

В. К. ОБОДЯК

кандидат технічних наук, доцент,
доцент кафедри кібербезпеки
Сумський державний університет
ORCID: 0000-0002-8539-1252

М. С. ОТРОЩЕНКО

аспірант кафедри комп'ютерних наук
Сумський державний університет
ORCID: 0000-0001-5064-6780

ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНОГО МАШИННОГО НАВЧАННЯ ДЛЯ РОЗПІЗНАВАННЯ НАЗЕМНИХ ОБ'ЄКТІВ БЕЗПЛОТНИМИ ЛІТАЛЬНИМИ АПАРАТАМИ

Стаття присвячена обґрунтуванню інноваційного підходу до автономної навігації безпілотних літальних апаратів (БПЛА) на основі машинного навчання з використанням інформаційно-екстремального методу. Основна увага зосереджена на оптимізації параметрів машинного навчання для підвищення точності розпізнавання наземних об'єктів у геопросторовій сцені.

У дослідженні визначено оптимальні значення параметрів машинного навчання вектору, що дозволило побудувати геометричні контейнери класів розпізнавання та сформувати на їх основі ефективні вирішувальні правила. Функціональне тестування алгоритму підтвердило безпомилковість роботи системи за навчальною матрицею, а екзаменаційний етап продемонстрував високу точність машинного навчання автономного БПЛА.

Ключовим теоретичним результатом є обґрунтування задачі інформаційно-екстремального синтезу бортової системи безпілотного літального апарату, яка полягає у пошуку глобального максимуму інформаційного критерію для оптимізації параметрів навчання у різних зонах геопросторової сцени. Додатково запропоновано функціональну категорійну модель машинного навчання другого рівня глибини, що може значно підвищити якість розпізнавання в умовах динамічного середовища.

Запропоновано нову функціональну категорійну модель машинного навчання другого рівня глибини, що значно підвищує якість розпізнавання складних об'єктів у динамічних умовах. Ефективність моделі полягає у поєднанні інформаційно-екстремального методу з категорійною моделлю машинного навчання. Практична значимість отриманих результатів проявляється у можливості їх використання для розробки інтелектуальних систем управління БПЛА, обробки геопросторових даних та застосування у військовій, картографічній та моніторинговій сферах.

Робота відкриває нові перспективи для створення високоефективних автономних систем навігації, здатних функціонувати в реальному часі у умовах динамічного змінного середовища.

Ключові слова: БПЛА, машинне навчання, інформаційно-екстремальний підхід, автономна навігація.

V. K. OBODYAK

Candidate of Technical Sciences,
Associate Professor at the Department of Cybersecurity
Sumy State University
ORCID: 0000-0002-8539-1252

M. S. OTROSHCHENKO

Postgraduate Student at the Department of Computer Science
Sumy State University
ORCID: 0000-0001-5064-6780

OPTIMIZING INFORMATION-EXTREMAL MACHINE LEARNING PARAMETERS FOR GROUND OBJECT RECOGNITION BY UNMANNED AERIAL VEHICLES

The article is devoted to the justification of an innovative approach to autonomous navigation of unmanned aerial vehicles (UAVs) based on machine learning using the information-extreme method. The main focus is on optimizing machine learning parameters to increase the accuracy of recognition of ground objects in a geospatial scene.

The study determined the optimal values of the vector machine learning parameters, which allowed constructing geometric containers of recognition classes and forming effective decision rules based on them. Functional testing of the algorithm confirmed the accuracy of the system's operation based on the training matrix, and the examination stage demonstrated the high accuracy of machine learning of an autonomous UAV.

The key theoretical result is the justification of the information-extreme synthesis problem of the onboard system of an unmanned aerial vehicle, which consists in finding the global maximum of the information criterion for optimizing the training parameters in different zones of the geospatial scene. Additionally, a functional categorical machine learning model of the second level of depth is proposed, which can significantly improve the quality of recognition in a dynamic environment.

