параметрів у моделях, а також унеможливлює вивчення моделлю параметрів для здійснення саме процедури збільшення розмірності знімку. Для розв'язання цих проблем запропоновано модель Fast Super-Resolution Convolutional Neural Networks (FSRCNN) [28]. На вході моделі подавали зображення з низьким розрізненням без будь-яких попередніх перетворень (рис. 1). Також тут додатково використано згортку  $1 \times 1$  і замінено функцію активації з Rectified Linear Unit (ReLU) на Parametric Rectified Linear Unit (PReLU). Для навчання моделі підвищення розрізнення зображення використано зворотну згортку (deconvolutional) шарів, що дало змогу навчати модель у спосіб «end-to-end».

Метод, що працює за схожим принципом, запропоновано у [29]. Він має назву Efficient Sub-Pixel Convolutional Neural Network (ESPCN). Архітектура цієї мережі за схожим принципом ґрунтується на використанні згорткових шарів, проте в кінці використовують не зворотну згортку (deconvolutional) шарів, а субпіксельні згорткові шари (рис. 2). Ця ідея схожа на використання інструментарію position-sensitive score maps під час детектування об'єктів [30].

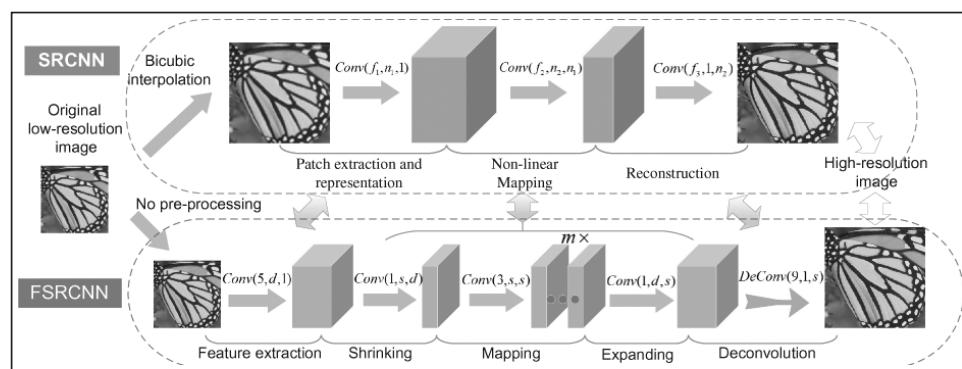


Рис. 1. Порівняння архітектур моделей SRCNN та FSRCNN [28]

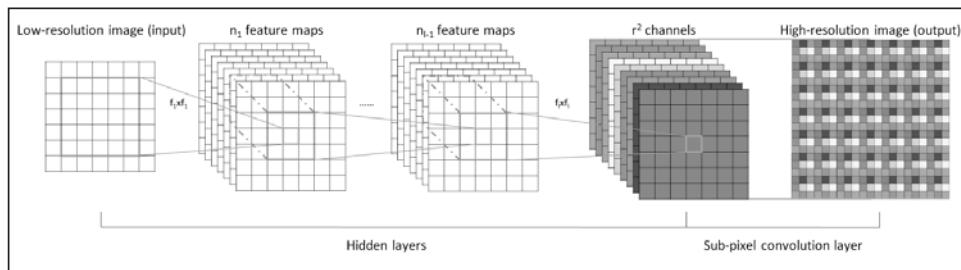


Рис. 2. Приклад використання субпіксельних згорткових шарів у моделі ESPCN [29]

Моделі Enhanced Deep Super-Resolution network (EDSR) та SRResNet [17] використовують ідею ResNet для підвищення розрізнення зображень. Проте в SRResNet видалено нелінійний шар з ReLU активацією, а в EDSR видалено шари нормалізації даних (batch normalization). У [17] експериментально показано, що ці модифікації дають змогу отримувати більш якісні зображення на виході моделі та допомагають зменшити обсяг пам'яті, використовуваної для навчання моделі.

У роботі [31] запропоновано каскадну модель Cascading Residual Network (CARN) на основі залишкових блоків. У [32] запропоновано модель Deep Recursive Residual Network (DRRN), що є фактично об'єднанням двох ідей. Перша ідея — це використання залишкових блоків, а інша — використання Deeply-Recursive Convolutional Network (DRCN) [33], що ґрунтується на застосуванні однієї й тієї самої згортки в ітеративний спосіб для покращення результату. В підсумку DRRN складається з 52 згорткових шарів, які навчаються у спосіб «end-to-end».

Проблема вищеписаних методів у тому, що вони можуть покращити розрізнення зображення у 2–4 рази. Щодо покращення у вісім та більше разів розглянуті моделі дають не дуже якісний результат. Для подолання цієї проблеми запропоновано мережу Laplacian Pyramid Super-Resolution Network (LapSRN) [34]. Ідея цієї моделі полягає в поетапному збільшенні зображення за допомогою піраміди (рис. 3). Функція втрат є сумаю функцій втрат на кожному рівні піраміди. Щоб обчислити функцію втрат на кожному рівні піраміди, тут застосовано бікубічну інтерполяцію для зменшення розрізнення зображення, яке необхідно відтворити. Як функцію втрат взято Charbonnier Loss, що є більш стійкою до викидів на думку авторів [34].

Усі описані методи працюють однаково на будь-якій частині зображення. Проте в цілому моделі слід зосереджуватися на якихось частинах зображення більше, ніж на інших. Для цього в глибинному навчанні використовують механізм уваги (attention) [25]. Для реалізації цієї ідеї у [35] запропоновано

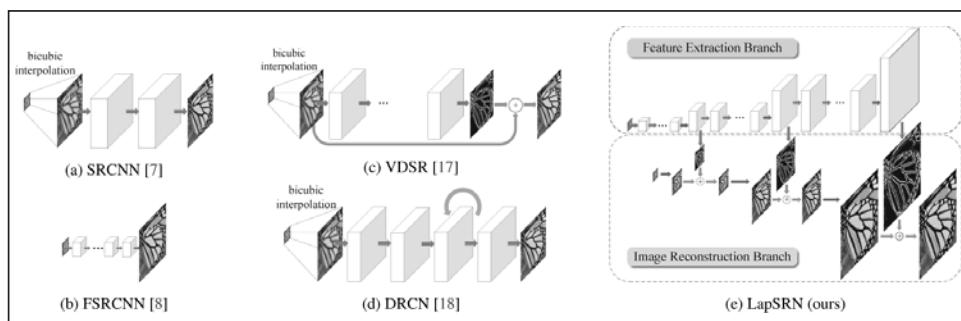


Рис. 3. Схематичні моделі SRCNN, FSRCNN, VDSR, DRCN та LapSRN [34]

