

УДК 004.032.26:007.052:629.7.072

В.В. Москаленко¹, А.С. Москаленко², А.Г. Коробов³, М.О. Зарецький⁴¹Сумський державний університет, м. Суми, Україна, v.moskalenko@cs.sumdu.edu.ua²Сумський державний університет, м. Суми, Україна, a.moskalenko@cs.sumdu.edu.ua³Сумський державний університет, м. Суми, Україна, a.korobov@cs.sumdu.edu.ua⁴Сумський державний університет, м. Суми, Україна, m.zaretskij@cs.sumdu.edu.ua

МОДЕЛЬ ТА АЛГОРИТМ НАВЧАННЯ СИСТЕМИ АВТОНОМНОЇ НАВІГАЦІЇ ДЛЯ МАЛОГАБАРИТНОГО БЕЗПІЛОТНОГО АПАРАТУ

В статті розглядається нова модель системи автономної навігації малогабаритного безпілотного апарату, що включає згорткову нейронну мережу для виділення візуальних ознак, машину екстремального навчання для оцінки переміщення та інформаційно-екстремальний класифікатор з використанням бустингу для оцінки перешкод. Запропоновано новий алгоритм навчання моделі, що полягає у навчанні екстрактора ознак без вчителя на основі зростаючого розріджено кодуючого нейронного газу, навчанні з учителем вирішальних правил та тонкій настройці моделі за допомогою алгоритму симуляції відпалу. Розглянуто комплексний критерій вибору параметрів моделі екстрактора ознак. Результати фізичного моделювання з оптимальною моделлю на відкритих KITTI-наборах даних підтверджують придатність запропонованих алгоритмів для практичного використання.

НАВІГАЦІЯ, ВІЗУАЛЬНА ОДОМЕТРИЯ, ЗГОРТКОВА НЕЙРОННА МЕРЕЖА, НЕЙРОННИЙ ГАЗ, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ, ЕКСТРЕМАЛЬНЕ НАВЧАННЯ.

В.В. Москаленко, А.С. Москаленко, А.Г. Коробов, Н.А. Зарецький. Модель и алгоритм обучения системы автономной навигации для малогабаритного беспилотного аппарата. В статье рассматривается новая модель системы автономной навигации малогабаритного беспилотного аппарата, которая включает свёрточную нейронную сеть для выделения визуальных признаков, машину экстремального обучения для оценки перемещения и информационно-экстремальный классификатор с использованием бустинга для оценки препятствий. Предложен новый алгоритм обучения модели, который заключается в обучении экстрактора признаков без учителя на основе растущего разреженного кодирующего нейронного газа, обучении с учителем решающих правил и тонкой настройке модели с помощью алгоритма симуляции отжига. Рассмотрен комплексный критерий выбора параметров модели экстрактора признаков. Результаты физического моделирования с оптимальной моделью на открытых KITTI-наборах данных подтверждают пригодность предложенных алгоритмов для практического использования.

НАВІГАЦІЯ, ВІЗУАЛЬНА ОДОМЕТРИЯ, СВЁРТОЧНЫЕ НЕЙРОННЫЕ СЕТИ, НЕЙРОННИЙ ГАЗ, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ, ЕКСТРЕМАЛЬНЕ ОБУЧЕННЯ.

V.V. Moskalenko, A.S. Moskalenko, A.G. Korobov, M.O. Zaretskiy. Aerial compact drone autonomous navigation system – the model and training algorithms. The paper presents a novel model of convolutional neural network for visual feature extraction, extreme-learning machine for position displacement estimation and boosted information-extreme classifier for obstacle prediction with new training algorithms to build decision rules of autonomous navigation system for compact drones are presented in the paper. Growing sparse-coding neural gas algorithm for unsupervised training of the convolution filters, supervised learning algorithms for training decision rules and simulated annealing search algorithm for fine tuning are proposed. The complex criterion for choosing parameter of feature extractor model is considered. Simulation results with optimal model on open KITTI-datasets confirm the suitability of proposed algorithms for practical usage.

NAVIGATION, VISUAL ODOMETRY, CONVOLUTIONAL NEURAL NETWORK, NEURAL GAS, INFORMATION CRITERION, EXTREME LEARNING.

Вступ

Автономна навігація має важливе значення у пошукових та рятувальних задачах, оскільки ручне дистанційне керування польотом за даними відеопотоку дуже проблематичне поблизу будівель, дерев та всередині приміщень [1–3]. Крім того, система глобального позиціонування може бути не надійною в умовах низького рівня супутникового покриття та внаслідок багатопроменевого поширення сигналу. Альтернативним рішенням може бути використання компактного лазерного сканера. Проте таке рішення дороге, і лазер має низьку

частоту [2]. Рішення на основі машинного зору найбільш придатне для автономної навігації з точки зору ваги, ціни та інформації яку можна отримати. За допомогою бортової камери літальний апарат може оцінювати власне переміщення та одночасно одержувати інформацію про навколишнє середовище польоту.

Геометричні методи візуальної одометрії, такі як прямі, напівпрямі та з використанням локальних ознак, набули найбільшого поширення [4, 5]. Проте геометричні методи не мають стійкості до ряду дуже поширених ефектів, таких як зміна

освітлення, рух динамічних об'єктів в полі зору камери, різні калібрування камери, слаботекстурованість поверхонь в полі зору, шум та розмитість кадрів при русі.

Використання методів глибокого навчання та недорогих камер загального призначення є найбільш перспективним підходом для візуальної одометрії. В рамках даного підходу є широкі можливості тренування системи для забезпечення стійкості до параметрів камери та складних умов середовища [5, 6]. Однак глибокі моделі споживають великі обсяги обчислювальних ресурсів як в режимі навчання, так і в режимі екзамону. Крім того, для успішного навчання, глибокі моделі потребують великий обсяг розміченого набору даних. Зниження складності моделі може бути досягнуте за рахунок звуження області застосування, до певної доменної області. Але навіть невелика глибока модель є ресурсоємкою і вимагає великого обсягу розмічених навчальних даних, що призводить до значних накладних витрат та уповільнення адаптації до нових умов чи середовища функціонування.

