

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет                      Комп'ютерної інженерії та управління  
Кафедра                        Комп'ютерних інтелектуальних технологій та систем

## **КВАЛІФІКАЦІЙНА РОБОТА**

### **Пояснювальна записка**

рівень вищої освіти                      другий (магістерський)

Інтелектуальний аналіз даних з краудсорсингу у кризових ситуаціях

Виконав:

здобувач 2 року навчання,

групи КІТм-23-1

Артем СКРЯБІН

Спеціальність 123 Комп'ютерна інженерія

Тип програми освітньо-професійна

Освітня програма Комп'ютерні

інтелектуальні технології

Керівник      проф. Наталія АКСАК

Допускається до захисту

Зав. кафедри

Олег РУДЕНКО

(підпис)

2024 р.

Харківський національний університет радіоелектроніки

Факультет	Комп'ютерної інженерії та управління
Кафедра	Комп'ютерних інтелектуальних технологій та систем
Рівень вищої освіти	другий (магістерський)
Спеціальність	123 Комп'ютерна інженерія
Тип програми	освітньо-професійна
Освітня програма	Комп'ютерні інтелектуальні технології

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

« \_\_\_\_\_ » \_\_\_\_\_ 202\_ р.

## ЗАВДАННЯ

### НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві \_\_\_\_\_ Скрябіну Артему Олександровичу  
(прізвище, ім'я, по батькові)

1. Тема роботи \_\_\_\_\_ Інтелектуальний аналіз даних з краудсорсингу у кризових ситуаціях

затверджена наказом по університету від “ 28 ” жовтня 2024 р. № 1156Ст

2. Термін подання студентом роботи до екзаменаційної комісії \_\_\_\_\_ 13.01.2025

3. Вхідні дані до роботи \_\_\_\_\_

Модальність зображень \_\_\_\_\_

Текстова модальність \_\_\_\_\_

Кризові ситуації \_\_\_\_\_

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

Мультимодальний аналіз, , \_\_\_\_\_

Краудсорсинг \_\_\_\_\_

Мультимодальна модель надання гуманітарної допомоги \_\_\_\_\_

Глибоке навчання \_\_\_\_\_

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (п.5 включається до завдання за рішенням кафедри)  
10 слайдів

6. Консультанти розділів роботи и (п.6 включається до завдання за наявністю консультантів згідно до наказу, зазначеному у п.1)

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Огляд і аналіз сучасного стану поставленої задачі	28.10.24 - 10.11.24	Виконано
2	Постановка задачі кваліфікаційної роботи	11.11.24 - 13.11.24	Виконано
3	Обґрунтування мети вирішення поставленої задачі	14.11.24 - 20.11.24	Виконано
4	Вибір та розробка мультимодального підходу до обробки гуманітарної інформації	21.11.24 - 18.12.24	Виконано
5	Оформлення матеріалів кваліфікаційної роботи	19.12.24 - 08.01.25	Виконано
6	Розробка презентації	09.01.25 - 13.01.25	Виконано
7	Подання кваліфікаційної роботи на рецензування	16.01.2025	Виконано
8	Попередній захист	21.01.2025	Виконано
9	Захист роботи	23.01.2024	Виконано

Дата видачі завдання 28 жовтня 2024 р.

Здобувач \_\_\_\_\_  
(підпис)

Керівник роботи \_\_\_\_\_  
(підпис)

Проф Наталія АКСАК \_\_\_\_\_  
(посада, ім'я, прізвище)

## РЕФЕРАТ

Пояснювальна записка кваліфікаційної роботи: 77 с., 6 рис., 5 таблиць, 2 дод., 32 джерела.

НЕЙРОННІ МЕРЕЖІ, ГЛИБОКЕ НАВЧАННЯ З ПІДКРИТТЯМ,  
МУЛЬТИМОДАЛЬНИЙ АНАЛІЗ, КРАУДСОРСИНГ, КРИЗОВІ СИТУАЦІЇ,  
ІНТЕЛЕКТУАЛЬНИЙ АНАЛІЗ

Метою роботи є розробка підходу до інтелектуального аналізу даних, отриманих із краудсорсингових платформ під час кризових ситуацій, для оперативного виявлення критичних зон, ідентифікації потреб постраждалих і підвищення ефективності процесу прийняття рішень щодо реагування на кризу.

*Об'єктом дослідження* магістерської кваліфікаційної роботи є процес збору, обробки, аналізу та використання даних, що отримані з краудсорсингових платформ під час кризових ситуацій, для прийняття рішень в умовах кризи

*Предмет дослідження* – методи, алгоритми та технології інтелектуального аналізу даних, отриманих із краудсорсингових платформ.

У роботі запропоновано метод мультимодального аналізу для одночасного опрацювання текстових даних та зображень.

Розроблений фреймворк демонструє свою ефективність у класифікації даних з краудсорсингу, генеруючи синтетичні зображення для незбалансованих наборів даних та інтерпретуючи результати для надання своєчасної допомоги після стихійних лих.

## ABSTRACT

Master's thesis:: 77 pages, 6 figures, 5 tables, 2 appendices, 32 sources.

NEURAL NETWORKS, DEEP REINFORCEMENT LEARNING, MULTIMODAL ANALYSIS, CROWDSOURCING, CRISIS SITUATIONS, INTELLECTUAL ANALYSIS

The aim of the work is to develop an approach to intelligent analysis of data obtained from crowdsourcing platforms during crisis situations to promptly identify critical areas, identify the needs of victims, and increase the efficiency of the decision-making process regarding crisis response.

The object of research of the master's qualification thesis is the process of collecting, processing, analyzing and using data obtained from crowdsourcing platforms during crisis situations for decision-making in crisis conditions. The subject of research is methods, algorithms and technologies of intelligent analysis of data obtained from crowdsourcing platforms.

In the work, we propose a multimodal analysis method for simultaneous processing of text and image data.

The introductory part of the study shows that the use of the latest BERT and ConvNeXt models significantly improves the classification of humanitarian aid. The developed framework demonstrates its effectiveness in crowdsourced data classification by generating synthetic images for imbalanced datasets and interpreting the results to provide timely aid after natural disasters.

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет Комп'ютерної інженерії та управління  
Кафедра Комп'ютерних інтелектуальних технологій та систем

## АНОТАЦІЯ

### КВАЛІФІКАЦІЙНОЇ РОБОТИ

Інтелектуальний аналіз даних з краудсорсингу у кризових ситуаціях

---

---

---

Виконав:

здобувач II курсу, групи КІТм-23-1

Артем СКРЯБІН

Спеціальність 123 Комп'ютерна інженерія

Тип програми освітньо-професійна

Освітня програма Комп'ютерні інтелектуальні  
технології

Керівник проф, Наталія АКСАК

2024 р.

## АНОТАЦІЯ

Скрябін А.О. Інтелектуальний аналіз даних з краудсорсингу у кризових ситуаціях. – Магістерська кваліфікаційна робота.

Аналіз краудсорсингових даних із використанням методів машинного навчання допомагає автоматично виявляти закономірності, класифікувати дані та знаходити "гарячі точки". Наприклад, алгоритми можуть визначати місця з найбільшою концентрацією повідомлень про допомогу. Одночасний аналіз тексту та зображень у даних з краудсорсингу може покращити якість інформації про гуманітарну допомогу.

Аналіз даних з краудсорсингу під час кризової ситуації означає процес збору, обробки та інтерпретації даних, зібраних від великої кількості людей (краудсорсинг), з метою розуміння та управління інформацією під час кризової ситуації.

Краудсорсинг підвищує рівень прозорості та залучення громадян до вирішення кризових ситуацій. Люди відчують свою причетність до подолання кризи, що підвищує рівень довіри до органів управління чи гуманітарних організацій.

Під час природних катастроф, таких як землетруси чи повені, краудсорсингові дані можуть надходити від людей, які повідомляють про ситуацію в реальному часі. Це допомагає швидше реагувати на події та приймати необхідні рішення.

У випадку терористичних атак чи масових заворушень, дані зібрані від очевидців через соціальні мережі або спеціальні платформи, можуть допомогти зрозуміти масштаб ситуації та координацію зусиль рятувальних служб.

*Метою роботи* є розробка підходу до інтелектуального аналізу даних, отриманих із краудсорсингових платформ під час кризових ситуацій, для оперативного виявлення критичних зон, ідентифікації потреб постраждалих і підвищення ефективності процесу прийняття рішень щодо реагування на кризу.

*Об'єктом дослідження* магістерської кваліфікаційної роботи є процес збору, обробки, аналізу та використання даних, що отримані з краудсорсингових платформ під час кризових ситуацій, для прийняття рішень в умовах кризи

*Предмет дослідження* – методи, алгоритми та технології інтелектуального аналізу даних, отриманих із краудсорсингових платформ.

*Методи дослідження.* Аналіз і синтез – вивчення наукової літератури, існуючих підходів до інтелектуального аналізу даних і краудсорсингу, їх узагальнення та інтеграція; моделювання – створення математичних і комп'ютерних моделей для аналізу даних із краудсорсингових платформ; методи машинного навчання – використання алгоритмів класифікації, кластеризації, регресії та нейронних мереж для аналізу даних; методи аналізу зображень та відео – застосування алгоритмів комп'ютерного зору для ідентифікації об'єктів на фото чи відеоматеріалах; геопросторовий аналіз - аналіз даних із геолокацією для виявлення критичних зон чи місць зосередження подій; використання графіків, теплових карт, географічних інформаційних систем (GIS) для представлення результатів аналізу даних у зрозумілому вигляді.

*Наукова новизна.* Розроблено новий підхід до інтеграції текстових, візуальних і геопросторових даних із соціальних мереж та спеціалізованих платформ для прийняття рішень у кризових ситуаціях. Запропоновано алгоритм класифікації текстових і візуальних даних із використанням передових моделей машинного навчання (BERT, ResNet, ALBERT), що забезпечує високу точність у класифікації гуманітарної інформації.

*Практична цінність отриманих результатів.* Методи, що поєднують OCR та мультимодальні підходи, можуть бути використані для аналізу даних у сферах моніторингу інфраструктури, підтримки постраждалих та оцінки збитків.

Ці результати мають значний потенціал для впровадження у системах кризового реагування, платформ для гуманітарної допомоги та автоматизованих системах аналізу соціальних медіа.

*Перший розділ* присвячено аналізу краудсорсингу як інструменту для збору, обробки та аналізу даних у кризових ситуаціях, таких як стихійні лиха, техногенні катастрофи чи соціальні кризи. Розглянуто джерела краудсорсингових даних, зокрема соціальні мережі, мобільні додатки та спеціалізовані платформи, а також типи даних (текстові повідомлення, зображення, відео, геолокаційні дані тощо). Окреслено

проблеми, пов'язані з достовірністю, великими обсягами інформації, конфіденційністю та інтеграцією даних.

Особливу увагу приділено використанню методів інтелектуального аналізу, таких як обробка природної мови, алгоритми машинного навчання, комп'ютерний зір, геопросторовий аналіз і Big Data платформи, для автоматизації обробки краудсорсингових даних. Наголошено на значущості швидкого аналізу даних для прийняття рішень, прогнозування розвитку кризових ситуацій та оптимізації розподілу ресурсів. Окреслено перспективи розвитку, які включають застосування глибокого навчання, інтегрованих платформ та посилення захисту конфіденційних даних.

У *другому розділі* розглянуто основні види модальностей зображень, що включають різноманітні методи та технології отримання, обробки й аналізу візуальних даних. Серед них:

- Оптичні зображення, отримані за допомогою камер, що реєструють світло, відбиття від об'єктів.
- Медичні зображення, такі як рентгенографія, КТ, МРТ та УЗД, які використовуються для діагностики та лікування.
- Супутникові та авіаційні зображення, що застосовуються у картографії, моніторингу довкілля та розвідці природних ресурсів.
- Інфрачервоні зображення, що відображають теплові характеристики об'єктів і застосовуються у технічних та наукових дослідженнях.
- Мікроскопічні зображення, які дозволяють досліджувати мікроскопічні об'єкти, такі як клітини або мікроорганізми.

Кожен вид модальностей має унікальні особливості, що визначають специфіку їх використання. У розділі підкреслюється значення спеціалізованих методів аналізу для кожного типу зображень, залежно від їх характеристик та цілей застосування.

Також наведений опис трьох основних етапів анотації в наборі даних CrisisMMD, призначеного для досліджень у сфері мультимодального аналізу гуманітарної інформації. CrisisMMD включає текстові й графічні дані (твітів і зображень), що дозволяє дослідникам аналізувати кризові ситуації за допомогою

сучасних мультимодальних підходів. Основна мета анотації – забезпечення структурованих міток для навчання моделей штучного інтелекту, спрямованих на підтримку гуманітарної допомоги. У розділі також обговорюються виклики мультимодального аналізу, такі як незбалансованість даних і складнощі інтерпретації, та розглядаються рішення, включаючи використання синтетичних даних і передових моделей глибокого навчання (BERT, ALBERT, RegNetY320 тощо).

У розділі 3 описано проблему обробки гуманітарної інформації із соціальних мереж під час природних лих, таких як землетруси, урагани чи повені. Через значний обсяг даних ручна обробка є занадто повільною для ефективного реагування гуманітарних організацій. Запропоновано автоматичну класифікацію текстових і візуальних даних, яка забезпечує ідентифікацію критичних повідомлень (закликів про допомогу, даних про постраждалих, інформації про пошкодження інфраструктури тощо).

Основна мета — розробка мультимодальної моделі машинного навчання, яка обробляє текстові й візуальні дані одночасно для підвищення точності класифікації. Вхідними даними є пари текстів та зображень із соціальних мереж, зокрема набору CrisisMMD, що містить 4383 анотовані пари. Кожна пара віднесена до певної категорії гуманітарної інформації.

Алгоритм класифікації включає:

Попередню обробку даних, що передбачає очищення тексту та нормалізацію зображень.

Розробку мультимодальної моделі, яка поєднує текстові ознаки, отримані з BERT, та візуальні ознаки, витягнуті з моделей ResNet або EfficientNet, для класифікації категорій.

Навчання моделі на основі набору даних CrisisMMD з використанням оптимізатора Adam і метрики крос-ентропії.

Оцінку моделі за точністю, повнотою та F1-мірою для кожної категорії.

Результатом є модель, яка демонструє високу точність класифікації ключових категорій (наприклад, 87% для пошкодженої інфраструктури та 83% для постраждалих осіб), забезпечуючи оперативну обробку інформації в режимі

реального часу.

У розділі 4 описано застосування алгоритмів оптичного розпізнавання символів (OCR) для вилучення тексту із зображень, отриманих із твітів у соціальних мережах, у контексті гуманітарних досліджень. OCR дозволяє перетворювати текст із зображень у машиночитний формат, що забезпечує подальшу автоматизовану обробку. Процес OCR охоплює кілька етапів:

1. Попередню обробку зображень для покращення їх якості.
2. Розпізнавання символів і перетворення їх у текст.
3. Корекцію помилок за допомогою контексту чи словників.
4. Виведення тексту у зручному текстовому форматі.

Окрім OCR, розглядаються методи виявлення об'єктів на зображеннях, які дозволяють класифікувати та локалізувати об'єкти. Для цього використовуються моделі машинного навчання, такі як YOLO, R-CNN, SSD та Faster-RCNN.

