

## МЕТОДИ ВІЗУАЛЬНОГО ВИЯВЛЕННЯ ПІДОЗРЛИХ РАДІОАКТИВНИХ ОБ'ЄКТІВ

С.В. Співак, Д.О. Белицький, Р.В. Єрмоленко

*Київський національний університет імені Тараса Шевченка, фізичний факультет, кафедра ядерної фізики та високих енергій, Київ, Україна*

Ефективне виявлення радіоактивних матеріалів є важливою задачею у сфері ядерної безпеки та радіаційного моніторингу. У більшості існуючих систем пошуку використовуються детектори гамма-випромінювання, здатні реєструвати джерела іонізуючого випромінювання за наявності достатнього рівня сигналу. Проте ефективність таких систем може суттєво знижуватися у випадках значного екранування джерела або низької інтенсивності випромінювання. У подібних умовах для накопичення статистично значущого сигналу може знадобитися збільшення часу вимірювання, що ускладнює оперативний пошук джерел на великих територіях або за невідомого місцезнаходження об'єкта. Щоб подолати це обмеження, візуальний огляд може служити першим кроком. Визначаючи області або об'єкти, що цікавлять, на основі зовнішнього вигляду, пошукові зусилля можна звузити до керованого набору «кандидатів» для подальшого радіологічного скринінгу. [1], [2]

Спіраючись на цю ідею, ми пропонуємо використовувати методи візуального розпізнавання на основі машинного навчання для автоматизації виявлення та визначення пріоритетів потенційно забруднених об'єктів. Нещодавні досягнення в галузі машинного навчання пропонують багатообіцяючі можливості для покращення ідентифікації та відстеження забруднених об'єктів. [3] Надійне виявлення об'єктів значною мірою залежить від різноманітності набору даних. Було визначено два цільові класи:

- Знак радіації: Обмежувальні рамки, що містять лише символ радіаційної небезпеки.
- Радіоактивний об'єкт: Об'єкти, що містять знак радіаційної небезпеки, напис «радіоактивний» або об'єкти без чіткого позначення, але класифіковані як радіоактивні на основі їх походження.

Початковий набір даних було зібрано з відкритих джерел вручну з приблизно 130 зображень (Рис. 1 та Рис. 2). Хоча цей набір забезпечив перший етап досліджень, його розміру було недостатньо для ефективного навчання моделей глибокого навчання, враховуючи вимогу суттєвої різноманітності даних для забезпечення надійної продуктивності. Щоб подолати це обмеження, набір даних було доповнено синтетично згенерованими зображеннями, тим самим збільшивши як обсяг, так і варіабельність навчального набору. Отриманий гібридний набір даних містить реальні та синтетично згенеровані зразки, забезпечуючи мінливість зовнішнього вигляду об'єкта, навколишнього середовища та умов візуалізації. Включення синтетичних даних ще більше покращує продуктивність, хоча спостережувані покращення залишаються помірними. Серед оцінених архітектур YOLO12 досягає найвищої загальної продуктивності, перевершуючи старішу архітектуру «v8», результати наведені у Таблиці 1.



Рис. 1. Приклад зображення радіоактивного об'єкта.



Рис. 2. Приклад зображення зі знаком радіації.

Розширення навчального набору синтетичними зображеннями не тільки призвело до покращення точності прогнозування, але й суттєво розширила набір даних, тим самим зменшивши статистичну

мінливість під час оптимізації. Це покращення стабільності дозволило включити додаткову підмножину зображень COCO — 80–100 на клас — зберігаючи стабільність навчання.

Табл. 1. Порівняльні метрики натренованих моделей YOLOv8 та YOLOv12 для різних конфігурацій набору даних (вручну сформований, гібридний, гібридний+COCO (HyCOCO)).

Model	Dataset type	mAP@50	mAP@50:95
		YOLOv8/12	YOLOv8/12
S	Manual	0.680/0.668	0.371/0.392
	Hybrid	0.694/0.698	0.404/0.397
	HyCOCO	0.725/0.695	0.412/0.421
L	Manual	0.734/0.704	0.4/0.415
	Hybrid	0.727/0.727	0.429/0.438
	HyCOCO	0.773/0.775	0.470/0.476
X	Manual	0.729/0.670	0.400/0.39
	Hybrid	0.729/0.654	0.405/0.395
	HyCOCO	0.789/0.762	0.455/0.464

Запропонований підхід показав, що використання реальних і синтетично згенерованих зображень у навчальному наборі покращує результати виявлення в складних умовах. Згенеровані дані дозволяють частково компенсувати обмежений обсяг доступних даних та підвищити стійкість моделі до варіацій у зображеннях. Отримані результати свідчать про перспективність використання генеративних моделей для задач виявлення потенційно небезпечних об'єктів у сфері ядерної безпеки та радіаційного моніторингу.

1. International Atomic Energy Agency. The Radiological Accident in Lia, Georgia. Vienna, Austria: international Atomic Energy Agency, 2014. URL: <https://www-pub.iaea.org/MTCD/Publications/PDF/Pub1660web-81061875.pdf>
2. International Atomic Energy Agency. The Radiological Accident in Istanbul. Vienna, Austria: International Atomic Energy Agency, 2000. URL: [https://www-pub.iaea.org/MTCD/Publications/PDF/Pub1102\\_web.pdf](https://www-pub.iaea.org/MTCD/Publications/PDF/Pub1102_web.pdf)
3. Shekoofeh Azizi et al. Synthetic Data from Diffusion Models Improves ImageNet Classification.2023. arXiv: [2304.08466 \[cs.CV\]](https://arxiv.org/abs/2304.08466). url: <https://arxiv.org/abs/2304.08466>