

О.Г. Гончаров, Вік.В. Гнатушенко, О.С. Шевцова

НЕЙРОМЕРЕЖЕВИЙ ПІДХІД СЕГМЕНТАЦІЇ СІЛЬСЬКОГОСПОДАРСЬКИХ УГІДЬ НА СУПУТНИКОВИХ ЗОБРАЖЕННЯХ

Анотація. В сучасному аграрному секторі важливу роль відіграє точне картографування та моніторинг агроугідь за допомогою супутникових знімків, що дозволяє оптимізувати використання ресурсів, планувати посівні площі та прогнозувати врожайність. Семантична сегментація геоданих за допомогою глибокого навчання відкриває нові можливості для автоматизації цих процесів, проте потребує ретельного вибору та оптимізації моделей, здатних ефективно працювати з високорозмірними геопросторовими даними. Дана робота присвячена аналізу та порівнянню трьох різних модифікацій архітектури U Net для задачі семантичної сегментації агроугідь на основі супутникових зображень. Було досліджено моделі з різними архітектурними особливостями, включаючи застосування остаточних блоків, методів нормалізації та регуляризації. Результати показали, що деякі модифікації архітектури U Net можуть значно підвищити точність сегментації, що відкриває шлях для подальших досліджень у напрямку вдосконалення алгоритмів обробки супутникових даних для потреб аграрного сектору.

Ключові слова: семантична сегментація, агроугіддя, супутникові зображення, глибоке навчання, архітектура U Net, геодані.

Постановка проблеми. Зростаюча потреба у точному моніторингу та управлінні агроугіддями через супутникові технології створює виклики для обробки та аналізу геопросторових даних [6,7]. Ефективне використання таких даних вимагає розробки точних алгоритмів семантичної сегментації, здатних розрізняти різні типи поверхонь з високою точністю та швидкістю. Традиційні методи часто не забезпечують достатньої точності або вимагають значних обчислювальних ресурсів, що обмежує їх застосування в реальному часі та на великих територіях. Інтеграція глибокого навчання в процеси аналізу геоданих обіцяє вирішення цих проблем, однак вибір і оптимізація моделей для специфічних завдань сегментації агроугідь залишаються невирішеними [5,8]. Відсутність універсального підходу до вибору архітектури нейронної мережі, яка б максимально ефективно виконувала б завдання сегментації за

мінімального часу обчислень, підкреслює потребу у дослідженні та адаптації існуючих моделей глибокого навчання.

Аналіз останніх досліджень і публікацій. Огляд сучасних наукових робіт у сфері семантичної сегментації виявляє значне зростання інтересу до використання глибокого навчання для рішення завдань у різноманітних dome-нах, включаючи аграрний сектор. Вивчення методів і підходів, застосованих у цих дослідженнях, може надати цінні вказівки для покращення технік семантичної сегментації в аграрному секторі.

У роботі "Residual wave vision U-Net for flood mapping using dual polarization Sentinel-1 SAR imagery" [1] розроблено модифіковану архітектуру U-Net, яка ефективно обробляє двополяризаційні SAR зображення для картографування затоплень. Важливим висновком цього дослідження є використання остаточних блоків для підвищення точності визначення водних об'єктів, що може бути застосовано для детального аналізу водної ретенції в агроугіддях .

Дослідження "Generating synthetic images from cone beam computed tomography using self-attention residual UNet for head and neck radiotherapy" [2] показує, як використання механізму самоуваги разом із остаточними блоками в архітектурі U-Net може значно покращити якість синтезованих медичних зображень. Такий підхід може бути адаптовано для створення високоякісних синтетичних зображень агроугідь для тренування моделей глибокого навчання без потреби великої кількості реальних даних .

Робота "Deep learning-based hybrid feature selection for the semantic segmentation of crops and weeds" [3] розкриває потенціал гібридного вибору ознак на основі глибокого навчання для семантичної сегментації сільськогосподарських культур і бур'янів. Висновки цього дослідження можуть слугувати основою для розробки більш точних методів класифікації культур і бур'янів на полях, що є ключовим для ефективного агроменеджменту .

У статті "Comparative performance analysis of simple U-Net, residual attention U-Net, and VGG16-U-Net for inventory inland water bodies" [4] порівнюється ефективність трьох варіацій архітектури U-Net для інвентаризації внутрішніх водних об'єктів. Основним внеском є демонстрація переваги використання увагових механізмів та передтренуваних мереж у підвищенні точності сегментації, що може бути адаптовано для ідентифікації різноманітних типів агроугідь .

Ці дослідження підкреслюють важливість інноваційних підходів у семантичній сегментації і надають перспективні напрямки для подальшого

вдосконалення методів оцінки та моніторингу агроугідь за допомогою технологій глибокого навчання.

