

УДК 623.746-519, 004.93'1; 004.932
УКПП
№ держреєстрації 0122U000786
Інв. №

Міністерство освіти та науки України
Сумський державний університет (СумДУ)
40007, м. Суми, вул. Римського-Корсакова, 2
тел. (0542) 33-41-08 факс (0542) 33-40-49

ЗАТВЕРДЖУЮ
Проректор з наукової роботи
д-р фіз.-мат. наук, професор

_____ А.М. Чорноус

ЗВІТ
ПРО НАУКОВО-ДОСЛІДНУ РОБОТУ
Інформаційна технологія автономної навігації безпілотного літального апарату за наземними природними та інфраструктурними орієнтирами

РОЗРОБЛЕННЯ МЕТОДУ ФОРМУВАННЯ ВХІДНОГО
МАТЕМАТИЧНОГО ОПИСУ БСН ШЛЯХОМ АНАЛІЗУ ВІДЕОПОТОКУ
ЗА ОПТО-ЕЛЕКТРОННИМ КАНАЛОМ
(проміжний)

Науковий керівник НДР
д-р техн. наук, професор

А.С. Довбиш

2022

Рукопис закінчено 17 грудня 2022 р.

Результати цієї роботи розглянуто науковою радою СумДУ, протокол від 22.12.2022 р. № 7

СПИСОК АВТОРІВ

Керівник НДР гол. наук. співроб., д-р техн. наук	(22.12.2022)	А.С. Довбиш (вступ, висновки)
Відповідальний виконавець: канд. техн. наук, старш. наук. співроб.	(22.12.2022)	І.В. Шелехов (підрозділ 2.1, 2.3)
Виконавці: Аспірант, молод. наук. співроб.	(22.12.2022)	М.І. Мироненко (підрозділи 1.1 – 1.3, 2.7, 3.2)
Канд. ф.-м. наук, виконавець договору	(22.12.2022)	О. О. Дрозденко (підрозділ 2.2)
Провідний інженер	(22.12.2022)	Г.В. Токаренко (підрозділ 3.1)
Інженер 1 категорії	(22.12.2022)	Н.М. Бровко (підрозділ 1.1)
Провідний інженер	(22.12.2022)	Ю.В. Симоновський (підрозділ 3.1)
Лаборант, студент	(22.12.2022)	Т. Р. Савченко (підрозділ 3.2)
Канд. техн. наук, виконавець договору	(22.12.2022)	В. В. Москаленко (підрозділ 2.1)
Канд. техн. наук, виконавець договору	(22.12.2022)	Н.Л. Барченко (підрозділ 2.2)
Канд. техн. наук, виконавець договору	(22.12.2022)	І. В. Науменко (підрозділ 2.5)
Аспірант, виконавець договору	(22.12.2022)	В. Ю. П'ятаченко (підрозділ 2.3)
Виконавець договору	(22.12.2022)	Д. В. Прилепа (підрозділ 2.4, 2.6)

Студент, виконавець договору	(22.12.2022)	О. В. Гриненко (підрозділ 3.2)
Студент, виконавець договору	(22.12.2022)	О. В. Токаренко (підрозділ 2.1)
Студент, виконавець договору	(22.12.2022)	А.М. Ященко (підрозділ 2.4)

РЕФЕРАТ

Звіт про НДР: 119 с., 20 рис., 1 табл., 201 джерело.

АВТОНОМНА БОРТОВА СИСТЕМА ВІДЕОНАВІГАЦІЇ, БЕЗПЛОТНИЙ АВІАЦІЙНИЙ КОМПЛЕКС, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ ОПТИМІЗАЦІЇ, ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ, МАШИННЕ НАВЧАННЯ, НАЗЕМНИЙ НАВІГАЦІЙНИЙ ОРІЄНТИР, ФУНКЦІОНАЛЬНА КАТЕГОРІЙНА МОДЕЛЬ

Мета роботи – підвищення функціональної ефективності автономної бортової системи навігації безпілотного авіаційного комплексу шляхом визначення місцезнаходження безпілотного літального апарату за наземними навігаційними орієнтирами.

Об'єктом дослідження є процес машинного навчання та автономного розпізнавання наземних об'єктів.

Предмет дослідження – категорійні моделі та методи інформаційно-екстремального машинного навчання бортової системи навігації БПЛА для визначення місцезнаходження безпілотного літального апарату за наземними навігаційними орієнтирами.

За результатами аналізу сучасних безпілотних авіаційних комплексів обґрунтовано доцільність інформаційного синтезу автономних безпілотних літальних апаратів. Запропоновано класифікацію рівнів автономності безпілотників за їх функціональними можливостями. Обґрунтовано вибір методу досліджень в рамках інформаційно-екстремальної інтелектуальної технології аналізу даних. Розроблено комплекс функціональних категорійних моделей та удосконалено метод оцінки інформаційної спроможності інформаційно-екстремального машинного навчання автономної бортової системи навігації безпілотного. Розглянуто приклад інформаційно-екстремального машинного навчання бортової системи відеонавігації.

ЗМІСТ

ПЕРЕЛІК СКОРОЧЕНЬ, УМОВНИХ ПОЗНАК, ОДИНИЦЬ І ТЕРМІНІВ.....	6
ВСТУП	7
1 АНАЛІЗ ПРОБЛЕМИ ІНФОРМАЦІЙНОГО СИНТЕЗУ АВТОНОМНОЇ БОРТОВОЇ СИСТЕМИ ВІДЕОНАВІГАЦІЇ БЕЗПЛОТНОГО ЛІТАЛЬНОГО АПАРАТУ	10
1.1 Сучасний стан та тенденції розвитку автономних безпілотних літальних апаратів.....	10
1.2 Методи навігації безпілотних літальних апаратів	18
1.3 Методи машинного навчання систем розпізнавання зображень	29
2 ОПИС МЕТОДУ ДОСЛІДЖЕНЬ	42
2.1 Основні принципи та положення інформаційно-екстремальної інтелектуальної технології аналізу даних.....	42
2.2 Основні властивості автономної бортової системи відеонавігації, що навчається	46
2.3 Інформаційні критерії оптимізації параметрів машинного навчання	49
2.4 Базовий алгоритм інформаційно-екстремального машинного навчання автономної бортової системи відеонавігації	55
2.5 Функціонування автономної бортової системи в режимі відеонавігації ..	61
2.6 Інформаційно-екстремальне машинне навчання інтелектуальної системи за ієрархічною структурою даних	64
2.7 Оптимізація словника ознак розпізнавання	73
3 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ МАШИННЕ НАВЧАННЯ АВТОНОМНОЇ БОРТОВОЇ СИСТЕМИ НАВІГАЦІЇ	77
3.1 Формалізована постановка задачі інформаційного синтезу автономної бортової системи в режимі відеонавігації	77
3.2 Машинне навчання автономної бортової системи відеонавігації з оптимізацією контрольних допусків на ознаки розпізнавання	79
ВИСНОВКИ.....	93
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	96

ПЕРЕЛІК СКОРОЧЕНЬ, УМОВНИХ ПОЗНАК, ОДИНИЦЬ І ТЕРМІНІВ

БАК – безпілотний авіаційний комплекс;

БПЛА – безпілотний літальний апарат;

БСН – бортова система навігації;

БЕОМ – бортова електронно-обчислювальна машина;

БФО – блок формування ознак;

ІЕІ-технологія – інформаційно-екстремальна інтелектуальна технологія;

ІНС – інерційна навігаційна система;

НСК – наземна станція керування;

НТР – науково-технічна розробка;

ОПР – особа, що приймає рішення;

ОЕС – оптико-електронна система;

СКД – система контрольних допусків.

ВСТУП

Широке використання безпілотних літальних апаратів (БПЛА) для підвищення вогневої ефективності ракетних військ і артилерії одночасно обумовило удосконалення засобів радіоелектронної боротьби (РЕБ). Сучасні системи РЕБ дозволяють переривати зв'язок між дроном та оператором як за допомогою шуму, який передається на частотах, які автоматично визначаються, так і особливо характерними для теперішнього часу системами перехоплення управління. В залежності від класу апарату він може по різному реагувати на втрату сигналу від оператора. Відомі БПЛА, наприклад, MQ-9 Reaper (США), які здатні при застосуванні засобів РЕБ повертатися до місця запуску, використовуючи глобальну мережу визначення місцезнаходження GPS. При цьому для того, щоб запобігти поверненню апарату до рук ворога необхідно не лише блокувати сигнали на частотах управління, а також і сигнали навігаційних систем.

Аналіз сучасних підходів і тенденцій розвитку бортових систем навігації (БСН) показав, що основним шляхом підвищення їх функціональної ефективності є надання їм властивості автономності шляхом застосуванням інтелектуальних технологій аналізу даних на основі машинного навчання та розпізнавання образів. Про складність вирішення цієї проблеми свідчить той факт, що побудову автономної бортової системи БПЛА за проектом з умовною назвою GS-2 (США) планується завершити до 2030 року. Застосування традиційних методів інтелектуального аналізу даних Data Mining, включаючи штучні нейронні мережі для інформаційного синтезу БСР, не завжди забезпечує високу функціональну ефективність машинного навчання через такі науково-методологічні обмеження [3] :

- довільні початкові умови формування цифрових зображень об'єктів на місцевості, що розпізнаються, обумовлених різними ракурсами аерофотозйомки, висотами літального апарату, положенням і місцезнаходженням об'єкту;

- перетин класів розпізнавання, що характеризують зображення об'єктів, в просторі ознак розпізнавання;
- багатовимірність словника ознак і алфавіту класів розпізнавання;
- вплив неконтрольованих факторів, пов'язаних, наприклад, із зміною погодних умов, освітленості, маскуванню тощо.

Тому актуальною проблемою, на вирішення якої спрямовано науково-технічну розробку (НТР), що виконується на кафедрі комп'ютерних наук Сумського державного університету, є підвищення функціональної ефективності машинного навчання автономної БСН розпізнавати наземні природні та інфраструктурні навігаційні маяки з відомими географічними координатами. Вирішення цієї надскладної проблеми дозволяє підвищити оперативність і повну ймовірність правильного прийняття класифікаційних рішень. Особливо актуальною тема проекту є для України, де відсутнє виробництво інтелектуальних автономних БСН, на які існує високий попит за умови ведення бойових дій з російським агресором.

Досягнення поставленої мети в НТР здійснюється шляхом подальшого розвитку створеної в Сумському державному університеті так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності автономної БСН в процесі машинного навчання.

Проміжний звіт НТР складається із вступу, трьох розділів, висновків і переліку джерел посилання.

Перший розділ присвячено аналітичному огляду застосування автономних БПЛА в різних галузях соціально-економічної сфери у тому числі для розпізнавання природних, інфраструктурних та інших наземних об'єктів. За результатами аналізу сучасних методів машинного навчання обґрунтовано вибір методу досліджень.

Другий розділ присвячено основним положенням і принципам інформаційно-екстремального машинного навчання автономної бортової

системи БПЛА для розпізнавання наземних природних та інфраструктурних навігаційних маяків.

У третьому розділі зроблено формалізовану постановку задачі і розроблено категорійні моделі інформаційно-екстремального машинного навчання автономної БСН, яка здатна розпізнавати наземні навігаційні орієнтири з відомими географічними координатами. Розроблено і програмно реалізовано алгоритми інформаційно-екстремального машинного навчання БСН розпізнавати наземні об'єкти. Крім того, проведено порівняльний аналіз функціональної ефективності інформаційно-екстремального машинного навчання за лінійною та ієрархічною структурами даних.

Результати наукових досліджень, одержаних виконавцями проекту, опубліковано в працях [1–25].

1 АНАЛІЗ ПРОБЛЕМИ ІНФОРМАЦІЙНОГО СИНТЕЗУ АВТОНОМНОЇ БОРТОВОЇ СИСТЕМИ ВІДЕОНАВІГАЦІЇ БЕЗПЛОТНОГО ЛІТАЛЬНОГО АПАРАТУ

1.1 Сучасний стан та тенденції розвитку автономних безпілотних літальних апаратів

Безпілотний авіаційний комплекс (БАК) включає безпілотний літальний апарат (БПЛА) та пункти дистанційного керування (наземні станції керування (НСК)), необхідні лінії зв'язку та обладнання згідно з типом та конструкцією комплексу. БПЛА мають різне призначення зокрема їх широко використовують у військовій справі для проведення розвідки, для корегування ударів по наземних цілях і безпосередньо як ударні [26–28]. Крім того, БПЛА використовуються для завдань, виконання яких пілотованою технікою з різних причин не доцільно. До таких завдань можна віднести: моніторинг поверхні землі і води та повітряного простору, екологічний контроль, доставка вантажу у важко доступні регіони, археологія, сільське господарство тощо [29–31].

У працях [32–34] представлені бортові система технічного зору для автономного виконання окремих функцій БПЛА. Посадочна площадка з різними розмірами оптичних маркерів ретельно розроблена для надійного розпізнавання на різних відстанях. Для забезпечення надійної інформації про посадочну площадку при відмовленні глобальної системи позиціонування GPS реалізований алгоритм комп'ютерного зору Детектор SIFT, який детектує наземні об'єкти за їх контуром [35–37]. Ідея дескрипторних методів детектування наземних об'єктів полягає в тому, щоб ознаки, отримані з початкового зображення можна було розпізнати при зміні освітлення, масштабу зображення та наявності шуму. Такі точки знаходяться на високо контрастних ділянках зображення, якими є межі об'єкту.

Дескриптори на основі SIFT перевершують за продуктивністю інші дескриптори у випадку текстурованих або структурованих зображень, які зазнали зміни масштабу в відношенні від 2 до 2.5 або при повороті від 30 до

45 градусів. SIFT можна використовувати для повністю автоматизованого зшивання панорами із декількох зображень.

Як детектори особливих точок часто використовуються алгоритми Harris-Laplace, Hessian-Laplace, Fast Hessian, SUSAN та DoG, серед яких найбільшою оперативністю характеризується Fast Hessian [38]. При цьому фрагменти зображення для більш компактного подання описують числовим вектором, який називають дескриптором локальної ознаки. Щодо точності, то обнадійливі результати отримано в праці [14] шляхом застосування сплайнів високих порядків. З точки зору відношення точності та оперативності найбільш ефективними є алгоритми SURF та FREAK. Проте основним недоліком дескрипторних методів детектування наземних об'єктів є відсутність формалізованих правил щодо вибору значень порогових параметрів, що відповідають за врахування чи відкидання локальних ознак.

Відомий досвід застосування автономного БПЛА для обприскування агрокультур, що є важливим для точного застосування пестицидів. Наприклад, у праці [39] розглядається система машинного навчання БПЛА, яка має переваги високої обчислювальної швидкості та відносно високої точності для обприскувачів при розпізнаванні ділянок розпилення пестицидів. Система машинного навчання була розроблена із використанням методу взаємного підпростору (MSM) для зображень, отриманих за результатами авіарозвідки з використанням БПЛА. Зображення були зібрані з низьких (5 м) і великих (15 м) висот для посівів та садів відповідно. Польові експерименти проводились у цільових районах для навчання та тестування системи за допомогою комерційного БПЛА із вбудованою камерою 4К. В автономній системі розпізнавання було отримано 74,4% точності для класифікаторів при розпізнаванні розпорошених та нерозпилюваних ділянок для посівів. Час обчислень при розпізнаванні наземного об'єкту для системи розпізнавання, яка знаходилась на наземній станції керування (НСК), був в середньому 0,0031 с.

Успіхи в розпізнаванні морських об'єктів різко зросли, особливо за останнє десятиліття. У праці [40] наведено огляд застосування методів глибокого машинного навчання нейромереж для розпізнавання БПЛА як надводних, так і підводних об'єктів. Для машинного навчання використано згорткові нейронні мережі (CNN), мережі глибоких переконань (DBN) та автокодер (AE) тощо. Відповідно в цій праці надаються набори популярних базових даних для розпізнавання морських об'єктів і всебічно аналізуються методології глибокого машинного навчання з інтенсивним порівнянням.

У праці [41] розглянуто приклади застосування БПЛА для управління активами цивільної інфраструктури. Кілька прикладів включають планові інспекції мостів, управління катастрофами, спостереження за лініями електропередач та обстеження руху. В праці детально описано процедуру машинного навчання згорткових штучних нейронних мереж (ШНМ) на наборі аерофотознімків для ефективного та автоматизованого розпізнавання об'єктів. Результати розпізнавання об'єктів показують, що, вибравши обмежений набір параметрів і достатньо репрезентативну навчальну вибірку, CNN може виявляти та класифікувати об'єкти з високим рівнем точності (97,5%). Нажаль дані про оперативність та обчислювальну ефективність в праці не приводяться. Крім того, варто вказати, що загальним недоліком ШНМ різних структур є їх чутливість до багатовимірності словника ознак розпізнавання, необхідність великої кількості зображень наземних об'єктів та інтерактивний режим машинного навчання, що суттєво обмежує застосування нейроподібних структур для машинного навчання автономних бортових систем БПЛА.

Найбільші виробники БАК оснащують НСК безпілотного авіаційного комплексу системою підтримки прийняття рішень (СППР). Так однією із складових, наприклад, турецького ударного безпілотника Байрактар ТБ2, який, до речі, використовується армією України, є автоматизована НСК, показана на рисунку 1.1 [42].



Рисунок 1.1 – Наземна станція керування авіаційним безпілотним комплексом Байрактар ТБ2

Оператори НСК отримують зображення з борту БПЛА та сумісно з СППР приймають рішення стосовно планування подальших дій. При такій взаємодії між людиною та машиною значну роль відіграє налагоджування каналу їх зв'язку. Більшість із досліджень, які зосередженні на вирішенні цього питання, пропонують створювати окремі програми-симулятори, як це показано в праці [43]. Такий підхід дозволяє підготувати оператора для сумісної роботи з СППР. Проте такі системи, зазвичай, ігнорують можливість налаштування та машинного навчання БСР у рамках комп'ютерної симуляції. Хоча це дозволило б отримати високостовірні вирішальні правила за контрольованих умов, наближених до реальних.

Таким чином, можна зробити висновки:

1) Сучасні БПЛА провідних у світі розробників все ще використовуються як транслятори зображень наземних об'єктів, які аналізуються операторами НСК з метою розв'язання відповідних задач.

2) Орієнтація на глобальні і локальні мережі GPS робить БПЛА слабо захищеним від засобів радіоелектронної боротьби (РЕБ) і створює сприятливі умови для організації вторгнень і кібератак, що гостро потребує вирішення

проблеми надання бортовим системам властивості автономного функціонування.

3) З метою кіберзахисності БПЛА актуальною задачею є створення на основі сучасних методів інтелектуального аналізу даних автономних БСВН, здатних визначати своє місцезнаходження за результатами розпізнавання наземних природних та/або інфраструктурних об'єктів, які відіграють роль навігаційних маяків. Крім того, розв'язання цієї задачі дозволить підвищити функціональну ефективність бортової системи для розпізнавання навігаційних перешкод і повітряних загроз.

Розпізнавання наземних рухомих і нерухомих об'єктів в працях вирішується у два етапи. Спочатку бортова система розпізнавання (БСР) за оптичним каналом визначає кадр зони інтересу, в якому з великою ймовірністю може знаходитися об'єкт, який розшукується. Такою зоною інтересу для виявлення, наприклад, наземного транспортного засобу звичайно є автомагістраль або інша дорога. На другому етапі кожний об'єкт, який знаходиться в кадрі зони інтересу, порівнюється з об'єктами, сформованими на етапі машинного навчання бортової системи. При цьому функціональна ефективність машинного навчання бортової системи розпізнавання за оптико-електронним каналом спостереження, основними складовими якої є достовірність і оперативність вирішальних правил, суттєво залежить від метода машинного навчання.

В останні роки основним напрямом підвищення функціональної ефективності бортових систем пошуку наземних об'єктів стало застосування інтелектуальних інформаційних технологій аналізу даних (Data Mining). Застосування традиційних методів інтелектуального аналізу даних [44–461], включаючи штучні нейронні мережі (ШНМ), для інформаційного синтезу БСР не завжди забезпечує успішне розв'язання задачі через такі науково-методологічні обмеження:

- довільні початкові умови формування зображень об'єктів на місцевості, що розпізнаються, обумовлених різними ракурсами

аерофотозйомки, висотами літального апарату, місцезнаходженням наземного об'єкту тощо;

- перетин класів розпізнавання, що характеризують зображення наземних об'єктів, в просторі ознак розпізнавання;
- багатовимірність словника ознак і алфавіту класів розпізнавання;
- вплив неконтрольованих факторів, пов'язаних, наприклад, із зміною погодних умов, освітленості, маскуванням тощо.

Поява нового класу автономних БПЛА обумовлює суттєву зміну структури і функцій НСК. Однією із нових функцій НСК є необхідність машинного навчання та перенавчання БСР за оперативними результатами авіарозвідки у випадку виявлення нового об'єкту в зоні бойових дій. Для можливості машинного навчання та перенавчання БСР структура НСК повинна включати так званий випробувально-налагоджувальний стенд (ВНС), призначений для розроблення, відлагодження та верифікації інформаційного, алгоритмічного та програмного забезпечення здатної навчатися БСР. ВНС складається із оснащеного широко форматним монітором симулятора 3D-зображень рельєфу регіону, що спостерігається, з можливістю комп'ютерної інтеграції у відеопоток об'єкту розпізнавання, який аналізується оптико-електронним каналом спостереження натурної бортової системи БПЛА, та необхідної інфраструктури. Таким чином створюються умови машинного навчання та перенавчання БСР, максимально наближені до реальних.

До теперішнього часу відсутнє узгоджене або юридичне визначення поняття терміну «автономний БПЛА». Найбільш поширеною є точка зору, що автономним називається БПЛА, здатний обирати самостійно свій варіант дій. У технологічному аспекті під автономністю БПЛА доцільно розуміти наявність інтелектуальної складової, що дозволяє за результатами машинного навчання будувати вирішальні правила з метою прийняття при виконанні польотного завдання класифікаційних рішень і навіть самостійно розробляти можливі варіанти дій у відповідь на нові проблеми.

Враховуючи функціональні можливості БПЛА запропонуємо таке визначення послідовних рівнів автономності:

1) Перший рівень автономності БПЛА забезпечує наявність на борту автопілота, зв'язаного з глобальними мережами позиціонування типу GPS.

2) Другий рівень автономності – здатність бортової системи БПЛА розпізнавати наземні, надводні, підводні та повітряні об'єкти за побудованими за результатами машинного навчання вирішальними правилами і передавати відповідну інформацію за криптозахисним каналом на НСК.

3) Третій рівень автономності – здатність бортової системи БПЛА самонавчатися розпізнавати наземні надводні, підводні та повітряні об'єкти.

4) Четвертий рівень – здатність БПЛА за результатами класифікаційних рішень виконувати автономно окремі функції польотного завдання, наприклад, для розвідувально-ударного БПЛА пуск і націлення боеприпасу безпосередньо з безпілота, для безпілота-доставщика вантажу самостійна посадка у визначеному місці тощо.

5) П'ятий рівень – здатність БПЛА здійснювати автономну навігацію за наземними природними та інфраструктурними орієнтирами без зв'язку автопілота з GPS.

6) Шостий рівень – здатність БПЛА виконувати завдання в режимі астронавігації без зв'язку автопілота з мережею GPS.

Варто підкреслити сучасну тенденцію, що для всіх рівнів автономності БПЛА повинні бути оснащені засобами РЕБ і системами інформаційного і кібернетичного захисту.

На сьогодні відсутня інформація про наближення прориву у досягненні високих рівнів автономності БПЛА, але це не означає, що насправді він близький. Вже відомі приклади використання БПЛА з автономністю другого рівня для розв'язання задач як цивільного, так і військового характеру. Відомі застосування «роїв безпілотників», які йдуть один за одним і виконують задачі за інформацією, отриманою з інших БПЛА [47]. При цьому забезпечується автоматизоване оброблення інформації. Також відомі випробування

автономних безпілотників, які працюють разом з пілотованим літальним апаратом «Loyal Wingman» («Вірний відомий») [48]. В США гарно зарекомендував комплекс спостереження за широким морським районом (BAMS), в склад якого входить патрульний літак військово-морських сил «Посейдон – 8» і БПЛА «Тритон» [49]. Разом з тим проводяться розробки та випробування БПЛА, які запускаються для роботи в автономному режимі з пілотованих літальних апаратів. Так відомо про випробування нано-безпілотників «PERDIX», в ході яких 100 безпілотних апаратів було скинуто з літака-носія F-18. В американському проекті Maven [50] кінцевою метою проекту є створення комплексної автономної бортової системи БПЛА, здатної самостійно виконувати покладені на неї завдання, навіть за умови повної відсутності зв'язку з НСК. Окрім ідентифікації відеопотоку цей проект спрямовано на вирішення проблеми адаптивності алгоритмів інтелектуального аналізу даних до розширення алфавіту класів розпізнавання з подальшим перенавчанням. Прототипи такої розробки наведено в праці [51]. Згідно з планами Агентства передових оборонних дослідних проектів (Defense Advanced Research Projects Agency, DARPA) розвиток власних інтелектуальних систем, що використовуються в БПЛА, здійснюється за такими напрямками:

- підвищення стійкості БПЛА, що дозволяє системі зберігати свій поточний стан, навіть при зміні зовнішніх факторів;
- боротьба з кібератаками, що тісно пов'язаний зі стійкістю системи;
- розвиток технічного забезпечення бортових систем і НСК для створення нового покоління БПЛА з властивістю повної автономності.

