

## СЕГМЕНТАЦІЯ ЗОБРАЖЕНЬ З УРАХУВАННЯМ НЕВИЗНАЧЕНОСТІ ЗА ДОПОМОГОЮ АРХІТЕКТУРИ U-NET І MONTE CARLO DROPOUT

*Анотація.* Історично згорткові нейронні мережі набули поширення для вирішення задач розпізнавання об'єктів на зображеннях, зокрема для попереднього аналізу пошкоджень після стихійних явищ. Архітектура U-Net стала одним із популярних рішень для сегментації зображень; за останні роки з'явилося багато досліджень і модифікацій даної моделі, що використовують як механізми уваги, так і окремі модулі для покращення результатів класифікації. Водночас дослідження оцінки невизначеності й пояснення роботи сегментаційних моделей все ще потребують поглиблення, чим і зумовлена актуальність даної роботи.

Хоча підвищення точності й ефективності є важливою складовою будь-якої моделі, в таких задачах як попередній аналіз пошкоджень і збитків оцінка впевненості, або невизначеності, є одним із вирішальних факторів, оскільки може бути використана для подальшого прийняття рішень. Мета дослідження полягає у побудові сегментаційної моделі модифікованої архітектури U-Net з модулем ASPP з урахуванням невизначеності шляхом множинного запуску моделі з різними масками відсіювання (Monte Carlo Dropout) для попереднього аналізу пошкоджених будівель на зображеннях.

В роботі представлено дослідження модифікованої архітектури U-Net із заміною bottleneck на модуль ASPP та застосуванням Monte Carlo Dropout. На основі розрахункових формул дисперсії, ентропії та взаємної інформації сформовано карти невизначеності, що застосовано для покращення сегментації. Показано, що ASPP підвищує точність визначення форм об'єктів, а комбінована функція втрат сприяє покращенню сегментації. У експериментах досягнуто приросту 3.8% середнього IoU, 4% для вцілілих і 5.3% для зруйнованих будівель. Маски невизначеності проаналізовано та використано в методі з двома пороговими значеннями впевненості й невизначеності моделі для виділення найбільш надійних ділянок. Для практичного впровадження описаних методів і підходів існує необхідність їх подальшого дослідження.

*Ключові слова:* розпізнавання пошкоджених будівель, згорткові нейронні мережі, комп'ютерний зір, семантична сегментація, Monte Carlo Dropout, ASPP, U-Net, Google Earth.

**Постановка проблеми.** Щороку природні явища як повені та урагани призводять до критичних руйнувань на значних територіях. Водночас, довготривалі військові дії носять ще масштабніший характер, що унеможлиблює швидке післявоєнне відновлення без автоматизованих технологій оцінки завданих збитків. Своєчасне виявлення пош-

кодженої цивільної та промислової інфраструктури дозволяє не лише пришвидшити процес, але й зменшити навантаження на логістичні центри, виявити найбільш критичні ділянки.

Останні дослідження відображають широке застосування згорткових нейронних мереж для оцінки ушкоджень після природних явищ та інших катастроф [1, 2]. Такі архітектури як YOLO, ResNet і U-Net показують високу ефективність в задачах виявлення об'єктів, а також сегментації зображень. U-Net, що історично застосовується для сегментації у медицині, використовується як самостійна модель, так і у якості окремого компонента у більших системах [3, 4].

Семантична сегментація є ключовим підходом машинного зору для оцінки руйнувань, оскільки існує необхідність визначення об'єктів у межах пікселів. Це дозволяє не лише отримувати приблизне розташування об'єкту, але й його неоднозначну структуру й характерні пошкодження. За останні роки набули широкого поширення модифікації U-Net, які використовують механізми уваги для визначення багатомасштабних ознак [5], так і окремі модулі, наприклад, просторово-пірамідального пулінгу (з англ. Atrous Spatial Pyramid Pooling, ASPP) [6], що підвищують точність сегментації.

Водночас, незважаючи на значні дослідження точності й ефективності як розпізнавання об'єктів, так і сегментації зображень, вони переважно зосереджені на кількісних показниках якості, залишаючи поза увагою оцінку невизначеності передбачень. Впевненість моделі є важливою складовою у даному випадку, оскільки надає додаткову інформацію, яка може бути використана для підвищення надійності прийняття рішень. Зокрема, аналіз невизначеності дозволяє виявляти області з потенційно помилковою сегментацією. Крім того, така інформація може бути використана для адаптивного вдосконалення моделі, наприклад, шляхом донавчання на найбільш проблемних зразках або оптимізації архітектурних рішень.