Метою дослідження є розробка та порівняльний аналіз модифікацій архітектури U-Net для задачі семантичної сегментації агроугідь на основі супутникових зображень. Дослідження спрямоване на виявлення оптимальних архітектурних та тренувальних підходів, що забезпечують високу точність сегментації з мінімальними обчислювальними витратами, з метою покращення ефективності моніторингу та управління агроугіддями. Особлива увага приділяється аналізу впливу остаточних (residual) блоків, методів нормалізації та регуляризації на загальну продуктивність моделей, щоб визначити найкращі практики для обробки геопросторових даних у сільськогосподарському секторі.

Основна частина. Для реалізації цілей нашого дослідження використовувалися супутникові зображення, отримані з архіву Copernicus HUB, зокрема дані супутника Sentinel-2 (ідентифікатор сцени: S2A_MSIL2A_20230605T083601_N0509_R064_T36TWS_20230605T125758.SAFE), зафіксовані 5 червня 2023 року. Вибір цієї дати обумовлений необхідністю аналізу стану сільськогосподарських угідь перед значними змінами, спричиненими катастрофою на Каховській ГЕС. Для аналізу обрано знімки, отримані з датчиків із просторовою роздільною здатністю 20 метрів, що містять інформацію в спектральних каналах B03 (синій), B04 (червоний), B8A (ближній інфрачервоний) та B11 (середній інфрачервоний). Для навчання моделі із помного знімку була взята лише область 2560x2560 px (51,2 тис м2) що дає змогу отримати 400 фрагментів зображень розміром 128x128 пікселів (Зображення 1). Для даного зображення була проведена ручна розмітка даних з трьома типами (зображення 2): сільськогосподарські поля (field); водойми (water); інше (other), куди попали дороги, ліси, зони міської та сільської застройки, тощо.



Рисунок 1 - Область дослідження та навчання моделі




Рисунок 2 - Розмітки даних по супутниковим знімкам

Попередня обробка даних полягала в розбитті первинних супутникових знімків на фрагменти розміром 128x128 пікселів, що охоплюють території з попередньо розміченими об'єктами. Цей підхід дозволив створити набір даних, адаптований для тренування моделей глибокого навчання, з подальшим об'єднанням інформації з вибраних спектральних каналів у єдиний файл для кожного фрагменту. Нормалізація інтенсивності пікселів здійснювалася шляхом їх масштабування до інтервалу [0; 1] без застосування додаткових методів аугментації, враховуючи достатню кількість даних для навчання. Визначення класів об'єктів на фрагментах базувалося на бінарних масках, де "1" позначало сільськогосподарські угіддя, а "0" - інші типи покриття.

Опис моделей глибокого навчання: В рамках дослідження було використано три модифікації архітектури U-Net, що включають варіації з базовими елементами (конволюційні блоки, активація, пулінг) та розширення, направлені на підвищення точності сегментації та запобігання перенавчанню (включення остаточних блоків, Dropout шарів, Batch Normalization, а також використання функції активації LeakyReLU).

Методи оцінки ефективності: Основною стратегією оцінки результатів сегментації було використання матриці помилок та візуального аналізу з метою визначення якості виокремлення сільськогосподарських угідь. Планується розширення інструментарію оцінки за допомогою додаткових метрик для глибшого аналізу.

Аналітичні інструменти та програмне забезпечення: У цьому дослідженні ми застосували Python як основу для розробки моделей глибокого навчання, використовуючи бібліотеки TensorFlow та Keras для створення та тренування нейронних мереж. Для обробки супутникових зображень використовувалися бібліотеки NumPy та Rasterio, що забезпечили потужні інструменти для

маніпуляції з даними, а GeoPandas допомогла у роботі з геопросторовими даними. Ручна розмітка даних для навчання моделей виконувалася за допомогою інструменту GroundWork, що забезпечило високу якість тренувальних датасетів і сприяло точній ідентифікації цільових об'єктів на знімках.

Ця методологія відображає комплексний підхід до аналізу сільськогосподарських угідь за допомогою супутникових знімків із застосуванням технологій глибокого навчання, забезпечуючи надійну основу для оцінки потенціалу різних моделей у контексті задач сегментації.

Модель № 1. U-Net з LeakyReLU активацією та Batch Normalization (Kernel 3x3 => 2x2). Архітектура моделі (Рисунок 3) складається з чотирьох блоків енкодера, які поступово зменшують просторовий розмір вхідного зображення 128x128 пікселів через конволюції та максимальне згортання, використовуючи фільтри від 64 до 512. Центральний шар, або "ботлнек", обробляє дані за допомогою 1024 фільтрів, після чого наступають чотири блоки декодера, які відновлюють розмір зображення до початкового, використовуючи операції збільшення розміру та конкатенації з відповідними блоками енкодера для збереження контексту. Вихідний шар використовує softmax для класифікації кожного пікселя на два класи, забезпечуючи семантичну сегментацію зображення. Усі конволюційні шари включають Batch Normalization та використовують LeakyReLU функцію активації.