Дослідження вітчизняних та закордонних вчених акцентуються на двох основних напрямках вирішення проблеми – це формування релевантного вхідного інформаційного опису автономної БСР і розроблення методів машинного навчання бортової системи розпізнавати наземні об'єкти. Подальшою перспективою підвищення рівня автономності БПЛА є застосування інформаційних інтелектуальних технологій аналізу даних для

автономної навігації за наземними природними та інфраструктурними орієнтирами без виходу в глобальну мережу GPS. Вирішення цієї проблеми також пов'язано з розпізнаванням наземних навігаційних об'єктів і визначенням методами проективної геометрії місцезнаходження БПЛА з метою відпрацювання відхилення безпілота від заданої траєкторії польоту.

Питання використання БАК регламентуються міжнародними та українськими нормативно-правовими документами [47, 48]. У випадку бойових дій автономні безпілоти повинні застосовуватися тільки проти військових цілей, а їх використання не повинно причиняти надмірних побічних втрат згідно з принципом сорозмірності.

1.2 Методи навігації безпілотних літальних апаратів

Основа навігаційних систем БПЛА складають приймачі глобальних мереж супутникової навігації GPS, комплексовані з блоком інерціальних датчиків просторової орієнтації. При цьому застосування інерціальних навігаційних систем (ІНС) не гарантує досягнення високої точності через такі причини:

- принциповим недоліком ІНС є збільшення помилки визначення координат продовж часу автономної роботи;
- сучасні системи радіоелектронної боротьби (РЕБ) дозволяють переривати зв'язок між БПЛА та оператором як за допомогою шуму, який передається на частотах, які автоматично визначаються, так і особливо характерними для теперішнього часу системами перехоплення керування.

Основним перспективним шляхом запобігання втрати БСН автономності та завадостійкості є застосування відеонавігації разом з визначенням координат БПЛА за пеленгаційними вимірами відстані до наземного навігаційного маяка з відомими координатами.

Для реалізації способу відеонавігації необхідно розв'язувати задачу пошуку на карті регіону та ідентифікації оптико-електронною системою спостереження автономної БСВН наземного навігаційного маяка з метою

визначення координат та орієнтації літального апарату. Розв'язання такої задачі вимагає моделювання когнітивних процесів природного інтелекту формування та прийняття класифікаційних рішень шляхом машинного навчання БСВН. При цьому успішна реалізація відеонавігації залежить від таких двох факторів:

- наявність релевантного вхідного інформаційного опису автономної БСВН;

- наявність методу машинного навчання з високою функціональною ефективністю.

У теперішній час виробники безпілотних систем проводять дослідження та розробки, спрямовані на забезпечення автономності БПЛА за умов відсутності сигналів супутникової навігації на основі альтернативних джерел інформації. До таких джерел відносяться в першу чергу видова інформація, отримана з бортових фото та відеокамер денного та інфрачервоного діапазонів, синтезоване зображення радара, дані цифрового рельєфу регіону, що спостерігається, космічні знімки, а також так звані «сигнали природного походження»: вектор сили ваги, магнітне поле Землі, положення зірок тощо. Наприклад, компанія RockwellCollins, виробляюча апаратуру навігації для БПЛА різних типів, оповістила про завершення розробки проекту Vision Augmented Inertial Navigation System (VAINS), в якому здійснюється корекція ІНС за швидкістю та координатам, що визначаються відеокамерою за відсутності сигналів супутникової навігаційної системи.

В основу методу відеонавігації покладено три базових способи:

1. Обчислення пройденої відстані шляхом аналізу відеопотоку даних, отриманих за оптико-електронним каналом спостереження. В першому кадрі відеопотоку знаходяться характерні ознаки, положення яких далі відслідковується в кадрі зображення регіону. За характером переміщення програма визначає як змінюється положення та орієнтація самої камери.

Основними обмеженнями методу є відносність визначення координат та орієнтації БПЛА, що може привести до накопичення помилки навігації з

часом. Також можуть бути умови, що не дозволяють знайти відповідні особливі інваріантні ознаки на знімках: недостатня освітленість, хмарність, відсутність характерних ознак розпізнавання на текстурних зображеннях поверхні регіону.

2. Метод точної прив'язки до рельєфу за стереоефектом, що утворюється при переміщенні відеокамери. Цей спосіб дозволяє частково компенсувати недоліки першого методу шляхом перекриття потоку фото- відеоданих, що дозволяє відновити рельєф, який порівнюється із закладеними у пам'ять БСВН даними, і у випадку збігання визначаються точні координати та орієнтація. Основна перевага перед попереднім методом – можливість знайти не тільки відносне, але і абсолютне положення камери, оскільки знання карти регіону прив'язує камеру до конкретних ознак на місцевості з відомими абсолютними координатами. У результаті помилка навігації не має тенденції до збільшення у часі польоту. Основний недолік методу – чутливість до великих помилок початкових координат камери, отриманих від ІНС, які метод повинен потім уточнювати. Також зберігається такий недолік першого методу, як виникнення суттєвих помилок при наявності гладкого рельєфу;

3. Метод точної прив'язки до еталонних фотографій, за яким кадри відеопотоку порівнюються із закладеними у пам'ять БСВН зображеннями ділянок маршруту і у випадку їх збігання визначаються точні координати та орієнтація. Цей метод забезпечує високу точність визначення абсолютних координат навіть при відсутності рельєфу. Він також дозволяє знайти абсолютне положення камери, навіть коли її приблизні координати взагалі невідомі. Це досягається шляхом сканування бази даних із знімками місцевості і порівняння їх з поточним знімком. Крім того, маючи «прив'язаний» знімок можна з високою точністю визначати координати наземними об'єктів, виявлених оптико-електронною апаратурою.

Розглянемо метод визначення координат БПЛА за пеленгаційним виміром наземного об'єкту з відомими координатами. Оскільки відсутні прямі методи визначення дальності до цілі, то виникає задача визначення її

координат тільки на основі кутових вимірів з подальшою прив'язкою координат цілі до карти місцевості. Для цього необхідне точне визначення положення самого БПЛА шляхом реалізації методу одночасної часової локалізації та картографування [3, 5].

Найбільш відомим алгоритмом локалізації цілі за пеленгом є розширений фільтр Калмана або навіть набір таких фільтрів з різними діапазонами дальності [1]. Для уточнення координат БПЛА необхідна прив'язка до наземних ориєнтирів, якими може бути мережа радіолокаційних вишок, пеленгуючих положення БПЛА і передаючих йому пеленг на визначеній раніше фіксованій частоті; набір характерних елементів ландшафту або інфраструктурних об'єктів з точно відомими координатами, які БПЛА розпізнає та визначає кути на елемент, відносно свого положення в просторі. Отже в обох варіантах визначення місцезнаходження БПЛА зводиться до задачі відновлення координат за пеленгаційними вимірами.

Попередня оцінка та комп'ютерне моделювання виконані в праці [], позазивають, що застосування методів визначення координат наземного об'єкту за оптико-електронним каналом БСН і цифровими геоданими дозволяє визначати координати місцезнаходження з помилкою не більше 30 м незалежно від часу польоту. Найкращий результат дає комплексне використання всіх методів у сполученні з традиційною ІНС. На рисунку 1.2 показано узагальнену схему комплексної БСН БПЛА.

На рисунку 1.2 роль концентратора комплексної бортової системи навігації БПЛА відіграє бортова електронно-обчислювальна машина, яка реалізується найчастіше на платі Rasbery P4. Геодані у вигляді зображення регіону, що спостерігається, обробляються оптоелектронною системою спостереження (ОЕС) і поступають у блок формування ознак (БФО), де здійснюється їх фільтрація, масштабування за висотою БПЛА, нормалізація, і формування фреймів відеопотоку, кадрування зображень та інші допустимі перетворення. У результаті з виходу БФО на вхід БЕОМ поступають із заданим часовим інтервалом структуровані вектори ознак розпізнавання, які

відбивають властивості кадрів зображень регіону і формують тривимірну навчальну матрицю. На другий вхід БФО поступають геодані отримані за інфрачервоним каналом спостереження, які можуть розглядатися як окремі ознаки розпізнавання, або бути приєднані після відповідних допустимих перетворень до структурованого вектору відеоознак, як додаткова інформація про об'єкт спостереження. Призначенням пеленгатора і вимірювача висоти БПЛА є визначення місцезнаходження БПЛА за пеленгаційними вимірами відстані до наземного орієнтира. Приймально-передавальні пристрої МОДЕМ1 і МОДЕМ2 забезпечують зв'язок з глобальною мережею GPS і НСК відповідно.

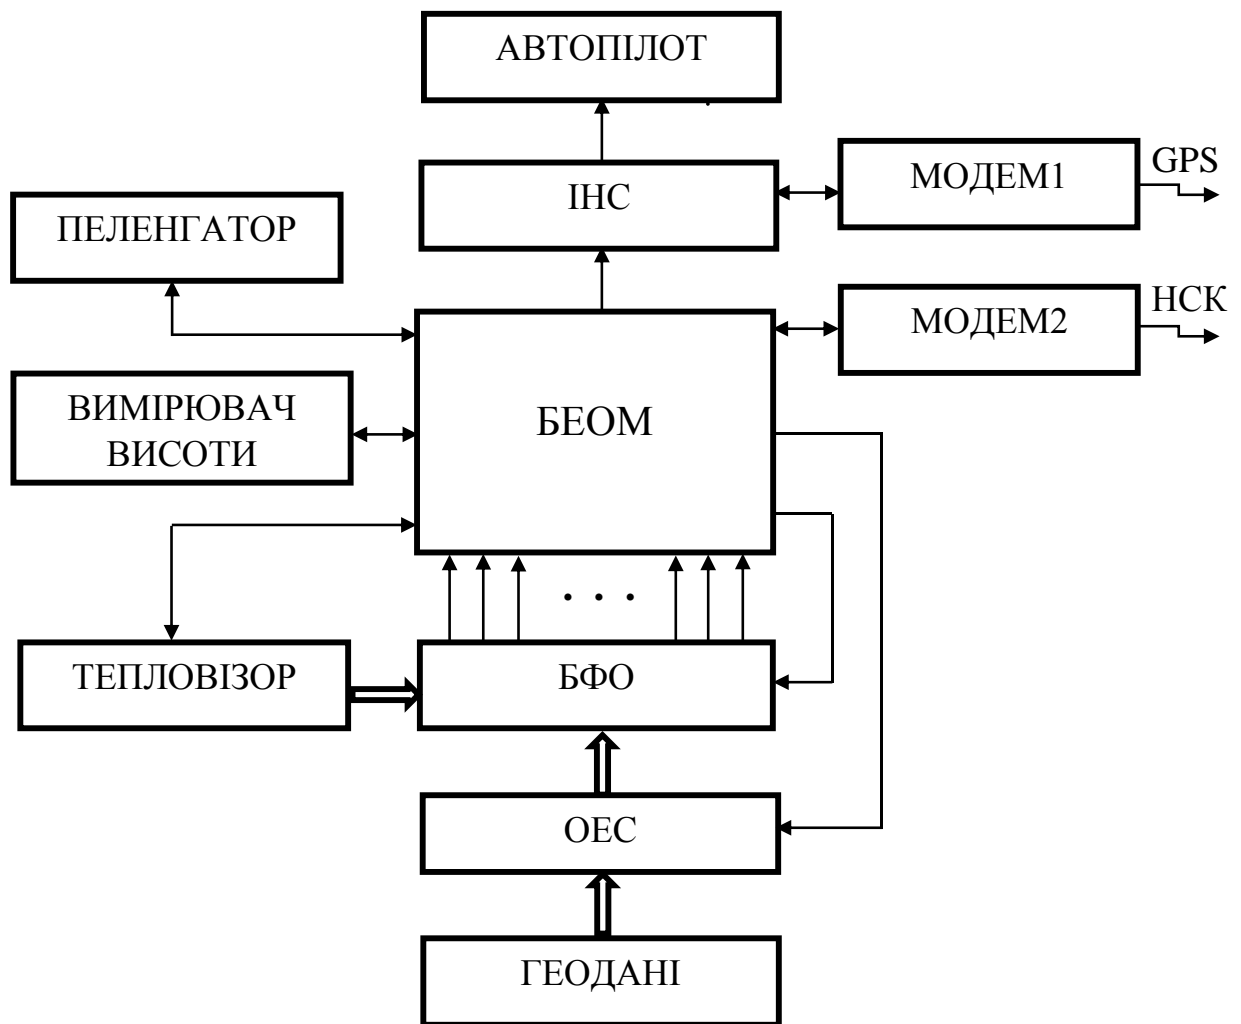


Рисунок 1.2 – Структурна схема комплексної бортової системи БПЛА

В задачах розпізнавання зображень самими трудомісткими є операції попередньої обробки і формування ознак, що вимагають перетворення двовимірних інформаційних масивів. Машинне навчання і класифікація, як правило, вимагають виконання комплексу простих арифметичних або логічних операцій над порівняно невеликою кількістю чисел (ознак). Для цієї мети добре пристосована цифрова техніка. Звідси витікає доцільність побудови гібридних (аналого-цифрових) систем розпізнавання зображень, в яких оптична аналогова частина виконує операції попередньої обробки і формування ознак, трудомістких з погляду їх реалізації на БЕОМ. Узагальнена функціональна схема гібридної оптико-електронної системи розпізнавання зображена на рисунку 1.3 [54].




Рисунок 1.3 – Узагальнена функціональна схема гібридної електронно-оптичної системи розпізнавання зображень

Світловий потік, що поступає від джерела, модулюється функцією досліджуваного зображення $f(x,y)$ – просторовим модулятором світла. Потім в блоці попереднього перетворення від цієї функції змінюється з урахуванням специфіки конкретної задачі (мультиплікація тощо). Після попереднього перетворення світловий потік поступає в БФО, вихідними величинами якого є напруги, пропорційні обчисленим функціоналам.

В електронних пристроях формування зображення як аналогових так і цифрових типів, до яких відносяться цифрові камери, модулі камери, мобільні телефони, оптичні миші та таке інше, використовують сенсори зображення. Сенсор зображення або світлочутлива матриця – це сенсор який виявляє та передає інформацію, яку використовують для створення зображення.

Двома основними типами електронних сенсорів зображення є сенсор з активним пікселем та сенсор із зарядовим зв'язком.

Сенсор з активним пікселем APS – це датчик зображення в якому кожна одинична комірка піксельного датчика має фотодетектор і один або декілька активних транзисторів [54, 56]. Існують різні типи APS такі як NMOS APS і більш поширений CMOS, який широко використовується в цифрових відеокамерах, камерах мобільних телефонів, веб-камерах, цифрових фотокамерах. CMOS датчик з'явився як альтернатива датчикам зображення з зарядовим зв'язком.

Датчики APS зазвичай використовують невелику кількість енергії, мають невелику затримку зображення. Датчики APS на відміну від CCD можуть об'єднувати в одній інтегральній схемі функції датчика зображення і функції обробки зображення. Датчики APS часто використовують в камерах мобільних телефонів. Вони також часто використовуються в інших областях, наприклад, у цифровій рентгенографії, військовому високошвидкісному обладнанні для отримання зображення, відеокамерах спостереження тощо.

Перевагою датчика CMOS є те що його виготовлення зазвичай дешевше ніж датчик CCD, оскільки елементи захоплення зображення і обробки зображення об'єднані на одній схемі, що потребує більш просту конструкцію. CMOS датчик має невелике енергоспоживання в статичному стані. Це дозволяє використовувати такі матриці в датчиках руху і системах спостереження, які знаходяться в режимі очікування більшу частину часу.

За допомогою механізму довільного доступу можна проводити зчитування обраних груп пікселів. Дана операція дозволяє зменшити розмір захопленого зображення і потенційно збільшити швидкість зчитування

порівняно з ССD матрицею, оскільки в ССD для обробки потрібно завантажити всю інформацію.

В системах, які містять контур розпізнавання зображень, знайшли широке використання особливо при ідентифікації кадрів та в задачах навігації екстремально-кореляційні методи розпізнавання зображень [57–59]. Серед них відзначимо найбільш типові.

Класичний екстремально-кореляційний метод ґрунтується на обчисленні взаємної кореляційної функції або інтегралу типу згортки з наступним пошуком максимуму цієї функції. Алгоритм характеризується великим обсягом обчислень і чуттєвий до взаємодії адитивних шумів і геометричних деформацій зображення типу повороту, зміни масштабу, ракурсу. Основні модифікації даного методу пов'язані з використанням різницевих алгоритмів, які мають переваги перед класичним алгоритмом, тому що в них відсутня операція множення.

Метод інваріантних моментів, сутність якого полягає у визначенні функції кореляції між статистичними моментами функції розподілу зображень, що порівнюються. Він є інваріантним до деформацій зображення типу зсуву, повороту, зміни масштабу, але має високу обчислювальну трудоемність.

Багаторівневі ієрархічні кореляційні алгоритми, в яких на нижньому рівні ієрархії приблизно визначається область найбільшої кореляції, а на наступному рівні в цій області обчислюється більш точне значення екстремуму взаємної кореляційної функції.

Алгоритм фазової кореляції, який зводиться до обчислення кореляції за фазовими складовими спектрів зображень, оскільки фаза спектра сигналу несе більш істотну інформацію про сигнал, ніж амплітуда. Цей алгоритм у порівнянні з класичним кореляційним є більш трудомістким, але кращим образом функціонує при наявності вузькополосного шуму.

Гradientні методи порівняння зображень, що враховують взаємне розташування об'єктів у кадрі [60]. Як стійкі ознаки алгоритм використовує

нормалі до локальних векторів градієнтів полів яскравості зображень. Зіставлення аналізованого зображення з еталонним описом здійснюється за такими параметрами нормалей, як їхня довжина, напрямок, знак контрасту, вага і зсув щодо обраної в еталонному описі точки відліку.

Основні переваги методу такі:

- інваріантність до значних змін полів яскравості зображень;
- малий обсяг пам'яті для збереження еталонного опису;
- можливість розпаралелювання процесу координатної прив'язки, що дозволяє виконувати обчислення в реальному масштабі часу.

Автоматичні системи, які реалізують екстремально-кореляційні методи розпізнавання, вимагають значних обчислювальних ресурсів. У зв'язку з чутливістю кореляційних систем до геометричних деформацій оброблюваних зображень необхідно зберігати в класифікаційній бібліотеці набір еталонів, що перекривають усі можливі зміни на зображеннях. Але основним недоліком екстремально-кореляційних методів, який обумовлює їх низьку завадозахищеність є відсутність адаптивного вибору порогу порівняння

Практично всі системи цифрової обробки зображень базуються на різних ідеологіях, що накладають певні обмеження на клас розв'язуваних задач.

З існуючих методів обробки і розпізнавання зображень отриманих за допомогою оптико-електронних систем розпізнавання зображень можна виділити шість підходів до обробки зображень [612, 62].

1. Корекція і перетворення зображень: установка оптимальної яскравості, контрастності і фокусування зображення, корекція яскравості і контрасту, визначення локальних оптичних характеристик об'єкта: оптичної щільності, коефіцієнтів відображення або пропущення з можливістю калібрування по еталонних ділянках, калібрування й аналіз зображення в режимі реєстрації відбитих електронів системи розпізнавання з визначенням локального атомного номера речовини зразка, підкреслення границь і зменшення шумів на вихідному напівтоновому зображенні, виділення границь

шляхом обчислення градієнта або перетворень Лапласа, корекція нерівномірності освітленості, арифметичні операції між декількома зображеннями.

2. Обробка й аналіз методами математичної морфології: перетворення напівтонового зображення в бінарне по одному порогу або в яскравісному вікні, геометричні перетворення першого рівня для бінарного зображення.

3. Індивідуальний морфологічний аналіз структури: корекція нерівномірності освітленості без аналізу опорного поля освітленості, перетворення напівтонового зображення в бінарне при дослідженні зображень з двома переважними градаціями яскравості, кольорокодування напівтонового зображення на основі яскравості, обчислення гістограми яскравості напівтонового зображення, аналіз напрямку орієнтації і ступеня анізотропії структури, побудова гістограм розподілу по розмірах, по площах, за коефіцієнтом форми, по сумарних площах в інтервалах розмірів пір (часток), обчислення матриць розподілу одночасно по двох параметрах: за формою і розмірам; калібрування збільшення для правильного одержання результатів у розмірних одиницях.

4. Фур'є-аналіз зображень, який включає: одномірне перетворення Фур'є заданого рядка зображення і метрологічний аналіз періодичності досліджуваної структури по її спектру, виділення часток і спектральний аналіз їхньої форми, швидке двовимірне перетворення Фур'є від напівтонового зображення, метрологічний аналіз просторової періодичності досліджуваної структури на основі двовимірного Фур'є-спектра.

5. Мікротомографія: установка оптимальної яскравості, контрастності і фокусування зображення, реконструкція внутрішньої тривимірної структури мікрооб'єкта по тінювих двовимірних проекціях із програмним управлінням мікросканером, одержання проекційних даних і їхня наступна реконструкція, одержання псевдо тривимірного зображення внутрішньої реконструйованої мікроструктури об'єкта, виведення зображень тінювих проекцій і реконструйованих перетинів.

6. Обробка кольорових зображень і стереопар: аналіз рельєфу по стереопарах, аналіз стереопар по кольору, виведення кольорового зображення на основі аналізу кольорів, перетворення кольорового напівтонового зображення в бінарне по ознаках яскравості і кольору.

Однак, щоб використовувати перераховані вище методи обробки оцифрованого зображення в автоматичному або напівавтоматичному режимі потрібно вирішити проблему автоматичного одержання зображення за однакових умов. Система розпізнавання зображень, що самонастроюється дозволить одержати зображення, що мають практично рівні параметри.

Незважаючи на великий обсяг публікацій значних зрушень у підвищенні ефективності машинного навчання систем розпізнавання зображень наземних об'єктів все ще не відбувається. Основними науково-методологічними причинами такого стану є:

модельний характер переважної більшості відомих методів автоматичної класифікації, що робить їх непридатними для практичного застосування;

нелінійність, нестационарність, багатofакторність і апріорна невизначеність складних процесів управління в нечіткому просторі функціональних станів, що й обумовлює їх слабку формалізованість.

Крім того, основний недолік більшості відомих методів оброблення і розпізнавання зображень полягає в ігноруванні перетину класів розпізнавання, що має місце на практиці.

Порівняльний аналіз методів розпізнавання електронно-оптичних зображень показав залежність вибору методу як від типу досліджуваного зразка, так і робочих умов системи розпізнавання.

Таким чином, проведений аналіз літератури дозволяє зробити висновки, що існуючі електронно-оптичні системи розпізнавання зображень не враховують у повній мірі властивостей конкретних типів досліджуваних зразків, робочих умов настроювання системи та її функціонування при виконанні поставленої задачі. Тому виникає потреба в створенні адаптивної

системи розпізнавання електронно-оптичних зображень на основі ідей і методів інтелектуального аналізу даних.

1.3 Методи машинного навчання систем розпізнавання зображень

В останні роки основним напрямком підвищення функціональної ефективності бортових систем пошуку наземних об'єктів стало застосування інтелектуальних інформаційних технологій аналізу даних. Найбільш поширеними в останні роки методами розпізнавання зображень є згорткові нейронні мережі (convolutional neural networks – CNN), які відносяться до нейронних мереж третього покоління [70–72]. Завдяки реалізації принципів глибокого машинного навчання багатозгорткові ШНМ набули великої популярності при вирішенні різноманітних завдань у галузі комп'ютерного зору [66–69]. Багатозгорткові ШНМ типової архітектури є багатоваршівним каскадом мереж прямого поширення. Основними типами шарів для таких ШНМ є кілька згорткових шарів, шарів об'єднання (pooling) та шарів мереж прямого поширення з навчанням. Вихідний шар згорткової мережі представляє карту ознак: кожен елемент вихідного шару отримано застосуванням операції згортки між вхідним шаром і кінцевою підобластю (рецептивним полем) із застосуванням певного фільтра (ядра) та подальшою дією нелінійної функції активації. Шари пулінга виконують операцію зниження рівня дискретизації (downsampling operation) для карти ознак (часто - за допомогою обчислення максимуму в межах певної кінцевої області). У багатокаскадній мережі після каскаду згорткових шарів і шарів пулінгу (stacked convolutional and pooling layers) зазвичай слідує кілька пов'язаних шарів (fully-connected layers, FL). Таким чином, багатокаскадна згорткова ШНМ перетворює матрицю піксельних значень вхідного зображення на матрицю остаточних ознак методом прямого поширення мережі (a feedforward manner). Параметри CNN (ваги зв'язків згорткових і повнозв'язних 15 шарів мережі) зазвичай налаштовуються застосуванням методу зворотного поширення помилки (backpropagation, BP), реалізованого за допомогою

класичного градієнтного спуску (stochastic gradient descent). Згорткові мережі з глибоким навчанням (deep convolutional neural networks – DCNN) продемонстрували великі можливості у вирішенні завдань обробки великих зображень високої роздільної здатності (зокрема, у вирішенні завдань класифікації таких зображень) завдяки двом особливостям [70–72]:

- DCNN мають великі можливості навчання (велику ємність мережі);
- DCNN дозволяють використовувати накопичені бази даних (що дозволяє компенсувати відсутність тих даних, які в конкретному завданні не мають). Для прискорення процесу навчання в DCNN часто використовується як функція активації мережевого нейрона нелінійна функція ReLU. Навчання великих мереж DCNN (наприклад, для таких мереж, як ImageNet), які часто містять мільйони параметрів, є складним завданням. Потрібні великі бази даних і навчальні матриці великих обсягів. При виконанні таких умов DCNN можуть бути використані в широкому колі завдань комп'ютерного зору, таких як класифікація зорових сцен, детектування образів (фрагментів зображення), семантична сегментація зображень, розпізнавання образів, відновлення зображень.

