

**ПОЛТАВСЬКИЙ ДЕРЖАВНИЙ АГРАРНИЙ УНІВЕРСИТЕТ
НАВЧАЛЬНО-НАУКОВИЙ ІНСТИТУТ ЕКОНОМІКИ, УПРАВЛІННЯ,
ПРАВА ТА ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КАФЕДРА ІНФОРМАЦІЙНИХ СИСТЕМ ТА ТЕХНОЛОГІЙ**

Пояснювальна записка

до кваліфікаційної роботи на здобуття ступеня вищої освіти магістр

**на тему: «Алгоритмізація дослідження продуктивності нейронних
мереж для відстеження пасажиропотоку в громадському транспорті»**

Виконав: здобувач вищої освіти
за освітньо-професійною програмою
Інформаційні управляючі системи та
технології спеціальності

126 Інформаційні системи та технології
ступеня вищої освіти магістр

групи 126ІСТмд_22

Федорченко М. Б.

Керівник: Уткін Ю. В.

Рецензент: Петраш Р.В.

Полтава – 2023 року

ВСТУП

Сучасний світ відзначається стрімким розвитком інформаційних технологій та комп’ютерних систем. Однією з ключових областей, де застосовуються передові технології комп’ютерного зору і штучного інтелекту, є відстеження пасажиропотоку в громадському транспорті. Впровадження автоматизованих систем моніторингу пасажирського руху дозволяє не лише підвищити рівень безпеки та зручності для пасажирів, але й оптимізувати роботу перевізників і планувати розвиток міського транспорту більш ефективно.

Актуальність теми дослідження полягає в тому, що в сучасних умовах існує велика кількість варіантів і методів відстеження пасажиропотоку, включаючи традиційні алгоритми комп’ютерного зору та новітні методи на основі нейронних мереж. Обрана тема дослідження спрямована на розробку та аналіз алгоритмів для відстеження пасажиропотоку в громадському транспорті з використанням нейронних мереж.

Мета та завдання дослідження включають в себе наступне:

- дослідження та аналіз сучасних теоретичних та методологічних аспектів комп’ютерного зору;
- вивчення основних концепцій та принципів нейронних мереж, їхню класифікацію та типологію моделей, які застосовуються у відстеженні;
- розробка методології оцінки ефективності алгоритмів трекінгу та вибір критеріїв для порівняння різних методів;
- аналіз наукових джерел та практичних розробок у сфері трекінгу пасажиропотоку, зокрема, огляд сучасних наукових праць та наявних реалізацій;
- розробка та практична реалізація алгоритмів трекінгу на базі нейронних мереж з подальшим аналізом результатів;
- формульовання висновків та рекомендацій для подального використання результатів дослідження.

Об'єкт та предмет дослідження полягають у вивченні та аналізі алгоритмів відстеження пасажиропотоку в громадському транспорті, а методи наукових досліджень включають в себе аналіз наукових джерел, експерименти з реалізацією алгоритмів та порівняльний аналіз отриманих результатів.

Інформаційна база дослідження включає в себе наукові статті, книги, онлайн ресурси, а також дані та бібліотеки програмного забезпечення, зокрема OpenCV та інші інструменти для реалізації алгоритмів комп'ютерного зору.

Елементи наукової новизни в дослідженні полягають у спробі застосувати передові методи нейронних мереж для розв'язання завдань відстеження пасажиропотоку та у розробці нових методів оцінки ефективності таких алгоритмів.

Практична значущість цього дослідження полягає у можливості створення автоматизованих систем для моніторингу пасажиропотоку, що можуть бути застосовані в громадському транспорті для підвищення якості обслуговування пасажирів і оптимізації роботи транспортних компаній.

Апробація результатів дослідження передбачає проведення відповідних експериментів та аналіз результатів на наукових конференціях і заходах з відповідною тематикою.

Структура кваліфікаційної роботи включає три основних розділи. Перший розділ присвячено теоретичним та методологічним аспектам дослідження алгоритмів комп'ютерного зору, другий розділ – дослідницько-аналітичному огляду алгоритмів трекінга і нейронних мереж. Третій розділ націлений на практичне застосування теоретичних знань та результатів досліджень для розробки системи відстеження пасажиропотоків, оцінки її ефективності, економічного аналізу впровадження системи, а також виявлення та мінімізації потенційних ризиків. Загальний обсяг пояснлюальної записки кваліфікаційної роботи складає 98 сторінок формату А4, містить посилання на список з 49 використаних літературних джерел.

РОЗДІЛ 1

ТЕОРЕТИЧНІ ТА МЕТОДОЛОГІЧНІ АСПЕКТИ ДОСЛІДЖЕННЯ АЛГОРИТМІВ КОМП'ЮТЕРНОГО ЗОРУ

1.1 Вступ до теми дослідження

Сучасний світ неможливо уявити без швидкісного обміну інформацією та високотехнологічних систем, що забезпечують цей обмін [1]. Однією з ключових областей, де такі системи знайшли своє застосування, є громадський транспорт. Відстеження пасажиропотоку з використанням комп'ютерного зору та нейронних мереж відкриває нові перспективи для збільшення ефективності та комфорту пасажирських перевезень. Це дослідження зосереджено на алгоритмізації та аналізі продуктивності нейронних мереж, призначених для відстеження пасажиропотоку, та їх можливого впровадження у системи громадського транспорту.

