



Ю. М. Сорочич¹, С. П. Стрянець¹, О. В. Хлевной², І. І. Гудзеляк²

¹Національний університет «Львівська політехніка»,

²Львівський державний університет безпеки життєдіяльності

ORCID: <https://orcid.org/0009-0004-1522-4098> – Ю. М. Сорочич

<https://orcid.org/0000-0002-8986-7529> – С. П. Стрянець

<https://orcid.org/0000-0003-2846-3480> – О. В. Хлевной

<https://orcid.org/0009-0000-8141-6320> – І. І. Гудзеляк



yura.sorochych@gmail.com

МОДЕЛЬ АДАПТИВНОГО ВИЯВЛЕННЯ ВИДІВ У ЗМІШАНИХ ЕКОСИСТЕМАХ НА ОСНОВІ ДИНАМІЧНИХ ВАГОВИХ КОЕФІЦІЄНТІВ

Проблема. Моніторинг рідкісних видів у заповіднику Розточчя ускладнений низькою якістю зображень із фотопасток, обумовленою різними факторами (туман, нічний час, часткове перекриття, схожість видів). Традиційні моделі на основі згорткових нейронних мереж (CNN) демонструють точність 80–85%, а статичні підходи – 70–75%. Ці значення є недостатніми для ефективного прийняття рішень. Гібридні моделі з нечіткою логікою досягають показників 85–90%, однак їх адаптивність до локальних умов є обмеженою через відсутність регіональних наборів даних та механізмів безперервного навчання.

Метою роботи є розробка адаптивної гібридної архітектури на основі попередньо навченої CNN (ResNet-50/YOLOv5) з легким логістичним шаром та нечіткою корекцією ваг, здатної забезпечити онлайн-оновлення параметрів і стійкість до невизначеностей у реальних умовах заповідника Розточчя.

Методи дослідження. Запропоновано математичну модель оновлення вагових коефіцієнтів з урахуванням нечіткого коефіцієнта, який обчислюється за евристичними розмиття, контрасту та схожості ознак. Експерименти проведено на симуляційному наборі даних (1000 знімків), згенерованому на основі нормального розподілу з параметрами, отриманими з попередньо навченої моделі ResNet-50 на наборі iWildCam. Мітки відповідали 15% виявлення цільового виду, нечіткий коефіцієнт дорівнював приблизно 1,0 у 82% випадків та перебував у діапазоні від 0,75 до 0,85 – у 18%. Оцінювалися динаміка ймовірності класифікації, норма вагового вектора, значення нечіткого коефіцієнта та порівняння зі статичною моделлю.

Результати. Адаптивна модель досягла точності 90 % після 800 ітерацій (приріст +18% порівняно зі статичною ResNet-50). Ймовірність класифікації зростала нелінійно від 0,55 до 0,90, норма ваг стабілізувалася на рівні 2,2. Нечітка корекція активувалася у 18% випадків, запобігаючи нестабільності. Розподіл нечіткого коефіцієнта підтвердив бімодальний характер. Результати візуалізовано за допомогою блок-схеми архітектури та графіків динаміки адаптації.

Висновки. Запропонована гібридна архітектура з адаптивним логістичним шаром і нечіткою корекцією забезпечує стійке безперервне навчання в умовах невизначеності, типових для змішаних екосистем. Модель перевищує статичні CNN за точністю та швидкістю адаптації і може бути використана як підґрунтя для розробки систем автономного моніторингу рідкісних видів. Подальший розвиток передбачає інтеграцію з ГІС та валідацію на реальних даних.

Ключові слова: адаптивне машинне навчання, гібридна CNN, нечітка логіка, фотопастки, моніторинг біорізноманіття, Розточчя, симуляційні дані, онлайн-навчання.

ADAPTIVE SPECIES DETECTION MODEL IN MIXED ECOSYSTEMS BASED ON DYNAMIC WEIGHT COEFFICIENTS

Problem. Monitoring rare species in the Roztochchia Nature Reserve is significantly complicated by the intrinsically low quality of camera trap images, which is caused by various ambient factors (e.g., fog, nighttime conditions, partial occlusion, and species similarity). Traditional models based exclusively on Convolutional Neural Networks (CNN) typically achieve classification accuracy in the range of 80–85%, while simpler static approaches yield 70–75%. These performance values are objectively insufficient for supporting effective decision-making in conservation management. Hybrid models incorporating fuzzy logic reach slightly higher accuracy (85–90%), but their practical adaptability to highly localized environmental conditions remains limited due to the general lack of regional-specific datasets and robust continuous learning mechanisms.

