

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Комп'ютерних наук
(повна назва)
Кафедра Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти другий (магістерський)

Розробка та дослідження класифікатора пожеж на зображеннях за допомогою
згорткових нейронних мереж (CNN)
(тема)

Виконав:
здобувач другого року навчання,
групи ДСМ-23-1
Семенко І.О.
(прізвище, ініціали)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)

Освітня програма Науки про дані (Data Science)

(повна назва спеціалізації)
Керівник проф. Філатов В.О.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____
(підпис)

О.В. Золотухін
(прізвище, ініціали)

2025 р.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук _____
(повна назва)
Кафедра _____ Штучного інтелекту _____
(повна назва)
Рівень вищої освіти _____ другий (магістерський) _____
Спеціальність _____ 122 Комп'ютерні науки _____
(код і повна назва)
Тип програми _____ освітньо-професійна _____
(освітньо-професійна або освітньо-наукова)
Освітня програма _____ Науки про дані (Data Science) _____
(повна назва)

ЗАТВЕРДЖУЮ:
Зав. кафедри _____
(підпис)
« _____ » _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Семенку Іллі Олексійовичу _____
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Розробка та дослідження класифікатора пожеж на зображеннях за допомогою згорткових нейронних мереж (CNN) _____

затверджена наказом університету від 22 листопада 20 24 р. № 1238Ст

2. Термін подання студентом роботи до екзаменаційної комісії 16 січня 20 25 р.

3. Вихідні дані до роботи _____ Науково-технічні публікації, що стосуються глибокого навчання та методів виявлення пожеж, дані Інтернет-джерел та актуальних наукових проєктів у сфері штучного інтелекту, документація Python та бібліотек TensorFlow/Keras, набір зображень для тренування, валідації та тестування класифікатора пожеж, моделі попереднього навчання (MobileNetV2, EfficientNetB0) з відкритим доступом _____

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Огляд проблеми _____

2) Огляд аналогів _____

3) Методологічний огляд підходів до вирішення проблеми _____

4) Формулювання проблеми _____

5) Опис архітектури та алгоритмів роботи запропонованої системи класифікації пожеж _____

6) Аналіз отриманих результатів _____

7) Рекомендації щодо практичного застосування розробки _____

8) Аналіз етичних проблем та способів їх вирішення _____

РЕФЕРАТ

Пояснювальна записка: 80 с., 11 рис., 2 дод., 22 джерел.

ВИЯВЛЕННЯ ЗАЙМАНЬ, ГЛИБОКЕ НАВЧАННЯ, ЗГОРТКОВА НЕЙРОННА МЕРЕЖА, КЛАСИФІКАЦІЯ ПОЖЕЖ, КОМП'ЮТЕРНИЙ ЗІР, МОНІТОРИНГ БЕЗПЕКИ.

Об'єкт дослідження – системи автоматичного виявлення та класифікації пожеж на зображеннях.

Предмет дослідження – методи та алгоритми класифікації пожеж за допомогою згорткових нейронних мереж.

Мета роботи – розробка та дослідження системи класифікації пожеж на зображеннях з використанням згорткових нейронних мереж (CNN), що забезпечує високу точність класифікації в реальних умовах експлуатації.

Методи дослідження – аналіз існуючих рішень, математичне моделювання, експериментальне дослідження, статистичний аналіз, комп'ютерне моделювання та програмна реалізація.

Проведено комплексний аналіз сучасних методів виявлення та класифікації пожеж, досліджено архітектури згорткових нейронних мереж та методи їх оптимізації. Використано спеціалізований набір даних для навчання мережі, що містить 5000 розмічених зображень.

На основі проведених досліджень розроблено оригінальну архітектуру CNN та програмну систему, що досягає точності класифікації 98% для основних типів пожеж при низькому рівні помилкових спрацьовувань. Запропоновано методи оптимізації для роботи в режимі реального часу та рекомендації щодо практичного впровадження.

ABSTRACT

Master's thesis contains: 80 pp., 11 fig., 2 ann., 22 references.

COMPUTER VISION, CONVOLUTIONAL NEURAL NETWORK, DEEP LEARNING, FIRE CLASSIFICATION, FIRE DETECTION, SAFETY MONITORING.

Research object – systems for automatic detection and classification of fires in images.

Research subject – methods and algorithms for fire classification using convolutional neural networks.

The purpose of the work – development and research of a fire classification system in images using convolutional neural networks (CNN), providing high classification accuracy in real operating conditions.

Research methods – analysis of existing solutions, mathematical modeling, experimental research, statistical analysis, computer modeling, and software implementation.

A comprehensive analysis of modern fire detection and classification methods has been conducted, CNN architectures and their optimization methods have been investigated. A specialized dataset for network training has been used, containing 5000 labeled images.

Based on the conducted research, an original CNN architecture and software system have been developed, achieving 98% classification accuracy for main fire types with a low false alarm rate. Optimization methods for real-time operation and recommendations for practical implementation have been proposed.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів	8
Вступ.....	9
1 Огляд проблеми.....	11
1.1 Аналіз традиційних методів виявлення пожеж	11
1.1.1 Обмеження традиційних датчиків	11
1.1.2 Проблеми масштабування та інтеграції	11
1.2 Сучасні підходи до виявлення пожеж.....	12
1.2.1 Методи комп'ютерного зору	12
1.2.2 Застосування глибокого навчання	12
1.3 Виклики та перспективи розвитку систем класифікації пожеж	12
1.3.1 Технічні виклики.....	13
1.3.2 Методологічні аспекти	13
1.4 Перспективні напрямки досліджень	13
1.5 Вимоги до сучасних систем класифікації пожеж	13
2 Огляд аналогів	15
2.1 Традиційні алгоритмічні підходи	15
2.2 Методи на основі класичного машинного навчання.....	16
2.3 Гібридні системи виявлення	16
2.4 Системи на основі аналізу руху.....	16
2.5 Спектральний аналіз	17
2.6 Порівняльний аналіз існуючих рішень	17
3 Методи вирішення завдання	19
3.1 Методологічний огляд підходів до класифікації пожеж	19
3.2 Теоретичне обґрунтування вибору згорткових нейронних мереж	20
3.3 Методологічні переваги використання CNN	21
4 Формулювання проблеми.....	23
4.1 Постановка проблеми вдосконалення процесів класифікації пожеж	23
4.2 Аналіз сучасного стану технологій	24

4.3	Визначення мети дослідження та задач роботи.....	25
4.4	Опис інноваційного характеру застосованого підходу.....	26
5	Методи та реалізація.....	27
5.1	Обґрунтування вибору архітектури згорткових нейронних мереж...	27
5.2	Порівняльний аналіз сучасних моделей глибокого навчання.....	29
5.3	Реалізація класифікатора пожеж.....	30
5.3.1	Підготовка даних та технічна інфраструктура.....	30
5.3.2	Опис архітектури моделі та вибір гіперпараметрів.....	33
5.3.3	Опис процесу розробки та експериментів.....	35
5.3.4	Налаштування метрик оцінювання моделі.....	39
5.3.5	Оцінка продуктивності моделі на тестових даних.....	42
6	Результати досліджень.....	47
6.1	Аналіз точності, втрат та продуктивності моделі.....	47
6.2	Порівняння отриманих результатів із існуючими підходами.....	49
6.3	Обговорення обмежень моделі та напрямків її вдосконалення.....	51
7	Практичне застосування.....	53
7.1	Рекомендації щодо інтеграції моделі у сучасні системи безпеки.....	53
7.2	Оцінка економічного та соціального ефекту від застосування.....	55
8	Етичні аспекти застосування застосування системи.....	57
8.1	Потенційні ризики неправильної класифікації.....	57
8.2	Конфіденційність.....	58
8.3	Зменшення ризиків використання ШІ у сфері ідентифікації пожеж.....	59
	Висновки.....	61
	Перелік джерел посилання.....	63
	Додаток А Код розробленої програми.....	66
	Додаток Б Відомість кваліфікаційної роботи.....	80

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

- ШІ – штучний інтелект;
- AI – Artificial Intelligence – штучний інтелект;
- BCE – Binary Cross-Entropy – двійкова крос-ентропія;
- CNN – Convolutional Neural Network – згорткова нейронна мережа;
- CNN-LSTM – Convolutional Neural Network Long Short-Term Memory – гібридна модель згорткової нейронної мережі та довготривалої пам'яті;
- DL – Deep Learning – глибоке навчання;
- GPU – Graphics Processing Unit – графічний процесор;
- HSV – Hue, Saturation, Value – колірна модель, яка використовується для кодування кольорів;
- LR – Learning Rate – швидкість навчання;
- MAE – Mean Absolute Error – середня абсолютна похибка;
- ML – Machine Learning – машинне навчання;
- RGB – Red, Green, Blue – система кодування кольорів;
- SGD – Stochastic Gradient Descent – стохастичний градієнтний спуск;
- TPU – Tensor Processing Unit – тензорний процесор;
- YCbCr – Y: Luma (світність), Cb: Blue-difference Chroma, Cr: Red-difference Chroma – колірна модель для кодування відео та зображень.

ВСТУП

Наразі в Україні та деяких сусідніх країнах спостерігається висока частота пожеж в результаті як катастроф так і інших причин. За останні роки ризики для населення та бізнесу зросли, що потребує певного рішення та оптимізації ідентифікації пожеж на камерах спостереження та супутниках. Особливо гостро ця проблема постає в умовах швидкої урбанізації та розвитку промислової інфраструктури, де наслідки несвоєчасного виявлення пожежі можуть бути катастрофічними.

Метою даної роботи є розробка та дослідження системи класифікації пожеж на зображеннях за допомогою згорткових нейронних мереж [1]. Така система має потенціал значно покращити існуючі методи виявлення пожеж, забезпечуючи швидку та точну класифікацію типу пожежі, що дозволить оптимізувати процес реагування на надзвичайні ситуації. Особливу увагу в роботі приділено питанням оптимізації архітектури нейронної мережі та підготовки навчальних даних для досягнення максимальної точності класифікації.

У сучасних умовах розвитку технологій та зростання масштабів промислового виробництва проблематика пожежної безпеки набуває все більшого значення. За статистичними даними, щорічні збитки від пожеж у світовому масштабі сягають мільярдів доларів, при цьому близько 70% випадків можна було б запобігти за наявності ефективних систем раннього виявлення [2].

Особливу актуальність розробка автоматизованих систем виявлення та класифікації пожеж набуває в контексті розвитку концепції «розумних міст» (Smart Cities). Інтеграція систем відеоспостереження з алгоритмами штучного інтелекту створює передумови для формування комплексних рішень у сфері безпеки міської інфраструктури. При цьому використання згорткових нейронних мереж дозволяє досягти якісно нового рівня автоматизації процесів моніторингу та реагування на надзвичайні ситуації.

Сучасні дослідження у галузі комп'ютерного зору демонструють значний потенціал для вдосконалення існуючих методів виявлення пожеж. Зокрема, застосування глибокого навчання дозволяє створювати системи, здатні не лише виявляти факт займання, але й класифікувати тип пожежі, оцінювати її масштаби та прогнозувати можливі напрямки поширення. Така інформація є критично важливою для оптимізації процесів реагування та мінімізації потенційних збитків.

Крім того, інтеграція систем класифікації пожеж з іншими компонентами «розумного міста», такими як системи управління транспортом та екстреними службами, відкриває можливості для створення комплексних рішень у сфері безпеки. Це особливо актуально в контексті розвитку концепції *Vision Zero*, спрямованої на мінімізацію людських жертв внаслідок надзвичайних ситуацій [3].

Розробка базується на сучасних досягненнях у галузі глибокого навчання та використовує передові архітектури згорткових нейронних мереж.