Однією з основних сфер застосування комп'ютерного зору є медицина. Він допомагає лікарям виявляти патології на рентгенограмах, проводити хірургічні операції з високою точністю, а також виявляти ознаки захворювань на ранніх стадіях [2]. Технології комп'ютерного зору є неоцінними в індивідуальній медицині, де вони допомагають у визначені індивідуальних ризиків та рекомендаціях щодо здоров'я.

У сфері автомобільної промисловості алгоритми комп'ютерного зору використовуються для створення автоматизованих водійських асистентів та систем автономного водіння. Вони допомагають водіям уникати аварій, виявляючи перешкоди, розпізнавати дорожні знаки і сигнали світлофорів, а також підтримувати безпечну дистанцію між автомобілями.

У галузі безпеки алгоритми комп'ютерного зору використовуються для виявлення вторгнень на об'єкти, розпізнавання облич та автоматичної перевірки відвідувачів. Це допомагає підвищити рівень безпеки на об'єктах та важливих точках доступу.

Робототехніка – ще одна галузь, де комп’ютерний зір знаходить широке застосування. Роботи, оснащені системами комп’ютерного зору, можуть навігувати у невідомих середовищах, виявляти об’єкти та розпізнавати їхні особливості. Це стає можливим завдяки алгоритмам відстеження об’єктів та плануванню маршруту.

Неспростовним завданням для алгоритмів комп’ютерного зору є використання їх у реальних умовах зі змінними факторами, такими як освітлення, погодні умови та інші. Відшукування оптимальних рішень для роботи в таких умовах вимагає подальших досліджень та розвитку алгоритмів [3].

Отже, алгоритми комп’ютерного зору відкривають перед нами широкі горизонти можливостей у багатьох галузях. Дослідження та аналіз цих алгоритмів є надзвичайно важливим завданням, що допоможе покращити якість та ефективність відповідних систем та застосувань.

Комп’ютерний зір – це галузь, що забезпечує машинам здатність «бачити» та аналізувати візуальні дані, що отримуються з навколошнього середовища через камери або інші оптичні сенсори. Використання комп’ютерного зору у громадському транспорті може включати моніторинг за заповненістю транспортних засобів, визначення оптимальних маршрутів, та інші задачі, спрямовані на покращення пасажирського сервісу та безпеки. Приклад моніторингу пасажиропотоку представлено на рисунку 1.1



Рисунок 1.1 – Приклад роботи моніторингу пасажиропотоку

Нейронні мережі відіграють важливу роль у розвитку інтелектуальних транспортних систем. Вони здатні самостійно «навчатися» на обсягах даних що збільшуються, це дозволяє їм ставати лише точнішими та ефективнішими з часом. Актуальність застосування нейронних мереж у громадському транспорті обумовлена потребою в автоматизації процесів управління пасажиропотоками та необхідністю вирішення складних задач, пов'язаних із обробкою великих обсягів даних в реальному часі. Приклад роботи нейронної мережі у рамках населеного пункту представлено на рисунку 1.2