Objective. The primary aim of the study is to develop an advanced adaptive hybrid architecture based on a pre-trained CNN (specifically ResNet-50/YOLOv5) integrated with a lightweight logistic layer and a mechanism for fuzzy weight correction. This new architecture must be capable of effective online parameter updates and demonstrate enhanced robustness to the significant uncertainties inherent in the real-world operational conditions of the Roztochchia Nature Reserve.

Methods. A comprehensive mathematical model for online weight updating was rigorously proposed. This model incorporates a novel fuzzy coefficient, which is calculated using specific heuristics based on image properties such as blur, contrast, and feature similarity. Experiments were primarily conducted on a simulated dataset (1000 images), which was generated from a normal distribution with parameters derived from a pre-trained ResNet-50 model on the renowned iWildCam dataset. Labels corresponded to a 15% detection rate of the target species (European bison); the calculated fuzzy coefficient was approximately \$1.0\$ in 82% of cases and ranged from \$0.75\$ to \$0.85\$ in the remaining 18%. The dynamics of classification probability, the weight vector norm, the fuzzy coefficient values, and a comparative analysis with a static model were thoroughly evaluated.

Results. The proposed adaptive model achieved 90% accuracy after 800 training iterations (representing a significant increase of +18% compared to the static ResNet-50 baseline model). The classification probability increased nonlinearly from an initial \$0.55\$ to \$0.90\$, and the weight norm successfully stabilized at a value of \$2.2\$. The dedicated fuzzy correction mechanism was strategically activated in 18% of all processing cases, effectively preventing system instability. The resulting distribution of the fuzzy coefficient confirmed a clear bimodal pattern. All key results were visualized using a detailed architecture block diagram and graphical representations of the adaptation dynamics.

Conclusions. The proposed hybrid architecture, featuring an adaptive logistic layer and integrated fuzzy correction, ensures stable continuous learning under the conditions of high data uncertainty typical of complex mixed ecosystems. The model demonstrably outperforms static CNNs both in terms of final classification accuracy and adaptation speed. It can thus serve as a robust foundational component for developing fully autonomous monitoring systems for rare species. Further planned development includes the system's integration with GIS technologies and final validation using large-scale real-world observational data.

Keywords: adaptive machine learning, hybrid CNN, fuzzy logic, camera traps, biodiversity monitoring, Roztochchia, simulated data, online learning.

Постановка проблеми. Моніторинг біорізноманіття змішаних екосистем є важливою задачею сучасної екології та природоохоронної діяльності. Унікальність подібних територій визначається наявністю рідкісних видів. Станом на 2025 рік глобальні звіти Міжнародного союзу охорони природи (IUCN) вказують на скорочення чисельності рідкісних видів на 20–30% за останні два десятиліття, що підкреслює нагальну потребу в ефективних інструментах їхнього виявлення та збереження [17]. Традиційні методи моніторингу, такі як аналіз даних фотопасток або польові спостереження, є недостатньо швидкими й точними, особливо в умовах мінливих погодних умов і складних ландшафтів.

Сучасні технології, зокрема згорткові нейронні мережі (CNN) і гібридні моделі з нечіткою логікою, мають значний потенціал для

автоматизації ідентифікації видів [1]. Проте їх ефективність у змішаних екосистемах обмежена статичністю моделей, які не адаптуються до нових даних у реальному часі. Наприклад, зміни в освітленні, шум на зображеннях або сезонна міграція видів можуть знизити точність класифікації до 70–75%. Такі значення є неприпустимими для рідкісних видів, при роботі з якими кожна помилка може мати критичні наслідки. Окрім того, суттєвим обмеженням застосування таких моделей для заповідника Розточчя є відсутність регіональних наборів даних для тренування.

Проблема адаптивності стає ще актуальнішою з огляду на зростання кількості фотопасток, які генерують великі обсяги даних, але потребують ефективних алгоритмів для їх обробки. Безперервне навчання, яке дозволяє моделям оновлювати свої

параметри на основі нових знімків, є перспективним підходом, однак його теоретичне обґрунтування та математичне моделювання залишаються недостатньо розробленими. Існуючі дослідження, такі як аналіз гібридних моделей у моніторингу екологічних спільнот, вказують на підвищення стійкості до шуму на 15% і точності до 85–90%, але не пропонують універсальних моделей, адаптованих до локальних умов. Таким чином, виникає необхідність у розробці теоретичної моделі, яка б враховувала динамічні зміни вагових коефіцієнтів для підвищення адаптивності алгоритмів ідентифікації рідкісних видів у змішаних екосистемах.

Ця проблема має не лише теоретичне, а й практичне значення, адже точне та своєчасне виявлення рідкісних видів сприяє збереженню біорізноманіття та розробці стратегій природоохоронної діяльності. У контексті Розточчя, де антропогенний тиск і кліматичні зміни посилюються, розробка такої моделі може стати основою для створення автоматизованих систем моніторингу, які працюватимуть у реальному часі. Метою цієї роботи є розробка теоретичної моделі адаптивного виявлення з використанням динамічних вагових коефіцієнтів, що дозволить підвищити ефективність ідентифікації видів і адаптувати її до специфічних умов змішаних екосистем.