У розділі представлено схему аналізу даних із соціальних мереж, що об'єднує текстові й візуальні ознаки. Зображення проходять попередню обробку, включаючи покращення, а текстові дані — очищення й нормалізацію. Екстракція тексту із зображень здійснюється за допомогою OCR, а для виявлення об'єктів застосовується Faster-RCNN Inception ResNet V2.

Для усунення дисбалансу в даних використовується генерація синтетичних зображень на основі GAN. Це дозволяє збільшити обсяг даних у категоріях із недостатнім представленням.

Загальний підхід забезпечує інтеграцію текстових і візуальних даних, підвищуючи точність класифікації гуманітарної інформації в соціальних мережах.

Також розглянуто застосування моделі ALBERT (A Lite BERT) для вилучення текстових ознак у мультимодальному аналізі. ALBERT — це оптимізована версія BERT, розроблена для підвищення ефективності та зменшення обчислювальних витрат, що досягається шляхом зменшення кількості параметрів моделі через поділ словникових ембеддингів на дві матриці. Модель також замінює завдання Next Sentence Prediction у BERT новим механізмом регуляризації, що покращує розуміння міжреченневих відносин.

ALBERT демонструє високі результати в задачах класифікації текстів, аналізу тональності та питань-відповідей, зберігаючи точність порівнянню або кращу за оригінальну BERT. У дослідженні для обробки текстової модальності використовували TensorFlow Hub, тоді як Keras застосовувався для роботи з іншими компонентами моделі.

Розділ також описує стратегію раннього злиття мультимодальних ознак, яка покращує продуктивність у порівнянні з пізнім злиттям. Механізм перехресної уваги додатково підвищує точність, дозволяючи моделі зосереджуватись на ключових аспектах даних. Для вирішення проблеми незбалансованості даних використовуються фокальні втрати, які мінімізують вплив легко передбачуваних прикладів, дозволяючи моделі краще навчатися на складних даних. Це робить ALBERT ефективним інструментом для аналізу текстової інформації в умовах складних та незбалансованих задач.

НЕЙРОННІ МЕРЕЖІ, ГЛИБОКЕ НАВЧАННЯ З ПІДКРИТТЯМ,  
МУЛЬТИМОДАЛЬНИЙ АНАЛІЗ, КРАУДСОРСИНГ, КРИЗОВІ СИТУАЦІЇ,  
ІНТЕЛЕКТУАЛЬНИЙ АНАЛІЗ

Публікації здобувача за темою роботи:

1. Скрябін А. О. Моделювання конфліктів і співпраці при розподілі ресурсів під час кризової ситуації Комп'ютерні інтелектуальні системи та мережі. Матеріали XVII Всеукраїнської науково практичної WEB конференції аспірантів, студентів та молодих вчених– Кривий Ріг: 2024.С. 243-245

Використані публікації керівника та співробітників кафедри, що становлять теоретичну базу роботи

1. Axak N., Korablyov M., Rosinskiy D. MapReduce Hadoop Models for Distributed Neural Network Processing of Big Data Using Cloud Services / Advances in Intelligent Systems and Computing IV. / Editors: Shakhovska, Natalya; Medykovskyy, Mykola O., Springer, 2019. – pp. 387 – 400. ISSN: 2194-5357 //doi.org/10.1007/978-3-030-33695-

0 (Входить до міжнародної наукометричної бази Scopus)

2. Axak N, Tatarnykov A. Development of Computer Vision Based Model to Support Learning Process. Proceedings of the 7th International Conference, COLINS-2023. Volume IV: Poster and Student Workshop, pp. 76-87 ISSN 2523-4013

3. Н.Г. Аксак, Н.М. Сердюк, Система віддаленого моніторингу та прогнозування стану здоров'я працівника // Інформаційні технології та системи: монографія / за заг. ред . В. С. Пономаренка. - Х. : Видавництво «Стиль-іздат», 2020. 174 с.

4. Mykola Korablyov, Oleksandr Fomichov, Natalia Axak. Classification of objects based on a tree-shaped artificial immune network model / Advances in Intelligent Systems and Computing V. / Editors: Shakhovska, Natalya; Medykovskyy, Mykola O., Springer, 2020. – pp. 160-172.

## ЗМІСТ

ВСТУП	16
1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ	18
1.1 Краудсорсинг	18
1.2 Огляд літератури	20
1.3 Постановка проблеми	23
2 МОДАЛЬНІСТЬ ЗОБРАЖЕНЬ	26
2.1 Основні види модальностей зображень	26
2.2 Гуманітарні дослідження під час надзвичайних ситуацій	28
2.3 Етапи анотації в наборі даних CrisisMMD	38
3 МУЛЬТИМОДАЛЬНА МОДЕЛЬ НАДАННЯ ГУМАНІТАРНОЇ ДОПОМОГИ	41
3.1 Класифікація гуманітарної інформації в соцмережах під час лиха	41
3.2 Мультимодальна модель класифікації	43
3.3 Інструменти для роботи з моделями	45
4 МЕТОД ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ КРАУДСОРСИНГОВИХ ДАНИХ	48
4.1 Алгоритм оптичного розпізнавання символів OCR	48
4.2 Модель ALBERT	53
4.3 Фреймворк, що ґрунтується на методі проб і помилок	55
4.4 Програмна реалізація аналізу даних з краудсорсингу	59
4.5 Підхід до інтелектуального аналізу краудсорсингових даних	62
ВИСНОВКИ	65
ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ	67
ДОДАТОК А Графічний матеріал кваліфікаційної роботи	
ДОДАТОК Б Приклади краудсорсингових даних	

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ  
І ТЕРМІНІВ

ШІ – Штучний інтелект

DL – (Deep learning) глибокого навчання.

ML – (Machine learning) машинне навчання.

NLP networks – (Natural Language Processing networks) мережі обробки природної мови.

GAN – (Generative adversarial networks) Генеративні змагальні мережі.

SVM – Support Vector Machine

## ВСТУП

Застосування інтелектуального аналізу даних має потенціал для усунення поточних недоліків у наданні гуманітарної допомоги під час стихійних лих.

Краудсорсинг дозволяє збирати інформацію в реальному часі від великої кількості учасників, що є критично важливим у кризових ситуаціях (наприклад, природні катаклізми, техногенні аварії чи соціальні конфлікти). Такий підхід допомагає швидко виявляти основні осередки проблем, потреби постраждалих та змінювати стратегію реагування.

Залучення великої кількості людей із різних регіонів дозволяє отримати багатогранну та локалізовану інформацію, яка може бути недоступною через офіційні канали. Це включає текстові повідомлення, фото, відео, геолокаційні дані тощо.

Аналіз зібраних даних дає можливість оцінити масштаби кризи, спрогнозувати розвиток подій та оптимізувати розподіл ресурсів. Наприклад, дані про затори чи пошкодження інфраструктури допомагають ефективніше координувати евакуацію чи доставку гуманітарної допомоги.

Краудсорсинг дає можливість зрозуміти, які потреби є найбільш актуальними в різних регіонах. Наприклад, це можуть бути потреби в їжі, воді, медичній допомозі чи укриттях.

Платформи краудсорсингу можуть бути швидко розгорнуті та адаптовані до специфіки кризи. Крім того, зібрані дані можуть інтегруватися з іншими системами для побудови аналітичних моделей та візуалізації.

Аналіз краудсорсингових даних із використанням методів машинного навчання допомагає автоматично виявляти закономірності, класифікувати дані та знаходити "гарячі точки". Наприклад, алгоритми можуть визначати місця з найбільшою концентрацією повідомлень про допомогу. Одночасний аналіз тексту та зображень у даних з краудсорсингу може покращити якість інформації про гуманітарну допомогу.

Аналіз даних з краудсорсингу під час кризової ситуації означає процес збору, обробки та інтерпретації даних, зібраних від великої кількості людей (краудсорсинг), з метою розуміння та управління інформацією під час кризової ситуації.

Краудсорсинг підвищує рівень прозорості та залучення громадян до вирішення кризових ситуацій. Люди відчують свою причетність до подолання кризи, що підвищує рівень довіри до органів управління чи гуманітарних організацій.

Під час природних катастроф, таких як землетруси чи повені, краудсорсингові дані можуть надходити від людей, які повідомляють про ситуацію в реальному часі. Це допомагає швидше реагувати на події та приймати необхідні рішення.

У випадку терористичних атак чи масових заворушень, дані зібрані від очевидців через соціальні мережі або спеціальні платформи, можуть допомогти зрозуміти масштаб ситуації та координацію зусиль рятувальних служб.

Під час спалахів інфекційних захворювань, краудсорсинг може використовуватися для збору даних про поширення хвороби, симптоми та місця перебування інфікованих, що допомагає у прогнозуванні та вжитті заходів для стримування поширення інфекції.

Однак аналіз даних із краудсорсингу має свої виклики, серед яких перевірка достовірності інформації, захист конфіденційності даних, а також складність обробки великих обсягів інформації у стислі строки.

Краудсорсинг є потужним інструментом для аналізу даних під час кризових ситуацій, оскільки дозволяє отримати оперативну, локалізовану та достовірну інформацію для прийняття обґрунтованих рішень. У сучасному світі, де доступ до технологій стає все ширшим, його актуальність тільки зростатиме.

Таким чином, використання краудсорсингових даних під час кризових ситуацій є цінним інструментом для забезпечення своєчасної та ефективної реакції на виклики, що виникають.

# 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ

## 1.1 Краудсорсинг

Краудсорсингом називається метод залучення великої кількості людей для збору, обробки або аналізу даних. У кризових ситуаціях, таких як стихійні лиха, техногенні катастрофи, соціальні чи політичні кризи, краудсорсинг стає ефективним інструментом для: швидкого отримання інформації про події; ідентифікації потреб постраждалих; координації дій рятувальних служб.

Дані можуть надходити з різних джерел: соціальні мережі, мобільні додатки, спеціалізовані платформи (наприклад, Ushahidi), месенджери та інші цифрові канали.

Існують такі типи даних із краудсорсингу:

- Текстові повідомлення у вигляді опису ситуації, запитів про допомогу.
- Документування руйнувань або інших наслідків кризи надані як зображення та відео
- Геолокаційні дані визначенні місцями подій, зон ризику або потреб.
- Дані із сенсорів, наприклад, мобільні пристрої з GPS чи сенсорами забруднення.

З аналізом краудсорсингових даних пов'язано багато проблем. По-перше, це обсяги даних, під час кризи збирається велика кількість інформації, яку важко швидко обробити. Краудсорсинг може містити недостовірні дані, фейкові новини, дезінформацію або спам. Також виникають етичні питання, пов'язані з конфіденційністю даних користувачів і ризик зловживань. Крім того існує складність інтеграції даних, дані різних форматів (текст, відео, геолокація) потребують спеціальних підходів до їх об'єднання.

Інтелектуальний аналіз даних це процес застосування методів і технологій штучного інтелекту (ШІ) для автоматизації обробки великих масивів даних із метою отримання нової інформації, прогнозування та прийняття рішень. У контексті краудсорсингу цей процес включає:

- класифікацію та фільтрацію даних;
- виявлення закономірностей у великих наборах даних;
- геопросторовий аналіз;
- прогнозування розвитку кризової ситуації.

Найбільш розповсюдженими методами та технологіями інтелектуального аналізу є

- Обробка природної мови (NLP) – аналіз текстових даних для класифікації повідомлень, визначення ключових слів, настроїв і запитів.
- Алгоритми машинного навчання, до яких відноситься класифікація, кластеризація, нейронні мережі для виявлення закономірностей.
- Комп’ютерний зір, тобто розпізнавання об’єктів на фото чи відео.
- Геоаналіз якк визначення зон ризику, аналіз переміщень людей.
- Big Data платформи – Apache Hadoop, Apache Spark для обробки великих обсягів даних.

В кризових ситуаціях інтелектуальний аналіз відіграє велику роль. Оперативна обробка інформації для визначення зон ризику дозволяє швидко реагувати. На прогнозування кінцевих результатів впливає оцінка можливих сценаріїв розвитку кризи. Для оптимізованого використання ресурсів здійснюється розподіл допомоги відповідно до потреб, виявлених у реальному часі. Дуже важливим є постійний аналіз динаміки подій.

Перспективами розвитку цієї сфери є використання глибокого навчання для більш точного аналізу даних; розробка інтегрованих платформ для збору, аналізу й візуалізації краудсорсингових даних; забезпечення кращого захисту даних і конфіденційності та розширення можливостей прогнозування на основі даних у реальному часі.

Таким чином, інтелектуальний аналіз даних із краудсорсингу є ефективним інструментом для реагування на кризові ситуації, оскільки дозволяє швидко отримувати, обробляти та використовувати дані для прийняття рішень. Подальший розвиток цієї сфери залежить від впровадження сучасних технологій штучного інтелекту та вирішення проблем достовірності й конфіденційності даних.

## 1.2 Огляд літератури

Швидке надання гуманітарної допомоги після стихійного лиха, особливо в перші години («золоте вікно»), відіграє ключову роль у зменшенні кількості постраждалих і загиблих [1]. Краудсорсингові дані можуть стати цінним джерелом інформації для ефективної та своєчасної організації допомоги. У перші години після катастрофи важлива інформація про постраждалих, зниклих безвісти, потреби та доступні ресурси часто з'являється в соціальних мережах [2]. Проте аналіз таких даних є складним завданням через специфіку інформації, пов'язаної з гуманітарною допомогою, та її великий обсяг. В умовах інформаційного перевантаження після катастрофи важливим є класифікування інформаційних потоків за їхнім змістом та передача відповідним службам реагування. Точне групування даних про гуманітарну допомогу з соціальних мереж є критично важливим для швидкого реагування та порятунку людських життів [3].

Методи машинного навчання (ML) демонструють перспективну ефективність в аналізі даних з краудсорсингових джерел. Зокрема, серед різних підходів, що застосовувалися у попередніх дослідженнях, методи глибокого навчання (DL) отримали особливу увагу завдяки їхній високій продуктивності порівняно з традиційними моделями ML [4]. Краудсорсингові дані з соціальних мереж зазвичай включають як текстову, так і графічну інформацію, обидва типи якої є важливими для отримання повного уявлення про потреби гуманітарної допомоги. Це робить мультимодальний аналіз, який дозволяє одночасно обробляти текстові та візуальні дані, вкрай необхідним.

Однак соціальні медіа часто містять незбалансовані джерела даних, що створює виклики для моделей класифікації, особливо тих, що базуються на логічному виведенні. Ефективність класифікаторів на основі DL значною мірою залежить від якості даних і наявності закономірностей, тому незбалансовані набори даних можуть значно знижувати точність класифікації. До того ж складність моделей глибокого навчання ускладнює їх інтерпретацію та розуміння їхньої поведінки. Зважаючи на критичну важливість гуманітарної допомоги, використання непрозорих моделей

«чорної скриньки» є небажаним [5]. Тому метою цього дослідження є розробка фреймворку для проведення інтерпретованого мультимодального аналізу даних із соціальних мереж, який також дозволить ефективно розв'язати проблему незбалансованості даних. Для досягнення цієї мети необхідно відповісти на низку ключових питань.

Які архітектури DL можуть ефективно аналізувати краудсорсингові дані, пов'язані зі стихійними лихами у віддалених регіонах?