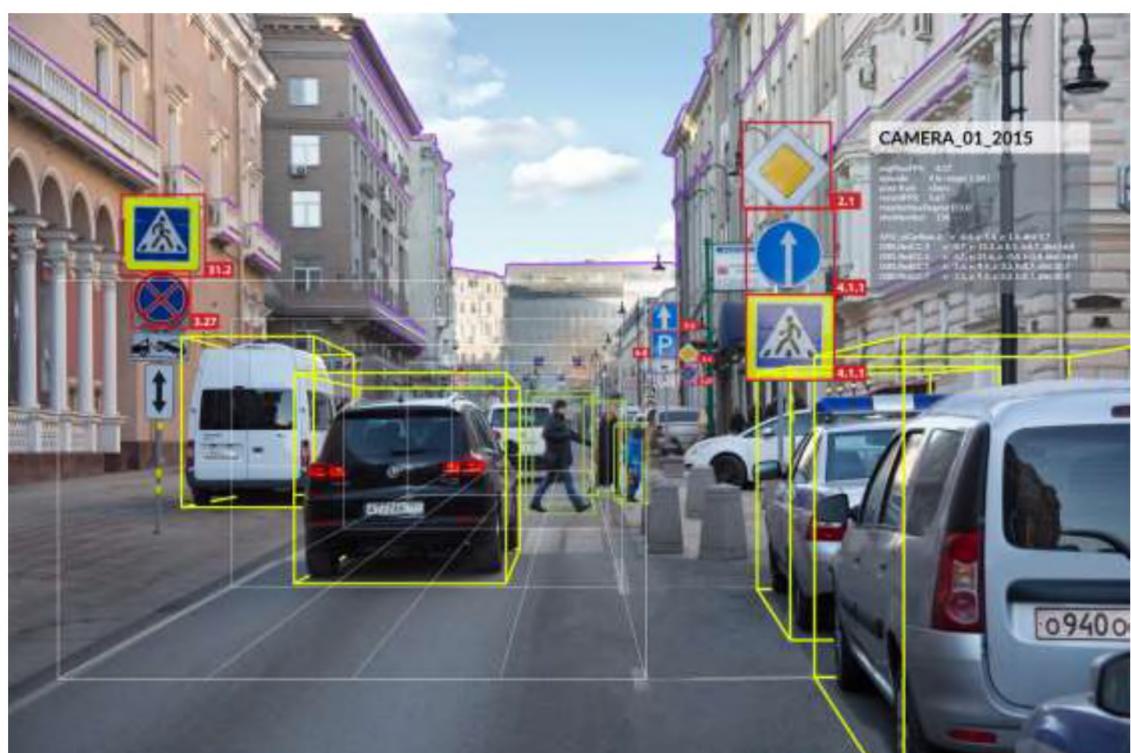


Рисунок 1.2 – Приклад роботи нейронної мережі у рамках населеного пункту

Мета даного дослідження полягає у розробці та тестуванні алгоритмів на базі нейронних мереж, які мають потенціал бути застосованими для відстеження пасажиропотоку в громадському транспорті. Це відкриває шлях до покращення якості та ефективності систем контролю пасажиропотоку, забезпечуючи більш точну інформацію про кількість пасажирів, їхній рух та розподіл у транспортних засобах.

Основні завдання дослідження включають в себе аналіз існуючих алгоритмів комп’ютерного зору, визначення їх ефективності та обмежень. Важливим аспектом є розробка нових моделей нейронних мереж, спроможних ефективно обробляти специфічні умови громадського транспорту. Це може включати в себе адаптацію до різних умов освітлення, різноманітних типів транспортних засобів та інших факторів.

Проведення експериментів для оцінки продуктивності розроблених алгоритмів є однією з ключових складових дослідження. Результати експериментів допоможуть з’ясувати, наскільки ефективними є запропоновані рішення та як вони впливають на точність та швидкість відстеження пасажирів.

Завершальним етапом дослідження буде надання рекомендацій щодо впровадження отриманих результатів у практику. Це може бути важливим кроком для покращення систем громадського транспорту та забезпечення задоволеності пасажирів.

Загальна актуальність теми полягає у тому, що вона може сприяти покращенню систем громадського транспорту та зробити їх більш зручними та ефективними для користувачів. Також вона відкриває можливості для подальших досліджень у галузі комп’ютерного зору та нейронних мереж, що є актуальними та перспективними напрямками наукових досліджень.

1.2 Теоретичні засади нейронних мереж

Нейронні мережі – це фундаментальна основа сучасних досліджень у галузі штучного інтелекту та машинного навчання. Їхнє застосування простягається від простих задач розпізнавання зразків до складних систем трекінгу та прогнозування. Вони імітують роботу людського мозку, використовуючи велику кількість взаємопов’язаних нейронів для обробки даних.

Важливим аспектом є теоретична база нейронних мереж, яка покладає основу для їхньої практичної реалізації. Нейронні мережі імітують роботу людського мозку, де нейрони з'єднані між собою, інформація передається через синапси, і відбувається обробка сигналів. Цей підхід дає можливість моделювати складні процеси та вирішувати завдання, які раніше були вкрай складними або навіть неможливими для розв'язання [4].

Теоретичні засади нейронних мереж включають в себе розділи математики, такі як лінійна алгебра, теорія ймовірностей та математична оптимізація. Нейронні мережі використовуються для розв'язання задач класифікації, регресії, кластеризації та багатьох інших. Вони дозволяють автоматизувати процеси обробки даних та виходити за межі традиційних методів аналізу.

Вони також включають в себе вивчення архітектур мереж, таких як зворотні зв'язки, згорткові шари, рекурентні нейронні мережі та багатошарові перцептрони. Кожна з цих архітектур має свої особливості та застосування в різних задачах.

Також важливим аспектом є вивчення функцій активації, які визначають, як нейронна мережа реагує на вхідні сигнали. Різні функції активації використовуються для вирішення різних завдань та можуть впливати на швидкість навчання та точність моделі.

Загальна теоретична база нейронних мереж є важливим елементом розуміння та розробки нових алгоритмів та моделей. Розуміння того, як працюють нейронні мережі на теоретичному рівні, допомагає вдосконалювати їхню практичну реалізацію та застосування в різних областях, включаючи відстеження пасажиропотоку в громадському транспорті [5].

У майбутньому, розвиток теоретичних зasad нейронних мереж продовжиться, що дозволить створювати більш потужні та ефективні моделі для різних завдань та сприяти подальшим досягненням у галузі машинного навчання та штучного інтелекту.

Основні принципи нейронних мереж:

- шари нейронних мереж. Традиційно, нейронна мережа складається з трьох типів шарів: входного, одного або декількох прихованих, та вихідного шару. Кожен шар містить нейрони, що отримують входні дані, обробляють їх і передають далі. Вхідний шар приймає первинні дані, приховані шари виконують обчислення, а вихідний шар надає результат.
- зв'язки між нейронами. Кожен нейрон у шарі пов'язаний із нейронами наступного шару через ваги, що є параметрами нейронної мережі та адаптуються в процесі навчання. Ваги визначають силу впливу одного нейрона на інший;
- функція активації. Нейрони використовують функції активації для визначення того, чи потрібно активувати (відправити сигнал) наступним нейронам. Функції активації, такі як сигмоїд, ReLU, та \tanh , допомагають мережі вчитися вирішувати нелінійні завдання;
- процес навчання. Навчання нейронних мереж здійснюється через процес, званий зворотним розповсюдженням помилки. Під час навчання мережі порівнюють вихідні дані з очікуваним результатом і регулюють ваги, щоб зменшити помилку;
- оптимізація. Алгоритми оптимізації, такі як градієнтний спуск, використовуються для знаходження найкращих ваг, які мінімізують втрати в процесі навчання.