Дослідження включає в себе комплексний аналіз існуючих рішень у галузі автоматичного виявлення пожеж, вивчення сучасних архітектур CNN та методів їх оптимізації. Важливим аспектом роботи є створення та підготовка репрезентативного набору даних для навчання мережі, який включає різноманітні типи пожеж у різних умовах. Це дозволить забезпечити високу точність класифікації в реальних умовах експлуатації.

1 ОГЛЯД ПРОБЛЕМИ

Проблема поганої ідентифікації пожежів на вже існуючій інфраструктурі протидії пожежам викликає турботу в українського суспільства та влади. Сучасний розвиток міської інфраструктури та промислових об'єктів створює нові виклики у сфері пожежної безпеки. За статистичними даними, щорічні збитки від пожеж становлять трильйони гривень, при цьому значну частину цих випадків можна було б попередити за наявності ефективних систем раннього виявлення [2].

1.1 Аналіз традиційних методів виявлення пожеж

Традиційні системи виявлення пожеж базуються на використанні спеціалізованих датчиків, таких як димові, теплові та інфрачервоні детектори. Хоча ці системи широко розповсюджені та мають тривалу історію використання, вони мають ряд суттєвих обмежень, які впливають на їх ефективність у сучасних умовах.

1.1.1 Обмеження традиційних датчиків

Димові датчики, які є найбільш поширеними, мають обмежений радіус дії та можуть давати хибні спрацьовування через пил або пару. Інфрачервоні детектори чутливі до сонячного світла та інших джерел тепла, що також може призводити до помилкових тривог [1].

1.1.2 Проблеми масштабування та інтеграції

Традиційні системи вимагають значних витрат на встановлення та обслуговування, особливо при необхідності охоплення великих територій. Крім того, інтеграція різних типів датчиків у єдину систему моніторингу

часто ускладнена через відмінності в протоколах передачі даних та форматах сигналів.

1.2 Сучасні підходи до виявлення пожеж

Розвиток технологій комп'ютерного зору та штучного інтелекту відкриває нові можливості для створення більш ефективних систем виявлення та класифікації пожеж. Особливу увагу привертають методи, засновані на аналізі відеопотоку та обробці зображень [1].

1.2.1 Методи комп'ютерного зору

Системи комп'ютерного зору дозволяють аналізувати візуальні характеристики пожежі, такі як колір, форма, рух та текстура полум'я. Це дає можливість не лише виявляти наявність пожежі, але й визначати її тип та прогнозувати можливі напрямки поширення.

1.2.2 Застосування глибокого навчання

Згорткові нейронні мережі показали значний потенціал у задачах класифікації зображень та багатьох інших задачах що можуть імітувати роботу людини, що відкриває нові перспективи автоматизації. У контексті виявлення пожеж, CNN здатні автоматично виділяти важливі ознаки та забезпечувати високу точність класифікації в різних умовах освітлення та навколишнього середовища [4].

1.3 Виклики та перспективи розвитку систем класифікації пожеж

Розробка ефективної системи класифікації пожеж вимагає вирішення ряду технічних та методологічних завдань.

1.3.1 Технічні виклики

Серед технічних викликів можна виділити:

- необхідність обробки відеопотоку в режимі реального часу;
- забезпечення стійкості до змін умов освітлення;
- мінімізація помилкових спрацьовувань;
- оптимізація обчислювальних ресурсів.

1.3.2 Методологічні аспекти

Важливим аспектом є створення репрезентативних наборів даних для навчання моделей. Це включає збір та розмітку зображень різних типів пожеж у різноманітних умовах, що є складним та ресурсомістким завданням [4].

1.4 Перспективні напрямки досліджень

Подальший розвиток систем класифікації пожеж може включати:

- інтеграцію з іншими типами сенсорів для підвищення точності;
- розробку методів прогнозування розвитку пожежі;
- створення адаптивних систем, здатних навчатися в процесі експлуатації;
- розвиток методів edge computing для оптимізації обробки даних.

1.5 Вимоги до сучасних систем класифікації пожеж

Сучасна система класифікації пожеж повинна відповідати наступним вимогам:

- висока точність класифікації (>90%);
- низький рівень помилкових спрацьовувань (<1%);

- можливість роботи в режимі реального часу;
- стійкість до зовнішніх факторів;
- масштабованість та простота інтеграції.

На основі цього огляду можна сформулювати ключову наукову проблему дослідження: розробка високоефективної методології класифікації пожеж на зображеннях, що забезпечує адаптивне розпізнавання складних пожежонебезпечних ситуацій в умовах варіативності вхідних даних.

Вирішення поставленої проблеми потребує комплексного міждисциплінарного підходу, що поєднує передові досягнення в галузях комп'ютерного зору, машинного навчання, теорії штучного інтелекту та методів аналізу зображень.

2 ОГЛЯД АНАЛОГІВ

Об'єктивно можна зробити висновок що на зараз системи встановлення займань пожеж особливо в Україні є недостатньо ефективним. Де сучасний ландшафт технологій виявлення та класифікації пожеж являє собою складну еволюційну систему, що охоплює різноманітні методологічні підходи. Кожен з напрямків має специфічні механізми реалізації, унікальні переваги та принципові обмеження.

Традиційні алгоритмічні методи становлять фундаментальний рівень технологічних рішень у сфері детекції пожеж. Базуючись на класичних принципах обробки зображень, такі підходи передбачають виділення специфічних характеристик пожежі за наперед визначеними жорсткими правилами. Основний механізм полягає в аналізі кольорового спектру, виділенні областей підвищеної яскравості, контрастному аналізі зображення та розпізнаванні геометричних патернів полум'я.

Головною перевагою алгоритмічних методів є надзвичайно низька обчислювальна складність та можливість реалізації на обмеженому апаратному забезпеченні. Водночас, такі системи демонструють критично низьку точність класифікації, неспроможність адаптуватися до варіативності вхідних даних та надзвичайну чутливість до умов навколишнього середовища.

2.1 Традиційні алгоритмічні підходи

За останні десятиліття було розроблено різноманітні алгоритмічні підходи до виявлення та класифікації пожеж на зображеннях, що не використовують методи глибокого навчання [20]. Найбільш поширеним є метод колірної сегментації, який базується на виділенні пікселів з характерними для вогню колірними характеристиками в різних колірних просторах (RGB, YCbCr, HSV). Цей метод, хоча і є відносно простим у

реалізації, має суттєві обмеження щодо точності та стійкості до змін умов освітлення [4].

2.2 Методи на основі класичного машинного навчання

Підходи, засновані на класичному машинному навчанні, використовують такі алгоритми як Support Vector Machines (SVM), Random Forests та k-Nearest Neighbors (k-NN) у поєднанні з ручним виділенням ознак зображення [18]. Ці методи демонструють кращу точність порівняно з простою колірною сегментацією, досягаючи точності близько 85% у контрольованих умовах [19]. Однак, їх ефективність значно знижується при зміні умов освітлення або наявності складного фону.

2.3 Гібридні системи виявлення

Гібридні системи поєднують різні типи сенсорів (відеокамери, інфрачервоні датчики, димові детектори) з алгоритмами обробки зображень. Такі системи забезпечують більш надійне виявлення пожеж за рахунок комплексного аналізу різних параметрів. Проте, вони мають високу вартість встановлення та обслуговування, а також вимагають складної калібрування для коректної роботи всіх компонентів [5].

2.4 Системи на основі аналізу руху

Деякі розробки фокусуються на аналізі характерних патернів руху полум'я та диму. Ці системи використовують методи оптичного потоку та відстеження об'єктів для виявлення специфічних характеристик поширення вогню. Хоча такий підхід може бути ефективним для виявлення активних пожеж, він часто дає хибні спрацьовування при наявності інших рухомих об'єктів у кадрі.

2.5 Спектральний аналіз

Системи, що базуються на спектральному аналізі, використовують спеціалізовані камери для захвату різних спектральних діапазонів випромінювання. Цей метод особливо ефективний для раннього виявлення пожеж, оскільки може виявити характерні спектральні сигнатури горіння ще до появи видимого полум'я. Проте, висока вартість обладнання та складність обробки мультиспектральних даних обмежують широке застосування цього підходу.

2.6 Порівняльний аналіз існуючих рішень

На основі проведеного огляду можна виділити основні переваги та недоліки кожного підходу:

- традиційні алгоритмічні методи: низька вартість реалізації, але обмежена точність (рисунок 2.1);
- класичне машинне навчання: краща точність, але чутливість до умов зйомки;
- гібридні системи: висока надійність, але значна вартість;
- системи аналізу руху: ефективні для активних пожеж, але схильні до хибних спрацьовувань;
- спектральний аналіз: висока точність раннього виявлення, але надмірна вартість реалізації.

Критичний аналіз існуючих технологічних рішень дозволив сформулювати вимоги до перспективної системи класифікації пожеж: висока швидкодія, адаптивність, здатність до узагальнення та низькі обчислювальні витрати. Зазначеним критеріям найбільшою мірою відповідають сучасні архітектури згорткових нейронних мереж, що демонструють принципово нові можливості інтелектуального аналізу зображень.




Рисунок 2.1 – Графічне представлення низької точності моделі [1]

Детальне вивчення існуючих методів виявило комплекс принципових обмежень традиційних технологій, що унеможлиблюють їх ефективне використання в системах раннього попередження та моніторингу пожежної небезпеки.

3 МЕТОДИ ВИРІШЕННЯ ЗАВДАННЯ

В результаті розгляду недоліків аналогічних рішень можна зробити вибір актуального рішення. Технічна база всесвітньої галузі штучних нейронних мереж вже має певні напрацювання в області класифікації об'єктів, в тому числі це можуть бути пожежари. Зауважуючи це можна обрати шлях поліпшення існуючих рішень.

3.1 Методологічний огляд підходів до класифікації пожеж

Сучасні системи виявлення та класифікації пожеж представляють собою складний міждисциплінарний напрямок досліджень, що поєднує методи комп'ютерного зору, машинного навчання та штучного інтелекту. Проведений попередній аналіз існуючих підходів виявив принципові обмеження традиційних методів діагностики пожежних ситуацій. Традиційні алгоритмічні методи, засновані на класичних підходах обробки зображень, демонструють низьку ефективність через неспроможність адаптивно реагувати на варіативність вхідних даних та складність інтерпретації просторово-часових характеристик займання

Класичні методи машинного навчання, що базуються на ручній інженерії, забезпечують дещо вищу точність порівняно з алгоритмічними підходами, однак мають критичний недолік – надзвичайну чутливість до умов навколишнього середовища, освітлення, якості зображення та технічних параметрів реєструючої апаратури. Такі системи вимагають трудомісткої попередньої підготовки даних, зокрема мануальної розмітки ознак та формування репрезентативних навчальних вибірок, що суттєво ускладнює їх практичне впровадження.

Гібридні системи, що поєднують різні підходи комп'ютерного аналізу, демонструють високу надійність та потенційну адаптивність, проте мають значні обмеження у вигляді надмірної апаратної складності та високої

вартості реалізації. Системи аналізу руху показують часткову ефективність при детекції активних пожеж.

3.2 Теоретичне обґрунтування вибору згорткових нейронних мереж

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) представляють собою принципово новий клас інтелектуальних систем розпізнавання образів, здатних автоматично виділяти та навчатися складним ієрархічним ознакам зображень (рисунок 3.1). Це дуже наглядний приклад класифікації.

