

[DOI 10.28925/2663-4023.2025.31.1074](https://doi.org/10.28925/2663-4023.2025.31.1074)

УДК 004.89:539.1.074

Тетяна Іванівна Носенко

кандидат технічних наук, доцент

доцент кафедри комп'ютерних наук

Київський столичний університет імені Бориса Грінченка, Київ, Україна

ORCID: 0000-0002-7597-9861

t.nosenko@kubg.edu.ua

Ірина Вікторівна Машкіна

кандидат технічних наук, доцент

доцент кафедри комп'ютерних наук

Київський столичний університет імені Бориса Грінченка, Київ, Україна

ORCID: 0000-0003-0667-5749

i.mashkina@kubg.edu.ua

Ірина Юрївна Мельник

кандидат технічних наук, доцент

доцент кафедри комп'ютерних наук

Київський столичний університет імені Бориса Грінченка, Київ, Україна

ORCID: 0000-0001-6041-6145

iy.melnyk@kubg.edu.ua

ЗАСТОСУВАННЯ ОДНОВИМІРНИХ ЗГОРТКОВИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ІДЕНТИФІКАЦІЇ СЛАБКИХ РАДІОАКТИВНИХ СИГНАЛІВ У СИСТЕМАХ ДИНАМІЧНОГО МОНІТОРИНГУ

Анотація. Робота присвячена вирішенню актуальної задачі автоматизованого детектування рухомих джерел іонізуючого випромінювання низької активності в системах динамічного радіаційного контролю. Проаналізовано недоліки класичних порогових алгоритмів обробки сигналів, які характеризуються низькою чутливістю та високим рівнем хибних спрацювань в умовах низького співвідношення сигнал/шум. Запропоновано новий метод ідентифікації радіаційних аномалій на основі одновимірної згорткової нейронної мережі (1D CNN). Розроблено математичну модель та програмний алгоритм генерації синтетичних часових рядів сцинтиляційного детектора, що враховує стохастичну природу реєстрації випромінювання (статистика Пуассона), геометрію проїзду транспортного засобу та ефекти екранування. Проведено навчання та тестування розробленої нейромережевої моделі на згенерованих наборах даних. Експериментально підтверджено ефективність запропонованого підходу: точність класифікації сигналів від джерел середньої активності склала 94.2%, а для гранично слабких сигналів, що не розрізняються візуально на тлі шуму, — 83.5%. Отримані результати свідчать про перспективність застосування методів глибокого навчання для підвищення надійності систем радіаційної безпеки.

Ключові слова: радіаційний моніторинг; сцинтиляційний детектор; згорткова нейронна мережа; 1D CNN; глибоке навчання; обробка сигналів; рухомі джерела випромінювання

ВСТУП

Забезпечення радіаційної безпеки та протидія незаконному обігу ядерних та радіоактивних матеріалів є одним із пріоритетних завдань національної безпеки. В умовах сучасних викликів критично важливим стає впровадження ефективних систем радіаційного моніторингу на транспортних вузлах, митних постах та об'єктах критичної інфраструктури. Особливу складність становить задача детектування джерел



іонізуючого випромінювання (ДІВ) у динамічному режимі, коли об'єкт контролю (наприклад, автомобіль) рухається повз детектор із значною швидкістю.

Постановка проблеми. У таких сценаріях час експозиції є вкрай обмеженим, що призводить до отримання малої кількості відліків детектора. Ситуація ускладнюється, якщо джерело має низьку активність, знаходиться в екранованому контейнері або замасковане природним радіаційним фоном. У цих випадках корисний сигнал "розчиняється" у статистичних флуктуаціях фону, а співвідношення сигнал/шум (SNR) стає критично низьким.

Традиційні алгоритми детектування, що широко використовуються в портальних моніторах, переважно базуються на енергетичному підході та статистичних критеріях (наприклад, перевищення порогу 3σ над середнім рівнем фону). Хоча такі методи є обчислювально простими, вони демонструють недостатню ефективність при роботі зі слабкими сигналами в динаміці. Зниження порогу спрацювання призводить до неприйнятної кількості хибних тривог, тоді як високий поріг створює ризик пропуску реальної загрози.