Неглибокі мережі для обробки природної мови (NLP), такі як Word2Vec і FastText, у поєднанні з глибокими згортковими мережами (VGGNet) [6] та глибокими залишковими мережами (ResNet), застосовувалися в дослідженнях мультимодального аналізу. Однак лише незначна кількість робіт досліджувала продуктивність новітніх моделей NLP та обробки зображень. Щоб надати більш ґрунтовну відповідь на це питання, було проведено оцінку ефективності класифікації двох сучасних моделей NLP та двох передових моделей обробки зображень.

Для NLP було обрано двонаправлене подання коду трансформаторів (BERT) [7] та його полегшений варіант ALBERT, а для обробки зображень — моделі ResNetY320 і ConvNeXt. На основі цих моделей та їх комбінацій було розроблено чотири мультимодальні архітектури, ефективність яких порівняли на невідомому тестовому наборі даних. Вибір цих моделей пояснюється їхньою високою продуктивністю, особливо при роботі з контентом соціальних мереж, що підтверджено результатами попередніх досліджень [8, 9].

Для вирішення проблеми дисбалансу наборів даних розглядаються генеративні змагальні мережі (GAN), які здатні створювати синтетичні зображення. Цей підхід дозволяє генерувати нові дані на основі наявних, що сприяє збагаченню класів із недостатньою кількістю записів. Ефективність використання GAN для балансування незбалансованих наборів даних із соціальних мереж була підтверджена у попередніх дослідженнях [10,11]. Проте їхній вплив на мультимодальні дослідження досі не досліджувався. У цьому дослідженні аналізується вплив синтетичних зображень, створених за допомогою GAN, на процес навчання моделей, шляхом оцінки їхньої роботи на невідомому тестовому наборі даних. Дисбаланс вхідних даних із

соціальних мереж, пов'язаних із гуманітарною допомогою, обумовлений обмеженнями щодо обміну зображеннями постраждалих людей після катастроф.

Надання гуманітарної допомоги після стихійного лиха є критично важливим і може врятувати життя. Тому всі моделі машинного навчання (ML), що застосовуються для цієї мети, мають бути ретельно інтерпретовані перед використанням. Для моделей ML принцип «чорної скриньки» ускладнює розуміння взаємозв'язку між вхідними та вихідними даними, але це можна вирішити за допомогою інструментів інтерпретації [12,13]. Раніше інтерпретація моделей ML на основі стрічок соціальних мереж та глибоких мереж для зображень була обмеженою. У цьому дослідженні використовується метод адитивного пояснення Шеплі (SHAP), який допомагає гуманітарним організаціям краще розуміти мультимодальні моделі, пояснювати структури даних та передбачати поведінку моделей.

По результатах проведеного аналізу сучасних наукових робіт можна зробити такі висновки.

Дані з соціальних мереж є важливим джерелом інформації для гуманітарної допомоги, проте їх мультимодальна природа (тексти, зображення) і незбалансованість створюють значні виклики для аналізу.

Методи глибокого навчання (DL) демонструють високу продуктивність у класифікації текстів і зображень. Інтеграція моделей обробки природної мови (NLP) і комп'ютерного бачення є перспективною для мультимодального аналізу.

Використання генеративних змагальних мереж (GAN) дозволяє ефективно збагачувати набори даних шляхом генерації синтетичних прикладів для рідкісних класів.

Інтерпретація моделей машинного навчання (ML) і глибокого навчання є критично важливою, особливо для застосувань, що впливають на життя людей. Інструменти на зразок SHAP допомагають пояснити поведінку моделей і взаємозв'язок між даними.

Дослідження [29] пов'язане з розподіленими обчисленнями та використанням хмарних сервісів для обробки великих даних, яке може бути пов'язане з аналізом

великих обсягів краудсорсингових даних для кризових ситуацій або моніторингу стану здоров'я.

Дослідження [30] зосереджене на комп'ютерному зорі, що може бути корисним для автоматичної обробки зображень із соціальних мереж у кризових ситуаціях, та для створення адаптивних навчальних систем для студентів. Воно буде поєднуватися з моделями для автоматизованої класифікації та аналітики в реальному часі.

Робота [31] буде пов'язана з прогнозуванням та моніторингом даних в реальному часі, використовуючи машинне навчання для аналітики стану здоров'я, подібно до системи автоматичного аналізу даних у кризових ситуаціях, що згадано у попередній роботі. Може бути інтегровано з концепцією інтелектуальних систем підтримки прийняття рішень.

Дослідження [32] пов'язане з класифікацією об'єктів за допомогою штучних імунних мереж, що буде використано для класифікації критичних даних, отриманих під час кризових ситуацій (наприклад, класифікація пошкоджених об'єктів на зображеннях або текстових повідомленнях).

Інтелектуальний аналіз краудсорсингових даних підтримує оперативність і ефективність гуманітарної допомоги, сприяючи більш точному визначенню потреб та координації ресурсів у кризових ситуаціях.

Ці висновки підкреслюють важливість інтеграції сучасних технологій аналізу даних у сфері гуманітарної допомоги, а також необхідність подальших досліджень для розробки ефективних та інтерпретованих рішень.

### 1.3 Постановка проблеми

Наведені аспекти вказують на важливі проблеми, які потребують вирішення.

Проблема ефективної обробки і класифікації текстових та графічних даних з краудсорсингових каналів. Необхідно розробити більш ефективні алгоритми для обробки комбінації зображень та текстів, щоб забезпечити більш точну та швидку реакцію на гуманітарні потреби.

Набори даних з соціальних мереж можуть бути сильно незбалансованими, що знижує ефективність моделей машинного навчання. Необхідно вирішити проблему недостатньої кількості даних для деяких категорій (наприклад, зображення постраждалих) і використовувати методи, як-от генеративні змагальні мережі (GAN), для створення синтетичних даних, що збагачують рідкісні класи.

Необхідно розвивати методи та інструменти для інтерпретації складних моделей, таких як глибоке навчання (DL), у контексті гуманітарної допомоги. Без інтерпретованих моделей гуманітарні організації не зможуть точно зрозуміти, як дані впливають на прийняття рішень і, відповідно, на результат операцій.

Після катастрофи необхідно обробляти величезні обсяги даних у реальному часі для точного визначення потреб постраждалих. Проблема полягає в тому, щоб аналізувати й класифікувати потік інформації швидко і без помилок, що вимагає значних обчислювальних ресурсів та оптимізації алгоритмів.

Потрібно забезпечити ефективну інтеграцію даних з різних джерел, таких як соціальні мережі, відгуки користувачів, зображення, текстові повідомлення тощо, щоб створити повну картину ситуації. Різноманітні джерела даних мають різні формати, і їх правильна обробка є критично важливою для забезпечення точності результатів.

Потрібно розробити адаптивні моделі, які можуть реагувати на зміни в даних, що надходять під час кризових ситуацій, таких як нові типи катастроф, зміна джерел інформації та нестабільність доступу до мереж. Це вимагатиме вдосконалення алгоритмів машинного навчання та їх інтеграції в реальні сценарії.

Враховуючи чутливий характер інформації (наприклад, зображення постраждалих), необхідно розробити методи, що забезпечують захист особистих даних під час аналізу та класифікації. Це також включає механізми анонімізації та захисту від маніпуляцій даними.

Для досягнення максимального ефекту важливо забезпечити ефективну комунікацію та взаємодію між різними організаціями, які здійснюють допомогу. Необхідно розробити методи класифікації та передачі інформації між різними відповідними службами для забезпечення своєчасного реагування.

Ці проблеми потребують комплексного підходу, включаючи удосконалення технологій машинного навчання, розвиток нових методів обробки даних, а також впровадження надійних механізмів забезпечення якості та безпеки інформації.

Метою цієї роботи є розробка підходу до інтелектуального аналізу даних, отриманих із краудсорсингових платформ під час кризових ситуацій, для оперативного виявлення критичних зон, ідентифікації потреб постраждалих і підвищення ефективності процесу прийняття рішень щодо реагування на кризу.

Для досягнення цієї мети необхідно вирішити наступні завдання:

- Розробити механізми для збору та агрегації даних з різноманітних краудсорсингових каналів, таких як соціальні мережі.
- Створити алгоритми для попередньої обробки даних.
- Розробити метод обробки природної мови (NLP) для аналізу текстових повідомлень.

## 2 МОДАЛЬНІСТЬ ЗОБРАЖЕНЬ

### 2.1 Основні види модальностей зображень

Модальність зображень охоплює різноманітні методи та технології, що використовуються для створення, обробки, інтерпретації та аналізу зображень. Ця категорія включає різні типи візуальних даних, які можуть бути отримані з використанням різних технік та пристроїв. Основні види модальностей зображень включають:

Зображення, отримані за допомогою камер, що реєструють світло, відбите від об'єктів.

Медичні зображення, створювані за допомогою таких методів візуалізації, як рентгенографія, комп'ютерна томографія (КТ), магнітно-резонансна томографія (МРТ), ультразвукове дослідження (УЗД), що застосовуються для діагностики та лікування.

Супутникові та авіаційні зображення, використовувані для картографії, моніторингу навколишнього середовища, розвідки природних ресурсів та інших цілей.

Інфрачервоні зображення, що надають теплові характеристики об'єктів, які можуть бути використані в різних технічних і наукових дослідженнях.

Мікроскопічні зображення, які дозволяють досліджувати об'єкти на мікроскопічному рівні, такі як клітини або мікроорганізми.

Кожен із цих типів зображень має свої унікальні характеристики, що вимагають спеціальних методів обробки та аналізу. Зокрема, медичні зображення застосовуються для клінічної діагностики та лікування, тоді як супутникові знімки активно використовуються для географічних досліджень та моніторингу кліматичних змін.

Аналіз даних, отриманих через краудсорсингові платформи, передбачає збір, обробку та інтерпретацію інформації, зібраної від великої кількості учасників через

різні канали та засоби. Краудсорсинг дає змогу залучити численні ресурси для виконання різноманітних завдань, таких як збір даних, їх обробка та оцінка. Основні етапи аналізу даних з краудсорсингу включають:

**Збір даних.** Інформація може бути зібрана через різноманітні засоби, такі як опитування, анкети, соціальні мережі, мобільні додатки або спеціалізовані краудсорсингові платформи (наприклад, Amazon Mechanical Turk). Це можуть бути текстові відповіді, зображення, відео, геолокаційні дані тощо.

**Попередня обробка даних.** На цьому етапі здійснюється очищення даних від шуму та помилок, нормалізація даних, а також видалення дублікатів і аномалій. Це забезпечує високу якість даних для подальшого аналізу.

**Агрегація та класифікація даних.** Зібрані дані об'єднуються й класифікуються за різними критеріями, такими як географічні ознаки, демографічні характеристики або тематичні категорії, що дозволяє структурувати дані для подальшої обробки.

**Аналіз даних.** Здійснюється різноманітний аналіз, зокрема статистичний аналіз, аналіз настроїв, кластерний аналіз та інші методи, які дозволяють виявляти корисні закономірності та тренди. Результати можуть бути представлені у вигляді графіків, діаграм, карт або інших візуалізацій для полегшення інтерпретації.

**Висновки та рекомендації.** На основі проведеного аналізу формулюються висновки та надаються рекомендації, що можуть допомогти в прийнятті рішень, розробці стратегій або вирішенні конкретних проблем.

**Перевірка достовірності даних.** Отримані результати підлягають перевірці через додаткові опитування або експертну оцінку для підтвердження точності та надійності даних.

Приклади застосування краудсорсингу включають: проекти на зразок OpenStreetMap, що залучають користувачів для картографування територій; опитування великої кількості осіб для збору даних про громадську думку або соціальні явища; збір даних про здоров'я та поведінку учасників для дослідження епідемій або захворювань; аналіз ринкових трендів та споживчих настроїв на основі отриманих відгуків користувачів.

Краудсорсинг дозволяє зібрати великий обсяг даних за короткий час і з

мінімальними витратами, що є важливим для досліджень та ухвалення рішень у різних сферах.

## 2.2 Гуманітарні дослідження під час надзвичайних ситуацій

Наукові дослідження, спрямовані на вивчення і вирішення проблем, що виникають внаслідок природних або техногенних катастроф, таких як землетруси, повені, урагани, війни або інші кризи можна віднести до гуманітарних досліджень під час надзвичайних ситуацій. Ці дослідження охоплюють різні аспекти гуманітарної допомоги та реагування на кризові ситуації, зокрема:

Оцінка термінових потреб людей, що постраждали від катастрофи, таких як їжа, вода, медичне обслуговування, укриття тощо.

Аналіз і оптимізація процесів розподілу допомоги серед постраждалих, щоб забезпечити ефективне використання ресурсів і мінімізувати втрати.

Дослідження соціальних, економічних і психологічних наслідків катастроф для громад та окремих осіб.

Використання технологій для збору та аналізу даних. Застосування інструментів, таких як краудсорсинг, аналіз великих даних, штучний інтелект і машинне навчання для збору і обробки інформації з постраждалих регіонів, що дозволяє оперативно реагувати на ситуацію.

Оцінка ефективності реагування на надзвичайні ситуації. Аналіз результатів наданої допомоги та вивчення, як можна поліпшити процеси реагування та запобігання катастроф.

Такі дослідження допомагають не тільки покращити оперативність і точність гуманітарних ініціатив, але й розробити довгострокові стратегії для зменшення наслідків катастроф та підвищення стійкості суспільства до кризових ситуацій.

Пости в соціальних мережах активно використовуються для оперативного інформування про ситуацію під час катастроф завдяки їх здатності працювати в реальному часі та орієнтованості на користувача [14]. Через соціальні платформи люди можуть як запитувати, так і пропонувати гуманітарну допомогу. Хоча стрічки

соціальних мереж містять багаті набори даних для аналізу, вони також можуть включати нерелевантний контент [15]. Методи машинного навчання (ML) виявляються потужними інструментами для виділення гуманітарних аспектів з краудсорсингових даних під час надзвичайних ситуацій, що дозволяє полегшити становище постраждалих від стихійних лих. Попередні дослідження в галузі гуманітарної допомоги, що застосовують аналіз краудсорсингових даних за допомогою ML, можна поділити на три основні категорії: текстові, графічні та комбіновані дані, залежно від типу вхідних даних. Вони надають інформацію щодо необхідності використання машинного навчання для обробки краудсорсингових даних, важливих характеристик цих даних як вхідних даних для моделювання, а також досягнень ML у сфері гуманітарної допомоги після стихійних лих.

До першої категорії належать підходи обробки природної мови (NLP) для витягування інформації про гуманітарну допомогу з краудсорсингових даних. Однією з останніх тенденцій є класифікація інформації за допомогою систем NLP, що підтверджується аналізом літератури, представленим на рисунку 2.1, де зображено результати дослідження зв'язків між соціальними мережами та катастрофами.