**Аналіз останніх досліджень і публікацій.** Оцінка невизначеності прогнозування для сегментаційних моделей є доволі складною, але важливою задачею, особливо для застосування у реальних умовах. Не лише через необхідність прогнозів із високою достовірністю, але й через можливість отримати потужний інструмент для пояснення і подальшого покращення роботи моделі. У контексті глибокого навчання розрізняють два основних типи невизначеності: алеаторну (статистичну), що пов'язана з внутрішньою варіативністю і шумами у даних (наприклад, низька якість зображень або неоднорідні межі об'єкту), й епістемічну, яка зумовлена обмеженістю знань самої моделі. В свою чергу, остання може бути зменшена шляхом покращення моделі, знаходження оптимальних параметрів, або розширення існуючих даних.

В різних наукових працях можна відмітити декілька основних підходів [7, 8, 9], наприклад, дослідження каліброваних показників достовірності (вихідні ймовірності з останнього шару моделі) на відповідність їх справжній ймовірності правильності, або зосередження на моделюванні невизначеності моделі, які зазвичай натхненні байєсівськими принципами, і включають метод Monte Carlo Dropout, запропонований Gal і

Ghahramani (2016), або глибокі ансамблі, що використовують для оцінки невизначеності набір прогнозів, від Lakshminarayanan, Pritzel і Blundell (2017).

Зважаючи на поширеність архітектури U-Net, в інших дослідженнях приділяється увага поєднанню цієї моделі з підходами активного навчання і баєсівського виведення для сегментації зображень з оцінкою невизначеності [10, 11]. Автори зазначають про достатню ефективність і стабільність сегментації навіть при обмежених даних, а також підтверджують доцільність використання невизначеності для подальшого підвищення ефективності моделей.

Загалом варто відзначити активні дослідження методів оцінки невизначеності й калібрації моделей, водночас наявні праці оцінки невизначеності для сегментаційних моделей досі обмежені, в тому числі, що розглядають попіксельні метрики й локальний просторовий аналіз. Таким чином, актуальність зумовлена необхідністю дослідження підходів і моделей, що поєднують достатню точність сегментації з можливістю кількісної оцінки невизначеності, що особливо корисно у випадках виявлення пошкоджених об'єктів при щільній забудові або зарослій місцевості.

**Мета дослідження.** Метою роботи є побудова модифікованої моделі архітектури U-Net семантичної сегментації з урахуванням невизначеності з використанням Monte Carlo Dropout (далі MCD) для попереднього аналізу пошкоджених будівель на зображеннях й визначення неоднозначних регіонів, що в подальшому може бути використано для покращення точності сегментації.

**Викладення основного матеріалу дослідження.** У даній роботі розглядається модифікація класичної архітектури U-Net, де замість найвужчого місця у мережі використовується окремий модуль ASPP [6]. Архітектура передбачає дві основні складові: стискаючий і розширюючий шляхи, які забезпечують виділення ознак, та відповідно сегментацію зображення на кінцевому шляху, що нагадує принцип роботи моделей типу кодер-декодер. Логіку даних складових можна розбити на блоки, які відповідають за окремі функції: згорткові блоки, що являють собою послідовності згортки розміром  $3 \times 3$  із функціями активації; блоки кодера, які формують стискаючий шлях і поєднують згорткові блоки з операціями підвибірки ( $2 \times 2$  пулінг) та застосуванням dropout; а також блоки декодера, що виконують зворотне просторове відновлення за допомогою апсемплінгу, конкатенації відповідних ознак із кодера й використання dropout в кінці.

В свою чергу, найвужче місце у мережі поєднує дві частини моделі, що містить найбільшу кількість каналів зі зменшеною просторовою роздільною здатністю, що дозволяє акумулювати найбільш узагальнене представлення вхідних даних. Хоча класична архітектура є достатньо ефективною, окремий модуль ASPP може позитивно впливати на точність сегментації.

Модуль складається із декількох пулінгових шарів, що мають не суцільні фільтри, а з деякими відстанями між ними, що застосовуються послідовно. Це дозволяє вилучити необхідні ознаки за різної масштабованості без підвищення складності розрахунків, оскільки враховуються лише ненульові значення фільтрів.