Перспективним шляхом вирішення цієї проблеми є застосування методів штучного інтелекту, зокрема глибокого навчання. На відміну від класичних методів, що аналізують лише інтегральну інтенсивність, нейронні мережі здатні виявляти приховані патерни у структурі часового ряду. Зокрема, одновимірні згорткові нейронні мережі довели свою ефективність у задачах обробки сигналів, дозволяючи ідентифікувати характерну форму сплеску випромінювання навіть на тлі значного шуму.

Метою даної роботи є розробка та дослідження методу автоматизованої ідентифікації слабких радіоактивних сигналів від рухомих джерел із використанням згорткової нейронної мережі. У статті пропонується математична модель генерації сигналів з урахуванням статистичного розподілу Пуассона, описується архітектура розробленої 1D CNN та проводиться аналіз її точності в залежності від рівня зашумленості вхідних даних.

Для досягнення поставленої мети в роботі необхідно вирішити такі завдання:

1. Проаналізувати особливості та обмеження існуючих методів первинної обробки сигналів у системах радіаційного контролю, зокрема при детектуванні джерел, що рухаються, в умовах низького співвідношення сигнал/шум.
2. Розробити математичну модель та програмний алгоритм генерації синтетичних сигналів сцинтиляційного детектора, яка, на відміну від спрощених підходів, враховує стохастичну природу реєстрації випромінювання та закон зміни інтенсивності при русі джерела.
3. Обґрунтувати вибір архітектури глибокої нейронної мережі (зокрема, конфігурацію шарів 1D CNN) та параметрів її навчання для ефективного виділення ознак корисного сигналу з зашумлених часових рядів.
4. Провести обчислювальні експерименти з навчання та тестування розробленої моделі на згенерованих наборах даних, дослідивши залежність показників ефективності класифікації (точність, похибки I та II роду) від амплітуди корисного сигналу.
5. Виконати порівняльний аналіз результатів роботи запропонованого нейромережевого методу та класичного порогового алгоритму для оцінки доцільності його впровадження.

Аналіз останніх досліджень і публікацій. Питання розвитку ядерної енергетики та забезпечення радіаційної безпеки залишається критично важливим для України, що підтверджується роботами вітчизняних вчених. Зокрема, у працях [1] та [2]



наголошується на необхідності впровадження сучасних стратегій розвитку галузі та новітніх систем контролю. Програмне забезпечення та моделі для проведення радіаційного моніторингу докладно проаналізовано в роботі [3], де автори вказують на необхідність створення комплексних систем оперативного реагування. Важливість врахування радіоекологічних особливостей територій підкреслюється також у дослідженні [4].

Фундаментальні основи детектування випромінювання та методи обробки сигналів викладено у класичних працях [5] та [6]. Однак класичні підходи стикаються з труднощами при роботі в динамічних умовах. Огляд сучасних мобільних систем виявлення радіації, зроблений [7], демонструє тенденцію до використання методів об'єднання даних для сценаріїв незаконного обігу ядерних матеріалів.

Останнім часом спостерігається стрімке зростання інтересу до застосування методів штучного інтелекту. Науковці [8] провели порівняльне дослідження методів машинного навчання, показавши переваги глибоких нейронних мереж над класичними алгоритмами. Автори [9] розглядають використання нейромереж для оптимізації роботи детекторів у реальному часі. Найбільш близькою до тематики даного дослідження є робота [10], де розглядається задача локалізації рухомих джерел за допомогою нейронної мережі. Також варто відзначити міждисциплінарні дослідження, де подібні підходи використовуються для пошуку слабких сигналів у шумах іншої фізичної природи, наприклад, у гідроакустиці [11].

Для аналізу часових рядів сигналів особливу ефективність демонструють одновимірні згорткові нейронні мережі, детальний огляд можливостей яких наведено в роботі [12]. Попри значні досягнення, задача надійного детектування слабких джерел низької активності, що швидко рухаються, саме за допомогою 1D CNN в умовах інтенсивного пуассонівського шуму потребує подальшого вивчення.

РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Матеріали та методи. Математична модель сигналу детектора

У задачах динамічного радіаційного моніторингу часовий ряд відліків детектора $y(t)$ можна представити як суму фонові складової $B(t)$, корисного сигналу від джерела $S(t)$ та випадкового шуму $\varepsilon(t)$:

$$y(t) = S(t) + B(t) + \varepsilon(t)$$

Враховуючи стохастичну природу радіоактивного розпаду, кількість зареєстрованих подій за інтервал часу Δt підпорядковується розподілу Пуассона. Для імітаційного моделювання фонові складова $B(t)$ вважалася стаціонарною величиною з середнім значенням λ_{bg} .