Типи нейронних мереж:

- згорткові нейронні мережі (CNN). Ці мережі широко використовуються для аналізу візуальних образів завдяки їх здатності виявляти важливі особливості в зображеннях. Структура згорткової нейронної мережі представлена на рисунку 1.3

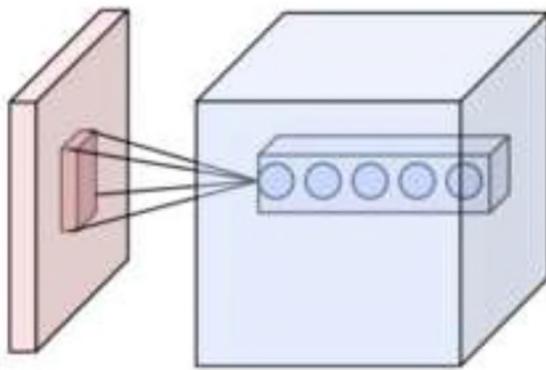


Рисунок 1.3 – Структура згорткової нейронної мережі

- рекурентні нейронні мережі (RNN). Ефективні для обробки послідовних даних, таких як мова або текст, оскільки мають «пам'ять» про попередні вхідні дані. Структура рекурентної нейронної мережі представлена на рисунку 1.4

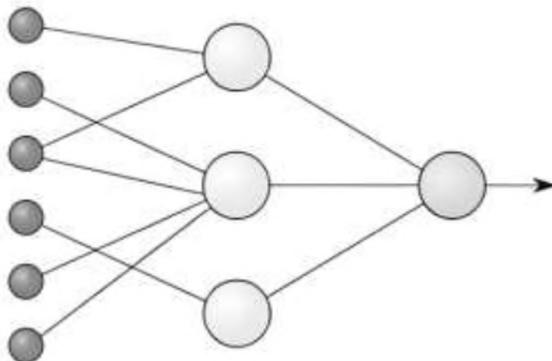


Рисунок 1.4 – Структура рекурентної нейронної мережі

- мережі прямого поширення. Стандартні нейронні мережі, де інформація рухається вперед від входного до вихідного шару без циклів;
- автокодувальники. Використовуються для зменшення розмірності даних і виявлення важливих особливостей в наборі даних;
- генеративні змагальні мережі (GAN). Складаються з двох мереж, генератора та дискримінатора, які «змагаються» між собою, дозволяючи створювати нові дані, схожі на навчальний набір. Приклад роботи генеративної змагальної мережі представлено на рисунку 1.5



Рисунок 1.5 – Приклад роботи генеративної змагальної мережі

Нейронні мережі застосовуються у трекінгу для ідентифікації та відстеження об'єктів у відеопотоці. Завдяки глибокому навчанню, системи трекінгу можуть самостійно адаптуватися до нових, раніше невідомих умов і продовжувати точне відстеження [6].

Перед тим як заглиблюватися у деталі теоретичних зasad, важливо розуміти загальний принцип роботи нейронних мереж. Нейронні мережі – це математичні моделі, які імітують структуру та функцію біологічних нейронних мереж у людському мозку. Вони складаються з нейронів, які з'єднані між собою, і взаємодіють за допомогою зважених з'єднань. Кожен нейрон обробляє вхідні сигнали, обчислює їхню вагу та передає результати наступному шару нейронів.

Теоретичні засади нейронних мереж включають в себе ряд ключових аспектів:

- кожен нейрон має функцію активації, яка визначає його відгук на вхідні сигнали. Популярні функції активації включають сигмоїду, ReLU (Rectified Linear Unit), тангенс гіперболічний та інші. Вибір функції активації може впливати на швидкість навчання та точність моделі;
- кожне з'єднання між нейронами має вагу, яка визначає важливість цього з'єднання для обчислень. Нейрони навчаються оптимізувати ці ваги під час тренування, щоб досягти бажаних результатів;

- для навчання нейронних мереж потрібна функція втрат, яка оцінює, наскільки відповіді моделі відрізняються від бажаних результатів. Популярні функції втрат включають середньоквадратичну помилку для задач регресії і категоріальну хрест-ентропію для задач класифікації;
- визначення кількості шарів та кількості нейронів у кожному шарі, а також способи з'єднання нейронів, є важливим аспектом розробки нейронної мережі. Архітектура може бути підібрана під конкретну задачу та тип даних;
- для того, щоб нейронна мережа вчилася, потрібен підходящий алгоритм навчання, такий як зворотнє поширення помилки (backpropagation) або еволюційні алгоритми. Алгоритм навчання визначає, яким чином коригуються ваги нейронів під час тренування;
- для запобігання перенавчанню (overfitting) може бути використана регуляризація, яка включає в себе методи, які обмежують величину ваг нейронів або використовують зважування.

