

УДК 004.9

DOI <https://doi.org/10.32782/IT/2024-4-13>

Денис ІВАНОВ

асистент кафедри інформаційних технологій та комп'ютерної інженерії, Національний технічний університет «Дніпровська політехніка», просп. Дмитра Яворницького 19, Дніпро, Україна, 49005

ORCID: 0000-0001-8660-0928

Scopus-Author ID: 58047075900

Віта КАШТАН

кандидат технічних наук, доцент, доцент кафедри інформаційних технологій та комп'ютерної інженерії, Національний технічний університет «Дніпровська політехніка», просп. Дмитра Яворницького 19, Дніпро, Україна, 49005

ORCID: 0000-0002-0395-5895

Scopus-Author ID: 57201902879

Бібліографічний опис статті: Іванов, Д., Каштан, В. (2024). Геоінформаційна технологія виявлення та моделювання затоплених зон міста Дубай на основі згорткової нейронної мережі. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 4, 99–113, doi: <https://doi.org/10.32782/IT/2024-4-13>

ГЕОІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ВИЯВЛЕННЯ ТА МОДЕЛЮВАННЯ ЗАТОПЛЕНИХ ЗОН МІСТА ДУБАЙ НА ОСНОВІ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ

Виявлення затоплених зон є важливим для ефективного реагування на стихійні лиха та їх управління, оскільки це дозволяє створювати системи раннього попередження та організовувати цілеспрямовану допомогу.

Мета роботи полягає у розробці геоінформаційної технології для виявлення та моделювання затоплених зон у Дубаї на основі згорткових нейронних мереж.

Методологія. Геоінформаційна технологія дослідження складається з декількох етапів, що забезпечують комплексний підхід до аналізу та моделювання затоплення території. Спершу здійснюється завантаження супутникових знімків та їх попередня обробка. Це включає корекцію атмосферних спотворень, вирівнювання кольорів та корекцію геометричних викривлень. Після цього знімки перетворюються у векторний формат для полегшення їх подальшої обробки та аналізу. Векторизація дозволяє точніше виділити ключові елементи на знімках, такі як річки, дороги, будівлі тощо. На наступному етапі інтегруються кліматичні та гідрографічні дані, а також цифрова модель рельєфу (ЦМР). Ці дані використовуються для побудови бази геоданих, яка включає інформацію про опади, гідрологічні умови, типи ґрунтів та рослинність на досліджуваній території. Застосування цифрової моделі рельєфу дозволяє враховувати висотні характеристики місцевості, що є критично важливим для точного моделювання водних потоків та зон затоплення. Для обробки та аналізу цих даних застосовуються методи машинного навчання, зокрема трансферне навчання, що дає змогу підвищити точність моделювання зон затоплення. За допомогою гідрологічної моделі розраховуються екстремальні гідрологічні параметри на основі кліматичних та гідрографічних даних, таких як інтенсивність опадів, тип ґрунту, умови землекористування та рослинний покрив. Ці параметри дозволяють створити криву ґрунтового номера та гідрограф, які відображають поведінку водного стоку на території. Наступним кроком є застосування гідравлічної моделі для визначення параметрів потоку, зокрема швидкості течії, глибини води та прогнозування зон потенційного затоплення. Моделювання затоплення базується на імplementації цифрової моделі рельєфу у форматі ASCII-сітки з розміром 30 м. Ця сітка імпортується в геоінформаційну систему (ГІС) QGIS для проведення розрахунків та моделювання зон затоплення. Завершальним етапом є створення карти зон небезпеки затоплення. Ця карта дозволяє ефективно візуалізувати потенційно небезпечні території, що є важливим інструментом для прийняття рішень у управлінні ризиками повеней та розробці заходів щодо захисту територій від затоплень.

Наукова новизна отриманих у роботі результатів полягає у застосуванні трансферного навчання для виявлення затоплених територій на основі супутникових знімків. Модифіковано архітектуру нейронної мережі шляхом додавання конволюційних шарів для підвищення точності виділення суттєвих ознак та використання максимального підсумовування для зменшення обчислювальної складності. Крім того, впроваджено щільний і згладжувальний шари для покращення стабільності навчання та запобігання пере-навчанням. Запропонований підхід дозволяє покращити ефективність прогнозування зон затоплення, підвищити точність класифікації та забезпечити вищий рівень автоматизації аналізу супутникових даних для управління природними ризиками.

Висновки. Дослідження було проведено для оцінки впливу потужної системи повільних штормів, що обрушилася на Об'єднані Арабські Емірати у квітні 2024 року, спричинивши значні опади і раптові повені. Для аналізу використано супутникові знімки Landsat-8, отримані до і після повені. Ці знімки були оброблені для отримання бінарних масок, а потім класифіковані на два основні класи: водні об'єкти та земна поверхня. Результати класифікації продемонстрували значне розширення затоплених територій після повені, що дозволило наочно відобразити масштаби та розподіл води. Метрики ефективності моделі, такі як точність, повнота та F1-міра, свідчать про високу точність у виявленні затоплених зон. Зокрема, точність моделі на навчальній вибірці склала 0.88, а на валідаційній – 0.87. Клас затоплених територій (FL) продемонстрував точність 0.91, що перевищує показники для класу інших територій (FV). Аналіз розподілу затоплення з використанням кроку 0,25 метра виявив, що затоплення є нерівномірним і значною мірою залежить від рельєфу місцевості. Найбільш вразливими до затоплення виявилися низько розташовані частини району, де рівень води досягав до 2 метрів.

Ключові слова: зона затоплення, згорткові нейронні мережі, класифікація зображень, моделювання, супутникові дані.

Denys IVANOV

Assistant at the Department of Information Technology and Computer Engineering, Dnipro University of Technology, 19, Dmytra Yavornytskoho Ave., Dnipro, Ukraine, 49005, ivanov.d.v@nmu.one

ORCID: 0000-0001-8660-0928

Scopus-Author ID: 58047075900

Vita KASHTAN

Candidate of Technical Science, Associate Professor, Associate Professor at the Department of Information Technology and Computer Engineering, Dnipro University of Technology, 19, Dmytra Yavornytskoho Ave., Dnipro, Ukraine, 49005, kashtan.v.yu@nmu.one

ORCID: 0000-0002-0395-5895

Scopus-Author ID: 57201902879

To cite this article: Ivanov, D., Kashtan, V. (2024). Heoinformatsiina tekhnolohiia vyivlennia ta modeliuvannia zatoplenykh zon mista Dubai na osnovi zghortkovoi neuronnoi merezhi [Geoinformation technology for detecting and modeling flooded areas of Dubai based on convolutional neural network]. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 4, 99–113, doi: <https://doi.org/10.32782/IT/2024-4-13>

GEOINFORMATION TECHNOLOGY FOR DETECTING AND MODELING FLOODED AREAS OF DUBAI BASED ON CONVOLUTIONAL NEURAL NETWORK

Detecting flooded areas is essential for effective disaster response and management, as it allows for the creation of early warning systems and the organization of targeted assistance.

The purpose of the work is to develop geographic information technology for detecting and modeling flooded areas in Dubai based on convolutional neural networks.

Methodology. The geoinformation technology of the study consists of several stages that provide a comprehensive approach to the analysis and modeling of flooding. First, satellite images are downloaded and pre-processed. This includes correction of atmospheric distortions, color alignment, and geometric distortions. After that, the images are converted into a vector format to facilitate their further processing and analysis. Vectorization allows you to more accurately identify key elements in the images, such as rivers, roads, buildings, etc. The next step is to integrate climatic and hydrographic data, as well as a digital elevation model (DEM). This data is used to build a geodatabase that includes information on precipitation, hydrological conditions, soil types, and vegetation in the study area. Using a digital elevation model allows us to take into account the altitude characteristics of the terrain, which is critical for accurate modeling of water flows and flood zones. Machine learning methods, such as transfer learning, are used to process and analyze this data, which makes it possible to improve the accuracy of flood zone modeling. The hydrological model calculates extreme hydrological parameters based on climatic and hydrographic data, such as precipitation, soil type, land use, and vegetation cover. These parameters allow for the creation of a soil number curve and hydrograph that reflect the behavior of water runoff in the area. The next step is to apply a hydraulic model to determine flow parameters, such as flow velocity, and water depth, and predict areas of potential flooding. Flooding modeling is based on the implementation of a digital elevation model in ASCII grid format with a size of 30 meters. This grid is imported into the geographic information system (GIS) QGIS to perform calculations and modeling of flood zones. The final step is to create a map of flood hazard zones. This map allows for effective visualization of potentially hazardous areas, which is

an important tool for decision-making in flood risk management and the development of measures to protect areas from flooding.

