

Золотухіна Оксана Анатоліївна

кандидат технічних наук, доцент, доцент кафедри інтелектуальних технологій
Київський національний університет імені Тараса Шевченка, Київ, Україна
ORCID ID 0000-0002-3314-417X
oksana.zolotukhina@knu.ua

Жултинська Ангеліна Костянтинівна

аспірантка
Державне некомерційне підприємство "Державний університет "Київський авіаційний інститут", м.
Київ, Україна
ORCID ID 0000-0001-9178-897X
angelinaremark1@gmail.com

**ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ АВТОМАТИЗОВАНОГО АНАЛІЗУ
АЕРОЗОБРАЖЕНЬ З БПЛА НА ОСНОВІ СПЛАЙН-АПРОКСИМАЦІЇ РОЗПОДІЛУ
ТЕКСТУРНИХ ОЗНАК**

Анотація. У статті представлено інформаційну технологію автоматизованого аналізу аерознімків безпілотних літальних апаратів на основі поліноміальної сплайн-апроксимації $S_{2,0}$. Запропоноване рішення дозволяє подолати високу обчислювальну складність сучасних нейромережових підходів та неадекватність параметричних моделей при описі гетерогенних текстур реальних аерознімків. Розроблена ІТ реалізована у вигляді тривірневої модульної архітектури Core-Services-GUI з двофазним обчислювальним конвеєром, теоретична складність якого становить $O(A_\mu \cdot A_\sigma)$ незалежно від роздільності вхідного зображення. Перша фаза виконує апроксимацію розподілу текстурних ознак $\mu \times \sigma$ поліноміальним сплайном на регулярній сітці; друга - топографічний пошук мод з верифікацією аналітичним гессіаном $H(S)$ та відбір найнадійніших псевдоміток за параметром p_{auto} . Наукова новизна полягає у формалізації двох детермінованих стратегій кластеризації: геометричного розбиття простору ознак (Discr) через TLS-апроксимацію дискримінантних ліній та використання конвергентного потенціалу (Grad). Гарантована детермінованість результатів ($\sigma(\text{ARI})=0$) забезпечує стабільну відтворюваність навчальної бази між різними сесіями розмітки. Емпіричну верифікацію виконано на 120 реалізаціях дискретного поля інтенсивностей трьох датасетів аерознімків (BPLA, LoveDA, OpenEarthMap). Встановлено, що при $p_{\text{auto}} = 0,10 - 0,20$ якість відібраних псевдоміток $\text{ARI} = 0,571 - 0,580$ вдвічі перевищує конкурентні методи без механізму confidence, а варіант з відбором 50% найбільш впевнених пікселів перевищує oGaele-методи з апіорним знанням кількості класів на всіх трьох датасетах. Точність автоматичного визначення кількості кластерів $|D_k| = 0,942 - 0,950$ є втричі кращою за GMM_BIC. Log-log нахил $\alpha = 0,070$ підтверджує придатність технології до SWaP-обмеженого бортового розгортання, а детермінованість $\sigma(\text{ARI}) = 0$ гарантує відтворюваність навчальної бази між сесіями розмітки. Статистичну значущість результатів підтверджено критерієм Фрідмана ($p < 0,05$) та ефектом Коена ($d > 0,8$). Запропонована ІТ забезпечує ефективне виявлення аномалій ($\text{ROC-AUC} = 0,630$) та є цілісним збалансованим рішенням для автоматизованих систем повітряного спостереження.

Ключові слова: БПЛА, аерознімки, сплайн-апроксимація, текстурні ознаки, кластеризація, виявлення аномалій, семантична сегментація, машинне навчання, навчання без вчителя.

Zolotukhina Oksana

Candidate of Technical Sciences, Associate Professor, Associate Professor of the Department of Intellectual Technologies
Taras Shevchenko National University of Kyiv, Kyiv, Ukraine
ORCID ID 0000-0002-3314-417X
oksana.zolotukhina@knu.ua

Zhultynska Anhelina

Postgraduate student
State Non-Profit Enterprise "State University "Kyiv Aviation Institute", Kyiv, Ukraine
ORCID ID 0000-0001-9178-897X
angelinaremark1@gmail.com

INFORMATION TECHNOLOGY FOR AUTOMATED ANALYSIS OF UAV AERIAL IMAGES BASED ON SPLINE APPROXIMATION OF TEXTURE FEATURE DISTRIBUTION

Abstract. The article presents an information technology for automated analysis of aerial photographs of unmanned aerial vehicles based on polynomial spline approximation $S_{2,0}$. The proposed solution allows overcoming the high computational complexity of modern neural network approaches and the inadequacy of parametric models in describing heterogeneous textures of real aerial photographs. The developed IT is implemented in the form of a three-level modular architecture Core–Services–GUI with a two-phase computational pipeline, the theoretical complexity of which is $O(A_\mu \cdot A_\sigma)$ regardless of the resolution of the input image. The first phase approximates the distribution of texture features $\mu \times \sigma$ by a polynomial spline on a regular grid; the second phase performs a topographic search for modes with verification by the analytical Hessian $H(S)$ and selection of the most reliable pseudo-labels by the parameter p_{auto} . The scientific novelty lies in the formalization of two deterministic clustering strategies: geometric partitioning of the feature space (Discr) through TLS-approximation of discriminant lines and use of convergent potential (Grad). The guaranteed determinism of the results ($\sigma(\text{ARI})=0$) ensures stable reproducibility of the training base between different labeling sessions. Empirical verification was performed on 120 implementations of the discrete intensity field of three aerial image datasets (BPLA, LoveDA, OpenEarthMap). It was found that at $p_{\text{auto}} = 0,10 - 0,20$ the quality of the selected pseudo-labels $\text{ARI} = 0,571-0,580$ is twice as high as that of competing methods without the confidence mechanism, and the option with the selection of 50% of the most confident pixels outperforms oracle methods with a priori knowledge of the number of classes on all three datasets. The accuracy of automatic clustering $|\Delta k| = 0,942 - 0,950$ is three times better than GMM_BIC. The log-log slope $\alpha = 0,070$ confirms the suitability of the technology for SWaP-limited onboard deployment, and the determinism $\sigma(\text{ARI}) = 0$ guarantees the reproducibility of the training set between labeling sessions. The statistical significance of the results was confirmed by the Friedman criterion ($p < 0,05$) and the Cohen effect ($d > 0,8$). The proposed IT provides effective anomaly detection ($\text{ROC-AUC} = 0,630$) and is a holistic balanced solution for automated aerial surveillance systems.