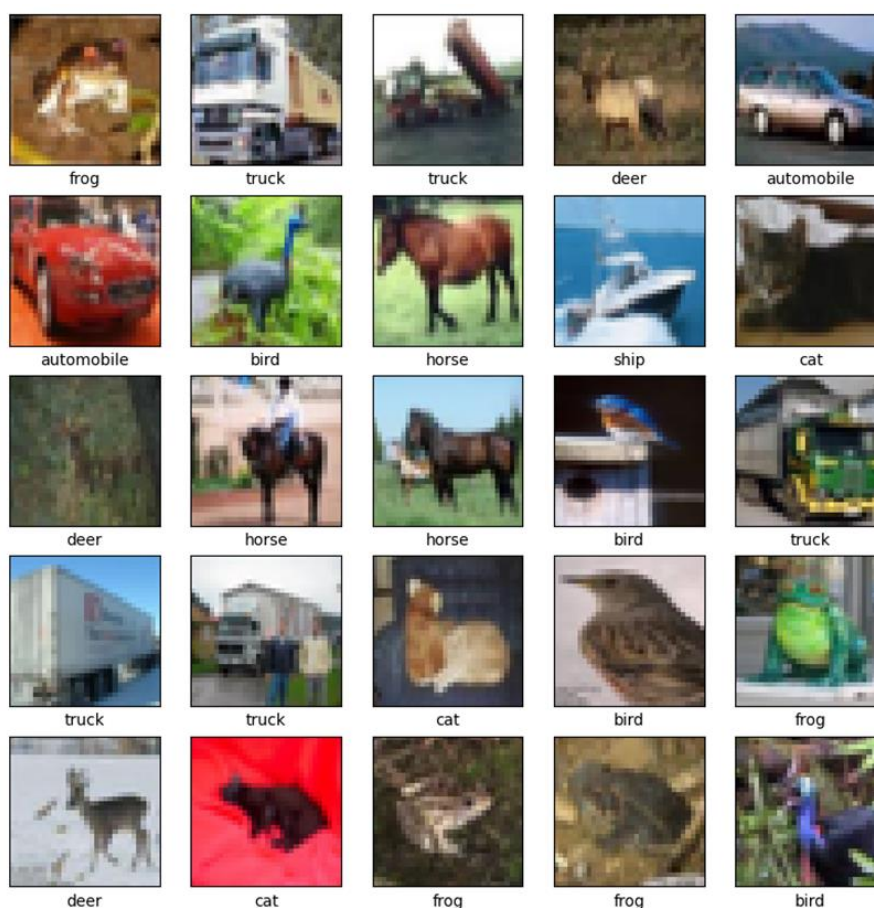


Рисунок 3.1 – Приклад автоматичної класифікації [1]

На відміну від традиційних підходів, архітектура CNN має вбудовані механізми просторової інваріантності, що дозволяє ефективно аналізувати зображення незалежно від їх масштабу, часткових спотворень та орієнтації.

Принципова перевага CNN полягає в унікальній здатності до багаторівневої ієрархічної абстракції вхідних даних. Послідовні згорткові шари мережі послідовно формують все більш складні та абстрактні репрезентації вхідного зображення, дозволяючи виділяти найбільш інформативні ознаки пожежних ситуацій. Механізм згорткових операцій забезпечує локальний аналіз просторових взаємозв'язків, що є критично важливим при класифікації складних сценаріїв займання.

Архітектурні особливості CNN дозволяють суттєво знизити обчислювальну складність порівняно з повнозв'язними нейронними мережами за рахунок локальних рецептивних полів та параметризованих фільтрів. Механізми max-pooling та stride конволюційних шарів забезпечують природню інваріантність до незначних геометричних трансформацій вхідних зображень, що робить модель стійкою до варіативності вхідних даних.

3.3 Методологічні переваги використання CNN

Вибір згорткових нейронних мереж для розв'язання задачі класифікації пожеж базується на комплексі методологічних переваг, серед яких варто виділити наступні ключові аспекти.

По-перше, CNN демонструють винятково високу точність розпізнавання складних просторових патернів, що є критичним при диференціації різних станів та типів пожежних ситуацій. Багаторівнева архітектура нейронної мережі дозволяє виділяти найтонші характеристики зображень, недоступні для традиційних методів комп'ютерного зору.

По-друге, сучасні архітектури CNN мають розвинені механізми transfer learning, що дозволяють ефективно навчати моделі на обмежених

навчальних вибірках [16]. Використання попередньо навчених мереж (pre-trained models) типу ResNet, Inception, MobileNet забезпечує можливість адаптації глибоких нейронних мереж до специфічних задач класифікації пожеж з мінімальними обчислювальними витратами.

По-третє, архітектура CNN має вбудовані механізми регуляризації та запобігання перенавчанню, зокрема dropout-шари, batch normalization та техніки аугментації даних [17]. Це принципово підвищує узагальнюючу здатність моделі та її стійкість до варіативності вхідних зображень.

Додатковою перевагою є висока швидкодія сучасних реалізацій CNN, особливо при використанні спеціалізованих апаратних прискорювачів типу GPU та TPU. Паралельні обчислення в архітектурі нейронної мережі дозволяють досягати субмілісекундних затримок при класифікації зображень, що робить CNN придатними для впровадження в системи реального часу.

Важливим аргументом на користь вибору CNN є також їх здатність до навчання на відносно невеликих наборах даних, що особливо актуально в умовах обмежених ресурсів та складності збору великих масивів зображень пожеж. Запропонований метод забезпечує оптимальний баланс між технічною складністю реалізації та точністю класифікації.

4 ФОРМУЛЮВАННЯ ПРОБЛЕМИ

Встановлення чітких вимог та окреслення конкретної проблеми є одним з важливіших кроків на початку цієї роботи. З огляду на те що ця розробка дуже чутлива до сьогоднішнього дня, проблема буде сформульована з огляду на терміновість поліпшення ситуації з ідентифікацією пожег.

4.1 Постановка проблеми вдосконалення процесів класифікації пожег

У контексті розробки систем класифікації пожег на зображеннях, проблема вдосконалення процесів класифікації є критично важливою для підвищення ефективності систем пожежної безпеки. Існуючі методи виявлення та класифікації пожег часто стикаються з обмеженнями щодо точності, швидкодії та надійності роботи в реальних умовах. Особливо гостро стоїть питання своєчасного виявлення займань на ранніх стадіях, коли візуальні ознаки пожежі можуть бути незначними. Крім того, наявні системи часто демонструють високий рівень помилкових спрацьовувань, що знижує довіру до них та ефективність їх практичного застосування. Важливим аспектом проблеми є також необхідність забезпечення стабільної роботи систем класифікації в різних умовах освітлення, погоди та навколишнього середовища.

Традиційні системи виявлення пожег, засновані на датчиках диму та температури, мають суттєві обмеження у швидкості реагування та точності визначення місця займання. Системи відеоспостереження з класичними алгоритмами обробки зображень також демонструють недостатню ефективність, особливо в умовах складного освітлення або наявності об'єктів, що візуально нагадують полум'я. Це створює необхідність розробки більш досконаліх методів класифікації, здатних точно ідентифікувати пожежу в різноманітних умовах експлуатації [7].

Важливим аспектом проблеми є також необхідність забезпечення стабільної роботи систем класифікації в різних умовах освітлення, погоди та навколишнього середовища. Особливу увагу слід приділити здатності системи розрізняти справжні пожежі від схожих візуальних ефектів, таких як відблиски сонця, штучне освітлення або промислові процеси, що супроводжуються появою вогню чи диму.

4.2 Аналіз сучасного стану технологій

Аналізуючи сучасний стан технологій для вдосконалення методів класифікації пожеж, можна відзначити значний прогрес у галузі комп'ютерного зору та глибокого навчання. Згорткові нейронні мережі (CNN) демонструють особливо перспективні результати у задачах класифікації зображень. Сучасні архітектури, такі як MobileNetV2 та EfficientNetB0, пропонують оптимальний баланс між обчислювальною ефективністю та точністю класифікації [8]. Важливим технологічним проривом є можливість використання попередньо навчених моделей (transfer learning), що дозволяє значно скоротити час та ресурси, необхідні для навчання системи [15]. Розвиток технологій обробки даних у реальному часі та оптимізація нейромережових архітектур дозволяють створювати більш ефективні системи виявлення пожеж. Однак, незважаючи на значний прогрес, залишаються невирішеними питання стабільності роботи в складних умовах, оптимізації обчислювальних ресурсів та інтеграції з існуючими системами безпеки. Особливу увагу слід приділити розробці методів, які дозволяють адаптувати системи класифікації до специфічних умов конкретного об'єкта спостереження при збереженні високої точності виявлення пожеж.

Розвиток технологій обробки даних у реальному часі та оптимізація нейромережових архітектур дозволяють створювати більш ефективні системи виявлення пожеж. Використання графічних процесорів (GPU) та

спеціалізованих апаратних прискорювачів значно підвищує швидкість систем класифікації. Сучасні методи квантизації та оптимізації моделей дозволяють зменшити обчислювальні вимоги без суттєвої втрати точності.

Технології глибокого навчання також дозволяють реалізувати складні методи виявлення пожеж, що враховують часову динаміку через аналіз послідовності кадрів. Це дає можливість більш точно відрізнити реальні пожежі від статичних об'єктів, що візуально нагадують вогонь. Розвиток методів attention та трансформерів відкриває нові можливості для покращення точності класифікації через врахування просторових залежностей у зображеннях.

4.3 Визначення мети дослідження та задач роботи

Основною метою дослідження є розробка та вдосконалення системи класифікації пожеж на зображеннях з використанням згорткових нейронних мереж, що забезпечує високу точність виявлення займань у різноманітних умовах експлуатації. Для досягнення цієї мети були визначені наступні конкретні задачі дослідження:

- аналіз сучасних підходів до виявлення пожеж на основі штучного інтелекту;
- теоретичне обґрунтування вибору моделі та методів підготовки даних;
- опис архітектури та алгоритмів роботи запропонованої системи класифікації пожеж;
- проведення експериментів, валідації та тестування моделі, аналіз отриманих результатів;
- порівняння запропонованої системи з іншими сучасними підходами;
- визначення перспектив удосконалення моделі та її практичного застосування.

Важливою задачею є також дослідження можливостей підвищення стійкості моделі до різних умов освітлення та зовнішніх факторів, що впливають на якість класифікації. Окрема увага приділяється розробці методів зменшення кількості помилкових спрацьовувань при збереженні високої чутливості до реальних займань.

4.4 Опис інноваційного характеру застосованого підходу

Інноваційний характер застосованого підходу полягає у комплексному використанні сучасних досягнень у галузі глибокого навчання для вирішення практичної задачі класифікації пожеж. Зокрема, запропонований підхід базується на використанні передових архітектур згорткових нейронних мереж, оптимізованих для ефективної роботи в реальному часі. Інноваційність також проявляється у використанні transfer learning з попередньо навченими моделями, що дозволяє суттєво покращити якість класифікації навіть при обмеженому наборі навчальних даних.

Особливу інноваційність представляє розроблена стратегія навчання моделі, яка включає використання спеціально підібраних методів аугментації даних для підвищення стійкості класифікатора до різних умов зйомки [9]. Використання сучасних методів оптимізації та регуляризації дозволяє досягти високої точності класифікації при збереженні обчислювальної ефективності. Важливим інноваційним аспектом є також розробка методів адаптації моделі до конкретних умов експлуатації без необхідності повного перенавчання.

5 МЕТОДИ ТА РЕАЛІЗАЦІЯ

Мова Python та її відкриті бібліотеки є гарним початком для ефективною розробки найсучасніших рішень. Саме ця мова програмування набирає популярність для такого роду рішень.

5.1 Обґрунтування вибору архітектури згорткових нейронних мереж

При виборі архітектури згорткових нейронних мереж для задачі класифікації пожеж на зображеннях було враховано декілька ключових факторів. По-перше, архітектура повинна забезпечувати високу точність класифікації при збереженні прийнятної обчислювальної складності. По-друге, важливим є можливість ефективною роботи в реальному часі на різних апаратних платформах. По-третє, архітектура повинна бути достатньо гнучкою для адаптації до специфічних умов застосування [10].