The scientific novelty of the results obtained in this work consists of the application of transfer learning to detect flooded areas based on satellite images. The architecture of the neural network was modified by adding convolutional layers to improve the accuracy of extracting significant features and using maximum summation to reduce computational complexity. In addition, dense and smoothing layers were introduced to improve training stability and prevent overfitting. The proposed approach has improved the efficiency of flood zone forecasting, increased classification accuracy, and provided a higher level of automation of satellite data analysis for natural risk management.

Conclusions. The study assessed the impact of slow-moving storms that hit the United Arab Emirates in April 2024, causing significant rainfall and flash flooding. The analysis utilized Landsat-8 satellite images acquired before and after the flood. These images were processed to obtain binary masks and then categorized into two main classes: water bodies and land surfaces. The classification results demonstrated a significant expansion of the flooded areas after the flood, which allowed for a visual representation of the extent and distribution of water. The model performance metrics, such as accuracy, completeness, and F1-measure, indicate high accuracy in detecting flooded areas. In particular, the model's accuracy on the training sample was 0.88, and on the validation sample – 0.87. The flooded areas (FL) class demonstrated an accuracy of 0.91, which is higher than the class of other areas (FV). Analysis of the flood distribution using a 0.25-meter step revealed that flooding is uneven and largely depends on the terrain. The most vulnerable to flooding were low-lying parts of the district, where the water level reached up to 2 meters.

Key words: flood zone, convolutional neural networks, image classification, modeling, satellite data.

Вступ. Повені представляють серйозну глобальну проблему, що становить значну загрозу для громад у всьому світі, викликаючи суттєві соціально-економічні та екологічні наслідки (Deolfa Jose Moises, 2023). Вчасне і точне виявлення та моніторинг повеней мають першорядне значення для ефективного реагування на стихійні лиха. Це дозволяє створювати системи раннього попередження, планувати евакуацію, розподіляти ресурси та цілеспрямовано надавати допомогу постраждалим. Тому, впровадження технологій автоматичного дистанційного зондування є важливим для забезпечення безпеки і добробуту суспільства.

Супутникові знімки стали цінним ресурсом для моніторингу повеней завдяки широкому діапазону зйомки, високій просторовій роздільній здатності, тощо. Проте, величезний обсяг даних і складна природа паводків вимагають передових обчислювальних методів для точного та ефективного аналізу. Картування міських повеней є складним завданням (Hsiao S.C., 2021). По-перше, міське середовище є дуже складним, з великою кількістю водних шляхів, які можуть бути надзвичайно вузькими, інколи менше метра в ширину. По-друге, затоплення у міських районах часто буває неглибоким і тимчасовим, що ускладнює його виявлення і моніторинг. По-третє, наявність ставків та інших водних об'єктів у містах означає, що масштаби затоплення можуть бути непередбачуваними і постійно змінюватися. Традиційні гідрологічні моделі, що використовуються для прогнозування повеней, не завжди можуть ефективно впоратися з цими факторами. Було зроблено багато спроб скласти карту міських повеней

і ризиків затоплення за допомогою традиційних методів. Гідрологічні моделі високої роздільної здатності є ефективними в невеликих масштабах, таких як кілька міських кварталів, але обчислювальні ресурси та високоточні вхідні дані, необхідні для належного моделювання міських повеней у масштабі громади, не є широко доступними з поточною технологією. Вищеописані обмеження демонструють необхідність пошуку методів картографування або прогнозування повеней, які є менш обчислювально інтенсивними.

Перевагою дистанційного зондування є можливість виявлення повеней для великомасштабного картографування без потреби у високоточних вхідних даних і інтенсивних обчислювальних процесах, що покращує управління ризиками повеней. У той час як екстремальні повені, особливо ті, що підпадають під категорію 100-річних подій, добре вивчені та детально нанесені на карту в літературі, незначні повені важко нанести на карту та передбачити. Це менш серйозне затоплення, відоме як неприємне затоплення (nuisance flooding, NF), становить меншу небезпеку для життя та майна, але все ще може бути незручним або навіть небезпечним, особливо для водіїв. У цій статті представлено новий підхід на основі глибокого навчання для виявлення повеней на супутникових знімках. Використовуючи сильні сторони цих технологій, запропонована методологія спрямована на розробку точної та надійної моделі виявлення повеней.

Літературний огляд. Контрольовані методи класифікації часто використовуються для задач бінарної або багатовимірної класифікації. Ці

методи, такі як класифікатор K-Nearest Neighbor (K-NN) (Shahabi H., 2020), класифікатор Random Forest (RF) і опорна векторна машина (SVM) (Tavus, B., 2021), були застосовані до зображень Sentinel-1 SAR для виявлення повеней. Штучні нейронні мережі (ШНМ), наприклад, є популярною технікою машинного навчання, яка використовується в супутниковому дистанційному зондуванні та обробці зображень і демонструє великий потенціал для виявлення повеней із супутникових зображень дистанційного зондування. Методи ШНМ успішно застосовувалися для процесів виявлення затоплення, проте ще існує багато невирішених проблем (A. Emily Jenifer, 2022).

Крім того, розроблено системи на основі машинного навчання для виявлення змін між сухими зображеннями та зображеннями повеней, що дозволяє маскувати водойми та нормальний рівень води в озерах і річках. Для виявлення змін (Change Detection) (Li Y., 2018) необхідні принаймні два зображення: контрольне зображення (перед подією) та цільове зображення (під час події) з того самого супутника, орбітальної траєкторії, поляризації та покриття. Визначення порогу між водяними та неводними пікселями за зображеннями зворотного розсіювання Sentinel-1 SAR є критично важливим кроком для виявлення затоплених місць. Для оцінки порогового значення та необхідності відрізнити затоплені території від інших наземних покривів зазвичай використовується метод порогового визначення Оцу (Chawla I., 2020).

У підходах до виявлення змін, де необхідна система нечіткої класифікації, класичні показники текстури спільного входження, змішані з інформацією про амплітуду, можуть використовуватися для визначення порогового значення. Однак у реальних додатках і через дефіцит наземних правдивих даних для швидкого картографування повеней краще використовувати неконтрольовані методи виявлення змін. Алгоритми неконтрольованого машинного навчання є більш надійними завдяки вищій швидкості, меншим вимогам до навчальних даних і часу виконання обчислень, що забезпечує кращу ефективність обчислень (Сао Н., 2019).

Неконтрольовані методи виявлення змін використовуються для автоматичного визначення змін у зображеннях без попереднього навчання на мічених даних. Це робить їх особливо цінними в умовах, коли швидкість та ефективність обробки є критичними, а доступ до наземних даних обмежений. Такі методи дозволяють оперативно реагувати на ситуації

надзвичайного стану, такі як повені, і забезпечують точне картографування затоплених територій.

В роботі (Wu X., 2023) підкреслюється критична важливість виявлення повеней в режимі, близькому до реального часу, з акцентом на використанні методів глибокого навчання для збору даних з 16 паводків у басейні річки Янцзи. Це дослідження представляє ефективні методи створення наборів даних, пристосованих для навчання, тестування та застосування. Зокрема, дослідження показує, що згорткові нейронні мережі (CNN) перевершують традиційні методи виявлення повеней, підкреслюючи їх стійкість в умовах, близьких до реального часу.

У роботі (Abdirahman H., 2021) представлено нову та надійну систему виявлення повеней у реальному часі на основі методів машинного навчання та глибокого навчання, включаючи Random Forest, Naive Bayes, J48 та згорткові нейронні мережі. Ця система спрямована на виявлення підвищення рівня води та прогнозування потенційних повеней з гуманітарними наслідками до того, як вони відбудуться. Це дослідження робить внесок у галузі штучного інтелекту, інтелектуального аналізу даних та глибокого навчання, впроваджуючи інноваційний підхід до запобігання повеней за допомогою Arduino з GSM-модемами.