Keywords: UAV, aerial photography, spline approximation, texture features, clustering, anomaly detection, semantic segmentation, machine learning, unsupervised learning.

1. Вступ

Широке впровадження БПЛА у сфері дистанційного зондування, екологічного моніторингу та інспектування інфраструктури генерує надвеликі обсяги візуальних даних [1]. Традиційна централізована модель обробки, яка передбачає передачу сирих або слабо оброблених даних на наземні станції, виявляється неефективною в умовах обмеженої пропускну здатності каналів зв'язку, затримок передачі та вразливості до засобів радіоелектронної протидії. У цьому контексті концепція edge computing передбачає перенесення обчислень безпосередньо на борт БПЛА, що дозволяє реалізувати обробку даних у режимі реального часу та зменшити залежність від зовнішньої інфраструктури. Водночас апаратна база БПЛА підпорядковується жорстким обмеженням SWaP (Size, Weight, and Power) [2], що істотно звужує спектр допустимих алгоритмічних рішень. Зокрема, сучасні підходи комп'ютерного зору, засновані на глибоких нейронних мережах (CNN, Vision Transformers), хоча й демонструють високу точність у задачах сегментації та виявлення об'єктів, характеризуються значною обчислювальною складністю, високими вимогами до енергоспоживання та необхідністю великих обсягів розмічених навчальних даних. Це обмежує їх застосування в автономних бортових системах, особливо в умовах реального часу. Альтернативою виступають класичні методи навчання без учителя, зокрема K-Means, Gaussian Mixture Models (GMM), а також підходи до виявлення аномалій (Isolation Forest, LOF). Попри їхню відносну обчислювальну ефективність, зазначені методи мають суттєві обмеження. Параметричні моделі, такі як GMM, передбачають апіорні припущення щодо форми розподілів, що є некоректним для гетерогенних та багатомодальних текстур реальних аерозображень. У свою чергу, щільнісні непараметричні методи (DBSCAN, HDBSCAN) потребують попарного аналізу об'єктів, що призводить до квадратичної або квазіквадратичної складності та робить їх непридатними для обробки великих зображень на бортових платформах. Таким чином, виникає суперечність між вимогами до точності аналізу складних текстурних структур аерозображень та обмеженнями обчислювальних ресурсів бортових систем. Це актуалізує потребу у розробленні нових інформаційних технологій, які поєднують непараметричну гнучкість представлення даних, низьку (бажано лінійну або сублінійну) обчислювальну складність, детермінованість результатів та незалежність від великих розмічених вибірок.

2. Постановка проблеми

Постановка проблеми полягає у необхідності розроблення комплексної інформаційної технології, яка б поєднувала непараметричну гнучкість сплайн-апроксимації з гарантованою сублінійною складністю $O(H \cdot W + A_\mu \cdot A_\sigma)$, придатною для SWaP-сумісного бортового розгортання.

3. Аналіз останніх досліджень і публікацій

Домінуючим підходом у задачах комп'ютерного зору є застосування CNN та візуальних трансформерів [3, 4], що демонструють високу ефективність на бенчмарках типу UAVid [5] та у гібридних архітектурах Deep Autoencoding GMM [6, 7]. Проте надвисока обчислювальна складність DNN [8, 9] та залежність від масивних розмічених вибірок [10] унеможливають їхнє ефективне бортове розгортання.

Альтернативою є класичні методи навчання без учителя: K-Means [11], Isolation Forest [12, 13], GMM [14, 15]. Однак параметричні моделі неадекватно описують гетерогенні та багатомодальні текстури реальних аерознімків [16]. Непараметричні підходи (DBSCAN, HDBSCAN [17, 18]) потребують попарного порівняння ознак, що призводить до складності $O(N \log N) - O(N^2)$, - неприйнятної для бортової SWaP-сумісної обробки [19].

Перспективним шляхом подолання зазначених обмежень є залучення поліноміальних сплайнів. Дослідження [20] доводять ефективність архітектур типу ExSpliNet, а теоретичні засади двовимірних поліноміальних сплайнів $S_{2,0}$, близьких до інтерполяційних у середньому, закладені у монографії [21]. Авторами у [22–24] розроблено та верифіковано математичну модель непараметричної оцінки сумішей розподілів локальних текстурних ознак (μ та σ) на основі двовимірних B-сплайнів. Відкритим залишається питання реалізації цього апарату у вигляді цілісної ІТ з гарантованою складністю $O(H \cdot W + A_\mu \cdot A_\sigma)$, придатної для бортового розгортання.

4. Мета і задачі дослідження

Метою дослідження є розроблення, архітектурна формалізація та верифікація інформаційної технології автоматизованого аналізу аерозображень з БПЛА на основі сплайн-апроксимації розподілу текстурних ознак для сегментації та виявлення аномалій у SWaP-сумісному розгортанні.