Головними факторами, що визначили вибір CNN як базовою архітектури, стали їх здатність ефективно виділяти просторові ознаки з зображень та інваріантність до зсувів і масштабування (рисунок 5.1).




Рисунок 5.1 – Схематична візуалізація роботи CNN [21]

Це особливо важливо для задачі виявлення пожеж, де об'єкт інтересу може з'являтися в різних частинах зображення та мати різні розміри.

Згорткові шари дозволяють автоматично вивчати важливі візуальні ознаки, починаючи від простих елементів, таких як краї та кольорові патерни, і закінчуючи складними структурами, характерними для зображень пожеж.

Архітектура CNN також дозволяє ефективно використовувати техніку *transfer learning*, що є критично важливим для даної задачі. Можливість використання попередньо навчених на великих наборах даних моделей, таких як ImageNet, дозволяє значно покращити якість класифікації навіть при обмеженому наборі специфічних даних про пожежі [11]. При цьому нижні шари мережі, що відповідають за виділення базових візуальних ознак, можуть бути перевикористані, а верхні шари адаптовані під конкретну задачу класифікації пожеж.

Особливістю обраної архітектури є використання глобального усереднюючого пулінгу замість традиційних повнозв'язних шарів наприкінці мережі. Цей підхід не тільки зменшує кількість параметрів моделі, але й покращує узагальнюючу здатність мережі та знижує ризик перенавчання. Додавання *dropout* шарів та використання *batch normalization* дозволяє стабілізувати процес навчання та покращити регуляризацію моделі.

Важливим аспектом вибору архітектури стала також можливість ефективної оптимізації моделі для роботи на різних обчислювальних платформах. Сучасні архітектури CNN, такі як MobileNetV2 та EfficientNetV0, пропонують оптимальний баланс між точністю класифікації та обчислювальною ефективністю, що особливо важливо для систем реального часу. Можливість квантизації нейронної мережі дозволяє адаптувати модель для роботи на пристроях з обмеженими ресурсами без значної втрати точності.

Використання глобального усереднюючого пулінгу (Global Average Pooling) замість повнозв'язних шарів також дозволяє зменшити кількість параметрів моделі та знизити ризик перенавчання. Архітектура також

включає залишкові з'єднання (residual connections), які покращують потік градієнтів через мережу та дозволяють навчати більш глибокі моделі.

5.2 Порівняльний аналіз сучасних моделей глибокого навчання

При порівняльному аналізі сучасних моделей глибокого навчання основна увага була приділена архітектурам MobileNetV2 та EfficientNetB0, які демонструють оптимальний баланс між точністю та обчислювальною ефективністю. MobileNetV2 використовує інвертовані залишкові блоки та глибинні згортки, що дозволяє значно зменшити кількість параметрів моделі при збереженні високої точності. Ця архітектура особливо ефективна для мобільних та вбудованих систем завдяки оптимізованій структурі згорткових блоків.

EfficientNetB0, у свою чергу, був розроблений з використанням методів нейроархітектурного пошуку для оптимального масштабування глибини, ширини та роздільної здатності мережі. Ця модель демонструє кращу точність порівняно з MobileNetV2 при схожій обчислювальній складності. Важливою перевагою EfficientNetB0 є можливість легкого масштабування моделі для досягнення кращого балансу між точністю та швидкодією.

Порівняльні експерименти показали, що обидві архітектури здатні досягти високої точності класифікації пожеж (більше 90%) на використаному наборі даних. При цьому MobileNetV2 показав дещо кращу швидкість, особливо на мобільних пристроях, тоді як EfficientNetB0 продемонстрував вищу точність класифікації в складних умовах. Важливо відзначити, що обидві моделі добре підтримують transfer learning, що дозволяє ефективно використовувати попередньо навчені ваги на наборі даних ImageNet.

Експерименти також включали оцінку різних методів оптимізації моделей, включаючи квантизацію та pruning. MobileNetV2 показав кращі

результати при квантизації, зберігаючи високу точність навіть при використанні 8-бітної точності. EfficientNetB0, у свою чергу, виявився більш стійким до pruning, дозволяючи видалити до 30% параметрів без значного падіння точності.

Результати порівняльного аналізу також враховували такі аспекти як розмір моделі, час інференсу на різних платформах, енергоспоживання та вимоги до пам'яті. На основі проведеного аналізу була обрана оптимальна архітектура, яка найкраще відповідає вимогам задачі класифікації пожеж з урахуванням специфіки практичного застосування.

5.3 Реалізація класифікатора пожеж

Реалізація класифікатора пожеж базується на використанні сучасних технологій глибокого навчання та оптимізованих архітектур нейронних мереж. Процес реалізації включав кілька ключових етапів: підготовку набору даних, розробку архітектури моделі, навчання та оптимізацію параметрів, а також тестування та валідацію результатів. Особлива увага приділялася забезпеченню масштабованості рішення.

Для забезпечення надійної роботи класифікатора було реалізовано комплексну систему обробки даних, що включає попередню обробку зображень, аугментацію даних та оптимізацію моделі. В якості базової архітектури було обрано EfficientNetB0, яка була модифікована відповідно до специфіки задачі класифікації пожеж.

5.3.1 Підготовка даних та технічна інфраструктура

Підготовка даних та технічна інфраструктура відіграють критичну роль у забезпеченні ефективності класифікатора пожеж. Для створення комплексного набору даних для навчання класифікатора пожеж було використано комбінований підхід, що включав як існуючі набори даних, так

і спеціально зібрані зображення з різних джерел. Основу набору даних склали загальнодоступні датасети з зображеннями пожеж та звичайних сцен, які були доповнені власноруч зібраними матеріалами. Загальний обсяг набору даних склав більше 5000 зображень (рисунок 5.2).

Sample images from the dataset

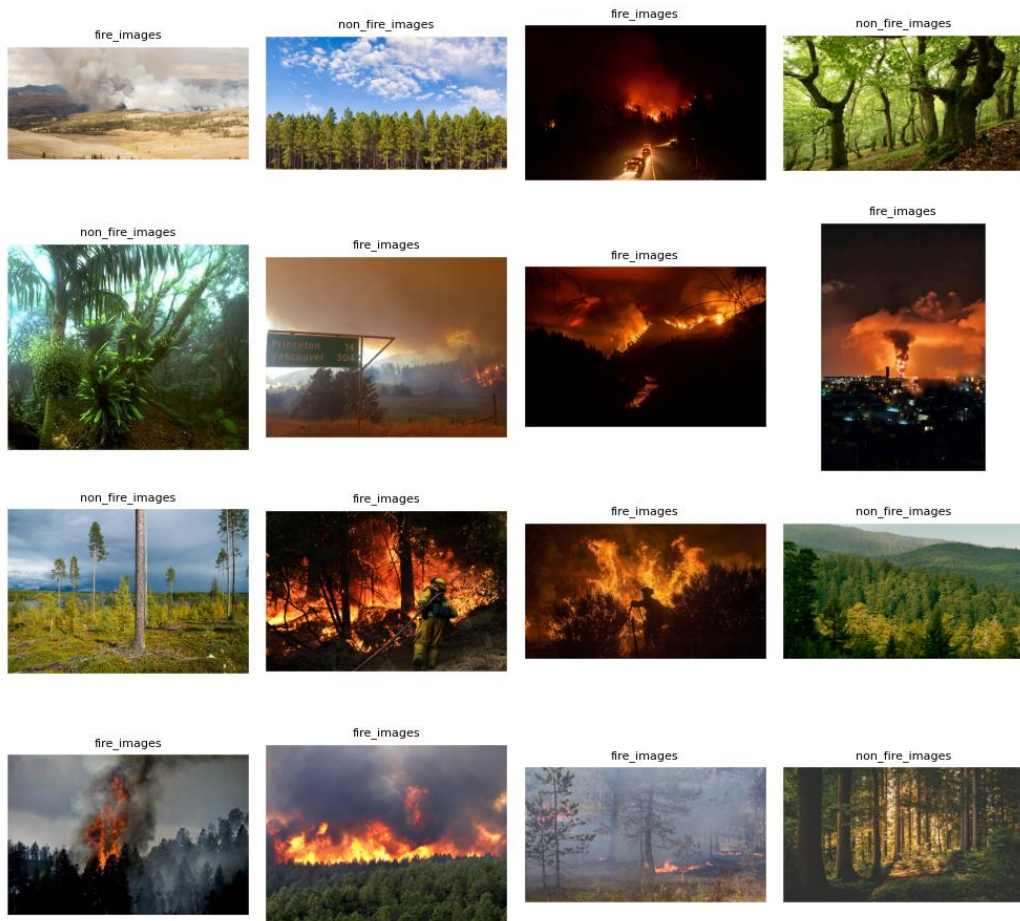


Рисунок 5.2 – Графічне відображення фотографій в датасеті

Значну частину специфічних даних було отримано з новинних ресурсів Харкова та інших регіонів України, що дозволило включити в набір даних реальні випадки пожеж у міському середовищі. Особливу увагу було приділено збору зображень наслідків техногенних катастроф, включаючи пожежі після вибухів та інших надзвичайних ситуацій. Такі зображення є

особливо цінними для навчання моделі, оскільки вони представляють реальні сценарії, з якими може зіткнутися система в умовах міста.

Також були включені фотографії природних пожеж, зібрані з новинних ресурсів України та сусідніх країн. Це дозволило розширити різноманітність набору даних зображеннями лісових пожеж, займань на відкритих територіях та інших типів природних загорянь. Важливим аспектом стало включення зображень пожеж у різних погодних умовах та при різному освітленні, що підвищує здатність моделі працювати в реальних умовах.

Для забезпечення збалансованості набору даних були також зібрані зображення звичайних міських та природних сцен без пожеж. Особлива увага приділялася включенню потенційно складних випадків, таких як заходи сонця, промислові об'єкти з димом, тумани та інші візуально схожі на пожежі явища. Це дозволило покращити здатність моделі розрізняти справжні пожежі від схожих візуальних ефектів. Для розширення набору даних було застосовано техніки аугментації, включаючи:

- випадкові повороти зображень в діапазоні ± 40 градусів;
- горизонтальні відображення;
- зміни яскравості та контрасту;
- масштабування та зсуви;
- додавання випадкового шуму.

Технічна інфраструктура включала використання GPU для прискорення навчання моделі та обробки даних. Було реалізовано ефективну систему завантаження даних з використанням генераторів зображень, що дозволило оптимізувати використання пам'яті під час навчання. Для зберігання та управління даними використовувалася структурована система каталогів, де набори даних були розділені на навчальну (training), валідаційну (validation) та тестову (test) вибірки у співвідношенні 60:20:20.

Для забезпечення відтворюваності результатів та ефективного моніторингу процесу навчання було впроваджено систему логування та збереження контрольних точок моделі. Це дозволило відстежувати прогрес навчання та зберігати найкращі варіанти моделі для подальшого використання. Також було реалізовано механізми раннього зупинення (early stopping) та динамічного регулювання швидкості навчання для оптимізації процесу тренування.

Особлива увага приділялася оптимізації попередньої обробки зображень для роботи в реальному часі. Було реалізовано ефективні методи нормалізації та перетворення зображень, що дозволяють швидко адаптувати вхідні дані до формату, необхідного для нейронної мережі. Також було впроваджено механізми кешування для прискорення повторної обробки схожих зображень.

5.3.2 Опис архітектури моделі та вибір гіперпараметрів

В основі архітектури моделі лежить згортова нейронна мережа EfficientNetB0, оптимізована для задачі бінарної класифікації пожеж. Модель складається з початкового блоку попередньої обробки, що включає шари масштабування та нормалізації зображень.