Традиційна згорткова нейронна мережа, що складається з багатошарового згорткового екстрактора ознак та правил прийняття рішень у вигляді повнозв'язних нейронних шарів, є безперечним лідером серед моделей аналізу зображень [7, 8]. Однак, основними недоліками традиційних згорткових нейронних мереж є їх нездатність до аналізу процесів, що відбуваються в часі, а також висока обчислювальна складність алгоритму навчання на основі зворотного поширення помилки, що ускладнює адаптацію до змін під час експлуатації [9]. Крім того, важко заздалегідь оцінити необхідну кількість нейронів у кожному згортковому шарі. Тому підходи, основані на використанні алгоритму зростаючого нейронного газу та його модифікацій, для навчання нейронних мереж без вчителя є перспективними [1, 10]. Крім того, згортковий екстрактор ознак у поєднанні з розрідженим кодуванням залишається працездатним і за умов малих розмірів навчальних вибірок. При цьому значна незбалансованість цільових класів у нерозміченому наборі даних може бути врахована шляхом точного настроювання екстрактора ознак за критерієм ефективності вирішальних правил системи навігації [8]. Комплексне налаштування в гібридних моделях часто обмежується багатьма неузгодженостями, недиференційованістю цільових функцій чи проміжних ланок та іншим. У цьому випадку, точна настройка може бути ефективно виконана будь-яким пошуковим метаевристичним алгоритмом. Однак швидкість машинного навчання залежатиме від складності побудови оптимальних вирішальних правил.

Завдання оцінки власного переміщення є найважливішою складовою процесу візуальної навігації, і його можна сформулювати як регресійний аналіз для визначення зсуву позиції. Метод опорних векторів та машина екстремального навчання (Extreme Learning Machine, ELM) широко використовуються як моделі регресії в гібридних інтелектуальних системах, особливо з наявністю обмежень на обчислювальні ресурси та розмір розміченого набору даних. У цьому випадку, ELM характеризується найбільш швидким навчанням для отримання рішення регресійної задачі згідно методу найменших квадратів [11]. Для того, щоб уникнути перенавчання, яке відбувається при великій кількості нейронів прихованого шару, важливо дослідити поступове навчання шляхом послідовного додавання прихованих нейронів.

Інформаційно-екстремальний класифікатор високорівневих ознак є одним з перспективних підходів для класифікаційного аналізу зображень на предмет перешкод. Інформаційно-екстремальне навчання дозволяє уникнути проблем пов'язаних з ефективністю обчислень та забезпеченням узагальнюючих властивостей. Основна ідея інформаційно-екстремального класифікатора полягає у перетворенні вхідного простору первинних ознак у бінарний простір Хеммінга з радіально-базисними вирішальними правилами. Цей підхід забезпечує високу обчислювальну ефективність, оскільки використовуються лише прості операції, такі як порівняння з порогами та розрахунок відстані Хеммінга на основі логічної операції XOR та підрахунку ненульових бітів. Проте, методи швидкої оптимізації порогів, для кодування ознак все ще не запропоновані. При цьому індукція ознак на основі алгоритмів випадкового лісу та бустінгу є двома особливо перспективними підходами до прискорення оптимізації порогів для бінарного кодування ознак [12-14].

Для здійснення автономної навігації та ідентифікації перешкод в умовах обмежених обчислювальних ресурсів у даній статті пропонується модель багатошарового згорткового розріджено кодуєчого екстрактора ознак з просторово-часових візуальних даних. Крім того, пропонуються алгоритми тренування моделі, основані на попередньому навчанні без вчителя та тонкій настройці з учителем екстрактора ознак з метою максимізації ефективності інформаційно-екстремального класифікатора та регресійної моделі у вигляді машини екстремального навчання.

1. Опис даних та архітектура моделі

Для формування вхідного математичного опису інтелектуальної інформаційної системи, використовувались набори даних KITTI VO / SLAM 07 та

09, що містять як послідовність кадрів зображення з рухомої відеокамери, так і реальні дані про рух по трьох координатних осях, отриманих з GPS та LiDaR (Набір даних: http://www.cvlibs.net/datasets/kitti/raw_data.php?type=residential. Ліцензія на набір даних: авторська ліцензія Creative Commons Attribution-NonCommercial-ShareAlike 3.0), що знаходяться на платформі Kaggle [8]. Цей набір даних був записаний з відносно низькою частотою кадрів (10 кадрів в секунду), в міських районах з багатьма динамічними об'єктами та швидкістю руху до 90 км / год. Попередня обробка зображень виконувалася із застосуванням функцій зміни розміру, перетворення у відтінки сірого та корекції спотворень внаслідок дисторсії [9]. Для цього необхідні були параметри калібрування камери, однак висока точність не потрібна. Використовувалися як навчальні, так і тестові відеокліпи набору даних KITTI Vision, без врахування анотацій. Щоб зменшити обчислювану складність алгоритмів, зображення були стиснуті до розміру 200x200 пікселів.

Навчена модель візуальної навігації повинна забезпечувати ухилення від перешкод та контроль власної позиції за допомогою одометрії. Запропонована модель візуальної навігації може бути навчена або як самостійна система, або як допоміжна система у вигляді паралельного коректора помилок для геометричної одометрії, основаної на використанні локальних ознак. У випадку допоміжного варіанту модель геометричної одометрії та коректор помилок повинні бути синхронізовані.

Схема інтелектуальної навігаційної системи для малогабаритного літального апарату показана на рис. 1.