Зазначена мета конкретизується у необхідності послідовного розв'язання чотирьох взаємообумовлених задач:

1. Алгоритмічна формалізація ІТ як двофазного конвеєру з верифікованою складністю $O(H \cdot W + A_\mu \cdot A_\sigma)$ та обґрунтування тривірневої архітектури Domain–Service–GUI.
2. Формалізація та порівняльний аналіз стратегій Discr і Grad на базі спільної сплайн-моделі $S_{2,0}$.
3. Математичне доведення та емпірична верифікація сублінійного масштабного закону в порівнянні з GMM, K-Means ($O(N \cdot K \cdot I)$) та HDBSCAN ($O(N \log N)$).
4. Комплексна порівняльна верифікація з конкурентними методами за критеріями точності, детермінованості та стійкості на реальних аерознімках 4K/8K.

Слід зазначити, що базові аналітичні властивості двовимірних поліноміальних B-сплайнів $S_{2,0}$, близьких до інтерполяційного в середньому, детально обґрунтовані у [22–24], тому у даній роботі головну увагу приділено алгоритмічній реалізації та верифікації розробленої інформаційної технології.

5. Результати дослідження

Архітектурна формалізація та обчислювальна модель інформаційної технології.

Інформаційна технологія реалізована як тривірнева модульна система (Domain–Service–GUI), де математичне ядро повністю відокремлено від сервісного шару та інтерфейсних компонентів. Ключовим проектним рішенням є цілковита ізоляція математичного ядра, що дозволяє виконувати автономну валідацію алгоритмів на бортових комп'ютерах БПЛА без накладних витрат на візуалізацію чи зовнішні системні виклики (рис. 1).

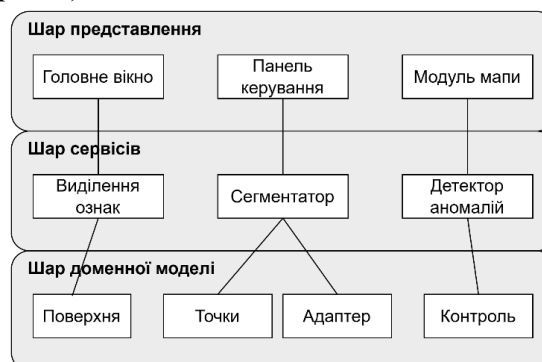


Рис. 1. Тривірнева архітектурна модель інформаційної технології

Для задачі ітеративного виключення аномалій архітектура доповнена патерном Dynamic Dataset: простір текстурних ознак $A_\mu \times A_\sigma$ фіксується одноразово на першій ітерації та залишається незмінним на всіх наступних, що гарантує просторову сумісність кумулятивних бінарних масок аномалій між ітераціями та робить результати незалежними від порядку обробки кадрів.

Для подолання квадратичної складності класичних методів обчислювальний конвеєр декомпозитовано на три фази (рис. 2). Фаза 1 здійснює лінійну $O(H \cdot W)$ екстракцію текстурних дескрипторів (μ, σ) через оператор boxFilter та формує 2D-гістограму фіксованого розміру $A_\mu \times A_\sigma$, редукуючи вхідний мегапіксельний кадр до константного аналітичного простору незалежно від площі вікна сканування.

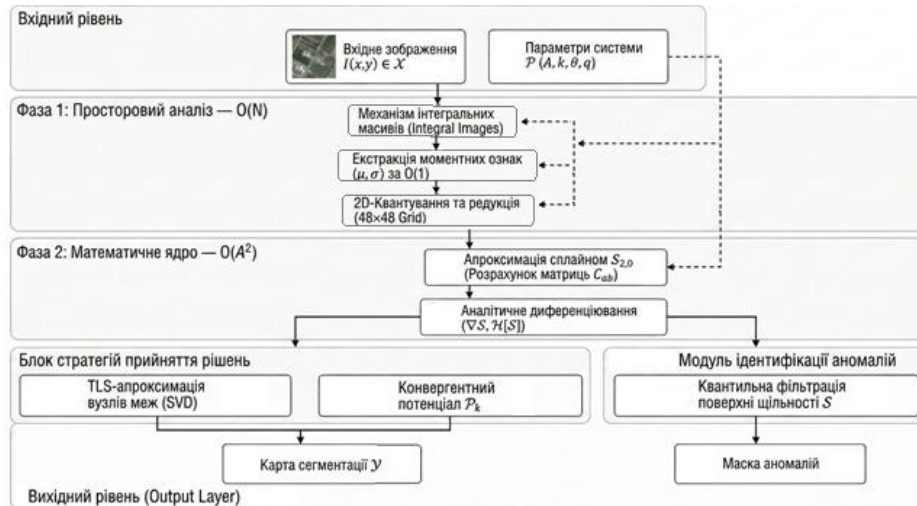


Рис. 2. Архітектурна декомпозиція обчислювального конвеєру інформаційної технології

Фаза 2 виконується виключно над матрицею ознак фіксованого розміру - незалежно від роздільності кадру. На цій сітці будується аналітична поверхня щільності $S_{2,0}$ на основі B-сплайнів, виконується топографічний пошук мод з верифікацією матрицею Гессе, NMS-фільтрація та TLS-апроксимація дискримінантних ліній через SVD - все за $O(A_\mu \cdot A_\sigma)$. Фаза 3 проводить векторизоване $O(H \cdot W)$ кластерне присвоєння за аналітично визначеними правилами розбиття.