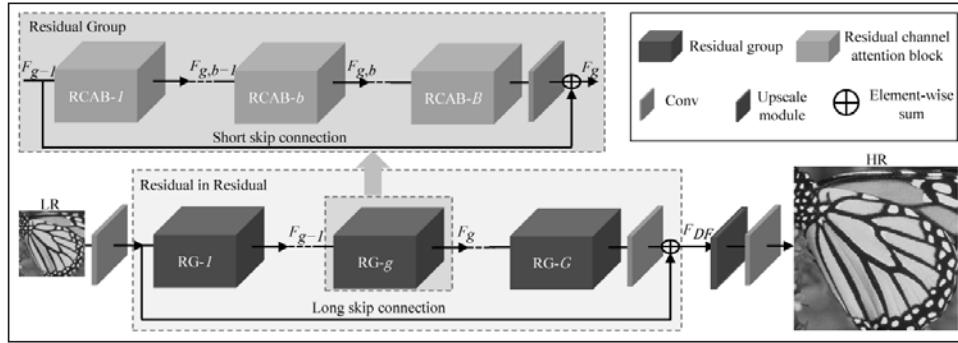


Рис. 4. Архітектура Residual Channel Attention Networks моделі [36]

Squeeze and Excitation (SE) блок, що дає змогу нейронній мережі звернати більшу увагу на важливі ознаки та меншу — на менш важливі.

У роботі [36] запропоновано Residual Channel Attention Networks (RCAN) модель, що використовує блоки із залишковими довгими та короткими зв’язками, а також Residual Channel Attention Block (RCAB) блоки, що є аналогами SE блоків. Загальну архітектуру цієї мережі наведено на рис. 4. У цій моделі для порівняння з попередніми моделями під час навчання використано функцію втрат L1.

Альтернативним підходом до підвищення розрізнення зображень є використання Generative Adversarial Networks (GAN) [37], які складаються з двох нейронних мереж — генератора та дискримінатора і навчаються за правилом навчання без учителя. Вперше цей підхід запропоновано у [38] під назвою Super Resolution Generative Adversarial Networks (SRGAN). Ідея моделі є такою. Одна нейронна мережа (генератор) породжує зображення вищого розрізнення, інша нейронна мережа (дискримінатор) намагатиметься визначити, яким є це зображення — справжнім чи згенерованим мережею. Навчання моделей завершується тоді, коли перша мережа навчиться генерувати «справжні» зображення підвищеного розрізнення, які інша мережа не зможе відрізнити від справжніх. Архітектури дискримінатора та генератора моделі SRGAN ґрунтуються на мережі ResNet і зображені на рис. 5. Тут також запропоновано для покращення результату замінити стандартну функцію втрат MSE на функцію втрат типу «perceptual loss» [39], яку обчислюють на основі

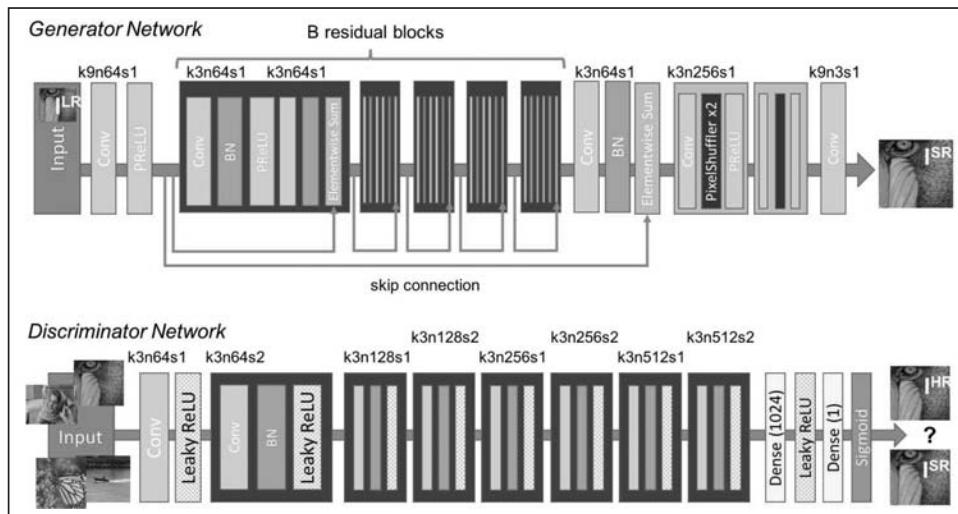


Рис. 5. Архітектура генератора та дискримінатора в моделі SRGAN [38]

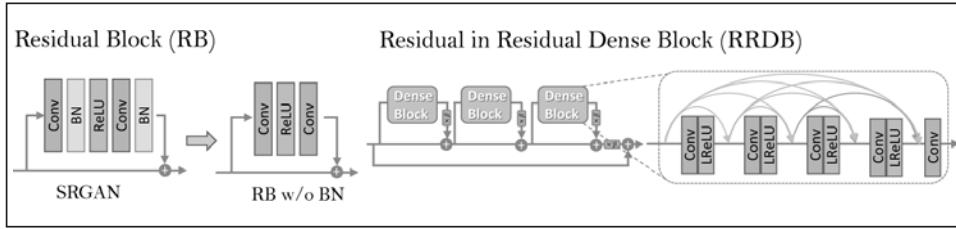


Рис. 6. Приклад базових блоків: залишкового блоку (зліва) та RRDB блоку (справа) [43]

ознак, отриманих за допомогою попередньо навченої мережі VGG. Для навчання GAN як змагальну функцію втрат (adversarial loss) використано стандартну функцію втрат — бінарну перехресну ентропію (cross-entropy) [38].

У роботі [40] ідею використання GAN для підвищення розрізнення модифіковано шляхом застосування CycleGAN [41], що ґрунтуються на навчанні моделі пепретворення зображення з низьким розрізненням у зображення з високим розрізненням, але без наявності шуму та розмиття, а також навпаки. Запропонований метод отримав назву Cycle-in-Cycle Generative Adversarial Networks (CinCGAN). До того ж, замінено стандартну змагальну функцію втрат (бінарну перехресну ентропію) на MSE [42], що дало змогу отримати більш чіткі результати. Також додано шрафні функції втрат консистенції в циклі (cycle consistency loss) та ідентичності (identity loss) у вигляді L2 та L1 норм відповідно. Загальну функцію втрат під час навчання моделі обчислювали як суму всіх запропонованих функцій втрат з певними коефіцієнтами, підібраними в емпіричний спосіб.