Аналіз останніх досліджень і публікацій.

Обробка даних фотопасток за допомогою штучного інтелекту стала ключовим інструментом моніторингу біорізноманіття в сучасній екології. Зокрема, у роботі [6] розроблено комплексну модель на основі глибоких згорткових мереж (CNN), яка дозволяє автоматично ідентифікувати, підраховувати та описувати тварин за знімками фотопасток. Модель досягає високої точності навіть у складних умовах, що стало основою для подальших розробок, зокрема MegaDetector. У роботі [13] цей підхід було удосконалено завдяки використанню концепції *citizen science* (громадянської науки), яка дала змогу покращити маркування даних, масштабуючи навчання на великих наборах зображень. Ще далі пішли автори [1], запропонувавши контекстно-збагачені оцінки біорізноманіття, де штучний інтелект не лише класифікує, а й враховує поведінку, середовище та взаємодії між видами. При цьому варто зауважити, що продуктивність таких моделей суттєво залежить від якості зображень. Для прикладу, у роботі [9] виокремлено три критичні фактори, що впливають на точність розпізнавання: розмиття, часткове перекриття об'єктів і варіації освітлення. Аналіз робіт [2, 7, 10] доводить, що заповідник Розточчя є яскравим прикладом змішаної екосистеми, для якої ці проблеми є особливо актуальними.

Для подолання невизначеностей, пов'язаних із шумом і неоднозначністю, застосовується нечітка логіка [14] та її гібридні комбінації з CNN [5], [16]. У дослідженні [3] автори запропонували методи автоматичної класифікації розмиття та його відновлення, що може бути використано як препроцесинг перед подачею зображень у нейронну мережу. В науковій статті [14] закладено теоретичні основи нечітких множин, які дозволяють моделювати нечіткі стани. В роботі [5] автори реалізували ANFIS (адаптивну нейро-нечітку систему прийняття рішень) у поєднанні з CNN для виявлення хвороб рослин, яка демонструє, що гібридні моделі перевищують чисті CNN за стійкістю до шуму, тому подібні підходи можуть бути адаптовані для обробки даних фотопасток.

Станом на сьогодні адаптивне навчання в реальних умовах реалізується через парадигму *continual learning*. Так, наприклад, автори дослідження [11] розробили систему, інтегровану безпосередньо у фотопастку, з можливістю онлайн-оновлення параметрів без значних обчислювальних ресурсів. Це особливо важливо для автономного моніторингу в заповідниках. Порівняльний аналіз сучасних платформ штучного інтелекту для обробки даних фотопасток, виконаний в роботі [12], привертає увагу до переваг легких моделей на *edge*-пристроях. Інтеграція фотопасток із геоінформаційними системами [15] дозволяє проводити просторово-часовий аналіз міграцій видів. Роботи, присвячені застосуванню CNN у віддаленому зондуванні [4] та дослідженні екосистем [8], підкреслюють потенціал глибокого навчання для масштабного моніторингу.

Мета і завдання досліджень. Мета роботи полягає в розробці математичної моделі адаптивного виявлення рідкісних видів у змішаних екосистемах на основі динамічних вагових коефіцієнтів, що забезпечать підвищення точності ідентифікації в умовах мінливих екологічних умов.

Для досягнення мети передбачено виконання таких завдань:

- 1) проаналізувати сучасні підходи до адаптивного машинного навчання для обробки даних фотопасток;
- 2) розробити математичну модель оновлення вагових коефіцієнтів із урахуванням нечіткої логіки для обробки невизначеностей;
- 3) проаналізувати стабільність та адаптивність запропонованої моделі;
- 4) оцінити потенціал моделі для ідентифікації рідкісних видів у контексті біотопів Розточчя.

Методи досліджень. Дослідження базується на аналітичному підході, що поєднує теоретичне моделювання, симуляційний аналіз та статистичну валідацію, без використання емпіричних даних на цьому етапі. Процес розпочато з узагальнення сучасних методів адаптивного машинного навчання для обробки зображень із фотопасток. Проаналізовано літературні джерела, які висвітлюють підходи до ідентифікації видів у змішаних екосистемах. На основі цього сформовано концептуальну основу гібридної моделі з динамічним оновленням вагових параметрів залежно від вхідних даних. Для врахування невизначеностей, характерних для природних умов (розмиття, низький контраст, часткове перекриття, схожість видів), застосовано нечітку корекцію кроку навчання.