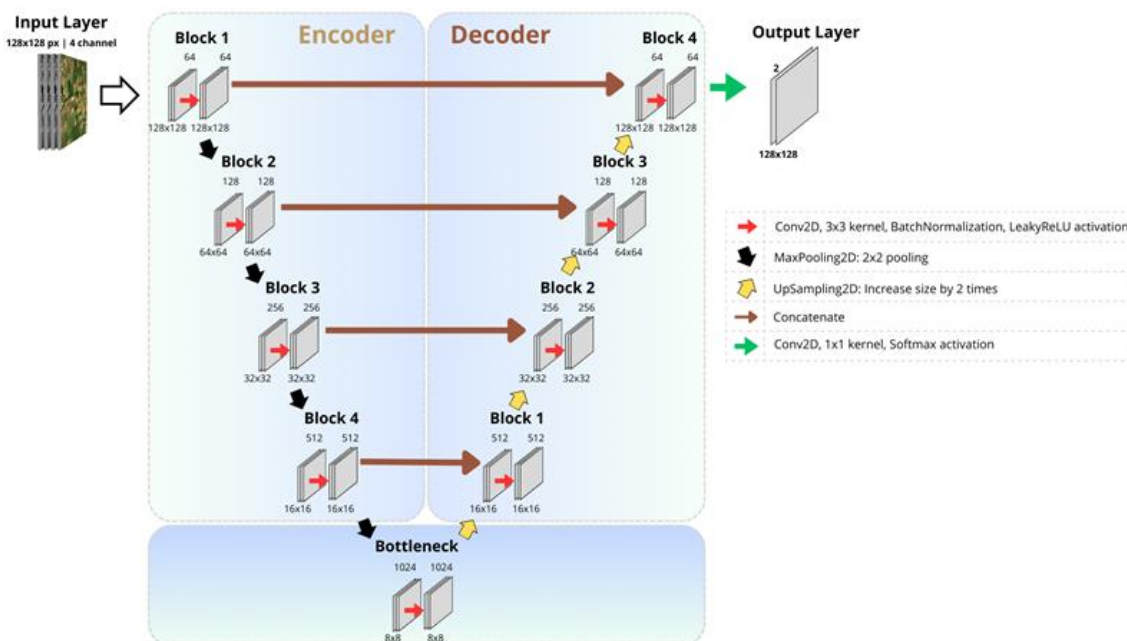


Рисунок 3 - Архітектура Моделі №1 U-Net з LeakyReLU активацією та Batch Normalization (Kernel 3x3 => 2x2)

Результати:

Accuracy: Поліпшення точності від 61.24% до 69.23% на валідаційному наборі даних.

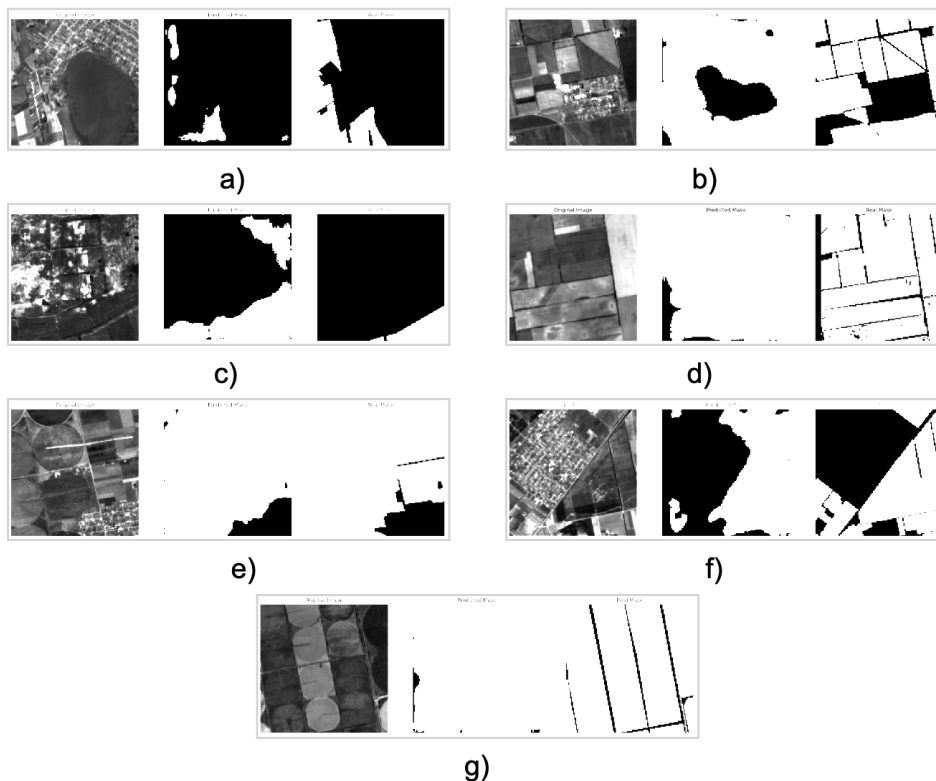


Рисунок 4 - Результат роботи моделі №1. Оригінальне зображення;
Результат маски від моделі; Реальна маска

Візуальний аналіз:

Сільськогосподарські угіддя: Виділяє поля, але з деякими помилками, особливо коли рельєф та текстури полів мають схожість із іншими природними елементами.