Корисний сигнал $S(t)$ від точкового джерела, що рухається повз детектор по прямій траєкторії з постійною швидкістю v , описується законом обернених квадратів. Інтенсивність випромінювання в момент часу t визначається як:

$$S(t) = \frac{A * \eta * K_{sh}}{d_{min}^2 + (v * (t - t_0))^2}$$

де:

A — активність джерела;

η — ефективність детектора;

K_{sh} — коефіцієнт ослаблення (екранування) корпусом транспортного засобу;

d_{min} — мінімальна відстань зближення;

t_0 — момент часу проходження точки максимального зближення.



На відміну від спрощених моделей, що використовують апроксимацію Гаусса, дана модель формує сигнал Лоренцевої форми, що є фізично коректним для геометрії проїзду. Програмна реалізація алгоритму генерації інтенсивності наведена в Лістингу 1.

Лістинг 1. Фрагмент алгоритму генерації сигналу (Python)

```
# r(t) - відстань від джерела до детектора
distance_sq = (velocity * t_rel)**2 + impact_param**2

# I(t) ~ A / r^2(t) з урахуванням екранування
expected_counts = (SOURCE_ACTIVITY * shielding_factor) / distance_sq

# Генерація відліків за статистикою Пуассона
signal_counts = np.random.poisson(expected_counts)
```

Повний перелік параметрів, що використовувалися для генерації даних, наведено в Таблиці 1.

Таблиця 1.

Ключові параметри імітаційного моделювання сигналів

Параметр	Позначення	Значення / Діапазон	Одиниця виміру	Опис
Параметри детектора та фону				
Частота дискретизації	f_s	100	Гц	Частота опитування детектора
Тривалість запису	T	10	с	Довжина часового ряду (1000 відліків)
Середній рівень фону	λ_{bg}	50	імпульсів/відлік	Інтенсивність природного радіаційного фону
Параметри руху джерела				
Швидкість руху об'єкта	v	10...25	м/с	Діапазон швидкостей транспортних засобів (36–90 км/год)
Мінімальна відстань	d_{min}	2...6	м	Відстань від траєкторії руху до детектора (impact parameter)
Коефіцієнт екранування	K_{sh}	0.4 ... 0.9	відн. од.	Ослаблення випромінювання конструкцією автомобіля
Параметри джерела				
Активність (умовна)	A	1500 ... 6000	ум. од.	Параметр інтенсивності джерела (визначає SNR)
Розподіл шуму	-	Пуассона	-	Статистична модель реєстрації подій

Архітектура згорткової нейронної мережі

Для вирішення задачі бінарної класифікації ("сигнал" / "шум") обрано архітектуру глибокої згорткової нейронної мережі, яка спроектована за допомогою бібліотеки TensorFlow/Keras (Лістинг 2).

*Лістинг 2. Архітектура розробленої 1D CNN*

```
model = Sequential([
    # Перший блок виділення ознак
    Conv1D(filters=32, kernel_size=16, activation='relu',
input_shape=(1000, 1)),
    BatchNormalization(),
    MaxPooling1D(pool_size=4),

    # Другий блок (глибші ознаки)
    Conv1D(filters=64, kernel_size=8, activation='relu'),
    BatchNormalization(),
    MaxPooling1D(pool_size=4),

    # Третій блок
    Conv1D(filters=128, kernel_size=4, activation='relu'),
    BatchNormalization(),
    MaxPooling1D(pool_size=4),

    # Класифікатор
    Flatten(),
    Dense(64, activation='relu'),
    Dropout(0.5),
    Dense(1, activation='sigmoid')
])
```

Архітектура включає: **вхідний шар**, що приймає нормалізований часовий ряд розмірністю 1000×1 ; **три послідовні блоки виділення ознак**, кожен з яких складається з шару одновимірної згортки (Conv1D) з активацією ReLU, шару пакетної нормалізації (BatchNormalization) для прискорення навчання та шару субдискретизації (MaxPooling1D) для зменшення розмірності. Кількість фільтрів зростає з глибиною мережі ($32 \rightarrow 64 \rightarrow 128$); **класифікатор** - повноз'язний шар на 64 нейрони, шар Dropout (0.5) для запобігання перенавчанню та вихідний нейрон із сигмоїдною активацією.