Робота (A. Emily J., 2022) зосереджена на точній ідентифікації затоплених територій за допомогою використання повністю згорткової мережі (FCN) на основі подвійних патчів, яка використовує злиття ознак на основі глибокого навчання. FCN незалежно навчаються на радарних із синтезованою апертурою (SAR) і мульти-спектральних (MS) зображеннях, що дозволяє їм фіксувати відмінні риси, які згодом комбінуються для покращення можливостей виявлення повеней.

У роботі (Kashif A., 2019) представлено виявлення повеней на основі часових послідовностей супутникових знімків. Вони використовують комбінацію підходів класичного комп'ютерного зору і машинного навчання. Їхні результати підкреслюють ефективність їхніх методів у вирішенні проблем, пов'язаних із завданням MediaEval, і роблять внесок у ширшу сферу аналізу катастрофічних подій і використання супутникових даних.

Існуючі методи виявлення та картографування повеней мають ряд обмежень. Контрольовані методи, такі як K-NN, RF та SVM, залежать від наявності великої кількості мічених даних для навчання, що може бути проблематичним у реальних умовах. Методи глибокого навчання,

такі як CNN та FCN, хоч і демонструють високу точність, потребують значних обчислювальних ресурсів і можуть бути повільними при обробці великих обсягів даних у режимі реального часу. Неконтрольовані методи виявлення змін, хоча і є більш надійними та швидкими, можуть бути менш точними через відсутність попереднього навчання на мічених даних. Це може призводити до високої частоти хибнопозитивних або хибнонегативних виявлень. Крім того, велика різноманітність міських середовищ, різні типи затоплень та неоднорідність даних ускладнюють розробку універсальних моделей для виявлення повеней. Обмежена доступність даних з високою просторовою та часовою роздільною здатністю також є важливою перешкодою для точного і своєчасного моніторингу повеней.

Мета дослідження: розробка геоінформаційної технології для виявлення та моделювання затоплених зон у Дубаї на основі згорткових нейронних мереж (CNN). Це дозволить підвищити точність класифікації затоплених територій і покращити управління ризиками та відновлювальними роботами.

Виклад основного матеріалу. Загальна структура запропонованої геоінформаційної технології представлена на рисунку 1 і включає наступні етапи: завантаження супутникових знімків, векторизація первинних даних, інтеграція кліматичних та гідрографічних даних, розробка бази геоданих, створення карти досліджуваної території, застосування методів машинного навчання, моделювання затоплення та отримання карти зон небезпеки затоплення.

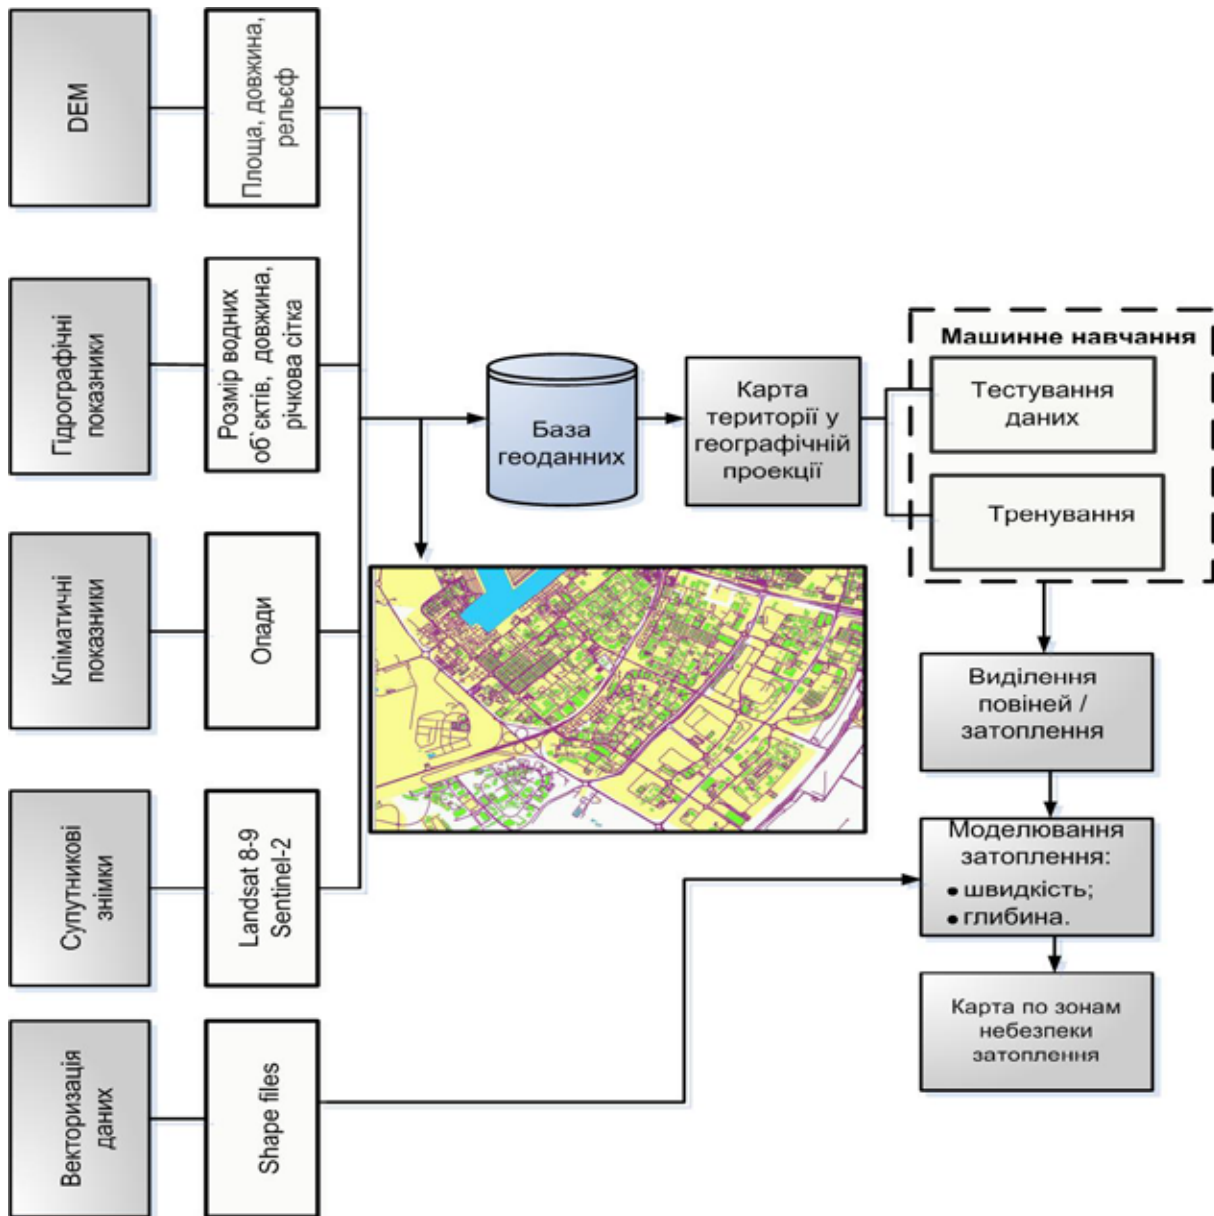


Рис. 1. Схема запропонованої геоінформаційної технології

З платформи Copernicus Open Access Hub завантажуються оптичні знімки з супутників Sentinel-2 або Landsat-8,9. Після завантаження зображень виконується ряд попередніх обробок, включаючи радіометричну та атмосферну корекції. Ці корекції спрямовані на усунення різноманітних спотворень, таких як вплив атмосфери, сонячне освітлення та інші фактори, що можуть виникати під час зйомки та передачі зображень з космосу. Радіометрична корекція забезпечує відповідність даних реальним фізичним величинам, що досягається шляхом перетворення цифрових значень (DN) пікселів у значення відбивної здатності. Це включає корекцію впливу сенсора та калібрування інструменту:

$$\text{Відбивна здатність} = \frac{L_{\text{TOA}}}{E_{\text{sun}} \cdot \cos(\theta) \cdot d^2} \quad (1)$$

де L_{TOA} – радіометрична яскравість на вершині атмосфери; E_{sun} – спектральна сонячна константа; θ – зенітний кут сонця; d – відстань між Землею і Сонцем в астрономічних одиницях.