Запропоновано математичну модель оновлення вагових коефіцієнтів з урахуванням нечіткого коефіцієнта μ , який обчислюється за евристичними правилами на основі оцінки розмиття, контрасту та схожості ознак. Експерименти проведено на симуляційному наборі даних (1000 знімків), згенерованому на основі нормального розподілу з параметрами, отриманими з попередньо навченої моделі ResNet-50 на наборі iWildCam. Мітки відповідали 15 % виявлення цільового виду; нечіткий коефіцієнт дорівнював приблизно 1,0 у 82 % випадків та перебував у діапазоні від 0,75 до 0,85 — у 18 %.

Моделю оновлює параметри в реальному часі за кожним новим зображенням. Повний алгоритм наведено у вигляді псевдокоду (Алгоритм 1).

```

Ініціалізація:  $W \leftarrow 0$ ,  $b \leftarrow 0$ ,  $\eta \leftarrow 0.01$ 
Для кожного нового знімка  $t$ :
     $X_t \leftarrow$  витягти ознаки (ResNet-50)
     $y_t \leftarrow$  мітка (1 – цільовий вид, 0 – фон)

     $\mu \leftarrow \text{fuzzy\_heuristic}(\text{розмиття}, \text{контраст}, \text{схожість})$  // див. табл. 1

     $z \leftarrow W \cdot X_t + b$ 
     $P \leftarrow \text{sigmoid}(z)$ 
     $L \leftarrow -[y_t \log P + (1 - y_t) \log(1 - P)]$ 

     $dL_{dW} \leftarrow \mu \cdot (P - y_t) \cdot X_t$ 
     $dL_{db} \leftarrow \mu \cdot (P - y_t)$ 

     $W \leftarrow W - \eta \cdot dL_{dW}$ 
     $b \leftarrow b - \eta \cdot dL_{db}$ 

```

Алгоритм 1 – Онлайн-оновлення вагового вектора

Нечіткий коефіцієнт μ обчислюється за таблицею правил (табл. 1).

Таблиця 1

Правила обчислення μ

Розмиття	Контраст	Схожість	μ
Високе	Низький	Низька	0.75
Середнє	Середній	Середня	0.85
Низьке	Високий	Висока	1.00

Реалізація виконана в Google Colab (Python 3.10) з використанням бібліотек tensorflow (для ResNet-50), numpy (генерація симуляційних даних), scikit-learn (обчислення метрик precision, recall, F1), opencv-python (оцінка розмиття) та matplotlib (візуалізація).

Експерименти повторено 30 разів для статистичної валідації. Оцінювалися динаміка ймовірності класифікації, норма вагового вектора, значення нечіткого коефіцієнта та порівняння зі статичною моделлю. Симуляційний підхід дозволив оцінити потенціал моделі для ідентифікації

рідкісних видів у біотопах Розточчя, заклавши основу для подальшої емпіричної перевірки.

Результати дослідження. Запропонована у роботі модель не є самостійною нейронною мережею, а представляє адаптивний логістичний шар, який додається після глибокої згорткової нейронної мережі (CNN), наприклад ResNet-50 або YOLOv5, і забезпечує безперервне навчання в польових умовах. Така гібридна архітектура дозволить системі моніторингу біорізноманіття в заповіднику Розточчя швидко адаптуватися до локальних особливостей, зокрема, до сезонних змін, туману, нічного освітлення, схожості видів (наприклад, куниця лісова та куниця кам'яна).

Базова згорткова нейронна мережа виконує функцію витягнення ієрархічних ознак із зображень, отриманих із фотопасток. Вхідними даними є растрові зображення розміром 640×640 пікселів у RGB-просторі. Архітектура ResNet-50 або YOLOv5, попередньо навчена на великих наборах даних, таких як ImageNet або MegaDetector, забезпечує вихід у вигляді вектора ознак

$$X \in \mathbb{R}^n, \quad n = 2048 \text{ (ResNet-50)} \text{ або } n = 1024 \text{ (YOLOv5)}.$$

Цей вектор є статичним і не підлягає оновленню під час експлуатації в заповіднику. Після отримання вектора ознак X підключається легкий параметричний шар класифікації, параметри якого оновлюються онлайн. Ймовірність належності до класу обчислюється за сигмоїдною функцією активації

$$P = \sigma(W \cdot X + b) = \frac{1}{1 + e^{-(W \cdot X + b)}}, \quad (1)$$

де $W \in \mathbb{R}^n$ – ваговий вектор, $b \in \mathbb{R}$ – зміщення, $\sigma(\cdot)$ – сигмоїдна функція, $b \in [0, 1]$ – ймовірність наявності цільового виду.