A new functional categorical machine learning model of the second level of depth is proposed, which significantly improves the quality of recognition of complex objects in dynamic conditions. The effectiveness of the model lies in the combination of the information-extreme method with the categorical machine learning model. The practical significance of the results obtained is manifested in the possibility of their use for the development of intelligent UAV control systems, geospatial data processing and application in the military, cartographic and monitoring spheres.

The work opens up new prospects for the creation of highly efficient autonomous navigation systems capable of operating in real time in a dynamic, changing environment.

Key words: UAV, machine learning, information-extreme approach, autonomous navigation.

Постановка проблеми

Сучасний розвиток технологій автономних БПЛА вимагає високої точності та надійності систем навігації, особливо в умовах динамічного та непередбачуваного середовища. Одним із ключових напрямків удосконалення бортових систем розпізнавання (БСР) є використання методів відео навігації, які дозволяють забезпечити автономне орієнтування БПЛА на основі аналізу візуальних даних. У цьому контексті важливим є вибір оптимального методу дослідження, який би враховував специфіку функціонування БПЛА та забезпечував високу ефективність прийняття рішень. За таким умов актуальним вбачається пошук та обґрунтування нових підходів та технологій до автономної навігації БПЛА на основі машинного навчання.

Аналіз останніх досліджень і публікацій

Огляд зазначеної проблематики свідчить про підвищений науковий інтерес з боку дослідників. Бадрінараянан, В., Кендалл, А., Чіполла, Р. [3], Чен, Л. К., Папандреу, Г., Коккінос, І., Мерфі, К., та Юйль, А. Л. [5], Роннебергер, О., Фішер, П., та Брокс, Т. [14], які присвятили власні дослідження розв'язанню проблеми забезпечення якості сегментації зображень за допомогою використання згорткової архітектури. Довбиш А. С., Будник М. М., П'ятаченко В. Ю., Мироненко М. І. [9], роботи яких присвячені інформаційно-екстремальному машинному навчанню бортової системи розпізнавання. Енгель, Дж., Колтун, В., Кремерс, Д. [6], Форстер, К., Піццолі, М., та Скарамуцца, Д. [6], Сінґх І. П., Патель А. [16], Скарамуцца, Д., Фраундорфер, Ф. [15], в роботах яких містяться ґрунтовні пропозиції щодо удосконалення візуальної одометрії в системах сучасної навігації.

Заслужує на увагу підхід до вирішення проблеми виявлення та уникнення БПЛА, який запропонований в роботі Фазано, Джанкармін; Аккардо, Доменіко; Тіррі, Мочча, Антоніо та Етторе Де Лелліс [13].

Крім того, варто відмітити праці, присвячені дослідженню окремих питань навігації, таких вчених, як: Хуанг, Г. [8], Парк, Дж., та Лі, Х. [12].

Поряд із цим, як показав ґрунтовний аналіз окреслених праць, потреба в нових підходах до автономної навігації БПЛА на основі машинного навчання залишається актуальною та потребує негайного розв'язання.

Формулювання мети дослідження

Метою статті є обґрунтування нового підходу до автономної навігації БПЛА на основі машинного навчання.

Викладення основного матеріалу дослідження

Розглянемо в рамках ІЕІ-технології формалізовану постановку задачі інформаційного синтезу здатної навчати бортової системи автономного БПЛА для розпізнавання наземних об'єктів у геопросторовій сцені.

Нехай сформовано множину абеток $\{X_m^o(z) | m = \overline{1, M}; z = \overline{1, Z_{\max}}\}$ класів розпізнавання, які характеризують однакові M наземних об'єктів в різних зонах геопросторової сцени. Для кожного параметричного класу розпізнавання $X_m^o(z)$, де z – параметр, який визначає номер зони геопросторової сцени, побудовано чотирьох вимірну навчальну матрицю $\|y_{m,i}^{(j)}(z)\|$ яскравості пікселів рецепторного поля кадрів зображення регіону, в якій рядок $\{y_{m,i}^{(j)}(z) | i = \overline{1, N}\}$, де N – кількість ознак розпізнавання, є реалізацією відповідного параметричного класу розпізнавання $X_m^o(z)$, а стовпчик матриці – випадкова навчальна вибірка $\{y_{m,i}^{(j)}(z) | j = \overline{1, N}\}$, яка складається з n випадкових значень i -ї ознаки класу розпізнавання $X_m^o(z)$.