Таблиця 1

Декомпозиція теоретичної асимптотичної складності функціональних етапів розробленої ІТ

Фаза конвеєра	Функціональний етап інформаційної технології	Теоретична обчислювальна складність	Характеристика архітектурної залежності
Фаза 1	Розрахунок текстурних ознак (μ, σ) через оператор boxFilter	$O(H \times W)$	Залежить виключно від кількості пікселів кадру; інваріантна до радіуса вікна
	Квантування простору ознак та побудова 2D-гістограми щільності	$O(H \times W)$	Лінійна просторова редуція великого масиву даних
Фаза 2	Розрахунок коефіцієнтів C_{ab} поліноміального сплайну $S_{2,0}$	$O(A_\mu \times A_\sigma)$	Константна. Абсолютно інваріантна до розміру вихідного зображення
	Топографічне сканування (пошук мод, градієнтний підйом, перевірка гессіаном)	$O(A_\mu \times A_\sigma)$	Константна. Залежить виключно від роздільної здатності дискретної сітки $A_\mu \times A_\sigma$
	NMS-фільтрація мод, SVD-розклад та TLS-апроксимація дискримінантних ліній	$O(K^2)$	Константна. Залежить від кількості виявлених мод K та попарного аналізу суміжних кластерів
Фаза 3	Векторизована зворотна проєкція простору рішень на площину зображення	$O(H \times W \cdot K)$	Лінійна. детермінована тензорна операція оцінки приналежності пікселя до зони полігона

Для обґрунтування обчислювальної орієнтації та SWaP-сумісності запропонованої архітектурної моделі авторами проведено детальний теоретичний аналіз асимптотичної вартості кожного функціонального мікроетапу розробленого конвеєра. Результати математичного аналізу,

систематизовані у таблиці 1, доводять фундаментальну перевагу розробленої архітектури: найресурсоемісні математичні розрахунки ізольовані у просторі константних величин, що гарантує сувору лінійну швидкодію всієї системи.

Загальна алгоритмічна вартість конвеєру зводиться до $O(H \cdot W + A_\mu \cdot A_\sigma)$. Центральний аналітичний етап виконується за сталий час, що апріорі виключає приховані ітеративні цикли та гарантує передбачувану швидкодію в edge-контролерах БПЛА реального часу.

Алгоритмічне забезпечення просторової сегментації та кластерного присвоєння.

На базі побудованої поверхні $S_{2,0}$ запропоновано дві математично відмінні стратегії кластеризації. Стратегія Discr реалізує глобальне геометричне розбиття простору ознак: локальні максимуми $S_{2,0}$ ідентифікуються як моди (верифікація аналітичним гессіаном - $\det H(S) > 0$, $\text{tr} H(S) < 0$), від них ініціюється градієнтний спуск до топографічних «долин» щільності, а знайдені вузлові точки апроксимуються методом загальних найменших квадратів (TLS) через SVD-розклад коваріаційної матриці - формуючи систему дискримінантних ліній, що детерміновано розбивають простір ознак на опуклі полігональні зони [22–24] (рис. 3).



Рис. 3. Алгоритмічні стратегії кластеризації на базі аналітичної сплайн-моделі

Стратегія Grad відмовляється від розрахунку дискримінантних меж та присвоює кожному пікселю x кластер k^* з максимальним конвергентним потенціалом

$$k^*(x) = \operatorname{argmax}_k, \varphi_k(x), \quad \varphi_k(x) = \nabla S(x) \cdot u_k, \quad (1)$$

де u_k - одиничний вектор напрямку до k -ї моди розподілу. Це забезпечує мінімальний час відгуку (129 мс проти 275 мс у Discr), але виявляє вищу чутливість до локальних мікрорумів апроксимуючої поверхні.

Ключовою перевагою обох стратегій є повна математична детермінованість: на відміну від K-Means та GMM з випадковою ініціалізацією центрів, сплайн-конвеєр завжди повертає єдину конфігурацію розбиття. Стратегія Discr забезпечує максимальну робастність, Grad - мінімальний час відгуку для систем реального часу.

Емпірична верифікація та статистичний аналіз результатів розробленої технології.

Верифікацію виконано у середовищі Benchmark Laboratory на 120 реалізаціях дискретного поля інтенсивностей: BPLA (37 сцен, 4K/8K, K = 3–5), LoveDA (7 сцен, K = 2–7) та OEM (76 сцен, K = 3–5). Граничні умови досліджено на змодельованих даних генератора gen_mixed_gmm (K = 3, параметр зближення $\gamma \in [0; 1]$). Методи поділяються на auto-K - SplineS20_Grad та SplineS20_Discr, HDBSCAN, GMM_BIC - та oracle-методи з апіорним k_{true} (KMeans_oracle, GMM_oracle), що є теоретичною верхньою межею.

Центральним результатом є верифікація механізму відбору псевдоміток за параметром p_{auto} . При $p_{\text{auto}} = 0,10$ у навчальну базу потрапляють лише 10% пікселів, що мають найбільші значення функції щільності окремо по кожному кластеру на поверхні $S_{2,0}$. Стратегія Discr досягає ARI = 0,574 та Macro-IoU = 0,568, Grad - ARI = 0,571 та Macro-IoU = 0,524 (середнє по 120 реалізаціях), що вдвічі перевищує найкращий конкурентний метод (GMM_oracle = 0,282). Discr систематично переважає Grad за Macro-IoU на $\sim 0,04$ завдяки точнішій лінійній апроксимації меж методом TLS/SVD. Оптимальна область - $p_{\text{auto}} = 0,20$ для Discr (ARI = 0,580), $p_{\text{auto}} = 0,10$ для Grad (рис. 4).