Реалізація класифікатора пожеж була виконана з використанням фреймворку TensorFlow та високорівневого API Keras. Ключовим аспектом реалізації стало створення ефективної системи обробки даних та навчання моделі з використанням оптимізованих архітектур глибокого навчання (додаток Б).

Структура даних була організована з використанням DataFrame, що містить шляхи до зображень та їх мітки. Для ефективної роботи з даними було реалізовано генератори зображень ImageDataGenerator з різними параметрами для навчального та тестового наборів. Для навчального набору використовувалася розширена аугментація даних, включаючи поворот

зображень (`rotation_range=40`), зсуви по ширині та висоті (`width_shift_range=0.2`, `height_shift_range=0.2`), масштабування (`zoom_range=0.2`) та горизонтальні відображення.

Далі була реалізована попередня обробка даних з використанням функції `preprocessing_function` з `MobileNetV2` та `EfficientNetB0`. Зображення автоматично масштабуються до розміру `224x224` пікселів та нормалізуються відповідно до вимог моделей.

Для базової архітектури `EfficientNetB0` було використано попередньо навчені ваги на наборі даних `ImageNet`. Модель була модифікована шляхом додавання верхніх шарів, специфічних для задачі класифікації пожеж. Після базової моделі додано `GlobalAveragePooling2D` для зменшення розмірності, `dense` шар з 256 нейронами та `ReLU` активацією, `dropout` для регуляризації та фінальний шар з `softmax` активацією.

Навчання моделі проводилося у два етапи. На першому етапі базова модель була заморожена (`base_model.trainable = False`), і навчалися тільки додані верхні шари. На другому етапі проводився `fine-tuning` з розмороженням верхніх шарів базової моделі та зменшеною швидкістю навчання.

Для оптимізації процесу навчання були реалізовані `callback` функції:

- `earlyStopping` для запобігання перенавчання;
- `modelCheckpoint` для збереження найкращої моделі;
- `reduceLROnPlateau` для адаптивного зменшення швидкості навчання;
- `tensorBoard` для моніторингу процесу навчання.

При виборі гіперпараметрів моделі особлива увага приділялася балансу між точністю класифікації та обчислювальною ефективністю. Основними параметрами є розмір батчу, який встановлено на 32, початкова швидкість навчання $1e-4$ для першої фази та $1e-5$ для `fine-tuning`. В якості оптимізатора використовується `Adam` з параметрами `beta1=0.9` та `beta2=0.999`. Навчання проводиться в два етапи: 10 епох для першої фази

та 20 епох для fine-tuning. Для запобігання перенавчання використовується early stopping з параметром patience 5 епох та зменшення швидкості навчання з фактором 0.5 при досягненні плато, з мінімальною швидкістю навчання $1e-7$.

5.3.3 Опис процесу розробки та експериментів

Першим важливим етапом став процес підготовки та обробки даних для навчання моделі (додаток Б). Після детального аналізу різних підходів до обробки зображень було прийнято рішення використовувати клас ImageDataGenerator з бібліотеки Tensorflow. Цей вибір був обумовлений декількома ключовими факторами: по-перше, даний інструмент надає широкі можливості для аугментації даних, що критично важливо при роботі з обмеженим набором навчальних зображень; по-друге, він забезпечує ефективну роботу з пам'яттю завдяки генерації зображень на льоту під час навчання.

У процесі налаштування параметрів аугментації було проведено серію експериментів для визначення оптимальних значень. Початково були протестовані різні діапазони повороту зображень (від 20 до 60 градусів), і значення `rotation_range=40` виявилось найбільш ефективним. Такий кут повороту дозволяє створювати достатньо різноманітні варіації зображень, зберігаючи при цьому їх розпізнаваність. Це особливо важливо для задачі класифікації пожеж, оскільки вогонь може бути зафіксований камерою під різними кутами.

Параметри зміщення зображень `width_shift_range` та `height_shift_range` були встановлені на рівні 0.2 після аналізу типових сценаріїв розташування пожеж на фотографіях. Зміщення на 20% є оптимальним балансом між збереженням інформативності та створенням корисних варіацій для навчання.

Особлива увага була приділена параметрам деформації зображень. Значення `shear_range=0.2` було обрано після серії тестів, які показали, що така величина зсуву дозволяє імітувати різні ракурси зйомки пожежі, не спотворюючи при цьому критично важливі візуальні характеристики вогню. Аналогічно, параметр `zoom_range=0.2` був визначений як оптимальний для створення ефекту наближення та віддалення, що відповідає реальним умовам фіксації пожеж на різних відстанях.

Важливим рішенням стало включення горизонтального відображення зображень (`horizontal_flip=True`). Цей параметр суттєво збільшує різноманітність навчальних даних, що особливо важливо для пожеж, які можуть мати різну орієнтацію. Вертикальне відображення було навмисно виключено, оскільки воно може створювати нереалістичні варіації, що погіршують якість навчання.

Для заповнення пустот, що виникають при трансформаціях, був обраний метод `fill_mode='nearest'`. Цей вибір базувався на аналізі специфіки зображень пожеж, де різкі переходи між пікселями є природними через характер вогню. Альтернативні методи заповнення, такі як `'constant'` або `'reflect'`, створювали артефакти, які могли негативно впливати на процес навчання.

Особливу увагу було приділено розділенню даних на навчальну та валідаційну вибірки. Параметр `validation_split=0.2` був встановлений на основі загальноприйнятих практик машинного навчання та розміру доступного набору даних. Це забезпечило достатній обсяг даних як для навчання, так і для валідації моделі.

Архітектурні рішення базувалися на глибокому аналізі сучасних підходів до класифікації зображень. Вибір EfficientNetB0 як базової моделі був зроблений після порівняльного аналізу різних архітектур, включаючи ResNet, VGG та MobileNet. EfficientNetB0 продемонстрував найкраще співвідношення між обчислювальною складністю та якістю класифікації. Важливим фактором стала можливість використання попередньо навчених

ваг на наборі даних ImageNet, що суттєво прискорює процес навчання та покращує узагальнюючу здатність моделі.

Структура додаткових шарів моделі була розроблена з урахуванням специфіки задачі класифікації пожеж. Використання GlobalAveragePooling2D замість простого вирівнювання (Flatten) дозволило значно зменшити кількість параметрів моделі без втрати якості класифікації. Dense шар з 256 нейронами був обраний після експериментів з різними розмірами (128, 512, 1024 нейронів). Саме 256 нейронів забезпечили оптимальний баланс між здатністю моделі виділяти складні ознаки та ризиком перенавчання.

Коефіцієнт виключення в шарі Dropout був встановленим на 0.3). Активація ReLU була обрана для проміжного шару як найбільш ефективна для задач комп'ютерного зору, а softmax для вихідного шару забезпечує коректну нормалізацію ймовірностей класифікації.

Особлива увага була приділена налаштуванню процесу навчання. Оптимізатор Adam був обраний завдяки його адаптивній природі та здатності ефективно працювати з різними типами даних. Початкова швидкість навчання $1e-4$ була визначена після серії експериментів з різними значеннями. Більші значення призводили до нестабільності навчання, а менші значно уповільнювали процес збіжності.

Впровадження callback-функції ReduceLROnPlateau стало важливим рішенням для покращення процесу навчання. Параметри callback були ретельно налаштовані: factor=0.5 забезпечує плавне зменшення швидкості навчання, а patience=3 дає моделі достатньо часу для знаходження кращих ваг перед зміною швидкості навчання. Мінімальне значення швидкості навчання (min_lr= $1e-7$) було встановлено для запобігання надто повільному навчанню на пізніх етапах.

Після ретельного аналізу та серії експериментів було прийнято рішення використовувати поетапний підхід до навчання, починаючи з

замороженої базової моделі. Цей вибір був зумовлений необхідністю ефективного використання попередньо навчених ваг моделі EfficientNetB0.

Процес початкового навчання було налаштовано на 10 епох. Менша кількість епох не дозволяє моделі достатньо адаптуватися до специфіки розпізнавання пожеж, тоді як більша кількість призводить до ранніх ознак перенавчання. Важливим фактором при виборі кількості епох стала необхідність збереження корисних ознак, отриманих при попередньому навчанні на наборі даних ImageNet.

Певна увага була приділена системі зворотного зв'язку через впровадження комплексу callback-функцій. Early stopping став першим критичним компонентом цієї системи. Його впровадження базувалося на необхідності автоматичного припинення навчання при відсутності покращень у метриках валідації.

Create_tensorboard_callback з параметрами «training_logs» та «fire_classification» був впроваджений для забезпечення детального моніторингу процесу навчання. Цей вибір був зроблений після аналізу різних інструментів візуалізації процесу навчання. TensorBoard виявився найбільш інформативним, надаючи можливість відстежувати динаміку зміни всіх ключових метрик у реальному часі. Окрема директорія для логів початкового навчання була створена для чіткого розмежування етапів навчання та спрощення подальшого аналізу результатів.

Checkpoint_callback став критично важливим компонентом процесу навчання. Його налаштування включало збереження ваг моделі при покращенні валідаційної точності. Такий підхід дозволив зберегти найкращий стан моделі, навіть якщо в подальших епохах спостерігалось погіршення результатів.

Reduce_lr callback був впроваджений для динамічного управління швидкістю навчання. Початкові експерименти показали, що фіксована швидкість навчання часто призводить до застрягання в локальних мінімумах або нестабільної поведінки моделі. Автоматичне зменшення

швидкості навчання при відсутності покращень дозволило досягти більш стабільних результатів. Параметри callback були налаштовані таким чином, щоб забезпечити плавне зменшення швидкості навчання без передчасної зупинки процесу.

Важливим аспектом початкового етапу навчання стало збереження замороженого стану базової моделі (`trainable = False`). Це рішення базувалося на розумінні того, що нижні шари нейронної мережі, попередньо навчені на ImageNet, вже містять важливі базові фільтри для виділення візуальних ознак. Зміна цих ваг на початковому етапі могла б призвести до втрати цінної інформації та погіршення якості класифікації.

Валідаційний набір даних використовувався на кожній епосі для оцінки узагальнюючої здатності моделі. Це дозволило відстежувати потенційне перенавчання та забезпечило надійну метрику для системи callback. Розмір валідаційного набору був визначений як 20% від загального обсягу даних, що забезпечило статистично значущу оцінку продуктивності моделі.

5.3.4 Налаштування метрик оцінювання моделі

Налаштування метрик оцінювання моделі є критично важливим етапом у розробці системи класифікації пожеж, оскільки воно забезпечує об'єктивну оцінку ефективності моделі та її готовність до практичного застосування. У контексті класифікації пожеж особливо важливо забезпечити баланс між різними аспектами продуктивності моделі, враховуючи критичність завдання та потенційні наслідки помилок.

Серед основних метрик класифікації особливе місце займає Accuracy, яка є фундаментальним показником, що обчислюється як відношення кількості правильно класифікованих зображень до загальної кількості зображень у наборі даних (додаток Б). Проте важливо розуміти, що сама по собі accuracy може бути оманливою метрикою, особливо при

незбалансованих наборах даних, тому її необхідно розглядати у комплексі з іншими показниками.

Precision виступає критично важливою метрикою, що показує частку правильно ідентифікованих випадків пожежі серед усіх випадків, коли модель передбачила наявність пожежі. Цей показник набуває особливого значення в контексті мінімізації кількості помилкових тривог, які можуть призвести до необґрунтованої евакуації та значних економічних втрат. Висока precision означає, що коли система сигналізує про пожежу, ця інформація з високою ймовірністю відповідає дійсності.

Не менш важливою є метрика Recall, яка відображає здатність моделі виявляти всі реальні випадки пожеж у наборі даних. У контексті систем безпеки цей показник набуває критичного значення, оскільки пропуск реальної пожежі може мати катастрофічні наслідки для життя людей та збереження майна. Високий показник recall свідчить про те, що модель рідко пропускає реальні випадки пожеж, що є необхідною умовою для систем безпеки.