Водойми: Модель добре розпізнає водойми, демонструючи чіткі межі водних ресурсів.

Забудовані території: Модель іноді неправильно ідентифікує будівлі та інші конструкції як угіддя, що свідчить про необхідність подальшого доопрацювання моделі для покращення розрізнення між класами.

Загальний висновок:

Модель №1 показує високий потенціал для точної сегментації сільськогосподарських угідь і водних ресурсів на спутникових знімках. Остаточні блоки та Batch Normalization ефективно сприяють стабільності навчання. Втім, модель потребує додаткової настройки, щоб зменшити кількість помилок і підвищити загальну точність в складних зонах зображень.

Модель № 2. U-Net з остаточною блоками (residual). Архітектура моделі №2 (зображення 5) поєднує класичний підхід U-Net з використанням остаточною блоків, що дозволяє підвищити точність моделі завдяки ефективнішому розповсюдженню градієнтів під час навчання. Модель розпочинається з вхідного шару для зображень розміром 128x128 пікселів із 4 каналами. Далі йдуть чотири блоки енкодера з остаточною з'єднаннями: перший блок з 32 фільтрами, другий — з 64 фільтрами, кожен з яких включає два конволюційні шари з активацією ReLU, а після кожного блоку застосовується максимальне згортання для зменшення розміру зображення вдвічі. Центральний шар, або "ботлнек", обробляє дані за допомогою 128 фільтрів, зберігаючи розмір 32x32 пікселів. В архітектурі декодера використовуються два блоки для поступового відновлення розміру зображення до первісних розмірів: перший блок декодера із 64 фільтрами, що збільшує розмір до 64x64 пікселів, і другий блок із 32 фільтрами, який повертає розмір до 128x128 пікселів. Обидва блоки декодера включають процеси збільшення розміру, конкатенації з відповідними блоками енкодера та дві конволюційні операції з активацією ReLU та остаточною з'єднаннями. Вихідний шар застосовує softmax для визначення класифікації кожного пікселя між двома можливими класами, забезпечуючи ефективну семантичну сегментацію зображення.

Результати:

Ассурасу: Найвища точність на тренувальних даних досягається у останньому епоці, близько 60.59%.

Точність: Показує здатність моделі розрізняти класи, однак залишається значний простір для покращення. Висока кількість помилково позитивних результатів свідчить про те, що модель часто неправильно класифікує незасіяні ділянки як засіяні. З іншого боку, кількість помилково негативних результатів, хоча й менша, вказує на тенденцію моделі упускати певні засіяні ділянки.

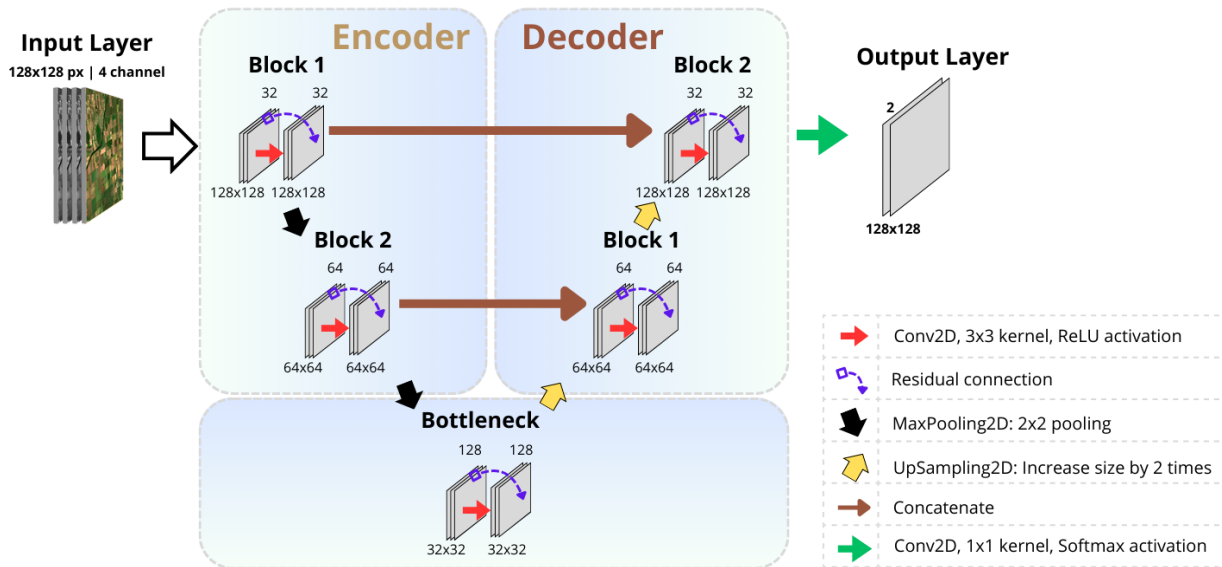


Рисунок 5 -Архітектура Моделі №2 U-Net з остаточними блоками (residual)

Візуальний аналіз:

З використанням остаточних блоків, модель показує здатність до більш точної сегментації, але деякі області все ще бракують точності порівняно з реальними масками, що вказує на потребу в подальших удосконаленнях.