У [43] запропоновано модель Enhanced Super-Resolution Generative Adversarial Networks (ESRGAN), що ґрунтуються на моделі SRResNet, проте базові залишкові блоки замінено на Residual in Residual Dense Block (RRDB) (рис. 6). Також була змінена змагальна функція втрат, щоб можна було не лише прогнозувати, якими є вхідні зображення — реальними чи підробленими, а й прогнозувати ймовірність того, що реальні зображення є відносно більш реалістичними, ніж підроблені.

Враховуючи всі розглянуті вище методи, можна дійти висновку, що найбільш підходящими нині є методи, що ґрунтуються на ідеї використання GAN для підвищення розрізнення зображення. Зокрема цю ідею використовують не лише у випадку звичайних фотографій, а й у разі розв'язання задач з іншими даними. Наприклад, у роботі [44] запропоновано модель на основі SRGAN для підвищення розрізнення Digital Elevation Models (DEMs) у чотири рази. У [45] за допомогою GAN підвищують розрізнення даних погодного радару, що дає змогу точніше прогнозувати погоду. Декілька робіт присвячено збільшенню мультиспектральних даних, зокрема супутниковых даних. У [46] використано ESRGAN для підвищення просторового розрізнення знімків Sentinel-2 до просторового розрізнення знімків WorldView, що дало змогу підвищити просторове розрізнення у 5 разів. Також ESRGAN використано для підвищення розрізнення знімків з безпілотних літальних апаратів [47]. Метод Edge-Enhancement Generative Adversarial Networks (EEGAN) запропоновано для підвищення розрізнення знімків з Jilin-1 та Digitalglobe [48]. Модифікований метод SRGAN із заміною двовимірних згорткових шарів на тривимірні згорткові шари та додаванням механізму уваги запропоновано для підвищення розрізнення мультиспектральних даних [49]. Більше прикладів застосування GAN моделей, а також моделей глибинного навчання до даних, отриманих методами дистанційного зондування землі, наведено в [50].

## АНАЛІЗ НАЯВНИХ МЕТОДІВ ДЛЯ ТРАНСФЕРНОГО НАВЧАННЯ У ДИСТАНЦІЙНОМУ ЗОНДУВАННІ ЗЕМЛІ

Технологія трансферного навчання (transfer learning) — це розділ у машинному навчанні, основною задачею якого є збереження та перенесення отриманої інформації та моделей штучного інтелекту на іншу або пов'язану задачу. У разі застосування підходу трансферного навчання до даних дистанційного зондування Землі основною задачею є перенесення моделей штучного інтелекту, навчених на наборі даних для заданої території і заданого часового періоду, на інші території або часові періоди. У цій постановці зазначені проблеми не є тривіальними, оскільки навіть одна й та сама територія кожного року на супутникових даних суттєво відрізняється за мультиспектральними показниками. Ці дані зазвичай отримують у різні дати року та за різних погодних умов, які впливають як на доступність даних, так і на освітлення поверхні землі під час зйомки.

Формально задачу трансферного навчання за допомогою математики можна описати так [51]: область  $D = \{X, P(X)\}$  складається з простору ознак  $X$  та граничного розподілу ймовірностей  $P(X)$ , при цьому область  $T = \{Y, f(\cdot)\}$  складається з простору міток  $Y$  та прогнозної функції  $f(\cdot)$ , яка моделює  $P(y|x)$ , де  $y \in Y, x \in X$ . Маючи початкову область  $D_s$  та навчальну задачу  $T_s$  разом з цільовою областю  $D_t$  та цільовою навчальною задачею  $T_t$ , формують підхід, орієнтований на покращення процесу навчання цільової прогнозної функції  $f_t(\cdot)$ , що належить  $T_t$ , використовуючи знання та інформацію з  $D_s$  та  $T_t$ , де  $D_s \neq D_t$  та/або  $T_s \neq T_t$ . Ця задача є особливо актуальною, коли  $|D_t| \leq |D_s|$ .

Цікавим прикладом застосування підходу трансферного навчання на даних дистанційного зондування Землі є перенесення інформації із задачі розпізнавання об'єктів ImageNet з використанням супутникових знімків високого просторового розрізnenня, отриманих вдень, у задачу передбачення інтенсивності нічного освітлення вночі для картографування індикаторів бідності та дотримання цілей сталого розвитку. Це дослідження було виконано командою із Стенфордського університету [52]. Під час його реалізації використано модель згорткової нейронної мережі з архітектурою VGG. Для картографування індикаторів бідності було сконструйовано transfer learning граф у вигляді лінійного ланцюга з трьома задачами transfer learning:  $P_1$  — розпізнавання об'єктів на даних ImageNet,  $P_2$  — прогнозування нічного освітлення на супутникових даних та  $P_3$  — прогнозування індикаторів бідності на основі денних супутниковых даних.

У [53] наведено дуже актуальній приклад використання методів глибинного навчання та трансферного навчання для розв'язання задачі прогнозування врожайності за допомогою даних дистанційного зондування Землі. Проблема полягає в тому, що статистика врожайності для країн, що розвиваються, доступна в дуже малому обсязі. Водночас для цих країн прогнозування врожайності є однією із запорук сталого розвитку сільського господарства та безпеки харчування. Під час експерименту використано супутникові дані MODIS та статистику врожайності сої на рівні країни та провінцій для Аргентини та Бразилії. Для навчання моделі глибинного навчання знімки MODIS, що містять мультиспектральні та температурні канали, подають у вигляді окремих гістограм, далі всі гістограми групують у вигляді матриці, яку перетворюють у тензор, що далі використовується на вході у моделі LSTM.

Під час експерименту автори [53] навчили модель прогнозування врожайності спочатку для Аргентини. Далі шар dense layer попередньо навченої моделі замінили на новий ненавчений та донавчили цю модель на невеликій кількості даних, доступних для Бразилії. Отже, було застосовано підхід трансферного навчання.