Атмосферна корекція усуває ефекти розсіювання та поглинання світла в атмосфері, що значно покращує якість зображень для подальшого аналізу.

В роботі запропоновано використати метод Dark Object Subtraction (DOS), що базується на припущенні, що найтемніші об'єкти в зображенні (зазвичай вода або тінь) мають нульову відбивну здатність, і будь-яке значення, відмінне від нуля, є результатом атмосферного розсіювання:

$$\text{Відкориговане значення} = DN - DN_{\text{min}}, \quad (2)$$

де DN_{min} – мінімальне значення DN у зображенні.

Після завантаження та попередньої обробки супутникових знімків здійснюється їх перетворення у векторний формат для полегшення подальшої обробки. Векторизація – це процес перетворення растрових зображень (пікселів) у векторні дані (геометричні форми, такі як точки, лінії та полігони). Цей етап дозволяє більш ефективно працювати з даними, забезпечуючи кращу інтеграцію з іншими геопросторовими даними та зменшуючи обсяг даних. Векторизація супутникових знімків включає кілька ключових етапів. Спочатку зображення сегментуються для визначення різних об'єктів на основі їхніх спектральних характеристик. Після сегментації виділяються контури об'єктів, які згодом будуть перетворені у векторні форми. Контури об'єктів перетворюються у точки, лінії

та полігони, що формують векторні шари. Для цього використовуються алгоритми, такі як алгоритм Дугласа-Пекера для спрощення ліній та полігонів.

Наступним етапом є завантаження кліматичних показників, включають дані про опади, температуру, вологість, швидкість вітру та інші кліматичні фактори, які можуть впливати на ймовірність та масштаб повеней. Ці дані зазвичай отримуються з метеорологічних станцій або кліматичних моделей. Для дослідження в регіоні Дубай обрані дані з чотирьох метеорологічних станцій, які значною мірою сприяють аналізу затоплень у цьому регіоні. Вони включають станції Дубай, Шарджа, Аль-Айн і Джебель-Алі, оскільки дані про кількість опадів з цих станцій є критичними для моделювання повеней у регіоні.

Гідрографічні показники включають інформацію про річки, озера, водосховища та інші водні об'єкти. Вони містять дані про рівень води, швидкість течії, об'єм води та інші характеристики, що впливають на динаміку затоплень. Цифрова модель рельєфу (DEM) є ключовим компонентом для аналізу та моделювання повеней. DEM представляє собою тривимірну цифрову модель поверхні Землі, яка включає висоти на певній площі. Ця модель використовується для розрахунків потоків води та визначення зон можливого затоплення. DEM завантажується з відповідних джерел, таких як USGS або платформи, що надають дані LIDAR. Обробка DEM включає згладжування даних, виправлення помилок та заповнення прогалів для забезпечення точного представлення рельєфу. Аналіз рельєфу використовується для розрахунку нахилів, напрямків стоку та інших характеристик, важливих для моделювання водного потоку та зон затоплення. Усі значення висоти в цій моделі зберігаються в метрах відносно геоїда WGS84 EGM96. Цей геоїд базується на еліпсоїді WGS84, а коефіцієнти обчислюються на основі глобальної бази даних 30-хвилинних середніх вільних гравітаційних аномалій, а також на даних, отриманих з супутників і безпосередньої альтиметрії (вимірювання висоти).

Після виконання векторизації супутникових знімків та інтеграції кліматичних, гідрографічних даних і DEM, система готова до подальшого аналізу та моделювання. Ці етапи потрібні для точного визначення зон затоплення та розробки карт небезпеки, що є важливими для ефективного управління ризиками повеней.

Створення бази геоданих. Спочатку підготовлюються векторні шейп-файли та растрові

зображення, які є основою для подальшого аналізу. Визначаються таблиці та поля для зберігання інформації, встановлюється структура бази геоданих (БГД), яка забезпечить цілісність та ефективність зберігання даних. База геоданих створюється в середовищі QGIS, де імпортуються вихідні дані з відповідних джерел. Цей етап включає імпорт векторних та растрових даних у визначену структуру бази. Для забезпечення цілісності даних встановлюються зв'язки між таблицями, що дозволяє зберігати логічні відносини між різними наборами даних. Використовуючи інструменти QGIS, проводиться редагування та внесення змін у дані. На цьому етапі застосовується алгоритм дерева рішень, частина процесу машинного навчання, для аналізу зв'язків між описовими ознаками та цільовими мітками для безперервних даних. Алгоритм дерева рішень використовує методи визначення змінних та значень поділу за допомогою домішок, що генеруються в кожному вузлі. Після створення БГД дані оптимізуються та індексуються для підвищення продуктивності та швидкості доступу до них.

Класифікація під контролем є поширеним методом для вилучення інформації із зображень, що включає два основних етапи: навчання та класифікацію. На етапі навчання для кожного класу вибирається набір репрезентативних зразків, який служить основою для навчання моделі класифікації. На етапі класифікації використовуються навчені моделі для оцінки ймовірності того, що кожен піксель зображення належить до одного з класів. Пікселі класифікуються відповідно до класу, що має найбільшу ймовірність, визначену класифікатором. Класифікація застосовується до зображень з використанням трьох класів: водні об'єкти, затоплені території та інші. Клас водних об'єктів представляє постійні водні площі в обох наборах даних. Для всіх трьох методів класифікації використовується однакова навчальна вибірка. У численних

дослідженнях були застосовані різні моделі згорткових нейронних мереж (CNN), такі як ResNet50, VGG16, InceptionV3 тощо (Wu X., Abdirahman H., A. Emily J., Kashif A.), які показали значні результати у різних сферах. У цій роботі використовується підхід трансферного навчання, де попередньо навчені моделі застосовуються для виявлення повеней. Модифіковано архітектуру моделей, додавши кілька конволюційних шарів для виділення суттєвих ознак місцевості та максимальне підсумовування для зменшення розмірності просторових даних. У другій гілці мережі застосовується щільний шар для інтеграції ознак та згладжувальний шар для підвищення стабільності навчання. Останній шар використовує максимальне підсумовування для збереження ключових ознак з подальшим переходом до щільного шару. Процес навчання моделі виконується з використанням оптимізатора Adam та бінарної втрати перехресної ентропії для мінімізації похибок. Ефективність оцінюється шляхом вимірювання показників точності на валідаційних даних, як відображено на Рисунку 2. Процес навчання моделі включає використання скомпільованого набору даних з оптимізатором Adam та бінарною втратою перехресної ентропії як цільовою функцією. Навчання проводиться шляхом ітерацій через кілька епох, де відбувається безперервне оновлення вагових коефіцієнтів моделі з метою мінімізації втрат і підвищення точності. Ефективність моделі оцінюється на валідаційному наборі даних шляхом вимірювання таких показників, як точність і втрати.

Вхідний шар приймає зображення розміру:

$$H \times W \times C, \quad (3)$$

де H – висота, W – ширина, C – кількість каналів.

Конволюційний шар застосовує фільтри для виділення ознак:

$$Y_{i,j,k} = \sum_{m,n} X_{i+m,j+n} \cdot W_{m,n,k} + b_k, \quad (4)$$

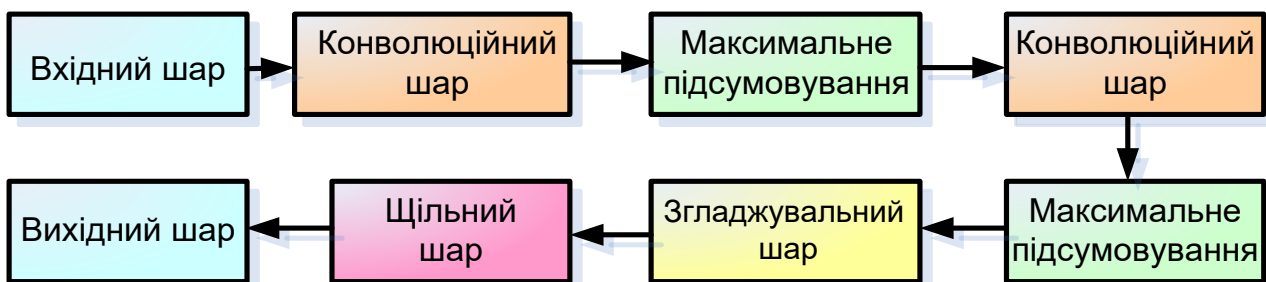


Рис. 2. CNN архітектура

де X – вхідні дані, W – ваги фільтрів, b – зсув, Y – вихідні ознаки.