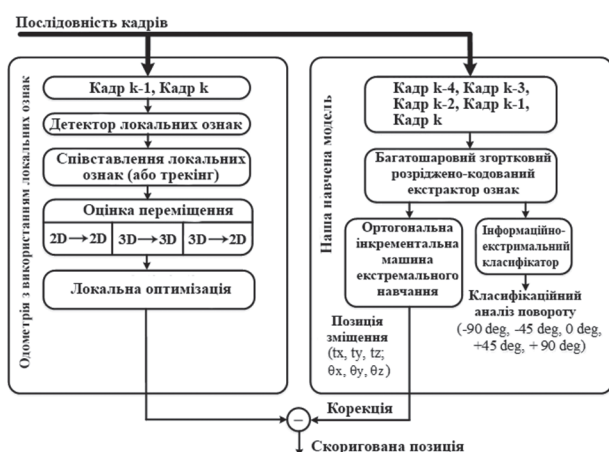


Рис. 1. Модель геометричної візуальної одометрії з запропонованою моделлю паралельного коректора помилок

Для того, щоб виділити ознаки візуальних спостережень, пропонується використовувати згорткову нейронну мережу, на вхід якої надходить багатоканальне зображення, сформоване із серії послідовних відео кадрів у градації сірого. Згорткова

нейронна мережа має багат шарову структуру, на виході якої формується високорівневий ознаковий опис візуальних спостережень. При цьому згорткові фільтри навчаються без вчителя, послідовно шар за шаром. Для виявлення перешкод та формування відповідної реакції використовується інформаційно-екстремальний класифікатор, що навчається з учителем на навчальних зразках, закодованих відповідними високорівневими ознаками. Регресійна модель в рамках ELM використовується для відображення візуальних ознак у відповідну оцінку зміщення відеокамери в просторі.

На рис. 2 показано 4-х шарову архітектуру згорткової нейронної мережі, в першому шарі якої знаходяться 3D фільтри різних розмірів: $5 \times 5 \times K_1$, $3 \times 3 \times K_1$ та $1 \times 1 \times K_1$. Кількість фільтрів регулюється параметром K_2 . Для збереження одного і того ж розміру карт ознак, створених багатомірними фільтрами, використовується техніка заповнення нулями [8]. У другому та третьому шарах параметр відступу для сканування карти ознак з багатомірними фільтрами становить 3 та 2, відповідно. При цьому пропонується використовувати алгоритм ортогонального узгодженого переслідування Orthogonal Matching Pursuit (OMP) [10] та функцію RELU, $y = \max(0, x)$, для обчислення багатоканальних пікселів карти ознак, проте для уникнення втрати інформації, можна подвоїти карту ознак за допомогою функції $y = \{\max(0, x), \max(0, -x)\}$. На рис. 2 не показано функцій обчислення пікселів карти ознак.

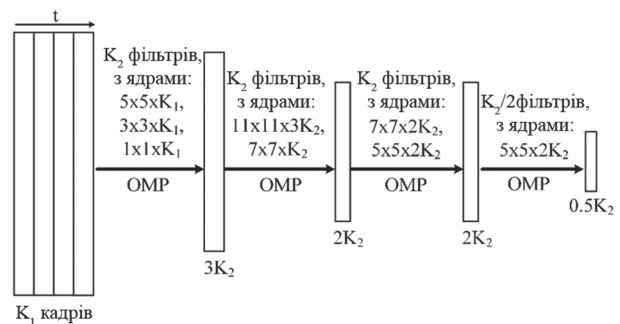


Рис. 2. Архітектура згорткової розріджено кодуючої моделі для екстракції візуальних ознак в навігаційній системі

Для навчання регресійної моделі $y = f(x)$ у вигляді мережі прямого поширення з одним прихованим шаром (МПОП) використовується набір навчальних даних, закодованих візуальними ознаками

$$\{(x_j, y_j) | x_j \in R^N, y_j \in R^M, 1 \leq j \leq n\},$$

де $x_j = (x_{j1}, x_{j2}, \dots, x_{jN})^T$. При цьому вихідна змінна $y_j \in R^M$ відповідає вектору зміщення положення, t , та вектору повороту, \bar{R} , камери $y = (y_1, y_2, \dots, y_n)^T = (t, \bar{R})^T$. МПОП з R адитивними

прихованими вузлами та функцією активації $\varphi(x)$ може бути подана у вигляді системи рівнянь

$$\sum_{r=1}^R \beta_r \varphi(w_r^T x_j + b_r) = o_j, 1 \leq j \leq n$$

де $w_r = (w_{r1}, w_{r2}, \dots, w_{rN})^T$ – вектор вагових коефіцієнтів, який зв’язує вхідний шар з r -м прихованим вузлом; b_r – зміщення r -го прихованого вузла; $\beta_r = (\beta_{r1}, \beta_{r2}, \dots, \beta_{rM})$ – вектор вагових коефіцієнтів, що зв’язує вихідний шар з r -м прихованим вузлом; o_j – вихід мережі для вхідного вектора x_j ; $\varphi(x)$ – функція активації.

Мережа з R прихованими вузлами може відтворити ці N зразків з нульовою помилкою, якщо всі параметри можуть вільно коригуватись, тобто існують, β_r , w_r і b_r . Вищевказані виразів можуть бути компактно переписані як матрична рівність

$$H\beta = Y,$$

де

$$H = \begin{bmatrix} \varphi(w_1^T x_1 + b_1) & \dots & \varphi(w_R^T x_1 + b_R) \\ \dots & \dots & \dots \\ \varphi(w_1^T x_n + b_1) & \dots & \varphi(w_R^T x_n + b_R) \end{bmatrix}_{n \times R},$$

$$\beta = \begin{bmatrix} \beta_1^M \\ \dots \\ \beta_R^M \end{bmatrix}_{R \times M}, \quad Y = \begin{bmatrix} y_1^M \\ \dots \\ y_n^M \end{bmatrix}_{n \times M}$$

де H – матриця виходу прихованого шару.

Інформаційно-екстремальний класифікатор в режимі екзамену приймає рішення про належність вхідного вектора x з відповідним двійковим поданням b до одного з класів повороту $\{X_z^o \mid z = \overline{1, Z}\}$ відповідно до максимального значення функції належності $\mu_z(b)$ згідно виразу $\arg \max \{\mu_z(b)\}$. У такому випадку функція належності $\mu_z(b)$ до класу X_z^o , оптимальний контейнер якого має опорний вектор b_z^* та радіус d_z^* , розраховується за формулою

$$\mu_z(b) = \exp\left(-\sum_{i=1}^{N_z} b_i \oplus b_{z,i}^* / d_z^*\right).$$

Двійкове кодування зразків даних x_j здійснюється шляхом конкатенації шляхів рішень у деревах з ансамблю T_1, \dots, T_k , де шлях подається у вигляді бінарного коду. При цьому кожен ненульовий біт закодованого шляху відповідає номеру вузлу дерева, через який проходив шлях класифікації вхідного зразка x_j відповідним деревом [13, 14].