Завдання пошуку та розпізнавання об'єктів на зображеннях актуальні як у галузі моніторингу та аналізу знімків дистанційного зондування Землі, так і для аналізу аерофотознімків. Для вирішення цих завдань використовувалися різні алгоритми – від простої порогової бінаризації до застосування гістограм спрямованих градієнтів. Нейромережеві алгоритми також набули поширення на вирішення цих задач. Часто завдання пошуку об'єктів заданого типу, розпізнавання об'єктів та класифікації об'єктів на зображенні виявляються пов'язаними, особливо у разі пошуку кількох типів об'єктів.

До завдань розпізнавання об'єктів у зображенні можна віднести задачу семантичної сегментації зображень – завдання виділення у зображенні локальних областей (сегментів), що відповідають різним класам об'єктів. Сегментація супутникових зображень потрібна у низці областей: автоматичне створення карт місцевості [73], аналіз георесурсів [74], містобудування [75],

аналіз землекористування [76] тощо. Але незважаючи на велику кількість відомих алгоритмів та методів класифікації об'єктів на зображеннях, актуальною є задача розробки методів та програмних засобів, що дозволяють автоматизувати цей процес та підвищити функціональну ефективність системи розпізнавання наземних об'єктів.

Як було з'ясовано, нейромережеві алгоритми з використанням саме згорткових мереж мають такі важливі переваги, як стійкість до спотворення вхідних даних, висока достовірність класифікації, не надто велика кількість параметрів, що настроюються. Як приклад розглянемо багатозгорткову ШНМ для семантичної сегментації кольорових супутникових зображень розроблену у праці [77]. В цій праці було побудовано та випробувано декілька багатозгорткових ШНМ різної архітектури, і в результаті вибір було зупинено на шестишаровій мережі, що містить три згорткові, один підвибірковий та два повнозв'язні шари. Для машинного навчання та тестування розробленої ШНМ використовувалася база даних, що складається з кількох тисяч супутникових знімків штату Массачусетс (США). Розмір кожного зображення 1500x1500 пікселів з роздільною здатністю 21m на піксель. Для уникнення проблеми перенавчання було реалізовано метод DropOut. Було реалізовано також регуляризацію нейромережі. В результаті розроблений метод забезпечив точність сегментації 85,31%. Можливості глибокого машинного навчання ШНМ в задачі побудови семантично сегментованих карт арктичної рослинності високої роздільної здатності за гіперспектральними супутниковими даними досліджені в праці [93]. При аналізі результатів були використані існуючі карти рослинного покриву областей західного узбережжя Аляски, що містять тундрові та вкриті лісами області. Побудована глибока багатозгорткова ШНМ, яка містила згорткові шари, шари пулінгу та повнозв'язні шари) дозволила ієрархічним чином виробляти із вхідних супутникових зображень ефективні узагальнені ознаки для семантичної класифікації. При цьому були використані мережі-автоенкодера для неконтрольованого стиснення даних. Було також використано шматковий

принцип обробки вхідних зображень (з поділом на фрагменти, що містять 9, 36 та 144 пікселів). В результаті вдалося досягти точності семантичної сегментації для заданого алфавіту із чотирьох класів розпізнавання від 66% до 96%, тобто в середньому 81%. Було зазначено, що для покращення результатів (збільшення точності семантичної сегментації арктичного рослинного покриву) потрібні детальніші гіперспектральні бази даних. Як відомо інформаційний синтез «дуже глибоких» багатозгорткових ШНМ пов'язаний з великими часовими витратами. Одним із шляхів подолання тривалості машинного навчання у завданнях розпізнавання образів та семантичної сегментації виявився метод так званого глибокого залишкового навчання (deep residual learning), запропонований у працях [94, 95]. Метод дозволив підвищити точність семантичної сегментації зображень загалом на 4 – 8%.

Застосування традиційних методів інтелектуального аналізу даних Data Mining, включаючи ШНМ, для інформаційного синтезу БСР для пошуку об'єктів на місцевості не завжди забезпечує успішне розв'язання задачі через такі науково-методологічні обмеження:

- довільні початкові умови формування зображень об'єктів на місцевості, що розпізнаються, обумовлених різними ракурсами аерофотозйомки, висотами літального апарату, положенням і місце з невеликим обсягом заходженням об'єкту;
- перетин класів розпізнавання, що характеризують зображення об'єктів, в просторі ознак розпізнавання;
- багатовимірність словника ознак і алфавіту класів розпізнавання;
- вплив неконтрольованих факторів, пов'язаних, наприклад, із зміною погодних умов, освітленості, маскуванням тощо.

В працях [78–80] розглядається для розпізнавання зображень використання сплайнів (Spline – шматково-поліноміальна функція), які представляють двовимірні геометричні об'єкти, здатні бути основою для побудови складніших тривимірних тіл. Зовні сплайни є різноманітними лініями, форма яких визначається типом вершин, через які вона проходить.

Сплайнами можуть бути як найпростіші геометричні фігури: прямокутники, зірки, еліпси тощо, так і складні ламані чи криві, а також контури текстових символів.

Основними елементами сплайнів є вершини (Vertex) та сегменти (Segment). Вершинами називають точки, розташовані на сплайні, при цьому перша вершина, що позначає початок сплайну, відзначається квадратиком білого кольору. Під сегментом прийнято розуміти ділянку лінії сплайну, обмежену двома сусідніми вершинами, - сегменти можуть бути як прямо-, так і криволінійними відрізками. Вершини сплайну відрізняються за типом, від якого залежить ступінь кривизни прилеглих до цих вершин сегментів сплайну. Усього виділяють чотири типи вершин:

Corner (Кутова) - вершина, в якій сплайн має злам, а сегменти, що примикають до неї, позбавлені кривизни.

Smooth (Згладжена) - вершина, через яку крива сплайну проводиться з плавним вигином, а кривизна прилеглих до вершини сегментів однакова з обох боків.

Bezier (Безьє) - вершина, що нагадує згладжену і відрізняється від неї можливістю управління ступенем кривизни обох сегментів. Останнє здійснюється завдяки наявності у вершині дотичних векторів, обмежених на кінцях маркерами у вигляді квадратиків зеленого кольору та званих ручками Безьє. Переміщуючи ручки Безьє, можна змінювати напрямок, відповідно до якого сегменти сплайну входять у вершину і виходять із неї, а змінюючи відстань від маркерів до вершини – регулювати ступінь кривизни сегментів сплайну. У вершин даного типу ручки Безьє пов'язані між собою, і переміщення однієї з них автоматично викликає переміщення другої.

Bezier Corner (Безтя кутова) — вершина, що має дотичні вектори, що дозволяють керувати ступенем кривизни сегментів, проте, на відміну від вершин Bezier, у вершин Bezier Corner дотичні вектори не пов'язані один з одним і переміщення одного з маркерів не залежить від переміщення іншого.

Відмінною особливістю інтенціональних методів є те, що як елементи операцій при побудові та застосуванні алгоритмів розпізнавання образів вони використовують різні характеристики ознак та їх зв'язків [102–104]. Такими елементами можуть бути окремі значення або інтервали значень ознак, середні величини та дисперсії, матриці зв'язків ознак тощо, над якими виробляються дії, що виражаються в аналітичній або конструктивній формі. При цьому об'єкти в цих методах не розглядаються як цілісні інформаційні одиниці, а виступають у ролі індикаторів для оцінки взаємодії та поведінки своїх атрибутів.

Методи, що ґрунтуються на оцінках щільностей розподілу значень ознак, запозичені з класичної теорії статистичних рішень, у якій об'єкти дослідження розглядаються як реалізації багатовимірної випадкової величини, розподіленої у просторі ознак за будь-яким законом [81–83]. Вони базуються на байєсівській схемі прийняття рішень і зводяться до визначення правдоподібності у різних галузях багатовимірного простору ознак.

Група методів, заснованих на оцінці щільності розподілу значень ознак, має пряме відношення до методів дискримінантного аналізу [84–86]. Байєсовський підхід до прийняття рішень відноситься до найбільш розроблених у сучасній статистиці так званих параметричних методів, для яких вважається відомим аналітичний вираз закону розподілу (в даному випадку нормальний закон) і потрібно оцінити лише невелику кількість параметрів [111–113]. Основними труднощами застосування зазначених методів вважаються необхідність запам'ятовування усієї навчальної вибірки для обчислення оцінок локальних щільностей розподілу ймовірностей та висока чутливість до презентабельності навчальної вибірки.

Досить висока якість вирішального правила може бути досягнуто за допомогою алгоритмів, які не мають суворого математичного доказу збіжності рішення до глобального екстремуму. До таких алгоритмів відноситься велика група процедур евристичного програмування, що представляють напрямок еволюційного моделювання [87–89]. Еволюційне моделювання є біонічним

способом, запозиченим у природи. Воно ґрунтується на використанні відомих механізмів еволюції з метою заміни процесу змістовного моделювання складного об'єкта феноменологічним моделюванням його еволюції. Відомим представником еволюційного моделювання у розпізнаванні образів є метод групового обліку аргументів (МГОА) [90]. В основу МГОА покладено принцип самоорганізації масової селекції. Однак досягненню практичних цілей у даному випадку не супроводжує вилучення нових знань про природу об'єктів, що розпізнаються.

Лінгвістичні методи розпізнавання образів засновані на використанні спеціальних ґраматик, що породжують мови, за допомогою яких може описуватися сукупність властивостей об'єктів, що розпізнаються [91]. Для різних класів об'єктів виділяються непохідні (атомарні) елементи (подоби, ознаки) та можливі відносини між ними. Ґраматикою називають правила побудови об'єктів із цих непохідних елементів. Шляхом синтаксичного аналізу (ґраматичного аналізу) «пропозиції» визначається його синтаксична «правильність» або, що еквівалентно, чи може деяка фіксована ґраматика, що описує клас, породити наявний опис об'єкта. Проте завдання відновлення (визначення) ґраматик за деякою множиною висловлювань (пропозицій - описів об'єктів), що породжують цю мову, є формалізованою.

Переважаюча кількість методів розпізнавання зображень для вирішення завдань дискримінантного аналізу базується на методі К-найближчих сусідів [92]. Метод полягає у наступному. При класифікації невідомого об'єкта знаходиться задане число геометрично найближчих до нього в просторі ознак інших об'єктів (К найближчих сусідів) з вже відомою належністю до класів, що розпізнаються. Рішення про віднесення невідомого об'єкта до того чи іншого класу розпізнавання приймається шляхом аналізу інформації про цю відому приналежність його найближчих сусідів, наприклад, за допомогою простого підрахунку голосів. З використанням методу К-найближчих сусідів для розпізнавання образів досліднику доводиться вирішувати складну проблему вибору метрики визначення близькості класів розпізнавання. Ця

проблема за умов високої розмірності простору ознак надзвичайно загострюється внаслідок достатньої трудомісткості даного методу, що стає значимою навіть для високопродуктивних комп'ютерів. Тому тут так само, як і в методі порівняння з прототипом, необхідно вирішувати творчу задачу аналізу багатовимірної структури експериментальних даних для мінімізації потужності алфавіту класів розпізнавання. Необхідність зменшення кількості об'єктів у навчальній вибірці є недоліком даного методу, оскільки зменшує представництво навчальної вибірки.

Аналітичний огляд методів застосування інтелектуальних технологій інформаційного синтезу БСР показує, що найбільш поширеними на практиці є дескрипторні методи, здатні виділяти контури наземних об'єктів [93]. Основним недоліком такого підходу є недостатня інформативність ознак розпізнавання, оскільки не враховуються локальні особливості конструкції та зовнішні характеристики наземного об'єкту. Такий саме недолік притаманний методам виявлення особливих точок на цифрових зображеннях наземних об'єктів розпізнавання [94]). Тому перспективним з точки зору інформативності ознак розпізнавання є детектування, основане на скануванні всього зображення наземного об'єкту. З цією метою при аналізі даних крім традиційних методів сканування широко використовуються методи вейвлет-перетворень [95]. Вейвлет-перетворення і використовуються як для аналізу сигналів, так і зображень. Оскільки вони характеризуються високою обчислювальною складністю, то при аналізі зображень слід перевагу віддавати швидким Фур'є-перетворенням. Практична цінність сперектральних методів аналізу даних полягає у залученні додаткових інформативних ознак розпізнавання при поєднанні з методами прямого сканування зображень. Але при цьому варто приймати до уваги, що при функціонуванні автономної БСР в робочому режимі існують жорсткі вимоги щодо забезпечення високої оперативності формування структурованого вектору ознак розпізнавання наземного об'єкту.

Таким чином, відомі результати досліджень по розпізнаванню наземних об'єктів через науково-методологічні ускладнення носять в основному модельний характер, що обумовило на практиці необхідність використання безпілотних авіаційних комплексів для розв'язання цієї задачі в інтерактивному режимі, тобто за участі людини-оператора.

Одним з перспективних підходів до аналізу та синтезу БСР об'єктів на місцевості є використання ідей та методів вітчизняної так званої інформаційно-екстремальної інтелектуальної технології (ІЕІТ), яка ґрунтується на максимізації інформаційної спроможності системи в процесі її машинного навчання, розробленої науковою школою професора Довбиша А.С. в Сумському державному університеті. Методи машинного навчання в рамках ІЕІТ відносяться до класу радіально базисних методів побудови роздільних гіперповерхонь класів розпізнавання.

Основна ідея методів інтелектуального аналізу даних в рамках ІЕІТ, як і в ШНМ, полягає в адаптації в процесі машинного навчання вхідного математичного опису до максимальної повної ймовірності прийняття правильних класифікаційних рішень. Але основна перевага методів інформаційно-екстремального машинного навчання полягає в тому, що вони на відміну від нейроподібних структур розробляються в рамках функціонального підходу до моделювання когнітивних процесів, притаманних людині при формуванні та прийнятті класифікаційних рішень, тобто безпосередньо моделюють природний механізм прийняття рішень. Такий підхід на відміну від структурних методів дозволяє методам інформаційно-екстремального машинного навчання надати гнучкість при перенавчанні системи через розширення алфавіту класів розпізнавання. Крім того, побудова в рамках геометричного підходу вирішальних правил практично вирішує проблему багатовимірності словника ознак розпізнавання, оскільки сучасні комп'ютери здатні обробляти структуровані вектори, які складаються з 2^{85} ознак розпізнавання.

Побудова високо достовірних вирішальних правил в рамках ІЕІТ здійснюється за багатоциклічною процедурою пошуку максимального усередненого за алфавітом $\{X_m^o \mid m = \overline{1, M}\}$ класів розпізнавання інформаційного критерію оптимізації параметрів машинного навчання, яка для машинного навчання з глибиною ξ -го рівня має вигляд [20]

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_1 \cap G_E} \frac{1}{M} \sum_{m=1}^M E_m \} \dots \} \}, \quad (1.1)$$

де E_m – інформаційний критерій оптимізації параметрів машинного навчання системи розпізнавати структуровані вектори ознак класу розпізнавання $\{X_m^o\}$;

G_{ξ} – допустима область значень ξ -го параметра машинного навчання;

G_E – робоча (допустима) область визначення функції інформаційного критерію.

У процедурі (1.1) внутрішній цикл реалізує так званий базовий алгоритм, призначенням якого є:

1) обчислення на кожному кроці машинного навчання інформаційного критерію і пошук глобального максимуму його функції;

2) визначення оптимальних геометричних параметрів контейнерів класів розпізнавання, які відновлюються в радіальному базисі простору ознак.

Для оцінки функціональної ефективності машинного навчання системи розпізнавання найбільше використовуються ентропійний критерій Шеннона та інформаційна міра Кульбака. У праці авторів проекту [25] для двохальтернативної системи оцінок рішень запропонована модифікована міра Кульбака у вигляді

$$E_m^{(k)} = \log_2 \left(\frac{2 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) * [1 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))] \quad (1.2)$$

де $\alpha_m^{(k)}(d)$ – помилка першого роду при прийнятті рішень на k -му кроці машинного навчання;

$\beta_m^{(k)}(d)$ – помилка другого роду;

d – дистанційна міра, яка визначає радіуси гіперсферичних контейнерів класів розпізнавання, побудованих в радіальному базисі Геммінгового простору ознак розпізнавання.

Нормована модифікація критерію (1.2) має вигляд

$$E_{Km}^{(k)} = \frac{E_m^{(k)}}{E_{\max}^{(k)}}, \quad (1.3)$$

де $E_{\max}^{(k)}$ – значення інформаційного критерію, яке він приймає при підстановках у формулу (1.2) точнісних характеристик

$$D_{1,m}^{(k)}(d) = D_{2,m}^{(k)}(d) = 1 \quad \text{і} \quad \alpha_m^{(k)}(d) = \beta_m^{(k)}(d) = 0.$$

Оскільки інформаційний критерій є функціоналом від точнісних характеристик, то при репрезентативному, але обмеженому обсязі навчальної вибірки користуються їх оцінками:

$$\alpha_m^{(k)}(d) = \frac{K_{1m}^{(k)}}{n_{\min}}; \quad \beta_m^{(k)}(d) = \frac{K_{2m}^{(k)}}{n_{\min}}, \quad (1.4)$$

де $K_{1,m}^{(k)}$ – кількість подій, при яких реалізації, що належать класу X_m^o , помилково до нього не відносяться;

$K_{3,m}^{(k)}$ – кількість подій, при яких помилково відносяться до класу розпізнавання X_m^o реалізації сусіднього класу розпізнавання X_c^o ;

n_{\min} – мінімальний обсяг навчальної вибірки, який визначається згідно з працею авторів проєкту [6].

Після підстановки оцінок точнісних характеристик (1.4) у вираз (1.2) одержимо робочу формулу для обчислення модифікованого критерію Кульбака [25]:

$$E_m^{(k)} = \frac{1}{n_{\min}} \log_2 \left\{ \frac{2n_{\min} + 10^{-r} - [K_1^{(k)} + K_2^{(k)}]}{[K_1^{(k)} + K_2^{(k)}] + 10^{-r}} \right\} \left[n - (K_{12}^{(k)} + K_3^{(k)}) \right], \quad (1.5)$$

де 10^{-r} – достатньо мале число, що вводиться для уникнення поділу на нуль.

Обчислення змінних $K_{1,m}^{(k)}$ і $K_{2,m}^{(k)}$ здійснюється відповідно за процедурами

$$\begin{aligned} \text{if } x_m^{(j)} \notin X_m^o \text{ then } K_1(j) &:= K_1(j-1) + 1; \\ \text{if } x_c^{(j)} \in X_m^o \text{ then } K_3(j) &:= K_3(j-1) + 1 \end{aligned}$$

При цьому віднесення, наприклад, реалізації $x^{(j)}$ до класу розпізнавання X_m^o здійснюється за алгоритмом:

$$1) \text{ обчислюється кодова відстань Хеммінга } d[x_m \oplus x^{(j)}];$$

2) якщо $d[x_m \oplus x^{(j)}] \leq d_m$, то $x^{(j)} \in X_m^o$, інакше – $x^{(j)} \notin X_m^o$;

Аналіз інформаційних критеріїв (1.2) і (1.3) показує, що вони є функціоналами від точнісних характеристик класифікаційних рішень, які в свою чергу залежать від дистанційних критеріїв. Тобто вище наведені модифікації критерію Кульбака можна розглядати як узагальнення відомих статистичних і дистанційних критеріїв близькості класів розпізнавання. Тоді як критерій схожості може розглядатися вираз

$$C = 1 - E_{K m}^{(k)}$$

Таким чином, з точки зору логіко-гносологічного аспекту розглянуті інформаційні критерії є мірами різноманітності об'єктів, що обґрунтовує доцільність застосування для розв'язання задач теорії розпізнавання образів саме теоретико-інформаційного підходу. Тому застосування ідей і методів ІЕІТ є перспективним напрямом інформаційного синтезу автономної БСР на основі машинного навчання.

2 ОПИС МЕТОДУ ДОСЛІДЖЕНЬ

2.1 Основні принципи та положення інформаційно-екстремальної інтелектуальної технології аналізу даних

Згідно з працями авторів НТР [21, 22, 25] основна ідея машинного навчання в рамках ІЕІ-технології аналізу даних полягає в трансформації апріорного у загальному випадку нечіткого розбиття простору ознак у чітке розбиття класів розпізнавання способом оптимізації параметрів функціонування системи. Водночас здійснюється цілеспрямований пошук глобального максимуму багато екстремальної функції статистичного інформаційного критерію в робочій (допустимій) області її визначення з одночасним відновленням оптимальних роздільних гіперповерхонь, що відновлюються в радіальному базисі бінарного простору ознак розпізнавання.

Методи інформаційно-екстремального машинного навчання базуються, крім відомих принципів системного аналізу, на таких специфічних принципах:

- максимізації інформації, обґрунтованому екстремальністю сенсорного сприйняття образу, що експериментально доведено вченими-фізіологами. Цей принцип реалізують способом уведення додаткових інформаційних обмежень, що збільшують різноманітність класифікованих об'єктів;

- дуальності, що полягає в реалізації на етапі апріорного моделювання простих алгоритмів за умови їх цілеспрямованого уточнення способом поглиблення машинного навчання для наближення вирішальних правил до безпомилкових за навчальною матрицею;

- апріорної недостатності обґрунтування гіпотез (принцип Бернуллі – Лапласа), згідно з яким за умов апріорної невизначеності даних доцільно розглядати апріорні гіпотези однаково ймовірними, тобто рішення приймаються системою за найгірших у статистичному розумінні умов;

- рандомізації вхідних даних, що дозволяє досліджувати детерміновано-статистичні характеристики процесу;

– редукції даних, що обумовлює необхідність оптимізації в інформаційному розумінні словника ознак розпізнавання способом видалення з нього неінформативних та ознак, які заважають;

- відкладених рішень О. Г. Івахненка, що полягає в необхідності повторення процедур машинного навчання для досягнення мети побудови безпомилкових за навчальною матрицею вирішальних правил;

– зовішнього доповнення, що обґрунтовує необхідність використання навчальної або контрольної (екзаменаційної) вибірки для оцінювання функціональної ефективності машинного навчання

Вирішальні правила в процесі оптимізації параметрів машинного навчання в рамках ІЕІ-технології будують згідно з принципом відкладених рішень Івахненка О. Г. за багатоциклічною ітераційною процедурою пошуку максимального граничного значення усередненого за алфавітом класів розпізнавання інформаційного критерію оптимізації [25]:

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_1 \cap G_E} \frac{1}{M} \sum_{m=1}^M E_m \} \dots \} \}, \quad (2.1)$$

де E_m – інформаційний критерій оптимізації параметрів навчання системи розпізнавати реалізації класу X_m^o ;

G_{ξ} – допустима область значень ξ -ї ознаки розпізнавання;

G_E – допустима область визначення функції інформаційного критерію оптимізації параметрів машинного навчання.

Водночас на алгоритм інформаційно-екстремального машинного навчання (2.1) накладаються обмеження:

$$(\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}) [X_m^o \neq \emptyset], \quad (2.2)$$

де $\tilde{\mathfrak{R}}^{|M|}$ – розбиття простору ознак на класи розпізнавання, потужність якого дорівнює $Card \tilde{\mathfrak{R}} = M$;

$$(\exists X_k^o \in \tilde{\mathfrak{R}}^{|M|})(\exists X_l^o \in \tilde{\mathfrak{R}}^{|M|})[X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset]; \quad (2.3)$$

$$(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|})(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|})[X_k^o \neq X_l^o \rightarrow KerX_k^o \cap KerX_l^o \neq \emptyset], \quad (2.4)$$

де $KerX_k^o$ – ядро класу розпізнавання X_k^o ;

$Ker X_l^o$ – ядро класу розпізнавання нижчого до класу розпізнавання X_k^o

$$(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|})(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) \left[\begin{array}{l} X_k^o \neq X_l^o \rightarrow [(d_k^* < d(x_k \oplus x_l)) \&] \\ \& (d_l^* < d(x_k \oplus x_l)) \end{array} \right], \quad (2.5)$$

де d_l^* – оптимальний радіус контейнера класу розпізнавання X_l^o ;

$d(x_k \oplus x_l)$ – кодова відстань між вектором x_k , усередненим за ансамблем векторів ознак класу розпізнавання X_k^o , і відповідним вектором x_l класу розпізнавання X_l^o ;

$$\bigcup_{X_m^o \in \tilde{\mathfrak{R}}} X_m^o \subseteq \Omega_B, \quad (2.6)$$

де Ω_B – бінарний простір Геммінга.

У виразах (2.2) – (2.6) прийнято $k \neq l$ і $k, l, m = \overline{1, M}$.

Глибина інформаційно-екстремального машинного навчання характеризується кількістю параметрів функціонування системи, що оптимізуються за інформаційним критерієм.