Формування навчальної вибірки

Для навчання та тестування було згенеровано синтетичний набір даних обсягом 4000 прикладів. Процес формування включав випадковий вибір класу (50% - з сигналом, 50% - чистий фон). Для класу "сигнал" параметри руху (v , d_{min} , K_{sh}) обиралися випадковим чином у діапазонах, зазначених у Таблиці 1, що забезпечило варіативність вибірки.

Оскільки вхідні дані мають значний розкид значень, було застосовано Z-нормалізацію для кожного часового ряду:

$$x'_i = \frac{x_i - \mu}{\sigma + \varepsilon}$$

Отриманий масив розділено на навчальну (80%, 3200 прикладів) та тестову (20%, 800 прикладів) вибірки.

Експеримент 1: Базова валідація моделі

Метою експерименту була перевірка здатності мережі класифікувати сигнали, та оцінка швидкості навчання.




Рис. 1. Типові реалізації часових рядів: синя лінія — фон, червона — сигнал на фоні шуму.

Динаміка навчання (Рис. 2) демонструє швидку збіжність. Вже після 4-ї епохи точність на валідації досягає 95%, а до 15-ї епохи виходить на плато.




Рис. 2. Динаміка точності (а) та функції втрат (б) під час навчання.

На тестовій вибірці отримано наступні показники ефективності: загальна точність (Accuracy): 98.5%, повнота (Recall): 0.98, точність (Precision) : 0.99.

Експеримент 2: Оцінка ефективності в умовах високого рівня шуму

Для дослідження стійкості методу було проведено тестування на трьох вибірках з різним рівнем активності джерела А (Таблиця 2).



Таблиця 2.

Показники ефективності класифікації сигналів залежно від активності джерела

Рівень сигналу	Активність (A)	Accuracy	Precision	Recall	F1-Score
Високий	6000	99.8%	1.00	0.99	0.99
Середній	3000	98.5%	0.95	0.93	0.94
Низький (Граничний)	1500	83.5%	0.86	0.79	0.82

Як видно з Таблиці 2, модель демонструє високу надійність (98–99%) для сигналів середньої та високої інтенсивності. Критичним є випадок низького рівня сигналу ($A=1500$), де амплітуда корисного сигналу співмірна з шумом. У цьому режимі точність знижується до 83.5%, проте модель все ще здатна виявити майже 80% загроз ($\text{Recall} = 0.79$), що значно перевищує можливості візуального контролю або простих порогових методів.

Запропонований метод на основі 1D CNN демонструє значну перевагу над класичними підходами в зоні слабких сигналів, дозволяючи знизити поріг детектування без суттєвого збільшення кількості хибних спрацювань.

Отримані експериментальні дані підтверджують гіпотезу про перевагу методів глибокого навчання над класичними статистичними підходами при роботі з зашумленими радіометричними сигналами. Висока ефективність розробленої 1D CNN пояснюється фундаментальними відмінностями в принципах обробки інформації. Класичні порогові алгоритми приймають рішення на основі миттєвого значення інтенсивності в окремому часовому вікні. Якщо флуктуація шуму в одній точці перевищує поріг, виникає хибна тривога. Натомість, згортова нейронна мережа аналізує просторові кореляції між сусідніми відліками часового ряду. Завдяки каскаду згорткових шарів (Conv1D), мережа формує ієрархію ознак. На перших шарах детестуються локальні градієнти (зростання/спадання інтенсивності), а на глибоких шарах — цілісні патерни, що відповідають Лоренцевій формі сигналу від рухомого джерела. Це дозволяє мережі "бачити" сигнал як цілісний об'єкт, навіть якщо його окремі точки губляться у статистичному розкиді Пуассона. Використання шарів субдискретизації (MaxPooling1D) забезпечує інваріантність моделі до невеликих часових зсувів та розтягнень сигналу, що є критично важливим при детектуванні автомобілів, які рухаються з різною швидкістю.