2. Структура алгоритму навчання

Процес машинного навчання навігаційної системи орієнтований на визначення оптимального вектора параметрів g , які забезпечують максимум комплексного критерію

$$J = \frac{\bar{E}}{E_{\max}} \cdot \frac{\varepsilon_{\min}}{\varepsilon} \cdot \frac{C_{\min}}{C}, \quad (1)$$

$$g^* = \arg \max_G \{J(g)\}, \quad (2)$$

де \bar{E} – інформаційний критерій ефективності навчання для розпізнавання перешкод, усереднений за набором класів; ε – значення середньої квадратичної похибки регресії при визначенні зміни координат камери у просторі; C – критерій обчислювальної трудомісткості моделі екстракції ознак; E_{\max} , ε_{\min} , C_{\min} – максимальне можливе значення інформаційного критерію ефективності навчання класифікатора, мінімально допустиме значення похибки регресійної моделі та критерію обчислювальної трудомісткості екстрактора ознак, відповідно; G – допустима область значень параметрів, які впливають на екстракцію ознак і прийняття рішень.

Пропонується провести навчання екстрактора ознак без вчителя, з використанням зростаючого розріджено кодуєного нейронного газу, основаного на принципах зростаючого нейронного газу та розрідженого кодування. У цьому випадку набір даних для навчання згорткових фільтрів формується шляхом розбиття вхідних зображень або карт ознак на патчі. Ці патчі трансформуються до 1D-векторів та надходять на вхід зростаючого розріджено кодуєного нейронного газу, основні етапи якого наведені нижче:

1. ініціалізація лічильника навчальних векторів $t := 0$;
2. два початкових вузли (нейрони) w_a і w_b ініціалізуються шляхом випадкового вибору векторів з навчальних даних. Вузли w_a і w_b з’єднуються ребром, вік якого встановлюється нульовим. Ці вузли вважаються нефіксованими;
3. обирається наступний вектор x , що нормалізується шляхом приведення до одиничної довжини (L2-нормування);
4. нормалізується кожний базисний вектор, $w_k, k = \overline{1, M}$, шляхом приведення до одиничної довжини (L2-нормалізація);
5. розраховується міра схожості вхідного вектора x до базисних векторів $w_{s_k} \in W$ для сортування $-(w_{s_0}^T x)^2 \leq \dots \leq -(w_{s_k}^T x)^2 \leq \dots \leq -(w_{s_{M-1}}^T x)^2$;
6. визначається найближчий вузол w_{s_0} та другий за близькістю вузол w_{s_1} ;
7. збільшується на одиницю вік всіх вузлів, інцидентних до w_{s_0} ;
8. якщо вузол w_{s_0} фіксований, то перехід до кроку 9, в інакше – крок 10;
9. якщо $(w_{s_0}^T x)^2 \geq \nu$, то перехід до кроку 12. В іншому випадку додаються новий нефіксований нейрон $w_r = x$ та нове ребро, яке з’єднує w_r і w_{s_0} , потім перехід до кроку 13;
10. вузол w_{s_0} та його топологічні сусіди (вузли, зв’язані з ним ребрами) зміщуються у напрямку

вихідного вектора x відповідно до правила Ойа [14] за формулами

$$\begin{aligned} \Delta w_{s_0} &= \varepsilon_b \eta_t y_0 (x - y_0 w_{s_0}), \quad y_0 := w_{s_0}^T x, \\ \Delta w_{s_n} &= \varepsilon_n \eta_t y_n (x - y_n w_{s_n}), \quad y_n := w_{s_n}^T x, \\ 0 < \varepsilon_b &\ll 1, \quad 0 < \varepsilon_n \ll \varepsilon_b, \\ \eta_t &:= \eta_0 (\eta_{final} / \eta_0)^{t/t_{max}}, \end{aligned}$$

де $\Delta w_{s_0}, \Delta w_{s_n}$ – вектори корекції вагових коефіцієнтів нейрона-переможця та його топологічних сусідів відповідно; $\varepsilon_b, \varepsilon_n$ – константи міри оновлення вагових коефіцієнтів нейрона-переможця та його топологічних сусідів відповідно; $\eta_0, \eta_t, \eta_{final}$ – початкове, поточне та кінцеве значення швидкості навчання відповідно;

11. якщо $(w_{s_0}^T E)^2 \geq \nu$, то нейрон w_{s_0} позначається як фіксований;

12. якщо w_{s_0} і w_{s_1} з'єднані ребром, їхній вік зменшується, в іншому випадку – між w_{s_0} і w_{s_1} формується нове ребро з нульовим віком;

13. всі ребра графа з віком більше, ніж a_{max} видаляються. У тому випадку, коли у деяких вузлах немає ребер (вузли стають ізольованими), ці вузли також видаляються;

14. якщо $t < t_{max}$, то переходимо до кроку 15, інакше – збільшуємо лічильник $t := t + 1$ і переходимо до кроку 3;

15. якщо всі нейрони фіксовані, то виконання алгоритму припиняється, інакше перехід до кроку 3 і починається нова епоха навчання (повторення набору даних навчання).

Для класифікаційного аналізу вихідної карти ознак формується навчальний набір даних $D = \{x_j, y_j | j = \overline{1, n}\}$, де n – обсяг вибірки, а y_j – мітка j -го пікселя, яка відповідає одному з класів алфавіту розпізнавання $\{X_z^o | z = \overline{1, Z}\}$. При цьому інформаційно-екстремальний класифікатор оцінює належність j -го елемента даних (пікселя на карті ознак) за його N_1 ознаками до одного з Z класів. Це здійснюється шляхом кодування ознак на основі дерев рішень та вирішальних правил, побудованих в радіальному базисі бінарного простору Хемінга. Навчання інформаційно-екстремального класифікатора відбувається відповідно до наступних кроків:

1. Ініціалізація вагових коефіцієнтів $w_j = 1/n$.

2. Для $k = 1 \dots K$ виконуються наступні кроки:

3. Генерація D_k набору навчальних даних з усього набору D з використанням функції розподілу ймовірності $P(X = x_j) = w_j$.

4. Навчання дерева рішень T_k на наборі D_k із застосуванням ентропійного критерію збурдженості вузлів.