Максимальне підсумовування зменшує розмірність карт ознак

$$Y_{i,j,k} = \max_{m,n} X_{s(i,m),s(j,n),k}, \quad (5)$$

де s – розмір вікна підсумовування.

Згладжувальний шар перетворює багатовимірні дані в одновимірний вектор.

Щільний шар використовує функцію активації для навчання:

$$Y_i = f\left(\sum_j W_{ij} \cdot X_j + b_i\right), \quad (6)$$

де f – функція активації, наприклад, ReLU або сигмоїдна функція.

Моделювання затоплення є ключовим етапом в оцінці та прогнозуванні потенційних зон затоплення. Воно включає використання як гідрологічних, так і гідравлічних моделей для детального аналізу обсягів водного стоку та умов течії потоку, що допомагає у визначенні зон потенційного затоплення. На першому етапі використовуються гідрологічні моделі для оцінки обсягів річкового стоку, що генерується під впливом екстремальних погодних подій або комбінацій різних серій подій у часі. Гідрологічна модель обчислює екстремальні значення, враховуючи дані про опади, топографію, тип ґрунту та умови землекористування, такі як рослинний покрив. Це дозволяє створити криву ґрунтового номера і гідрограф, які відображають поведінку водного стоку на території. Наступний етап передбачає використання гідравлічної моделі для розрахунку умов течії потоку, зокрема швидкості потоку, глибини води та розміру потенційного затоплення. Моделювання затоплення починається з імплементації цифрової моделі рельєфу (ЦМР) у форматі файлу сітки ASCII. Цей файл імплементується у геоінформаційну систему QGIS для подальшої обробки. Обчислення сітки виконуються на основі ASCII файлу, при цьому розмір сітки визначається на рівні 30 м. Розмір сітки обирається за формулою:

$$0.3m / c \leq \frac{Q_{\max}}{A_{\text{elem}}} \leq 3 \text{ м/с} \quad (7)$$

де Q_{\max} – максимальний стік, розрахований для елемента сітки, A_{elem} – площа елемента сітки. Інтерполяція сітки забезпечує визначення репрезентативної висоти кожного елемента.

Для моделювання небезпеки затоплення використовуються кумулятивні значення періодів повернення (10, 30, 50, 100 і 300 років) кліматичного та гідрологічного моделювання. Результати моделювання, такі як максимальна

глибина потоку та максимальна швидкість потоку, обробляються у програмному забезпеченні QGIS.

Для оцінки небезпеки затоплення карти класифікуються на зони високого, середнього та низького ризику, використовуючи критерії Гарсії та Лопеса. Зони визначаються за глибиною води h :

$$v \cdot h, \quad (8)$$

де v – швидкість потоку.

Наприклад, зона $h > 1,5$ м і $v \cdot h > 1,5$ м/с класифікується як зона високої небезпеки. Зони з $0,5 < h < 1,5$ м і $v \cdot h < 1,5$ м/с класифікуються як зона середньої небезпеки. Зони з $0,1 < h < 0,5$ м і $v \cdot h < 0,5$ м/с вважаються зонами низького рівня небезпеки. Результати класифікації відображаються на картах із кольоровою індикацією рівня небезпеки: червоний для високого рівня, жовтий для середнього та зелений для низького рівня.

Експерименти. Об'єднані Арабські Емірати (ОАЕ) є державою, розташованою на Аравійському півострові, відомою своїм сухим пустельним кліматом. У квітні 2024 року ця країна зазнала впливу потужної системи повільних штормів, що призвела до значних опадів, які перевищили річну норму за кілька днів. Це викликало раптові повені в східних регіонах країни, що спричинило затоплення доріг та порушення транспортної інфраструктури. Для аналізу впливу повені на регіон було використано супутникові знімки Landsat-8, отримані до (рис. 3 а) та після (рис. 3 б) повені. Знімки до повені, зроблені на початку квітня 2024 року, використовувались для визначення базового стану території. Після завершення штормів, знімки, отримані 19 квітня 2024 року, дозволили оцінити масштаби затоплення та його вплив на інфраструктуру.

Для подальшого аналізу впливу повені на регіон було застосовано модель згорткових нейронних мереж (CNN). Спочатку для отримання бінарних масок (рис. 4) було проведено класифікацію пікселів, де водні об'єкти були позначені як 1, а суша – як 0. Це дозволило створити бінарні маски, які наочно відображають присутність водних об'єктів на супутникових знімках.

Після отримання бінарних масок було створено знімки з чіткою класифікацією територій як суші або води. На цих знімках водні об'єкти були виділені червоним кольором, що дозволяє візуально ідентифікувати контури затоплених зон. Це дає змогу легко порівняти зміни між зображеннями до і після повені, особливо в областях,



а)



б)

Рис. 3. Супутникові знімки космічного апарату Landsat 8-9 синтезовані у R-G-B канали: а) 18.03.2024 року; б) 19.04.2024 року

що зазнали затоплення. Зміни між зображеннями до і після повені стали очевидними, особливо в областях, що зазнали затоплення. Це наочно демонструє масштаби і розподіл води після повені, що є важливим для планування відновлювальних заходів та управління територіями. На зображеннях після обробки машинного навчання (рис. 5) чітко видно зміну класів у затоплених районах, що підтверджує ефективність застосованої методики класифікації.

Для оцінки продуктивності моделі класифікації у даному дослідженні були використані комбінація категоріальної перехресної ентропії та індексу Дісе як функція втрат, а також метод Адама як оптимізатор. Метрика точності, яка була застосована для оцінки результатів моделювання, є F1-score, що дозволяє комплексно оцінити ефективність моделі в умовах дисбалансу класів. Точність визначається як відношення кількості правильно класифікованих позитивних зразків до загальної кількості класифікованих як позитивні, а повнота – як

відношення кількості правильно класифікованих позитивних зразків до загальної кількості позитивних зразків у даних.

Точність:

$$\text{Точність} = \frac{TP}{TP + FP} \quad (8)$$

де TP – кількість правильних позитивних прогнозів, FP – кількість хибних позитивних прогнозів.

Повнота:

$$\text{Повнота} = \frac{TN}{TN + FN} \quad (9)$$

де FN – кількість хибних негативних прогнозів.


F1 Score:

$$F1 = \frac{2 \cdot \text{Точність} \cdot \text{Повнота}}{\text{Точність} + \text{Повнота}} \quad (10)$$


Результати. У таблиці 1 представлені результати роботи моделі, отримані на навчальній та валідаційній вибірках. Дані показують, що



Рис. 4. Бінарна маска супутникового знімка 19.04.2024 року



а)



б)

Рис. 5. Неймережева класифікація супутникового знімку Landsat 8-9: а) до повені 18.03.2024 року; б) після повені 19.04.2024 року

результати тестування на валідаційних даних та на тестових даних є подібними, що свідчить про стабільність моделі.

Таблиця 1
Результати роботи моделі на навчальній та валідаційній вибірках

Вибірка	Точність	Повнота	Повнота
Навчальна	0.88	0.85	0.86
Валідаційна	0.87	0.84	0.85

Таблиця 2 демонструє оцінку F1 для кожного класу, розраховану на основі прогнозів моделі, отриманих з тестових даних. Результати вказують на те, що модель демонструє високу точність у класифікації класу водних об'єктів (FL) порівняно з класом земної поверхні (FV). Клас FL, що представляє затоплені території, передбачений з вищою точністю, ніж клас FV.

Таблиця 2
Оцінка F1 для кожного класу на основі тестових даних

Клас	Точність	Повнота	F1
FL	0.91	0.89	0.90
FV	0.84	0.78	0.81

У процесі дослідження було побудовано кілька графіків, які наочно демонструють інтенсивність опадів у Дубаї під час шторму. На рис. 6 представлено результат у вигляді графіка з використанням сітки даних з координатами, що охоплюють Дубай та прилеглі території.

Інтенсивність опадів була відображена методом контурної заливки, що дозволяє детально показати зміни в кількості опадів. Кольорова шкала показує величину опадів у кожній точці, де більш інтенсивні опади позначені темнішими відтінками синього. Графік дозволяє візуально оцінити розподіл опадів по всій території Дубаю та визначити області з найбільш інтенсивними опадами.