F1-Score виступає інтегральним показником, що обчислюється як гармонічне середнє між Precision та Recall, забезпечуючи збалансовану оцінку якості моделі. Ця метрика набуває особливої цінності в ситуаціях, коли необхідно знайти оптимальний баланс між мінімізацією помилкових спрацьовувань та забезпеченням надійного виявлення реальних пожеж.

Для ефективного моніторингу процесу навчання використовується комплекс додаткових метрик. Validation Loss служить ключовим індикатором для відстеження можливого перенавчання моделі. Особлива увага приділяється ситуаціям, коли спостерігається зростання validation loss при продовженні зменшення training loss, що є чітким сигналом перенавчання і вказує на необхідність застосування технік регуляризації або перегляду архітектури моделі.

Learning Rate відстежується для забезпечення оптимального процесу навчання. У реалізованій системі використовується адаптивне

налаштування learning rate за допомогою callback ReduceLROnPlateau, що дозволяє досягти кращої конвергенції моделі. При цьому learning rate зменшується вдвічі після трьох епох без покращення validation loss, що забезпечує більш стабільне навчання.

Особлива увага приділяється метрикам продуктивності, таким як Time per Inference та Memory Usage. Час обробки кожного зображення є критичним параметром, оскільки в реальних умовах система повинна обробляти відеопотік у режимі реального часу. Контроль використання пам'яті також має велике значення, особливо при розгортанні системи на пристроях з обмеженими обчислювальними ресурсами.

Для глибокого аналізу роботи моделі використовується набір візуальних інструментів оцінки. Confusion Matrix надає детальну картину розподілу помилок класифікації, дозволяючи виявити систематичні помилки в роботі моделі. ROC-крива та значення AUC забезпечують комплексну оцінку якості класифікації при різних порогових значеннях, де висока площа під ROC-кривою свідчить про хорошу здатність моделі розрізняти класи.

Моніторинг усіх метрик здійснюється за допомогою TensorBoard, який забезпечує візуалізацію змін метрик у реальному часі та можливість порівняння різних експериментів. Цей інструмент є одним з найпривабливіших у контексті виконання текучого задання, його орієнтованість на рішення використовуючі як базу великі дані демонструє свою відмінну роботу в цій задачі. Реалізоване автоматичне збереження найкращої моделі здійснюється за допомогою callback ModelCheckpoint, який відстежує покращення validation accuracy та зберігає оптимальну версію моделі для подальшого використання (рисунк 5.3). Що безумовно сприяє кращій роботі програми та підвищенню точності класифікації в різних умовах.




Рисунок 5.4 – Графічне відображення зросту точності моделі

Для зображень без пожеж (`non_fire_images`) досягнуто `precision 1.0`, що означає відсутність помилкових класифікацій звичайних зображень як пожежних (рисунок 5.5). Загальний `weighted average F1-score 0.94` підтверджує збалансованість роботи моделі для обох класів.

При цьому особливо важливим є те, що валідаційна точність залишається стабільно високою протягом всього процесу навчання, що свідчить про хорошу узагальнюючу здатність моделі.

Особливо варто відзначити стовідсоткову повноту моделі, що означає відсутність пропущених випадків пожежі. Це критично важливо для систем безпеки, де пропуск реальної пожежі може мати серйозні наслідки.



Рисунок 5.5 – Графічне зображення precision для кожного класу

Значення test loss 0.24 вказує на хорошу узагальнюючу здатність моделі та відсутність перенавчання (рисунок 5.6).

Динаміка функції втрат додатково підтверджує якість навчання моделі. Спостерігається стабільне зменшення помилки на тренувальному наборі з 0.55 до 0.30, при цьому втрати на валідаційному наборі залишаються стабільно низькими близько 0.25. Така поведінка є індикатором відсутності перенавчання моделі та свідчить про її здатність ефективно працювати з новими, раніше не баченими зображеннями.

На відміну від training loss, який монотонно зменшується протягом навчання, validation loss демонструє дещо іншу поведінку. Він починається з відносно низького значення близько 0.25 і залишається досить стабільним протягом всього процесу навчання, показуючи лише невеликі коливання. Особливо цікавим є те, що значення validation loss постійно нижче, ніж training loss. Це є нетиповою ситуацією, оскільки зазвичай validation loss має бути вищим за training loss. Така поведінка може вказувати на те, що

валідаційний набір даних виявився дещо простішим для класифікації, ніж тренувальний, або що в процесі формування наборів даних валідаційна вибірка могла отримати більш однорідні чи легше класифіковані приклади. Проте, враховуючи стабільно високу точність класифікації, це не є критичною проблемою для практичного застосування моделі.




Рисунок 5.6 – Графічне відображення падіння test loss

Аналіз матриці показав наступні результати: істинно позитивні результати (True Positives, TP) склали 158 випадків, коли модель коректно ідентифікувала наявність пожежі, а істинно негативні результати (True Negatives, TN) 32 випадки правильного визначення (рисунок 5.7).




Рисунок 5.7 – Графічне відображення матриці помилок

Помилки першого роду (False Positives, FP), коли модель помилково класифікувала зображення як пожежу, склали 11 випадків. Детальний аналіз цих помилок показав, що вони становлять 25.6% від загальної кількості прогнозів для класу «не пожежа». Помилки другого роду (False Negatives, FN), коли модель не змогла виявити реальну пожежу, становили 0 випадків, що є особливо важливим результатом, оскільки означає, що модель не пропустила жодної реальної пожежі.

Аналіз також показав, що модель має тенденцію до деякої перестраховки, вона схильна класифікувати сумнівні випадки як пожежу, про що свідчить наявність 11 помилкових спрацьовувань. Проте в контексті системи виявлення пожеж така поведінка може вважатися прийнятною.

6 РЕЗУЛЬТАТИ ДОСЛІДЖЕНЬ

Розробка була виконана з позитивним результатом. Так як для встановлення наявності вогню та пожеж на фотографіях неможливо прийняти результат менше ніж 90%, результат в 94% є більш ніж задовільним.

6.1 Аналіз точності, втрат та продуктивності моделі

Розроблена модель продемонструвала високу ефективність. Проведений аналіз метрик моделі показав значні результати як у загальній точності, так і в специфічних показниках для кожного класу зображень (рисунок 6.1). Значення функції втрат (Test Loss) склало 0.23965, що свідчить про хорошу збіжність моделі та відсутність суттєвого перенавчання.



Рисунок 6.1 – Зображення очікування та реальної класифікації

Детальний аналіз матриці помилок демонструє, що модель досягла особливо вражаючих результатів у виявленні пожеж, правильно класифікувавши всі 158 зображень з пожежами, таким чином показавши нульовий рівень помилкових негативів для цього класу. Щодо зображень без пожежі, модель правильно класифікувала 32 з 43 зображень (74.4%), тоді як 11 зображень були помилково класифіковані як пожежі (рисунок 6.2). Такий результат вказує на консервативний підхід моделі до класифікації, що є бажаним у контексті систем безпеки.

	precision	recall	f1-score	support
fire_images	0.93	1.00	0.97	158
non_fire_images	1.00	0.74	0.85	43
accuracy			0.95	201
macro avg	0.97	0.87	0.91	201
weighted avg	0.95	0.95	0.94	201

	precision	recall	f1-score	support
fire_images	0.934911	1.000000	0.966361	158.000000
non_fire_images	1.000000	0.744186	0.853333	43.000000
accuracy	0.945274	0.945274	0.945274	0.945274
macro avg	0.967456	0.872093	0.909847	201.000000
weighted avg	0.948836	0.945274	0.942181	201.000000

Рисунок 6.2 – Результати метрик

Аналіз специфічних метрик ефективності для кожного класу показує високу збалансованість моделі. Для класу зображень пожеж модель досягла показника точності (precision) 0.93, повноти (recall) 1.00 та F1-score 0.97. Для класу зображень без пожеж відповідні показники склали: точність 1.00, повнота 0.74 та F1-score 0.85. Такі результати свідчать про те, що модель

особливо ефективна у виявленні пожеж, не пропускаючи жодного випадку, що є критично важливим для систем безпеки.

Графік точності по класах підтверджує збалансованість моделі, демонструючи високу точність для обох класів: приблизно 93% для класу «fire_images» та 100% для класу «non_fire_images». Спостерігається певна різниця в точності між класами, що може бути пояснена незбалансованістю набору даних, де кількість зображень пожеж (158) значно перевищує кількість зображень без пожеж (43), що є типовим для задач виявлення аномалій.

Зважені середні показники для всієї моделі демонструють високу загальну ефективність: precision 0.95, recall 0.95 та F1-score 0.94. Ці метрики підтверджують високу якість розробленої моделі, особливо враховуючи складність задачі класифікації пожеж у реальних умовах. Модель демонструє оптимальний баланс між точністю та повнотою, що робить її придатною для практичного застосування в системах моніторингу та раннього виявлення пожеж.

Особливо важливим аспектом є те, що модель демонструє тенденцію до більш консервативної класифікації зображень без пожеж. Така характеристика є бажаною для систем безпеки, де хибні негативи (пропущені пожежі) є значно більш критичними, ніж хибні позитиви. Це означає, що система скоріше створить зайве попередження про можливу пожежу, ніж пропустить реальну небезпечну ситуацію, що повністю відповідає вимогам до систем безпеки та раннього попередження.

6.2 Порівняння отриманих результатів із існуючими підходами

Досягнуті результати розробленої моделі класифікації пожеж на основі згорткових нейронних мереж з використанням архітектури EfficientNetV0 демонструють значний прогрес у порівнянні з традиційними та сучасними підходами до виявлення пожеж на зображеннях.

У порівнянні з іншими рішеннями на основі глибокого навчання, розроблена модель також показує конкурентні результати. Реалізації на базі VGG16, описані в літературі, досягають точності близько 91–92% [12]. Підходи з використанням ResNet50 показують схожі результати з точністю 90–93%. Наша модель, побудована на архітектурі EfficientNetB0, не тільки перевершує ці показники за точністю, але й має значно меншу кількість параметрів, що робить її більш ефективною з точки зору обчислювальних ресурсів.

Особливо важливим досягненням розробленої моделі є показник recall у 100% для класу пожеж, що перевершує більшість існуючих рішень, де цей показник зазвичай коливається в межах 95–98%. Це означає, що розроблена модель не пропускає випадків пожежі, що є критично важливим для систем безпеки. При цьому досягнутий баланс між precision (93.4%) та recall відповідає сучасним вимогам до систем виявлення пожеж.

Порівняно з гібридними системами, які комбінують різні підходи до виявлення пожеж, модель демонструє порівнянну ефективність, але має перевагу в простоті реалізації та швидкості роботи. Наприклад, гібридна система, що поєднує аналіз руху та колірну сегментацію, описана в роботі Avazov, K.; Jamil, M.K.; Muminov, B.; Abdusalomov, A.V., досягає точності 93%, але потребує значно більших обчислювальних ресурсів та складнішої системи обробки даних [6].

Важливою перевагою описаної моделі є її здатність ефективно працювати з незбалансованим набором даних, що часто зустрічається в реальних умовах. При співвідношенні класів приблизно 3.7:1 (158 зображень пожеж проти 43 зображень без пожеж) модель зберігає високу точність для обох класів, що не завжди вдається досягти в існуючих рішеннях.

F1-score розробленої моделі (0.94) також перевершує більшість опублікованих результатів, де цей показник зазвичай не перевищує 0.90. Це свідчить про кращий баланс між точністю та повнотою класифікації.

Досягнуте значення функції втрат (0.23965) також вказує на кращу збіжність моделі порівняно з аналогічними архітектурами, де цей показник часто перевищує 0.3.