5. Виконання бінарного кодування вектора x_j з набору даних D шляхом об'єднання шляхів

рішення в деревах T_1, \dots, T_k . Кожне дерево формує двійковий код, в якому одиниці знаходяться у позиціях, що відповідають номерам вузлів, через які проходить шлях вектора x_j від кореня до термінального вузла. Нарешті, формування результуючого коду вектора x_j відбувається шляхом об'єднання кодів, сформованих кожним із дерев [12]. Результатом роботи цього етапу є бінарна матриця $\{b_{z,s,i} | i = \overline{1, N_2}; s = \overline{1, n_z}; z = \overline{1, Z}\}$, де N_2 кількість індукованих бінарних ознак та n_z кількість реалізацій відповідного класу X_z^o , що задовольняє рівність $n = \sum_z n_z$.

6. Побудова інформаційно-екстремальних вирішальних правил в радіальному базисі бінарного простору Хемінга та обчислення інформаційного критерію

$$E_z^* = \max_{\{d\}} E_z(d),$$

де $\{d\} = \{0, 1, \dots, \left(\sum_i b_{z,i} \oplus b_{c,i} - 1\right)\}$ – набір концентричних радіусів з центром b_z ; b_z – опорний вектор розподілу даних в класі X_z^o , який розраховується за правилом

$$b_{z,i} = \begin{cases} 1, & \text{if } \frac{1}{n_z} \sum_{s=1}^{n_z} b_{z,s,i} > \frac{1}{Z} \sum_{A=1}^Z \frac{1}{n_A} \sum_{s=1}^{n_A} b_{A,s,i}; \\ 0, & \text{otherwise.} \end{cases}$$

де E_z – критерій ефективності побудови вирішальних правил в режимі навчання для класу X_z^o , який розраховується як нормалізована модифікація інформаційної міри Кульбака [11]:

$$E_z = \frac{1 - (\alpha_z + \beta_z)}{\log_2(2 + \zeta) - \log_2 \zeta} \cdot \log_2 \left[\frac{2 - (\alpha_z + \beta_z) + \zeta}{(\alpha_z + \beta_z) + \zeta} \right], \quad (3)$$

де α_z, β_z – частота хибно позитивних та хибно негативних спрацювань вирішальних правил класу X_z^o ; ζ – будь-яке мале знакододатне число, яке вводиться, для уникнення невизначеності при діленні на нуль.

З метою підвищення ефективності навчання, загальноприйнятим є зведення проблеми багатокласової класифікації до серії двокласових класифікацій за принципом «один проти всіх». Для уникнення проблеми незбалансованості класів розпізнавання, обумовленої переважанням у навчальному наборі даних негативних зразків, здійснюється введення синтетичного класу, який є альтернативним для X_z^o . Синтетичний клас представлено n_z векторами з інших класів, які найбільш близькі до опорного вектора b_z , де n_z – обсяг навчального набору даних класу X_z^o .

7. Тестування отриманих інформаційно-екстремальних вирішальних правил на наборі даних D та розрахунок коефіцієнту помилок для кожної

реалізації з D . При цьому, в режимі розпізнавання прийняття рішення про належність вектора b до одного з класів розпізнавання з алфавіту $\{X_z^o | z = \overline{1, Z}\}$ здійснюється за максимальним значенням функції належності $\mu_z(b)$ згідно виразу $\arg \max\{\mu_z(b)\}$. У цьому випадку функція належності $\mu_z(b)$ бінарного подання b вхідного вектора даних x до класу X_z^o , оптимальний контейнер якого має опорний вектор b_z^* та радіус d_z^* , розраховується за формулою

$$\mu_z(b) = \exp\left(-\sum_{i=1}^{N_2} b_i \oplus b_{z,i}^* / d_z^*\right).$$

8. Оновлення коефіцієнтів $\{w_j\}$, пропорційне отриманій помилці для вектора x_j .

9. Якщо $|E_k^* - E_{k-1}^*| < \varepsilon$ то вийти з циклу.

Ортогональну інкрементальну машину екстремального навчання пропонується використовувати як регресійну модель. Вона уникає надлишкових вузлів і отримує рішення рівнянь найменших квадратів $H\beta = Y$ на основі методу ортогоналізації Грем-Шмідта. Теоретичні докази збіжності ортогонального інкрементального екстремального навчання дано в праці [11]. Метод навчання ортогональної інкрементальної ELM відбувається відповідно до наступних кроків.

1. Встановлюється максимальна кількість ітерацій L_{\max} та бажана точність навчання E_0 .

2. Для $L = 1 \dots L_{\max}$ виконуються наступні кроки.

3. Збільшити кількість прихованих вузлів на один: $r = r + 1$.

4. Випадковим чином згенерувати один прихований нейрон та розрахувати його вихідний вектор h_r .

5. Якщо $r = 1$ тоді $v_r = h_r$ інакше

$$v_r = h_r - \frac{\langle v_1, h_r \rangle}{\langle v_1, v_1 \rangle} v_1 - \frac{\langle v_2, h_r \rangle}{\langle v_2, v_2 \rangle} v_2 - \dots - \frac{\langle v_{r-1}, h_r \rangle}{\langle v_{r-1}, v_{r-1} \rangle} v_{r-1}$$

6. Якщо $\|v_r\| \geq \varepsilon$, то виконується обчислення вихідної ваги для нового прихованого вузла $\beta_r = v_r^T E / (v_r^T v_r)$ та розраховується нова залишкова помилка $E = E - v_r \beta_r$ інакше $r = r - 1$.

7. Якщо $\|E\| \geq E_0$ відбувається вихід з основного циклу роботи.