В кінці модуля розташовані пулінгові шари, та відповідний шар, що поєднує усі попередні в один, після чого відбувається згортка до відповідного розміру. Дані з мо-

дуля ASPP подаються до другої частини моделі, яка має аналогічну будову до класичної, після чого генерується сегментаційна маска, яка є результатом роботи побудованої моделі. Загальна будова наведена на рис. 1.




Рисунок 1 - Архітектура моделі згорткової U-Net з модулем ASPP

**Monte Carlo Dropout.** Даний метод є поширеним для оцінки невизначеності в глибоких мережах через простоту його реалізації, коли необхідно отримати оцінювання варіативності передбачень. Gal і Ghahramani у своїй праці [7] пояснюють теоретичну основу MCD, який передбачає використання dropout у навчанні нейронних мереж як наближеного байєсівського висновку в глибоких гаусових процесах. У межах підходу модель розглядається як сукупність стохастичних підмереж, тобто, замість одного результату отримується розподіл можливих вихідних даних.

Застосування MCD передбачає активацію dropout не лише під час навчання, а власне й на етапі висновку (інференсу). Для кожного вхідного зразку виконується декілька стохастичних проходів через мережу з різними dropout, в результаті чого формується набір передбачень (рис. 2), на основі якого обчислюються різні статистичні характеристики: середнє, дисперсія, ентропія тощо. Таким чином MCD дозволяє отримати усереднений прогноз на основі декількох результатів, а також кількісно оцінити невизначеність моделі.




Рисунок 2 - Різні вихідні зображення мережі (кольорами обведені деякі відмінності між сегментаційними масками завдяки різним маскам dropout)

Отримані оцінки невизначеності можуть бути використані для побудови окремих сегментаційних масок, які піксельно відображають регіони, які модель визначає з більшою або меншою впевненістю, які в свою чергу можуть бути застосовані для підвищення якості як набору даних (виявлення проблематичних ділянок для сегментації), так і модифікації самої моделі. Також результати MCD можна застосовувати для повторної сегментації зображень на основі отриманої інформації про впевненість моделі.

**Набір даних і попередня обробка.** В рамках дослідження було використано власний невеликий набір даних, що містить 100 зображень 512 на 512 пікселів міста Маріуполь (джерело Google Earth), зроблених у 2022 року. Усі зображення загалом містять близько 2500 унікальних будівель, які поділені на 2 класи: зруйновані та вцілілі. Враховуючи специфіку руйнувань, які неможливо повністю оцінити у виду зверху, до вцілілих будівель було віднесено усі можливі, для яких чітко не відслідковуються зовнішні пошкодження. Приклад деяких зображень наведено на рис. 3.



Рисунок 3 - Приклад зображень набору даних

Враховуючи задній фон (або бекграунд), набір даних містить 3 класи, які будуть враховуватися під час навчання, а також крім оригінальних зображень, у наборі присутні відповідні сегментаційні і вагові маски, які застосовуються для балансування класів будівель і заднього фону.

Для розширення варіативності набору на етапі попередньої обробки до зображень застосовуються прості перетворення: повороти, віддзеркалення, зсуви, а також обме-

жене масштабування. Таким чином, набір даних було збільшено у декілька разів (в дослідження розглядаються різні конфігурації).

**Застосовані метрики і оцінка невизначеності.** Для семантичної сегментації найчастіше використовується функція втрат категоріальна перехресна ентропія (англ. Categorical Cross Entropy, CCE), яка обчислює “відстань” між фактичним розподілом і відповідним прогнозом. Нижча оцінка визначає кращий ступінь узгодженості, відповідно, вища вказує на розбіжності. Формула (1) для CCE наведена нижче:

$$CCE = -\sum_{c=1}^k \text{ground\_truth}_c \times \log(\text{image}_c), \quad (1)$$

де  $c$  – поточний клас у діапазоні від 1 до  $k$ ,  $\text{image}$  – вихідні дані (зображення),  $\text{ground\_truth}$  – сегментаційна маска відповідного зображення.

Також було використано узагальнену функцію втрат, яка враховує комбінацію втрат CCE та Dice Loss (2), що максимізує перекриття між прогнозованою й цільовою сегментаційними масками:

$$\text{Dice}_{\text{loss}} = 1 - \frac{2\sum_i g_i p_i}{\sum_i g_i + \sum_i p_i}, \quad (2)$$

де  $g_i$  – оригінальна сегментаційна маска,  $p_i$  – прогнозована сегментаційна маска.