У бінарному просторі ознак Геммінга для заданого рівня глибини інформаційно-екстремального машинного навчання задано вектор-кортеж $\{g_m(z)\}$ параметрів машинного навчання, які впливають на його точність. У загальному випадку структура вектору параметрів машинного навчання бортової системи розпізнавання (БСР) для заданої абетки класів розпізнавання $\{X_m^o(z)\}$ має вигляд

$$g_m(z) = \langle g_{m,1}(z), \dots, g_{m,\xi}(z), \dots, g_{m,\Xi}(z) \rangle. \quad (1)$$

Водночас задано обмеження на відповідні параметри машинного навчання:

$$\text{Rm}(g_{m,1}(z), \dots, g_{m,\xi}(z), \dots, g_{m,\Xi}(z)) \leq 0.$$

У процесі інформаційно-екстремального машинного навчання автономного БПЛА необхідно:

1) Визначити для заданого рівня глибини ξ оптимальні значення параметрів машинного навчання вектору, які забезпечують максимальне значення усередненого за абеткою класів розпізнавання інформаційного критерію, обчислене в робочій (допустимій) області визначення його функції:

$$\bar{E}^*(z) = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap G_d} E_m^{(z)}(d), \quad (2)$$

де $E_m^{(z)}(d)$ – інформаційний критерій оптимізації параметрів машинного навчання, обчислений при поточному значенні радіусу гіперсферичного контейнера параметричного класу розпізнавання $X_m^o(z)$; G_E – робоча область визначення інформаційного критерію оптимізації параметрів машинного навчання; G_d – область допустимих значень радіусів контейнерів класів розпізнавання;

2) За визначеними на етапі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання побудувати вирішувальні правила;

3) У режимі функціонального тестування алгоритму інформаційно-екстремального машинного навчання автономного БПЛА перевірити безпомилковість за навчальною матрицею вирішувальних правил, побудованих за отриманими в процесі машинного навчання геометричними параметрами контейнерів класів розпізнавання;

4) На етапі екзамєну перевірити точність машинного навчання автономного БПЛА і при необхідності збільшити глибину машинного навчання шляхом оптимізації інших параметрів функціонування системи, включаючи параметри формування вхідного математичного опису.

Таким чином, задача інформаційно-екстремального синтезу бортової системи автономного БПЛА для розпізнавання наземних об'єктів у геопросторовій сцені полягає в оптимізації параметрів машинного навчання (1) класів розпізнавання в різних зонах геопросторової сцени шляхом пошуку глобального максимуму інформаційного критерію (2).

Обов'язковою умовою для визначення координат місцезнаходження автономного БПЛА є наявність правил прийняття рішень на основі результатів машинного навчання БСР наземних цілей, обраних під час планування місії автономного БПЛА; для визначення місцезнаходження БПЛА необхідно визначити його відстань до виявлених наземних цілей. Традиційним непрямим методом визначення відстані є вимірювання кутів пеленгу до навігаційних маяків на відомій висоті БПЛА. Однак використання бортового радіопеленгатора не забезпечує інформаційну безпеку БПЛА через вплив засобів радіоелектронної боротьби. Більш перспективним є використання лазерного далекоміра (лідара), який дозволяє з точністю до одного метра визначати відстань до наземного об'єкта, що знаходиться на відстані 1000 метрів від БПЛА [11].

У рамках ІЕІ-технології розглянемо задачу інформаційно-екстремального машинного навчання з оптимізацією контрольних допусків на ознаки параметричних класів розпізнавання.