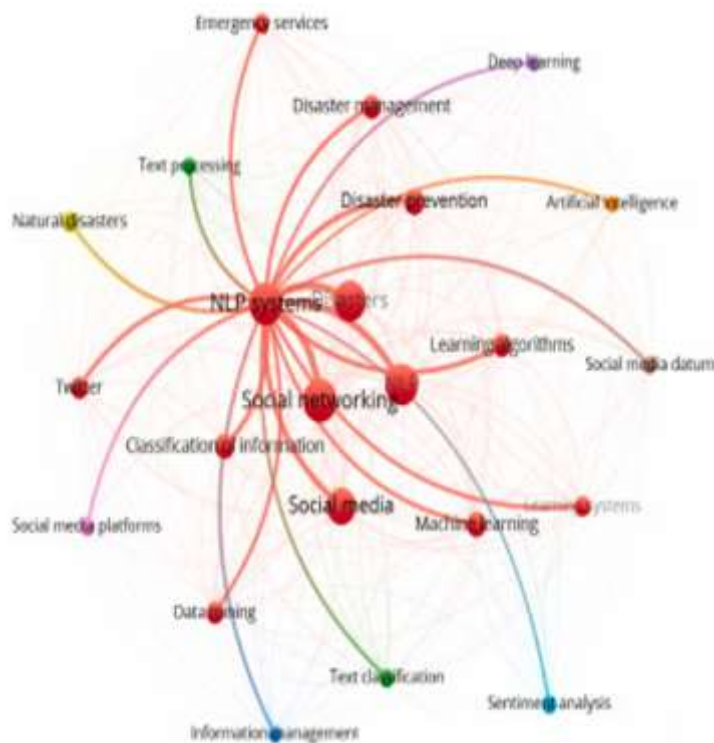


Рисунок 2.1 – Мережа ключових слів текстового аналізу

Цей рисунок показує, що соціальні мережі можуть бути важливим джерелом для систем NLP. Зазначимо, що рисунок 2.1 є ненаправленою мережею. На рисунках 2.2 та 2.3 зображено мережі ключових слів обробки зображень та мультимодального аналізу (одночасний аналіз тексту та зображень).

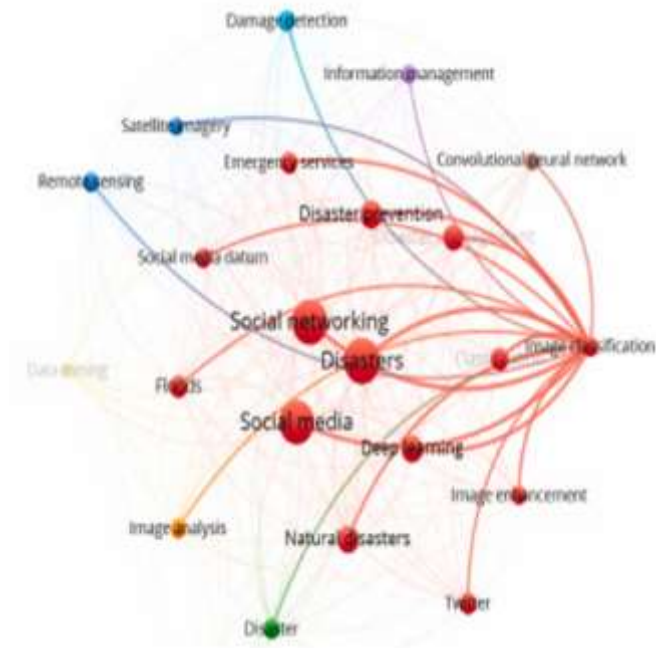


Рисунок 2.2 – Мережа ключових слів обробки зображень

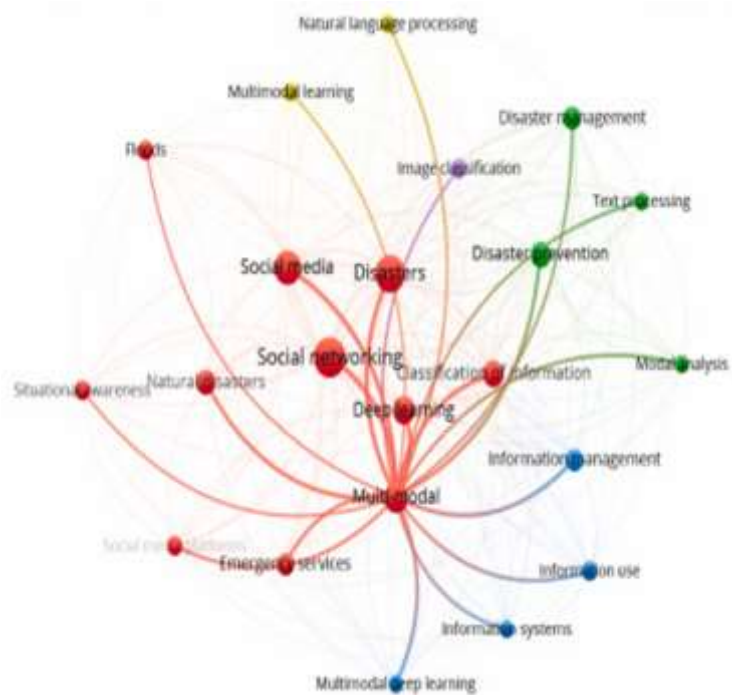


Рисунок 2.3 – Мережа ключових слів мультимодального аналізу

У таблиці 2.1 надано огляд нещодавніх досліджень NLP, що стосуються класифікації інформації під час надзвичайних ситуацій. Різні дослідження розробили моделі ML для виявлення специфічних типів інформації, зокрема термінових твітів під час урагану Харві 2017 року [16], новинних повідомлень з Times of India, NDTV India та Indian Express, настроїв твітів про катастрофи, створених компанією Figure Eight inc. (Arpen), випадкових речень у інформаційних бюлетенях після Великого землетрусу Ханшин-Авадзі 1995 року та Великого землетрусу на сході Японії 2011 року [17], а також пов'язаних з катастрофами твітів з набору даних конкурсу Kaggle.

Таблиця 2.1 –Текстова модальність

N	Вхідний набір даних	Обсяг набору даних	Текстові моделі
1	Manually labelled disaster tweets during the 2017 Hurricane Harvey	3191	Glove-Transformers; ELMNO-Transformers; BERT; RoBERTa; DistillBERT; ALBERT; XLNet; BERT-LSTM; BERT-CNN
2	4 datasets based on the CrisisNLP dataset	28,647	Base CNN; CNN-GRU; CNN_SkipCNN
3	Tweets during Hurricane Harvey 2017. Content labels by SocialDISC	4227	BiLSTM
4	Harvard tweet dataset for hurricane Harvey 2017 - annotations by topic modelling	18,331,877	Random Forest
5	Train: Earthquakes tweet dataset; Test: manually annotated COVID-19 tweets	122,743 + 2274	LR; CNN; MLP
6	Kaggle competition dataset (labels are manually annotated by humans)	10,876	Trees; Random Forest; LR; Skip-gram; FastText; GloVe; Skip-gram + Bi-LSTM; FastText + Bi-LSTM; GloVe + Bi-LSTM; BERT; BERT + Bi-LSTM
7	Manually annotated sentences from newsletters during two earthquakes	4059	SVM
8	A twitter dataset of Figure Eight inc.	10,876	SentiBERT; BiLSTM; CNN
9	Labelled (relevant news or not) news from Indian news	About 11,000	Multinomial Naïve; Bayes algorithm; Logistic regression; SVM; Random Forest; Xtereme Gradient Boosting Model
10	Manually labelled tweets during Hurricane Harvey 2017	2,072,715	CNN; SVM; MLP; AdaBoost; Logistic Regression; Naïve Bayes; Decision Tree; Ridge Classifier

Текстова модальність у даному контексті стосується обробки текстових даних для вилучення релевантної інформації в гуманітарних дослідженнях під час надзвичайних ситуацій. У таблиці 2.1 представлено різноманітні текстові набори даних, моделі машинного навчання, що використовуються для їх аналізу, а також специфіку кожного набору.

Перший стовбець таблиці це джерела текстових даних такі як твіти, новини, чи розмічені дані, які використовуються для навчання моделей. Ці дані були зібрані під час катастроф, наприклад, ураган Харві 2017 року.

У другому стовбчику наведений обсяг набору даних, який складається з розміру текстових даних (кількість прикладів), що аналізуються. Більші обсяги даних дозволяють створювати більш точні моделі, але вимагають більшої обчислювальної потужності.

У третьому стовбчику наведені текстові моделі тобто це методи й алгоритми, які використовуються для аналізу тексту. Вони включають:

- прості алгоритми, такі як логістична регресія (LR), опорні вектори (SVM), найвний Баєс (Naïve Bayes);
- нейронні мережі – CNN, BiLSTM, Transformers, BERT, RoBERTa, XLNet тощо;
- комбіновані моделі, наприклад, поєднання попередньо натренованих моделей (BERT, GloVe) з іншими нейронними мережами, такими як BiLSTM чи CNN.

По результатах аналізу таблиці 2.1 можна робити такі висновки:

Набори текстових даних охоплюють твіти, новини, анотовані речення й спеціалізовані набори (наприклад, CrisisNLP, Figure Eight inc.). Це свідчить про широкий спектр застосувань текстової модальності для аналізу даних під час надзвичайних ситуацій.

Набори значно варіюються за обсягом — від кількох тисяч до мільйонів текстових прикладів, що демонструє різні масштаби проблем, які аналізуються.

Сучасні моделі, такі як BERT, RoBERTa та ALBERT, забезпечують високоточний аналіз тексту завдяки їхній здатності враховувати контекст. Інші моделі, наприклад, SVM чи Random Forest, можуть використовуватися для

порівняння результатів.

Моделі застосовуються для різних завдань, таких як класифікація твітів за тематикою (гуманітарна допомога, терміновість), аналіз настроїв, ідентифікація релевантних новин чи прогнозування.

Текстова модальність є критичною для вилучення цінної інформації з великих текстових наборів даних у реальному часі, що допомагає ефективно координувати гуманітарну допомогу.

Текстова модальність у мовознавстві стосується способів вираження можливості, ймовірності, необхідності, бажаності або інших відтінків значення в тексті. Модальність може бути виражена різними мовними засобами, такими як модальні дієслова (може, мусить, повинно), умовні форми дієслів, прислівники (можливо, напевно) тощо. Вона допомагає передавати ставлення мовця до висловлюваного, визначати рівень впевненості, обов'язковості чи бажаності подій або дій.

Модальність зображення у контексті гуманітарних досліджень під час надзвичайних ситуацій стосується обробки та аналізу зображень для вилучення корисної інформації, наприклад, оцінки пошкоджень, визначення типу катастрофи чи ідентифікації критичних об'єктів. У таблиці 2.2 наведено приклади наборів даних, обсяги зображень і моделі, які використовуються для аналізу зображень.

Таблиця 2.2 – Модальність зображення

N	Вхідний набір даних	Обсяг набору даних	Текстові моделі
1	Manually labelled images from Google, Twitter and BGS's image database	11,737	ResNet-50
2	Two open-fire image datasets	1650	4 ResNets (ResNet18, 50, 101, and InceptionResNetV2)- SVM
3	Binary annotated images from three hurricanes in 2017	7387 + 3683	VggNet; ResNet; AlexNet- SVM

Зображення збираються з платформ, таких як Google, Twitter, або спеціалізовані бази даних, наприклад, база зображень BGS.

Мітки до зображень можуть відображати категорії, наприклад, наявність чи відсутність пошкоджень, наявність відкритого вогню, або інші характеристики.

У таблиці 2.2 вказано кількість зображень у наборі, що варіюється від 1650 до понад 11 тисяч зображень. Обсяг набору впливає на якість навчання моделей — великі набори забезпечують кращу генералізацію.

Для аналізу зображень використані такі моделі:

- ResNet – глибока згорткова нейронна мережа (ResNet-18, ResNet-50, ResNet-101), яка є популярною завдяки своїй здатності працювати з великими наборами даних, враховуючи складні візуальні особливості.

- InceptionResNetV2 – комбінована архітектура, що поєднує ідеї ResNet і Inception для підвищення ефективності класифікації.

- VggNet – проста, але ефективна згорткова нейронна мережа для задач класифікації зображень.

- AlexNet – одна з перших глибоких нейронних мереж, яка продемонструвала високі результати в комп'ютерному зорі.

- SVM (Support Vector Machine) – використовується як класифікатор, зазвичай у комбінації з іншими моделями для уточнення результатів.

Наприклад, набір зображень з Google, Twitter і бази даних BGS містить 11,737 вручну розмічених зображень. Використовується модель ResNet-50, яка добре розпізнає об'єкти на зображеннях.

По результатах аналізу таблиці 2.2 можна робити такі висновки:

Обробка зображень дозволяє автоматично визначати важливі характеристики (наприклад, пошкодження чи небезпеки) з великої кількості даних, що значно спрощує аналіз ситуації під час катастроф.

Популярні моделі для обробки зображень, такі як ResNet і VggNet, забезпечують точність завдяки їхній здатності враховувати складні візуальні патерни.

Комбінація з SVM допомагає підвищити ефективність класифікації, особливо при невеликих наборах даних.

Мультиmodalність у контексті обробки даних для гуманітарних досліджень під час надзвичайних ситуацій стосується аналізу та синтезу інформації з різних

джерел, таких як текст і зображення, для покращення розуміння та ухвалення рішень. Це поєднання різних типів даних дозволяє моделювати складніші ситуації, ніж при аналізі лише одного типу даних (таблиця 2.3).

Таблиця 2.3 – Мультиmodalність

N	Вхідний набір даних	Обсяг набору даних	Текстові моделі	Текстові моделі
1	CrisisMMD	12,708 (img) + 11,400 (txt)	VGG16; VGG19; ResNet50; DenseNet121; RegNetY320	DistilBERT
2	Annotated multi-labelled humanitarian tweets based on text and images (Sources: CrisisLexT26 and Datasets from Crises)	4383	DenseNet feature extraction; Faster RCNN Object detection	BERT
3	Extracted Henan torrential rain dataset in 2021	2219 (img) + 25,880 (txt)	VGG16	BERT
4	CrisisMMD	18,126	VGG16; DenseNet-201	BERT
5	CrisisMMD	18,126 (img) + 16,097 (txt)	VGG16	Bi-LSTM
6	Annotated Twitter messenger content after Hurricane Irma 2017	6898 (img) + 19,088 (txt)	VGGNet; ResNet; Inception-V3; Tuned Inception-V3	Word2Vec
7	CrisisMMD	12,743 (img) + 11,404 (txt)	VGG16	FastText
8	YFCC100M, CrisisMMD, and tweets after Hurricane Harvey 2017 and Hurricane Irma 2017. The dataset is annotated manually.	1795 + 1555	ResNet-18 + LR; ResNet-18 + decision tree; ResNet-18 + SVM with linear kernel	Keyword search
9	CrisisMMD	8079 (img) + 7216 (txt)	VGG16	Word2Vec + CNN

Дані таблиці 2.3 включають текстову інформацію (наприклад, твіти, повідомлення) та зображення (наприклад, фотографії з місця подій). Джерелами даних є CrisisMMD, Henan Torrential Rain Dataset, твіти, контент після ураганів та інші гуманітарні бази даних.

Вказується кількість текстових і візуальних елементів (наприклад, 12,708 зображень і 11,400 текстових даних для CrisisMMD). Набори містять як великі, так і невеликі обсяги даних залежно від специфіки дослідження.

Для аналізу зображень були використані такі моделі:

– VGG16, VGG19 – глибокі згорткові нейронні мережі для обробки зображень.

- ResNet, DenseNet, Inception – моделі для вилучення ознак із зображень з використанням складних архітектур.

- Faster RCNN Object Detection – використовується для визначення об'єктів на зображеннях.

- Регресійні моделі (ResNet-18 + LR, Decision Tree, SVM) – застосовуються для подальшого аналізу отриманих ознак.