У дослідженні розглядається використання метрики Intersection over Union (IoU), яка враховує співвідношення кількості пікселів вихідного зображення із відповідною сегментаційною маскою. Реалізована функція враховує середнє IoU (3-4) між усіма класами, а також для основних класів будівель - пошкоджених і вцілілих, що дозволяє отримати повнішу картину про роботу моделі. Розрахункові формули наступні:

$$\text{IoU}_c = \frac{\text{TP}_c}{\text{TP}_c + \text{FP}_c + \text{FN}_c}, \quad (3)$$

де  $c$  – поточний клас для розрахунку, TP – «істинно позитивне» значення, FP – «хибно-позитивне» значення, FN – «хибнонегативне» значення пікселів.

$$\text{IoU}_{\text{mean}} = \frac{1}{c_{\text{max}}} \sum_c \text{IoU}_c, \quad (4)$$

де  $c$  – поточний клас для обчислення,  $c_{\text{max}}$  – загальна кількість класів,  $\text{IoU}_c$  – розраховане значення IoU для класу  $c$ .

Для оцінки невизначеності було розраховано дисперсію (5), прогностичну ентропію (6) і взаємну інформацію (7), які набули широкого поширення у моделях, що використовують MCD. Дисперсія вимірює розсіювання прогнозованих ймовірностей класів за набором стохастичних проходів, ентропія фіксує загальну невизначеність усередненого прогнозу на наборі результатів, що були отримані під час проходжень, а взаємна інформація ізолює епістемічну невизначеність шляхом кількісної оцінки розбіжностей між окремими прогнозами й середнім значенням [7]. Узагальнені формули виглядають наступним чином:

$$\text{Var} = \frac{1}{T} \sum (p_t^c - m^c)^2, \quad (5)$$

де  $p_t^c$  – ймовірність для відповідного класу на проходженні  $t$ ,  $m^c$  – середня ймовірність,  $T$  – кількість проходжень.

$$H = - \sum_{c=1}^C p^c \log p^c, \quad (6)$$

де  $p^c$  – розрахована середня ймовірність для класу  $c$ .

$$MI = \frac{1}{T} \sum_{t=1}^T (- \sum_{c=1}^C p_t^c \log p_t^c), \quad (7)$$

де  $p^c$  – розрахована середня ймовірність для класу  $c$ .

**Результати тренування і тестування моделі.** Початкова побудована модель мала наступні параметри: кількість фільтрів – 32, dropout – 0.2, фільтри ASPP = {1, 3, 6, 9}, збільшення набору даних у 5 разів. Набір даних було розділено наступним чином: 70% - вибірка для тренування, 15% – вибірка для оцінки на етапі навчання, а також 15% унікальних зображень для тестування моделі на абсолютно нових для неї даних. На рисунку 4 наведено одне із сегментованих зображень.




Рисунок 4 – Приклад сегментації зображення базовою моделлю: оригінальне зображення, ідеальна сегментація і вихідне зображення

Було проведено декілька експериментів із різними параметрами моделі й набору даних, найкращі результати з усіх епох навчання занесені у табл. 1.

Згідно проведених досліджень впливає позитивний вплив використаної комбінованої функції втрати, що враховує як CSE, так і Dice Loss. Також невелике збільшення Dropout обмежено покращує сегментацію, що можна побачити по відповідним метрикам IoU. Порівнюючи найкращі моделі з базовою, вдалося досягти приросту 3.8% середнього IoU, 4% IoU вцілілих будівель, а також 5.3% для зруйнованих.

Модуль ASPP має незначний позитивний вплив на точність сегментації і дозволяє отримувати більш рівномірні краї об'єктів. Водночас збільшення кількості фільтрів сповільнює процес навчання і погіршує точність сегментації з аналогічними параметрами. Але варто відзначити потенційно позитивну динаміку при збільшенні Dropout і кількості епох, що врівноважує модель і сповільнює перенавчання з часом.

В рамках експерименту було побудовано різні маски невизначеності (рис. 5) на основі відповідних формул (5-7), у даному випадку порядок наступний: на основі прогностичної ентропії, дисперсії та взаємної інформації. Як можна побачити, кожен метод має власні особливості розрахунків, а отже й відображення усереднених невизначеностей навіть для одного й того ж зображення.