Нехай для розпізнавання реалізацій, наприклад, параметричного класу розпізнавання $X_m^o(z)$ задано вектор параметрів машинного навчання автономного БПЛА для розпізнавання наземних об'єктів у геопросторовій сцені:

$$g_m(z) = \langle x_m(z), d_m(z), \delta(z) \rangle, \quad (3)$$

де $x_m(z)$ – усереднений за реалізаціями двійковий вектор ознак, вершина якого визначає центр гіперсферичного контейнера класу розпізнавання $X_m^o(z)$; $d_m(z)$ – радіус гіперсферичного контейнера класу розпізнавання $X_m^o(z)$, який відновлюється в радіальному базисі простору ознак розпізнавання; $\delta(z)$ – параметр, величина якого дорівнює половині симетричного поля контрольних допусків для всіх ознак розпізнавання.

Згідно з працею [9] параметр $\delta(z)$ дорівнює половині симетричного поля контрольних допусків i -ї ознаки розпізнавання (рис. 1).




Рис. 1. Поля допусків на ознаку розпізнавання

На рисунку 1 прийнято такі позначення: $A_{0,i}$ – номінальне значення ознаки y_i ; $A_{H,i}$ – нижній нормований (експлуатаційний) допуск; $A_{b,i}$ – верхній нормований допуск; $A_{HK,i}$ – нижній контрольний допуск; $A_{BK,i}$ – верхній контрольний допуск; $\delta_{K,i}$ – поле контрольних допусків; $\delta_{H,i}$ – поле нормованих допусків, δ_i – параметр, який дорівнює половині симетричного двобічного поля контрольних допусків i -ї ознаки розпізнавання.

Область значень параметра $\delta(z)$ задається нерівністю

$$\delta(z) < \delta_H(z)/2,$$

де $\delta_H(z)$ – мінімальне нормоване поле допусків на ознаки розпізнавання, яке задає область значень параметра $\delta(z)$.

Область значень радіуса контейнера параметричного класу розпізнавання $X_m^o(z)$ задається нерівністю

$$d_m(z) < d[x_m(z) \oplus x_c(z)],$$

де $d(x_m \oplus x_c)$ – міжцентрова відстань між класом розпізнавання $X_m^o(z)$ і його найближчим сусідом $X_c^o(z)$, яка визначається як кодова відстань між відповідними усередненими векторами ознак розпізнавання $x_m(z)$ і $x_c(z)$.

Таким чином, вектор задає третій рівень глибини машинного навчання, оскільки оптимізуються на першому рівні глибини два геометричні параметри: усереднений вектор ознак розпізнавання $x_m(z)$ і радіус $d_m(z)$ гіперсферичного контейнера класу розпізнавання X_m^o ; на другому рівні – параметр δ .

Необхідно визначити для заданого рівня глибини оптимальні значення параметрів машинного навчання вектору, які забезпечують максимальне значення усередненого за абеткою класів розпізнавання інформаційного критерію, обчислене в робочій (допустимій) області визначення його функції.

У рамках ІЕІ-технології реалізація алгоритмічного забезпечення починається із розроблення категорійної функціональної моделі інформаційно-екстремального машинного навчання заданого рівня глибини.

Вхідний математичний опис автономної БСР функціональної категорійної моделі представимо у вигляді, аналогічному структурі:

$$I_{ex} = \langle W, T, \Omega, Z, X, \{Y^{[M]}(z)\}, \{X^{[M]}(z)\}; f_1, f_2 \rangle, \quad (3)$$

де $\{Y^{[M]}(z)\}$ – вхідна навчальна матриця M параметричних класів розпізнавання; $\{X^{[M]}(z)\}$ – робоча бінарна навчальна матриця M параметричних класів розпізнавання, задана в Геммінговому просторі ознак розпізнавання.

На рисунку 2 показано функціональну категорійну модель інформаційно-екстремального машинного навчання за алгоритмом другого рівня глибини для розпізнавання наземних об'єктів у геопросторовій сцені з паралельною оптимізацією контрольних допусків на ознаки розпізнавання. На першому рівні здійснюється оптимізація геометричних параметрів контейнерів класів розпізнавання, на другому – оптимізація контрольних допусків на ознаки розпізнавання.