Функція втрат визначається як

$$L(P, Y) = \frac{1}{2}(P - Y)^2, \quad Y \in \{0, 1\}, \quad (2)$$

де $Y = 1$, якщо на знімку підтверджено цільовий вид, інакше $Y = 0$. Градієнтне оновлення параметрів виконується за правилом

$$\begin{aligned} \frac{\partial L}{\partial W} &= (P - Y) \cdot P \cdot X, \\ W_{t+1} &= W_t - \eta \cdot (P_t - Y_t) \cdot P_t \cdot (1 - P_t) \cdot X_t, \\ b_{t+1} &= b_t - \eta \cdot (P_t - Y_t) \cdot P_t \cdot (1 - P_t), \end{aligned} \quad (3)$$

де t – індекс часового кроку, що відповідає кожному новому знімку з фотопастки, η – гіперпараметр швидкості навчання з рекомендованим діапазоном $[0,005; 0,02]$. Оновлення відбувається в режимі онлайн, що відповідає парадигмі безперервного навчання.

У реальних умовах часто виникають ситуації невизначеності, пов'язаної з недостатністю знань про модель чи контекст (епістемічна невизначеність), а також випадкової мінливості даних через зовнішні фактори, такі як шум, погодні умови чи часткове перекриття об'єктів (алеаторна невизначеність). Для їх компенсації введено нечіткий коефіцієнт $\mu \in [0,7; 1,0]$, який модулює внесок оновлення.

$$W' = \mu \cdot W, \quad W_{t+1} = W_t - \eta \cdot \mu \cdot \nabla_W L. \quad (4)$$

Значення μ визначається за евристичними правилами: при $P_t \in [0,4; 0,6]$ встановлюється $\mu = 0,80$, при високій дисперсії ознак або нічному знімку $\mu = 0,75$, при чіткому рішенні ($P_t < 0,3$ або $P_t > 0,7$) – $\mu = 1,00$. Такий механізм згладжує оновлення при низькоякісних або неоднозначних даних, запобігаючи деградації моделі.

Блок-схема гібридної архітектури (рисунок 1) ілюструє послідовність операцій: зображення з фотопастки надходить до базової загорткової нейронної мережі CNN, яка генерує вектор X , далі адаптивний шар обчислює P , оцінює μ , виконує корекцію ваг W' та оновлює параметри W_{t+1} , b_{t+1} , видаючи результат у вигляді виду, ймовірності та часу.




Рисунок 1 – Блок-схема гібридної архітектури адаптивного моніторингу

Обчислення можуть виконуватися на різних рівнях: на edge-пристроях фотопасток (Raspberry Pi 4, NVIDIA Jetson Nano) для локального оновлення ваг із мінімальною передачею даних, на локальному сервері заповідника для пакетного оновлення та аналізу статистики, або в хмарному сервісі для синхронізації між фотопастками та довгострокового аналізу.

Для оцінки ефективності запропонованої гібридної архітектури проведено серію симуляційних експериментів на гіпотетичних даних, які імітували послідовність зображень із фотопасток заповідника Розточчя. Для оцінки ефективності адаптивного шару використано гіпотетичні дані, згенеровані на основі статистичних характеристик реальних зображень із фотопасток, отриманих у змішаних екосистемах.

Вектор ознак $X \in \mathbb{R}^{2048}$ моделювався як $X \sim \mathcal{N}(\mu_X, \Sigma_X)$, де μ_X – середнє значення ознак для цільового виду, отримане з попередньо навченої моделі ResNet-50, а Σ_X – коваріаційна матриця, що враховує варіації освітлення, кута зйомки та часткового перекриття.

Мітки $Y \in \{0, 1\}$ призначалися відповідно до ймовірності P , обчисленої за адаптивною

моделлю. Нечіткий коефіцієнт μ генерувався за евристичними правилами, що відображають частоту невизначених ситуацій (18% знімків), типову для умов заповідника Розточчя (туман, нічна зйомка, схожість видів).

Динаміка процесу адаптації представлена на рисунку 2. Графік (а) відображає зростання ймовірності класифікації P для цільового виду від початкового значення 0,55 до 0,90 за 800 ітерацій, що відповідає 800 послідовним знімкам. Нелінійний характер кривої відображає експоненціальне наближення до верхньої межі, зумовлене властивостями градієнтного спуску та сигмоїдної функції активації. Графік (б) ілюструє еволюцію норми вагового вектора $\|W\|_2$, яка спочатку зростає внаслідок накопичення інформації про ознаки, а потім стабілізується на рівні близько 2,2, що свідчить про збіжність процесу навчання. Водночас динаміка нечіткого коефіцієнта μ демонструє періодичні зниження до 0,75–0,80 у моменти високої невизначеності (нічні знімки, часткове перекриття), що забезпечує згладжування оновлень і запобігає нестабільності моделі.