Це зведення демонструє, що модель №2 здатна до ідентифікації сегментованих зон, однак виникають помилки, особливо у випадку класифікації несільськогосподарських зон. Для покращення результатів може знадобитися більш глибока архітектура або розширені методи тренування, такі як трансферне навчання чи додаткова аугментація даних.

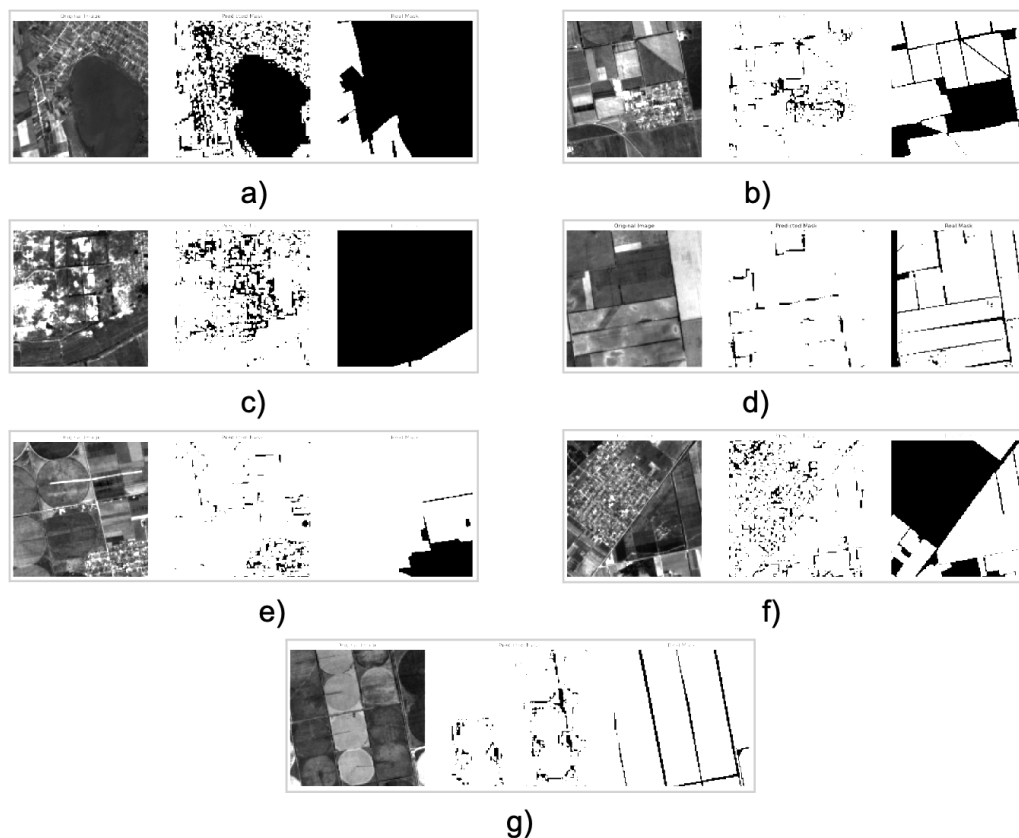


Рисунок 6 - Результат роботи моделі №2. Оригінальне зображення;
Результат маски від моделі; Реальна маска

Модель № 3. U-Net з остаточними блоками (residual) та нормалізацією. Архітектура моделі №3 (зображення 7) це продовження розробки ідей, закладених у моделі №2, з акцентом на подальшому підвищенні ефективності моделі через впровадження шару Batch Normalization і шару Dropout в кожен остаточний блок. Впровадження Batch Normalization сприяє нормалізації вхідних даних перед активацією, покращуючи загальну стабільність і швидкість навчання моделі, а також допомагаючи уникнути проблеми внутрішнього зсуву коваріації. Включення шару Dropout забезпечує додатковий захист від перенавчання, тимчасово відключаючи частину нейронів під час тренування, що спонукає мережу навчатися на більш різноманітних шаблонах даних і підвищує узагальненість отриманих рішень. Ці зміни роблять модель №3 більш стійкою до викликів, пов'язаних з перенавчанням, і підвищують її ефективність у завданнях семантичної сегментації, особливо на складних і різноманітних наборах даних.