Рис. 2. Функціональна категорійна модель машинного навчання другого рівня глибини для розпізнавання наземних об'єктів у геопросторовій сцені

На рисунку 2 терм-множина E значень інформаційного критерію є загальною для всіх контурів оптимізації параметрів машинного навчання, заданих вектором (3). Оператор $r: E \rightarrow \tilde{\mathcal{R}}^{[M]}(z)$ будує на кожному кроці машинного навчання у загальному випадку апріорно нечітке покриття $\tilde{\mathcal{R}}^{[M]}(z)$, яке відображається оператором ζ на розподіл $\{X^{[M]}(z)\}$ двійкових векторів ознак розпізнавання. Далі оператор $\psi: X^{[M]}(z) \rightarrow I^{[G]}(z)$, де $I^{[G]}(z)$ – множина G гіпотез перевіряє основну статистичну гіпотезу $\gamma_1: x_{m,i}^{(j)} \in X_m^o$. Оператор γ формує множину $\mathcal{Z}^{[Q]}(z)$ точнісних характеристик класифікаційних рішень, де $Q = G^2$, а оператор ϕ обчислює множину значень E інформаційного критерію оптимізації як функціонала від точнісних характеристик. Контур оптимізації контрольних допусків на ознаки розпізнавання замикається через терм-множину D , елементами якої є значення системи контрольних допусків на ознаки розпізнавання. У цьому контурі оператор δ_1 на кожному кроці машинного навчання задає з терм-множини D нове значення параметра δ_1 поля контрольних допусків, який оптимізується в процесі машинного навчання за паралельним алгоритмом. Оператор δ_2 обчислює на кожному кроці машинного навчання нові

контрольні допуски для всіх ознак розпізнавання. Оператор λ_1 запускає лічильник Λ зон геопросторової сцени, а оператор λ_2 обирає набір зображень наземних об'єктів, розташованих у відповідній зоні геопросторової сцени, які відображаються на горизонтальному моніторі багатофункціонального стенду-симулятора динамічного оточення для формування вхідної навчальної матриці $Y^{IM}(z)$. Процес машинного навчання регламентується оператором u .

Перевагою інформаційно-екстремального машинного навчання порівняно зі згортковими штучними нейронними мережами (ШНМ) є на порядок менший розмір вибірки наземних опорних зображень, що значно зменшує матеріальні та часові витрати машинного навчання. Правила прийняття рішень, засновані на результатах інформаційно-екстремального машинного навчання, характеризувалися високою точністю та ефективністю класифікаційних рішень. При цьому для генерації вхідної інформації використовувався багатофункціональний симулятор динамічного середовища, що значно зменшує матеріальні та часові витрати машинного навчання БПЛА.

У зв'язку зі складністю й ресурсомісткістю проведення натурних експериментів з використанням реальних безпілотних літальних апаратів (БПЛА) в умовах динамічного геопросторового середовища, на початковому етапі дослідження було зосереджено увагу на теоретичному моделюванні та математичному обґрунтуванні запропонованого підходу.

Висновки

Таким чином, показана на рисунку 2 функціональна категорійна модель представляє узагальнену структурну схему базового двох циклічного алгоритму інформаційно-екстремального машинного навчання з оптимізацією радіусів гіперсферичних контейнерів класів розпізнавання і контрольних допусків на ознаки розпізнавання. Реалізація цього алгоритму дозволяє на кожному кроці машинного навчання трансформувати вхідну навчальну матрицю в задану у просторі Геммінга робочу бінарну навчальну матрицю, яка в процесі інформаційно-екстремального машинного навчання адаптується до його максимальної точності, під якою розуміється середня повна ймовірність прийняття правильних класифікаційних рішень для заданої абетки класів розпізнавання.

Запропонована модель інформаційно-екстремального машинного навчання дозволяє формалізовано представити процес оптимізації параметрів розпізнавання, що є передумовою для подальшої розробки та практичної реалізації.