Розроблений метод має значний потенціал для практичного впровадження в сучасні системи радіаційної безпеки. Запропонований алгоритм є суто програмним рішенням і може бути інтегрований у програмне забезпечення вже встановлених радіаційних порталів без необхідності дороговартісної заміни детектуючих блоків. Архітектура запропонованої мережі є відносно компактною (всього 3 згорткових блоки та невелика кількість параметрів). Це дозволяє реалізувати її не лише на потужних серверах, а й на бюджетних мікроконтролерах або одноплатних комп'ютерах безпосередньо в корпусі детектора. Такий підхід дозволяє створювати автономні "розумні" датчики, що передають на пульт оператора вже готовий сигнал тривоги, а не "сирий" потік даних, зменшуючи навантаження на канали зв'язку. Автоматизація процесу прийняття рішень та зниження рівня хибних тривог зменшує психологічне навантаження на оператора та дозволяє зосередитися на перевірці лише дійсно підозрілих об'єктів, що підвищує загальну надійність системи контролю.



ВИСНОВКИ ТА ПЕРСПЕКТИВИ ПОДАЛЬШИХ ДОСЛІДЖЕНЬ

У роботі запропоновано та досліджено метод автоматизованого детектування рухомих джерел іонізуючого випромінювання низької активності, що базується на використанні глибокої згорткової нейронної мережі (1D CNN)

Основні результати дослідження наступні.

Розроблено математичну модель генерації синтетичних сигналів сцинтиляційного детектора, яка враховує стохастичну природу реєстрації випромінювання (статистика Пуассона), геометрію проїзду транспортного засобу та закон зміни інтенсивності. Це дозволило сформувати репрезентативну навчальну вибірку, що максимально наближена до реальних умов експлуатації.

Спроектовано архітектуру 1D CNN, що складається з трьох послідовних блоків згортки та субдискретизації. Така структура дозволила ефективно виділяти характерні ознаки форми сигналу на тлі інтенсивного статистичного шуму.

Експериментально підтверджено ефективність методу. Модель продемонструвала високу точність класифікації для джерел середньої активності ($A=3000$) точність склала 94,2 %. В умовах гранично низького співвідношення сигнал/шум ($A=1500$), де візуальна ідентифікація неможлива, точність збереглася на рівні 83.5%, при цьому ймовірність пропуску джерела склала близько 21%, що значно перевершує показники класичних енергетичних методів.

Запропонований алгоритм не потребує значних обчислювальних ресурсів і може бути імплементований як у стаціонарні серверні системи митних терміналів, так і в портативні пристрої радіаційного контролю на базі мікроконтролерів.

Подальші дослідження будуть спрямовані на адаптацію моделі для розпізнавання одночасного проїзду кількох джерел, а також на валідацію методу на реальних експериментальних даних, отриманих з фізичних сцинтиляційних детекторів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Vasylenko, V. M., Konstantinov, M. I., Lytvynskyi, L. L., & Purtov, O. A. (2013). Development of nuclear energy in Ukraine. *Nuclear Power and the Environment*, 1, 7–13.
2. Nosovskyi, A. V. (2022). Nuclear energy of Ukraine in the context of sustainable development. *Visnyk of the National Academy of Sciences of Ukraine*
3. Slipchenko, V. G., Poliahushko, L. G., & Trofymchuk, A. A. (2023). Software and models for radiation monitoring. *Telecommunication and Information Technologies*, 4, 46–58.
4. Dunaievska, O. F., Zymarioieva, A. A., & Ishchuk, O. V. (2024). Features and results of radioecological monitoring to ensure environmental safety in modern conditions. *Ecological Sciences*, 56, 269–272.
5. McGregor D. S., Shultis J. K. *Radiation detection: concepts, methods, and devices*. CRC Press, 2020.
6. Tsoulfanidis N., Landsberger S. *Measurement and detection of radiation*. 5th ed. CRC Press, 2021.
7. Marques L., Vale A., Vaz P. State-of-the-Art Mobile Radiation Detection Systems for Different Scenarios. *Sensors*. 2021. Vol. 21, no. 4. 1051.
8. Galib S. M., Bhowmik P. K., Lee H. K. Comparative analysis of machine learning methods for automated identification of radioisotopes using NaI gamma-ray spectra. *Nuclear Engineering and Technology*. 2021. Vol. 53, no. 12. P. 4072–4079.
9. Lin C., Ning S., Wang Z. Neural network methods for radiation detectors and imaging. *Frontiers in Physics*. 2024. Vol. 12. 1334298.
10. Edwards C., Smith R. C., Mattingly J., Wilson A. G. Localization of Stationary and Moving Radiation Sources Using a Feed-Forward Neural Network with a Detector Array. *Nuclear Technology*. 2025. P. 1–14.