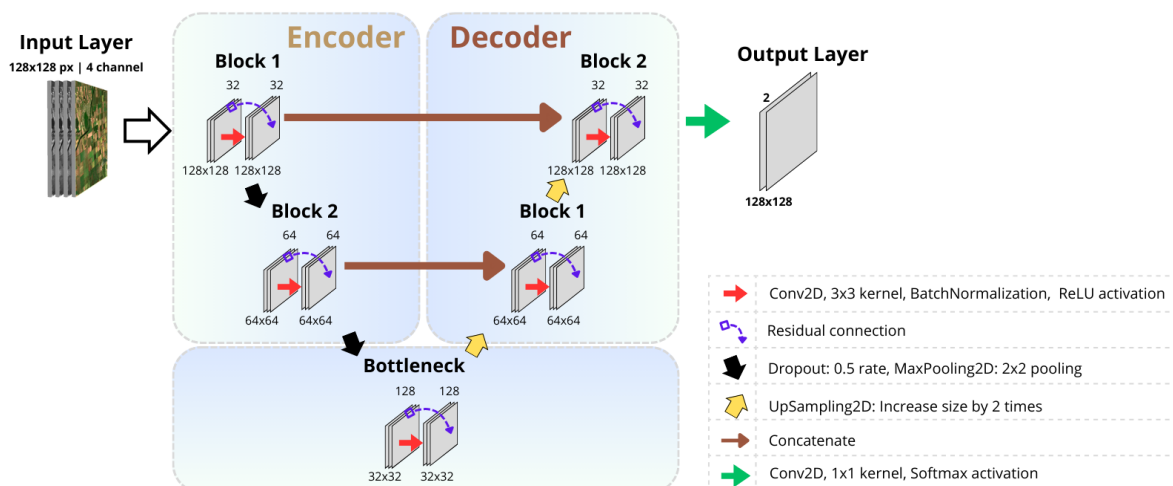


Рисунок 7 - Архітектура Моделі №3 U-Net з остаточними блоками (residual) та нормалізацією

Результати:

Ассурасу: Найвища точність на тренувальних даних досягнута у останньому епоці, близько 67.65%.

Точність: Вказує на певне покращення у визначенні класів порівняно з попередніми моделями. Проте, висока кількість помилково позитивних результатів (false positives) та помилково негативних результатів (false negatives) підкреслює потребу в додатковій оптимізації моделі.

Візуальний аналіз:

Зображення з передбаченими масками показують, що модель здатна виділяти об'єкти, але існують помилки у точності обробки країв та деталей, особливо на складних ділянках зображення.

Моделі №3, яка використовує остаточні блоки з BatchNormalization та Dropout, показує здатність до поліпшення загальної точності класифікації порівняно з попередніми ітераціями. Введення Dropout допомагає уникнути перенавчання, а BatchNormalization сприяє стабілізації та прискоренню процесу навчання. Однак висока кількість помилково позитивних і помилково негативних результатів свідчить про необхідність подальшої роботи над точністю моделі, особливо в частині визначення кордонів об'єктів. На основі візуального аналізу передбачених масок можна стверджувати, що модель потребує покращення у точності сегментації, щоб досягти більш чіткого та точного виявлення об'єктів, а також для мінімізації помилкових класифікацій.

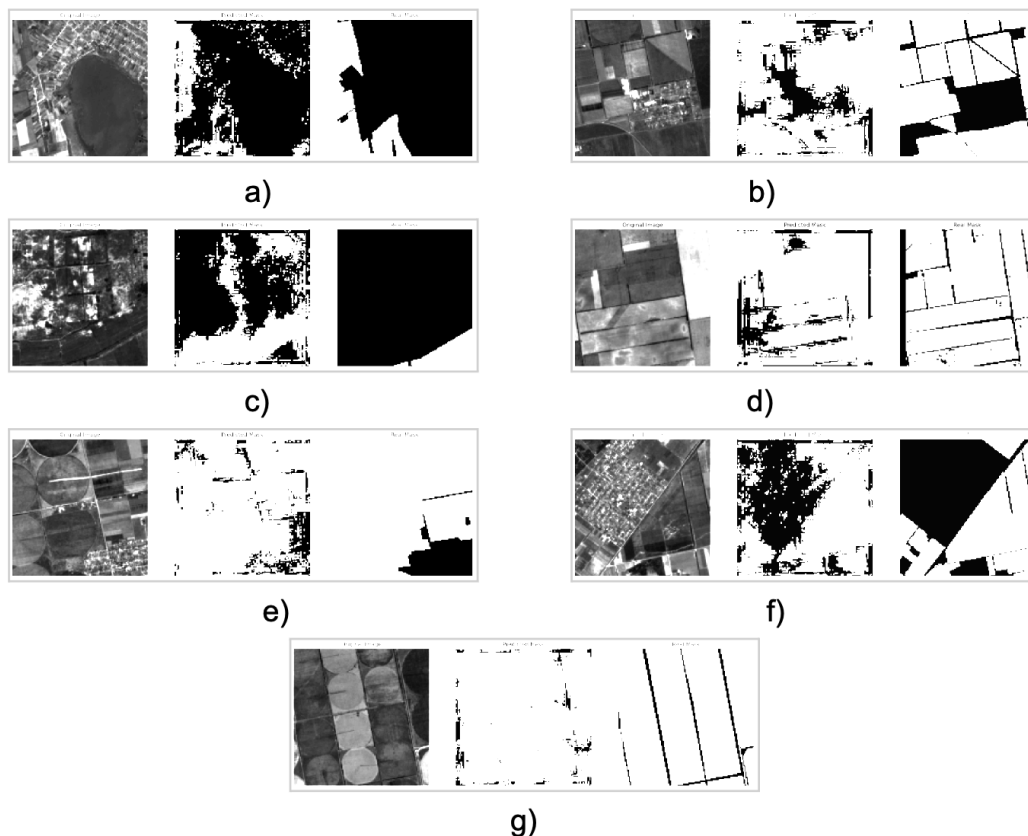


Рисунок 8 - Результат роботи моделі №3. Оригінальне зображення;
Результат маски від моделі; Реальна маска