Порівняльна таблиця побудованих моделей з розрахованими метриками

Функція втрат	Інші параметри	Loss		IoU aged		IoU Intact		IoU Mean	
		Val	Test	Val	Test	Val	Test	Val	Test
CCE	Базова модель	0.275	<b>0.269</b>	0.415	<b>0.395</b>	0.418	<b>0.406</b>	0.546	<b>0.539</b>
	32 фільтри, 0.2 dropout, 10 аугмент.	0.232	<b>0.224</b>	0.436	<b>0.43</b>	0.42	<b>0.409</b>	0.55	<b>0.546</b>
	32 фільтри, 0.3 dropout, 10 аугмент. *	0.147	<b>0.146</b>	0.462	<b>0.453</b>	0.47	<b>0.45</b>	0.586	<b>0.577</b>
	32 фільтри, 0.4 dropout, 10 аугмент.	0.155	<b>0.153</b>	0.437	<b>0.43</b>	0.436	<b>0.423</b>	0.557	<b>0.553</b>
Combined loss	Базова модель	0.256	<b>0.245</b>	0.41	<b>0.404</b>	0.413	<b>0.427</b>	0.559	<b>0.555</b>
	32 фільтри, 0.2 dropout, 10 аугмент.	0.227	<b>0.221</b>	0.431	<b>0.423</b>	0.42	<b>0.399</b>	0.56	<b>0.552</b>
	32 фільтри, 0.3 dropout, 10 аугмент.	0.204	<b>0.199</b>	0.454	<b>0.448</b>	0.462	<b>0.446</b>	0.582	<b>0.577</b>
	32 фільтри, 0.4 dropout, 10 аугмент. **	0.201	<b>0.196</b>	0.456	<b>0.448</b>	0.459	<b>0.444</b>	0.584	<b>0.577</b>




Рисунок 5 – Дослідження різних методів побудови масок невизначеності для сегментаційної моделі на основі MCD

Окремо в рамках дослідження було створено алгоритм генерації нової сегментаційної маски (останнє зображення на рис. 5), який враховував два порогових значення, а саме впевненості моделі у належності кожного пікселя до відповідного класу, а також відповідне значення невизначеності моделі для кожного пікселя на основі побудованої усередненої маски невизначеності. Розраховані чисельні показники вказують як на можливе покращення сегментації, так і її погіршення, в залежності від деяких умов, що можуть включати як особливості самого зображення, так і обраного методу, а також будови й налаштувань самої моделі.

Таким чином можна стверджувати про потенційно позитивний вплив застосованого підходу на основі невизначеності, отриманих за допомогою методу MCD. В свою чергу, для подальшого практичного застосування підходу на практиці, існує необхідність більш глибокого дослідження впливу різних параметрів моделі на сегментацію вихідного зображення, а також розрахункових формул невизначеностей.

**Висновки.** Завдання оцінки пошкоджень і збитків – складний і трудомісткий процес. Сучасні технології і моделі дозволяють автоматизувати визначення об'єктів на зображеннях, так найбільшого поширення набули згорткові нейронні мережі, зокрема архітектура U-Net. Існує багато досліджень модифікації і вдосконалення архітектури U-Net, наприклад, за допомогою механізмів уваги, додаткових модулів або підгонці параметрів моделі, водночас дослідження оцінки невизначеності сегментаційних моделей все ще потребує розвитку.

У статті розглянуто побудову модифікованої архітектури U-Net із модулем ASPP замість bottleneck, а також застосування множинних проходжень із активним дропаутом (MCD) для отримання показників невизначеності. Використовуючи розрахункові формули дисперсії, ентропії та взаємної інформації, були побудовані відповідні сегментаційні маски невизначеності, які були використані для покращення результатів.

Відмічено позитивний вплив модуля ASPP на визначення форми об'єктів на зображеннях, а також застосування комбінованої функції витрат. У ході експерименту вдалося досягти приросту 3.8% середнього IoU, 4% IoU вцілілих будівель, а також 5.3% для зруйнованих будівель у порівнянні з базовою моделлю. Побудовані маски невизначеності були проаналізовані як візуально, так й оцінені кількісно, а також використані в запропонованому методі покращення сегментації, який спирається на застосування двох порогів для попиксельного відображення ділянок із найбільшим рівнем впевненості й низькою невизначеністю. Доцільно продовжити дослідження описаних методів і підходів для подальшого впровадження їх у практику.