Основна ідея машинного навчання методами ІЕІ-технології, так само як і у ШНМ – адаптація вхідного математичного опису системи розпізнавання до максимальної повної ймовірності класифікаційних рішень. Принципова відмінність методів інформаційно-екстремального машинного навчання від нейроподібних структур полягає в тому, що їх розробляють у рамках функціонального підходу до моделювання когнітивних процесів, притаманних людині під час формування та прийняття класифікаційних рішень, тобто вони безпосередньо моделюють механізм природного інтелекту. Водночас процес машинного навчання розглядають як оптимізацію параметрів системи розпізнавання, що впливають на її функціональну ефективність. Такі параметри називають параметрами машинного навчання. Як критерій оптимізації в методах ІЕІ-технології можна використовувати будь-яку статистичну інформаційну міру різноманітності аналізованих об'єктів. Якщо в ШНМ глибина машинного навчання обумовлена кількістю прихованих шарів, то в методах ІЕІ-технології її визначають за кількістю параметрів машинного навчання, що оптимізуються. Водночас достатню глибину інформаційно-екстремального машинного навчання визначають згідно з принципом відкладених рішень О. Г. Івахненка за умови досягнення граничного максимального значення усередненого за алфавітом класів розпізнавання інформаційного критерію оптимізації. Вирішальні правила будують за одержаними в процесі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання, що відновлюються в радіальному базисі бінарного простору ознак Геммінга. Побудова вирішальних правил у рамках геометричного підходу робить їх майже інваріантними до багатовимірності простору ознак розпізнавання, тому що сучасні комп'ютерні комплекси можуть обробляти двійкові вектори, що містять 2^{85} ознак розпізнавання. Крім того, такі вирішальні правила характеризуються високою оперативністю прийняття класифікаційних рішень у разі функціонування автономної БСВН в робочому режимі, що є важливим фактором для детектування наземних навігаційних орієнтирів.

Отже, використання ідей і застосування методі ІЕІ-технології відкриває широкі перспективи для вирішення проблеми інформаційного синтезу здатної навчатися автономної БСВН як складової комплексної БСН.

2.2 Основні властивості автономної бортової системи відеонавігації, що навчається

Розглянемо основні властивості БСВН, здатної функціонувати в режимах машинного навчання та розпізнавання образів.

1. Функціональна ефективність – це властивість, що характеризує здатність БСВН виконувати поставлене перед нею основне завдання.

2. Функціональна стійкість до кіберзагроз – це властивість БСВН повертатися до попереднього робочого функціонального стану після припинення дії збурюючих факторів, зокрема у вигляді атак або несанкціонованих дій.

3. Керованість – це існування необмеженого керування, що може перевести БСВН із довільного початкового функціонального стану в будь-який інший заданий стан за кінцевий інтервал часу.

4. Спостережуваність – це можливість визначення поточного функціонального стану БСВН шляхом аналізу вхідної, робочої та вихідної інформації за час виконання польотного завдання. З точки зору теоретико-інформаційного підходу умовою спостережуваності БСВН є наявність умовної кількості інформації, яку вона одержує, аналізує і передає, тобто повинна виконуватися нерівність

$$I = H - H(\gamma) > 0,$$

або

$$0 < I \leq H,$$

де H – апіорна (безумовна) ентропія, що характеризує невизначеність даних на вході БСВН і визначається за формулою

$$H = -\sum_{l=1}^M p(\gamma_l) \log_2 p(\gamma_l), \quad (2.7)$$

де $p(\gamma_l)$ – безумовна ймовірність прийняття гіпотези γ_l ;

M - кількість гіпотез;

$H(\gamma)$ – апостеріорна ентропія, що характеризує залишкову невизначеність після прийняття БСВН класифікаційного рішення і визначається як

$$H(\gamma) = -\sum_{l=1}^M \sum_{m=1}^M p(\gamma_l) p(\mu_m / \gamma_l) \log_2 p(\mu_m / \gamma_l), \quad (2.8)$$

де $p(\mu_m / \gamma_l)$ – апостеріорна умовна ймовірність прийняття рішення μ_m за умови, що прийнята гіпотеза γ_l .

Система може втратити спостережуваність як за умови впливу зовнішніх, наприклад, погодних умов, наслідків кібератаки тощо, так і внутрішніх збурюючих факторів. Прикладом внутрішнього фактору може бути випадок невинного збільшення або зменшення поля контрольних допусків на ознаки розпізнавання, що має наслідком збіг структурованих векторів ознак різних класів розпізнавання, які характеризують відповідні наземні навігаційні орієнтири. Тобто спостережуваність БСВН можна трактувати як властивість системи розрізняти класи розпізнавання.

5. Інформаційна спроможність, що визначається кількісними інформаційними характеристиками БСВН.

6. Точність, що визначається через точнісні характеристики відповідної системи оцінювань рішень. Наприклад, для двохальтернативної системи оцінювань достовірність БСВН характеризується повною ймовірністю правильного прийняття класифікаційних рішень:

$$P_t = p_1 D_1 + p_2 D_2,$$

- де p_1 – безумовна ймовірність прийняття основної гіпотези γ_1 ;
 p_2 – безумовна ймовірність прийняття альтернативної гіпотези γ_2 ;
 D_1 – перша достовірність;
 D_2 – друга достовірність;

і повною ймовірністю неправильного прийняття класифікаційних рішень:

$$P_f = p_1 \alpha + p_2 \beta,$$

- де α – помилка першого роду;
 β – помилка другого роду.

Оскільки гіпотези γ_1 і γ_2 складають повну групу подій, то має місце

$$P_t + P_f = 1.$$

7. Надійність БСВН. Це властивість системи забезпечувати виконання заданих функцій, зберігаючи в часі функціональну ефективність системи в заданих межах.

8. Стабільність БСВН Це властивість системи зберігати незмінними свої характеристики в процесі експлуатації.

9. Енерговитрати, пов'язані з функціонуванням БСВН.

10. Вартість як сукупні витрати на всіх етапах життєвого циклу системи.

Зрозуміло, що властивості БСВН не обмежуються вищенаведеними, оскільки теорія проектування систем цього класу перебуває в стані неспинного розвитку.

2.3 Інформаційні критерії оптимізації параметрів машинного навчання

Центральним питанням інформаційного синтезу здатної навчатися автономної БСВН є оцінювання функціональної ефективності процесу машинного навчання, основними критеріями якої є достовірність та оперативність класифікаційних рішень. Як критерії оптимізації параметрів машинного навчання в методах ІЕІ-технології можуть використовуватися різні критерії, що задовольняють таким властивостям інформаційної міри:

- інформаційна міра є дійсна і знакододатна функція від імовірності;
- кількість інформації для детермінованих подій ($p_i = 1$ або $p_i = 0$) дорівнює нулю;
- інформаційна міра має екстремум за значення ймовірності $p_i = \frac{1}{m}$, де m – кількість якісних ознак розпізнавання;
- сумісна інформаційна міра двох незалежних повідомлень дорівнює сумі їх відповідних інформаційних мір.

Серед інформаційних мір для оцінювання функціональної ефективності БСВН, що навчається, перевагу варто віддавати статистичним логарифмічним критеріям, що дозволяють працювати з порівняно малими навчальними вибірками. Серед таких критеріїв найчастіше використовувані ентропійні міри Шеннона та інформаційна міра Кульбака [20, 21, 25].

Подамо нормований ентропійний критерій оптимізації параметрів машинного навчання системи розпізнавати реалізації класу X_m^o як [6]:

$$E_m^{(k)} = \frac{I_m^{(k)}}{I_{\max}^{(k)}} = \frac{H_m - H_m^{(k)}(\gamma)}{H_m}, \quad (2.11)$$

де $I_m^{(k)}$ – кількість умовної інформації, оброблюваної на k -му кроці машинного навчання системи розпізнавати вектори ознак класу X_m^o ;

$I_{\max}^{(k)}$ – максимальна кількість умовної інформації, одержаної на k -му кроці машинного навчання;

$$H_m = - \sum_{l=1}^M p(\gamma_{l,k}) \log_2 p(\gamma_{l,k}) - \quad (2.12)$$

апостеріорна (безумовна) ентропія щодо розпізнавання векторів ознак класу X_m^o , яка існує на вході БСВН,

$$H_m^{(k)} = - \sum_{l=1}^M \sum_{m=1}^M p(\gamma_l) p^{(k)}(\mu_m / \gamma_l) \log_2 p^{(k)}(\mu_m / \gamma_l) - \quad (2.13)$$

апостеріорна (умовна) ентропія, що характеризує залишкову невизначеність після k -го кроку навчання системи розпізнавати реалізації класу X_m^o ;

$p(\gamma_l)$ – безумовна ймовірність прийняття гіпотези γ_l ;

$p^{(k)}(\mu_m / \gamma_l)$ – апостеріорна ймовірність прийняття на k -му кроці машинного навчання рішення μ_m за умови, що прийнята гіпотеза γ_l .

Для двохальтернативної системи оцінювань ($M=2$) і рівноймовірних гіпотез, що характеризує згідно з принципом Бернуллі – Лапласа найбільш важкий у статистичному розумінні випадок прийняття рішень, після відповідної підстановки ентропій (2.12) і (2.13) у вираз (2.11) та заміни за формулою Байєса відповідних апостеріорних ймовірностей на апостеріорні критерій набирає вигляду

$$E_m^{(k)} = 1 + \frac{1}{2} \left(\frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} + \right.$$

$$\begin{aligned}
& + \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \\
& + \frac{D_{1,m}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{D_{1,m}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \\
& \left. + \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \right), \quad (2.14)
\end{aligned}$$

де $\alpha_m^{(k)}(d)$ – помилка першого роду прийняття рішення на k -му кроці машинного навчання;

$\beta_m^{(k)}(d)$ – помилка другого роду;

$D_{1,m}^{(k)}(d)$ – перша достовірність;

$D_{2,m}^{(k)}(d)$ – друга достовірність;

d – дистанційна міра, яка визначає радіуси гіперсферичних контейнерів класів розпізнавання, побудованих в радіальному базисі бінарного простору Геммінга.

Оскільки точнісні характеристики є функціями відстані роздільної гіперповерхні від геометричних центрів контейнерів відповідних класів розпізнавання, то критерій (2.14) потрібно розглядати як нелінійний і взаємно-неоднозначний функціонал від точнісних характеристик, що потребує перебування в процесі машинного навчання робочої (допустимої) області його визначення.

Розглянемо процедуру обчислення в практичних задачах критерію (2.14). Оскільки інформаційний критерій є функціоналом від точнісних характеристик, то за репрезентативного обсягу навчальної вибірки необхідно користуватися їх оцінками:

$$D_{1,m}^{(k)}(d) = \frac{K_{1,m}^{(k)}(d)}{n_{\min}}; \quad \alpha_m^{(k)}(d) = \frac{K_{2,m}^{(k)}(d)}{n_{\min}};$$

$$\beta_m^{(k)}(d) = \frac{K_{3,m}^{(k)}(d)}{n_{\min}}; D_{2,m}^{(k)}(d) = \frac{K_{4,m}^{(k)}(d)}{n_{\min}}, \quad (2.15)$$

де $K_{1,m}^{(k)}(d)$ – кількість подій, які означають належність “своїх” реалізацій класу розпізнавання X_m^o ;

$K_{2,m}^{(k)}(d)$ – кількість подій, які означають неналежність “своїх” реалізацій класу розпізнавання X_m^o ;

$K_{3,m}^{(k)}(d)$ – кількість подій, які означають належність “чужих” реалізацій класу розпізнавання X_m^o ;

$K_{4,m}^{(k)}(d)$ – кількість подій, які означають неналежність “чужих” реалізацій класу розпізнавання X_m^o ;

n_{\min} – мінімальний обсяг репрезентативної навчальної вибірки, який визначається за методом, запропонованим у праці [11].

Після підставлення відповідних позначень (2.15) у вираз (2.14) одержимо робочу формулу для обчислення в рамках ІЕІ-технології ентропійного критерію оптимізації параметрів машинного навчання системи розпізнавати структуровані вектори ознак класу X_m^o :

$$E_m^{(k)} = 1 + \frac{1}{2} \left(\frac{K_{1,m}^{(k)}(d)}{K_{1,m}^{(k)}(d) + K_{3,m}^{(k)}(d)} \log_2 \frac{K_{1,m}^{(k)}(d)}{K_{1,m}^{(k)}(d) + K_{3,m}^{(k)}(d)} + \frac{K_{2,m}^{(k)}(d)}{K_{2,m}^{(k)}(d) + K_{4,m}^{(k)}(d)} \log_2 \frac{K_{2,m}^{(k)}(d)}{K_{2,m}^{(k)}(d) + K_{4,m}^{(k)}(d)} + \frac{K_{3,m}^{(k)}(d)}{K_{1,m}^{(k)}(d) + K_{3,m}^{(k)}(d)} \log_2 \frac{K_{3,m}^{(k)}(d)}{K_{1,m}^{(k)}(d) + K_{3,m}^{(k)}(d)} + \frac{K_{4,m}^{(k)}(d)}{K_{2,m}^{(k)}(d) + K_{4,m}^{(k)}(d)} \log_2 \frac{K_{4,m}^{(k)}(d)}{K_{2,m}^{(k)}(d) + K_{4,m}^{(k)}(d)} \right). \quad (2.16)$$

У праці авторів проєкту [1] запропоновано модифікацію диференціальної інформаційної міри Кульбака, яка подається як добуток відношення правдоподібності на міру відхилень відповідних розподілів імовірностей. Для двохальтернативних апріорно рівноймовірних рішень модифікований критерій Кульбака, який обчислюється на k -му кроці машинного навчання системи розпізнавати реалізації класу X_m^o , має вигляд

$$E_m^{(k)} = \log_2 \left(\frac{2 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) * [1 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))]. \quad (2.17)$$

Нормована форма критерію (2.17) має вигляд [6]

$$E_{K,m}^{(k)} = \frac{E_{K,m}^{(k)}}{E_{K \max}^{(k)}}, \quad (2.18)$$

де $E_{K \max}^{(k)}$ – значення інформаційного критерію (2.17) при

$$D_{1,m}^{(k)}(d) = D_{2,m}^{(k)}(d) = 1; \quad \alpha_m^{(k)}(d) = \beta_m^{(k)}(d) = 0.$$

Робоча модифікація критерію (2.17) після відповідного підставлення оцінок (2.15) набуває вигляду

$$E_m^{(k)} = \frac{\lfloor n - (K_{2,m}^{(k)}(d) + K_{3,m}^{(k)}(d)) \rfloor *}{n} * \log_2 \left\{ \frac{2n + 10^{-r} - [K_{2,m}^{(k)}(d) + K_{3,m}^{(k)}(d)]}{[K_{2,m}^{(k)}(d) + K_{3,m}^{(k)}(d)] + 10^{-r}} \right\}, \quad (2.19)$$

де 10^{-r} – достатньо мале число, яке вводиться для уникнення поділу на нуль.

Розглянемо схему обчислення змінних $K_1^{(k)} - K_4^{(k)}$. На рисунку 2.1 показано структуру навчальної матриці під час побудові оптимального контейнера класу розпізнавання X_1^o . Навчальна матриця складається з векторів реалізацій двох найближчих сусідніх класів розпізнавання: $\{x_1^{(j)}\} \in X_1^o$ і $\{x_2^{(j)}\} \in X_2^o$.




Рисунок 2.1 – Структура навчальної матриці найближчих сусідніх класів розпізнавання

Схема обчислення змінних $K_1^{(k)} - K_4^{(k)}$ має вигляді:

$$(\forall X_1^o \in \mathfrak{R}^{|\Lambda|}) (\forall X_2^o \in \mathfrak{R}^{|\Lambda|}) [\text{if } x_1^{(j)} \in X_1 \text{ then} \\ K_1(j) := K_1(j-1) + 1 \text{ else } K_2(j-1) + 1],$$

$$(\forall X_1^o \in \mathfrak{R}^{|\Lambda|}) (\forall X_2^o \in \mathfrak{R}^{|\Lambda|}) [\text{if } x_2^{(j)} \in X_1 \text{ then}$$

$$K_3(j) := K_3(j-1) + 1 \text{ else } K_4(j) := K_4(j-1) + 1].$$

Водночас визначення належності, наприклад, вектору $x_m^{(j)}$ до свого класу здійснюється за таким правилом

1) обчислюється кодова відстань $d[x_m \oplus x_m^{(j)}]$;

2) якщо $d[x_m \oplus x_m^{(j)}] \leq d_m$, то $x_m^{(j)} \in X_m^o$, інакше – $x_m^{(j)} \notin X_m^o$.

Таким чином, інформаційні критерії (2.14) і (2.17) є функціоналами як від точнісних характеристик класифікаційних рішень, так і від дистанційних критеріїв, що дозволяє їх вважати загальними критеріями валідності

машинного навчання, оскільки вони є узагальненням відомих статистичних і детермінованих (дистанційних) критеріїв близькості.

2.4 Базовий алгоритм інформаційно-екстремального машинного навчання автономної бортової системи відеонавігації

Базовий інформаційно-екстремальний алгоритм оптимізації просторово-часових параметрів функціонування автономної БСВН реалізується у внутрішньому циклі процедури машинного навчання (3.1), що й обумовило його назву. Призначенням базового алгоритму навчання є:

- оптимізація геометричних параметрів контейнерів класів розпізнавання;
- обчислення інформаційного критерію оптимізації параметрів машинного навчання системи;
- пошук глобального максимуму інформаційного критерію в робочій (допустимій) області визначення його функції.

Категорійну модель інформаційно-екстремального машинного навчання БСВН за базовим алгоритмом подамо у вигляді спрямованого графа відображення операторами одна на одну відповідних множин, які застосовуються в процесі навчання. Вхідний математичний опис здатної навчатися БСВН подамо у вигляді структури

$$I_{\text{ex}} = \langle G, T, \Omega, Z, Y, X; f_1, f_2 \rangle, \quad (2.20)$$

де G – простір вхідних сигналів (факторів);

T – множина моментів часу зняття інформації;

Ω – простір ознак розпізнавання;

Z – простір можливих функціональних станів БСВН;

Y – вхідна навчальна матриця;

X – робоча бінарна навчальна матриця, яка в процесі інформаційно-екстремального машинного навчання адаптується до максимальної повної ймовірності прийняття правильних діагностичних рішень;

f_1 – оператор формування вхідної навчальної матриці Y із джерела інформації, яке задається декартовим добутком $G \times T \times \Omega \times Z$;

f_2 – оператор перетворення вхідної навчальної матриці Y в робочу бінарну навчальну матрицю X .

Функціональну категорійну модель інформаційно-екстремального машинного навчання автономної БСВН за базовим алгоритмом показано на рисунку 2.2.




Рисунок 2.2 – Функціональна категорійна модель машинного навчання за базовим алгоритмом

На рисунку 2.2 терм-множина E , яка складається із обчислених на кожному кроці машинного навчання значень інформаційного критерію, є загальною для всіх контурів оптимізації параметрів. Оператор $r : E \rightarrow \tilde{\mathfrak{R}}^{|M|}$ в процесі машинного навчання відновлює в радіальному базисі простору ознак контейнери класів розпізнавання, які утворюють розбиття $\tilde{\mathfrak{R}}^{|M|}$. Оператор θ відображає розбиття $\tilde{\mathfrak{R}}^{|M|}$ на нечіткий розподіл апріорно класифікованих двійкових векторів ознак класів розпізнавання. Далі оператор $\psi : X \rightarrow I^{|S|}$, де $I^{|S|}$ – множина гіпотез, перевіряє основну статистичну гіпотезу $\gamma_1 : x_m^{(j)} \in X_m^o$. Оператор γ визначає множину точнісних характеристик $\mathfrak{S}^{|\mathcal{Q}|}$, де $\mathcal{Q} = S^2$, а

оператор φ обчислює множину значень E інформаційного критерію оптимізації, якій є функціоналом від точнісних характеристик. Контур оптимізації контрольних допусків замикається через терм-множину D , елементами якої є значення контрольних допусків на ознаки розпізнавання. Оператор u регламентує процес машинного навчання.

Згідно з принципом відкладених рішень О. Г. Івахненка для максимізації інформаційної спроможності системи може бути необхідною оптимізація інших параметрів, які впливають на функціональну ефективність машинного навчання. У цьому разі категорійна модель буде мати додаткові контури оптимізації цих параметрів. Крім того, згідно з принципом повної композиції контури оптимізації повинні мати загальну терм-множину E , елементи якої обчислюються на кожному кроці машинного навчання.

Вхідною інформацією для навчання за базовим алгоритмом є тривимірний масив реалізацій класів розпізнавання $\{y_{m,i}^{(j)} \mid m = \overline{1, M}; i = \overline{1, N}; j = \overline{1, n}\}$; значення параметра поля контрольних допусків δ на ознаки розпізнавання і рівні селекції (квантування) $\{\rho_m\}$ координат усереднених двійкових векторів ознак класів розпізнавання, які за замовчуванням дорівнюють 0,5 для всіх класів розпізнавання. За базовий беруть клас розпізнавання X_1^o , який характеризує максимальну функціональну ефективність автономної БСВН і стосовно якого визначаються контрольні допуски.

У праці авторів [6] розглянуто етапи реалізації базового алгоритму інформаційно-екстремального машинного навчання:

1. Обчислюється для навчальної матриці класу розпізнавання X_1^o усереднений вектор ознак $\{y_{1,i} \mid i = \overline{1, N}\}$.
2. Формується масив $\{x_{1,i}^{(j)}\}$ двійкових векторів ознак класу розпізнавання X_1^o за правилом

$$x_1^{(j)} = \begin{cases} 1, & \text{if } y_{1,i} - \delta \leq y_{1,i}^{(j)} \leq y_{1,i} + \delta, \\ 0, & \text{if else.} \end{cases} \quad (2.21)$$

3. Формується масив усереднених двійкових векторів-реалізацій $\{x_{m,i} \mid m = \overline{1, M}, i = \overline{1, N}\}$, елементи яких визначаються за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m, \\ 0, & \text{if else,} \end{cases}$$

де ρ_m – рівень селекції координат двійкового вектора $x_m \in X_m^o$.

4. Розбиття множини усереднених векторів ознак на пари найближчих «сусідів» $\mathfrak{R}_m^{[2]} = \langle x_m, x_l \rangle$, де x_l – усереднений вектор ознак сусіднього класу X_l^o , за такою схемою:

а) структурують множину векторів $\{x_m\}$, починаючи з вектора x_1 базового класу X_1^o ;

б) будують матрицю розмірності $M \times M$ кодових відстаней між усередненими векторами ознак усіх класів розпізнавання;

в) для кожного рядка матриці кодових відстаней обчислюють мінімальний елемент, який належить стовпчику вектора, найближчого до вектора, що визначає рядок. За наявності декількох однакових мінімальних елементів вибирають з них будь-який, оскільки вони є рівноправними;

г) формують структуровану множину елементів попарного розбиття $\{\mathfrak{R}_m^{[2]} \mid m = \overline{1, M}\}$, яка задає план машинного навчання.

5. Здійснюють оптимізацію кодової відстані d_m , яка змінюється за заданим законом. У цьому разі беруть $E_m(0) = 0..$

6. Процедура закінчується в разі знаходження максимуму інформаційного критерію оптимізації параметрів машинного навчання в робочій області визначення його функції.

Таким чином, базовий алгоритм навчання є ітераційною процедурою пошуку глобального максимуму інформаційного критерію оптимізації параметрів машинного навчання в робочій області визначення його функції:

$$d_m^* = \arg \max_{G_E \cap \{d\}} E_m^*(d). \quad (2.22)$$

На рисунку 5 показано геометричну інтерпретацію реалізації базового алгоритму інформаційно-екстремального машинного навчання СВА на прикладі побудови оптимального гіперсферичного контейнера класу розпізнавання X_1^o [6].




Рисунок 2.3 – Схема реалізації базового алгоритму інформаційно-екстремального машинного навчання

На рисунку 2.3 показано визначені в бінарному просторі Геммінга вершини усередненого двійкового вектору x_1 класу розпізнавання X_1^o та

усередненого двійкового вектора x_2 класу розпізнавання X_2^o , який є найближчим сусідом для класу розпізнавання X_1^o . На схемі кодова відстань Геммінга між векторами x_1 і x_2 дорівнює $d = (x_1 \oplus x_2) = 11$. У процесі машинного навчання за базовим алгоритмом здійснюється покрокове збільшення радіуса d_1 контейнера класу розпізнавання X_1^o на одну кодову одиницю. Водночас згідно з умовою (2.7) на величину радіуса d_1 накладається обмеження

$$d_1 < d(x_1 \oplus x_2) - 1.$$

На кожному кроці машинного навчання обчислюється значення інформаційного критерію E_1 оптимізації радіуса контейнера класу розпізнавання X_1^o . Як оптимальний радіус беруть екстремальне значення глобального максимуму критерію E_1 , обчислене в робочій (допустимій) області визначення функції інформаційного критерію. На рисунку 2.3 робоча область обчислення інформаційного критерію позначена заштрихованою ділянкою. Для двохальтернативних рішень робоча область існує за умови, що їх перша і друга достовірності перевищують відповідно помилки першого та другого родів. Аналіз рисунка 5 засвідчує, що максимальне значення критерію E_1^* одержане на четвертому кроці машинного навчання, тобто оптимальний радіус контейнера класу розпізнавання X_1^o дорівнює $d_1^* = 4$ (тут і далі в кодових одиницях).

Таким чином, основною функцією базового алгоритму машинного навчання в рамках ІЕІ-технології є обчислення на кожному кроці навчання інформаційного критерію та організація пошуку його глобального максимуму в робочій області визначення функції критерію з метою визначення оптимальних геометричних параметрів розбиття простору ознак на класи розпізнавання. При гіперсферичному контейнері класів розпізнавання такими

параметрами при інформаційно-екстремальному машинному навчанні за базовим алгоритмом є оптимальні кодові відстані $\{d_m^*\}$ і оптимальні усереднені вектори-реалізації $\{x_m^*\}$ для заданого алфавіту $\{X_m^o\}$.