Для аналізу тексту були використані такі моделі:

- BERT, DistilBERT – моделі трансформерів для аналізу тексту, які забезпечують глибоке розуміння контексту.

- Bi-LSTM, Word2Vec, FastText – використовуються для роботи з текстовими послідовностями, витягуючи семантичну та синтаксичну інформацію.

- CNN для тексту – використовується для автоматичного вилучення ознак у текстових даних.

Тут можна побачити синтез мультимодальних даних. Дані з тексту та зображень аналізуються окремо, а потім поєднуються для отримання загальної моделі. Наприклад, VGG16 обробляє зображення, а BERT обробляє текстову частину.

Основні висновки такі:

Поєднання тексту та зображень дозволяє отримати більш повну картину надзвичайних ситуацій. Наприклад, текст може описувати подію, а зображення дає візуальне підтвердження.

Технології на основі глибокого навчання (ResNet, BERT) дають змогу досягти високої точності при класифікації та аналізі даних.

Мультимодальні моделі є ефективними для задач, пов'язаних з аналізом криз, таких як оцінка збитків, автоматична класифікація подій та виявлення пріоритетних дій для реагування.

Іншим напрямом досліджень є виділення додаткових вимірів інформації про гуманітарну допомогу з доступних наборів даних. Наприклад, у нещодавньому дослідженні класифікація інформації була виконана за категоріями, такими як потреби, доступність та інші класи твітів. Було встановлено, що багатосарові перцептрони з попередньо навченим вбудовуванням Word2Vec досягли точності

83% на тестовому наборі даних. В іншій роботі [18] аналізували анотовані дані Twitter про ураган «Гарві» 2017 року за тематичними категоріями, включаючи «допомогу, жертви та відновлення», «співчуття», «вдячність і підтримку», «попередження про ураган», «пошкодження та травми» і «корисна інформація». SocialDISC додатково виділили такі категорії: «екологічні загрози», «бізнес, робота, школа», «постраждали», «інфраструктура», «рятувальні операції», «житло», «транспорт» тощо. На основі цих даних була розроблена модель BiLSTM для передбачення категорій твітів, що показала, що 64% контенту включали згадки про конкретні об'єкти або місця.

Пол та ін. [19] використали категорії «жертви та волонтерство», «нагальні потреби», «пошкодження інфраструктури», «жертви» та «нерелевантні» для створення моделей CNN на основі чотирьох наборів даних про стихійні лиха (землетрус у Непалі 2015 року, циклон Рам 2015 року, землетрус у Каліфорнії 2014 року та тайфун Хагупіт 2014 року, набори даних CrisisNLP). Вони показали, що модель CNN-SkipCNN (з додатковими шарами CNN) перевершує базові CNN. Було також розроблено модель для пошуку жертв на основі ключових слів, таких як «допомога», «адреса», «жертва» та «небезпека», із використанням BERT і його модифікацій. Результати показали, що моделі BERT забезпечують вищу якість класифікації порівняно з іншими NLP-моделями на обмежених даних.

З огляду на зростання обчислювальних потужностей, обсягу даних і точності DL-моделей у порівнянні з традиційними ML-моделями [20], останнім часом дослідження фокусуються на застосуванні моделей DL, зокрема BERT. Крім покращення точності, зростає увага до інтерпретованості ML-моделей. Інструменти LIME [5] та SHAP [21] допомагають виявляти ключові слова і слабкі місця моделей, роблячи їх більш зрозумілими.

Інша категорія досліджень DL пов'язана з класифікацією зображень для ідентифікації катастроф через соцмережі (рис. 2.2). Оскільки DL-моделі потребують значних обсягів даних для навчання, використовуються попередньо навчені ваги з ImageNet [22]. Наприклад, такі моделі прогнозували прохідність доріг під час ураганів «Гарві», «Марія» та «Ірма» 2017 року. Для виявлення лісових

пожеж використовували модель ResNet на основі ImageNet і SVM для класифікації зображень. У іншому дослідженні ResNet-50 використовувалася для класифікації зсувів за допомогою набору з 11 737 зображень [23].

Третя категорія, відома як мультимодальний аналіз, охоплює текстові й графічні дані, забезпечуючи глибше розуміння гуманітарної допомоги з вищою точністю класифікації. У минулих дослідженнях гуманітарної допомоги більшість уваги приділялося першій категорії, тоді як третя отримала значно менше досліджень. Як показано на рисунку 2.3, сучасні мультимодальні дослідження часто застосовують методи глибокого навчання для аналізу стрічок соціальних мереж. У третьому стовбчику таблиці 2.3 представлена інформація про попередні дослідження, які фокусувалися на мультимодальному аналізі таких стрічок. Завдяки доступу до потужних обчислювальних ресурсів та зростанню кількості маркованих постів у соціальних мережах, таблиця 2.3 демонструє, що моделі глибокого навчання стали популярними як для текстових, так і для графічних модальностей. Для мультимодального аналізу широко використовуються попередньо навчені моделі ImageNet, зокрема ResNet, VGG, Inception, DenseNet і RegNet. Також активно застосовуються BERT та його модифікації.

### 2.3 Етапи анотації в наборі даних CrisisMMD

Одним із відомих наборів даних для мультимодального аналізу є CrisisMMD, який містить три етапи анотації. CrisisMMD це мультимодальний набір даних, розроблений для досліджень у галузі аналізу гуманітарної допомоги. Він складається з текстових і графічних даних, отриманих із соціальних мереж, зокрема твітів і відповідних до них зображень. Основна мета цього набору даних забезпечити дослідників інструментом для вивчення мультимодальних підходів до аналізу інформації, пов'язаної з кризовими ситуаціями. Набір даних містить пари текст-зображення (4383 анотованих пари текст-зображення.), які дозволяють проводити одночасний аналіз текстової та візуальної інформації. Існують такі категорії гуманітарної інформації: постраждалі особи; пошкодження

інфраструктури та комунальних послуг; поранені або загиблі; зниклі або знайдені люди; рятувальні операції, волонтерство чи благодійність; пошкодження транспортних засобів; інша важлива інформація; дані, які не стосуються справи або не можуть бути класифіковані.

Етапи анотації в наборі даних CrisisMMD це процес позначення (анотації) текстових і графічних даних для створення структурованих міток, що використовуються для навчання моделей мультимодального аналізу. Ці етапи допомагають організувати дані, зокрема твіти й зображення, за їхньою інформативністю та категоріями гуманітарної інформації. Описано три основні етапи анотації:

#### Етап 1. Визначення інформативності.

Метою є з'ясування, чи містить твіт корисну інформацію для гуманітарної допомоги. Результати анотації можуть бути інформативні та неінформативні:

- інформативні – дані, які мають значення для розуміння ситуації (наприклад, повідомлення про пошкодження, заклики до допомоги, інформація про постраждалих).
- неінформативні – дані, що не містять корисної інформації (наприклад, загальні коментарі, гумористичні твіти або повторні публікації).

#### Етап 2. Категоризація гуманітарної інформації.

Метою є класифікація інформативних даних за їхнім типом гуманітарної інформації. Результатом анотації будуть постраждалі особи; пошкодження інфраструктури та комунальних послуг; поранені чи загиблі; зниклі безвісти чи знайдені люди; рятувальні операції, волонтерство або благодійність; пошкодження транспортних засобів; інша важлива інформація; не стосується справи / не можу визначити.

Цей етап виконується окремо для тексту та зображень. Наприклад, текст може містити повідомлення про "зниклих людей"; зображення може демонструвати "пошкодження будівель".

#### Етап 3. Оцінка модальності зображень.

Метою є оцінка специфічної інформації, доступної лише в зображеннях.

Результати анотації буде визначення рівня пошкоджень інфраструктури та інженерних комунікацій. Цей етап виконується виключно для графічних даних (зображень) і не пов'язаний із текстом. Наприклад, зображення сильно пошкодженого мосту отримує оцінку "високий рівень пошкоджень". Маркування у вгляді анотованих даних з урахуванням взаємозв'язку текстів і зображень, що дозволяє враховувати їхній контекст.

Раніше у дослідженнях гуманітарної допомоги штучний інтелект використовували для вилучення інформації з соціальних мереж, зосереджуючись на текстових, графічних та мультимодальних даних. Сучасні моделі гуманітарної допомоги значною мірою спираються на мультимодальні дані, які підвищують їхню цінність для гуманітарних організацій. Однак попередні мультимодальні моделі мали певні недоліки, включаючи незбалансованість даних, застарілі підходи до розробки моделей і недостатню інтерпретацію результатів. Для вирішення цих проблем використовуються синтетичні дані, створені за допомогою GAN, а також передові моделі глибокого навчання, такі як RegNetY320, ConvNeXts, BERT і ALBERT. Особлива увага приділяється підвищенню прозорості й зрозумілості результатів мультимодальних моделей.

## 3 МУЛЬТИМОДАЛЬНА МОДЕЛЬ НАДАННЯ ГУМАНІТАРНОЇ ДОПОМОГИ

### 3.1 Класифікація гуманітарної інформації в соцмережах під час лиха

Опис проблеми. Під час природних лих, таких як землетруси, урагани чи повені, соціальні мережі стають важливим джерелом інформації для гуманітарних організацій. Однак обсяг даних є величезним, і їх обробка вручну займає багато часу. Автоматична класифікація гуманітарної інформації може значно прискорити процес ідентифікації критичних повідомлень, таких як заклики про допомогу, дані про постраждалих чи інформація про пошкоджену інфраструктуру.

Мета задачі. Розробити модель машинного навчання для автоматичної класифікації гуманітарної інформації із соціальних мереж на основі текстових і графічних даних (твіти та пов'язані з ними зображення).

Модель повинна:

- Визначати, чи є дані інформативними.
- Класифікувати інформативні дані за категоріями гуманітарної інформації.
- Обробляти текстову та візуальну модальності одночасно для покращення точності.

Вхідними даними є пари текст-зображення з соціальних мереж (наприклад, Twitter). Набір даних CrisisMMD –містить 4383 пари текстів і зображень. Короткі повідомлення (до 280 символів), які можуть містити ключову інформацію про лихо. Фотографії, пов'язані з текстом, які можуть містити візуальні ознаки руйнувань, допомоги тощо. Кожна пара має мітку категорії (наприклад, «Постраждалі особи», «Пошкодження інфраструктури»). Приклади тексту твітів і пар зображень із різними мітками анотацій із різних катастроф наведені у додатку Б.

Мультимодальний набір даних CrisisMMD Twitter складається з кількох тисяч анотованих вручну твітів і зображень, зібраних під час семи великих стихійних лих, включаючи землетруси, урагани, лісові пожежі та повені, які сталися в 2017 році в різних частинах світу [27].

Таблиця 3.1 – Набір мультимодальних кризових даних

Назва кризи	Ключові слова	Дата початку	Кінцева дата
Ураган Ірма	Ураган Ірма, шторм Ірма, шторм Ірма, ураган Ірма, Ірма	6 вересня 2017 р	21 вересня 2017 р
Ураган Харві	Ураган Харві, Харві, Ураган Харві, Торнадо	25 серпня 2017 року	20 вересня 2017 року
Ураган Марія	Ураган Марія, Марія Сторм, Марія Циклон, Марія Торнадо, Тропічний шторм Марія, Ураган Марія, Пуерто-Ріко	20 вересня 2017 року	13 листопада 2017 року
Лісові пожежі в Каліфорнії	Каліфорнійська пожежа, Каліфорнійська лісова пожежа, Лісова пожежа Каліфорнія, США Лісова пожежа, Каліфорнійська лісова пожежа	10 жовтня 2017 року	27 жовтня 2017 року
Землетрус у Мексиці	землетрус у мексиці, землетрус у мексиці	20 вересня 2017 року	6 жовтня 2017
Ірако-іранський землетрус	землетрус в Кувейті, землетрус в Ірані, землетрус в Халабджа, землетрус в Іраку	13 листопада 2017 року	19 листопада 2017 року
Повені на Шрі-Ланці	повінь Шрі-Ланка, FloodSL, повінь у Шрі-Ланці, повінь у Шрі-Ланці, повінь у Шрі-Ланці, тайфун Мора, циклон Мора, Мора, Циклон Мора	31 травня 2017 р	3 липня 2017 р

Вихідними даними є мітки категорії для кожної пари текст-зображення: постраждалі особи; пошкодження інфраструктури та комунальних послуг; поранені чи загиблі; зниклі безвісти чи знайдені люди; рятувальні операції, волонтерство або благодійність; пошкодження транспортних засобів; інша важлива інформація; не стосується справи / не могу визначити.

Твіти можуть бути написані на різних мовах і стилях. Зображення можуть мати різну якість і контекст. Деякі категорії (наприклад, «Поранені чи загиблі») можуть бути менш представлені, ніж інші. Текст і зображення можуть мати різні типи

інформації, але бути контекстуально пов'язаними. У реальному часі необхідна швидка класифікація для негайної реакції гуманітарних організацій.

Алгоритм складається з наступних кроків:

Крок 1. Попередня обробка даних. Очистити текст твітів від стоп-слів, URL-адрес, спеціальних символів, емоційних позначок. Зменшити роздільну здатність зображень для оптимізації обчислень та нормалізувати піксельні значення. Використати метадані CrisisMMD для відображення тексту та зображень у відповідні категорії (наприклад, "Пошкодження інфраструктури").

Крок 2. Розробка моделі. Використати мультимодальну архітектуру, яка обробляє текст та зображення одночасно. Попередньо навчена модель BERT (або її модифікації) для обробки тексту твітів. Попередньо навчена модель ResNet або EfficientNet для витягування ознак із зображень. Об'єднати текстові та візуальні ознаки через шар злиття (наприклад, конкатенація чи увага) для створення спільного представлення. Додати повнозв'язний шар для класифікації категорій гуманітарної інформації.

Крок 3. Навчання моделі. Використати CrisisMMD як тренувальний і тестовий набір. Навчальна вибірка: 80% пар текст-зображення. Тестова вибірка: 20% пар для перевірки. Втратами є крос-ентропія для класифікації категорій; оптимізатор – adam з адаптивним навчальним коефіцієнтом.

Крок 4. Для оцінки моделі обчислюються точність, повнота та F1-міра для кожної категорії, а також оцінка важливості текстових і зображень для моделі за допомогою Grad-CAM або SHAP.

Крок 5. Результат у вигляді моделі, яка успішно класифікує пости на категорії, наприклад, модель ідентифікувала "Пошкодження інфраструктури" з точністю 87% і "Постраждалі особи" з точністю 83%.

### 3.2 Мультимодальна модель класифікації

Побудована мультимодальна модель класифікації, компонентами якої є блок обробки тексту, блок обробки зображення, шар злиття та класифікатор.

Компонент тексту обробляє текстові дані (твіти) для витягування ознак, що характеризують зміст, тональність і контекст повідомлення. Ці ознаки використовуються в мультимодальній моделі для класифікації гуманітарної інформації.

Компонент базується на попередньо навченій моделі трансформера, наприклад, BERT (Bidirectional Encoder Representations from Transformers). BERT спеціалізується на контекстному розумінні тексту, враховуючи як лівий, так і правий контекст кожного слова.

На першому кроці відбувається токенизація – вхідний текст (твіт) розбивається на токени за допомогою спеціального токенайзера BERT. Токенайзер додає спеціальні токени:

- [CLS] – початок послідовності (використовується для класифікації);
- [SEP] – кінець послідовності.