Для апроксимації глобального оптимуму комплексного критерію під час навчання вирішальних правил та тонкої настройки екстрактора ознак ми пропонуємо використовувати метаевристичний алгоритм імітації відпалу [14]. Ефективність алгоритму симуляції відпалу залежить від реалізації процедури пошуку сусідів `create_neighbor_solution` для формування нового рішення s_i на i -ій ітерації алгоритму. На рис. 3 показано псевдо код алгоритму симуляції відпалу, на кожній ітерації якого виконується обчислення функції критерію $f()$, яка

обчислюється шляхом пропускання розміченого навчального набору даних через модель детектора та розрахунку комплексного критерію (1) [14].

```

s_current ← create_initial_solution()
s_best ← s_current
T ← T_0
c ← ε, 0 < ε < 1
for(i = 1 to epochs_max)
    s_i ← create_neighbor_solution(s_current)
    if f(s_i) ≥ f(s_current)
        s_current ← s_i
        if f(s_i) ≥ f(s_best)
            s_best ← s_i
        end if
    elseif exp((f(s_current) - f(s_i)) / T) > uniform_random(0,1)
        s_current ← s_i
    end if
    T ← c × T
end for
return(s_best)

```

Рис. 3. Псевдокод алгоритму симуляції відпалу

Аналіз псевдокоду на рис. 3 показує, що поточне рішення $s_{current}$, відносно якого відбувається пошук нових кращих рішень s_{best} , оновлюється у випадку знаходження нового рішення, що збільшує критерій (1) або випадковим чином з розподілу Гіббса. При цьому початкове рішення утворюється за допомогою процедури `create_initial_solution`. Для формування нового рішення пропонується використовувати найпростіший неадаптивний алгоритм, який можна представити у вигляді формули [14]

$$s_{current} = s_{current} + \text{uniform_random}(-1,1) \cdot \text{step_size},$$

де `uniform_random` – функція генерації випадкових чисел з рівномірного розподілу з заданого діапазону; `step_size` – це розмір діапазону пошуку нових рішень, сусідніх з $s_{current}$.

3. Результати моделювання та обговорення

Різні значення параметрів K_1 та K_2 впливають як на інформативність ознак, так і на обчислювальну трудомісткість. Ми пропонуємо вимірювати трудомісткість за кількістю операцій множення (Mul) та додавання (Add), що виконуються під час згорткових операцій з зображенням або картою ознак. Для архітектури мережі, показаної на рис. 2, трудомісткість може бути розрахована за формулою

$$C = K_2(2706472K_1 + 4438784K_2) \quad (4)$$

Для класифікатора та регресійної моделі оптимальна конфігурація згорткового екстрактора може бути різною, оскільки вона відповідає за різні завдання. Тому комплексний критерій (1) пропонує компроміс з точки зору точності правил прийняття рішень та обчислювальної складності екстрактора візуальних ознак.

Множина класів розпізнавання $\{X_z^o\}$ описує характерні перешкоди та відповідні команди реакції і має потужність $Z = 5$. Перший клас розпізнавання X_1^o характеризує рух вперед без повороту. Класи X_2^o і X_3^o відповідають лівому повороту 45 і 90 градусів відповідно. Класи X_4^o і X_5^o відповідають правому повороту 45 і 90 градусів відповідно. Обсяг навчальних та тестових даних кожного класу $n_z = 300$.

Спочатку пропонується навчати вирішальні правила моделі, використовуючи попередньо навчений без вчителя екстрактор ознак за допомогою зростаючого розріджено кодуєчого нейронного газу без тонкої настройки. При цьому під час навчання без вчителя використовуються три фіксованих значення параметра реконструкції набору навчальних даних v . Цей параметр безпосередньо впливає на кількість каналів карт ознак K_2 .

Для покращення результатів машинного навчання візуальної навігаційної системи підвищують інформативність ознакового опису шляхом тонкої настройки навчених без вчителя згорткових фільтрів. У цьому випадку використовувались наступні параметри алгоритму симуляції відпалу: $c = 0.98$, $T_0 = 10$, $epochs_max = 5000$, $step_size = 0.001$. На кожному кроці для тонкої настройки передбачається перепідготовка моделі регресії та класифікатора.

Для виявлення тенденції зміни середніх значень часткових та комплексного критеріїв при зростанні параметрів K_1 та K_2 , що впливають на розмір екстрактора ознак (рис. 2), було виконано симуляцію для трьох фіксованих значень кожного з цих параметрів (Табл. 1). При цьому оптимальні значення цих параметрів визначаються для відкритого набору даних КІТГІ-07.

Таблиця 1

Залежність часткових та комплексного критерію від параметрів екстрактора ознакового опису K_1 і K_2

| v | K_1 | K_2 | \bar{E} / E_{max} | $\epsilon_{min} / \epsilon$ | C_{min} / C | J |
|-----|-------|-------|---------------------|-----------------------------|---------------|----------|
| 0.6 | 3 | 18 | 0,083 | 0,112 | 1,000 | 0,009296 |
| 0.6 | 5 | 18 | 0,101 | 0,188 | 0,827 | 0,015703 |
| 0.6 | 7 | 18 | 0,098 | 0,200 | 0,705 | 0,013818 |
| 0.7 | 3 | 21 | 0,28 | 0,688 | 0,297 | 0,057214 |
| 0.7 | 5 | 21 | 0,29 | 0,756 | 0,264 | 0,057879 |
| 0.7 | 7 | 21 | 0,29 | 0,775 | 0,238 | 0,053491 |
| 0.8 | 3 | 46 | 0,39 | 0,968 | 0,082 | 0,030957 |
| 0.8 | 5 | 46 | 0,55 | 1,000 | 0,077 | 0,04235 |
| 0.8 | 7 | 46 | 0,51 | 1,000 | 0,072 | 0,03672 |

Аналіз табл. 1 показує, що збільшення значень параметрів K_1 і K_2 загалом призводить до збільшення достовірності та обчислювальної складності (4) вирішальних правил класифікатора та

регресійної моделі. У той же час, збільшення параметра K_1 мало впливає на ефективність класифікатора внаслідок зниження ефективності пошукового алгоритму зі значним збільшенням розміру простору пошуку, тоді як помилка регресії однаково чутлива до значення параметрів K_1 і K_2 .

Однак, з огляду на те, що при зростанні K_1 та K_2 достовірність правил прийняття рішень зростає повільніше, ніж обчислювальна складність, то використання комплексного критерію J забезпечує компромісне рішення. Тобто ми вважаємо наступні значення параметрів $K_1^* = 5$ та $K_2^* = 21$ оптимальними.