2.5 Функціонування автономної бортової системи в режимі відеонавігації

За одержаними в процесі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання будуються вирішальні правила, які в продукційній формі подамо у вигляді

$$(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|})(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) \left(f [(\mu_m > 0) \& (\mu_m = \max_{\{m\}} \{\mu_m\})] \right. \\ \left. \text{then } x^{(j)} \in X_m^o \text{ else } x^{(j)} \notin X_m^o \right), \quad (2.23)$$

де $x^{(j)}$ – вектор, що розпізнається;

μ_m – функція належності вектору $x^{(j)}$ контейнеру класу розпізнавання X_m^o .

У виразі (2.23) функція належності для гіперсферичного контейнера класу розпізнавання X_m^o визначається за формулою

$$\mu_m = 1 - \frac{d(x_m^* \oplus x^{(j)})}{d_m^*}, \quad (2.24)$$

де x_m^* – оптимальний усереднений двійковий вектор ознак;

d_m^* – оптимальний радіус гіперсферичного контейнера.

Таким чином, при функціонуванні БСВН в режимі екзамену визначається за вирішальними правилами (23) належність реалізації розпізнавального класу до одного з класів із заданого алфавіту. Водночас вирішальні правила через малу обчислювальну трудомісткість відрізняються високою оперативністю.

Оцінювання функціональної ефективності інформаційно-екстремального машинного навчання здійснюється під час функціонування БСВН в режимі екзамену, алгоритм якого аналогічний алгоритму функціонування системи безпосередньо в робочому режимі. У рамках ІЕІ-технології категорійну модель у вигляді орієнтованого графа відображень множин, що застосовуються на етапі екзамену, показано на рисунку 2.4.




Рисунок 2.4 – Категорійна модель функціонування автономної БСВН в режимі екзамену

У категорійній моделі (рис. 2.4) оператор Φ_1 формує екзаменаційний вектор ознак y класу, що розпізнається, аналогічний за структурою вектору z навчальної матриці. Оператор Φ_2 за заданими на етапі машинного навчання контрольними допусками формує двійковий вектор x , а оператор P відображає цей вектор на побудоване на етапі машинного навчання оптимальне розбиття \mathfrak{R}^* класів розпізнавання. Оператор Ψ_1 для кожного вектора ознак, що розпізнається, обчислює значення побудованих на етапі машинного навчання вирішальних правил і формує терм-множину F , а оператор Ψ_2 за максимальним значенням вирішального правила відносить вектор x , до одного з класів заданого алфавіту $\{X_m^o\}$. У цьому разі множина

гіпотез $I^{|M+1|}$ містить додаткову гіпотезу γ_{M+1} , що характеризує некласифіковане рішення, тобто вектор, який розпізнається, не належить до жодного класу із заданого алфавіту класів розпізнавання. Призначенням оператора U_E є регламентація процесу екзамену.

Розглянемо схему реалізації алгоритму екзамену:

- 1) ініціалізація лічильника класів розпізнавання $m := 0$;
- 2) $m := m + 1$;
- 3) ініціалізація лічильника кількості реалізацій $j := 0$;
- 4) $j := j + 1$;
- 5) обчислення функції належності (2.24);
- 6) порівняння: якщо $j \leq n$, то виконується пункт 4, інакше – пункт 7;
- 7) обчислення усередненого значення функції належності (2.24)

$$\bar{\mu}_m = \frac{1}{n} \sum_{j=1}^n \mu_{m,j}; \quad (2.25)$$

- 8) порівняння: якщо $m \leq M$, то виконується пункт 2, інакше – пункт 9;
- 9) обчислення максимального значення функції (2.25)

$$\bar{\mu}_m^* = \max_{\{m\}} \bar{\mu}_m;$$

10) визначення класу розпізнавання за максимальним значенням функції (2.25);

11) якщо для всіх класів розпізнавання максимальні значення функції (2.25) від'ємні, то екзаменаційна реалізація не класифікується;

12) ЗУПИН.

Таким чином, побудовані в процесі машинного навчання в рамках геометричного підходу вирішальні правила є чіткими і відрізняються

незначною обчислювальною трудомісткістю і тому характеризуються високою оперативністю, що є важливим фактором при функціонуванні БПЛА в режимі відеонавігації.

Розглянуті вище категорійні моделі відбивають притаманні людині перетворення інформації та інформаційні потоки, які мають місце за когнітивних процесів формування та прийняття класифікаційних рішень. Тому їх можна розглядати як узагальнені структурні схеми алгоритмів інформаційно-екстремального машинного навчання і функціонування БСВН в режимі екзамену.

2.6 Інформаційно-екстремальне машинне навчання інтелектуальної системи за ієрархічною структурою даних

Якщо побудова вирішальних правил у межах геометричного підходу робить їх практично інваріантними до багато вимірності простору ознак розпізнавання, то при цьому залишається проблема багато вимірності алфавіту класів розпізнавання, потужність якого в режимі відеонавігації може досягати великих значень. Відомо, що під час збільшення потужності алфавіту класів розпізнавання в незмінному просторі ознак збільшується ступінь перетину класів розпізнавання і відповідно достовірність буде зменшуватися. Основним напрямом зменшення впливу багато вимірності алфавіту класів розпізнавання на функціональну ефективність машинного навчання інтелектуальної системи є перехід від лінійних структур даних до ієрархічних.

Розглянемо ієрархічну структуру даних у вигляді бінарного дерева з донизу східним перенесенням атрибутів вершин. На відміну від рекурсивної ієрархічної структури таку структуру будемо називати декурсивною.

На рисунку 2.5 показано приклад декурсивного бінарного дерева, в якому атрибути – навчальні матриці класів розпізнавання передаються з вершин вищого ярусу у відповідні вершини страт нижнього ярусу.




Рисунок 2.5 – Декурсивна ієрархічна структура даних

Атрибути вершин декурсивного дерева (рис. 2.5) є навчальні матриці класів розпізнавання із заданого алфавіту $\{X_{h,s,m}^o\}$, де h – порядковий номер ярусу, s – порядковий номер страти h -го ярусу і m – порядковий номер класу розпізнавання в алфавіті страти. На рисунку 2.5 верхній ярус (перший за дендрографічною класифікацією) має одну страту, яка складається із двох класів $X_{1,1,1}^o$ і $X_{1,1,3}^o$, а другий ярус – дві страти, кожна з яких складаються із двох класів $X_{2,1,1}^o$, $X_{2,1,4}^o$ і $X_{2,2,2}^o$, $X_{2,2,3}^o$ відповідно. Отже показана на рисунку 9 структура дозволяє підвищувати ймовірність побудови безпомилкових за навчальною матрицею вирішальних правил через зменшення ступеня перетину між класами розпізнавання.

Матрицю інциденції $A = \{a_{\pi,\zeta}\}$ декурсивного дерева будемо визначати так:

$a_{\pi,\zeta} = 1$, якщо початок ребра ζ з'єднується з вершиною π і має напрям від вершини;

$a_{\pi,\zeta} = -1$, якщо кінець (стрілка) ребра ζ з'єднується з іншою вершиною і має напрям від вершини π ;

$a_{\pi,\zeta} = 0$, якщо початок ребра ζ не з'єднується з вершиною π ;

$a_{\pi,\zeta} = *$, якщо початок ребра ζ з'єднується з вершиною π і має напрям від вершини π до вершини страти нижнього ярусу з однаковим атрибутом.

Для декурсивного дерева (рис. 2.5) матриця інциденції наведена в таблиці 2.1.

Таблиця 2.1 – Матриця інциденції

$\zeta \backslash \pi$	1	2	3	4	5	6	7	8
0	-1	-1	0	0	0	0	0	0
1	1	0	-1	-1	0	0	0	0
2	0	1	0	0	-1	-1	0	0
3	0	0	*	0	0	0	-1	0
4	0	0	0	1	0	0	0	-1
5	0	0	0	0	1	0	0	0
6	0	0	0	0	0	*	0	0
7	0	0	0	0	0	0	*	0
8	0	0	0	0	0	0	0	1

У таблиці 2.1 змінна ζ характеризує порядковий номер ребер графа (рис. 2.5), а π – номер вершин. Аналіз таблиці 2.1 показує, що вона враховує перехід класів розпізнавання в свою страту нижнього рівня, що є особливістю декурсивної ієрархічної структури. Цей факт підтверджується наявністю в таблиці елементів, позначених символом *. Водночас для матриці інциденцій декурсивного дерева специфічну відмінність від орієнтованого графа встановлює наступна лема.

Для декурсивного графа з ζ ребрами кількість стовпчиків матриці інциденцій, які мають нульову суму елементів дорівнює $\zeta - \pi^*$, де π^* – кількість вершин, які передають свої атрибути

Розглянемо формалізовану постановку задачі інформаційного синтезу здатної навчатися за декурсивною ієрархічною структурою даних БСВН. Нехай задано алфавіт класів розпізнавання у вигляді декурсивної ієрархічної структури $\{X_{h,s,m}^o \mid h = \overline{1, H}; s = \overline{1, S}; m = \overline{1, M}\}$, де H – кількість ярусів ієрархічної структури; S – кількість страт на h -му ярусі; M – кількість класів розпізнавання в заданому алфавіті. Водночас кожний клас

розпізнавання характеризує відповідний наземний об'єкт спостереження. За результатами аерофотозйомки сформовано для кожного класу розпізнавання вхідну навчальну матрицю яскравості пікселів рецепторного поля зображення наземних об'єктів $\|y_{h,s,m,i}^{(j)}\|_{i=\overline{1,N}, j=\overline{1,n}}$, де N – кількість ознак розпізнавання в структурованому векторі-реалізації класу розпізнавання $X_{h,s,m}^o$; n – кількість реалізацій, яка дорівнює кількості часових інтервалів аналізу трафіка.

Отже i -й стовпчик матриці $\|y_{m,i}^{(j)}\|$ містить значення навчальної вибірки, а j -й рядок є реалізацією класу розпізнавання $X_{h,s,m}^o$. Крім того, нехай задано структурований вектор параметрів машинного навчання БСВН розпізнавати реалізації класу $X_{h,s,m}^o$:

$$g_{h,s} = \langle x_{h,s,m}, d_{h,s,m}, \delta_{K,h,s,m,i} \rangle, \quad (2.26)$$

де $x_{h,s,m}$ – двійкова усереднена реалізація класу розпізнавання $X_{h,s,m}^o$;
 $d_{h,s,m}$ – кодова відстань, яка визначає радіус гіперсферичного контейнера класу розпізнавання $X_{h,s,m}^o$;
 $\delta_{K,h,s,m,i}$ – параметр, який дорівнює половині симетричного поля контрольних допусків i -ї ознаки вектора $x_{h,s,m}$.

При цьому задано обмеження:

1) закон розподілу реалізацій, наприклад, класу розпізнавання $X_{h,s,m}^o$, за якими визначається усереднений вектор ознак $x_{h,s,m}$, повинен згідно з гіпотезою нечіткої компактності бути наближеним до нормального;

2) областю значень радіуса контейнера класу розпізнавання $X_{h,s,m}^o$ є

$$d_{h,s,m} \in [0; d(x_{h,s,m} \oplus x_{h,s,c}) - 1],$$

де $d(x_{h,s,m} \oplus x_{h,s,c})$ – кодова відстань між вектором ознак $x_{h,s,m} \in X_{h,s,m}^o$ і аналогічним вектором $x_{h,s,c}$ найближчого класу розпізнавання $X_{h,s,c}^o$;

3) для двобічних симетричних допусків на ознаки розпізнавання має місце обмеження

$$\delta_{K,h,s,i} \in [0; \delta_{E,h,s,i} / 2],$$

де $\delta_{E,h,s,m,i}$ – поле нормованих допусків i -ї ознаки вектора $x_{h,s,m}$.

На етапі машинного навчання необхідно:

1) оптимізувати параметри вектору (2.26) за усередненим за алфавітом класів розпізнавання $\{X_{h,s,m}^o\}$ інформаційним критерієм

$$\bar{E}_{h,s} = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap G_d} E_{h,s,m}(d_{h,s,m}), \quad (2.27)$$

де $E_{h,s,m}(d_{h,s,m})$ – інформаційний критерій оптимізації параметрів машинного навчання БСВН розпізнавати реалізації класу $X_{h,s,m}^o$.

2) за результатами інформаційно-екстремального машинного навчання у рамках геометричного підходу побудувати високо достовірні вирішальні правила.

Функціональну категорійну модель машинного навчання БСВН з ієрархічною структурою даних представимо у вигляді орієнтованого графу (рис. 2.6).




Рисунок 2.6 – Категорійна модель ієрархічного машинного навчання БСВН

На рисунку 2.5 оператор f_1 формує вхідну навчальну матрицю Y для заданого алфавіту класів розпізнавання, оператор f_1 будує декурсивне бінарне дерево H , а оператори f_1 і f_1 формують відповідно вхідні євклідові навчальні матриці і робочі бінарні навчальні матриці для всіх страт декурсивного бінарного дерева. Оператор ξ відображає структуровані двійкові вектори робочої матриці на поточне розбиття $\mathfrak{R}^{[2]}$ класів розпізнавання s -ї страти h -го ярусу

Як критерій оптимізації параметрів машинного навчання БСВН за ієрархічною структурою даних будемо використовувати модифіковану інформаційну міру Кульбака, яка для рівно ймовірних двох альтернативних гіпотез має вигляд

$$E_{h,s,m}^{(k)} = \frac{1}{2} \{ 2 - [\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)] \} \times \log_2 \frac{2 - [\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)] + 10^{-r}}{\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d) + 10^{-r}}, \quad (2.28)$$

де $\alpha_{h,s,m}^{(k)}(d)$ – помилка першого роду класифікаційних рішень, обчислена на k -му кроці машинного навчання в процесі відновлення гіперсферичного контейнера класу розпізнавання $X_{h,s,m}^o$;

$\beta_{h,s,m}^{(k)}(d)$ – помилка другого роду при прийнятті класифікаційних рішень, обчислена в процесі відновлення гіперсферичного контейнера класу розпізнавання $X_{h,s,m}^o$;

$d_{h,s,m}$ – радіус гіперсферичного контейнера класу розпізнавання $X_{h,s,m}^o$;

10^{-r} – достатньо мале число, яке вводиться для уникнення поділу на нуль.

Під час обчисленні інформаційного критерію оптимізації (2.28) на практиці в процесі реалізації алгоритму машинного навчання замість точнісних характеристик використовують їх оцінки:

$$\alpha_{h,s,m}^{(k)}(d) = \frac{K_{1,h,s,m}^{(k)}(d)}{n}; \quad \beta_{h,s,m}^{(k)} = \frac{K_{2,h,s,m}^{(k)}(d)}{n}, \quad (2.29)$$

де $K_{1,h,s,m}^{(k)}(d)$ – кількість подій, при яких реалізації класу розпізнавання

$X_{h,s,m}^o$ не відносяться до свого класу;

$K_{2,h,s,m}^{(k)}(d)$ – кількість подій, при яких “чужі” реалізації помилково відносяться до класу розпізнавання $X_{h,s,m}^o$;

n – обсяг репрезентативної навчальної вибірки.

Після підстановки оцінок точнісних характеристик (2.29) у формулу (2.28) отримуємо робочу формулу для обчислення інформаційного критерію оптимізації

$$E_{h,s,m}^{(k)}(d) = \frac{1}{n} \{n - [K_{1,h,s,m}^{(k)}(d) + K_{2,h,s,m}^{(k)}(d)]\} \times \\ \times \log_2 \frac{2n - [K_{1,h,s,m}^{(k)}(d) + K_{2,h,s,m}^{(k)}(d)] + 10^{-r}}{[K_{1,h,s,m}^{(k)}(d) + K_{2,h,s,m}^{(k)}(d)] + 10^{-r}}. \quad (2.30)$$

Нормований критерій оптимізації параметрів машинного навчання представимо у вигляді

$$J_{h,s,m}^{(k)}(d) = \frac{E_{h,s,m}^{(k)}(d)}{E_{\max}},$$

де E_{\max} – максимальне значення критерію (2.30), яке отримано у разі підстановки

$$K_{1,h,s,m}^{(k)}(d) = K_{2,h,s,m}^{(k)}(d) = 0.$$

Згідно з категорійною моделлю (рис. 2.6) схема інформаційно-екстремального машинного навчання за ієрархічною декурсивною структурою даних має такий вигляд:

- 1) обнуління лічильника ярусів $h := 0$;
- 2) ініціалізація лічильника ярусів $h := h + 1$;
- 3) обнуління лічильника страт h -го ярусу ієрархічної структури $s := 0$;
- 4) ініціалізація лічильника страт яруса $s := s + 1$;
- 5) обнуління лічильника кроків зміни параметра поля контрольних допусків $\delta_{K,h,s} := 0$;
- 6) ініціалізація лічильника кроків зміни параметра поля контрольних допусків $\delta_{K,h,s} := \delta_{K,h,s} + 1$;
- 7) реалізація базового алгоритму машинного навчання, який для s -ї страти h -го ярусу ієрархічної структури обчислює максимальне значення інформаційного критерію $E_{h,s,m}(d_{h,s,m})$ та визначає оптимальні геометричні параметри контейнерів класів розпізнавання за процедурою

$$d_{m,h,s}^* = \arg \max_{G_E \cap G_d} \bar{E}_{h,s}(d_{h,s,m}), m = \overline{1, M}_{h,s},$$

де $M_{h,s}$ – кількість класів розпізнавання s -ої страти h -го ярусу;

8) якщо $\delta < \delta_H / 2$, то виконується пункт 6, інакше – пункт 9;

9) обчислюється максимальне значення усередненого за алфавітом класів розпізнавання s -ї страти h -го ярусу ієрархічної структури значення інформаційного критерію $\bar{E}_{h,s}^*$;

10) визначається для s -ї страти h -го ярусу оптимальне значення параметра поля контрольних допусків на ознаки розпізнавання за процедурою

$$\delta_{K,h,s}^* = \arg \max_{G_{\delta,h,s}} \{ \max_{G_E \cap G_d} \bar{E}_{h,s}(d) \},$$

де $G_{\delta,h,s}$ – область допустимих значень параметра $\delta_{K,h,s}$ поля контрольних допусків на ознаки для класів розпізнавання s -ї страти h -го ярусу ієрархічної структури.

11) обчислюються оптимальні нижні $A_{HK_i}^*$ та верхні $A_{BK_i}^*$ контрольні допуски:

$$A_{HK_i}^* = y_{h,s,1,i} - \delta_{h,s}^*; A_{BK_i}^* = y_{h,s,1,i} + \delta_{h,s}^*,$$

де $y_{h,s,1,i}$ – значення i -ї координати усередненого вектора ознак базового класу розпізнавання $X_{h,s,1}$, щодо якого задається система контрольних допусків;

12) якщо $s \leq S_h$, то виконується пункт 4, інакше – пункт 13;

13) якщо $h \leq H$, то виконується пункт 2, інакше – пункт 14;

14) ЗУПИН.

За оптимальними геометричними параметрами гіперсферичних контейнерів класів розпізнавання побудовані вирішальні правила, які в предикатній формі мають вигляд

$$(\forall X_{m,h,s}^o \in \mathfrak{R}^{|M|})(\forall x^{(j)} \in \mathfrak{R}^{|M|}) \{ \text{if } [(\mu_m > 0) \& (\mu_m = \max_{\{m\}} \{\mu_m \mid m = \overline{1, M}\})] \text{ then } x^{(j)} \in X_{m,h,s}^o \text{ else } x^{(j)} \in X_{m,h,s}^o \}, \quad (2.31)$$

де $x^{(j)}$ – вектор ознак, який розпізнається;

μ_m – функція належності вектора $x^{(j)}$ гіперсферичному контейнеру класу розпізнавання $X_{m,h,s}^o$, яка визначається за формулою

$$\mu_m = 1 - \frac{d(x^{(j)} \oplus x_{h,s,m}^*)}{d_{h,s,m}^*}. \quad (2.32)$$

Отже вектор ознак $x^{(j)}$ належить до того класу із заданого алфавіту відповідної страти, для якого функція належності (2.32) є додатною і максимальною. Крім того, побудовані в межах геометричного підходу вирішальні правила (2.31) дозволяють приймати класифікаційні рішення в реальному темпі часу, що є актуальним під час застосування ієрархічної структури даних за великої потужності алфавіту класів розпізнавання.

2.7 Оптимізація словника ознак розпізнавання

Одним із ефективних шляхів стиснення інформації є оптимізація словника ознак, спрямована на зменшення його інформаційної надлишковості.

У загальному випадку проблема формування оптимального в інформаційному розумінні словника ознак розпізнавання може розглядатися у трьох аспектах:

1) попередній відбір ознак для формування початкового словника ознак розпізнавання;

2) пошук у надлишковому словнику інформативних ознак, виявлення латентних і виключення неінформативних і “заважаючих” ознак розпізнавання;

3) доповнення словника інформативними первинними та вторинними ознаками розпізнавання.

Початковий відбір ознак все ще залишається в основному функцією людини – розробника інформаційного забезпечення інтелектуальної системи. Доступність ознак розпізнавання для вимірювання, наявність необхідних датчиків інформації (сенсорів) і приладів вимірювання значною мірою впливають на формування словника ознак. При цьому не виключається можливість ігнорування ознак, важливих для процесу прийняття рішень. Тому важливого значення набуває необхідність найкращого використання наявних ознак розпізнавання. Саме на це спрямовано другий аспект вирішення проблеми шляхом оптимізації вхідного математичного опису в процесі машинного навчання БСВН. При цьому під латентними розуміються інформативні ознаки, які є “схованими”, наприклад, через їх малу частоту спостережень.

Третій аспект проблеми формування інформативного словника так само доцільно вирішувати шляхом оптимізації параметрів машинного навчання БСВН, наприклад, за методами ІЕІ-технології.

Згідно із принципом відкладених рішень введемо, наприклад, у функціональну категорійну модель машинного навчання додатковий контур, який замикається операторами $\pi: E \rightarrow \Sigma$, де множина Σ – словник ознак розпізнавання, що містить первинні та вторинні у загальному випадку надлишкові в інформаційному розумінні ознаки, і $\omega: \Sigma^\Lambda \rightarrow \Omega$, який безпосередньо змінює розмірність простору ознак розпізнавання. Крім того, розширення словника може здійснюватися, наприклад, за рахунок вимірювання параметрів впливу зовнішнього середовища та інших параметрів функціонування БСВН, які впливають на потужність простору функціональних станів Z , за допомогою оператора $h: \Sigma \rightarrow Z$.

Орієнтований граф відображення множин у процесі машинного навчання БСВН за ІЕІ-технологією із оптимізацією словника ознак розпізнавання показано на рисунку 2.7.




Рисунок 2.7 – Функціональна категорійна модель машинного навчання з оптимізацією словника ознак розпізнавання

У діаграмі (рис. 2.7) оператор τ змінює крок дискретизації реалізацій образу, що призводить до зміни потужності словника Σ . Після формування оператором $F: G \times T \times Z \rightarrow \Sigma$ у загальному випадку апріорно надлишкового варіанта словника Σ його оптимізація здійснюється у процесі машинного навчання БСВН шляхом реалізації ітераційної процедури пошуку максимуму цільової функції

$$\Sigma^* = \arg \max_{\Sigma \in \Omega} EK(\Omega), \quad (2.33)$$

де $EK(\Omega)$ – узагальнена цільова функція, що включає як інформаційний критерію оптимізації параметрів машинного навчання, так і додаткові умови (наприклад, мінімальна розмірність простору ознак та інше), які є характерними для відповідного алгоритму селекції ознак розпізнавання. Наявність таких додаткових умов свідчить про існування допоміжних контурів оптимізації словника ознак розпізнавання, які пов'язані з іншими параметрами функціонування БСВН, що оптимізуються.

З урахування вище наведеного діаграма відображень множин, які застосовуються у процесі машинного навчання БСВН з оптимізацією словника ознак розпізнавання, набирає вигляду, показаного на рисунку 2.8.




Рисунок 2.8 – Узагальнена категорійна модель машинного навчання з оптимізацією словника ознак розпізнавання

У діаграмі (рис. 2.8) штрихпунктирними стрілками позначені можливі додаткові оператори оптимізації словника, що використовують особливості оптимізації інших параметрів функціонування БСВН, що навчається. Так, оператор h_D виділяє групу ознак розпізнавання, які не змінюють значення інформаційного критерію у процесі оптимізації параметрів машинного навчання за умови, що така оптимізація проводилася для кожної ознаки розпізнавання послідовно. Оператор $h_{\tilde{\mathcal{R}}^{|M|}}$ здатний перевірити, які з ознак було задіяно при реалізації максимально-дистанційного або мінімально-дистанційного принципів оптимізації геометричних параметрів розбиття простору ознак розпізнавання. Слід зазначити, що ці контури впливають лише на стратегію оптимізації словника, оскільки здатні об'єднувати окремі ознаки розпізнавання в групи відповідно до їх впливу на функціональну ефективність системи, що навчається.