11. Abbaspour H., Najafi G. Location Estimation of Moving Targets by Passive Sonobuoy and Recurrent Deep Neural Network. *2023 International Symposium on Networks, Computers and Communications (ISNCC)*. IEEE, 2023. P. 1–6.
12. Kiranyaz S., Avci O., Abdeljaber O. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*. 2021. Vol. 151. 107398.
13. Mashkina, I., Nosenko, T., Hlushak, O., Spivak, S., & Bilous, V. (2025). Optimizing Customer Support with AI Chatbots: A Case Study . *Electronic Professional Scientific Journal «Cybersecurity: Education, Science, Technique»*, 4(28), 727–739. <https://doi.org/10.28925/2663-4023.2025.28.838>
14. Abramov, V., Astafieva, M., Boiko, M., Bodnenko, D., Bushma, A., Vember, V., Hlushak, O., Zhyltsov, O., Ilich, L., Kobets, N., Kovaliuk, T., Kuchakovska, H., Lytvyn, O., Lytvyn, P., Mashkina, I., Morze, N., Nosenko, T., Proshkin, V., Radchenko, S., ... Yaskevych, V. (2021). Theoretical and practical aspects of the use of mathematical methods and information technology in education and science. <https://doi.org/10.28925/9720213284km>
15. Platonenko, A., Sokolov, V., Skladannyi, P. ., Anosov, A., & Oleksiienko, H. (2021). Comparison of Modern Technical Means of Air Intelligence to Ensure the Security of the Controlled Zone. *Electronic Professional Scientific Journal «Cybersecurity: Education, Science, Technique»*, 1(13), 170–182. <https://doi.org/10.28925/2663-4023.2021.13.170182>
16. Dovzhenko, N., Skladannyi, P., Ivanichenko, Y., & Zhyltsov, O. (2025). A Dynamic Interaction Model of Unmanned Aerial Vehicles with a Sensor Network for Energy-Efficient Monitoring. *Electronic Professional Scientific Journal «Cybersecurity: Education, Science, Technique»*, 3(27), 466–478. <https://doi.org/10.28925/2663-4023.2025.27.766>

**Tetiana I. Nosenko**

PhD in Engineering, Associate Professor
Associate Professor of Department of Computer Science
Borys Grinchenko Kyiv Metropolitan University, Kyiv, Ukraine
ORCID: 0000-0002-7597-9861
t.nosenko@kubg.edu.ua

Iryna V. Mashkina

PhD in Engineering, Associate Professor
Associate Professor of Department of Computer Science
Borys Grinchenko Kyiv Metropolitan University, Kyiv, Ukraine
ORCID: 0000-0003-0667-5749
i.mashkina@kubg.edu.ua

Iryna Yu. Melnyk

PhD in Engineering, Associate Professor
Professor of Department of Computer Science
Borys Grinchenko Kyiv Metropolitan University, Kyiv, Ukraine
ORCID: 0000-0001-6041-6145
iy.melnyk@kubg.edu.ua

APPLICATION OF ONE-DIMENSIONAL CONVULSIVE NEURAL NETWORKS FOR IDENTIFICATION OF WEAK RADIOACTIVE SIGNALS IN DYNAMIC MONITORING SYSTEMS

Abstract. The paper addresses the urgent problem of automated detection of low-activity moving sources of ionizing radiation in dynamic radiation monitoring systems. The limitations of classical threshold-based signal processing algorithms, characterized by low sensitivity and high false alarm rates under low signal-to-noise ratio conditions, are analyzed. A novel method for identifying radiation anomalies based on a One-Dimensional Convolutional Neural Network (1D CNN) is proposed. A mathematical model and software algorithm for generating synthetic time series of a scintillation detector have been developed, taking into account the stochastic nature of radiation detection (Poisson statistics), vehicle passage geometry, and shielding effects. The developed neural network model was trained and tested on the generated datasets. The effectiveness of the proposed approach has been experimentally confirmed: the classification accuracy for medium-activity sources reached 98.5%, and for extremely weak signals visually indistinguishable from noise, it remained at 83.5%. The obtained results demonstrate the potential of applying deep learning methods to enhance the reliability of radiation security systems.