Висновок. Аналіз різних архітектур U-Net, адаптованих до задачі семантичної сегментації аграрних угідь, підкреслив значення інноваційних підходів у покращенні точності моделей. Експерименти з остаточними блоками, нормалізацією за партіями, Dropout та іншими техніками оптимізації вказали на їх ефективність у боротьбі з перенавчанням та підвищенні загальної точності. Подальше дослідження та адаптація цих методик може принести значний внесок у розвиток точних та надійних інструментів для моніторингу аграрних угідь.

Прогрес у цій області можливий завдяки комбінації глибоких архітектур нейронних мереж зі збагаченими наборами даних та удосконаленою передобробкою даних. Враховуючи широкий спектр потенційних застосувань, важливо зосередитися на розробці моделей, здатних адаптуватися до різноманітних умов та відображати специфіку аграрних ландшафтів. Результати цього дослідження можуть слугувати основою для подальших інновацій, які підвищать точність визначення аграрних угідь та сприятимуть ефективному використанню земельних ресурсів.

ЛІТЕРАТУРА

1. Jamali, A., Roy, S.K., Hashemi Beni, L., Pradhan, B., Li, J., Ghamisi, P., 2024. Residual wave vision U-Net for flood mapping using dual polarization Sentinel-1 SAR imagery. *International Journal of Applied Earth Observation and Geoinformation* 127, March 2024, 103662. <https://doi.org/10.1016/j.jag.2024.103662>
2. Yoganathan, S.A., et al., 2023. Generating synthetic images from cone beam computed tomography using self-attention residual UNet for head and neck radiotherapy. *Physics and Imaging in Radiation Oncology* VOLUME 28, 100512, OCTOBER 2023. <https://doi.org/10.1016/j.phro.2023.100512>.
3. Janneh, L.L., Youngjun, Z., Hyudara, M., Cui, Z., 2024. Deep learning-based hybrid feature selection for the semantic segmentation of crops and weeds. *ICT Express* 10 (2024) 118–124. <https://doi.org/10.1016/j.icte.2023.07.008>.
4. Ghaznavi A., Saberioon M., Brom J., Itzerott S., 2023. Comparative performance analysis of simple U-Net, residual attention U-Net, and VGG16-U-Net for inventory inland water bodies. *Applied Computing and Geosciences* 21 (2024) 100150. <https://doi.org/10.1016/j.acags.2023.100150>.
5. Hnatushenko Vik., Hnatushenko Vo., Kashtan V., Heipke C., 2023: Detection of Forest Fire Consequences on Satellite Images using a Neural Network. In: Kersten T., Tilly N. (Eds.), 43. Wissenschaftlich-Technische Jahrestagung der DGPF e.V. - München, Publikations DGPF, Vol. 31 https://www.dgpf.de/src/tagung/jt2023/proceedings/paper/15_dgpf2023_Hnatushenko_et_al.pdf
6. HEIPKE C. & ROTTENSTEINER F., 2020: Deep learning for geometric and semantic tasks in photogrammetry and remote sensing. *Geo-spatial Information Science*, 23(1), 10-19, <https://doi.org/10.1080/10095020.2020.1718003>
7. KAPLAN, G. & AVDAN, U., 2018: Sentinel-1 and Sentinel-2 Data fusion for wetlands mapping: Balıkdami, Turkey. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 42(3), 729-734, <https://doi.org/10.5194/isprs-archives-XLII-3-729-2018>.
8. KASHTAN, V. & HNATUSHENKO, V., 2023: Deep Learning Technology for Automatic Burnt Area Extraction Using Satellite High Spatial Resolution Images. In: Babichev, S., Lytvynenko, V. (eds) *Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. ISDMCI 2022. Lecture Notes on Data Engineering and Communications Technologies*, 149. Springer, Cham. https://doi.org/10.1007/978-3-031-16203-9_37.