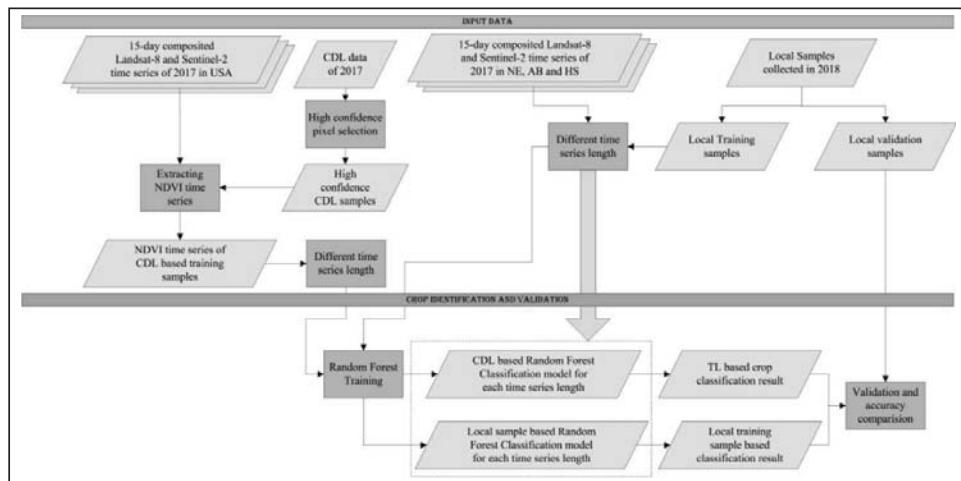


Рис. 7. Схема навчання моделі випадкового лісу на даних Crop Data Layer для перенесення її на інші країни [54]

Класичний експеримент, що показує як працює трансферне навчання, описано у [54]. Тут використано Crop Data Layer [55], що продукується щороку Міністерством сільського господарства Сполучених Штатів Америки, як навчальні наземні дані для класифікації сільськогосподарських культур за 15 денними композитами гармонізованої колекції супутникових даних Sentinel-2 та Landsat-8. На рис. 7 зображене схему цього експерименту. Автори навчили модель класифікатора випадкового лісу на території Сполучених Штатів та перенесли її на територію Китаю та Канади, отримавши високу точність класифікації, що становить 97.79 % та 94.86 % для території Америки та Канади відповідно і 86.45 % для території Китаю. Очевидно, що чим більшими є відмінності у кліматі, способах здійснення сільськогосподарської діяльності, ландшафті та в інших природних та антропоморфних характеристиках території, тим меншою є точність класифікації отриманої моделі. Проте цю проблему можна зменшити, збільшивши обсяг корисної інформації, наприклад подаючи інформацію за кілька років, яка при цьому покриває повний вегетаційний сезон. Також слід зважати на кількість класів під час перенесення моделі. У цьому експерименті для навчання обрано так званий кукурудзяний пояс Америки — місцевість, на якій мажоритарними культурами є кукурудза, озима пшениця і бавовна. Відповідно модель розпізнає тільки три сільськогосподарські культури і не може працювати коректно на місцевостях з більшою варіативністю посівів.

Підхід є ефективним і для складніших візуальних даних. Це показано, наприклад, у [56], де описано експеримент з оцінювання якості доріг у Нігерії на основі супутниковых даних дуже високого просторового розрізнення. При цьому основною проблемою цього дослідження є відсутність достатньої кількості розміщених даних для території інтересу. Тому автори роботи застосували підхід трансферного навчання, навчивши згорткову модель нейронної мережі на 53686 знімках, які покривають 2400 кілометрів доріг у Сполучених Штатах Америки та налаштували і протестували параметри на 1000 розміщених знімках Нігерії.

#### АНАЛІЗ НАЯВНИХ ПІДХОДІВ ВИКОРИСТАННЯ РЕКУРЕНТНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ РОБОТИ З ЧАСОВИМИ ДАНИМИ

У задачах, в яких застосовуються супутникові дані, часто виникає потреба в отриманні моделей, що надають вектор виходів для окремих територій або часових рядів. Ця проблема особливо часто виникає у задачі класифікації сільськогосподарських полів у країнах з теплим кліматом або розвиненими

сільськогосподарськими практиками, в яких наявні подвійні посіви для одного сезону. Найпростішим підходом до розв'язання цієї задачі класифікації класичними методами машинного або глибинного навчання є кодування подвійних посівів за допомогою введення нових класів для карти класифікації і застосування звичайних етапів побудови карти класифікації. Проте ці методи не дуже дієві, бо на практиці такі карти класифікації мають досить низьку точність, оскільки кількість класів є дуже високою, а кількість наземних даних є обмеженою. Другим, більш поширеним способом розв'язання цієї проблеми, який зараз активно розробляють і покращують сучасні науковці, є використання сучасних архітектур нейронних мереж, оптимізованих для роботи з часовими рядами, і кожному часовому відрізку надають відповідну мітку класу. За такого підходу кількість класів не збільшується і в результаті можна отримати більше ніж одну карту класифікації для сільськогосподарського сезону за одне застосування та навчання моделі. Другою важливою задачею є створення моделей глибинного навчання, що дають змогу класифіковати багаторічні супутникові дані і для кожного року надавати інформацію за типом земного покрову чи сільськогосподарських культур. Найпоширенішим типом моделей глибинного навчання для розв'язання цих задач є нейронні мережі зі зворотним зв'язком.

Класичний приклад використання архітектури рекурентної нейронної мережі для розв'язання задачі багаторічної класифікації земного покрову на основі супутниковых даних наведено у [57], де виконано класифікацію земного покрову з 1982 р. по 2015 р. за супутниковими даними з використанням набору карт земного покрову для Китаю CNLUCC як навчальних даних. Їхня модель мала 10 класів земного покрову, як-от: сільськогосподарські угіддя, ліс, кущі, луг, вода, льодовики, болота, міста, пустеля та тундра для семи років: 1980, 1990, 1995, 2000, 2005, 2010 та 2015. Як модель класифікації використано архітектуру на основі двосторонньої нейронної мережі з короткотривалою та довготривалою пам'яттю, зображену на рис. 8. Ця нейронна мережа складається з двох звичайних нейронних мереж LSTM, часові вектори яких направлені у протилежні сторони і мають назву Forward LSTM та Backward LSTM. У цьому дослідженні властивість LSTM моделей генерувати вектор виходів використано для створення набору часових ознак, які об'єднуються і проходять через шари Mean Pooling, та нормованої експоненційної функції (Softmax), для отримання ймовірності виходу, з якого вибирають найбільш вірогідний клас.