Загальна мета досліджень у галузі теоретичних зasad нейронних мереж полягає у розумінні цих аспектів і розробці моделей, які були б здатні вирішувати різноманітні завдання, від розпізнавання об'єктів на зображеннях до аналізу тексту та прогнозування майбутніх подій. Можливості нейронних мереж безмежні, і їхнє використання широко розповсюджується в різних галузях, від медицини до фінансів [7].

Теоретичні засади нейронних мереж – це основа, на якій будується практична реалізація алгоритмів машинного навчання та систем штучного інтелекту. Вивчення цих засад дозволяє краще розуміти принципи роботи нейронних мереж, вдосконалювати їх ефективність та розробляти нові методи та підходи до розв'язання завдань.

Однією з ключових переваг нейронних мереж є їхня здатність до автоматичного навчання і адаптації до змінних умов. Нейронні мережі можуть навчатися на прикладах і виявляти складні залежності в даних, що робить їх потужними інструментами для аналізу та обробки інформації.

Глибоке навчання, відгалуження машинного навчання, яке використовує структуровані шари алгоритмічних обчислень для висновку, є ключовим фактором, що впливає на розвиток сучасних алгоритмів трекінгу. Ця технологія відрізняється здатністю до самонавчання з великих наборів даних і забезпечує значне підвищення точності в розпізнаванні образів, що є критично важливим для трекінгу об'єктів.

Нейронні мережі є підгалуззю машинного навчання, яка спрямована на використання штучних нейронних мереж для вирішення завдань. Основною відмінністю глибокого навчання є використання глибоких нейронних мереж, які мають багато шарів (відсічок) для обробки даних. Це дозволяє моделям глибокого навчання автоматично вивчати корисні функції та ознаки з великих об'ємів даних, що зробило цю технологію надзвичайно потужною в різних застосуваннях.

Однією з ключових характеристик глибокого навчання є здатність до відгалуження (або декомпозиції) великих завдань на менші підзавдання, які розв'язуються окремими шарами мережі. Це дозволяє створювати багаторівневі архітектури, де кожен рівень відповідає за різні аспекти аналізу даних. У контексті трекінгу це може бути корисним для визначення руху об'єкту, відстеження його форми та розмірів, а також вирішення інших завдань.

Глибоке навчання також славиться своєю здатністю до самонавчання на основі великих наборів даних. Моделі глибокого навчання можуть адаптуватися до нових, раніше невідомих умов, і продовжувати точно відстеження об'єктів навіть у складних умовах освітлення, шуму та інших факторів [8].

Застосування глибокого навчання у трекінгу об'єктів відкриває безліч можливостей. Можливість автоматично вивчати та розпізнавати об'єкти на відеозаписах робить глибоке навчання ідеальним інструментом для відстеження руху пасажирів у громадському транспорті. Відгалужені

архітектури можуть виконувати багато завдань одночасно, роблячи тренінг більш точним та ефективним.

Глибоке навчання внесло революційний вклад у спосіб, яким системи комп’ютерного зору ідентифікують та відстежують об’єкти у відеопотоках. Згорткові нейронні мережі (CNN), які ефективно виконують фільтрацію та ієрархічну класифікацію візуальних даних, стали фундаментом для багатьох сучасних систем трекінгу. Завдяки їх здатності до виявлення ознак на різних рівнях абстракції, CNN забезпечують необхідну гнучкість і точність для трекінгу в різноманітних умовах.

Перш за все, слід зазначити, що нейронні мережі – це математичні моделі, які намагаються імітувати роботу нейронів у людському мозку. Основною одиницею нейронної мережі є штучний нейрон, який приймає вхідні дані, обробляє їх та генерує вихід. Група таких нейронів утворює шар, а кілька шарів можуть бути використані для побудови повноцінної нейронної мережі.

Згорткові нейронні мережі (CNN) є однією з найпоширеніших архітектур нейронних мереж у задачах комп’ютерного зору. Вони ефективно впораються із завданнями фільтрації та класифікації візуальних даних завдяки спеціальним шарам згортки та пулінгу. Згорткові шари дозволяють виявляти різноманітні ознаки на різних рівнях деталізації, що дуже корисно у задачах трекінгу об’єктів. Пулінгові шари зменшують просторовий обсяг даних та покращують роботу мережі [9].

Однією з ключових особливостей нейронних мереж, що робить їх такими потужними, є їхній здатність до самонавчання на основі наборів даних. Нейронні мережі можуть адаптуватися до нових умов та завдань, вивчаючи корисні закономірності та ознаки зі вхідних даних. Це особливо важливо у задачах трекінгу, де умови можуть змінюватися, а об’єкти мають різні розміри, форми та властивості.

Застосування глибокого навчання та нейронних мереж у відстеженні об’єктів відкриває безліч можливостей для покращення точності та

продуктивності систем трекінгу. Вони можуть ефективно розпізнавати та відстежувати об'єкти навіть у складних умовах, враховуючи особливості їх руху та зміну форми. У дослідженні розглянуто основні поняття та методи глибокого навчання, які використовуються для трекінгу об'єктів у відеопотоці, та досліджено їхню ефективність у практичних застосуваннях.