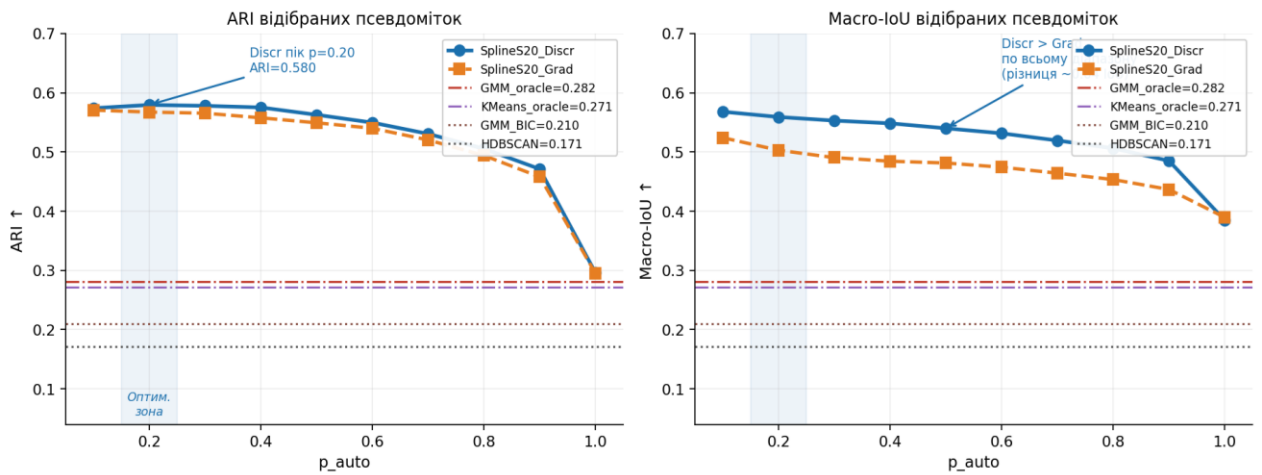


Рис. 4. Оцінка якості відібраних псевдоміток залежно від p_auto для обох стратегій $S_{2,0}$ (горизонтальні лінії - конкуренти без механізму відбору)

На 120 реальних реалізаціях із ground-truth розміткою варіант SplineS20_Discr_p50 (відбір 50% найбільш впевнених пікселів) досягає $ARI = 0,423$ (BPLA) та $0,369$ (OEM), SplineS20_Grad_p50 - $0,431$ та $0,350$ відповідно. Обидва значення перевищують oracle-методи з апіорним k_{true} (GMM_oracle на BPLA = $0,301$; KMeans_oracle на OEM = $0,272$), а на LoveDA Discr_p50 ($0,438$) перевершує обидва oracle. Серед auto-K методів Grad лідує на BPLA ($ARI = 0,318$), Discr - на LoveDA ($0,319$) та OEM ($0,275$). HDBSCAN демонструє $|\Delta k| = 5,16$ на BPLA - систематичне подрібнення кластерів. 30 незалежних запусків підтвердили $\sigma(ARI) = 0$ для обох стратегій SplineS20, тоді як GMM_unseeded має $\sigma = 0,101$ - нестабільність, неприйнятна для відтвореної навчальної бази (рис. 5).




Рис. 5. Порівняння ARI методів на реальних датасетах із розміткою: а - BPLA (37 сцен); б - OEM (76 сцен)




Рис. 6. Масштабованість часу виконання конвеєру: а - залежність від обсягу вибірки N у log-log шкалі (HDBSCAN завершується збоєм пам'яті при $N > 30\,000$); б - залежність ARI від кількості класів K

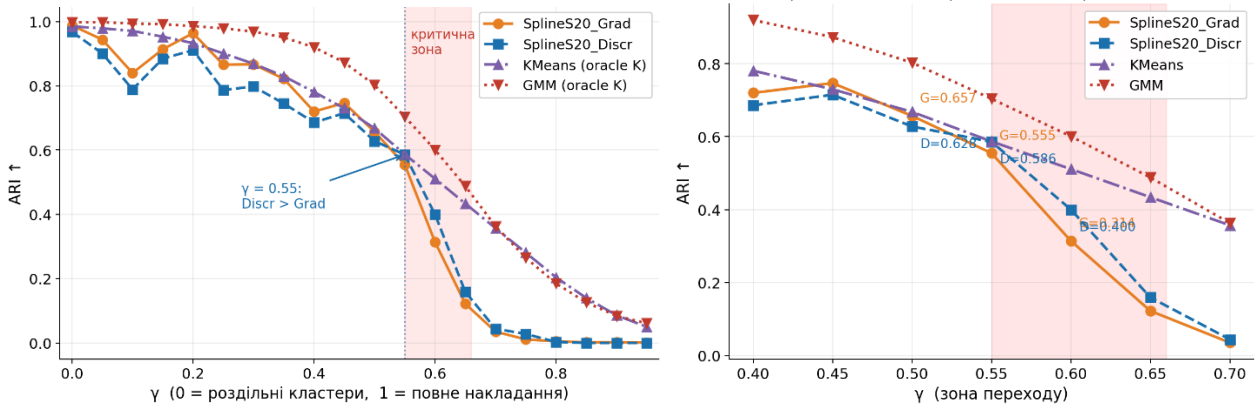


Рис. 7. Оцінка глобальної точності:
 а - крива ARI при зростаючому зближенні кластерів γ на змодельованих даних ($K = 3$);
 б - збільшення критичної зони $\gamma \in [0,4; 0,7]$




Рис. 8. Візуалізація результатів розробленого конвеєру інформаційної технології

Логарифмічно-логарифмічний нахил α підтверджує теоретичну складність $O(A_\mu \cdot A_\sigma)$ аналітичного ядра. Стратегія Discr демонструє $\alpha = 0,070$ - практично константний час. При N від 600 до 90 000 повний конвеєр змінюється з 0,40 до 0,61 с, базовий - з 0,028 до 0,037 с. Grad має $\alpha = 0,191$ (сублінійне зростання). HDBSCAN ($\alpha = 1,661$) при $N = 30\ 000$ потребує 10,15 с і є операційно неприйнятним для бортового обчислювача. Стратифікація за реальним K виявила характеристичну область переваги. При $K = 4$ обидві стратегії перевершують усі методи включаючи oracle (Discr = 0,367; Grad = 0,362 проти KMeans_oracle = 0,330). При $K \geq 5$ Grad (0,367) незначно кращий за Discr (0,325) завдяки точнішій апроксимації складних мод градієнтним потенціалом (рис. 6).