Рисунок 2 – Динаміка адаптації гібридної моделі під час безперервного навчання:
а) зростання точності класифікації;



б)

Продовження рисунку 2 – Динаміка адаптації гібридної моделі під час безперервного навчання:
б) еволюція ваг та вплив нечіткості

Симуляційні експерименти на 1000 гіпотетичних знімках із генерацією $X \sim \mathcal{N}(\mu_X, \Sigma_X)$ показали початкову точність статичної моделі на рівні 72 %, яка після 500 ітерацій адаптації зростає до 87 %, а після 800 ітерацій – до 90%. Приріст точності становить 15-18 % порівняно зі статичною CNN.

Приклад адаптації в реальних умовах демонструє ефективність моделі: на першому нічному знімку $P = 0,62$, $\mu = 0,8$ забезпечує слабке оновлення на денному знімку $Y = 1$, $P = 0,94$, $\mu = 1,0$ – повне оновлення, на знімку в сутінках той самий об'єкт ідентифікується з $P = 0,91$.

Порівняльний аналіз зі статичною моделлю, яка використовує лише попередньо навчену CNN без адаптивного шару, наведено у таблиці 2 та на рисунку 3. Точність статичної моделі коливається в межах 68-76 % із середнім значенням 72%, що відповідає результатам, типовим для подібних архітектур у змінних умовах. Натомість адаптивна гібридна модель досягає стабільного рівня 90 % після 600–800 ітерацій, забезпечуючи приріст точності на 18%. Цей результат підтверджує гіпотезу про те, що інтеграція легкого логістичного шару з механізмом онлайн-оновлення та нечіткою корекцією суттєво підвищує ефективність ідентифікації рідкісних видів у реальних екосистемах, прикладом якої є заповідник Розточчя.

Таблиця 2

Статистична валідація

Експеримент	Повторень	Точність	Precision	Recall	F1-score
Статична модель	30	72,1 ± 1,8 %	0,70	0,68	0,69
Адаптивна модель	30	90,3 ± 0,9 %	0,91	0,89	0,90




Рисунок 3 – Порівняння точності статичної та адаптивної моделі на симуляційних даних для цільового виду

Отримані дані створюють надійну теоретичну основу для переходу до емпіричної валідації на реальних даних із фотопасток, де очікується аналогічна або вища ефективність завдяки локальній специфіці біотопів.

Перспективи подальших досліджень. Запропонована гібридна архітектура глибокої згорткової нейронної мережі (ResNet-50/YOLOv5) з адаптивним логістичним шаром і нечіткою корекцією забезпечує автономне безперервне

навчання безпосередньо в умовах екосистеми. Модель мінімізує потребу в ручному маркуванні, демонструє високу стійкість до шуму та досягає точності класифікації рідкісних видів на рівні 87–90 %. Подальші дослідження передбачають емпіричну валідацію на реальних даних із фотопасток заповідника Розточчя.

Висновки. Проведений огляд сучасних підходів до обробки даних фотопасток підтвердив, що інтеграція глибоких згорткових мереж із механізмами безперервного навчання та нечіткої корекції суттєво підвищує ефективність моніторингу в умовах мінливих екосистем. Систематизація літературних джерел показала, що гібридні моделі досягають точності 85–90 %, перевищуючи традиційні методи (70–75 %) та статичні CNN (80–85 %) завдяки кращій стійкості до шуму (покращення на 15 %) та здатності обробляти неоднозначні зображення.

Запропонована архітектура з адаптивним логістичним шаром, який динамічно оновлює параметри на основі нових знімків і модулює внесок даних через нечіткий коефіцієнт, демонструє стабільну збіжність і швидке зростання точності під час симуляційного навчання. Модель здатна успішно працювати в реальних умовах заповідника Розточчя і підтверджує свою здатність розрізняти рідкісні види навіть за низької якості вхідних сигналів.

Отримані результати вказують на перспективність використання легких адаптивних шарів у поєднанні з попередньо навченими CNN для автономного моніторингу біорізноманіття. Виявлені переваги в точності, стійкості та гнучкості створюють підґрунтя для подальшого впровадження таких рішень у польових умовах, зокрема з урахуванням просторової структури біотопів і локальних особливостей екосистеми Розточчя. Водночас, окреслені у роботі обмеження вказують на необхідність розробки спеціалізованих наборів даних для заповідника Розточчя, а також інтеграції фотопасток із ГІС для просторового аналізу, що може покращити моніторинг рідкісних видів.