У оптимальній конфігурації екстрактора ознак середнє значення інформаційного критерію функціональної ефективності рівне $\bar{E} = 0.29$. Це відповідає точності 95,2% для навчального набору та 94% для тестового набору. На рис. 4 показано графік зміни середнього значення інформаційного критерію ефективності (4) відносно кількості ітерацій алгоритму імітації відпалу.

Аналіз рис. 4 показує, що після 1000-ї ітерації зростання інформаційного критерію (4) почало сповільнюватися, а після 2500-ї ітерації практично не змінилося. Така зміна критерію вказує на те, що подальше збільшення інформаційного критерію досягне лише за рахунок збільшення інформативності ознакового опису або шляхом збільшення значень K_1 та K_2 , або шляхом вдосконалення структури екстрактора (рис. 2).




Рис. 4. Графік зміни усередненого значення інформаційного критерію ефективності (3) залежно від кількості ітерацій алгоритму імітації відпалу

Для візуальної оцінки ефективності машинного навчання навігаційної системи, реальна траєкторія, виміряна за допомогою GPS та LiDaR, може бути порівняна з реконструйованою траєкторією, отриманою з використанням навченої моделі. На рис. 5а показано результат використання одометрії на основі локальних ознак з системи ORB-SLAM [5, 6]. Максимальна кількість ключових точок обмежена до 100, щоб забезпечити необхідну частоту

кадрів у випадку бортової системи без застосування обчислювальних можливостей графічного процесора.

Аналіз рис. 5а показує, що реконструйована траєкторія має значну похибку. На рисунку 5б показано результат використання запропонованої моделі, навченої та перевіреної на тих самих наборах даних. У цьому випадку помилка реконструкції набагато менша. На рисунку 5в показано результат використання одометрії на основі локальних ознак від ORB-SLAM з паралельною корекцією на основі запропонованої моделі. Як бачите, точність реконструкції висока.

На рис. 6а показано, що навчена модель на наборі даних КІТТІ-07 має низьку продуктивність при тестуванні на іншому наборі даних. На рис. 6б показано, що повторне навчання моделі на новому наборі даних значно підвищило точність реконструкції траєкторії з набору даних.

Таким чином, результати, отримані на відкритих наборах даних, свідчать про придатність моделі для практичного використання. Щоб уникнути перенавчання, оптимізована складність моделі. Але обмежена ємність моделі викликає потребу повторного навчання при зміні доменної області використання.

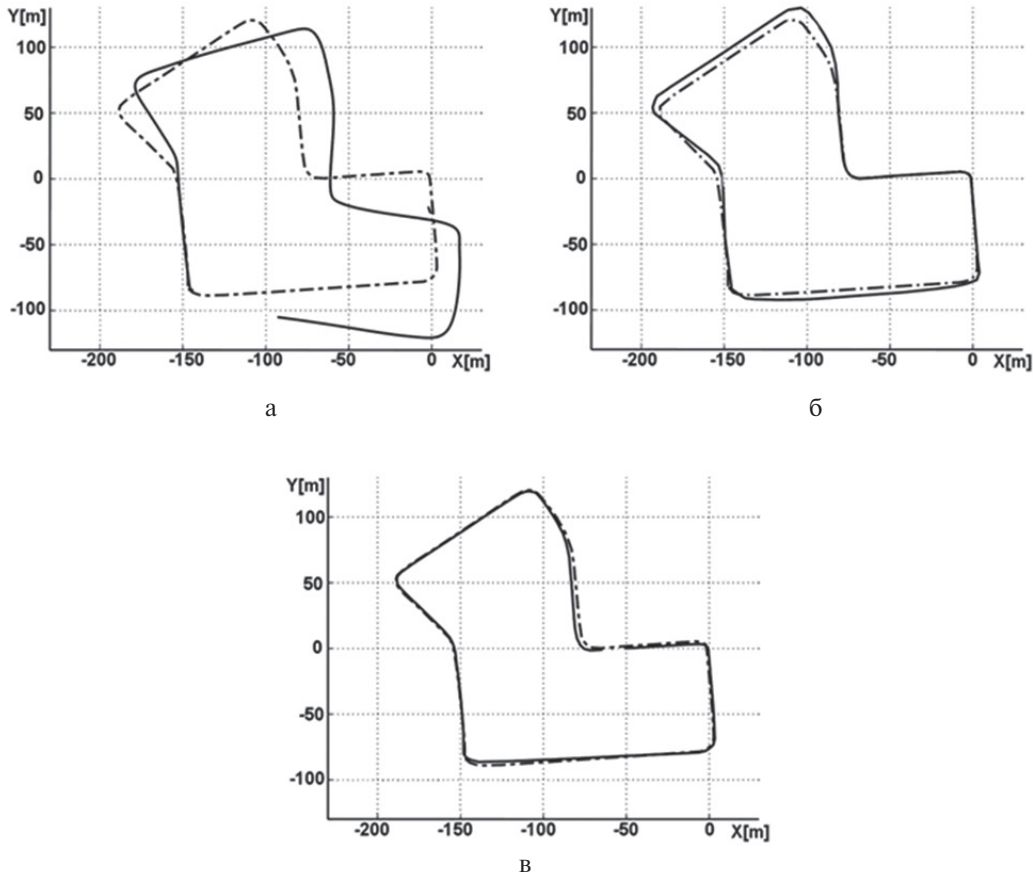


Рис. 5. Реальна траєкторія (пунктирна лінія) та реконструйована (суцільна лінія) для КІТТІ-07:

(а) – монокулярна одометрія на основі локальних ознак; (б) – запропонована модель; (в) – паралельна корекція помилок для монокулярної одометрії на основі локальних ознак з використанням запропонованої моделі




Рис. 6. Реальна траєкторія (пунктирна лінія) і реконструйована (суцільна лінія) траєкторії для КІТТІ-09:

(а) – навчена модель на КІТТІ-07;
(б) – після перенавчання на КІТТІ-09

Висновки

1. Наукова новизна результатів полягає в наступному:

– запропоновано нову модель автономної навігаційної системи для малогабаритного літального апарату. Модель складається з 4-х шарової згорткової розріджено кодууючої мережі, що складається з різномасштабних 3D згорткових фільтрів і приймає на вхід серію послідовних кадрів, машини екстремального навчання для оцінки переміщення і інформаційно-екстремальний класифікатор для прогнозування повороту;

– розроблено комплексний критерій оцінки ефективності моделі з урахуванням обчислювальної трудомісткості екстрактора ознак та точності вирішальних правил моделі;

– розроблено алгоритм навчання, що складається з 3-х частин. Перша частина – це навчання екстрактора ознак без вчителя на основі розтушеного розріджено кодуючого нейронного газу. Друга частина – навчання з учителем інформаційно-екстремального класифікатора та машини екстремального навчання. Остання частина – тонка настройка екстрактора ознак на основі метаевристичного алгоритму симуляції відпалу для підвищення ефективності вирішальних правил.