Глобальна точність auto- K визначення (Exp F, 120 реалізацій): Discr досягає $|\Delta k| = 0,942$, Grad - 0,950, тоді як HDBSCAN - 2,508 і GMM_BIC - 3,242. Обидві стратегії Splines20 втричі точніші за GMM_BIC при одночасно вищому ARI. На змодельованих даних (Exp G) при $\gamma < 0,50$ обидві стратегії утримують $ARI > 0,62$. У зоні $\gamma \in [0,55; 0,65]$ відбувається перетин - Discr ($ARI = 0,586$) вперше перевищує Grad (0,555), оскільки TLS/SVD-дискримінант стійкіший при мінімальному градієнті поверхні між кластерами $|\nabla S| \rightarrow 0$. Оскільки реальні аерознімки відповідають $\gamma < 0,50$, це є граничним обмеженням, а не характерним режимом (рис. 7).

Системна перевага технології підтверджується у п'яти вимірах: (1) $ARI = 0,571-0,580$ при $p_{\text{auto}} = 0,10 - 0,20$ - вдвічі вище за конкурентів без механізму confidence; (2) варіант p_{50} перевершує oracle на всіх трьох датасетах ($ARI = 0,423-0,438$); (3) $|\Delta k| = 0,942 - 0,950$ - втричі точніше GMM_BIC і вдвічі точніше HDBSCAN; (4) $\alpha = 0,070$ для Discr - практично константний час, придатний для SWaP-обмеженого бортового розгортання; (5) $\sigma(ARI) = 0$ - архітектурна гарантія детермінованості проти $\sigma = 0,101$ у GMM. Критерій Фрідмана ($p < 0,05$) і ефект Коена ($d > 0,8$) підтверджують статистичну та практичну значущість переваги. Виявлення аномалій без розмічених даних - ROC-AUC = 0,630 проти One-Class SVM (0,591), реалізується у Фазі 2 без додаткових обчислювальних витрат.

Візуальне зіставлення результатів масштабованості (рис. 8) наочно демонструє, що запропонована ІТ є збалансованим рішенням, яке поєднує архітектурну гнучкість, повну детермінованість та асимптотичну незалежність швидкодії від роздільної здатності сенсорів БПЛА, що робить її універсальною платформою для систем повітряного спостереження реального часу.

6. Висновки та перспективи подальших досліджень

У роботі розроблено інформаційну технологію автоматизованого аналізу аерознімків БПЛА на основі поліноміальної сплайн-апроксимації $S_{2,0}$, що вирішує задачу формування навчальної бази з нерозмічених зображень для семантичної сегментації. Технологія реалізована у вигляді трирівневої архітектури Core-Services-GUI з двофазним конвеєром, теоретична складність якого становить $O(A_\mu \cdot A_\sigma)$ незалежно від розміру вхідного зображення.

Верифікація на 120 реалізаціях дискретного поля інтенсивностей підтвердила системну перевагу технології. Механізм відбору псевдоміток при $p_{\text{auto}} = 0,10 - 0,20$ забезпечує $ARI = 0,571-0,580$, що вдвічі перевищує конкурентні методи без механізму confidence, а варіант з відбором 50% найбільш впевнених пікселів перевершує oracle-методи з апіорним k_{true} на всіх трьох датасетах ($ARI = 0,423-0,438$). Точність автоматичного визначення кількості кластерів $|\Delta k| = 0,942 - 0,950$ є втричі кращою за GMM_BIC. Стратегія Discr демонструє log-log нахил $\alpha = 0,070$, що підтверджує придатність до SWaP-обмеженого бортового розгортання, а детермінованість $\sigma(ARI) = 0$ є архітектурною гарантією відтворюваності навчальної бази. Статистичну значущість результатів підтверджено критерієм Фрідмана ($p < 0,05$) та ефектом Коена ($d > 0,8$).

Встановлено, що при $\gamma \geq 0,55$ якість знижується внаслідок нестійкості ідентифікації сідлової точки на $S_{2,0}$ при $|\nabla S| \rightarrow 0$, однак реальні аерознімки відповідають діапазону $\gamma < 0,50$, тому це є прийнятним граничним обмеженням.

Перспективами подальших досліджень є інтеграція псевдоміток у повний цикл напівсупервізованого навчання з оцінкою приросту точності сегментації, розширення апроксимаційного базису для підвищення стійкості у критичній зоні $\gamma \geq 0,55$, а також апаратна оптимізація базового конвеєру для розгортання на спеціалізованих бортових обчислювачах.

Внесок авторів Анастасія Жултинська – концептуалізація; аналітичне опрацювання джерел; методика; збір і перевірка емпіричних даних; програмне забезпечення; емпіричне дослідження; візуалізація; підготовка первинного тексту; Оксана Золотухіна – аналітичне опрацювання джерел; систематизація, підготовка та організація джерел і даних для подальшого аналізу; візуалізація; редагування та доопрацювання.

Декларація про штучний інтелект

Автори декларують, що інструменти штучного інтелекту застосовувалися виключно для допоміжного редагування тексту (перевірка стилістики, граматики та формулювань). Штучний інтелект не використовувався для генерування наукового змісту, результатів дослідження, інтерпретації даних або формулювання висновків. Усі наукові положення статті є результатом самостійної роботи авторів.