Нейронні мережі є математичними моделями, які моделюють роботу нейронів у біологічному мозку. Вони складаються зі штучних нейронів, які приймають вхідні дані, обробляють їх та генерують вихід. Група таких нейронів утворює шар, а кілька шарів можуть бути використані для побудови повноцінної нейронної мережі. Одні з основних компонентів нейронних мереж включають в себе ваги, функції активації та зв'язки між нейронами. Ваги визначають важливість вхідних сигналів, функції активації визначають вихід сигналу нейрона, а зв'язки встановлюють зв'язки між нейронами в різних шарах мережі.

Однією з найпоширеніших архітектур нейронних мереж у задачах трекінгу є згорткові нейронні мережі (CNN). Вони спеціалізовані на обробці візуальної інформації та виявленні ознак у великих зображеннях. Згорткові шари дозволяють виявляти локальні ознаки на різних рівнях абстракції, що дуже корисно для трекінгу об'єктів з різними характеристиками та розмірами. Пулінгові шари допомагають зменшити просторовий обсяг даних та забезпечують інваріантність до масштабу та зсувів.

Рекурентні нейронні мережі (RNN) є іншою важливою архітектурою, яка використовується для відстеження об'єктів у відеопотоках. Особливо варто відзначити довгострокову короткочасну пам'ять (LSTM), яка дозволяє моделювати динаміку об'єктів з часом. Це критично важливо для точного відстеження об'єктів, оскільки вони можуть змінювати своє положення та характеристики з часом.

Використання глибокого навчання та нейронних мереж у задачах трекінгу дозволяє системам комп'ютерного зору адаптуватися до нових умов

та різних типів об'єктів. Вони можуть автоматично вивчати закономірності з великих наборів даних та забезпечувати точне та надійне відстеження.

Інтеграція глибокого навчання з традиційними алгоритмами трекінгу, такими як Kalman фільтри, призводить до створення гібридних систем, які поєднують надійність статистичних методів з потужністю самонавчання нейронних мереж [10]. Таке поєднання дозволяє системам трекінгу адаптуватися до нових умов в реальному часі і з високою точністю.

Розвиток глибокого навчання відчиняє двері для створення систем трекінгу нового покоління, які будуть оптимізовані для конкретних умов та завдань, характерних для громадського транспорту. Особливий інтерес викликає розвиток нейронних мереж, здатних до ефективного трекінгу в умовах обмеженого обчислювального ресурсу, що дозволить їх широке впровадження в мобільні та вбудовані системи.

Глибоке навчання є однією з ключових технологій, що революціонізує сучасну обробку візуальної інформації та аналіз зображень [11]. Ця технологія базується на штучних нейронних мережах, які імітують роботу людського мозку. Вона дозволяє системам аналізувати та розуміти великий обсяг візуальних даних, що робить її незамінною у сферах, де важлива обробка відеопотоку та трекінг об'єктів.

Важливою перевагою глибокого навчання є можливість навчання на великих наборах даних, що дозволяє створювати нейронні мережі, які здатні розв'язувати складні завдання трекінгу з високою точністю. Однак для громадського транспорту існують унікальні вимоги, такі як обмежений обчислювальний ресурс, висока залежність від швидкості обробки та точності результатів. Тому розвиток нейронних мереж для відстеження пасажиропотоку вимагає спеціалізованих підходів та оптимізації.

Глибоке навчання змінило свою позицію як фундаментальна основа для розвитку алгоритмів трекінгу, зокрема в контексті відстеження пасажиропотоку в громадському транспорті. Продовження досліджень і інтеграція нових відкриттів в практичні застосування є пріоритетними для

досягнення високої точності, адаптивності та ефективності систем в реальних умовах.

Громадський транспорт в сучасному місті є життєво важливою складовою інфраструктури, і забезпечення його ефективності та зручності для пасажирів є однією з ключових задач для міських влад. Однак відстеження та аналіз пасажиропотоку може бути завданням, яке вимагає значних зусиль та ресурсів. У цьому контексті важливою стає роль сучасних технологій, зокрема глибокого навчання, у вирішенні цих завдань.

Однією з ключових переваг глибокого навчання є його здатність до автоматичного виявлення та розпізнавання об'єктів на зображеннях. Це стає велими корисним у відстеженні пасажирів, що входять та виходять з транспортних засобів. Системи відстеження, побудовані на основі нейронних мереж, можуть автоматично реєструвати кількість пасажирів, визначати їхні маршрути та аналізувати зміни в пасажиропотоці з часом.

Однак використання глибокого навчання для відстеження пасажиропотоку вимагає вирішення ряду важливих технічних і організаційних питань.

По-перше, необхідно мати доступ до великих обсягів відеоданих, на яких можна навчати нейронні мережі. Це може включати в себе встановлення відеокамер в транспортних засобах, робочих місцях станцій, а також забезпечення потужностями для зберігання та обробки цих даних.

По-друге, важливо розробити ефективні алгоритми для відстеження пасажирів. Це може включати в себе розпізнавання облич, виявлення унікальних рис пасажирів, таких як одяг чи аксесуари, та здатність враховувати зміни в освітленні та атмосферних умовах.