Отримані результати можуть бути інтегровані в програмне забезпечення симуляторів та використані для подальшої валідації на стендових або польових випробуваннях.

Список використаної літератури

1. Afghah F., Razi A., Chakareski J., Ashdown J. Wildfire Monitoring in Remote Areas using Autonomous Unmanned Aerial Vehicles // *arXiv preprint*. 2019. № arXiv:1905.00492. URL: <https://arxiv.org/abs/1905.00492>
2. An Onboard Vision-Based System for Autonomous Landing of a Low-Cost Quadrotor on a Novel Landing Pad / Liu et al. *Sensors*. 2019. Vol. 19, no. 21. P. 4703. URL: <https://doi.org/10.3390/s19214703>
3. Badrinarayanan V., Kendall A., Cipolla R. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2017. Vol. 39, no. 12. P. 2481–2495. URL: <https://doi.org/10.1109/tpami.2016.2644615>
4. Current status and perspective of remote sensing application in crop management / M. Jurišić et al. *Journal of Central European Agriculture*. 2021. Vol. 22, no. 1. P. 156–166. URL: [:10.5513/JCEA01/22.1.3042](https://doi.org/10.5513/JCEA01/22.1.3042)
5. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs / L.-C. Chen et al. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2018. Vol. 40, no. 4. P. 834–848. URL: <https://doi.org/10.1109/tpami.2017.2699184>
6. Engel J., Koltun V., Cremers D. Direct Sparse Odometry. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2018. Vol. 40, no. 3. P. 611–625. URL: <https://doi.org/10.1109/tpami.2017.2658577>
7. Forster C., Pizzoli M., Scaramuzza D. SVO: Fast semi-direct monocular visual odometry. *2014 IEEE International Conference on Robotics and Automation (ICRA)*. 2014. P. 15–22. URL: <https://ieeexplore.ieee.org/document/6906584/citations#citations>
8. G. Huang. Visual-Inertial Navigation: A Concise Review. *International Conference on Robotics and Automation (ICRA)*. 2019. P. 9572-9582. URL: [10.1109/ICRA.2019.8793604](https://doi.org/10.1109/ICRA.2019.8793604)
9. Information-Extreme Machine Learning of On-Board Vehicle Recognition System / A. S. Dovbysh et al. *Cybernetics and Systems Analysis*. 2020. Vol. 56, no. 4. P. 534–543. URL: <https://doi.org/10.1007/s10559-020-00269-y>
10. Liu Y., Zhang L. Machine Vision and Deep Learning for Autonomous UAV Navigation. *Journal of Field Robotics*. 2018. No. 35(4). P. 665–684. URL: <https://doi.org/10.1002/rob.21855>
11. Otroshchenko M., Myronenko M. DETERMINING THE LOCATION OF THE AUTONOMOUS UAV. *Information Technology and Implementation (Satellite): Conference Proceedings*, Kyiv, 24 November 2024. Kyiv, 2024. P. 56–57. URL: http://iti.fit.univ.kiev.ua/wp-content/uploads/36ipka-19_12_2024_ITI_2024-e.pdf

12. Park J., Lee H. GPS/IMU and Vision Integration for Autonomous UAV Navigation. *International Journal of Aerospace Engineering*. 2017. P. 1–10. URL: <https://doi.org/10.1155/2017/4792174>
13. Radar/electro-optical data fusion for non-cooperative UAS sense and avoid / G. Fasano et al. *Aerospace Science and Technology*. 2015. Vol. 46. P. 436–450. URL: <https://doi.org/10.1016/j.ast.2015.08.010>
14. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science*. Cham, 2015. P. 234–241. URL: https://doi.org/10.1007/978-3-319-24574-4_28
15. Scaramuzza D., Fraundorfer F. Visual Odometry [Tutorial]. *IEEE Robotics & Automation Magazine*. 2011. Vol. 18, no. 4. P. 80–92. URL: <https://doi.org/10.1109/mra.2011.943233>
16. Singh, I. P., Patel, A. Visual odometry for autonomous vehicles. *Int. J. of Adv. Res.* 7. 2019. P. 1136–1144. URL: <https://dx.doi.org/10.21474/IJAR01/9765>