Рисунок 7а показує площі затоплення за період з 15 квітня по 19 квітня 2024 року. З графіка видно, що площа затоплення поступово збільшувалась з 10.2 гектарів 15 квітня до 42.61 гектарів 19 квітня. Це відображає наростаючий ефект шторму, що супроводжувався інтенсивними опадами, які викликали значні затоплення. Кругова діаграма на рис. 7 б допомагає зрозуміти масштаб затоплення в порівнянні з іншими територіями, вказуючи на суттєву частку затоплених земель.

На рис. 8 значна частина території Дубаї (райони: Nasyan 1, Nasyan 2, Jebel Ali, Palm та Jebel Ali) затоплена водою глибиною від 1.75 до 2 метрів, що позначено чорними крапками. Це вказує на серйозний вплив затоплення на ці райони. Інші кольори вказують на поступове зменшення рівня води в різних частинах території. Зображення також показує інші рівні затоплення, розподілені по різних ділянках: рожеві ділянки (1.5 – 1.75 метра) займають меншу площу порівняно з червоними; жовті, світло-зелені, зелені, бірюзові та блакитні ділянки позначають райони, в яких поступово зменшується рівень затоплення.

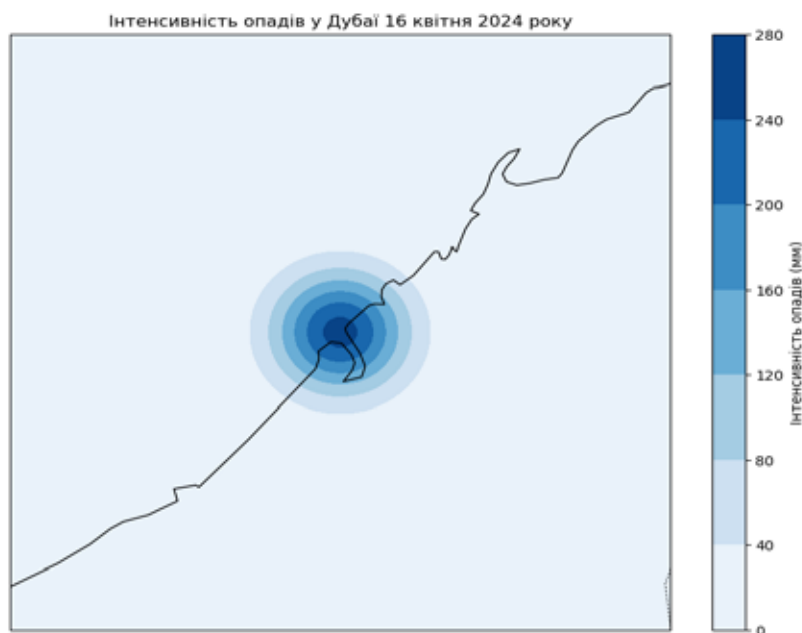


Рис. 6. Графік інтенсивності опадів в Дубаї

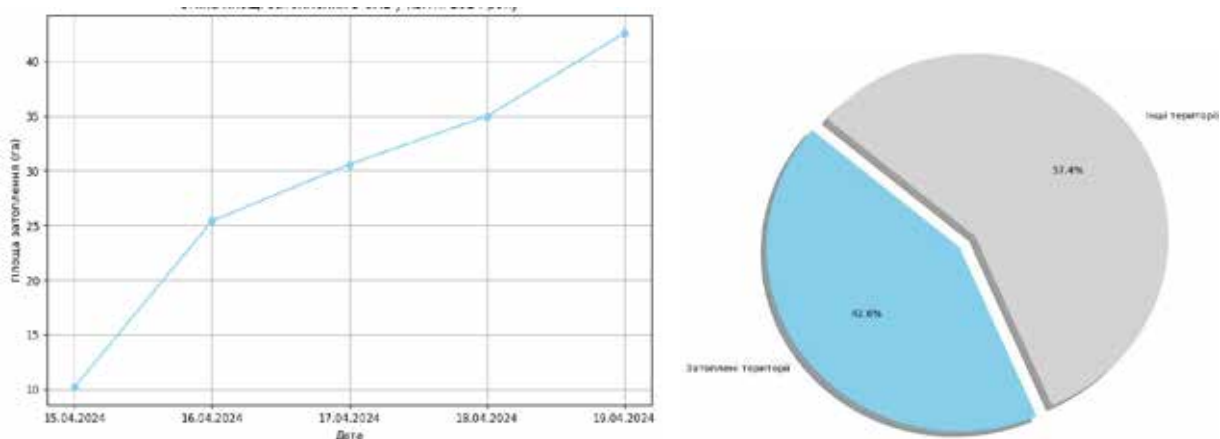


Рис. 7. Зміни площі затоплення в Дубаї: а) графік в період з 15.04.2024 року по 20.04.2024 року; б) діаграма співвідношення площі затоплених та інших територій