По-третє, системи відстеження повинні бути гнучкими та адаптивними до різних умов. Це може включати в себе розробку алгоритмів, які здатні працювати в різних погодних умовах, в рухомих транспортних засобах, а також здатність враховувати ситуації, коли кількість пасажирів може значно змінюватися.

Однак незважаючи на ці технічні виклики, переваги використання глибокого навчання для відстеження пасажиропотоку є очевидними. Системи, побудовані на цій основі, можуть забезпечити надійний та точний аналіз пасажиропотоку, що дозволить оптимізувати роботу громадського транспорту та підвищити задоволеність пасажирів.

Таким чином, дослідження теоретичних та методологічних аспектів використання нейронних мереж для відстеження пасажиропотоку є актуальним та перспективним напрямом досліджень у галузі комп’ютерного зору та штучного інтелекту. Розвиток нових алгоритмів та їхнє практичне впровадження можуть сприяти покращенню систем громадського транспорту та підвищенню ефективності та зручності подорожей для всіх громадян.

1.3 Методологічні підходи до оцінки алгоритмів трекінгу

Методологія оцінки алгоритмів трекінгу відіграє ключову роль у вимірюванні їхньої продуктивності, зокрема при аналізі пасажиропотоку в громадському транспорті. Важливість встановлення ефективних критеріїв та методів оцінки полягає у можливості порівняння та відбору найбільш оптимальних рішень для конкретних умов використання.

Критерії оцінки ефективності алгоритмів трекінгу мають бути вибрані таким чином, щоб вони відображали ключові аспекти роботи системи, включаючи точність трекінгу, швидкість обробки, стабільність в різноманітних умовах, а також спроможність до адаптації. Визначення цих критеріїв має ґрунтуватися на аналізі вимог до системи та потенційних сценаріїв її застосування.

Основні аспекти, які необхідно врахувати:

- для алгоритмів, які використовуються для відстеження пасажиропотоку, життєво важливим є визначення точності ідентифікації окремих осіб або груп людей. Точність може бути оцінена за допомогою

порівняння вихідних даних алгоритму зі стандартними даними (ground truth), що включають марковані об'єкти в натовпі;

- враховуючи, що в громадському транспорті пасажиропотік є динамічним, алгоритми трекінгу повинні обробляти дані в режимі реального часу. Швидкість обробки даних алгоритмом є ключовим критерієм, який визначає його практичність у реальних умовах;

- громадський транспорт характеризується різноманітністю умов, включаючи зміну освітлення та погодних умов. Алгоритми повинні бути адаптивними до таких змін і здатними підтримувати високу точність незалежно від зовнішніх умов;

- стабільність оцінює спроможність алгоритму підтримувати надійне трекінг навіть при перешкодах, таких як перекриття об'єктів або втрата об'єктів з поля зору камери;

- важливо враховувати здатність алгоритму масштабуватися на велику кількість одночасних користувачів, особливо в години пік, коли пасажиропотік максимальний;

- особливо важливо для мобільних систем моніторингу, де алгоритми повинні бути оптимізовані для роботи з обмеженими обчислювальними та енергетичними ресурсами;

- алгоритми повинні бути стійкими до помилкових даних та випадкового шуму, які можуть бути спричинені рухом інших об'єктів, відображеннями або недоліками камер.

Для визначення цих критеріїв слід використовувати комплексні методики, які можуть включати аналіз даних, зібраних з реальних сценаріїв громадського транспорту, а також використання симуляцій та моделювання для оцінки потенційної ефективності алгоритмів в різних умовах. Слід також розглянути методи машинного навчання для автоматизації та покращення процесів оцінки та аналізу алгоритмів.

Методики тестування алгоритмів трекінгу зазвичай включають використання стандартизованих наборів даних із зазначенням ground truth, що

дозволяє об'єктивно оцінити їх продуктивність. Вони можуть включати сценарії з різними рівнями складності: від статичних зображень до динамічних відеопотоків з різними зовнішніми умовами. Це дозволяє визначити стійкість алгоритмів до змін у середовищі та їх здатність ефективно обробляти реальні ситуації.

Оцінка ефективності алгоритмів трекінгу є важливим аспектом дослідження в галузі комп'ютерного зору та штучного інтелекту. У контексті дослідження, яке спрямоване на розробку та тестування алгоритмів на базі нейронних мереж для відстеження пасажиропотоку в громадському транспорті, оцінка ефективності грає важливу роль.

Для проведення об'єктивної оцінки алгоритмів трекінгу необхідно мати чітко визначені критерії та методики тестування. Один із підходів до визначення ефективності полягає в використанні метрик, які вимірюють точність, швидкість та стійкість алгоритмів. Наприклад, метрика «точність відстеження» визначає, наскільки точно алгоритм може відстежувати об'єкти на відеозаписі, метрика «швидкість обчислень» вказує на час, який потрібен для обробки кожного кадру відео, а метрика «стійкість до змін» визначає, наскільки добре алгоритм справляється зі змінами в освітленні, фоні та швидкості руху об'єктів.

Основна мета роботи полягає в розробці універсальної методології для оцінки продуктивності нейронних мереж, які використовуються для відстеження пасажиропотоку. Для цього можуть бути використані стандартні датасети відеоданих з реальних громадських транспортних систем, які містять різноманітні умови та сценарії. Аналіз отриманих результатів дозволить визначити переваги та недоліки різних алгоритмів та розробити рекомендації щодо їхнього використання.