2. Практичне значення отриманих результатів для безпілотної авіації полягає у формуванні сучасної наукової та методологічної основи для проектування здатних до навчання систем автономної навігації для малогабаритних літальних апаратів, що мають ресурсні та інформаційні обмеження. У той же час результати симуляції моделі підтверджують високу ефективність отриманих вирішальних правил для визначення координат у просторі та розпізнавання перешкод на основі відеопотоку.

Подяки

Робота виконана на базі лабораторії інтелектуальних систем кафедри комп'ютерних наук Сумського державного університету при фінансовій підтримці МОН України в рамках держбюджетної науково-дослідної роботи ДР №0117U003934

Список літератури:

- [1] Moskalenko, V.; Moskalenko, A.; Korobov, A.; Boiko, O.; Martynenko, S.; Borovenskyi, O. Model and Training Methods of Autonomous Navigation System for Compact Drones. Proceedings of the 2018 IEEE Second International Conference on Data Stream Mining & Processing (DSMP), Lviv, Ukraine, 21–25 August 2018; Lviv Polytechnic Publishing House: Lviv, Ukraine, 2018; pp. 503 – 508.
- [2] Wang, S.; Deng, Z.; Yin G. An Accurate GPS-IMU/DR Data Fusion Method for Driverless Car Based on a Set of Predictive Models and Grid Constraints. Sensors 2016, 16(3), pp. 280–293, DOI:10.3390/s16030280. Available online: <https://www.mdpi.com/1424-8220/16/3/280>.
- [3] Suwandi, B.; Kitasuka, T.; Aritsugi, M. Low-cost IMU and GPS fusion strategy for apron vehicle positioning. Proceedings of the 2017 IEEE Region 10 Conference (TENCON), Penang, Malaysia, 5–8 Nov. 2017; pp. 449–454.
- [4] Mary, B. A.; Gerhard, P. H. Pose Estimation of a Mobile Robot Based on Fusion of IMU Data and Vision Data Using an Extended Kalman Filter. Sensors (Basel) 2017, 17(10), 2164, DOI:10.3390/s17102164. Available online: <https://www.mdpi.com/1424-8220/17/10/2164> (accessed on 04 November 2018).
- [5] Folkesson, J.; Leederkerken, J.; Williams, R.; Patrikakis, A.; Leonard J. A. A Feature Based Navigation System for an Autonomous Underwater Robot. Proceedings of the sixth edition of Field and Service Robotics, Chamonix, France, 9–12 July 2007; Laugier C., Siegwart R. Eds; Springer Tracts in Advanced Robotics Springer: Berlin, Germany, 2008; pp.105–114, DOI:10.1007/978-3-540-75404-6_10. Available online: https://link.springer.com/chapter/10.1007/978-3-540-75404-6_10 (accessed on 04 November 2018).
- [6] Cadena, C.; Carlone, L.; Carrillo, H.; Latif, Y.; Scaramuzza, D.; Neira, J.; Reid, I.; Leonard, J. Past, Present, and Future of Simultaneous Localization And Mapping: Towards the Robust-Perception Age. IEEE Transactions on Robotics 2016, 32(6), 1309–1332, DOI: 10.1109/TRO.2016.2624754.
- [7] Dorian, G.-L.; Marta, S.; Juan, D. T.; Montiel, J.M.M. Real-time monocular object SLAM. Robotics and Autonomous Systems 2016, 75, 435–449, DOI:10.1016/j.robot.2015.08.009.
- [8] Ayoul, Th.; Buckley, T.; Crevier, F.; UAV Navigation above Roads Using Convolutional Neural Networks. Available online: <http://cs231n.stanford.edu/reports/2017/pdfs/553.pdf> (accessed on 04 November 2018)
- [9] Mohanty, V. DeepVO: A Deep Learning approach for Monocular Visual Odometry. Available online: <https://arxiv.org/pdf/1611.06069.pdf> (accessed on 04 November 2018).
- [10] Labusch, K.; Barth, E.; Martinetz, T. Sparse Coding Neural Gas: Learning of Overcomplete Data Representations. Neurocomputing 2009, 72(7–9), 1547–1555, DOI: 10.1016/j.neucom.2008.11.027.
- [11] Zou, W.; Xia, Y.; Li, H. Fault Diagnosis of Tennessee-Eastman Process Using Orthogonal Incremental Extreme Learning Machine Based on Driving Amount, IEEE Transactions on Cybernetics 2018, 1–8. DOI: 10.1109/TCYB.2018.2830338.
- [12] Москаленко, В. В.; Коробов, А. Г. Інформаційно-екстремальний алгоритм функціонування системи розпізнавання об'єктів на місцевості з оптимізацією параметрів екстрактора ознак. Радіоелектроніка, інформатика, управління 2017, 2, 38–45, 10.15588/1607-3274-2017-2-7.
- [13] Vens, C.; Costa, F. Random Forest Based Feature Induction. Proceedings of the IEEE 11th International Conference on Data Mining, Vancouver, Canada, 11–14 Dec, 2011; Publisher: Piscataway, NJ, 2011; pp. 744–753. DOI: 10.1109/ICDM.2011.121. Available online: <https://ieeexplore.ieee.org/document/6137279>
- [14] Moskalenko, V.; Dovbysh, S.; Naumenko, I.; Moskalenko, A.; Korobov, A. Improving the effectiveness of training the on-board object detection system for a compact unmanned aerial vehicle. Eastern-European Journal of Enterprise Technologies 2018, 4/9 (94), pp. 19–26. DOI: 10.15587/1729-4061.2018.139923

Надійшло до редакції 29.10.2018