Keywords: radiation monitoring; scintillation detector; Convolutional Neural Network; 1D CNN; deep learning; signal processing; moving radiation sources

REFERENCES

1. Vasylychenko, V. M., Konstantinov, M. I., Lytvynskyi, L. L., & Purtov, O. A. (2013). Development of nuclear energy in Ukraine. *Nuclear Power and the Environment*, 1, 7–13.
2. Nosovskyi, A. V. (2022). Nuclear energy of Ukraine in the context of sustainable development. *Visnyk of the National Academy of Sciences of Ukraine*
3. Slipchenko, V. G., Poliahushko, L. G., & Trofymchuk, A. A. (2023). Software and models for radiation monitoring. *Telecommunication and Information Technologies*, 4, 46–58.



4. Dunaievskaya, O. F., Zymarioieva, A. A., & Ishchuk, O. V. (2024). Features and results of radioecological monitoring to ensure environmental safety in modern conditions. *Ecological Sciences*, 56, 269–272.
5. McGregor D. S., Shultis J. K. *Radiation detection: concepts, methods, and devices*. CRC Press, 2020.
6. Tsoulfanidis N., Landsberger S. *Measurement and detection of radiation*. 5th ed. CRC Press, 2021.
7. Marques L., Vale A., Vaz P. State-of-the-Art Mobile Radiation Detection Systems for Different Scenarios. *Sensors*. 2021. Vol. 21, no. 4. 1051.
8. Galib S. M., Bhowmik P. K., Lee H. K. Comparative analysis of machine learning methods for automated identification of radioisotopes using NaI gamma-ray spectra. *Nuclear Engineering and Technology*. 2021. Vol. 53, no. 12. P. 4072–4079.
9. Lin C., Ning S., Wang Z. Neural network methods for radiation detectors and imaging. *Frontiers in Physics*. 2024. Vol. 12. 1334298.
10. Edwards C., Smith R. C., Mattingly J., Wilson A. G. Localization of Stationary and Moving Radiation Sources Using a Feed-Forward Neural Network with a Detector Array. *Nuclear Technology*. 2025. P. 1–14.
11. Abbaspour H., Najafi G. Location Estimation of Moving Targets by Passive Sonobuoy and Recurrent Deep Neural Network. *2023 International Symposium on Networks, Computers and Communications (ISNCC)*. IEEE, 2023. P. 1–6.
12. Kiranyaz S., Avci O., Abdeljaber O. 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*. 2021. Vol. 151. 107398.
13. Mashkina, I., Nosenko, T., Hlushak, O., Spivak, S., & Bilous, V. (2025). Optimizing Customer Support with AI Chatbots: A Case Study . *Electronic Professional Scientific Journal «Cybersecurity: Education, Science, Technique»*, 4(28), 727–739. <https://doi.org/10.28925/2663-4023.2025.28.838>
14. Abramov, V., Astafieva, M., Boiko, M., Bodnenko, D., Bushma, A., Vember, V., Hlushak, O., Zhyltsov, O., Ilich, L., Kobets, N., Kovaliuk, T., Kuchakovska, H., Lytvyn, O., Lytvyn, P., Mashkina, I., Morze, N., Nosenko, T., Proshkin, V., Radchenko, S., ... Yaskevych, V. (2021). Theoretical and practical aspects of the use of mathematical methods and information technology in education and science. <https://doi.org/10.28925/9720213284km>
15. Platonenko, A., Sokolov, V., Skladannyi, P. ., Anosov, A., & Oleksiienko, H. (2021). Comparison of Modern Technical Means of Air Intelligence to Ensure the Security of the Controlled Zone. *Electronic Professional Scientific Journal «Cybersecurity: Education, Science, Technique»*, 1(13), 170–182. <https://doi.org/10.28925/2663-4023.2021.13.170182>
16. Dovzhenko, N., Skladannyi, P., Ivanichenko, Y., & Zhyltsov, O. (2025). A Dynamic Interaction Model of Unmanned Aerial Vehicles with a Sensor Network for Energy-Efficient Monitoring. *Electronic Professional Scientific Journal «Cybersecurity: Education, Science, Technique»*, 3(27), 466–478. <https://doi.org/10.28925/2663-4023.2025.27.766>