У [18] детально описано, як можна використати рекурентні нейронні мережі та нейронну мережу з довготривалою та короткотривалою пам'яттю (LSTM) для

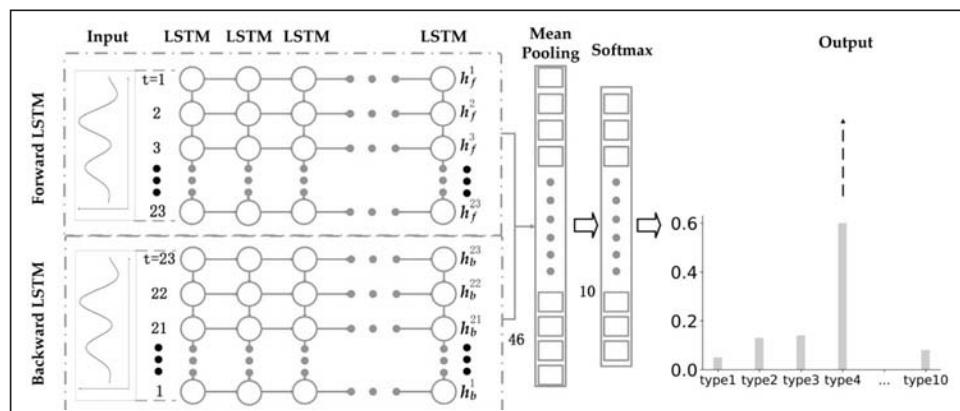


Рис. 8. Архітектура двосторонньої нейронної мережі з довготривалою та короткотривалою пам'яттю для класифікації земного покрову [57]

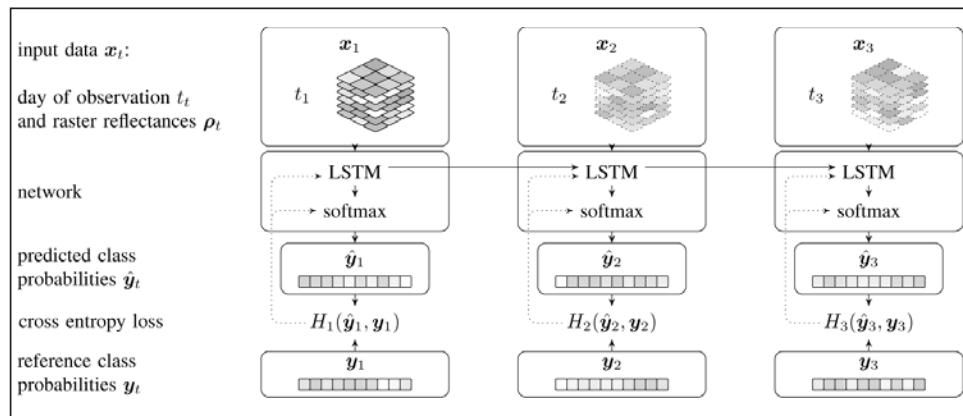


Рис. 9. Схема роботи нейронної мережі LSTM з виходами на кожному часовому відрізку [18]

класифікації часових рядів супутникових даних для отримання карт сільськогосподарських культур. При цьому важливою особливістю рекурентних нейронних мереж є те, що на виході кожний нейрон, який отримує на вході свій часовий відрізок та інформацію з минулих виходів нейронів, тобто інформацію з минулих часових відрізків, продуктує вихід на основі нормованої експоненційної функції (softmax) та перетворюється в імовірності класів для карти класифікації. У такий спосіб здійснюється генерація карти класифікації, яка відповідає відповідному вхідному часовому відрізку. На рис. 9 зображене діаграму роботи моделі нейронної мережі LSTM. За допомогою цього підходу можна отримати кілька карт класифікації сільськогосподарських культур для одного сезону.

Схожий приклад застосування LSTM моделі на часових рядах супутниковых знімків, проте для задачі отримання карт класифікації земного покрову за кілька років з використанням однієї нейронної мережі, опубліковано у [58]. Тут використано дані місії Landsat та CDL за 2013–2016 рр. для того, щоб навчити нейронну мережу з багаторічним входом супутниковых даних продукувати карти класифікації земного покрову за відповідні роки. На рис. 10 наведено схему роботи архітектури нейронної мережі. Видно, що цей принцип є подібним до принципу роботи нейронної мережі з [18], проте відрізняється за довжиною часового ряду, який вже становить 4 роки.

Окрім переваг у побудові високоточних карт класифікацій для часового ряду супутниковых даних LSTM-архітектури мають велику перевагу над кла-

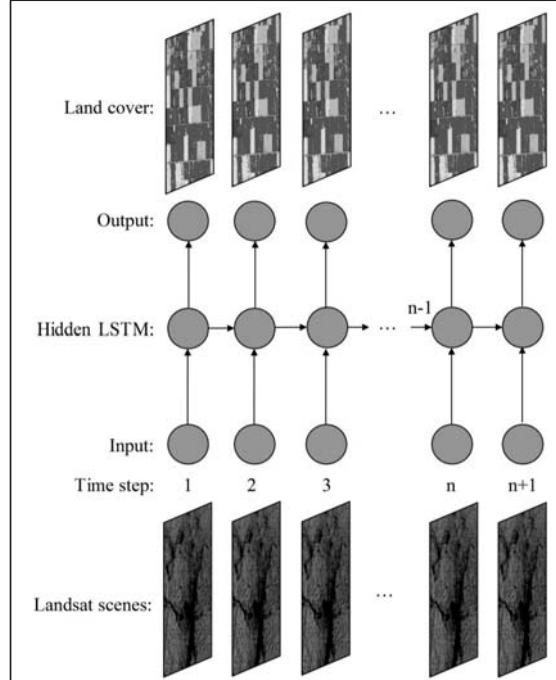


Рис. 10. Схема роботи нейронної мережі для отримання карт класифікації земного покрову за кілька років [58]

сичними методами у задачі прогнозування. Рекурентні нейронні мережі у цьому напрямку вже демонструють найвищу якість спродукованих результатів та дають можливість ефективно здійснювати прогнозування врожайності на велико-му часовому ряду гетерогенних даних на рівні районів, країн та навіть континентів [59]. Оскільки цей підхід вже продемонстрував свою ефективність та перспективність, науковці проводять дослідження та розроблення ускладнених архітектури нейронних мереж. У [60] запропоновано використовувати attention шари в архітектурі LSTM для прогнозування врожайності помідорів. Отже, ця архітектура дає можливість покращити властивості класичних рекурентних нейронних мереж за рахунок запам'ятовування у довгострокову пам'ять інформації з високим рівнем важливості у просторі екзогенних змінних, що мають вплив на значення залежних змінних.