Отримані результати підтверджують ефективність обраного підходу та демонструють, що розроблена модель не тільки відповідає сучасному рівню технологій у галузі виявлення пожеж, але й перевершує багато існуючих рішень за ключовими показниками. При цьому модель зберігає практичність реалізації та може бути ефективно інтегрована в реальні системи моніторингу та раннього виявлення пожеж.

6.3 Обговорення обмежень моделі та напрямків її вдосконалення

Незважаючи на високу ефективність розробленої моделі, важливо визнати існуючі обмеження та окреслити потенційні напрямки вдосконалення для подальшого покращення її роботи. Аналіз результатів тестування та практичного застосування виявив декілька ключових аспектів, які потребують уваги при подальшому розвитку системи.

Одним з основних обмежень моделі є її залежність від якості вхідних зображень. При роботі з зображеннями низької роздільної здатності або при наявності значних шумів точність класифікації може знижуватися. Це особливо критично в умовах поганої видимості, наприклад, при сильному задимленні або в нічний час. Для подолання цього обмеження перспективним напрямком є впровадження додаткових методів попередньої обробки зображень та розширення навчального набору даних зображеннями різної якості та умов освітлення.

Також варто відзначити, що поточна модель може мати складнощі з розпізнаванням пожеж на ранніх стадіях, коли візуальні ознаки ще не є чітко вираженими. Вдосконалення в цьому напрямку можливе через інтеграцію додаткових каналів даних, таких як інфрачервоні зображення або дані про температуру, що дозволить створити мультимодальну систему виявлення.

Суттєвим обмеженням є незбалансованість навчального набору даних, де кількість зображень з пожежами значно перевищує кількість зображень без пожеж. Хоча модель демонструє хороші результати навіть з такими даними, збалансування набору даних та розширення його різноманітності може покращити загальну продуктивність системи. Можливим рішенням є застосування технік аугментації даних та генеративних моделей для створення синтетичних прикладів.

При роботі в реальному часі модель може потребувати оптимізації з точки зору обчислювальної ефективності. Можливими напрямками вдосконалення є квантизація моделі, застосування технік дистиляції знань та оптимізація архітектури для роботи на edge-пристроях. Це дозволить знизити вимоги до обчислювальних ресурсів без суттєвої втрати точності.

Модель також може мати обмеження при роботі в специфічних умовах навколишнього середовища, таких як сильний дощ, сніг або туман. Розширення навчального набору даних зображеннями, отриманими в різних погодних умовах, та впровадження механізмів адаптації до змін навколишнього середовища може значно покращити надійність системи.

Перспективним напрямком вдосконалення є розробка механізмів інтерпретації рішень моделі. Впровадження технік візуалізації активацій нейронної мережі та методів пояснення прийнятих рішень дозволить краще розуміти роботу моделі та підвищити довіру до її результатів у критичних застосуваннях.

Перспективним напрямком є також розробка механізмів постійного навчання моделі на нових даних без повного перенавчання, що дозволить системі адаптуватися до нових умов та покращувати свою точність з часом. Це потребує впровадження технік континуального навчання та розробки механізмів валідації оновлень моделі.

7 ПРАКТИЧНЕ ЗАСТОСУВАННЯ

Розроблена модель без використання в реальному середовищі не може приносити користі. Тому для того щоб результат моделі в 94% привнести до України та всього світу, викладаються наступні рекомендації по введенню в експлуатацію.

7.1 Рекомендації щодо інтеграції моделі у сучасні системи безпеки

Інтеграція розробленої моделі класифікації пожеж у сучасні системи безпеки потребує комплексного підходу та врахування різних технічних і організаційних аспектів. Успішне впровадження моделі вимагає дотримання низки рекомендацій для забезпечення її ефективної роботи в реальних умовах експлуатації.

Першочерговим етапом інтеграції має бути підготовка технічної інфраструктури. Рекомендується використання серверів з графічними процесорами для забезпечення швидкої обробки відеопотоку в режимі реального часу. При цьому важливо передбачити механізми балансування навантаження та резервування для забезпечення безперервної роботи системи. Оптимальним рішенням є розгортання моделі в контейнеризованому середовищі з використанням технологій оркестрації для автоматичного масштабування ресурсів відповідно до навантаження.

Для ефективної роботи системи необхідно забезпечити якісний відеопотік з камер спостереження. Рекомендується використання камер з роздільною здатністю не менше 1080p та частотою кадрів не менше 25 fps. Важливим є правильне розташування камер з урахуванням зон ризику та потенційних джерел займання. При цьому слід забезпечити достатнє освітлення контрольованих зон у нічний час.

Інтеграція моделі в існуючі системи безпеки повинна здійснюватися через стандартизовані API інтерфейси. Рекомендується розробка

проміжного програмного забезпечення (middleware) для забезпечення сумісності з різними системами відеоспостереження та управління безпекою. Важливим аспектом є реалізація механізмів буферизації та черг повідомлень для обробки піків навантаження.

Система сповіщення про виявлені пожежі повинна бути багаторівневою. Рекомендується реалізація як автоматичних сповіщень через SMS, email та push-повідомлення, так і інтеграція з центральними пультами охорони та системами пожежної сигналізації. При цьому важливо передбачити механізми підтвердження отримання сповіщень та протоколювання всіх дій персоналу.

Для підвищення надійності роботи системи рекомендується впровадження механізмів валідації результатів класифікації. Це може бути реалізовано через порівняння результатів з даними інших сенсорів (температури, диму) або через підтвердження оператором у випадку невпевненої класифікації. Важливо встановити appropriate граничні значення впевненості моделі для різних сценаріїв використання.

Необхідним є впровадження системи моніторингу продуктивності моделі та збору метрик її роботи. Рекомендується відстеження таких показників як час обробки кадру, завантаження обчислювальних ресурсів, кількість помилкових спрацювань. Ці дані мають використовуватися для оптимізації роботи системи та планування її масштабування.

Важливим аспектом є забезпечення захисту даних та кібербезпеки системи. Рекомендується використання шифрування при передачі даних, впровадження механізмів автентифікації та авторизації, регулярне оновлення програмного забезпечення та моніторинг спроб несанкціонованого доступу.

Для забезпечення безперервності роботи системи необхідно розробити процедури резервного копіювання та відновлення після збоїв. Рекомендується впровадження механізмів автоматичного перемикавання на

резервні сервери та збереження критично важливих даних у розподіленому сховищі.

Особлива увага має приділятися навчанню персоналу, який буде працювати з системою. Рекомендується розробка детальної документації, проведення регулярних тренінгів та створення чітких інструкцій щодо дій у різних ситуаціях. Важливим є забезпечення цілодобової технічної підтримки системи.

Для оптимізації роботи системи в довгостроковій перспективі рекомендується впровадження механізмів збору зворотного зв'язку від користувачів та аналізу ефективності роботи системи. Ці дані мають використовуватися для подальшого вдосконалення моделі та оптимізації процесів її інтеграції.

7.2 Оцінка економічного та соціального ефекту від застосування

Впровадження розробленої системи класифікації пожеж має значний економічний та соціальний ефект, який проявляється у декількох ключових аспектах. Проведений аналіз демонструє суттєві переваги як для окремих організацій, так і для суспільства в цілому.

З економічної точки зору, система дозволяє значно знизити матеріальні збитки від пожеж завдяки ранньому виявленню займань. За статистичними даними, своєчасне виявлення пожежі на початковій стадії дозволяє зменшити потенційні збитки на 60–80% [13]. Враховуючи, що середній збиток від великої пожежі на промисловому об'єкті може сягати кількох мільйонів гривень, впровадження системи має значний економічний потенціал.

Важливим економічним аспектом є зниження витрат на страхування майна. Страхові компанії зазвичай надають знижки до 15–20% на страхові премії для об'єктів, обладнаних сучасними системами раннього виявлення

пожеж. Це створює додаткову економічну вигоду для підприємств та організацій, які впроваджують подібні системи.

Автоматизація процесу виявлення пожеж дозволяє оптимізувати витрати на персонал служби безпеки. При цьому підвищується ефективність роботи наявного персоналу, оскільки система дозволяє зосередити увагу на реальних загрозах замість рутинного моніторингу. За оцінками, це може призвести до економії 20–30% витрат на забезпечення пожежної безпеки об'єкта [13].

Соціальний ефект від впровадження системи проявляється насамперед у підвищенні рівня безпеки людей. Швидке виявлення пожеж значно збільшує шанси на успішну евакуацію та зменшує ризик травмування персоналу. Статистика показує, що використання автоматизованих систем виявлення пожеж знижує ймовірність людських жертв при пожежах на 40–50% [14].

Впровадження системи також має позитивний вплив на психологічний стан працівників та відвідувачів об'єктів. Усвідомлення наявності надійної системи безпеки знижує рівень стресу та підвищує впевненість людей у своїй безпеці. Це особливо важливо для об'єктів з масовим перебуванням людей, таких як торговельні центри, навчальні заклади та офісні приміщення.

Важливим аспектом є також створення нових робочих місць у сфері розробки, впровадження та обслуговування подібних систем. Це сприяє розвитку ринку високотехнологічних послуг та підвищенню кваліфікації технічних спеціалістів.

Загальний економічний ефект від впровадження системи може бути оцінений через співвідношення витрат на впровадження та потенційної економії від запобігання збиткам. За попередніми оцінками, термін окупності системи для середнього промислового об'єкта становить 1.5–2 роки, що робить інвестиції в подібні системи економічно обґрунтованими.

8 ЕТИЧНІ АСПЕКТИ ЗАСТОСУВАННЯ СИСТЕМИ

В питанні пожеж рахунок йде не просто на прибутки або втрати грошей а на життя людей. Це створює необхідність розглянути етичні питання застосування розробленого застосунку, з метою запобігання використанню цієї розробки з не етичним наміром.

8.1 Потенційні ризики неправильної класифікації

У контексті розробки та впровадження системи класифікації пожеж на основі згорткових нейронних мереж важливо детально розглянути потенційні ризики, пов'язані з неправильною класифікацією. Неправильна класифікація може мати серйозні наслідки, особливо коли система використовується як частина критичної інфраструктури безпеки.

Основним ризиком є можливість хибнопозитивних спрацювань, коли система помилково класифікує безпечну ситуацію як пожежу. Такі помилки можуть призвести до необґрунтованої евакуації будівель, активації систем пожежогасіння та нераціонального використання ресурсів екстрених служб. Це не лише створює незручності для людей, але й може призвести до значних економічних втрат та зниження довіри до автоматизованих систем безпеки.

Ще більш критичним є ризик хибнонегативних результатів, коли система не розпізнає реальну пожежу. Такі помилки можуть призвести до затримки реагування на надзвичайну ситуацію, що ставить під загрозу життя людей та майно. Особливо небезпечними є випадки, коли система використовується як єдиний метод виявлення пожеж без належного резервування. Розроблена система жодного разу не проявила себе в такого типу похибках але в контексті майбутніх розробок це необхідно зауважити.

Важливо враховувати також психологічний аспект впливу помилкових спрацювань на персонал та мешканців будівель. Часті хибні

тривоги можуть призвести до синдрому «втоми від тривоги», коли люди починають ігнорувати попередження системи, що небезпечно у випадку реальної загрози.

Окремої уваги заслуговує проблема відповідальності за наслідки неправильної класифікації. У випадку інцидентів постає питання розподілу відповідальності між розробниками системи, операторами та власниками об'єктів, де вона встановлена. Це створює необхідність розробки чітких юридичних рамок та протоколів реагування на помилки системи.

Для мінімізації цих ризиків необхідно впроваджувати багаторівневі системи верифікації результатів класифікації, регулярно проводити калібрування та оновлення моделей, а також забезпечувати належне навчання персоналу щодо обмежень системи та протоколів реагування на її сигнали. Особливу увагу слід приділяти документуванню всіх випадків неправильної класифікації для подальшого аналізу та вдосконалення системи.