Конфлікт інтересів

Автори заявляють про відсутність конфлікту інтересів та підтверджують, що під час підготовки цієї роботи не існувало жодних комерційних, фінансових чи інших взаємовідносин, які могли б бути розцінені як такі, що здатні вплинути на результати дослідження або їх інтерпретацію. Робота виконана відповідно до принципів академічної доброчесності, етичних норм проведення наукових досліджень та вимог редакційної політики щодо запобігання конфлікту інтересів.

Список використаної літератури

1. Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646. <https://doi.org/10.1109/IIOT.2016.2579198>
2. Telli, K., Kraa, O., Himeur, Y., Ouamane, A., Boumehraz, M., Atalla, S., & Mansoor, W. (2023). A comprehensive review of recent research trends on UAVs. *arXiv*. <https://doi.org/10.48550/arXiv.2307.13691>
3. Zhu, X. X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>
4. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
5. Lyu, Y., Vosselman, G., Xia, G.-S., Yilmaz, A., & Yang, M. Y. (2020). UAVid: A semantic segmentation dataset for UAV imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 165, 108–119. <https://doi.org/10.1016/j.isprsjprs.2020.05.009>
6. Zong, B., Song, Q., Min, M., Cheng, W., Lumezanu, C., Cho, D., & Chen, H. (2018). Deep autoencoding Gaussian mixture model for unsupervised anomaly detection. In *International Conference on Learning Representations*.
7. Ruff, L., Vandermeulen, R., Goernitz, N., Deecke, L., Siddiqui, S. A., Binder, A., Müller, E., & Kloft, M. (2018). Deep one-class classification. In *Proceedings of the 35th International Conference on Machine Learning* (pp. 4393–4402). PMLR. <https://proceedings.mlr.press/v80/ruff18a.html>
8. Xiao, H., Zhao, K., Xie, X., Song, P., Dong, S., & Yang, J. (2024). YOLOv5-LW: Lightweight UAV object detection algorithm based on YOLOv5. In C. Wu, X. Chen, J. Feng, & Z. Wu (Eds.), *Mobile Networks and Management (MONAMI 2023)* (Vol. 559, pp. 1–13). Springer. https://doi.org/10.1007/978-3-031-55471-1_2
9. Canziani, A., Paszke, A., & Culurciello, E. (2016). An analysis of deep neural network models for practical applications. *arXiv*. <https://doi.org/10.48550/arXiv.1605.07678>
10. Wang, M., & Deng, W. (2018). Deep visual domain adaptation: A survey. *Neurocomputing*, 312, 135–153. <https://doi.org/10.1016/j.neucom.2018.05.083>
11. Arthur, D., & Vassilvitskii, S. (2007). K-means++: The advantages of careful seeding. In *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms* (pp. 1027–1035).
12. Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). Isolation forest. In *2008 Eighth IEEE International Conference on Data Mining* (pp. 413–422). <https://doi.org/10.1109/ICDM.2008.17>
13. Breunig, M. M., Kriegel, H.-P., Ng, R. T., & Sander, J. (2000). LOF: Identifying density-based local outliers. In *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data* (pp. 93–104). <https://doi.org/10.1145/342009.335388>
14. Reynolds, D. A. (2009). Gaussian mixture models. In S. Z. Li & A. Jain (Eds.), *Encyclopedia of biometrics* (pp. 659–663). Springer. https://doi.org/10.1007/978-0-387-73003-5_196

15. Biernacki, C., Celeux, G., & Govaert, G. (2000). Assessing a mixture model for clustering with the integrated completed likelihood. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(7), 719–725. <https://doi.org/10.1109/34.865189>
16. Ojala, T., Pietikäinen, M., & Mäenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987. <https://doi.org/10.1109/TPAMI.2002.1017623>
17. Schubert, E., Sander, J., Ester, M., Kriegel, H.-P., & Xu, X. (2017). DBSCAN revisited, revisited: Why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems*, 42(3), Article 19, 1–21. <https://doi.org/10.1145/3068335>
18. Campello, R. J. G. B., Moulavi, D., & Sander, J. (2013). Density-based clustering based on hierarchical density estimates. In J. Pei, V. S. Tseng, L. Cao, H. Motoda, & G. Xu (Eds.), *Advances in Knowledge Discovery and Data Mining* (pp. 160–172). Springer. https://doi.org/10.1007/978-3-642-37456-2_14
19. Jain, A. K. (2010). Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, 31(8), 651–666. <https://doi.org/10.1016/j.patrec.2009.09.011>
20. Fakhoury, D., Fakhoury, E., & Speleers, H. (2022). ExSpliNet: An interpretable and expressive spline-based neural network. *Neural Networks*, 152, 332–346. <https://doi.org/10.1016/j.neunet.2022.04.029>
21. Приставка, П. О. (2004). *Поліноміальні сплайни в задачах обробки інформації*. Вид-во ДНУ.
22. Zhultynska, A., & Prystavka, P. (2024). Spline model of digital images based on moment characteristics. In *Proceedings of the 3rd International Conference on Cyber Hygiene & Conflict Management in Global Information Networks* (pp. 325–333). <https://ceur-ws.org/Vol-3925/short09.pdf>
23. Zhultynska, A., & Prystavka, P. (2025). Method for reproducing the estimation of heterogeneous mixtures of distributions based on non-parametric spline for anomaly detection in digital images. In *Proceedings of the Workshop on Cybersecurity Providing in Information and Telecommunication Systems* (pp. 587–593). <https://ceur-ws.org/Vol-3991/short4.pdf>
24. Zhultynska, A., & Prystavka, P. (2024). Spline approaches for anomaly detection in UAV-based aerial surveillance. In *2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development* (pp. 187–190). IEEE. <https://doi.org/10.1109/APUAVD64488.2024.10765898>