Під час роботи рекурентних нейронних мереж із даними у форматі багатовимірних матриць або зображень можна комбінувати їх зі згортковими нейронними мережами, тобто створювати гібридні архітектури. У [61] запропоновано використовувати архітектуру DeepYield для прогнозування врожайності сільськогосподарських культур за супутниковими даними на рівні країни, яка ґрунтуються на використанні так званих ConvLSTM-шарів. Нейронно-мережеві шари, що поєднують згорткові фільтри та рекурентні нейрони, дають можливість продукувати складніші ознаки, що відображають не тільки зміну мультиспектральних характеристик пікселів у часі, а й залежності між цими змінами у сусідніх пікселях, а також враховувати текстуру посівів та рельєф.

## ВІСНОВКИ

У цій статті наведено огляд сучасних технологій зі спостереження Землі на основі геопросторових даних. Детально розглянуто основні напрямки та сфери прикладних задач оброблення даних та аналізу їхніх часових рядів, а саме підвищення розрізнення графічних даних, використання підходу трансферного навчання до оптимізації процесів навчання та масштабування глибоких нейронно-мережевих моделей і аналізу часових рядів за допомогою рекурентних нейронних мереж. Переважна більшість розглянутих методів ґрунтуються на математичних методах машинного навчання, зокрема глибинного навчання. Отже, в цьому огляді детально описано інтеграцію сучасних методів глибинного навчання для розв'язання прикладних задач з використанням доступних геопросторових даних, зокрема супутниковых даних високого розрізнення.

## СПИСОК ЛІТЕРАТУРИ

1. Sohnesen T.P., Fisker P., Malmgren-Hansen D. Using satellite data to guide urban poverty reduction. *Review of Income and Wealth*. 2021. <https://doi.org/10.1111/roiw.12552>.
2. Michael Y., Lensky I.M., Brenner S., Tchetchik A., Tessler N., Helman D. Economic assessment of fire damage to urban forest in the wildland-urban interface using planet satellites constellation images. *Remote Sensing*. 2018. Vol. 10, Iss. 9. 1479. <https://doi.org/10.3390/rs10091479>.
3. Bilokonska Y., Yailymova H., Yailymov B., Shelestov A., Shumilo L., Lavreniuk M. Losses assessment for winter crops based on satellite data and fuzzy logic. *Proc. 2020 IEEE 5th International Symposium on Smart and Wireless Systems within the Conferences on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS-SWS)* (17–18 September 2020, Dortmund, Germany). Dortmund, 2020. P. 1–5.

4. Merz B., Kreibich H., Schwarze R., Thielen A. Assessment of economic flood damage. *Natural Hazards and Earth System Sciences (NHESS)*. 2010. Vol. 10, Iss. 8. P. 1697–1724. <https://doi.org/10.5194/nhess-10-1697-2010>.
5. Lelkes M., Csornai G. & Wirthhardt C. Natural disaster monitoring by remote sensing in Hungary: waterlogging and floods in the 1998-2001 period. In: Observing Our Environment from Space. Begni G. (Ed.). London: CRC Press, 2002. P. 259–264.
6. Tralli D.M., Blom R.G., Zlotnicki V., Donnellan A., Evans D.L. Satellite remote sensing of earthquake, volcano, flood, landslide and coastal inundation hazards. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2005. Vol. 59, Iss. 4. P. 185–198. <https://doi.org/10.1016/j.isprsjprs.2005.02.002>.
7. Martinez L.R. How much should we trust the dictator's GDP growth estimates? *SSRN Electronic Journal*. 2019. <http://doi.org/10.2139/ssrn.3093296>.
8. Kussul N., Deininger K., Shumilo L., Lavreniuk M., Ali D.A., Nivievs'kyi O. Biophysical impact of sunflower crop rotation on agricultural fields. *Sustainability*. 2022. Vol. 14, N 7. 3965. <https://doi.org/10.3390/su14073965>.
9. Shumilo L., Lavreniuk M., Skakun S., Kussul N. Is soil bonitet an adequate indicator for agricultural land appraisal in Ukraine? *Sustainability*. 2021. Vol. 13, N 21. 12096. <https://doi.org/10.3390/su132112096>.
10. Skakun S., Justice C.J., Kussul N., Shelestov A., Lavreniuk M. Satellite data reveal cropland losses in South-Eastern Ukraine under military conflict. *Frontiers in Earth Science*. 2019. Vol. 7. <https://doi.org/10.3389/feart.2019.00305>.
11. Efremova N. et al. Prediction of soil moisture content based on satellite data and sequence-to-sequence networks. arXiv preprint arXiv:1907.03697. 2019. <https://doi.org/10.48550/arXiv.1907.03697>.
12. Reichstein M., Camps-Valls G., Stevens B., Jung M., Denzler J., Carvalhais N., Prabhat. Deep learning and process understanding for data-driven Earth system science. *Nature*. 2019. Vol. 566 (7743). P. 195–204. <https://doi.org/10.1038/s41586-019-0912-1>.
13. Chen H., He X., Qing L., Wu Y., Ren C., Sheriff R.E., Zhu C. Real-world single image super-resolution: A brief review. *Information Fusion*. 2022. Vol. 79. P. 124–145. <https://doi.org/10.1016/j.inffus.2021.09.005>.
14. Bellavia F., Fanfani M., Colombo C., Piva A. Experiencing with electronic image stabilization and PRNU through scene content image registration. *Pattern Recognition Letters*. 2021. Vol. 145. P. 8–15. <https://doi.org/10.1016/j.patrec.2021.01.014>.
15. Nadif M., Role F. Unsupervised and self-supervised deep learning approaches for biomedical text mining. *Briefings in Bioinformatics*. 2021. Vol. 22, Iss. 2. P. 1592–1603. <https://doi.org/10.1093/bib/bbab016>.
16. Chaiani M., Selouani S.A., Boudraa M., Yakoub M.S. Voice disorder classification using speech enhancement and deep learning models. *Biocybernetics and Biomedical Engineering*. 2022. Vol. 42, Iss. 2. P. 463–480. <https://doi.org/10.1016/j.bbe.2022.03.002>.
17. Lim, B., Son S., Kim H., Nah S., Lee K.M. Enhanced deep residual networks for single image super-resolution. *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (21–26 July 2017, Honolulu, HI, USA). Honolulu, 2017. P. 136–144. <https://doi.org/10.1109/CVPRW.2017.151>.
18. Rußwurm M., Körner M. Temporal vegetation modelling using long short-term memory networks for crop identification from medium-resolution multi-spectral satellite images. *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (21–26 July 2017, Honolulu, HI, USA). Honolulu, 2017. P. 11–19. <https://doi.org/10.1109/CVPRW.2017.193>.