#### ЛІТЕРАТУРА

1. Moreno González, C. L., Montoya, G. A., & Lozano Garzón, C. (2025). Toward reliable post-disaster assessment: Advancing building damage detection using You Only Look Once convolutional neural network and satellite imagery. *Mathematics*, 13, 1041. <https://doi.org/10.3390/math13071041>.
2. Liu, J., Luo, Y., Chen, S., Wu, J., & Wang, Y. (2024). BDHE-Net: A novel building damage heterogeneity enhancement network for accurate and efficient post-earthquake assessment using aerial and remote sensing data. *Applied Sciences*, 14, 3964.

<https://doi.org/10.3390/app14103964>.

3. Mazurets, O., Molchanova, M., Shurypa, M., & Sobko, O. (2026). Devising a neural-network method for assessing the condition of destroyed buildings using images from unmanned aerial vehicles. *Eastern-European Journal of Enterprise Technologies*, 1(2(139)), 6–16. <https://doi.org/10.15587/1729-4061.2026.351605>
4. Deng, L., & Wang, Y. (2022). Post-disaster building damage assessment based on improved U-Net. *Scientific Reports*, 12, 15862. <https://doi.org/10.1038/s41598-022-20114-w>.
5. Yang, Q., Wang, Z., Liu, S., & Li, Z. (2024). Research on improved U-net based remote sensing image segmentation algorithm. *arXiv*. <https://doi.org/10.48550/arXiv.2408.12672>.
6. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), 1904–1916. <https://doi.org/10.48550/arXiv.1406.4729>.
7. Gal, Y., & Ghahramani, Z. (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. In *Proceedings of the 33rd International Conference on Machine Learning* (Vol. 48, pp. 1050–1059). <https://doi.org/10.48550/arXiv.1506.02142>.
8. Rey, M., Mnih, A., Neumann, M., Overlan, M., & Purves, D. (2025). Uncertainty evaluation of segmentation models for Earth observation. *arXiv*. <https://doi.org/10.48550/arXiv.2510.19586>.
9. Dechesne, C., Lassalle, P., & Lefèvre, S. (2021). Bayesian U-Net: Estimating uncertainty in semantic segmentation of Earth observation images. *Remote Sensing*, 13(19), 3836. <https://doi.org/10.3390/rs13193836>.
10. Saidu, C., & Csató, L. (2021). Active learning with Bayesian U-Net for efficient semantic image segmentation. *Journal of Imaging*, 7(2), 37. <https://doi.org/10.3390/jimaging7020037>.
11. Saifullah, S., & Dreżewski, R. (2026). Bayesian optimization-driven U-Net architecture tuning for brain tumor segmentation. In *Proceedings of the 6th International Electronic Conference on Applied Sciences* (Eng. Proc., 124(1), 22). <https://doi.org/10.3390/engproc2026124022>.

#### REFERENCES

1. Moreno González, C. L., Montoya, G. A., & Lozano Garzón, C. (2025). Toward reliable post-disaster assessment: Advancing building damage detection using You Only Look Once convolutional neural network and satellite imagery. *Mathematics*, 13, 1041. <https://doi.org/10.3390/math13071041>.
2. Liu, J., Luo, Y., Chen, S., Wu, J., & Wang, Y. (2024). BDHE-Net: A novel building damage heterogeneity enhancement network for accurate and efficient post-earthquake assessment using aerial and remote sensing data. *Applied Sciences*, 14, 3964. <https://doi.org/10.3390/app14103964>.
3. Mazurets, O., Molchanova, M., Shurypa, M., & Sobko, O. (2026). Devising a neural-network method for assessing the condition of destroyed buildings using images from unmanned aerial vehicles. *Eastern-European Journal of Enterprise Technologies*, 1(2(139)), 6–16. <https://doi.org/10.15587/1729-4061.2026.351605>