REFERENCE

1. Jamali, A., Roy, S.K., Hashemi Beni, L., Pradhan, B., Li, J., Ghamisi, P., 2024. Residual wave vision U-Net for flood mapping using dual polarization Sentinel-1 SAR imagery. *International Journal of Applied Earth Observation and Geoinformation* 127, March 2024, 103662. <https://doi.org/10.1016/j.jag.2024.103662>
2. Yoganathan, S.A., et al., 2023. Generating synthetic images from cone beam computed tomography using self-attention residual UNet for head and neck radiotherapy. *Physics and Imaging in Radiation Oncology* VOLUME 28, 100512, OCTOBER 2023. <https://doi.org/10.1016/j.phro.2023.100512>.
3. Janneh, L.L., Youngjun, Z., Hydera, M., Cui, Z., 2024. Deep learning-based hybrid feature selection for the semantic segmentation of crops and weeds. *ICT Express* 10 (2024) 118–124. <https://doi.org/10.1016/j.icte.2023.07.008>.
4. Ghaznavi A., Saberioon M., Brom J., Itzerott S., 2023. Comparative performance analysis of simple U-Net, residual attention U-Net, and VGG16-U-Net for inventory inland water bodies. *Applied Computing and Geosciences* 21 (2024) 100150. <https://doi.org/10.1016/j.acags.2023.100150> .
5. Hnatushenko Vik., Hnatushenko Vo., Kashtan V., Heipke C., 2023: Detection of Forest Fire Consequences on Satellite Images using a Neural Network. In: Kersten T., Tilly N. (Eds.), 43. *Wissenschaftlich-Technische Jahrestagung der DGPF e.V. - München, Publikations DGPF, Vol. 31* https://www.dgpf.de/src/tagung/jt2023/proceedings/paper/15_dgpf2023_Hnatushenko_et_al.pdf
6. HEIPKE C. & ROTTENSTEINER F., 2020: Deep learning for geometric and semantic tasks in photogrammetry and remote sensing. *Geo-spatial Information Science*, 23(1), 10-19, <https://doi.org/10.1080/10095020.2020.1718003>
7. KAPLAN, G. & AVDAN, U., 2018: Sentinel-1 and Sentinel-2 Data fusion for wetlands mapping: Balıkdami, Turkey. *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, 42(3), 729-734, <https://doi.org/10.5194/isprs-archives-XLII-3-729-2018>.
8. KASHTAN, V. & HNATUSHENKO, V., 2023: Deep Learning Technology for Automatic Burnt Area Extraction Using Satellite High Spatial Resolution Images. In: Babichev, S., Lytvynenko, V. (eds) *Lecture Notes in Data Engineering, Computational Intelligence, and Decision Making. ISDMCI 2022. Lecture Notes on Data Engineering and Communications Technologies*, 149. Springer, Cham. https://doi.org/10.1007/978-3-031-16203-9_37.

Received 07.05.2024.
Accepted 09.05.2024.

Neural Network Approach for Segmentation of Agricultural Lands on Satellite Images

Precision mapping and monitoring of agricultural lands using satellite imagery have become crucial for optimizing agricultural practices. This research focuses on exploring the effectiveness of deep learning models, particularly U-Net modifications, for semantic segmentation of agricultural lands in satellite images.

Recent Studies and Publications Analysis. Recent advancements in convolutional neural networks (CNNs) have shown promising results in various semantic segmentation tasks, including medical imaging, flood mapping, and environmental monitoring. Studies such as "Residual wave vision U-Net for flood mapping using dual polarization Sentinel-1 SAR imagery" and "Deep learning-based hybrid feature selection for the semantic segmentation of crops and weeds" underline the adaptability of U-Net architectures to diverse data characteristics, motivating their application in agricultural land segmentation.

Research Objective. The primary aim of this study is to assess the applicability and efficiency of modified U-Net architectures in accurately segmenting agricultural lands from satellite images. It seeks to identify optimal model modifications that enhance segmentation accuracy while maintaining computational efficiency, contributing to more effective agricultural monitoring.

Main Body of Research. Utilizing satellite images from the Copernicus HUB archive, this work experiments with various U-Net architectures incorporating residual blocks, normalization methods, and regularization techniques. The study compares the performance of these models in segmenting agricultural lands, highlighting the impact of architectural enhancements on improving model precision and generalization capabilities.

Conclusions. The research concludes that specific modifications in the U-Net architecture significantly enhance the segmentation accuracy of agricultural lands in satellite images. Implementing residual blocks, batch normalization, and dropout proved effective in overcoming overfitting, suggesting a promising direction for future work in geospatial data processing for agriculture. Further investigation into hyperparameter tuning, dataset expansion, and ensemble methods is recommended to refine the models' predictive performance.

Keywords: semantic segmentation, agricultural lands, satellite images, deep learning, U-Net architecture, geodata.

Гнатушенко Вікторія Володимирівна – доктор технічних наук, професор, завідувач кафедри інформаційних технологій і систем Українського державного університету науки і технології (м. Дніпро).

Гончаров Олександр Геннадійович – аспірант кафедри інформаційних технологій і систем Українського державного університету науки і технології (м. Дніпро).

Шевцова Ольга Сергіївна - аспірантка кафедри програмного забезпечення комп'ютерних систем Національного технічного університету «Дніпровська політехніка» (м. Дніпро).

Hnatushenko Viktoriia – Doctor of engineering's sciences, Professor, Head of Department of Information Technologies and Systems, Ukrainian State University of Science and Technology.

Honcharov Oleksandr – Postgraduate Student, Department of Information Technologies and Systems, Ukrainian State University of Science and Technology.

Shevtsova Olha - Postgraduate Student, Department of Computer Systems Software, Dnipro University of Technology, Dnipro, Ukraine.