Наприклад:

Вхідний текст: "Землетрус зруйнував будинки."

Токени: ['[CLS]', 'Землетрус', 'зруйнував', 'будинки', '.', '[SEP]']

Кожен токен перетворюється в багатовимірний вектор (ембеддинг), який враховує:

- Лексичне значення токена.
- Позицію токена в тексті.
- Сегмент (у разі, якщо текст складається з кількох частин).

Ембеддинги токенів подаються в багатошаровий трансформер, який використовує механізм самоуваги для моделювання взаємозв'язків між словами в контексті всього тексту.

Вихідний вектор для токена [CLS] містить зведену інформацію про весь текст і використовується для класифікації.

Вектор [CLS] (наприклад, розміром 768 для BERT-base) подається на вихід компонента як представлення тексту.

Наприклад, твіт має такий зміст:

"Терміново! Люди під завалами, потрібна допомога. Місто X."



файлів).

- NumPy – робота з багатовимірними масивами (наприклад, текстовими ембеддингами).

Інструменти для розгортання:

- FastAPI або Flask – легкі веб-фреймворки для створення API, через які модель може взаємодіяти з іншими сервісами.

- Docker – використовується для контейнеризації моделі, щоб забезпечити її портативність.

- AWS SageMaker, Google Cloud AI, або Azure Machine Learning – хмарні платформи для розгортання та масштабування моделей.

Приклад базової реалізації наведений у листінгу 3.1.

### Листінг 3.1 – Приклад базової реалізації

```
from transformers import BertTokenizer, BertModel
# Завантаження токенайзера та моделі BERT
tokenizer = BertTokenizer.from_pretrained("bert-base-uncased")
model = BertModel.from_pretrained("bert-base-uncased")
# Вхідний текст
text = "Urgent! People are trapped under debris in City X."
# Токенізація
inputs = tokenizer(text, return_tensors="pt", truncation=True,
padding=True, max_length=128)
# Отримання текстових ознак
outputs = model(**inputs)
text_features = outputs.last_hidden_state[:, 0, :] # Вектор [CLS]
print(text_features.shape)
```

У результаті виконання цього коду буде отримано вектор ознак для введеного тексту, що представляє собою контекстне уявлення (embedding) цього тексту в 768-вимірному просторі (якщо використовується модель BERT-base). На кожному етапі відбудеться:

Завантажуються бібліотеки BertTokenizer і BertModel з бібліотеки transformers,

що дозволяє працювати з моделями BERT.

Використовується токенизатор `bert-base-uncased` для перетворення тексту в токени.

Завантажується модель BERT `bert-base-uncased`, що використовує 12 шарів і розмір векторів ознак 768.

Вхідний текст "Urgent! People are trapped under debris in City X." токенизується в набір токенів.

Параметри `return_tensors="pt"` означають, що вихід буде у форматі тензора PyTorch.

Параметри `truncation=True` і `padding=True` забезпечують, що текст буде обрізаний або доповнений до заданої довжини (максимум 128 токенів).

Токени передаються через модель BERT, яка виводить кілька об'єктів, серед яких `last_hidden_state`. Це тензор розміром (1, 128, 768), де 1 — це кількість прикладів, 128 — кількість токенів, а 768 — розмір вектора для кожного токена.

`last_hidden_state[:, 0, :]` вибирає перший токен [CLS], який містить вектор, що є агрегованим представленням всього тексту. Цей вектор має розмірність 768.

Вихідний результат буде тензором розміру (1, 768), що містить 768-вимірний вектор, який є контекстним представленням введеного тексту. Цей вектор можна використовувати для подальших завдань, таких як класифікація або аналіз тексту:

```
torch.Size([1, 768])
```

Цей тензор є векторним уявленням тексту, яке можна використовувати в наступних етапах моделювання, наприклад, для класифікації або побудови мультимодальних моделей.

## 4 МЕТОД ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ КРАУДСОРСИНГОВИХ ДАНИХ

### 4.1 Алгоритм оптичного розпізнавання символів OCR

Для аналізу зображень твітів і вилучення з них тексту будемо використовувати OCR (Optical Character Recognition) – алгоритми оптичного розпізнавання символів. Це технології, що дозволяють автоматично розпізнавати текст, який є частиною зображень або сканованих документів. Вони перетворюють текст, надрукований або написаний вручну, у машиночитний формат, що дозволяє редагувати, зберігати або обробляти його за допомогою комп'ютера. OCR зазвичай використовується для сканування паперових документів, книг, журналів або рукописних нотаток і перетворення їх у текстові файли.

Процес OCR включає кілька етапів.

Попередня обробка зображення – покращення якості зображення для забезпечення точності розпізнавання.

Розпізнавання символів – ідентифікація окремих символів на зображенні, їх класифікація та перетворення в текст.

Корекція помилок – перевірка результатів на наявність помилок за допомогою словників або контексту.

Виведення тексту – перетворення результату в текстовий формат.

Алгоритми виявлення об'єктів (object detection) спрямовані на виявлення і класифікацію об'єктів на зображеннях або відео. Вони дозволяють знаходити не тільки місцезнаходження об'єкта, але й визначати його тип. Виявлення об'єктів є важливою частиною комп'ютерного зору та має широке застосування в різних сферах, таких як безпека (розпізнавання осіб, транспортних засобів), автономні системи (автопілоти для автомобілів), медичні діагностики (визначення аномалій на зображеннях медичних сканувань).

Процес виявлення об'єктів зазвичай включає такі етапи:

Аналіз зображення – отримання та обробка зображення для виявлення потенційних об'єктів.

Розпізнавання об'єктів – застосування алгоритмів машинного навчання (наприклад, нейронних мереж) для виявлення і класифікації об'єктів.

Маркери та межі – визначення точного місця розташування об'єкта на зображенні.

Популярні методи для виявлення об'єктів включають алгоритми, такі як YOLO (You Only Look Once), R-CNN (Region Convolutional Neural Network) та SSD (Single Shot Multibox Detector), які застосовуються для реального часу або високоточних задач.

На рисунку 4.1 представлено схему, що описує процес аналізу даних соціальних медіа для класифікації інформації, пов'язаної з гуманітарними подіями.

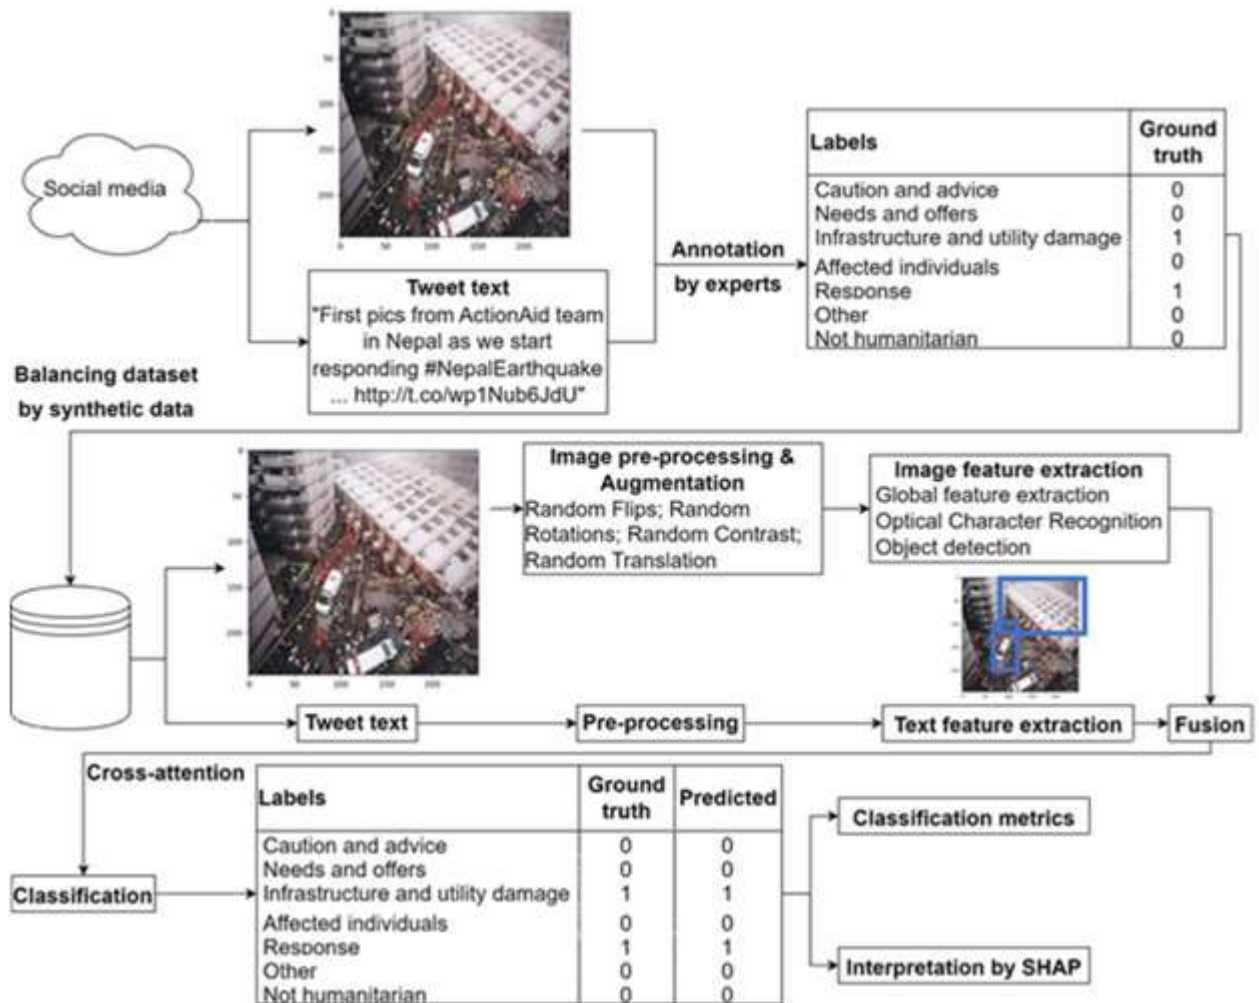


Рисунок 4.1 – Процес аналізу даних соціальних медіа для класифікації інформації

Вхідними даними є текст і зображення з соціальних медіа (твіти, супроводжені фотографіями). Текст і зображення мають бути позначені експертами для встановлення істинності даних (ground truth).

Експерти додають мітки до даних, визначаючи, чи стосуються вони категорій, таких як: попередження та поради; потреби та пропозиції; пошкодження інфраструктури; постраждалі особи; реакція; інше; не гуманітарна інформація.

Зображення проходять процедури покращення, зокрема випадкові повороти, відображення, контраст, трансляція тощо. Це допомагає збалансувати набір даних і підвищити стійкість алгоритмів до варіацій. Для зображення виконується глобальне витягування ознак, розпізнавання тексту (OCR), і виявлення об'єктів. Для тексту виконується витягування текстових ознак. Результати екстракції ознак із зображень та тексту об'єднуються (fusion).

Для класифікації обирається модель із використанням механізму cross-attention об'єднує текстові й візуальні ознаки для визначення категорій даних. Далі порівнюються передбачення моделі із встановленими істинними мітками (ground truth).

Результати оцінюються за допомогою метрик класифікації.

Інтерпретація моделі виконується за допомогою SHAP (SHapley Additive exPlanations), який дозволяє визначити вплив кожної ознаки на кінцеве рішення.

Таким чином, схема на рисунку 4.1 демонструє, як можна використовувати текстові та візуальні дані для створення моделі класифікації в контексті гуманітарних катастроф.

На рисунку 4.2 представлена радарна діаграма, яка демонструє розподіл значень за категоріями, пов'язаними з аналізом гуманітарних даних:

- Not humanitarian (NH) – некатегоризовані або негуманітарні дані.
- Caution and advice (CA) – попередження та поради.
- Needs and offers (NO) – потреби та пропозиції.
- Infrastructure and utility damage (IU) – пошкодження інфраструктури та комунікацій.
- Affected individuals (AF) – постраждалі особи.

- Response (RE) – реакція на події.
- Other humanitarian (OH) – інші гуманітарні аспекти.

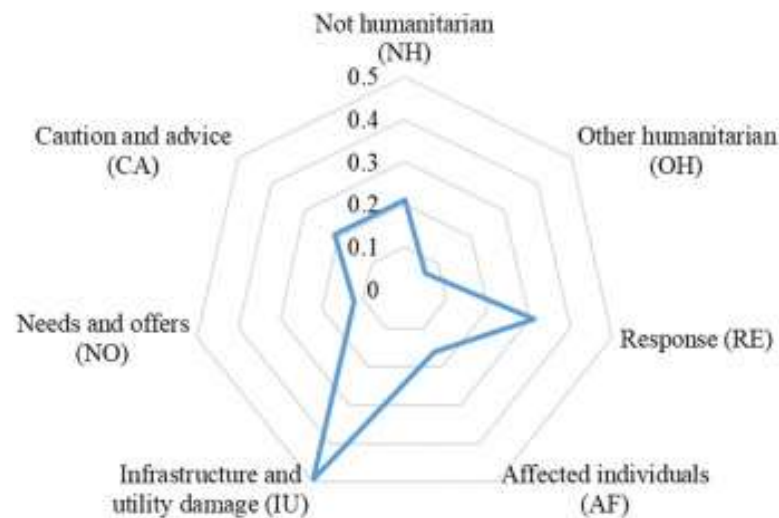


Рисунок 4.2 – Незбалансований набір даних гуманітарної інформації у стрічках соціальних мереж

Значення представлені у вигляді багатокутника, розташованого всередині діаграми. Кожна точка на осі відповідає частковому внеску або рівню важливості відповідної категорії. Найвищі значення спостерігаються у категорії Response (RE), що може свідчити про велику увагу до реакції в аналізованих даних. Категорії Not humanitarian (NH) та Caution and advice (CA) мають мінімальний внесок у багатокутник, що може свідчити про низьку присутність даних цих типів. Infrastructure and utility damage (IU) та Affected individuals (AF) мають середній рівень значень, що підкреслює їх важливість у розглянутих даних.

На рисунку 4.2 показано співвідношення записів з «виявленим контентом» і «невиявленим» для кожної гуманітарної категорії. Якщо це співвідношення дорівнює 0,5, це означає, що в класах «виявлено» і «не виявлено» однакова кількість записів даних. Для більшості категорій (за винятком «Пошкодження інфраструктури та об'єктів життєзабезпечення» (IU) і «Реагування» (RE)) це значення менше 0,25, що означає, що кількість записів у виявленому класі значно менша за кількість записів у невиявленому класі. Для вирішення проблеми незбалансованості вхідних наборів даних, проілюстрованої на рис. 3, в дослідженні [24] використовується GAN, в якому

нові дані генеруються для обслуговування наявних даних і збагачення класів з меншою кількістю записів даних. Відповідно до того, що обмеження на обмін зображеннями постраждалих осіб є однією з основних причин дисбалансу наборів даних про гуманітарну допомогу. Для вирішення цієї проблеми було створено лише синтетичні зображення. Цей метод створення синтетичних даних складається з генератора та дискримінатора, які працюють один проти одного. Генератор створює нові екземпляри даних, тоді як дискримінатор перевіряє дані і визначає, чи є кожен екземпляр даних «справжнім» з навчального набору даних, чи «підробленим» з генератора. Генератор і дискримінатор навчаються працювати один проти одного, поки генератор не зможе генерувати реалістичні синтетичні дані, які дискримінатор не зможе класифікувати як фальшиві.