References

1. Afghah F., Razi A., Chakareski J., Ashdown J. Wildfire Monitoring in Remote Areas using Autonomous Unmanned Aerial Vehicles // *arXiv preprint*. 2019. № arXiv:1905.00492. URL: <https://arxiv.org/abs/1905.00492>
2. Badrinarayanan, V., Kendall, A., & Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481–2495. <https://doi.org/10.1109/tpami.2016.2644615>
3. Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., & Yuille, A. L. (2018). DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(4), 834–848. <https://doi.org/10.1109/tpami.2017.2699184>
4. Current status and perspective of remote sensing application in crop management / M. Jurišić et al. *Journal of Central European Agriculture*. 2021. Vol. 22, no. 1. P. 156–166. URL: :10.5513/JCEA01/22.1.3042
5. Dovbysh, A. S., Budnyk, M. M., Piatachenko, V. Y., & Myronenko, M. I. (2020). Information-Extreme Machine Learning of On-Board Vehicle Recognition System. *Cybernetics and Systems Analysis*, 56(4), 534–543. <https://doi.org/10.1007/s10559-020-00269-y>
6. Engel, J., Koltun, V., & Cremers, D. (2018). Direct Sparse Odometry. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40(3), 611–625. <https://doi.org/10.1109/tpami.2017.2658577>
7. Fasano, G., Accardo, D., Tirri, A. E., Moccia, A., & De Lellis, E. (2015). Radar/electro-optical data fusion for non-cooperative UAS sense and avoid. *Aerospace Science and Technology*, 46, 436–450. <https://doi.org/10.1016/j.ast.2015.08.010>
8. Forster, C., Pizzoli, M., & Scaramuzza, D. (2014). SVO: Fast semi-direct monocular visual odometry. *2014 IEEE International Conference on Robotics and Automation (ICRA)*, 15–22. <https://ieeexplore.ieee.org/document/6906584/citations#citations>
9. G. Huang. Visual-Inertial Navigation: A Concise Review. *International Conference on Robotics and Automation (ICRA)*. 2019. P. 9572–9582. URL: 10.1109/ICRA.2019.8793604
10. Liu, Zhang, Tian & Liu. (2019). An Onboard Vision-Based System for Autonomous Landing of a Low-Cost Quadrotor on a Novel Landing Pad. *Sensors*, 19(21), 4703. <https://doi.org/10.3390/s19214703>
11. Liu, Y., & Zhang, L. (2018). Machine Vision and Deep Learning for Autonomous UAV Navigation. *Journal of Field Robotics*, (35(4)), 665–684. <https://doi.org/10.1002/rob.21855>
12. Otroshchenko, M., & Myronenko, M. (2024). DETERMINING THE LOCATION OF THE AUTONOMOUS UAV. *Y Information Technology and Implementation (Satellite): Conference Proceedings* (c. 56–57). Taras Shevchenko National University of Kyiv. http://iti.fit.univ.kiev.ua/wp-content/uploads/36ipka-19_12_2024_ITI_2024-e.pdf
13. Park, J., & Lee, H. (2017). GPS/IMU and Vision Integration for Autonomous UAV Navigation. *International Journal of Aerospace Engineering*, 1–10. <https://doi.org/10.1155/2017/4792174>
14. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Y Lecture Notes in Computer Science* (c. 234–241). Springer International Publishing. https://doi.org/10.1007/978-3-319-24574-4_28
15. Scaramuzza, D., & Fraundorfer, F. (2011). Visual Odometry [Tutorial]. *IEEE Robotics & Automation Magazine*, 18(4), 80–92. <https://doi.org/10.1109/mra.2011.943233>
16. Singh, I. P., Patel, A. Visual odometry for autonomous vehicles. *Int. J. of Adv. Res.* 7. 2019. P. 1136–1144. URL: <https://dx.doi.org/10.21474/IJAR01/9765>