19. Jiang H., Lu N., Qin J., Tang W., Yao L. A deep learning algorithm to estimate hourly global solar radiation from geostationary satellite data. *Renewable and Sustainable Energy Reviews*. 2019. Vol. 114. 109327. <https://doi.org/10.1016/j.rser.2019.109327>.
20. Li X., Song W., Lian L., Wei X. Forest fire smoke detection using back-propagation neural network based on MODIS data. *Remote Sensing*. 2015. Vol. 7, N 4. P. 4473–4498. <https://doi.org/10.3390/rs70404473>.
21. Jianchao Y., Huang T. Image super-resolution: Historical overview and future challenges. In: Super-resolution imaging. Milanfar P. (Ed.). Boca Raton: CRC Press, 2011. P. 20–34. <https://doi.org/10.1201/9781439819319-1>.
22. Zhang J., Wang Z., Zheng Y., Zhang G. Cascade convolutional neural network for image super-resolution. arXiv:2008.10329. 2020. P. 1–12. <https://doi.org/10.48550/arXiv.2008.10329>.
23. Yang J., Wright J., Huang T.S., Ma Y. Image super-resolution via sparse representation. *IEEE Transactions on Image Processing*. 2010. Vol. 19, Iss. 11. P. 2861–2873. <https://doi.org/10.1109/TIP.2010.2050625>.
24. Dong C., Loy C.C., He K., Tang, X. Image super-resolution using deep convolutional networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2016. Vol. 38, Iss. 2. P. 295–307. <https://doi.org/10.1109/TPAMI.2015.2439281>.
25. Zhihao W., Chen J., Hoi S.C.H. Deep learning for image super-resolution: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2021. Vol. 43, Iss. 10. P. 3365–3387. <https://doi.org/10.1109/TPAMI.2020.2982166>.
26. Kim J., Lee J.K., Lee K.M. Accurate image super-resolution using very deep convolutional networks. *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition* (27–30 June 2016, Las Vegas, NV, USA). Las Vegas, 2016. P. 1646–1654.
27. Simonyan K., Zisserman A. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556. 2014. <https://doi.org/10.48550/arXiv.1409.1556>.
28. Dong C., Loy C.C., Tang X. Accelerating the super-resolution convolutional neural network. *Proc. European conference on computer vision (ECCV 2016)* (11–14 October 2016, Amsterdam, The Netherlands). Amsterdam, 2016. *Lecture Notes in Computer Science*. 2016. Vol. 9906. P. 391–407. [https://doi.org/10.1007/978-3-319-46475-6\\_25](https://doi.org/10.1007/978-3-319-46475-6_25)
29. Shi W., Caballero J., Huszár F., Totz J., Aitken A.P., Bishop R., Rueckert D., Wang Z. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network. *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (27–30 June 2016, Las Vegas, NV, USA). Las Vegas, 2016. P. 1874–1883.
30. Dai J., Li Y., He K., Sun, J. R-fcn: Object detection via region-based fully convolutional networks. *Proc. 30th Annual Conference on Neural Information Processing Systems 2016 (NIPS 2016)* (5–10 December 2016, Barcelona, Spain). Barcelona, 2016. Vol. 1. P. 379–387.
31. Ahn N., Kang B., Sohn K.A. Fast, accurate, and lightweight super-resolution with cascading residual network. *Proc. European Conference on Computer Vision (ECCV 2018)* (8–14 September 2018, Munich, Germany). Munich, 2018. Part XV. P. 252–268.
32. Tai Y., Yang J., Liu X. Image super-resolution via deep recursive residual network. *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (21–26 July 2017, Honolulu, HI, USA). Honolulu, 2017. P. 3147–3155.
33. Kim J., Kwon Lee J., Mu Lee K. Deeply-recursive convolutional network for image super-resolution. *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (27–30 June 2016, Las Vegas, NV, USA). Las Vegas, 2016. P. 1637–1645.
34. Lai W.S., Huang J.B., Ahuja N., Yang M.H. Deep Laplacian pyramid networks for fast and accurate super-resolution. *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (21–26 July 2017, Honolulu, HI, USA. Honolulu, 2017. P. 624–632.