Діаграма показує, що у вибірці гуманітарних даних найбільший акцент зроблено на реакції (Response), тоді як інші категорії, такі як поради та некатегоризовані дані, мають менший вплив. Це може слугувати основою для прийняття рішень про перенесення фокусу на менш розвинені аспекти аналізу.

Перед виконанням мультимодального аналізу за допомогою DL-моделей необхідна попередня обробка тексту та зображень твітів. Це пояснюється тим, що дані в їх первісній формі можуть бути шумними, некоректно структурованими або неадаптованими для моделей машинного навчання. Це необхідно тому, що тексти та зображення мають різну природу (текст є послідовністю символів, а зображення — матрицею пікселів), тому кожен тип потребує окремих підходів для перетворення у формат, який DL-моделі можуть обробляти. Твіти часто містять помилки, посилання, спеціальні символи, які можуть заважати моделі аналізувати контекст. Попередня обробка дозволяє зменшити шум і виділити суттєві особливості, що збільшує точність аналізу.

Попередня обробка тексту твіту містить розпакування скорочень, перетворення в малі літери, вставку пробілів між словами та розділових знаків. Крім того, під час попередньої обробки тексту видаляються символи хештегів (текст хештегу залишається), символні об'єкти HTML, текстові бігунки, гіперпосилання, пробіли, URL, RT, згадки (@), слова з двома або менше літерами, символи (&, < i >),

слова з помилками, розділові знаки, емодзі, символ Basic Multilingual Plane (BMP), стоп-слова. Для зображень твітів виконується доповнення зображень з метою збільшення кількості навчальних зображень шляхом переміщення зображення вздовж осі X або Y (або обох осей), обертання зображення навколо горизонтальної або вертикальної осі, а також зміни освітленості та темряви зображень.

Перед тим, як витягти глобальні ознаки з пари тексту та зображення, для аналізу зображення твіту застосовуються алгоритми оптичного розпізнавання символів (OCR) та виявлення об'єктів. OCR використовується для аналізу зображень твітів і вилучення з них тексту. Розпізнавання тексту та виявлення об'єктів є двома поширеними підходами, які дослідники використовують для аналізу контенту соціальних мереж. Крім того, виявлення об'єктів використовується для виявлення об'єктів на зображенні та визначення положення виявлених об'єктів. Для виявлення об'єктів у цьому фреймворку обрано модель Faster-RCNN. У цьому дослідженні використовується попередньо навчена модель Faster-RCNN Inception Resnet V2 від ImageNet, яка базується на екстракторах ознак Resnet та Inception Resnet.

## 4.2 Модель ALBERT

Для глобального вилучення ознак для текстової модальності обрано оригінальний BERT [8] та його модифіковану версію (ALBERT) [25]. BERT і ALBERT обрано на основі їхньої видатної ефективності у стрічках соціальних мереж для надання інформації про допомогу після стихійних лих.

ALBERT (A Lite BERT) це оптимізована та легша версія оригінальної моделі BERT (Bidirectional Encoder Representations from Transformers), яка була створена для зменшення витрат на обчислення та пам'ять, а також для підвищення продуктивності в задачах обробки природної мови (NLP). ALBERT був запропонований дослідниками з Google Research у 2019 році. У BERT розмір словникових ембеддингів та прихованих шарів однаковий, що призводить до значного споживання пам'яті. В ALBERT матриця ембеддингів поділяється на дві менші матриці:

1. Матриця меншого розміру для збереження словникових ембеддингів.

## 2. Матриця для перетворення їх у прихований простір.

Це знижує кількість параметрів без втрати продуктивності. ALBERT вводить нову форму регуляризації — інтервальний класифікатор (inter-sentence coherence loss), яка дозволяє краще навчати модель для задач розуміння відношень між реченнями (Sentence Pair Tasks). Це замінює завдання "Next Sentence Prediction" у BERT. ALBERT має значно менше параметрів, ніж BERT, але досягає подібної або навіть кращої якості на багатьох популярних NLP-задачах, таких як класифікація текстів, аналіз тональності, питання-відповідь тощо.

Для зображень і ConvNeXts розглядаються RegNetY320 - це проста і швидка мережа, яка використовується через її прийнятну продуктивність для CrisisMMD при класифікації інформації про гуманітарну допомогу. Крім того, ConvNeXt побудовані на основі стандартних модулів ConvNet і мають кращу продуктивність у різноманітних додатках для обробки зображень. TensorFlow Hub використовується для розробки BERT і ALBERT, тоді як інтерфейс прикладного програмування Keras застосовується для RegNetY320 і ConvNeXts.

Стратегія раннього злиття інтегрує виокремлені мультимодальні ознаки. Раннє злиття забезпечує більшу гнучкість для аналізу мультимодальності і демонструє кращу продуктивність, ніж пізнє злиття, для класифікації емоцій [26]. Згідно з припущенням попередніх досліджень, механізм перехресної уваги виконується після злиття, щоб сконцентруватися на важливій частині стрічки соціальних мереж. Перехресна увага є новим модулем для визначення цільових областей об'єкта та покращення дискримінації виокремленої ознаки. Через незбалансованість наборів даних у розробленому фреймворку в якості функції втрат використовується фокальна втрата. Фокальні втрати є варіантом бінарних перехресних ентропійних втрат, і саме вони використовуються в цьому дослідженні. Фокальні втрати є потужним рішенням для покращення продуктивності класифікаторів для незбалансованих наборів даних. Рівняння фокальних втрат використовується для вирішення проблеми незбалансованості класів у задачах класифікації, особливо в таких завданнях, як виявлення об'єктів, де негативні приклади (фон) значно переважають позитивні. Це вдосконалення класичної крос-ентропійної функції втрат.

Рівняння (4.1) фокальних втрат наведено нижче:

$$FL(p_t) = -\alpha_t(1 - p_t)^\gamma \log(p_t) \quad (4.1)$$

де  $\gamma$  - параметр фокусування на класі дисбалансу; якщо  $\gamma = 0$ , то фокусні втрати будуть подібні до перехресної ентропії;  $\alpha_t$  - коефіцієнт балансування;  $p_t$  можна оцінити на основі наступного рівняння (4.2):

$$p_t = \begin{cases} -p, \mathcal{Y} = 1 \\ 1 - p, \text{otherwise} \end{cases} \quad (4.2)$$

де  $\mathcal{Y}$  - клас правдивих даних (один клас інформації про гуманітарну допомогу);  $p$  - ймовірність, оцінена моделлю глибокого навчання. Для генерації та верифікації всіх моделей використовується мова Python та відповідні пакети.

У випадку незбалансованості класів, "легкі" приклади (де  $p_t$  близьке до 1) можуть домінувати у функції втрат, перешкоджаючи моделі навчатися на "важких" прикладах. Фокальні втрати знижують вплив добре передбачених прикладів на загальні втрати, дозволяючи моделі зосередитись на складних випадках.

$\alpha_t$  застосовується для зменшення впливу класів із великою кількістю зразків, компенсуючи нерівність між класами.

Роль  $(1-p_t)^\gamma$ : якщо  $p_t$  велике (тобто приклад передбачений правильно),  $(1-p_t)^\gamma$  зменшується, що зменшує втрату для цього прикладу; якщо  $p_t$  мале (тобто приклад важкий),  $(1-p_t)^\gamma$  стає більшим, підсилюючи втрату для цього прикладу.

### 4.3 Фреймворк, що ґрунтується на методі проб і помилок

Налаштування параметрів розробленого фреймворку, що ґрунтується на методі проб і помилок, наведено в таблиці 4.1. Вказані налаштування оптимізують продуктивність фреймворку в мультимодальному аналізі (наприклад, робота із зображеннями та текстами). Низький коефіцієнт Dropout та добре налаштована

швидкість навчання допомагають знайти баланс між швидкістю конвергенції та узагальненням. Використання Binary Focal Loss і GAN-синтетичних даних вирішує проблему незбалансованості та покращує якість класифікації.

Таблиця 4.1 – Параметри розробленого фреймворку

Параметр	Налаштування
Input image size	224 × 224 pixels
Dropout rate	0.25
Activation function	ReLU, Sigmoid
Batch size	32
Learning rate	0.00002
Optimizer	Adam
Loss function	Binary Focal Loss (gamma = 2)
Number of hidden layers after fusion	2
Number of neurons in each hidden layer after fusion	256, 64
Number of GAN synthetic images for each run	25

Для ефективного налаштування розробленого фреймворку було проведено наступне тестування методом проб і помилок (рис. 4.3.)

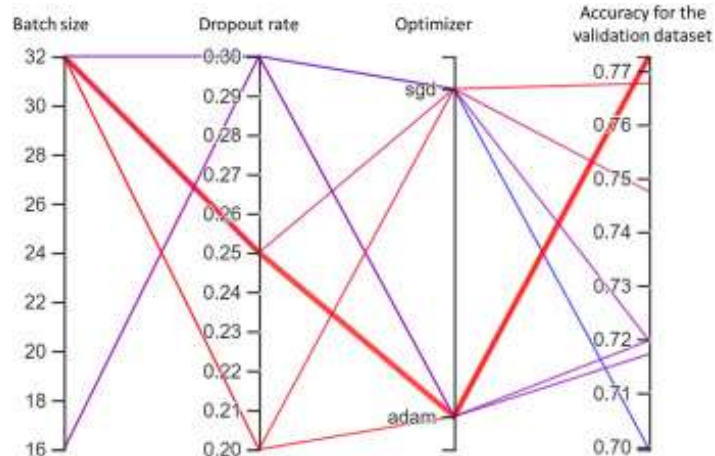


Рисунок 4.3 – Налаштування гіперпараметрів моделей глибокого навчання

Графік на рисунку 4.2 показує залежність точності моделі на валідаційній вибірці від налаштувань гіперпараметрів. Batch size визначає кількість зразків, які обробляються одночасно під час одного кроку навчання. Різні значення (16, 32) впливають на навчання моделі та точність на валідації. Розмір пакету 32 показує кращу точність (0.77), ніж розмір 16. Це може бути пов'язано з тим, що більший розмір пакету сприяє більш стабільним оновленням градієнтів.

Dropout rate зменшує ризик перенавчання шляхом випадкового вимкнення нейронів під час навчання. Експерименти проводяться з різними значеннями (0.20–0.30). Ймовірність 0.30 показує кращий результат на валідаційній вибірці. Можливо, це значення краще запобігає перенавчанню.

Optimizer – вибір оптимізатора (наприклад, SGD або Adam) впливає на оновлення ваг мережі під час навчання. Оптимізатор Adam забезпечує вищу точність (0.77), ніж SGD. Це може бути зумовлено адаптивною природою Adam, який краще підходить для більшості моделей.

Accuracy for the validation dataset це ключова метрика, яка демонструє, наскільки добре модель узагальнює свої знання на невідомих даних.

Оптимальні налаштування гіперпараметрів для цієї моделі:

- Batch size: 32
- Dropout rate: 0.30
- Optimizer: Adam

Поєднання цих параметрів забезпечує найвищу точність на валідаційній вибірці.

Для оцінки ефективності моделей класифікаторів використовуються показники точності, точності, пригадування та F1-бали. Ці метрики допомагають зрозуміти, наскільки добре модель класифікує дані. Рівняння (4.3), (4.4), (4.5), (4.6) показують, як обчислити точність, точність, пригадування та оцінку F1 відповідно.

Точність показує, яку частку правильних передбачень зробила модель відносно загальної кількості передбачень:

$$Accuracy = \frac{True\ positive + True\ negative}{True\ positive + True\ negative + False\ positive + False\ negative} \quad (4.3)$$

Точність (іноді називається прецизійністю) показує частку правильно передбачених позитивних результатів від усіх передбачених позитивних результатів:

$$Precision = \frac{True\ positive}{True\ positive + False\ positive} \quad (4.4)$$

Пригадування (іноді називається чутливістю) показує частку правильно передбачених позитивних результатів від усіх фактичних позитивних результатів:

$$Recall = \frac{True\ positive}{True\ positive + False\ positive} \quad (4.5)$$

F1-бал є гармонічним середнім між точністю та пригадуванням, і він забезпечує баланс між цими двома метриками. F1-бал особливо корисний, коли потрібно враховувати як False Positives, так і False Negatives.

$$F1\ score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (4.6)$$

True Positive (TP) – Кількість правильних позитивних передбачень.

True Negative (TN) – Кількість правильних негативних передбачень.

False Positive (FP) – Кількість неправильно передбачених позитивних результатів (тип I помилка).

False Negative (FN) – Кількість неправильно передбачених негативних результатів (тип II помилка).

Істинно позитивний (істина і прогноз = 1) і істинно негативний (істина і прогноз = 0) - це правильні класифікації інформації про гуманітарну допомогу. Хибнопозитивний (істина = 1, а прогноз = 0) і хибнонегативний (істина = 0, а прогноз = 1) означають, що модель ML не змогла точно передбачити клас.

Ці метрики допомагають оцінити модель з різних аспектів, залежно від того, що є більш важливим для конкретного застосування: загальна точність, здатність правильно передбачати позитивні результати або баланс між точністю та пригадуванням.

#### 4.4 Програмна реалізація аналізу даних з краудсорсингу

Було обрано та впроваджено SHAP з бібліотекою Python, щоб зрозуміти поведінку розробленого фреймворку при класифікації соціальної стрічки гуманітарної допомоги (Лістинг 4.1).

Бібліотека SHAP (SHapley Additive exPlanations) є потужним інструментом для пояснення виходів моделей машинного навчання. Вона дозволяє оцінити внесок кожної ознаки у передбачення моделі, використовуючи значення Шеплі (Shapley values). SHAP сумісний з багатьма популярними бібліотеками Python для машинного навчання, такими як scikit-learn, XGBoost, LightGBM, CatBoost та інші.