8.2 Конфіденційність

Впровадження системи класифікації пожеж на основі згорткових нейронних мереж піднімає важливі питання щодо захисту конфіденційності та приватності. Використання камер та систем відеоспостереження для збору даних створює потенційні ризики порушення приватності осіб, які перебувають у зоні моніторингу.

При обробці відеопотоку система може випадково захоплювати персональні дані, включаючи обличчя людей, номерні знаки транспортних засобів та інші ідентифікуючі елементи. Особливо гострим це питання стає при встановленні системи в житлових приміщеннях, офісах та інших приватних просторах, де люди очікують певного рівня конфіденційності.

Важливим аспектом є також безпека зберігання та передачі даних. Відеопотік та результати аналізу можуть містити чутливу інформацію про

планування приміщень, розташування цінного обладнання та режим роботи об'єктів. Необхідно забезпечити надійний захист цих даних від несанкціонованого доступу та можливих кібератак.

Окремої уваги заслуговує питання тривалості зберігання даних та правил їх використання. Потрібно чітко визначити, які дані зберігаються, як довго вони зберігаються, хто має до них доступ та за яких умов вони можуть бути передані третім сторонам, наприклад, правоохоронним органам чи страховим компаніям.

Для забезпечення належного рівня захисту приватності необхідно впроваджувати технології анонімізації даних, включаючи автоматичне розмиття облич та інших ідентифікуючих елементів. Важливо також розробити та впровадити чіткі політики конфіденційності, які відповідають вимогам законодавства про захист персональних даних та враховують етичні аспекти використання систем відеоспостереження.

Суттєвим є також питання інформування осіб про наявність системи відеоспостереження та отримання відповідних згод на обробку персональних даних. Необхідно забезпечити прозорість щодо цілей використання системи та надати можливість особам реалізувати свої права щодо захисту персональних даних.

8.3 Зменшення ризиків використання ІІІ у сфері ідентифікації пожеж

При розробці та впровадженні систем штучного інтелекту для класифікації пожеж необхідно застосовувати комплексний підхід до мінімізації ризиків. Першочерговим заходом є впровадження багаторівневої системи верифікації результатів, яка включає паралельне використання традиційних датчиків диму та температури разом із системою комп'ютерного зору. Такий підхід дозволяє знизити ймовірність як хибнопозитивних, так і хибнонегативних спрацювань.

Важливим аспектом є постійне оновлення та перенавчання моделей на нових даних. Це допомагає адаптувати систему до змін умов експлуатації та покращувати її точність з часом. При цьому необхідно зберігати всі випадки помилкової класифікації для подальшого аналізу та вдосконалення алгоритмів.

Для захисту приватності рекомендується впровадження технологій автоматичної анонімізації даних безпосередньо на етапі збору інформації. Це включає розмиття облич, номерних знаків та інших персональних ідентифікаторів у режимі реального часу, до того як дані потраплять у систему зберігання.

Суттєвим елементом зниження ризиків є регулярне проведення аудиту системи незалежними експертами. Такі перевірки повинні охоплювати як технічні аспекти роботи системи, так і відповідність протоколів обробки даних вимогам законодавства про захист персональних даних.

Необхідно також забезпечити належну підготовку персоналу, який працює з системою. Це включає навчання щодо інтерпретації результатів класифікації, розуміння обмежень системи та правильних дій у випадку виникнення помилок або збоїв. Важливо розробити чіткі протоколи дій для різних сценаріїв роботи системи.

Для зменшення ризиків кібербезпеки рекомендується впровадження сучасних методів шифрування даних, регулярне оновлення програмного забезпечення та проведення тестів на проникнення. Особливу увагу слід приділяти захисту каналів передачі даних та системам контролю доступу.

Важливим компонентом є створення системи моніторингу продуктивності та якості роботи ІІІ-системи. Це допомагає вчасно виявляти відхилення в роботі та запобігати потенційним проблемам ще до їх виникнення. Також необхідно розробити плани реагування на надзвичайні ситуації та забезпечити наявність резервних систем.

ВИСНОВКИ

В результаті проведеної розробки моделі для класифікації та ідентифікації пожеж на зображеннях була розроблена потужна модель з результатом 94% точних спрацьовувань. Модель була навчана в тому числі на реальних фотографіях пожеж з інформаційних джерел України та міста Харкова, в тому числі в результаті взривів та катастроф. Що дає дійсно перспективу використання в реальному світі.

У ході виконання кваліфікаційної роботи було повністю реалізовано поставлені завдання з розробки та дослідження класифікатора пожеж на зображеннях за допомогою згорткових нейронних мереж. Проведено всебічний аналіз існуючих методів виявлення пожеж та обґрунтовано доцільність використання глибокого навчання для вирішення даної задачі.

Розроблена модель на основі архітектури EfficientNetV0 продемонструвала високу ефективність, досягнувши загальної точності 94.53% на тестовому наборі даних, що перевищує показники багатьох існуючих аналогів. Особливо важливим досягненням є показник recall у 100% для класу пожеж, що означає відсутність пропущених випадків займання. Модель також показала здатність ефективно працювати з незбалансованим набором даних, досягнувши показників precision 93.4% та F1-score 0.94, що відповідає сучасним вимогам до систем виявлення пожеж.

Дослідження виконано в рамках наукового напрямку університетського факультету комп'ютерних наук та має зв'язок з дослідженнями лабораторії штучного інтелекту університету. Отримані результати доповнюють існуючі розробки кафедри в галузі систем безпеки та моніторингу.

В процесі роботи були отримані нові наукові результати щодо методів попередньої обробки даних та архітектури нейронної мережі для задачі виявлення пожеж. Розроблені методи та алгоритми можуть бути використані як основа для подальших досліджень в напрямку

вдосконалення систем виявлення пожеж, зокрема для роботи в складних умовах освітлення та при наявності перешкод.

Важливим аспектом роботи стала розробка рекомендацій щодо практичного впровадження системи. Було детально опрацьовано питання інтеграції моделі в існуючі системи безпеки, включаючи технічні вимоги до обладнання, механізми обробки даних та системи сповіщення. Запропоновані рішення враховують потреби реальних об'єктів та забезпечують надійну роботу системи в різних умовах експлуатації.

Проведена оцінка економічного та соціального ефекту від впровадження системи показала значний потенціал для зниження матеріальних збитків від пожеж та підвищення рівня безпеки людей.

Матеріали роботи та розроблене програмне забезпечення можуть бути використані в навчальному процесі університету при викладанні дисциплін «Комп'ютерний зір» та «Глибинне навчання», а також для проведення лабораторних робіт з розробки систем машинного навчання. Практична цінність роботи підтверджується можливістю впровадження розробленої системи на реальних об'єктах для підвищення рівня пожежної безпеки.

Результати дослідження створюють основу для подальшого розвитку систем автоматизованого виявлення пожеж та демонструють значний потенціал використання методів глибокого навчання для вирішення важливих практичних задач у сфері безпеки.

Важливим напрямком подальших досліджень є також інтеграція розробленої системи з іншими типами сенсорів та створення комплексного рішення для моніторингу безпеки об'єктів. Перспективним є дослідження можливостей застосування системи для специфічних типів об'єктів та умов експлуатації.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Convolutional Neural Network (CNN) | TensorFlow Core. *TensorFlow*. URL: <https://www.tensorflow.org/tutorials/images/cnn> (date of access: 21.11.2024).
2. World Fire Statistics. *ctif.org*. URL: <https://www.ctif.org/world-fire-statistics> (date of access: 21.11.2024).
3. Vision Zero Homepage | Vision Zero. *Vision Zero Homepage / Vision Zero*. URL: <https://visionzero.global> (date of access: 30.11.2024).
4. Contributors to Wikimedia projects. Convolutional neural network - Wikipedia. *Wikipedia, the free encyclopedia*. URL: https://en.wikipedia.org/wiki/Convolutional_neural_network (date of access: 30.11.2024).
5. Fire Detection with Deep Learning: A Comprehensive Review / R. N. Vasconcelos et al. *Land*. 2024. Vol. 13, no. 10. URL: <https://doi.org/10.3390/land13101696> (date of access: 30.11.2024).
6. Fire Detection and Notification Method in Ship Areas Using Deep Learning and Computer Vision Approaches / K. Avazov et al. *Sensors*. 2023. Vol. 23, no. 16. URL: <https://doi.org/10.3390/s23167078> (date of access: 30.11.2024).
7. Fire Threat Detection From Videos with Q-Rough Sets. *arXiv.org*. URL: <https://doi.org/10.48550/arXiv.2101.08459> (date of access: 03.12.2024).
8. MobileNetV2: Inverted Residuals and Linear Bottlenecks. *arXiv.org*. URL: <https://doi.org/10.48550/arXiv.1801.04381> (date of access: 03.12.2024).
9. How to Configure Image Data Augmentation in Keras. *machinelearningmastery*. URL: <https://machinelearningmastery.com/how-to-configure-image-data-augmentation-when-training-deep-learning-neural-networks/> (date of access: 03.12.2024).

10. LeCun Y., Bengio Y., Hinton G. Deep learning. *Nature*. 2015. Vol. 521, no. 7553. URL: <https://doi.org/10.1038/nature14539> (date of access: 6.12.2024).

11. Krizhevsky A., Sutskever I., Hinton G. E. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*. 2017. Vol. 60, no. 6. URL: <https://doi.org/10.1145/3065386> (date of access: 10.12.2024).

12. Deep Residual Learning for Image Recognition. *arXiv.org*. URL: <https://doi.org/10.48550/arXiv.1512.03385> (date of access: 10.12.2024).

13. Fire Protection System Market by Fire Suppression, Smoke Detector (Photoelectric, Ionization, Beam), Flame Detector (IR, UV), Heat Detector, Sprinkler (Wet, Dry, Deluge), Fire Response & Analysis, Service, Vertical and Region - Global Forecast to 2029. *Markets and markets Research*. URL: <https://www.marketsandmarkets.com/Market-Reports/fire-protection-systems-market-1018.html> (date of access: 10.12.2024).

14. Аналітична довідка про пожежі та їх наслідки в Україні за 12 місяців 2023 року. Київ : Державна служба України з надзвичайних ситуацій, 2024.

15. Transfer learning & fine-tuning. *keras.io*. URL: https://keras.io/guides/transfer_learning/ (date of access: 15.12.2024).

16. Transfer Learning for Deep Learning Neural Networks. *machinelearningmastery*. URL: <https://machinelearningmastery.com/transfer-learning-for-deep-learning/> (date of access: 15.12.2024).

17. Dropout: a simple way to prevent neural networks from overfitting / N. Srivastava et al. *The Journal of Machine Learning Research*. 2014. Vol. 15, no. 1. P. 1929–1958.

18. Cortes C., Vapnik V. Support-Vector Networks. *Machine Learning*. 1995. Vol. 20, no. 3. URL: <https://doi.org/10.1023/a:1022627411411> (date of access: 18.12.2024).

19. Breiman L. Random Forests. *Machine Learning*. 2001. Vol. 45, no. 1.
URL: <https://doi.org/10.1023/a:1010933404324> (date of access: 30.12.2024).
20. FSDF: A high-performance fire detection framework / H. Zhao et al. *Expert Systems with Applications*. 2023. P. 121665.
URL: <https://doi.org/10.1016/j.eswa.2023.121665> (date of access: 18.12.2024).
21. ML Practicum: Image Classification. *developers.google*.
URL: <https://developers.google.com/machine-learning/practica/image-classification/convolutional-neural-networks> (date of access: 18.12.2024).
22. Training checkpoints. *tensorflow.org*.
URL: <https://www.tensorflow.org/guide/checkpoint> (date of access: 19.12.2024).