References

1. Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646. <https://doi.org/10.1109/JIOT.2016.2579198>
2. Telli, K., Kraa, O., Himeur, Y., Ouamane, A., Boumehraz, M., Atalla, S., & Mansoor, W. (2023). A comprehensive review of recent research trends on UAVs. *arXiv*. <https://doi.org/10.48550/arXiv.2307.13691>
3. Zhu, X. X., Tuia, D., Mou, L., Xia, G.-S., Zhang, L., Xu, F., & Fraundorfer, F. (2017). Deep learning in remote sensing: A comprehensive review and list of resources. *IEEE Geoscience and Remote Sensing Magazine*, 5(4), 8–36. <https://doi.org/10.1109/MGRS.2017.2762307>
4. Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., & Johnson, B. A. (2019). Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
5. Lyu, Y., Vosselman, G., Xia, G.-S., Yilmaz, A., & Yang, M. Y. (2020). UAVid: A semantic segmentation dataset for UAV imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 165, 108–119. <https://doi.org/10.1016/j.isprsjprs.2020.05.009>
6. Zong, B., Song, Q., Min, M., Cheng, W., Lumezanu, C., Cho, D., & Chen, H. (2018). Deep autoencoding Gaussian mixture model for unsupervised anomaly detection. In *International Conference on Learning Representations*.
7. Ruff, L., Vandermeulen, R., Goernitz, N., Deecke, L., Siddiqui, S. A., Binder, A., Müller, E., & Kloft, M. (2018). Deep one-class classification. In *Proceedings of the 35th International Conference on Machine Learning* (pp. 4393–4402). PMLR. <https://proceedings.mlr.press/v80/ruff18a.html>
8. Xiao, H., Zhao, K., Xie, X., Song, P., Dong, S., & Yang, J. (2024). YOLOv5-LW: Lightweight UAV object detection algorithm based on YOLOv5. In C. Wu, X. Chen, J. Feng, & Z. Wu (Eds.), *Mobile Networks and Management (MONAMI 2023)* (Vol. 559, pp. 1–13). Springer. https://doi.org/10.1007/978-3-031-55471-1_2

9. Canziani, A., Paszke, A., & Culurciello, E. (2016). An analysis of deep neural network models for practical applications. *arXiv*. <https://doi.org/10.48550/arXiv.1605.07678>
10. Wang, M., & Deng, W. (2018). Deep visual domain adaptation: A survey. *Neurocomputing*, 312, 135–153. <https://doi.org/10.1016/j.neucom.2018.05.083>
11. Arthur, D., & Vassilvitskii, S. (2007). K-means++: The advantages of careful seeding. In *Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms* (pp. 1027–1035).
12. Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). Isolation forest. In *2008 Eighth IEEE International Conference on Data Mining* (pp. 413–422). <https://doi.org/10.1109/ICDM.2008.17>
13. Breunig, M. M., Kriegel, H.-P., Ng, R. T., & Sander, J. (2000). LOF: Identifying density-based local outliers. In *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data* (pp. 93–104). <https://doi.org/10.1145/342009.335388>
14. Reynolds, D. A. (2009). Gaussian mixture models. In S. Z. Li & A. Jain (Eds.), *Encyclopedia of biometrics* (pp. 659–663). Springer. https://doi.org/10.1007/978-0-387-73003-5_196
15. Biernacki, C., Celeux, G., & Govaert, G. (2000). Assessing a mixture model for clustering with the integrated completed likelihood. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(7), 719–725. <https://doi.org/10.1109/34.865189>
16. Ojala, T., Pietikäinen, M., & Mäenpää, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7), 971–987. <https://doi.org/10.1109/TPAMI.2002.1017623>
17. Schubert, E., Sander, J., Ester, M., Kriegel, H.-P., & Xu, X. (2017). DBSCAN revisited, revisited: Why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems*, 42(3), Article 19, 1–21. <https://doi.org/10.1145/3068335>
18. Campello, R. J. G. B., Moulavi, D., & Sander, J. (2013). Density-based clustering based on hierarchical density estimates. In J. Pei, V. S. Tseng, L. Cao, H. Motoda, & G. Xu (Eds.), *Advances in Knowledge Discovery and Data Mining* (pp. 160–172). Springer. https://doi.org/10.1007/978-3-642-37456-2_14
19. Jain, A. K. (2010). Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, 31(8), 651–666. <https://doi.org/10.1016/j.patrec.2009.09.011>
20. Fakhoury, D., Fakhoury, E., & Speleers, H. (2022). ExSpliNet: An interpretable and expressive spline-based neural network. *Neural Networks*, 152, 332–346. <https://doi.org/10.1016/j.neunet.2022.04.029>
21. Prystavka, P. O. (2004). *Polynomialni splainy v zadachakh obrobky informatsii* [Polynomial splines in information processing tasks]. Dnipropetrovsk National University.
22. Zhultynska, A., & Prystavka, P. (2024). Spline model of digital images based on moment characteristics. In *Proceedings of the 3rd International Conference on Cyber Hygiene & Conflict Management in Global Information Networks* (pp. 325–333). <https://ceur-ws.org/Vol-3925/short09.pdf>
23. Zhultynska, A., & Prystavka, P. (2025). Method for reproducing the estimation of heterogeneous mixtures of distributions based on non-parametric spline for anomaly detection in digital images. In *Proceedings of the Workshop on Cybersecurity Providing in Information and Telecommunication Systems* (pp. 587–593). <https://ceur-ws.org/Vol-3991/short4.pdf>
24. Zhultynska, A., & Prystavka, P. (2024). Spline approaches for anomaly detection in UAV-based aerial surveillance. In *2024 IEEE 7th International Conference on Actual Problems of Unmanned Aerial Vehicles Development* (pp. 187–190). IEEE. <https://doi.org/10.1109/APUAVD64488.2024.10765898>

Надійшла до редакції: 13.12.25

Прийнята до друку: 17.03.26

Опубліковано: 30.03.26