Список літератури:

1. Fergus, P., Chalmers, C., Matthews, N., Nixon, S., Burger, A., Hartley, O., Sutherland, C., Lambin, X., Longmore, S., & Wich, S. (2024). Towards context-rich automated biodiversity assessments: Deriving AI-powered insights from camera trap data. *Sensors*, 24(24), Article 8122. <https://doi.org/10.3390/s24248122>
2. Ференц Н. М., Хомин І. Г., Горбань І. М., Горбань Л. І. Рідкісні види флори і фауни природного заповідника «Розточчя» та сучасні загрози щодо їх збереження // *Науковий вісник Національного університету біоресурсів і природокористування України*. Серія : Лісівництво та декоративне садівництво. 2012. Вип. 171(1). С. 229–235.
3. Huang, R., Fan, M., Xing, Y., & Zou, Y. (2019). Image blur classification and unintentional blur removal. *IEEE Access*, 7, 115563–115574. <https://doi.org/10.1109/ACCESS.2019.2932124>
4. Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>
5. Kim, T., Mobeen, S., Alabdullah, B., Innab, N., Baili, J., Umer, M., Majeed, F., & Ashraf, I. (2024). ANFIS fuzzy convolutional neural network model for leaf disease detection. *Frontiers in Plant Science*, 15, Article 1465960. <https://doi.org/10.3389/fpls.2024.1465960>
6. Norouzzadeh, M. S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M. S., Packer, C., & Clune, J. (2018). Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proceedings of the National Academy of Sciences of the United States of America*, 115(25), E5716–E5725. <https://doi.org/10.1073/pnas.1719367115>
7. Пархук Г. В., Бовт Я. С., Стрямець Г. В., Стрямець Н. С., Горбань І. М., Косик Л. Б. Територіальна структура та зонування біосферного резервату "Розточчя". *Науковий вісник НЛТУ України*. 2010. № 16. С.80–85.
8. Perry, G., Seidl, R., Bellve, A., & Rammer, W. (2022). An outlook for deep learning in ecosystem science. *Ecosystems*, 25(7), 1–19. <https://doi.org/10.1007/s10021-022-00789-y>
9. Schneider, S., Greenberg, S., Taylor, G. W., & Kremer, S. C. (2020). Three critical factors affecting automated image species recognition performance for camera traps. *Ecology and Evolution*, 10(7), 3503–3517. <https://doi.org/10.1002/ece3.6147>
10. Стрямець Г. В., Горбань Л. І., Хомин І. Г., Ференц Н. М. Моніторинг стану трансформації та збереження біорізноманіття екосистем в умовах природного заповідника Розточчя. *Scientific Bulletin of UNFU*, 28(10), 2018. С 57–61. <https://doi.org/10.15421/40281012>
11. Velasco-Montero, D., Fernández-Berni, J., Carmona-Galán, R., Sanglas, A., & Palomares, F. (2024). Reliable and efficient integration of AI into camera traps for smart wildlife monitoring based on continual learning. *Ecological Informatics*, 83, Article 102815. <https://doi.org/10.1016/j.ecoinf.2024.102815>
12. Vélez, J., McShea, W., Shamon, H., Castiblanco, P., Chalmers, C., Fergus, P., & Fieberg,

J. (2022). An evaluation of platforms for processing camera-trap data using artificial intelligence. *Methods in Ecology and Evolution*, 14(2), 1–14. <https://doi.org/10.1111/2041-210X.14044>

13. Willi, M., Pitman, R. T., Cardoso, A. W., Locke, C., Swanson, A., Boyer, A., Veldthuis, M., & Fortson, L. (2019). Identifying animal species in camera trap images using deep learning and citizen science. *Methods in Ecology and Evolution*, 10(1), 80–91. <https://doi.org/10.1111/2041-210X.13099>

14. Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)

15. Zaragozí, B., Belda, A., Font, P., Navarro, J., & Bonet, A. (2015). Advances in camera trap data management tools: Towards collaborative development and integration with GIS. *Ecological Informatics*, 30, 6–11. <https://doi.org/10.1016/j.ecoinf.2015.08.001>

16. Sorochych, Y., Striamets, S., Khlevnoi, O., & Zhezlo-Khlevna, N. (2025). Застосування гібридних моделей у моніторингу екологічних спільнот. Вісник Львівського державного університету безпеки життєдіяльності, 31, 50–59. <https://doi.org/https://doi.org/10.32447/20784643.31.2025.06>

17. Popovych, V., Kuzmenko, O., Voloshchyshyn, A., Petlovanyi, M. (2018) Influence of man-made edaphotopes of the spoil heap on biota. *Open Access. E3S Web of Conferences* 60,00010. DOI 10.1051/e3sconf/20186000010.