##### Лістинг 4.1 – Використання SHAP з XGBoost

```
import xgboost as xgb
import shap
import numpy as np
import pandas as pd
from sklearn.model_selection import train_test_split
# Завантаження даних
data =
pd.read_csv("https://github.com/selva86/datasets/raw/master/BostonHousing.csv")
X = data.drop("medv", axis=1)
y = data["medv"]
# Розділення даних на тренувальний та тестовий набори
X_train, X_test, y_train, y_test = train_test_split(X, y,
test_size=0.2, random_state=42)
# Тренування моделі XGBoost
```

```

model = xgb.XGBRegressor(objective="reg:squarederror",
random_state=42)
model.fit(X_train, y_train)
# Створення об'єкту explainer для моделі
explainer = shap.Explainer(model)
# Обчислення SHAP-значень для тестового набору
shap_values = explainer(X_test)
# Візуалізація SHAP-значень для окремого передбачення
shap.initjs()
shap.force_plot(explainer.expected_value, shap_values[0,:],
X_test.iloc[0,:])
# Візуалізація важливості ознак для моделі
shap.summary_plot(shap_values, X_test)

```

Застосування значень SHAP для аналізу текстових даних може допомогти зрозуміти, як кожне слово або фраза впливають на класифікацію тексту, наприклад, для виявлення важливої інформації про гуманітарну допомогу в кризових ситуаціях. На лістингу 4.2 наведено приклад використання SHAP з моделлю на основі TF-IDF та Logistic Regression для класифікації текстових повідомлень:

#### Лістинг 4.2

```

import shap
import numpy as np
import pandas as pd
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.linear_model import LogisticRegression
from sklearn.model_selection import train_test_split
# Зразкові дані
data = pd.DataFrame({
    'text': [
        'Need urgent medical help in the flood-affected area',
        'Food and water required immediately for displaced families',
        'Looking for shelter for people affected by the earthquake',
        'Supplies are running low, need more humanitarian aid',

```

```

        'Volunteers needed to help with distribution of aid'
    ],
    'label': [1, 1, 1, 1, 0] # 1 - потребує допомоги, 0 - не
потребує допомоги
}))
# Розділення даних на тренувальний та тестовий набори
X_train, X_test, y_train, y_test = train_test_split(data['text'],
data['label'], test_size=0.2, random_state=42)
# Перетворення тексту в TF-IDF
vectorizer = TfidfVectorizer()
X_train_tfidf = vectorizer.fit_transform(X_train)
X_test_tfidf = vectorizer.transform(X_test)
# Тренування моделі Logistic Regression
model = LogisticRegression()
model.fit(X_train_tfidf, y_train)
# Створення об'єкту explainer для моделі
explainer = shap.Explainer(model, X_train_tfidf)
# Обчислення SHAP-значень для тестового набору
shap_values = explainer(X_test_tfidf)
# Перетворення тестових даних назад у слова для візуалізації
feature_names = vectorizer.get_feature_names_out()
shap.plots.text(shap_values, feature_names=feature_names)

```

Спочатку використовуємо простий набір текстових даних з повідомленнями про кризові ситуації та їх метками (1 - потребує допомоги, 0 - не потребує допомоги).

Перетворюємо текстові дані у числовий формат за допомогою TF-IDF векторизатора.

Далі тренуємо просту модель Logistic Regression.

Використовуємо SHAP для обчислення значень SHAP і пояснення внеску кожного слова у класифікацію.

Використовуємо SHAP для візуалізації, щоб показати, які слова найбільше впливають на передбачення.

Значення SHAP можуть продемонструвати внесок кожного слова в класифікацію та виявити важливість інформації про гуманітарну допомогу. Вибір SHAP для інтерпретації моделей глибокого навчання для гуманітарної допомоги в цьому дослідженні пов'язаний з трьома ключовими атрибутами SHAP. По-перше, SHAP-аналіз враховує взаємозалежності між змінними, щоб кількісно оцінити вагу кожної ознаки в моделі ML. По-друге, SHAP здатний справедливо розподілити важливість кожної ознаки, яка може бути важливою для діяльності з надання гуманітарної допомоги. По-третє, SHAP є найповнішим методом пояснення моделей машинного навчання, і його можна використовувати для різних типів даних, таких як текст і зображення. Кожна модальність інтерпретується окремо за допомогою шейп-значень.

#### 4.5 Підхід до інтелектуального аналізу краудсорсингових даних

Для створення підходу до інтелектуального аналізу даних з краудсорсингових платформ під час кризових ситуацій можна застосувати комплексний підхід, що поєднує кілька ключових технологій та методів з аналізу великих даних, машинного навчання та мультимодального аналізу.

1. Збір даних. Використовувати краудсорсингові платформи, зокрема соціальні мережі, мобільні додатки та спеціалізовані веб-сайти для збору різноманітних даних: текстових повідомлень, зображень, відео та геолокаційних даних.

Дані можуть бути різних типів: текстові повідомлення (твіттер, пости в соцмережах), зображення (фото з місць подій, супутникові знімки), відео (мобільні записи користувачів) та геолокаційні дані (GPS-координати).

2. Проблеми збору даних. Для забезпечення якості й надійності даних застосовувати попередню перевірку через антиспамові алгоритми, фільтрацію фейкових або надлишкових повідомлень. Використовувати технології шифрування та анонімізації для захисту конфіденційної інформації та забезпечення відповідності нормативним вимогам (наприклад, GDPR).

3. Інтелектуальний аналіз даних. Для аналізу текстових даних застосовувати

алгоритми обробки природної мови, зокрема, BERT, ALBERT, для виділення ключових слів, визначення теми повідомлення, та категоризації за критичністю ситуацій.

Для аналізу зображень використовувати моделі глибокого навчання, такі як ResNet, EfficientNet, YOLO для виявлення пошкоджень інфраструктури, людей, що потребують допомоги, чи інших важливих об'єктів на зображеннях.

Використовувати геолокаційні дані для ідентифікації критичних зон на карті та побудови прогностичних моделей щодо розвитку кризової ситуації, наприклад, для моніторингу зони повені або руху евакуаційних потоків.

Для обробки великих обсягів даних застосовувати Hadoop, Spark для зберігання і аналізу великих даних, що надходять у реальному часі.

4. Аналіз мультимодальних даних. Об'єднання текстових і візуальних даних для покращення точності виявлення критичних ситуацій. Наприклад, застосування мультимодальних моделей машинного навчання, що комбінують текстові ознаки з BERT і візуальні ознаки з ResNet для кращого аналізу та точнішого прогнозування.

Використання OCR для автоматичного вилучення тексту з зображень, що дозволить оперативно реагувати на важливі повідомлення, що супроводжуються зображеннями.

5. Автоматизація процесів. Використовувати машинне навчання для автоматизації класифікації та виявлення важливих подій. Наприклад, класифікація повідомлень про заклики до допомоги, пошкоджену інфраструктуру, постраждалих людей.

Застосування моделей глибокого навчання, таких як LSTM, ALBERT для виявлення тенденцій у текстових повідомленнях та прогнозування можливих кризових подій.

Інтеграція синтетичних даних для балансування наборів даних і покращення точності моделей.

6. Прогнозування розвитку кризових ситуацій. Створення моделей для прогнозування розвитку ситуацій на основі зібраних даних. Це можуть бути моделі, що оцінюють ступінь ризику в конкретних зонах, прогнозують часові рамки та

ймовірність наступних подій (наприклад, землетрусів, повеней чи соціальних заворушень).

Використовувати аналітику великих даних для виявлення аномалій та патернів, що вказують на можливі майбутні кризові події.

7. Підтримка прийняття рішень. Розробка систем підтримки прийняття рішень для організацій, що займаються гуманітарною допомогою, які забезпечують оптимізацію ресурсів на основі результатів інтелектуального аналізу даних.

Визначення критичних зон на карті за допомогою геопросторового аналізу для направлення допомоги в найпотрібніші місця в перші години після початку кризи.

8. Перспективи розвитку. Застосування нових методів глибокого навчання для вдосконалення класифікації та прогнозування, таких як нейронні мережі, здатні враховувати складні залежності між різними типами даних.

Розвиток інтегрованих платформ, які об'єднують різні типи даних для комплексного аналізу та оперативної реакції на ситуацію.

9. Етика та конфіденційність. Акцент на захисті особистих даних, зокрема через анонімізацію даних, використання політик захисту конфіденційності для запобігання несанкціонованому доступу до чутливих даних.

Загалом, цей підхід забезпечує інтеграцію різноманітних технологій для ефективного та швидкого аналізу даних з краудсорсингових платформ у кризових ситуаціях, сприяючи оперативному виявленню критичних зон і підтримці прийняття рішень в умовах нестабільності.

## ВИСНОВКИ

Аналіз краудсорсингових даних у кризових ситуаціях показав значний потенціал цього інструменту для збору та обробки великих обсягів інформації, що надходить у реальному часі через соціальні мережі та мобільні додатки. Виявлено ключові проблеми, зокрема достовірність даних, обсяги інформації та захист конфіденційності, що потребують інтеграції інтелектуальних методів аналізу для ефективного використання краудсорсингу в кризових ситуаціях.

Мультимодальний підхід до обробки гуманітарної інформації забезпечує значні переваги, оскільки поєднання текстових і візуальних даних підвищує точність класифікації і дозволяє швидше та точніше реагувати на зміни в кризових ситуаціях. Використання моделей машинного навчання, таких як BERT та ALBERT, виявилось ефективним для обробки великих обсягів інформації, що містить як текст, так і зображення.

Запропоновано підхід до інтелектуального аналізу даних, що збираються з краудсорсингових платформ під час кризових ситуацій. Збір даних здійснюється з різних джерел, таких як соціальні мережі, мобільні додатки та спеціалізовані платформи, що дозволяють отримувати текстові повідомлення, зображення, відео та геолокаційні дані. Застосовуються методи фільтрації для забезпечення достовірності даних і захисту конфіденційності користувачів.

Для аналізу даних використовуються сучасні алгоритми обробки природної мови (NLP), комп'ютерний зір, геопросторовий аналіз та мультимодальні моделі, що поєднують текстові й візуальні дані. Ці технології дозволяють класифікувати повідомлення, виявляти пошкодження інфраструктури та прогнозувати розвиток кризи.

Автоматизація процесів класифікації та прогнозування за допомогою глибокого навчання сприяє ефективному реагуванню на ситуації. Прогнозування розвитку подій дозволяє оцінити ризики і ймовірність подальших пошкоджень або розширення зони катастрофи. Важливу роль відіграють питання етики, захисту даних і підтримки

прийняття рішень для гуманітарних організацій, що дозволяє оперативно реагувати та оптимізувати використання ресурсів під час криз.

Таким чином, кваліфікаційна робота демонструє високий потенціал для вдосконалення процесів збору та аналізу даних у кризових ситуаціях з використанням новітніх технологій машинного навчання, глибокого навчання та обробки зображень, що забезпечить значну підтримку у гуманітарних та кризових дослідженнях.

## ПЕРЕЛІК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. X. Ning, L. Yao, X. Wang, B. Benatalla, Calling for response: automatically distinguishing situation-aware tweets during crises.
2. F. Alam, F. Ofli, M. Imran, Crisismmd: multimodal twitter datasets from natural disasters
3. C. Rajeshkannan, S. Kogilavani, Modelling of flood prediction by optimizing multimodal data using regression network
4. M. Arashpour, V. Kamat, A. Heidarpour, M.R. Hosseini, P. Gill, Computer vision for anatomical analysis of equipment in civil infrastructure projects: theorizing the development of regression-based deep neural networks
5. S. Behl, A. Rao, S. Aggarwal, S. Chadha, H.S. Pannu, Twitter for disaster relief through sentiment analysis for COVID-19 and natural hazard crises
6. S.D. Mohanty, et al., A multi-modal approach towards mining social media data during natural disasters-A case study of Hurricane Irma
7. J. Devlin, M.-W. Chang, K. Lee, K. Toutanova, Bert: Pre-Training Of Deep Bidirectional Transformers For Language Understanding
8. Z. Han, M. Jian, G.-G. Wang, ConvUNeXt: an efficient convolution neural network for medical image segmentation
9. S. Kotha, S. Haridasan, A. Rattani, A. Bowen, G. Rimmington, and A. Dutta, "Multimodal combination of text and image tweets for disaster response assessment," 2022: International Workshop on Data-Driven Resilience Research.
10. B. Wu, L. Liu, Y. Yang, K. Zheng, X. Wang, Using improved conditional generative adversarial networks to detect social bots on Twitter
11. T. Zhou, Q. Li, H. Lu, Q. Cheng, X. Zhang, GAN review: models and medical image fusion applications
12. M. Haggag, A. Yosri, W. El-Dakhakhni, E. Hassini, Interpretable data-driven model for Climate-Induced Disaster damage prediction: the first step in community resilience planning

13. M. Arashpour, et al., Predicting individual learning performance using machine-learning hybridized with the teaching-learning-based optimization
14. Y. Chen, S. He, Z. Zhou, Investigation of social media representation bias in disasters: towards a systematic framework
15. R.I. Ogie, S. James, A. Moore, T. Dilworth, M. Amirghasemi, J. Whittaker, Social media use in disaster recovery: a systematic literature review
- Devaraj, D. Murthy, A. Dontula, Machine-learning methods for identifying social media-based requests for urgent help during hurricanes
16. F. Sakahira, U. Hiroi, Designing cascading disaster networks by means of natural language processing
17. M. Karimiziarani, K. Jafarzadegan, P. Abbaszadeh, W. Shao, H. Moradkhani, Hazard risk awareness and disaster management: extracting the information content of twitter data
18. N.R. Paul, D. Sahoo, R.C. Balabantaray, Classification of crisis-related data on Twitter using a deep learning-based framework
19. P.K. Roy, A. Kumar, J.P. Singh, Y.K. Dwivedi, N.P. Rana, R. Raman, Disaster related social media content processing for sustainable cities
20. J.G.D. Harb, R. Ebeling, K. Becker, A framework to analyze the emotional reactions to mass violent events on Twitter and influential factors
21. J. Deng, W. Dong, R. Socher, L.-J. Li, K. Li, L. Fei-Fei, Imagenet: A Large-Scale Hierarchical Image Database
22. C.V. Pennington, et al., A near-real-time global landslide incident reporting tool demonstrator using social media and artificial intelligence
23. S. Liu, H. Jiang, Z. Wu, Y. Liu, K. Zhu, Machine fault diagnosis with small sample based on variational information constrained generative adversarial network
24. Z. Lan, M. Chen, S. Goodman, K. Gimpel, P. Sharma, R. Soricut, Albert: A Lite Bert For Self-Supervised Learning Of Language Representations
25. H. Gunes, M. Piccardi, Affect recognition from face and body: early fusion vs. late fusion

26. P. Linardatos, V. Papastefanopoulos, S. Kotsiantis, Explainable ai: a review of machine learning interpretability methods.

27. Набір мультимодальних кризових даних  
[https://crisisnlp.qcri.org/crisismmd#data\\_version2.0](https://crisisnlp.qcri.org/crisismmd#data_version2.0)

28. Скрябін А. О. Моделювання конфліктів і співпраці при розподілі ресурсів під час кризової ситуації Комп'ютерні інтелектуальні системи та мережі. Матеріали XVII Всеукраїнської науково практичної WEB конференції аспірантів, студентів та молодих вчених. – Кривий Ріг: 2024.С. 243-245

29. Axak N., Korablyov M., Rosinskiy D. MapReduce Hadoop Models for Distributed Neural Network Processing of Big Data Using Cloud Services / Advances in Intelligent Systems and Computing IV. / Editors: Shakhovska, Natalya; Medykovskyy, Mykola O., Springer, 2019. – pp. 387 – 400. ISSN: 2194-5357 //doi.org/10.1007/978-3-030-33695-0 (Входить до міжнародної наукометричної бази Scopus)

30. Axak N, Tatarnykov A. Development of Computer Vision Based Model to Support Learning Process. Proceedings of the 7th International Conference, COLINS-2023. Volume IV: Poster and Student Workshop, pp. 76-87 ISSN 2523-4013

31. Н.Г. Аксак, Н.М. Сердюк, Система віддаленого моніторингу та прогнозування стану здоров'я працівника // Інформаційні технології та системи: монографія / за заг. ред . В. С. Пономаренка. - Х. : Видавництво «Стиль-іздат», 2020. 174 с.

32. Mykola Korablyov, Oleksandr Fomichov, Natalia Axak. Classification of objects based on a tree-shaped artificial immune network model / Advances in Intelligent Systems and Computing V. / Editors: Shakhovska, Natalya; Medykovskyy, Mykola O., Springer, 2020. – pp. 160-172.