3 ІФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ МАШИННЕ НАВЧАННЯ АВТОНОМНОЇ БОРТОВОЇ СИСТЕМИ НАВІГАЦІЇ

3.1 Формалізована постановка задачі інформаційного синтезу автономної бортової системи в режимі відеонавігації

Розглянемо формалізовану постановку завдання інформаційного синтезу здатної навчатися автономної БСВН в рамках ІЕІ-технології. Нехай дано алфавіт $\{X_m^o | m = \overline{1, M}\}$ класів розпізнавання, що характеризують попередньо задані на маршруті польоту БПЛА наземні навігаційні орієнтири, і навчальну матрицю типу «об'єкт – властивість» $\|y_{m,i}^{(j)}\|, i = \overline{1, N}, j = \overline{1, n}$, де N, n – кількість ознак розпізнавання та структурованих векторів ознак (далі в тексті реалізації) класів розпізнавання відповідно. Водночас рядок матриці $\{y_{m,i}^{(j)} | i = \overline{1, N}\}$ визначає j -у реалізацію, а стовпчик $\{y_{m,i}^{(j)} | j = \overline{1, n}\}$ – навчальну випадкову вибірку значень i -ї ознаки. Відомо, що концепція ІЕІ-технології полягає в перетворенні вхідної навчальної матриці Y на робочу бінарну матрицю X , що способом допустимих перетворень у процесі машинного навчання адаптується до максимальної повної ймовірності прийняття правильних класифікаційних рішень. Тому для бінарного простору Геммінга задамо множину $\{g_m\}$ структурованих векторів параметрів функціонування, що впливають на функціональну ефективність машинного навчання БСВН. У подальшому такі параметри функціонування називатимемо параметрами машинного навчання. Вектор параметрів машинного навчання БСВН розпізнавати реалізації класу X_m^o представимо у вигляді структури

$$g = \langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}, f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle, \quad \Xi_1 + \Xi_2 = \Xi, \quad (3.1)$$

де $\langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1} \rangle$ – генотипні параметри функціонування, що впливають на параметри розподілу реалізацій класу розпізнавання;

$\langle f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle$ – фенотипні параметри функціонування, що впливають на геометрію контейнерів класів розпізнавання, відновлюваних в радіальному базисі простору ознак.

Водночас відомі обмеження на відповідні параметри машинного навчання:

$$R_{\xi_1}(g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}) \leq 0, R_{\xi_2}(f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2}) \leq 0.$$

Необхідно:

- 1) визначити оптимальні значення параметрів машинного навчання
- (2.) $\{g_{\xi}^* | \xi = \overline{1, \Xi_1 + \Xi_2}\}$, що забезпечують максимум усередненого за алфавітом класів розпізнавання інформаційного критерію

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap \{k\}} E_m^{(k)}, \quad (3.2)$$

де $E_m^{(k)}$ – інформаційний критерій оптимізації параметрів машинного навчання розпізнавати реалізації класу X_m^o , значення якого обчислено на k -му кроці машинного навчання;

G_E – допустима область визначення функції інформаційного критерію оптимізації, що далі називатимемо робочою областю;

$\{k\}$ – упорядкована множина кроків машинного навчання (відновлення контейнерів класів розпізнавання в радіальному базисі дискретного простору ознак);

- 2) для апріорно класифікованого нечіткого розбиття $\tilde{\mathfrak{R}}^{|M|}$ побудувати шляхом допустимих перетворень у субпарацептуальному

бінарному просторі ознак розпізнавання Геммінга оптимальне (тут і далі в тексті в інформаційному розумінні) чітке розбиття класів розпізнавання $\mathfrak{R}^{|M|}$, на основі якого сформувані безпомилкові за навчальною матрицею вирішальні правила;

3) на етапі екзамену для перевірки функціональної ефективності машинного навчання прийняти рішення про належність реалізації образу, що розпізнається, до одного з класів заданого алфавіту $\{X_m^o\}$.

Отже завдання інформаційного синтезу здатної навчатися БСВН зводиться до оптимізації в процесі інформаційно-екстремального машинного навчання параметрів функціонування (2.9) за інформаційним критерієм (2.10) та прийняття в режимі екзамену класифікаційного рішення за побудованими на етапі навчання вирішальними правилами.

3.2 Машинне навчання автономної бортової системи відеонавігації з оптимізацією контрольних допусків на ознаки розпізнавання

У рамках ІЕІ-технології адаптація вхідного математичного опису здатної навчатися системи до її максимальної інформаційної спроможності здійснюється шляхом оптимізації параметрів машинного навчання за інформаційним критерієм. Реалізація базового алгоритму машинного навчання в загальному випадку не гарантує високої достовірності розпізнавання наземних навігаційних орієнтирів, оскільки стартові контрольні допуски на ознаки розпізнавання зазвичай є неоптимальними. Таким чином, виникає необхідність збільшення глибини машинного навчання за допомогою оптимізації системи контрольних допусків, які істотно впливають як на геометричні параметри контейнерів класів розпізнавання, так і на точнісні характеристики класифікаційних рішень. Нехай задано вектор параметрів машинного навчання для алфавіту класів розпізнавання $\{X_m^o\}$

$$g_m = \langle x_m, d_m, \delta \rangle, \quad (3.3)$$

де x_m – усереднений структурований вектор ознак класу розпізнавання X_m^o
 d_m – радіус гіперсферичного контейнера класу розпізнавання X_m^o , який відновлюється в радіальному базисі простору ознак розпізнавання;
 δ – параметр поля контрольних допусків на ознаку розпізнавання.

Параметр δ дорівнює половині симетричного поля контрольних допусків на ознаки розпізнавання, як це показано на рисунку 3.1.




Рисунок 3.1 – Поле допусків на ознаку розпізнавання

На рисунку 3.1 взято 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..

Двобічне симетричне поле контрольних допусків через параметр δ визначається за формулою

$$\delta_{K,i} = 2\delta \frac{A_{B,i} - A_{H,i}}{a}, \quad (3.4)$$

де a – кількість градацій контрольного поля допусків, яка для всіх ознак розпізнавання є однаковою.

Область значень радіуса контейнера класу розпізнавання X_m^o задається нерівністю

$$d_m < d(x_m \oplus x_c),$$

де $d(x_m \oplus x_c)$ – міжцентрова відстань найближчих класів розпізнавання

X_m^o і X_c^o , яка визначається як кодова відстань між відповідними усередненими векторами ознак x_m і x_c .

На практиці при $a=100$ параметр δ може визначатися як кількість відсотків відхилення i -ї ознаки розпізнавання від її номінального значення $A_{0,i}$.

Категорійну модель інформаційно-екстремальної машинного навчання автономної БСВН з оптимізацією контрольних допусків на ознаки розпізнавання з урахуванням моделі базового алгоритму показано на рисунку 3.2.




Рисунок 3.2 – Категорійна модель машинного навчання з оптимізацією контрольних допусків

Категорійна модель (рис. 3.2) порівняно з моделлю машинного навчання за базовим алгоритмом (рис. 2.2) містить додатковий контур операторів оптимізації контрольних допусків на ознаки розпізнавання, який замикається через терм-множину D допустимих значень системи контрольних допусків. Водночас оператор δ_1 на кожному кроці машинного навчання змінює

контрольне поле допусків на ознаки розпізнавання, а оператор δ_2 оцінює належність ознак розпізнавання заданому контрольному полю допусків.

Двох циклічний алгоритм машинного навчання системи з оптимізацією контрольних допусків на ознаки розпізнавання згідно з категорійною моделлю (рис. 3.2) має вигляд

$$\{\delta_{K,i}^* | i = \overline{1, N}\} = \arg \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \}, \quad (3.5)$$

де

$$\bar{E}^{(k)} = \frac{1}{M} \sum_{m=1}^M E_m^{(k)} -$$

усереднене за алфавітом класів розпізнавання значення інформаційного критерію оптимізації, обчислене на k -му кроці машинного навчання;

G_δ – область допустимих значень контрольних допусків на ознаки розпізнавання.

Оптимізація контрольних допусків на ознаки розпізнавання може здійснюватися за такими основними схемами:

- алгоритм паралельної оптимізації, за яким контрольні допуски оптимізуються для всіх ознак одночасно;
- алгоритм послідовної оптимізації, за яким контрольні допуски оптимізуються послідовно для кожної ознаки розпізнавання за фіксованих (стартових) значень інших ознак;
- алгоритм оптимізації за зведеним полем допусків, який доцільно застосовувати як послідовно-паралельний алгоритм за наявності різних шкал вимірювання для окремих груп ознак розпізнавання.

Перевагою паралельного алгоритму оптимізації контрольних допусків є висока оперативність реалізації алгоритму, але він не дозволяє одержати точне значення глобального максимуму інформаційного критерію в робочій області визначення його функції. Тому екстремальні значення параметрів

функціонування БСВН, одержані в процесі їх оптимізації за паралельним алгоритмом, є квазіоптимальними.

Алгоритми послідовної оптимізації системи контрольних допусків дозволяють обчислювати точні значення глобального максимуму інформаційного критерію в робочій області, але характеризуються низькою оперативністю. З метою поєднання переваг цих алгоритмів оптимізацію контрольних допусків доцільно здійснювати за паралельно-послідовним алгоритмом. При цьому реалізація паралельного алгоритму дозволяє визначити стартові контрольні допуски, які є вхідними для алгоритму послідовної оптимізації. Це дозволяє підвищити оперативність послідовного алгоритму, оскільки стартові квазіоптимальні контрольні допуски вже знаходяться в робочій області визначення функції інформаційного критерію.

Структурований алгоритм послідовної оптимізації поля контрольних допусків на ознаки розпізнавання має вигляд

$$\delta_{K,i}^* = \arg \left[\bigotimes_{l=1}^L \max_{G_\delta} \{ \max_{G_E \cap G_d} \bar{E}_l^{(i)}(d, \delta) \} \right], \quad (3.6)$$

де $\bar{E}_l^{(i)}(d, \delta)$ – усереднене значення інформаційного критерію оптимізації параметрів машинного навчання БСВН, обчислене під час оптимізації контрольних допусків i -ї ознаки розпізнавання на l -му прогоні ітераційної процедури оптимізації системи контрольних допусків на ознаки розпізнавання;

G_{δ_i} – область допустимих значень поля контрольних допусків для i -ї ознаки розпізнавання;

G_E – робоча область визначення функції інформаційного критерію оптимізації;

G_d – область допустимих значень кодової відстані d , яка визначає радіус гіперсферичного контейнера класу розпізнавання;

\otimes – символ операції повторення;

L – кількість прогонів ітераційної процедури оптимізації системи контрольних допусків на ознаки розпізнавання;

N – кількість ознак розпізнавання.

Необхідно на етапі машинного навчання автономної БСВН оптимізувати параметри вектора (3.3), які забезпечують максимальне значення інформаційного критерію оптимізації (2.19) в робочій (допустимій) області визначення його функції.

Розглянемо інформаційно-екстремальне машинне навчання БСВН з гіперсферичним класифікатором, в якому відновлення контейнерів класів розпізнавання відбувається шляхом паралельної оптимізації контрольних допусків на ознаки розпізнавання. Вхідною інформацією для алгоритму машинного навчання є масив навчальної матриці $\{y_{m,i}^{(j)}\}$ і система полів нормованих допусків $\{\delta_{H,i}\}$ на ознаки розпізнавання, яка задає область значень відповідних контрольних допусків.

Розглянемо основні етапи реалізації алгоритму машинного навчання СВА з паралельною оптимізацією контрольних допусків на ознаки розпізнавання, за якою на кожному кроці навчання змінюються контрольні допуски для всіх ознак розпізнавання одночасно:

1) ініціалізація лічильника кроків зміни параметра δ поля контрольних допусків: $\delta := 0$;

2) $\delta := \delta + 1$;

3) обчислюються для всіх ознак розпізнавання нижні $A_{HK,i}$ і верхні $A_{BK,i}$ контрольні допуски на ознаки розпізнавання:

$$A_{HK,i} = \bar{y}_i - \delta; \quad A_{BK,i} = \bar{y}_i + \delta. \quad (3.7)$$

4) реалізується базовий алгоритм, за яким для кожного значення параметра δ визначаються згідно з процедурою (2.22) оптимальні значення радіусів контейнерів класів розпізнавання;

5) якщо $\delta < \delta_H / 2$, то виконується пункт 2, інакше – пункт 6;

6) обчислюється усереднене за алфавітом класів розпізнавання максимальне значення інформаційного критерію \bar{E}^* ;

7) визначається оптимальний параметр поля контрольних допусків, який забезпечує максимальне значення усередненого критерію \bar{E}^* :

$$\delta^* = \arg \bar{E}^* ;$$

8) обчислюються за формулами (3.7) відповідні оптимальні контрольні допуски на ознаки розпізнавання

$$A_{HK,i}^* = \bar{y}_i - \delta^* ; A_{BK,i}^* = \bar{y}_i + \delta^* ;$$

9) у базі знань автономної БСВН запам'ятовуються оптимальні параметри машинного навчання, задані структурованим вектором (3.3);

10) ЗУПИН.

Визначені на етапі паралельної оптимізації контрольні допуски на ознаки розпізнавання є квазіоптимальними, оскільки вони були обчислені за однаковою кількістю кроків навчання для всіх ознак. Для визначення оптимальних контрольних допусків на ознаки розпізнавання в методах інформаційно-екстремального машинного навчання здійснюється їх послідовна оптимізація. Водночас визначені на етапі паралельної оптимізації контрольні допуски беруться як стартові для алгоритму послідовної оптимізації. Оскільки під час оптимізації i -ї ознаки інші наступні ознаки мають неоптимальні контрольні допуски, то послідовна оптимізація потребує у цьому разі проведення ітераційних прогонів до того часу, поки значення інформаційного критерію

оптимізації не буде змінюватися. Це призводить до зменшення оперативності алгоритму машинного навчання. Але завдяки тому, що стартовими обрано квазіоптимальні контрольні допуски, то під час послідовній оптимізації обчислені на кожному кроці навчання значення інформаційного критерію оптимізації будуть перебувати постійно в робочій області визначення його функції. Тому на практиці оперативність алгоритму інформаційно-екстремального машинного навчання з паралельно-послідовною оптимізацією контрольних допусків на ознаки розпізнавання вже за кількості ознак $N \geq 10$ перевершує оперативність послідовної оптимізації.

Розглянемо основні етапи алгоритму (3.6) послідовної оптимізації контрольних допусків на діагностичні ознаки.

1. Ініціалізація лічильника прогонів процедури оптимізації параметрів машинного навчання: $l := 0$.

2. $l := l + 1$.

3. Ініціалізація лічильника ознак розпізнавання: $i := 0$.

4. $i := i + 1$.

5. Визначення екстремального значення параметра поля контрольних допусків за процедурою (3.3)

6. Порівняння: якщо $i \leq N$, то виконується крок 4, інакше – крок 7.

7. Обчислюється усереднене за алфавітом класів розпізнавання значення інформаційного критерію $\bar{E}^{(l)}$.

8. Якщо $\left| \bar{E}^{(l-1)} - \bar{E}^{(l)} \right| \leq \varepsilon$, де ε – будь-яке мале додатне число, то виконується крок 9, інакше – крок 2.

9. Обчислюються оптимальні параметри поля контрольних допусків на ознаки розпізнавання шляхом операції присвоювання

$$\{\delta_i^* := \delta_i^{(l)} \mid i = \overline{1, N}\},$$

10. За формулами (3.5) обчислюються оптимальні нижні та верхні контрольні допуски.

11. Запам'ятовуються оптимальні координати структурованого вектора (3.1):

$\{x_m^* | m = \overline{1, M}\}$ – оптимальні усередненні вектори ознак класів розпізнавання із заданого алфавіту;

$\{d_m^* | m = \overline{1, M}\}$ – оптимальні радіуси контейнерів класів розпізнавання;

$\{A_{HK,i}^* | i = \overline{1, N}\}, \{A_{BK,i}^* | i = \overline{1, N}\}$ – оптимальні верхні

контрольні допуски на ознаки розпізнавання..

12. ЗУПИН.

Отже одержані за результатами інформаційно-екстремального машинного навчання оптимальні параметри функціонування автономної БСВН дозволяють побудувати в просторі ознак розпізнавання вирішальні правила (2.23) для прийняття класифікаційних рішень.

Для формування вхідного інформаційного опису було змодельовано 3D-макет місцевості, який містить зони інтересу (рис. 3.3).



Рисунок 3.3 – Рецепторне поле зображення регіону спостереження

На рисунку 3.4 як класи розпізнавання було обрано кадри ділянок показаного на рисунку 3.3 зображення: клас X_1^o – воєнний об’єкт; клас X_2^o – дорога; клас X_3^o – оране поле; клас X_4^o – густий ліс. Розмір кадрів 58x58 пікселів.




Рисунок 3.4 – Зображення кадрів зон інтересу: a – клас X_1^o ; b – клас X_2^o ;
 v – клас X_3^o ; z – клас X_4^o

На рисунку 3.5 показано графік залежності усередненого за алфавітом класів розпізнавання нормованого критерію (2.18) від параметра δ поля контрольних допусків, отриманого при їх паралельній оптимізації. На цьому графіку і далі робочу область визначення функції критерію виділено темним кольором.




Рисунок 3.5 – Графік залежності інформаційного критерію 2. від параметра поля контрольних допусків на ознаки розпізнавання

Як видно з графіку (рис. 3.5) максимальне значення інформаційного критерію дорівнює 0,38 при $\delta = 23$ градацій яскравості. З метою збільшення достовірності розпізнавання наземних об'єктів було реалізовано послідовну оптимізацію контрольних допусків на ознаки розпізнавання за процедурою 3.4. На рисунку 3.6 показано зміну нормованого інформаційного критерію в процесі послідовної оптимізації контрольних допусків на ознаки розпізнавання.




Рисунок 3.6 – Графік зміну нормованого інформаційного критерію в процесі послідовної оптимізації контрольних допусків на ознаки розпізнавання

Аналіз рисунку 3.6 показує, що інформаційний критерій оптимізації, який визначається відношенням кількості ітерацій i до кількості ознак N , збільшився до значення 0,7.

На рисунку 3.7 показано графіки залежності інформаційного критерію (2.19) від радіусів контейнерів класів розпізнавання, оптимальні значення яких дозволяють побудувати вирішальні правила (2.23).

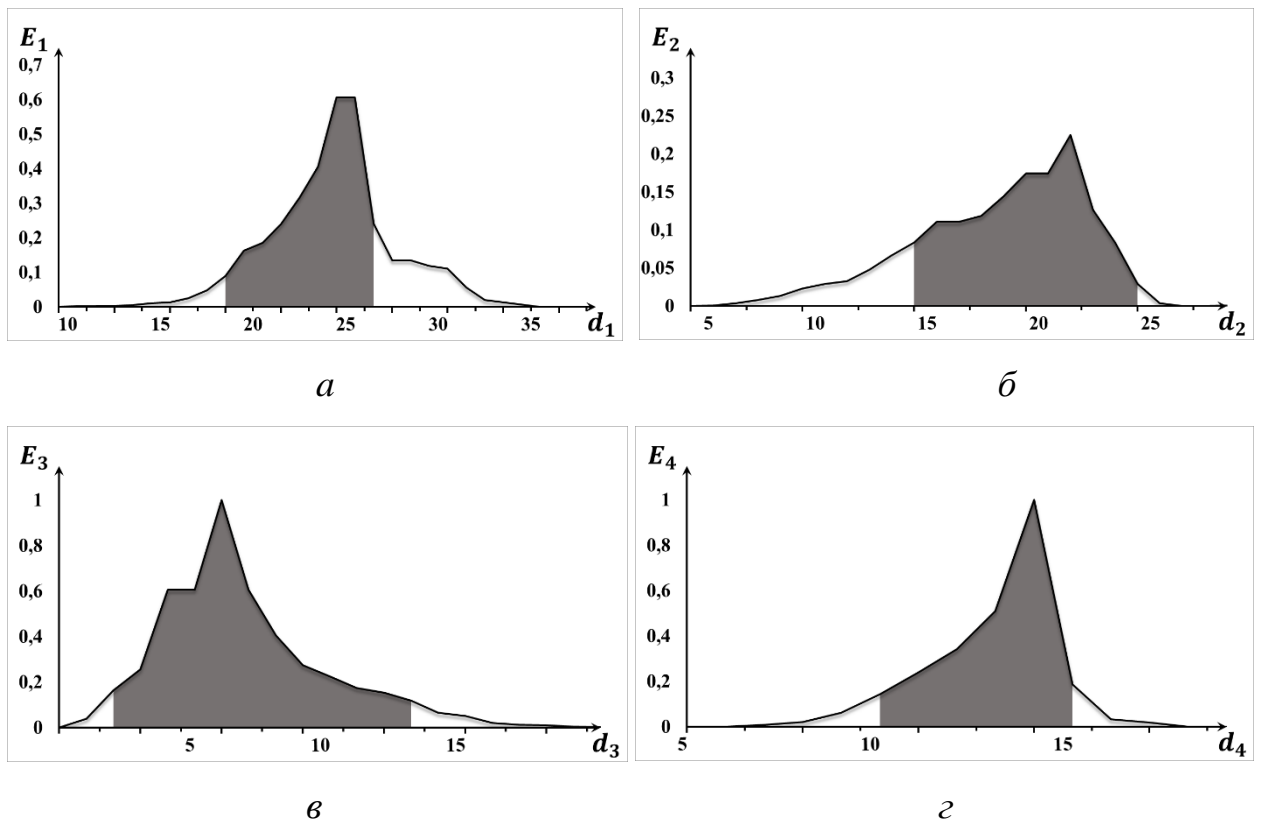


Рисунок 3.7 – Графіки залежності інформаційного критерію 2. Від радіусів контейнерів класів розпізнавання: a – клас X_1^o ; $б$ – клас X_2^o ;
 $в$ – клас X_3^o ; $г$ – клас X_4^o

Аналіз рисунку 3.7 показує, що оптимальні значення радіусів контейнерів класів розпізнавання дорівнюють: $d_1 = 25$ (тут і далі в кодovих одиницях) для класу X_1^o ; $d_2 = 21$ – для класу X_2^o ; $d_3 = 6$ – для класу X_3^o і $d_4 = 14$ – для класу X_4^o .

Перевірка функціональної ефективності машинного навчання БСВН здійснювалась в режимі екзамену, за результатом якого побудовано оцифроване зображення регіону спостереження, показане на рисунку 3.8. При цьому важливо зазначити, що екзамен відбувався на зображенні, яке було отримане не мна симуляторі, а з борту реального БПЛА.



Рисунок 3.7 – Оцифроване зображення регіону спостереження

Додатково було зроблене сегментоване зображення (рис. 8), яке є аналогом попереднього оцифрованого результату, але кожному кадру ставиться у відповідність колір ідентифікованого класу. X_1^o -білий колір; X_2^o - темно зелений; X_3^o - коричневий; X_4^o - світло зелений.




Рисунок 3.8 – Сегментоване зображення регіону, що спостерігається

Візуальний аналіз показує, що отримана достовірність розпізнавання наземних об'єктів є достатньо високою, якщо врахувати, що вхідний інформаційний опис БСВН був сформований за даними симулятора 3D-зображень, а етап екзамену проводився за зображенням, отриманим з борту реального безпілота.

ВИСНОВКИ

1. Аналіз сучасного стану використання безпілотних авіаційних комплексів в задачах спостереження за поверхнею Землі показує, що сучасні БПЛА провідних у світі розробників все ще використовуються як транслятори зображень наземних об'єктів, які аналізуються операторами наземних станцій керування з метою розв'язання відповідних задач.

2. Орієнтація на глобальні і локальні мережі позиціонування типу GPS робить БПЛА слабо захищеним від засобів радіоелектронної протидії і створює сприятливі умови для організації вторгнень і кібератак, що гостро потребує вирішення проблеми надання бортовим системам властивості автономного функціонування. Тому актуальною задачею подальшого розвитку безпілотних авіаційних комплексів є розроблення автономних бортових систем розпізнавання наземних об'єктів на основі машинного навчання та розпізнавання образів.

3. Аналіз існуючих методів інтелектуального аналізу даних не забезпечує алаптивності побудованих за результатами машинного навчання вирішальних правил до довільних умов формування зображень наземних об'єктів, гнучкість БСР до перенавчання та інваріантність до збільшення потужностей словника ознак і алфавіту класів розпізнавання через такі основні причини науково-методологічного характеру:

- довільні початкові умови формування зображень об'єктів на місцевості, що розпізнаються, обумовлених різними ракурсами аерофотозйомки, висотами літального апарату, положенням і місце великий обсяг знаходженням об'єкту;
- перетин класів розпізнавання, що характеризують зображення об'єктів, в просторі ознак розпізнавання;
- багатовимірність словника ознак і алфавіту класів розпізнавання;
- вплив неконтрольованих факторів, пов'язаних, наприклад, із зміною погодних умов, освітленості, маскуванням тощо.

4. Одним із перспективних шляхів аналізу та синтезу здатних навчатися бортових систем БПЛА для розпізнавання наземних об'єктів є використання ідей і методів прогресивної інформаційно-екстремальної інтелектуальної технології (ІЕІТ) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи розпізнавання в процесі її машинного навчання. Головна перевага методів інформаційно-екстремального машинного навчання полягає в тому, що вони розробляються в рамках функціонального підходу до моделювання когнітивних процесів, притаманних людині при формуванні та прийнятті класифікаційних рішень.

5. З точки зору теоретико-інформаційного підходу умовою спостережуваності БСВН, що навчається, є наявність умовної кількості інформації, яку вона одержує, аналізує і передає, тобто спостережуваність БСВН можна трактувати як властивість системи розрізняти класи розпізнавання.

6. Як критерії оптимізації параметрів машинного навчання в методах ІЕІТ можуть використовуватися різні критерії, що задовольняють властивостям інформаційної міри. Серед інформаційних мір для оцінювання функціональної ефективності БСВН, що навчається, перевагу варто віддавати статистичним логарифмічним критеріям, що дозволяють працювати з порівняно малими навчальними вибірками.