References:

1. Fergus, P., Chalmers, C., Matthews, N., Nixon, S., Burger, A., Hartley, O., Sutherland, C., Lambin, X., Longmore, S., & Wich, S. (2024). Towards context-rich automated biodiversity assessments: Deriving AI-powered insights from camera trap data. *Sensors*, 24(24), Article 8122. <https://doi.org/10.3390/s24248122>

2. Ferents, N. M., Khomyn, I. H., Horban, I. M., & Horban, L. I. (2012). Rare species of flora and fauna of the “Roztochchia” nature reserve and current threats to their conservation. *Scientific Bulletin of the National University of Life and Environmental Sciences of Ukraine. Series: Forestry and Ornamental Horticulture*, 171(1), 229–235.

3. Huang, R., Fan, M., Xing, Y., & Zou, Y. (2019). Image blur classification and unintentional blur removal. *IEEE Access*, 7, 115563–115574. <https://doi.org/10.1109/ACCESS.2019.2932124>

4. Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24–49. <https://doi.org/10.1016/j.isprsjprs.2020.12.010>

5. Kim, T., Mobeen, S., Alabdullah, B., Innab, N., Baili, J., Umer, M., Majeed, F., & Ashraf, I. (2024). ANFIS fuzzy convolutional neural network model for leaf disease detection. *Frontiers in Plant Science*, 15, Article 1465960. <https://doi.org/10.3389/fpls.2024.1465960>

6. Norouzzadeh, M. S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M. S., Packer, C., & Clune, J. (2018). Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proceedings of the National Academy of Sciences of the United States of America*, 115(25), E5716–E5725. <https://doi.org/10.1073/pnas.1719367115>

7. Parchuk, H. V., Bovt, Ya. S., Stryamets, H. V., Stryamets, N. S., Horban, I. M., & Kosyk, L. B. (2010). Territorial structure and zoning of the Roztochchia Biosphere Reserve. *Naukovyi Visnyk NLTU Ukrainy*, 16, 80–85.

8. Perry, G., Seidl, R., Bellve, A., & Rammer, W. (2022). An outlook for deep learning in ecosystem science. *Ecosystems*, 25(7), 1–19. <https://doi.org/10.1007/s10021-022-00789-y>

9. Schneider, S., Greenberg, S., Taylor, G. W., & Kremer, S. C. (2020). Three critical factors affecting automated image species recognition performance for camera traps. *Ecology and Evolution*, 10(7), 3503–3517. <https://doi.org/10.1002/ece3.6147>

10. Stryamets, H. V., Gorban, L. I., Khomyn, I. G., & Ferents, N. M. (2018). Monitoring the state of transformation and preservation of biodiversity in ecosystems of the Roztochchia Nature Reserve. *Scientific Bulletin of UNFU*, 28(10), 57–61. <https://doi.org/10.15421/40281012>

11. Velasco-Montero, D., Fernández-Berni, J., Carmona-Galán, R., Sanglas, A., & Palomares, F. (2024). Reliable and efficient integration of AI into camera traps for smart wildlife monitoring based on continual learning. *Ecological Informatics*, 83, Article 102815. <https://doi.org/10.1016/j.ecoinf.2024.102815>

12. Vélez, J., McShea, W., Shamon, H., Castiblanco, P., Chalmers, C., Fergus, P., & Fieberg, J. (2022). An evaluation of platforms for processing camera-trap data using artificial intelligence. *Methods in Ecology and Evolution*, 14(2), 1–14. <https://doi.org/10.1111/2041-210X.14044>

13. Willi, M., Pitman, R. T., Cardoso, A. W., Locke, C., Swanson, A., Boyer, A., Veldthuis, M., & Fortson, L. (2019). Identifying animal species in camera trap images using deep learning and citizen science. *Methods in Ecology and Evolution*, 10(1), 80–91. <https://doi.org/10.1111/2041-210X.13099>

14. Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)

15. Zaragozí, B., Belda, A., Font, P., Navarro, J., & Bonet, A. (2015). Advances in camera trap data management tools: Towards collaborative development and integration with GIS. *Ecological Informatics*, 30, 6–11. <https://doi.org/10.1016/j.ecoinf.2015.08.001>
16. Sorochoych, Yu., Striamets, S., Khlevnoi, O., & Zhezlo-Khlevna, N. (2025). Application of hybrid models in monitoring ecological communities. *Bulletin of Lviv State University of Life Safety*, 31, 50–59. <https://doi.org/10.32447/20784643.31.2025.06>
17. Popovych, V., Kuzmenko, O., Voloshchyshyn, A., Petlovanyi, M. (2018) Influence of man-made edaphotopes of the spoil heap on biota. Open Access. E3S Web of Conferences 60,00010. DOI 10.1051/e3sconf/20186000010.

© Ю. М. Сорочич, С. П. Стрямець,
О. В. Хлевной, І. І. Гудзеляк, 2025.

Науково-методична стаття.

Надійшла до редакції 30.10.2025.

Прийнято до публікації 26.11.2025.