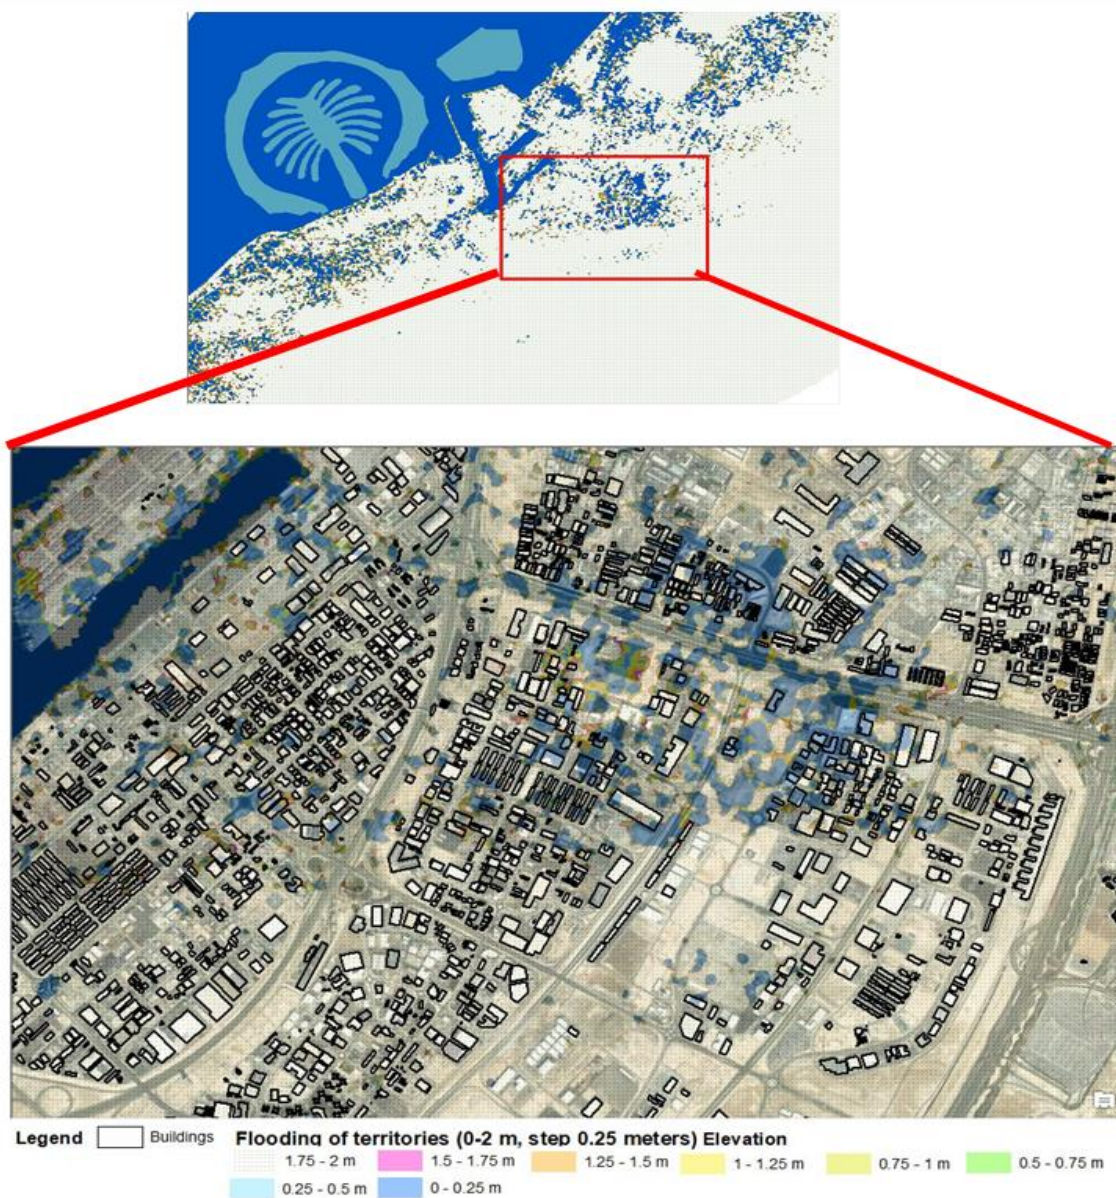


Рис. 8. Карта зон затоплення Дубаї

На рисунку 9 представлено вісім карт, що відображають зони затоплення району Jebel Ali Industrial 2. Карти демонструють глибину затоплення в діапазоні від 0 до 2 метрів з кроком 0,25 метра. Кожна карта відображає території, які будуть затоплені на певну глибину, що дозволяє здійснити детальний аналіз впливу поступового підвищення рівня води на цей район.

Загальний розподіл затоплення вказує на його нерівномірність, з більшою глибиною затоплення в північній і центральній частині району. Деякі території залишаються незатопленими або затопленими на незначну глибину, що вказує на різницю у висоті та особливостях рельєфу. Крок 0,25 метра, який використовується в даних картах, дозволяє детально

відобразити динаміку затоплення та зрозуміти, як поступове підвищення рівня води впливатиме на територію. Початковий етап затоплення (0 – 0,25 метра) охоплює обмежені території, переважно в низько розташованих частинах району. Зі збільшенням рівня води до 0,5 метра затоплені території розширюються, переважно вздовж річок і каналів. При підвищенні рівня води до 0,75 метра спостерігається значне розширення зон затоплення, особливо в низько розташованих районах. Коли глибина затоплення досягає 1 метра, затоплення охоплює ще більше територій, включаючи деякі забудовані райони. Подальше підвищення рівня води до 1,25 метра призводить до затоплення ще більших частин промислових зон.

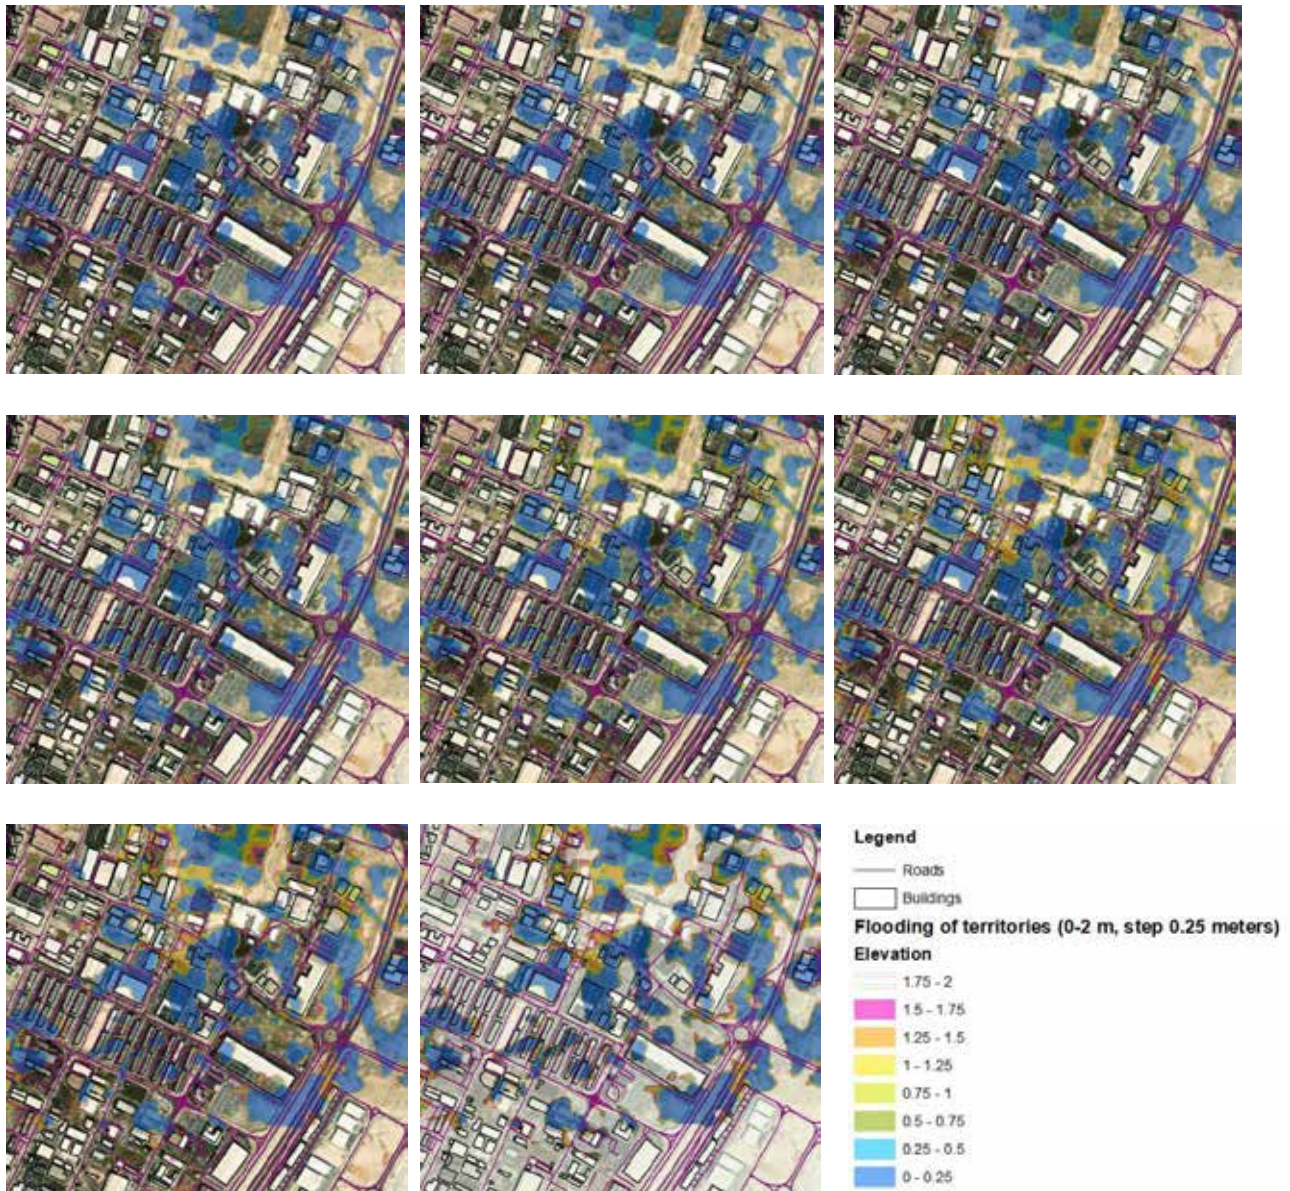


Рис. 9. Карта зон затоплення району Jebel Ali Industrial 2

При досягненні рівня води 1,5 метра затоплення поширюється на ще більші території. На глибині 1,75 метра спостерігається майже повне затоплення низькорозташованих частин району, а при максимальній глибині затоплення до 2 метрів охоплюються найнижчі території, з мінімальними залишками незатоплених зон. Виходячи з отриманих даних, райони з низькою абсолютною висотою є найбільш вразливими до затоплення, з максимальним затопленням до 2 метрів. Прогресивне затоплення з кроком 0,25 метра демонструє, як поступове підвищення рівня води впливає на територію, надаючи цінну інформацію для планування заходів щодо захисту та адаптації. Для районів з глибиною затоплення понад 1 метр слід розглянути додаткові захисні заходи, такі як будівництво дамб або підвищення рівня будівель. Отримані результати можуть бути використані для подальшого аналізу та розробки стратегій управління ризиками затоплення, а також для інформування громадськості та планування розвитку інфраструктури в районі Jebel Ali Industrial 2.