7. Основною функцією базового алгоритму машинного навчання в рамках ІЕІТ є обчислення на кожному кроці навчання інформаційного критерію та організація пошуку його глобального максимуму в робочій області визначення функції критерію з метою визначення оптимальних геометричних параметрів розбиття простору ознак на класи розпізнавання.

8. Побудовані в процесі машинного навчання в рамках геометричного підходу вирішальні правила є чіткими і відрізняються незначною обчислювальною трудомісткістю і тому характеризуються високою оперативністю, що є важливим фактором при функціонуванні БПЛА в режимі відеонавігації.

9. Запропоновані функціональні категорійні моделі відбивають притаманні людині перетворення інформації та інформаційні потоки, які мають місце за когнітивних процесів формування та прийняття класифікаційних рішень. Тому їх можна розглядати як узагальнені структурні схеми алгоритмів інформаційно-екстремального машинного навчання і функціонування БСВН в режимі екзамену.

10. Вперше розроблено метод інформаційно-екстремального ієрархічного машинного навчання БСВН за структурою даних у вигляді декурсивного бінарного дерева.

11. Удосконалено метод інформаційно-екстремального машинного навчання БСВН з оптимізацією словника ознак розпізнавання.

12. Аналіз результатів машинного навчання автономної БСВН показує, що отримана достовірність розпізнавання наземних об'єктів є достатньо високою, якщо врахувати, що вхідний інформаційний опис БСВН був сформований шляхом використання симулятора 3D-макетів, а етап екзамену проводився за зображенням, отриманим з борту реального безпілотнока.

13. Розроблено структурну схему бортової системи відеонавігації БПЛА.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Dovbysh A.S. Information-Extreme Machine Learning of On-Board Vehicle Recognition System / A. S. Dovbysh, M. M. Budnyk, V. Yu. Piatachenko, M. I. Myronenko // *Cybernetics and Systems Analysis*, 2020. – Vol. 56(4). – P 534-543. DOI:10.1007/s10559-020-00269-y.
2. Protsenko O. Informational and extreme machine learning for onboard recognition system of ground objects / O. Protsenko, T. Savchenko, M. Myronenko, O. Prikhodchenko // *Proceedings - 2020 IEEE 11th International Conference on Dependable Systems, Services and Technologies, DESSERT, 2020.* – P. 213-218/
3. Dovbysh, A., Naumenko, I., Myronenko, M., Savchenko, T. Information-extreme machine learning on-board recognition system of ground objects with the adaptation of the input mathematical description / Dovbysh, A., Naumenko, I., Myronenko, M., Savchenko, T. // *3rd International Workshop on Computer Modeling and Intelligent Systems, CMIS 2020; National University "Zaporizhzhia Polytechnic "Zaporizhzhia; Ukraine; 27 April 2020 to 1 May 2020; CEUR Workshop Proceedings, 2020.* – Volume 2608. – P. 913-925
4. Рішення про реєстрацію договору, який стосується права автора на твір Комп'ютерна програма «Визначення базового класу розпізнавання при інформаційно-екстремальному машинному навчанні системи розпізнавання зображень». Автори Довбиш А.С., Шелехов І.В., Мироненко М. І., Савченко Т.Р. Реєстраційний номер 5768. Дата реєстрації 03.09.2020.
5. Свідоцтво про реєстрацію авторського права на твір №100201 Комп'ютерна програма «Інформаційно-екстремальне машинне навчання системи діагностування онкопатологій за зображенням морфології тканини». Автори Довбиш А.С., Романюк А.М., Москаленко Р. А., П'ятаченко В. Ю. Дата реєстрації 05.10.2020.
6. Основи інформаційно-екстремального синтезу автоматизованої системи керування кіберзахистом / А.С. Довбиш, В.К. Ободяк, І.В. Шелехов, Д.В.

Великодний // в кн. «Сучасні інформаційні технології в кібербезпеці»: монографія; за ред. В.К. Ободяка і І.В. Шелехова– Суми: Сумський державний університет, 2021.–348 с.

7. Довбиш А. С. Інформаційно-аналітична система оцінювання відповідності сучасним вимогам навчального контенту спеціальності кібербезпека // А. С. Довбиш, І. В. Шелехов, Ю. О. Хібовська, О. В. Матяш // Радіоелектронні та комп'ютерні системи, 2021. – №1. – С. 35–47.

8. Свідоцтво про реєстрацію авторського права на твір № 104081. Комп'ютерна програма «Ідентифікація кадрів цифрового зображення регіону». Автори Довбиш А.С., Науменко І. В., Мироненко М. І. Савченко Т. Р. Дата реєстрації 15.04.2021 р.

9. Dovbysh. Hierarchical Clustering Approach for Information-Extreme Machine Learning of Hand Brush Prosthesis / A. Dovbysh, V. Piatachenko // Proceedings of the 5th International Conference on Computational Linguistics and Intelligent Systems (COLINS 2021), 2021, p.p. 1706-1715.

10. Свідоцтво про реєстрацію авторського права на твір № 106653. Комп'ютерна програма «Інформаційно-екстремальне машинне навчання системи розпізнавання емоційно-психічного стану людини за зображенням її обличчя». Автори Довбиш А.С., Шелехов І. В., Прилепа Д.В. Дата реєстрації 26.07.2021 р.

11. Свідоцтво про реєстрацію авторського права на твір № 107707. Комп'ютерна програма «Ієрархічне машинне навчання системи керування протезом кінцівки руки з неінвазивним зчитуванням біосигналів». Автори Довбиш А.С., Шелехов І. В., П'ятаченко В.Ю. Дата реєстрації 01.09.2021 р.

12. Москаленко В.В. Багатоетапний метод глибинного навчання з попереднім самонавчанням для класифікаційного аналізу дефектів стічних труб / В. В. Москаленко, М. О. Зарецький, А. С. Москаленко, А. С. Коробов, Я. Ю. Ковальський // Радіоелектронні і комп'ютерні системи. – 2021. – № 4(100). – С. 71-81. DOI: 10.32620/reks.2021.4.06

13. Москаленко В.В. Model and training method for context classification in CCTV sewer inspection video frames / M. Zaretskyi, A. S. Moskalenko, A. O. Panych, V. V. Lysyuk // Radio Electronics, Computer Science, Control. – 2021. – № 3. – P.63-76. DOI: 10.15588/1607-3274-2021-3-9.
14. Москаленко В.В. Модель та метод навчання для класифікаційного аналізу рівня води в стічних трубах за даними відео інспекції / М. О. Зарецький, А. Г. Коробов, Я. Ю. Коваль-ський, А. Ф. Шаєхов, В. А. Семашко, А. О. Панич // Радіоелектронні і комп'ютерні системи. – No 2 (98). – 2021. – С. 4-15. DOI: 10.32620/reks.2021.2.01
15. Москаленко В.В. Модель і метод навчання класифікатора контекстів спостереження на зображеннях відеоінспекції стічних труб / М. О. Зарецький, Я. Ю. Коваль-ський, С. С. Мартиненко // Радіоелектронні і комп'ютерні системи. – No 3(95). – 2020. – С. 59-66. DOI: 10.32620/reks.2020.3.06
16. Москаленко В.В. Sewer Pipe Defects Classification Based on Deep Convolutional Network with Information-extreme Error-correction Decision Rules // A. S. Moskalenko, M. O. Zaretskyi, V. Lysyuk // Communications in Computer and Information Science (CCIS-2020) – Vol. 1158. – pp. 253–263. – 2020. DOI: 10.1007/978-3-030-61656-4_16
17. Москаленко В.В. Deep feature extractor with information-extreme decision rules for visual classification of sewer pipe defects and its training method / A. Moskalenko, M. Zaretskyi, V. Lysyuk // Data Stream Mining & Processing 2020. – Lviv, Ukraine, 21-25 Aug. 2020. – pp.191-195. DOI: 10.1109/DSMP47368.2020.9204083.
18. Москаленко В.В. Multi-Layer Model and Training Method for Information-Extreme Malware Traffic Detector / A. Moskalenko, A. Shaikhov, M. Zaretskyi // The Third International Workshop on Computer Modeling and Intelligent Systems – April 27-May 1. – 2020. – p. 288-299.
19. Москаленко В.В. Multi-layer model and training method for malware traffic detection based on decision tree ensemble / М. О. Zaretskyi, А. S. Moskalenko,

- A. M. Kudryavtse, V. A. Semashko // *Radioelectronic and Computer Systems*, 2020, (2-94), pp. 92–101. DOI: 10.32620/reks.2020.2.08
20. Dovbysh A.S. Information-extreme algorithm for recognizing current distribution maps in magnetocardiography / A. S. Dovbysh, S. S. Martynenko, A. S. Kovalenko, M. M. Budnyk // *Journal of Automation and Information Sciences*, 2011.– V. 43.– № 2.– P. 63-70. DOI: 10.1615/JAutomatInfScien.v43.i2.60
21. Dovbysh A. S. Information-Extreme Method for Classification of Observations with Categorical Attributes / A. S. Dovbysh, V. V. Moskalenko, A. S. Rizhova // *Cibernetica and Systems Analysis*, 2016. V. 52. – No 2. – P. 45-52. DOI: 10.1007/s10559-016-9818-1
22. Naumenko I. Information-extreme learning of on-board system for recognition of ground vehicle / I. Naumenko, M. Myronenko, V. Piatachenko // *CEUR Workshop Proceedings*, 2019. – P. 121 – 132.
23. Simonovskiy Juliy. On-board Geographic Information System of Images' Identification / Juliy Simonovskiy, Vladislav Piatachenko, Mykyta Myronenko // *In Proceedings of the VI International Conference «Advanced Information Systems and Technologies – AIST-2018»*, Sumy, May 16 – 18, 2018. – Sumy. – Sumy State University, 2018. – P. 115 – 118.
24. Рішення про реєстрацію договору, який стосується права автора на твір «Побудова вирішальних правил для СППР адаптації навчального контенту випускової кафедри до вимог ринку праці». Автори Шелехов І.В., Прилепа Д. В., О. П., Міщенко А. Є. Реєстраційний номер 6551. Дата реєстрації 31.05.2022.
25. Довбиш А. С. Інформаційно-екстремальне машинне навчання системи виявлення атак // А. С. Довбиш, І. В. Шелехов, В. О.Любчак, Ю. В. Симоновський, А.О. Теницька // *Радіоелектронні та комп'ютерні системи*, 2022. – №3. – С. 17–29.
26. Hermes 450 - Tactical Long Endurance UAS, Elbit Systems Australia, Retrieved 2020-09-13. Akcess mode: <https://www.elbitsystems.com.au/uas-hermes-450-tactical-long-endurance-uas/>

27. Bereznyi A. Information technology of automatic detection and identification of stationary objects with unmanned aerial vehicles / A. Bereznyi, A. Trystan O. Lavrov // Сучасні інформаційні системи. – Вип. 4(1). С. 5–10. DOI:10.20998/2522-9052.2020.
28. Гороховатский А, Структурный анализ и интеллектуальная обработка данных в компьютерном зрении (монография) / А. Гороховатский // Харьков: Компания СМІТ, 2014.
29. Бережний А. О. Метод автоматизованого планування маршрутів безпілотних літальних апаратів з урахуванням виявлення стаціонарних об'єктів / А. О. Бережний, І. М. Крижанівський, О. В. Барабаш // Телекомунікаційні та інформаційні технології, Київ, 2019. – Вип. 4(65). – С. 90–98. DOI:10.31673/2412-4338.2019.049098
30. Єпіфанов І. Н. Проблематика використання безпілотних літальних апаратів (дронів) в логістиці [Електронний ресурс] / І. Н. Єпіфанов // Режим доступу: <https://scientificarticle.ru/images/PDF/2016/9/problematika-ispolzovaniya-bespilotnykh.pdf>.
31. Ю. П. Стародуб та П. П. Урсуляк Інформаційні технології в комп'ютерному моделюванні еколого-геофізичних процесів Львів / Ю. П. Стародуб, П. П. Урсуляк // ЛДУ БЖД, 2013.
32. Куссуль Н. Оценка состояния растительности и прогнозирование урожайности озимых культур Украины по спутниковым данным / Н. Куссуль, Н. Ильин, С. Скакун, А. Лавренюк // Институт космических исследований НАНУ-НКАУ, 2005.
33. X. Liu, S. Zhang, J. Tian, and L. Liu, “An onboard vision-based system for autonomous landing of a low-cost quadrotor on a novel landing pad / X. Liu, S. Zhang, J. Tian, and L. Liu // Sensors (Switzerland), 2019. – Vol. 19. – No. 21.
34. Fasano, Giancarmine. Radar electro-optical data fusion for non-cooperative UAS sense and avoid / Giancarmine Fasano, Domenico Accardo, Anna Elena Tirri, Antonio Moccia, Ettore De Lellis // Aerospace Science and Technology, 2015. – Vol. 46. – P. 436–450.

35. Object Recognition from Local Scale-Invariant Features. Access mode: <https://www.cs.ubc.ca/~lowe/papers/iccv99.pdf>.
36. Brevet U.S. 6,711,293 [archive], Method and apparatus for identifying scale invariant features in an image and use of same for locating an object in an image. Revenir plus haut en: a b et c Lowe, 2004/<https://patents.google.com/patent/US6711293>
37. Mikolajczyk K.; Schmid, C. "A performance evaluation of local descriptors" (PDF) / K. Mikolajczyk, C. Schmid // IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005. – Vol. 27 (10). – pp. 1615–1630.
38. Kachikian S. A Review of detector descriptors' on Object Tracking / S. Kachikian, M. Emadi // International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 2016, vol. 5, № 7, pp. 5815-5828.
39. Приставка П.О., Сорокопуд В. І., Чирков А.В. Експериментальний зразок автоматизованої системи пошуку підозрілих об'єктів на відео з безпілотного повітряного судна// Системи озброєння і військова техніка. –2017. –№2(50). – С. 26 –32
40. P. Gao, Y. Zhang, L. Zhang, R. Noguchi, and T. Ahamed, "Article development of a recognition system for spraying areas from unmanned aerial vehicles using a machine learning approach / P. Gao, Y. Zhang, L. Zhang, R. Noguchi, T. Ahamed // Sensors (Switzerland), 2 Vol. 19, no. 2, 2019, doi: 10.3390/s19020313.
41. Wang N. Review on deep learning techniques for marine object recognition: Architectures and algorithms / N. Wang, Y. Wang, M. J. Er // Control Eng. Pract., 2020. DOI: 10.1016/j.conengprac.2020.104458.
42. Chen J. Performance evaluation of 3D descriptors for object recognition in construction applications / J. Chen, Y. Fang, Y. K. Cho // Autom. Constr., 2018. – Vol. 86. DOI: 10.1016/j.autcon.2017.10.033.
43. BAYKAR Unmanned Aerial Vehicle Systems. Access mode: <https://baykardefence.com/uav-15.html>

44. Konert A. Military autonomous drones (UAVs) - from fantasy to reality. Legal and Ethical implications / A. Konert, T. Balcerzak // *Transportation Research Procedia*, 2019. – Vol. 59. – P. 292–299.
45. Honglin A. Network Traffic Classification Method Using Support Vector Machine with Feature Weighted-degree / A. Honglin // *Journal of Digital Information Management*, 2017. – Vol. 15(2). – P. 76–83.
46. Ammour H. Deep Learning Approach for Car Detection in UAV Imagery / H. Ammour, A. Alhichri, Y. Bazi, B. Benjdira // *Ammour Remote Sens*, 2017. – Vol. 9. – no 4. – P. 1–15.
47. Bengio Y. Representation learning: A review and new perspectives / Y. Bengio, A. Courville, P. Vincent // *Pattern Analysis and Machine Intelligence*, 2013. – No. 35(8). – P. 1798–1828.
48. Floreano Dario. Science, technology and the future of small autonomous drones / Dario Floreano, Robert J. Wood, 2015.
49. Sepulveda Palacios E. Impact of mission requirements on the design of low observableUCAV configurations / Palacios E. Sepulveda, H. Smith // *Aircraft Engineering and Aerospace Technology*, 2019. – Vol. 91. – No. 10. – P. 1295-1307.
50. Lutz R. Integration of unmanned aircraft systems into complex airspace environments / R. Lutz, P. Frederick, P. Walsh, K. Wasson, N. Fenlason // *Johns Hopkins APL Technical Digest (Applied Physics Laboratory)*, 2017. – Vol. 33(4). – P. 291-302.
51. Joint Artificial Intelligence Center. Access mode: <https://www.ai.mil/> Retrieved: Jan, 2022.
52. Konert, A. Military autonomous drones (UAVs) - from fantasy to reality. Legal and Ethical implications / A. Konert, T. Balcerzak // *Transportation Research Procedia*, 2021. – Vol. 59. – P. 292–299. [Doi.org/10.1016/j.trpro.2021.11.121](https://doi.org/10.1016/j.trpro.2021.11.121)
53. Повітряний кодекс України від 19.05.2011 № 3393-VI (Редакція від 12.04.2017).

54. Правила виконання польотів безпілотними авіаційними комплексами державної авіації України затверджені Наказом Міністерства оборони України від 08.12.2016 № 661.
55. Fasano Giancarmine. Radar/electro-optical data fusion for non-cooperative UAS sense and avoid / Giancarmine Fasano, Domenico Accardo, Anna Elena Tirri, Antonio Moccia, Ettore De Lellis // *Aerospace Science and Technology*, 2019. – Vol. 46. – P. 436–450.
56. Eric R. Fossum and D. B. Hondongwa A Review of the Pinned Photodiode for CCD and CMOS Image Sensors / Eric R. Fossum, D. B. Hondongwa // *IEEE Journal of the Electron Devices Society*, 2014. Vol. – 2(3). – P. 33–43. [55] Meroli Stefano, "CMOS vs CCD sensor. Who is the clear winner?". Access mode: meroli.web.cern.ch. Retrieved 28 March 2020.
57. Гиренко А.В. Методи кореляційного виявлення об'єктів / А. В. Гиренко, В. В.Ляшенко, В.П. Машталир, Е. П. Путятин // Харків: АО «БизнесИнформ», 1996. 112 с.
58. Carsten Steger Carsten. Machine Vision Algorithms and Applications (2nd ed.) / Carsten Steger, Ulrich Markus, Christian Wiedemann // Weinheim: Wiley-VCH, 2018.
59. E. Roy Davies Machine Vision: Theory, Algorithms, Practicalities/ E. Roy Davies // Morgan Kaufmann, 2005.
60. В. М. Теслюк та М. І. Андрійчук Конспект лекцій з курсу «Методи синтезу та оптимізації» для студентів базового напрямку «Комп'ютерні науки», Ч.1 / В. М. Теслюк, М. І. Андрійчук // Львів, 2005.
61. Творошенко І. С. Конспект лекцій з дисципліни «Цифрова обробка зображень» (для студентів 5 курсу денної та заочної форм навчання спеціальності 7.08010105 – Геоінформаційні системи та технології) / І. С. Творошенко // Харків, ХНУМГ ім. О. М. Бекетова, 2015.
62. Перелигін Б. В. Спектрально-часовий аналіз даних моніторинга: навчальний посібник / Б. В. Перелигін, Т. Б. Ткач, С. А. Гор'єв // Одеський державний екологічний університет. Одеса: ТЕС, 2017.

63. J. Long, E. Shelhamer, and T. Darrell Fully convolutional networks for semantic segmentation / J. Long, E. Shelhamer, T. Darrell // IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2015. – P. 115 –127.
64. Abhishek Sharma, Chathuranga Basnayaka, M. Wijerathna and Dushantha Nalin K. Jayakody Communication and networking technologies for UAVs: A survey / Abhishek Sharma, Chathuranga Basnayaka, M. Wijerathna, Dushantha Nalin K. Jayakody // Journal of Network and Computer Applications, 2020. – Vol. 168: 102739.
65. J. Goldberger, S. Roweis, G. Hinton and R. Salakhutdinov Neighbourhood Components Analysis, in Neural Information Processing Systems (NIPS) / J. Goldberger, S. Roweis, G. Hinton, R. Salakhutdinov // Montreal, Canada, 2014.
66. Karpathy Andrej et al. Large-scale video classification with convolutional neural networks / Andrej Karpathy et al. // IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2014.
67. Krizhevsky A. Imagenet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G. E. Hinton // Advances in neural information processing systems, 2012. – P. 1097–1105.
68. O. Vinyals, C. Blundell, T. Lillicrap, K. Kavukcuoglu and D. Wierstra Matching Networks for One Shot Learning / O. Vinyals, C. Blundell, T. Lillicrap, K. Kavukcuoglu, D. Wierstra // Advances in Neural Information Processing Systems, 2016. – Vol. 29. – P. 3630-3638.
69. D. Yi, S. Ji and S. Bu An Enhanced Optimization Scheme Based on Gradient Descent Methods for Machine Learning / D. Yi, S. Ji, S. Bu // *Symmetry*, 2019. – Vol. 11(7). – P. 942–949.
70. Ciresan D. Multi-column deep neural networks for image classification / D. Ciresan, U. Meie, J. Schmidhuber // Computer Vision and Pattern Recognition (CVPR), 2012. – P. 3642–3649.
71. Bengio Y. Representation learning: A review and new perspectives / Y. Bengio, A. Courville, P. Vincent // Pattern Analysis and Machine Intelligence, 2013. – No. 35(8). – P. 1798–1828.

72. Hinton G. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups / G. Hinton, L. Deng, D. Yu // IEEE Signal Processing Magazine, 2012. – P. 82–97.
73. Mou L. Deep recurrent neural networks for hyperspectral image classification / L. Mou, P. Ghamisi, X. Zhu // IEEE Transactions on Geoscience and Remote Sensing, 2017. – Vol. 55. – No. 7. – P. 3639–3655.
74. W. Hu, Y. Huang, L. Wei, F. Zhang and H. Li Deep convolutional / W. Hu, Y. Huang, L. Wei, F. Zhang, H. Li // IEEE Signal Process. Lett., 2014. Vol. 21. No. 9. P. 1159–1163.
75. L. Mou, P. Ghamisi, and X. Zhu Deep recurrent neural networks for hyperspectral image classification / L. Mou, P. Ghamisi, X. Zhu // IEEE Transactions on Geoscience and Remote Sensing, 2017. – Vol. 55. – No. 7. – P. 3639–3655.
76. Long J Fully convolutional networks for semantic segmentation / J. Long, E. Shelhamer, T. Darrell // IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2015.
77. Куcssуль Н. Оценка состояния растительности и прогнозирование урожайности озимых культур Украины по спутниковым данным / Н. Куcssуль, Н. Ильин, С. Скакун, А. Лавренюк // Киев, Институт космических исследований НАНУ-НКАУ, 2005.
78. Приставка П. О. Експериментальний зразок автоматизованої системи пошуку підозрілих об'єктів на відео з безпілотного повітряного судна / П. О. Приставка, В. І. Сорокопуд, А. В. Чирков // Системи озброєння і військова техніка, 2017. – №2(50). – С. 26–32.
79. Приставка П. О. Пошук особливих точок цифрового зображення та розпізнавання об'єктів на основі сплайн-моделі / П. О. Приставка // Актуальні проблеми автоматизації та інформаційних технологій: Зб. Наук.праць. – Дніпро: ЛІРА, 2016. – Т. 20. – С. 65–77.

80. Y. Sung-Joo, and T. Kim Development of Stereo Visual Odometry Based on Photogrammetric Feature Optimization / Y. Sung-Joo, T. Kim // *Remote Sensing*, 2019. – Vol. 11. –P. 1-17.
81. Фукунага К. Введение в статистическую теорию распознавания образов. Пер. с англ. / К. Фукунага // М.: Наука, 1979.
82. [106] T. Hastie, R. Tibshirami and J. Eridman, *The Elements of Statistical Learning: data Mining, Inference and Prediction*. –2nd ed., Springer Verlag, 2009.
83. M. Fraire Statistical methods for exploratory multidimensional data analysis on time use / M. Fraire // *Statistica*, 2009. – Vol. 69. – P. 317-341.
84. Flamary Rémi. Wasserstein discriminant analysis / Rémi Flamary, Marco Cuturi, Nicolas Courty, Alain Rakotomamonjy // *Machine Learning*, 2018. – Vol. 107(12). – P. 1923–1945.
85. D. Hu, F. Nie, and X. Li Deep linear discriminant analysis hashing / D. Hu, F. Nie, and X. Li // *Scientia Sinica Informationis*, 2021. – Vol. 51(2). – P. 279–293.
86. L. Clemmensen, T. Hastie, D. Witten, and B. Ersboll Sparse discriminant analysis / L. Clemmensen, T. Hastie, D. Witten, B. Ersboll // *Technometrics*, 2011. Vol. 53(4). P. 406–413,
87. M. Mozina, J. Demsar, M. Kattan, and B. Zupan Nomograms for Visualization of Naive Bayesian Classifier / M. Mozina, J. Demsar, M. Kattan, B. Zupan // *In Proc. of PKDD*, 2004. – P. 337—348.
88. А. О. Олійник, С. О. Субботін та О. О. Олійник Еволюційні обчислення та програмування: навчальний посібник / А. О. Олійник, С. О. Субботін, О. О. Олійник. – Запоріжжя: ЗНТУ,, 2010.
89. В. І. Дубровін Методи оптимізації та їх застосування в задачах навчання нейронних мереж / В. І. Дубровін, С. О. Субботіню – Запоріжжя: ЗНТУ, 2003.
90. R. Haupt and S. Yaupr Practical genetic algorithms / R. Haupt, S. Yaupr // *New Jersey John Willey&Sons*, 2004.
91. А. Г. Івахненко, Ю. П. Зайченко, В. Д. Димитров Прийняття рішень на основі самоорганізації / А. Г. Івахненко, Ю. П. Зайченко, В. Д. Димитров. – М.: «Рад. радіо », 1976.