35. Hu J., Shen L., Sun G. Squeeze-and-excitation networks. *Proc. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (18–23 June 2018, Salt Lake City, UT, USA). Salt Lake City, 2018. P. 7132–7141.
36. Zhang Y., Li K., Li K., Wang L., Zhong B., Fu Y. Image super-resolution using very deep residual channel attention networks. *Proc. European Conference on Computer Vision (ECCV 2018)* (8–14 September 2018, Munich, Germany). Munich, 2018. P. 286–301.
37. Goodfellow I., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Bengio Y. Generative adversarial nets. *Proc. 27th International Conference on Neural Information Processing Systems (NIPS 2-14)* (8–13 December 2014, Montreal, Canada). Montreal, 2014. P. 2672–2680.
38. Ledig C., Theis L., Huszár F., Caballero J., Cunningham A., Acosta A., Shi W. Photo-realistic single image super-resolution using a generative adversarial network. *Proc. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (21–26 July 2017, Honolulu, HI, USA. Honolulu, 2017. P. 4681–4690.
39. Johnson J., Alahi A., Fei-Fei L. Perceptual losses for real-time style transfer and super-resolution. *Proc. European Conference on Computer Vision (ECCV 2016)* (11–14 October 2016, Amsterdam, The Netherlands). *Lecture Notes in Computer Science*. Vol. 9906. 2016. P. 694–711.
40. Yuan Y., Liu S., Zhang J., Zhang Y., Dong C., Lin L. Unsupervised image super-resolution using cycle-in-cycle generative adversarial networks. *Proc. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (18–22 June 2018, Salt Lake City, UT, USA). Salt Lake City, 2018. P. 814–81409.
41. Zhu J., Park T., Isola P., Efros A. Unpaired image-to-image translation using cycle-consistent adversarial networks. *Proc. 2017 IEEE International Conference on Computer Vision (ICCV)* (22–29 October 2017, Venice, Italy). Venice, 2017. P. 2242–2251.
42. Mao X., Li Q., Xie H., Lau R.Y., Wang Z., Paul Smolley S. Least squares generative adversarial networks. *Proc. 2017 IEEE International Conference on Computer Vision (ICCV)* (22–29 October 2017, Venice, Italy). Venice, 2017. P. 2813–2831.
43. Wang X., Yu K., Wu S., Gu J., Liu Y., Dong C., Qiao Y., Loy C.C. ESRGAN: Enhanced super-resolution generative adversarial networks. *Proc. European Conference on Computer Vision (ECCV 2018) Workshops* (8–14 September 2018, Munich, Germany). Munich, 2018. Part V. P. 63–79.
44. Demiray B.Z., Sit M., Demir I. D-SRGAN: DEM super-resolution with generative adversarial network. arXiv preprint arXiv:2004.04788. 2020. <https://doi.org/10.48550/arXiv.2004.04788>.
45. Chen H., Zhang X., Liu Y., Zeng Q. Generative adversarial networks capabilities for super-resolution reconstruction of weather radar echo images. *Atmosphere*. 2019. Vol. 10, N 9. 555. <https://doi.org/10.3390/atmos10090555>.
46. Salgueiro Romero L., Marcello J., Vilaplana V. Super-resolution of Sentinel-2 imagery using generative adversarial networks. *Remote Sensing*. 2020. Vol. 12, N 15. <https://doi.org/10.3390/rs12152424>.
47. Pashaei M., Starek M.J., Kamangir H., Berryhill J. Deep learning-based single image super-resolution: an investigation for dense scene reconstruction with UAS photogrammetry. *Remote Sensing*. 2020. Vol. 12, N 11. 1757. <https://doi.org/10.3390/rs12111757>.
48. Jiang K., Wang Z., Yi P., Wang G., Lu T., Jiang J. Edge-enhanced GAN for remote sensing image superresolution. *IEEE Transactions on Geoscience and Remote Sensing*. 2019. Vol. 57, Iss. 8. P. 5799–5812. <https://doi.org/10.1109/TGRS.2019.2902431>.
49. Dou X., Li C., Shi Q., Liu M. Super-resolution for hyperspectral remote sensing images based on the 3D attention-SRGAN network. *Remote Sensing*. 2020. Vol. 12, N 7. 1204. <https://doi.org/10.3390/rs12071204>.

50. Tsagkatakis G., Aidini A., Fotiadou K., Giannopoulos M., Pentari A., Tsakalides P. Survey of deep-learning approaches for remote sensing observation enhancement. *Sensors*. 2019. Vol. 19, N 18. 3929. <https://doi.org/10.3390/s19183929>.
51. Pan S.J., Yang Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*. 2009. Vol. 22, N 10. P. 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>.
52. Xie M., Jean N., Burke M., Lobell D., Ermon S. Transfer learning from deep features for remote sensing and poverty mapping. arXiv preprint arXiv:1510.00098. 2015. <https://doi.org/10.48550/arXiv.1510.00098>.
53. Wang A.X., Tran C., Desai N., Lobell D., Ermon S. Deep transfer learning for crop yield prediction with remote sensing data. *Proc. 1st ACM SIGCAS Conference on Computing and Sustainable Societies (COMPASS '18)* (20–22 June 2018, Menlo Park and San Jose, CA, USA). Menlo Park and San Jose, 2018. 50. P. 1–5. <https://doi.org/10.1145/3209811.3212707>.
54. Hao P., Di L., Zhang C., Guo L. Transfer learning for crop classification with Cropland Data Layer data (CDL) as training samples. *Science of The Total Environment*. 2020. Vol. 733. 138869. <https://doi.org/10.1016/j.scitotenv.2020.138869>.
55. Crop Data Layer. URL: <https://nassgeodata.gmu.edu/CropScape/>.
56. Brewer E., Lin J., Kemper P., Hennin J., Runfola D. Predicting road quality using high resolution satellite imagery: A transfer learning approach. *PLoS ONE*. 2021. Vol. 16, N 7. <https://doi.org/10.1371/journal.pone.0253370>.
57. Wang H., Zhao X., Zhang X., Wu D., Du X. Long time series land cover classification in China from 1982 to 2015 based on Bi-LSTM deep learning. *Remote Sensing*. 2019. Vol. 11, N 14. 1639. <https://doi.org/10.3390/rs11141639>.
58. Sun Z., Di L., Fang H. Using long short-term memory recurrent neural network in land cover classification on Landsat and Cropland data layer time series. *International Journal of Remote Sensing*. 2019. Vol. 40, Iss. 2. P. 593–614.
59. Sun J., Lai Z., Di L., Sun Z., Tao J., Shen Y. Multilevel deep learning network for county-level corn yield estimation in the U.S. corn belt. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2020. Vol. 13. P. 5048–5060. <https://doi.org/10.1109/JSTARS.2020.3019046>.
60. Cho W., Kim S., Na M., Na I. Forecasting of tomato yields using attention-based LSTM network and ARMA model. *Electronics*. 2021. Vol. 10, N 13. 1576. <https://doi.org/10.3390/electronics10131576>.
61. Gavahi K., Abbaszadeh P., Moradkhani H. DeepYield: A combined convolutional neural network with long short-term memory for crop yield forecasting. *Expert Systems with Applications*. 2021. Vol. 184. 115511. <https://doi.org/10.1016/j.eswa.2021.115511>.

**M. Lavreniuk, L. Shumilo, B. Yailymov, N. Kussul**  
**REVIEW OF DEEP LEARNING METHODS IN APPLIED PROBLEMS  
 OF ECONOMIC MONITORING BASED ON GEOSPATIAL DATA**

**Abstract.** Development of modern observation technologies, increase in open data, and development of new approaches open new opportunities in carrying out applied research in economic activity of people. The central approach in this field is the use of deep learning methods in data processing and analysis of their time series. In this paper, we review the basic (in terms of geospatial analysis) sections of deep learning: increasing the resolution of graphical data, using transfer learning for optimization of learning processes and deep neural network models, and time series analysis using recurrent neural networks.

**Keywords:** deep learning, transfer learning, satellite data, geospatial data, recurrent neural networks.

*Надійшла до редакції 27.06.2022*