Висновки. Розроблено геоінформаційну технологію виявлення та моделювання затоплених зон Дубаю на основі згорткової нейронної мережі з використанням супутникових даних. Дослідження показало, що запропонований підхід ефективно виявляє та класифікує затоплені території, що підтверджується отриманими метриками точності та повноти.

Результати класифікації на навчальній та валідаційній вибірках продемонстрували високий рівень точності, повноти та F1-міри. На

навчальній вибірці модель досягла точності 0.88, повноти 0.85 та F1-міри 0.86. На валідаційній вибірці точність склала 0.87, повнота 0.84, а F1-міра – 0.85. Це свідчить про стабільність та надійність моделі при застосуванні до нових даних. Крім того, аналіз результатів по окремих класах показав, що модель краще справляється з виявленням класу FL (затоплені території), ніж класу FV (інші території). Точність для класу FL становить 0.91, повнота – 0.89, а F1-міра – 0.90. Для класу FV точність складає 0.84, повнота – 0.78, а F1-міра – 0.81. Це вказує на високу ефективність моделі для виявлення затоплених зон. Загальний розподіл затоплення показав нерівномірність затоплених зон, з більшою глибиною затоплення у північній і центральній частинах району. Аналіз з використанням кроку 0,25 метра дозволив детально відобразити динаміку затоплення, показуючи, як поступове підвищення рівня води впливатиме на територію. Початкові етапи затоплення охоплюють обмежені території, переважно в районах з низькою абсолютною висотою. Отримані результати надають цінну інформацію для планування заходів щодо захисту та адаптації, особливо для районів з глибиною затоплення понад 1 метр, де можуть знадобитися додаткові захисні заходи, такі як будівництво дамб або підвищення рівня будівель. Запропонована методика виявлення та моделювання затоплених зон може бути використана для подальшого аналізу, розробки стратегій управління ризиками затоплення, а також для інформування громадськості та планування розвитку інфраструктури.

ЛІТЕРАТУРА:

1. Deolfa Jose Moises, Olivia Kungum. Strengthening Namibia's Flood Early Warning System through a Critical Gap Analysis. *Sustainability*. 2023.15. 524.
2. Hsiao S. C., Chiang W. S., Jang J. H., Wu H. L. Lu, W. S. Chen, W. B. Wu Y. T. Flood risk influenced by the compound effect of storm surge and rainfall under climate change for low-lying coastal areas. *Sci. Total Environ*. 2021. 764. 144439.
3. Shahabi H., Shirzadi A., Ghaderi K., Omidvar E., Al-Ansari N., Clague J. J. Geertsema M., Khosravi K., Amini A., Bahrami S. et al. Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: Hybrid Intelligence of Bagging Ensemble Based on K-Nearest Neighbor Classifier. *Remote Sens*. 2020. 12. 266.
4. Tavus B., Kocaman S., Gokceoglu C. Flood damage assessment with Sentinel-1 and Sentinel-2 data after Sardoba dam break with GLCM features and Random Forest method. *Sci. Total Environ*. 2021. 816. 151585
5. Emily Jenifer A, Sudha N. DeepFlood: A deep learning based flood detection framework using feature-level fusion of multi-sensor remote sensing images. *Journal of Universal Computer Science*. 2022. Vol. 28. P. 329–343.
6. Li Y., Martinis S., Plank S., Ludwig R. An automatic change detection approach for rapid flood mapping in Sentinel-1 SAR data. *Int. J. Appl. Earth Obs. Geoinf*. 2018. 73. P.123–135.
7. Chawla I., Karthikeyan L., Mishra A.K. A review of remote sensing applications for water security: Quantity, quality, and extremes. *J. Hydrol*. 2020. 585. 124826.

8. Cao H., Zhang H., Wang C., Zhang B. Operational Flood Detection Using Sentinel-1 SAR Data over Large Areas. *Water*. 2019. 11. 786.
9. Wu X., Zhang Z., Xiong S., Zhang W., Tang J., Li Z., An B., Li R. A Near-Real-Time Flood Detection Method Based on Deep Learning and SAR Images. *Remote Sensing*. 2023. 15(8):2046.
10. Abdirahman H., Abdullahi A., Mohamed E., Siti H., Octavio R. R. A Real-Time Flood Detection System Based on Machine Learning Algorithms with Emphasis on Deep Learning. *International Journal of Engineering Trends and Technology*. 2021. 69. P.249–256.
11. A. Emily J., Sudha N. DeepFlood: A deep learning based flood detection framework using feature-level fusion of multi-sensor remote sensing images. *JUCS -Journal of Universal Computer Science*. 2022. 28(3). P. 329-343
12. Kashif A., Konstantin P., Mohib U., Michael R., Nicola Conci, Johannes L., Ala Al-F. Multi-Modal Machine Learning for Flood Detection in News, Social Media and Satellite Sequences. *Computer Vision and Pattern Recognition, MediaEval* 2019.

REFERENCES:

1. Deolfa Jose Moises and Olivia Kungum. (2023). Strengthening Namibia's Flood Early Warning System through a Critical Gap Analysis. *Sustainability*. 15. 524. [in English].
2. Hsiao, S. C., Chiang, W. S., Jang, J. H., Wu, H. L. Lu, W. S. Chen, W. B. Wu, Y. T. (2021). Flood risk influenced by the compound effect of storm surge and rainfall under climate change for low-lying coastal areas. *Sci. Total Environ*. 764. 144439. [in English].
3. Shahabi, H. Shirzadi, A., Ghaderi, K., Omidvar, E., Al-Ansari, N., Clague, J. J. Geertsema, M., Khosravi, K., Amini, A., Bahrami, S. et al. (2020). Flood Detection and Susceptibility Mapping Using Sentinel-1 Remote Sensing Data and a Machine Learning Approach: Hybrid Intelligence of Bagging Ensemble Based on K-Nearest Neighbor Classifier. *Remote Sens*. 12. 266. [in English].
4. Tavus, B., Kocaman, S., Gokceoglu, C. (2021). Flood damage assessment with Sentinel-1 and Sentinel-2 data after Sardoba dam break with GLCM features and Random Forest method. *Sci. Total Environ*. 816. 151585. [in English].
5. A. Emily Jenifer and Sudha Natarajan. (2022). DeepFlood: A deep learning based flood detection framework using feature-level fusion of multi-sensor remote sensing images. *Journal of Universal Computer Science*. Vol. 28. P. 329–343. [in English].
6. Li Y., Martinis S., Plank S., Ludwig R. (2018). An automatic change detection approach for rapid flood mapping in Sentinel-1 SAR data. *Int. J. Appl. Earth Obs. Geoinf*. 73. P.123–135. [in English].
7. Chawla, I., Karthikeyan, L., Mishra, A. K. (2020). A review of remote sensing applications for water security: Quantity, quality, and extremes. *J. Hydrol*. 585. 124826. [in English].
8. Cao, H., Zhang, H., Wang, C., Zhang, B. (2019). Operational Flood Detection Using Sentinel-1 SAR Data over Large Areas. *Water*. 11. 786. [in English].
9. Wu, X., Zhang, Z., Xiong, S., Zhang, W., Tang, J., Li, Z., An, B., Li, R. (2023). A Near-Real-Time Flood Detection Method Based on Deep Learning and SAR Images. *Remote Sensing*. 15(8):2046. [in English].
10. Abdirahman, H., Abdullahi, A., Mohamed, E., Siti, H., Octavio, R. R. (2021). A Real-Time Flood Detection System Based on Machine Learning Algorithms with Emphasis on Deep Learning. *International Journal of Engineering Trends and Technology*. 69. P.249–256. [in English].
11. A. Emily, J., Sudha, N. (2022). DeepFlood: A deep learning based flood detection framework using feature-level fusion of multi-sensor remote sensing images. *JUCS -Journal of Universal Computer Science*. 28(3). P. 329–343. [in English].
12. Kashif, A., Konstantin, P., Mohib, U., Michael, R., Nicola Conci, Johannes, L., Ala, Al-F. (2019). Multi-Modal Machine Learning for Flood Detection in News, Social Media and Satellite Sequences. *Computer Vision and Pattern Recognition, MediaEval* [in English].