4. Deng, L., & Wang, Y. (2022). Post-disaster building damage assessment based on improved U-Net. *Scientific Reports*, 12, 15862. <https://doi.org/10.1038/s41598-022-20114-w>.
5. Yang, Q., Wang, Z., Liu, S., & Li, Z. (2024). Research on improved U-net based remote sensing image segmentation algorithm. *arXiv*. <https://doi.org/10.48550/arXiv.2408.12672>.
6. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Spatial pyramid pooling in deep convolutional networks for visual recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9), 1904–1916. <https://doi.org/10.48550/arXiv.1406.4729>.
7. Gal, Y., & Ghahramani, Z. (2016). Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. In *Proceedings of the 33rd International Conference on Machine Learning* (Vol. 48, pp. 1050–1059). <https://doi.org/10.48550/arXiv.1506.02142>.
8. Rey, M., Mnih, A., Neumann, M., Overlan, M., & Purves, D. (2025). Uncertainty evaluation of segmentation models for Earth observation. *arXiv*. <https://doi.org/10.48550/arXiv.2510.19586>.
9. Dechesne, C., Lassalle, P., & Lefèvre, S. (2021). Bayesian U-Net: Estimating uncertainty in semantic segmentation of Earth observation images. *Remote Sensing*, 13(19), 3836. <https://doi.org/10.3390/rs13193836>.
10. Saidu, C., & Csató, L. (2021). Active learning with Bayesian U-Net for efficient semantic image segmentation. *Journal of Imaging*, 7(2), 37. <https://doi.org/10.3390/jimaging7020037>.
11. Saifullah, S., & Dreżewski, R. (2026). Bayesian optimization-driven U-Net architecture tuning for brain tumor segmentation. In *Proceedings of the 6th International Electronic Conference on Applied Sciences (Eng. Proc., 124(1), 22)*. <https://doi.org/10.3390/engproc2026124022>.

Received 17.04.2026.  
Accepted 22.04.2026.  
Published 30.04.2026

### ***Uncertainty-based image segmentation using U-Net architecture and Monte Carlo Dropout***

*Historically, convolutional neural networks have been widely used to solve image object recognition problems, in particular for preliminary damage analysis after natural disasters. The U-Net architecture has become one of the popular solutions for image segmentation; in recent years, many studies and modifications of this model have proposed, using both attention mechanisms and separate modules to improve classification results. At the same time, research into uncertainty assessment and explanation of the operation of segmentation models still need to be deepened, which is why this work is relevant.*

*Although increasing accuracy and efficiency is an important component of any model, in tasks such as preliminary damage and loss analysis, the assessment of confidence, or uncertainty, is one of the decisive factors, since it can be used for further decision-making. The purpose of the study is to build a segmentation model of the modified U-Net architecture with the ASPP module, taking into account uncertainty by multiple runs of the model with different dropout masks (Monte Carlo Dropout) for preliminary analysis of damaged buildings in images.*

*The paper presents a study of the modified U-Net architecture with the replacement of the bottleneck with the ASPP module and the use of Monte Carlo Dropout. Based on the cal-*

*ulation formulas of variance, entropy and mutual information, uncertainty maps were formed, which were used to improve segmentation. It is shown that ASPP increases the accuracy of object shape detection, and the combined loss function contributes to improving segmentation. In the experiments, an increase of 3.8% of the average IoU was achieved, 4% for surviving and 5.3% for destroyed buildings. The uncertainty masks were analyzed and used in the method with two threshold values of confidence and model uncertainty to select the most reliable areas. For the practical implementation of the described methods and approaches, there is a need for their further study.*

*Keywords: damaged building detection, convolutional neural networks, computer vision, semantic segmentation, Monte Carlo Dropout, ASPP, U-Net, Google Earth.*

**Димо Валерій Володимирович** – аспірант кафедри інтелектуальних інформаційних систем Чорноморського національного університету ім. Петра Могили.

ORCID: <https://orcid.org/0009-0001-6024-3018>.

**Гожий Олександр Петрович** – доктор технічних наук, професор кафедри інтелектуальних інформаційних систем Чорноморського національного університету ім. Петра Могили.

ORCID: <https://orcid.org/0000-0002-3517-580X>.

**Dymo Valerii Volodymyrovych** – postgraduate student of the Department of Intellectual Information Systems of Petro Mohyla Black Sea National University.

ORCID: <https://orcid.org/0009-0001-6024-3018>.

**Gozhyj Aleksandr Petrovych** – Doctor of Technical Sciences, Professor of the Department of Intellectual Information Systems of the Petro Mohyla Black Sea National University.

ORCID: <https://orcid.org/0000-0002-3517-580X>.