92. Б. П. Русын Структурно-лингвистические методы распознавания изображений в реальном времени / Б. П. Русын. – К.: Наук. думка, 1986.
93. T. Hastie, R. Tibshirani, and J. Friedman *The Elements of Statistical Learning* / T. Hastie, R. Tibshirani, J. Friedman. – Springer, 2001.
94. Kachikian and M. Emadi A Review of detector descriptors' on Object Tracking // *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, 2016. – Т. 5. – № 7. Р. – 5815–828.
95. А. Я. Білецький та П. О. Приставка Застосування поліноміального сплайну трьох змінних на основі В-сплайнів при опрацюванні результатів спостережень / А. Я. Білецький, П. О. Приставка // *Вісн. НАУ, К.: НАУ*, 2001. – №3(10). – С. 153–155.
96. M. M. Mukhedkar and S. B. Powalkar Fast face recognition based on Wavelet Transform on PCA / M. M. Mukhedkar, S. B. Powalkar // in *International Conference on Energy Systems and Applications*, Pune, 2015.
97. Cireşan, D. Multi-column deep neural networks for image classification / D. Cireşan, U. Meier, J. Schmidhuber // *Computer Vision and Pattern Recognition (CVPR)*. — 2012. — Pp. 3642–3649.
98. 16. Deng, L. The MNIST database of handwritten digit images for machine learning research / L. Deng // *IEEE Signal Processing Magazine*. — 2012. — no. 29.6. — Pp. 141–142.
99. Pedregosa, F. Scikit-learn: Machine learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort et al. // *The Journal of Machine Learning Research*. — 2011. — no. 12. — Pp. 2825–2830.
100. Hinton G., Deng L. and Yu D. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups, *IEEE Signal Processing Magazine*, pp. 82 – 97. 18 10 2012.
101. Krizhevsky A., Sutskever I. and Hinton G. ImageNet Classification with Deep Convolutional Neural Networks, *Advances in Neural Information Processing Systems* 25, pp. 1097-1105, 2012.

102. Bengio, Y. Learning deep architectures for AI / Y. Bengio // Foundations and trends in Machine Learning. — 2009. — no. 1. — Pp. 1–127.
103. Bengio, Y. Representation learning: A review and new perspectives / Y. Bengio, A. Courville, P. Vincent // Pattern Analysis and Machine Intelligence. — 2013. — no. 35(8). — Pp. 1798–1828.
104. Bengio, Y. Why does unsupervised pre-training help deep learning? / Y. Bengio, D. Erhan // The Journal of Machine Learning Research. — 2010. — no. 11. — Pp. 625–660.
105. Ciresan, D. Multi-column deep neural networks for image classification / D. Ciresan, U. Meier, J. Schmidhuber // Computer Vision and Pattern Recognition (CVPR). — 2012. — Pp. 3642–3649.
106. Deng, L. The MNIST database of handwritten digit images for machine learning research / L. Deng // IEEE Signal Processing Magazine. — 2012. — no. 29.6. — Pp. 141–142.
107. Krizhevsky, A. Imagenet classification with deep convolutional neural networks / A. Krizhevsky, I. Sutskever, G.E. Hinton // Advances in neural information processing systems. — 2012. — Pp. 1097–1105.
108. Pedregosa, F. Scikit-learn: Machine learning in Python / F. Pedregosa, G. Varoquaux, A. Gramfort et al. // The Journal of Machine Learning Research. — 2011. — no. 12. — Pp. 2825–2830.
109. Hinton G., Deng L. and Yu D. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups, IEEE Signal Processing Magazine, pp. 82 – 97. 18 10 2012.
110. Krizhevsky A., Sutskever I. and Hinton G. ImageNet Classification with Deep Convolutional Neural Networks, Advances in Neural Information Processing Systems 25, pp. 1097-1105, 2012.
111. Goldberger J., Roweis S., Hinton G. and Salakhutdinov R. Neighbourhood Components Analysis, in Neural Information Processing Systems (NIPS), Montreal, Canada, 2014.

112. Vinyals O., Blundell C., Lillicrap T., Kavukcuoglu K. and Wierstra D. Matching Networks for One Shot Learning, *Advances in Neural Information Processing Systems* 29, pp. 3630-3638, 2016.
113. C. Bassani. et al., 2010) C. Bassani, R. M. Cavalli, and S. Pignatti. Aerosol Optical Retrieval and Surface Reflectance from Airborne Remote Sensing Data over Land. *Sensors (Basel)* 10(7): 6421–6438, 2010. DOI: 10.3390/s100706421 PMID: 22163558.
114. Y. Bengio et al., 2007).
115. Y. Bengio., P. Lamblin, D. Popovici, and H. Larochelle. Greedy layer-wise training of deep networks, in *Proc. Neural Inf. Process. Syst.*, Cambridge, MA, USA, pp. 153–160, 2007.
116. (J. Bioucas-Dias et al., 2013) J. Bioucas-Dias et al., Hyperspectral remote sensing data analysis and future challenges, *Geosci. Remote Sens. Mag.*, v. 1, n. 2, pp. 6–36, 2013.
117. (K. Chatfield et al., 2014). K. Chatfield, K. Simonyan, A. Vedaldi, A. Zisserman. Return of the Devil in the Details: Delving Deep into Convolutional Nets. In *Proceedings of the British Machine Vision Conference*, Nottingham, UK, 1–5, September 2014.
118. (Y. Chen et al., 2015) Y. Chen, X. Zhao, and X. Jia, Spectra-spatial classification of hyperspectral data based on deep belief network, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 8, no. 6, pp. 2381–2392, 2015.
119. (R. K. Gangwar et al., 2014). R. K. Gangwar, A. K. Mathur, B. S. Gohil, and Sujit Basu. Neural network based retrieval of atmospheric temperature profile using AMSU-A observations, *International Journal of Atmospheric Sciences*, vol. 2014, Article ID 763060, 8 pages <http://dx.doi.org/10.1155/2014/763060>.
120. (P. Ghamisi et al., 2016) P. Ghamisi, Y. Chen, and X. Zhu, A self-improving convolution neural network for the classification of hyperspectral data, *IEEE Geoscience and Remote Sensing Letters*, v. 13, n. 10, pp. 1537–1541, 2016.

121. (K. He et al., 2010) K. He, X. Zhang, S. Ren, and J. Sun, Deep residual learning for image recognition, Open Access version, Computer Vision Foundation, 2010. <http://image-net.org/challenges/LSVRC/2015>;
<http://mscoco.org/dataset/#detections-challenge2015>.
122. (K. He et al., 2016) K. He, X. Zhang, S. Ren, and J. Sun, Deep residual learning for image recognition, IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
123. (G. Hinton et al., 2006 a) G. Hinton, and R. Salakhutdinov., Reducing the dimensionality of data with neural networks, *Science*, vol. 313. no. 5786, pp. 504–507, 2006.
124. (G. Hinton et al., 2006 b) G. E. Hinton, S. Osindero, and Y. Teh, A fast learning algorithm for deep belief nets, *Neural Computation*, vol. 18, no. 7, pp. 1527–1554, 2006.
125. (W. Hu et al., 2015) W. Hu, Y. Huang, L. Wei, F. Zhang, and H. Li, Deep convolutional neural networks for hyperspectral image classification, *Journal of Sensors*, v. 2015, n. 258619, 2015. <http://dx.doi.org/10.1155/2015/258619>.
126. (F. Hu et al., 2015). Fan Hu, Gui-Song Xia, Jingwen Hu and Liangpei Zhang. Transferring Deep Convolutional Neural Networks for the Scene Classification of High-Resolution Remote Sensing Imagery. *Remote Sens.* 2015, 7(11), 14680-14707; DOI:10.3390/rs71114680.
127. (Y. Jia et al., 2014). Y. Jia, E. Shelhamer, J. Donahue, S. Karayev, J. Long, R. Girshick, S. Guadarrama, T. Darrell, Caffe: Convolutional Architecture for Fast Feature Embedding. In *Proceedings of the ACM International Conference on Multimedia*, Orlando, FL, USA, 3–7 November 2014.
128. Krizhevsky et al., 2012). A. Krizhevsky, I. Sutskever, and G. Hinton, Imagenet classification with deep convolutional neural networks, *Advances in Neural Information Processing Systems (NIPS)*, Lake Tahoe, NV, USA, 3–8 December 2012; pp. 1097–1105.
129. (N. Kussul et al., 2017) N. Kussul, M. Lavreniuk, S. Skakun, and A. Shelestov, Deep learning classification of land cover and crop types using remote sensing data,

IEEE Geoscience and Remote Sensing Letters, DOI:10.1109/LGRS. 2017. 2681128.

130. (Z.L. Langford et al., 2017). Z. L. Langford, J. Kumar, and F.M. Hoffman. Convolutional Neural Network Approach for Mapping Arctic Vegetation using Multi-Sensor Remote Sensing Fusion. IEEE International Conference on Data Mining Workshops, 2017. DOI 10.1109/ICDMW.2017.48.

131. (J. Li. et al., 2013). J. Li, J.M Bioucas-Dias, and A. Plaza. Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning, IEEE Trans. Geosci. Remote Sens., vol. 51, no. 2, pp. 844–856, Feb. 2013.

132. (B. Liu et al., 2018). Bing Liu; Xuchu Yu; Anzhu Yu; Gang Wan. Deep convolutional recurrent neural network with transfer learning for hyperspectral image classification, J. of Applied Remote Sensing, 12(2), 2018. <https://doi.org/10.1117/1.JRS.12.026028>.

133. (J. Long et al., 2015) J. Long, E. Shelhamer, and T. Darrell, Fully convolutional networks for semantic segmentation, IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 2015.

134. Lyapustin et al., 2011) A. Lyapustin, Y. Wang, L. Laszlo, R. Kahn, Korkin, L. Remer, R. Levy, and J. S. Reid. Multiangle implementation of atmospheric correction (MAIAC): 2. Aerosol algorithm. JOURNAL OF GEOPHYS. RESEARCH, v. 116, D03211, 2011. DOI:10.1029/2010JD014986, 2011.

135. K. Makantasis et al., 2015) K. Makantasis, K. Karantzalos, A. Doulamis, and N. Doulamis, Deep supervised learning for hyperspectral data classification through convolutional neural networks, IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2015.

136. (L. Mou et al., 2017, a)) L. Mou, P. Ghamisi, and X. X. Zhu, Fully conv-deconv network for unsupervised spectral-spatial feature extraction of hyperspectral imagery via residual learning, IEEE International Geoscience and Remote Sensing Symposium (IGARSS), 2017.

137. (L. Mou et al., 2017 b)) L. Mou, P. Ghamisi, and X. Zhu, Unsupervised spectralspatial feature learning via deep residual conv-deconv network for

hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, in press.

138. (L. Mou et al., 2017 c)] L. Mou, P. Ghamisi, and X. Zhu, Deep recurrent neural networks for hyperspectral image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 55, no. 7, pp. 3639–3655, 2017.

139. (T. Postadjiana et al., 2017). T. Postadjiana, A. Le Brisa, H. Sahbib, C. Malleta. Investigating the potential of deep neural networks for large-scale classification of very high resolution satellite images. *Remote Sensing and Spatial Information Sciences*, Volume IV-1/W1, pp. 183 – 190, 2017.

140. Plaza et al., 2009). Plaza A, Plaza J., and Martin G, Incorporation of spatial constraints into spectral mixture analysis of remotely sensed hyperspectral data,” in *Proc. IEEE Int. Workshop Mach. Learn. Signal Process.*, Grenoble, France, 2009, pp. 1–6.

141. (T. Postadjiana et al., 2017). T. Postadjiana, A. Le Brisa, H. Sahbib, C. Malleta. Investigating the potential of deep neural networks for large-scale classification of very high resolution satellite images. *Remote Sensing and Spatial Information Sciences*, Volume IV-1/W1, pp. 183 – 190, 2017.

142. Romero et al., 2016) A. Romero, C. Gatta, and G. Camps-Valls, Unsupervised deep feature extraction for remote sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 3, pp. 1349–1362, 2016.

143. (R. Salakhutdinov et al., 2009). R. Salakhutdinov, and G.E. Hinton. Deep Boltzmann machines, in *Proc. Int. Conf. Artif. Intell. Statist.*, Clearwater Beach, FL, USA, pp. 448–455, 2009.

144. Santara et al., 2017) A. Santara, K. Mani, P. Hatwar, A. Singh, A. Garg, K. Padia, and P. Mitra, Bass net: Band-adaptive spectral-spatial feature learning neural network for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, v. 55, n. 9, pp. 5293–5301, 2017.

145. (P. Sermanet et al., 2014). P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus, Y. LeCun. OverFeat: Integrated Recognition, Localization and Detection

- using Convolutional Networks. In Proceedings of the International Conference on Learning Representations. CBLIS, Banff, AL, Canada, 14–16, April 2014.
146. (K. Simonyan et al., 2013) K. Simonyan, A. Vedaldi, A. Zisserman, Deep inside convolutional networks: visualizing image classification models and saliency maps. arXiv preprint arXiv:1312.6034, 2013.
147. (K. Simonyan et al., 2015). K. Simonyan, A. Zisserman. Very deep convolutional networks for large-scale image recognition. In Proceedings of the International Conference on Learning Representations (ICLR), San Diego, CA, USA, 7–9 May 2015.
148. (C. Szegedy et al., 2015) C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, A. Rabinovich. Going deeper with convolutions. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 7–12 June 2015; pp. 1–9.
149. (P. Vincent et al., 2010) P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P. Manzagol, Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion, *Journal of Machine Learning Research*, vol. 11, pp. 3371–3408, 2010.
150. (J. Yue et al., 2015). Jun Yue, Wenzhi Zhao, Shanjun Mao & Hui Liu, Spectral-spatial classification of hyperspectral images using deep convolutional neural networks. *Remote Sensing Letters*, v. 6, pp. 468-477, 2015.
151. (J. Yue et al., 2016). Jun Yue, Shanjun Mao & Mei Li. A deep learning framework for hyperspectral image classification using spatial pyramid pooling. *Remote Sensing Letters*, v. 7, pp. 875-884, 2016.
152. (M.D. Zeiler et al., 2014) M.D. Zeiler, R. Fergus. Visualizing and understanding convolutional networks. In Proceedings of the European Conference on Computer Vision, Zurich, Switzerland, 6–12 September 2014; pp. 818–833.
153. (W. Zhao et al., 2016) W. Zhao and S. Du, Spectral-spatial feature extraction for hyperspectral image classification: A dimension reduction and deep learning approach, *IEEE Transactions on Geoscience and Remote Sensing*, v. 54, n. 8, pp. 4544–4554, 2016.

154. (Z. Zhen et al., 2014 a). Z. Zhen, and G. Wang. Learning discriminative hierarchical features for. object recognition, *IEEE Signal Process. Lett.*, vol. 21, no. 9, pp. 1159–1163, 2014.
155. (P. Zhong et al., 2017). Ping Zhong, Zhiqiang Gong. A Hybrid DBN and CRF Model for Spectral-Spatial Classification of Hyperspectral Images. *Stat., Optim. Inf. Comput.*, v. 5, pp 75–98. 2017.
156. Басс Л.П., Кузьмина М.Г., Николаева О.В. Сверточные нейронные сети с глубоким обучением в задачах обработки гиперспектральных спутниковых данных 30 источников) https://keldysh.ru/papers/2018/rep2018_282.pdf
157. Y. Tarabalka, J. A. Benediktsson, and J. Chanussot, “Spectral-spatial classification of hyperspectral imagery based on partitional clustering techniques,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 47, no. 8, pp. 2973–2987, 2009.
158. W. Li, S. Prasad, F. James, and B. Lour, “Locality-preserving dimensionality reduction and classification for hyperspectral image analysis,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 50, no. 4, pp. 1185–1198, 2012.
159. G. Mountrakis, J. Im, and C. Ogole, “Support vector machines in remote sensing: a review,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 66, no. 3, pp. 247–259, 2011.
160. J. Li, J. M. Bioucas-Dias, and A. Plaza, “Spectral-spatial classification of hyperspectral data using loopy belief propagation and active learning,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 51, no. 2, pp. 844–856, 2013.
161. F. Ratle, G. Camps-Valls, and J. Weston, “Semisupervised neural networks for efficient hyperspectral image classification,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 5, pp. 2271–2282, 2010.
162. D. C. Cireşan, U. Meier, J. Masci, L. M. Gambardella, and J. Schmidhuber, “Flexible, high performance convolutional neural networks for image classification,” in *Proceedings of the 22nd International Joint Conference on Artificial Intelligence (IJCAI '11)*, vol. 22, pp. 1237–1242, July 2011.

163. P. Sermanet and Y. LeCun, "Traffic sign recognition with multi-scale convolutional networks," in Proceedings of the International Joint Conference on Neural Network (IJCNN '11), pp. 2809–2813, IEEE, August 2011.
164. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in Proceedings of the Advances in Neural Information Processing Systems 25 (NIPS '12), pp. 1097–1105, 2012.
165. D. Ciregan, U. Meier, and J. Schmidhuber, "Multi-column deep neural networks for image classification," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR '12), pp. 3642–3649, IEEE, June 2012.
166. R. Girshick, J. Donahue, T. Darrell, and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR '14), pp. 580–587, IEEE, June 2014.
167. C. Farabet, C. Couprie, L. Najman, and Y. LeCun, "Learning hierarchical features for scene labeling," IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 35, no. 8, pp. 1915–1929, 2013.
168. P. Sermanet, S. Chintala, and Y. LeCun, "Convolutional neural networks applied to house numbers digit classification," in Proceedings of the 21st International Conference on Pattern Recognition (ICPR '12), pp. 3288–3291, IEEE, November 2012.
169. 73) Y. Taigman, M. Yang, M. Ranzato, and L. Wolf, "DeepFace: closing the gap to human-level performance in face verification," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR '14), pp. 1701–1708, Columbus, Ohio, USA, June 2014.
170. T. N. Sainath, A.-R. Mohamed, B. Kingsbury, and B. Ramabhadran, "Deep convolutional neural networks for LVCSR," in Proceedings of the 38th IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '13), pp. 8614–8618, IEEE, Vancouver, Canada, May 2013.

171. O. Abdel-Hamid, A.-R. Mohamed, H. Jiang, and G. Penn, “Applying convolutional neural networks concepts to hybrid NN-HMM model for speech recognition,” in Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '12), pp. 4277–4280, IEEE, March 2012.
172. Y. Chen, Z. Lin, X. Zhao, G. Wang, and Y. Gu, “Deep learning-based classification of hyperspectral data,” IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, vol. 7, no. 6, pp. 2094–2107, 2014.
173. Y. A. LeCun, L. Bottou, G. B. Orr, and K.-R. Müller, “Efficient backprop,” in Neural Networks: Tricks of the Trade, pp. 9–48, Springer, Berlin, Germany, 2012.
174. J. Bergstra, F. Bastien, O. Breuleux et al., “Theano: deep learning on GPUs with python,” in Proceedings of the NIPS 2011, Big Learning Workshop, pp. 712–721, Granada, Spain, December 2011.
175. Y. Jia, E. Shelhamer, J. Donahue et al., “Caffe: convolutional architecture for fast feature embedding,” in Proceedings of the ACM International Conference on Multimedia, pp. 675–678, ACM, Orlando, Fla, USA, November 2014.
176. N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, “Dropout: a simple way to prevent neural networks from overfitting,” The Journal of Machine Learning Research, vol. 15, no. 1, pp. 1929–1958, 2014.
177. <https://www.hindawi.com/journals/js/2015/258619/>
178. [1, Таблица 4] Aomei Li An Improved FAST+SURF Fast Matching Algorithm / Aomei Li, Wanli Jiang, Weihua Yuan, Dehui Dai, Siyu Zhang, Zhe Wei // Procedia Computer Science, 2017. – Vol. 107. – pp. 306-312.
179. [2, Таблица 4] Kachikian S. A Review of detector descriptors’ on Object Tracking [Text] / S. Kachikian, M. Emadi // International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, 2016, vol. 5, № 7, pp. 5815-5828.
180. [3, Таблица 4] Sung-Joo Y. Development of Stereo Visual Odometry Based on Photogrammetric Feature Optimization / Y.Sung-Joo, T. Kim // Remote Sensing. – 2019. – Vol. 11. – pp. 1-17.

181. [4 Таблиця 4] Приставка П.О., Сорокопуд В. І., Чирков А.В. Експериментальний зразок автоматизованої системи пошуку підозрілих об'єктів на відео з безпілотного повітряного судна// Системи озброєння і військова техніка. –2017. –№2(50). –С. 26 –32.
182. [5 Таблиця 4] Serdar Selim. Semi-automatic Tree Detection from Images of Unmanned Aerial Vehicle Using Object-Based Image Analysis Method / Serdar Selim, Namik Kemal Sonmez, Mesut Coslu, Isin Onur // Journal of the Indian Society of Remote Sensing, 2019.– Vol. 47, Is. 2. – pp 193–200.
183. [6 Таблиця 4] Kliushnikov I. M. Using automated battery e replacement stations for the persistent operation of UAV-enabled wireless networks during NPP post-accident monitoring [Text] / I. M. Kliushnikov, H. V. Fesenko, V. S. Kharchenko // Radioelektronic and computer systems. – 2019. – №4(92). – P. 30-38. DOI:10.32620/reks.2019.4.03
184. [7 Таблиця 4] Jafari M. Intelligent Control for Unmanned Aerial Systems with System Uncertainties and Disturbances Using Artificial Neural Network / M. Jafari, H. Xu // Drones, 2018. – №2(3). – pp. 24-36.
185. [8 Таблиця 4] Deep Learning Approach for Car Detection in UAV Imagery [Text] / H. Ammour, A. Alhichri, Y. Bazi,, B. Benjdira, N. Ammour // Remote Sens, 2017. – Vol. 9. – № 4. – P. 1-15
186. А. С. Довбиш, Основи проектування інтелектуальних систем, Суми: СумДУ, 2009.
187. А. С. Довбиш, А. В. Васильєв та В. О. Любчак, Інтелектуальні інформаційні технології в електронному навчанні, Суми: СумДУ, 2013.
188. Д. Р. Белоусов и И. Э. Фролов, " Методологические и предметные особенности прогнозирования научно-технологического развития в современных условиях ", Проблемы прогнозирования, № 3, pp. 88-105, 2008.
189. Y. Li, H. Lu, L. Zhang, J. Zhu, S. Yang and et al., Softer Computing in Information Communication Technology, Berlin, Springer Berlin Heidelberg, 2012.
190. А. С. Довбиш, В. І. Зимовець та З. С. Козлов "Інформаційно-екстремальний алгоритм навчання системи функціонального контролю

электроприводу шахтної підйомної машини", *Радиоэлектроника и информатика*, № 4, с. 58- 63, 2017.

191. А. С. Довбиш та І. В. Шелехов, *Основи теорії розпізнавання образів*, Суми: Сумський державний університет, 2015.

192. S. Dovbysh, M. M. Budnyk and V. V. Moskalenko, "Information-extreme algorithm for optimizing parameters of hyperellipsoidal containers of recognition classes", *Journal of automation and information sciences*, vol. 44, no. 10, pp. 35-44, 2012 doi: 10.1615/JAutomatInfScien.v44.i10.30

193. Petr Dolezel, Pavel Skrabanek and Lumir Gago, "Pattern recognition neural network as a tool for pest birds detection" *Computational Intelligence (SSCIIEEE Symposium Series on)*, Athens, Greece, 2016, pp. 1-6. doi: 10.1109/HSI.2008.4581457

194. В. А. Гороховатский, *Структурный анализ и интеллектуальная обработка данных в компьютерном зрении (монография)*, Харьков: Компания СМІТ, 2014.

195. T. Efendigil, S. Önüt, and C. Kahraman, "A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: a comparative analysis", *Expert Systems with Applications*, vol. 36, no. 3, pp. 6697–6707, 2009.

196. А. С. Довбиш, В. В. Москаленко, та А. С. Риждова, "Інтелектуальна автоматизована система керування з оптимізацією часових параметрів аналізу вхідних даних", *Вісник Сумського державного університету. Серія "Технічні науки"*, № 3, с. 7-14, 2013.

197. S. Subbotin, "The neuro-fuzzy network synthesis and simplification on precedents in problems of diagnosis and pattern recognition", *Optical Memory and Neural Networks (Information Optics)*, vol. 22, № 2, pp. 97-103, 2013. doi:10.3103/s1060992x13020082.

198. Y. Shi and M. Mizumoto, "An improvement of neuro-fuzzy learning algorithm for tuning fuzzy rules", *Fuzzy sets and systems*, vol. 118, no. 2, pp. 339-350, 2001.

199. M. Fraire, "Statistical methods for exploratory multidimensional data analysis on time use", *Statistica*, vol. 69, pp. 317-341, 2009. doi:10.6092/issn.1973-2201/3573.
200. С. А. Субботин, А. А. Олейник, В. К. Яценко "Отбор информативных признаков на основе модифицированного метода муравьиных колоний", *Радіоелектроніка та інформатика*, № 1, с. 65-69, 2006.
201. Р. А. Нейдорф и А. А. Дервянкина, "Решение многоэкстремальных задач методом делящихся роев", *Вестник Донского государственного технического университета*, т. 10, №. 4, с. 492-499, 2010.