Важливим елементом методології є також збір та обробка даних. Для проведення тестування алгоритмів потрібно мати доступ до великих обсягів відеоданих, які можуть бути записані в реальних умовах громадського

транспорту. Дані мають бути анотовані для визначення правильних результатів трекінгу та оцінки відповідності алгоритмів.

Однією з ключових переваг методології є її універсальність. Вона може бути використана для оцінки різних алгоритмів трекінгу, незалежно від їхньої архітектури та реалізації. Такий підхід дозволяє порівнювати різні методи та визначити найбільш ефективні з точки зору відстеження пасажиропотоку.

Загальний висновок полягає в тому, що оцінка ефективності алгоритмів трекінгу є важливим етапом у розробці систем відстеження пасажиропотоку для громадського транспорту. Розробка універсальної методології та використання стандартних метрик та датасетів дозволяє об'єктивно оцінювати алгоритми та забезпечує базу для подальших досліджень та розробки нових рішень.

1.4 Аналіз наукових джерел та практичних розробок

Аналіз наукових джерел та практичних розробок є важливим кроком у підготовці та розробці будь-якої наукової роботи або проекту, присвячену темі трекінгу пасажиропотоку з використанням комп’ютерного зору. Описано сучасні дослідження та розробки в цій області, а також основні напрямки, які можуть бути корисними для вашого дослідження.

Сучасні дослідження та практичні розробки в області трекінгу пасажиропотоку з використанням комп’ютерного зору можна розділити на кілька ключових напрямків:

- алгоритми комп’ютерного зору. Багато досліджень спрямовані на розробку та оптимізацію алгоритмів обробки зображень для виявлення та відстеження об’єктів на відеозаписах. Використання класичних алгоритмів, таких як Haar-каскади, або сучасних, як YOLO (You Only Look Once), SSD (Single Shot MultiBox Detector), є актуальними та ефективними підходами;

- машинне навчання та нейронні мережі. Розвиток глибокого навчання внес значний внесок у сферу трекінгу пасажиропотоку. Застосування згорткових нейронних мереж (CNN) та рекурентних нейронних мереж (RNN), зокрема Long Short-Term Memory (LSTM), дозволяє покращити точність та швидкість відстеження об'єктів;
- аналіз великих обсягів даних. Зі збільшенням доступності великих обсягів відеоданих і розвитком технологій обробки даних стала можливою робота з великими датасетами для тренування та тестування алгоритмів. Важливим аспектом є розробка методик анотування даних для навчання моделей;
- системи реального часу та вбудовані рішення. Деякі дослідження спрямовані на розробку систем трекінгу, які мають працювати в реальному часі, з обмеженим обчислювальним ресурсом. Це актуально для вбудованих систем у громадському транспорті;
- аналіз змінних умов. Умови, в яких працюють системи трекінгу, можуть змінюватися, і важливо мати алгоритми, які стійкі до цих змін, таких як зміна освітлення, об'єктів в фоні тощо.

Важливим аспектом є також аналіз практичних розробок та впровадження систем трекінгу пасажиропотоку у громадському транспорті. Приклади вже функціонуючих систем та їх ефективність можуть бути корисними для порівняння та валідації дослідження.

«Study on Subway passenger flow prediction based on deep recurrent neural network» [12]. Це дослідження фокусується на прогнозуванні пасажиропотоку в метро, висвітлюючи складнощі через комплексну структуру системи маршрутів та різноманітність подорожі пасажирів.

«Review of Automatic Passenger Counting Systems in Public Urban Transport» [13]. Це дослідження розглядає роль глибокого навчання в системах громадського транспорту на замовлення, зокрема в автобусному транспорті, та її вплив на зменшення заторів, викидів і використання приватних транспортних засобів.

Ці та інші наукові роботи створюють фундамент для розробки нових, більш точних та ефективних алгоритмів для систем відстеження пасажиропотоку, відкриваючи широкі перспективи для покращення управління громадським транспортом і підвищення безпеки пасажирів.

На основі глибокого аналізу наукової літератури та результатів експериментальних досліджень можна зробити ряд теоретичних висновків, які мають вирішальне значення для розвитку алгоритмів трекінгу пасажиропотоку з використанням нейронних мереж [14]. Сучасні технології комп’ютерного зору та машинного навчання демонструють значний потенціал у точному та ефективному відстеженні та аналізі динаміки пасажиропотоків, що є ключовим для підвищення безпеки та ефективності громадського транспорту.

Оцінки і висновки, отримані в ході дослідження, підтверджують, що використання згорткових нейронних мереж (CNN) та рекурентних нейронних мереж (RNN) може істотно покращити якість визначення патернів руху пасажирів та прогнозування їх потоків. Алгоритми, засновані на глибокому навчанні, здатні виявляти складні взаємозв'язки в даних, що традиційні методи можуть пропустити. Також вони показують кращу адаптивність до змінних умов, які часто зустрічаються в реальних сценаріях громадського транспорту.

Проте слід зазначити, що існує потреба в подальшій оптимізації цих алгоритмів, особливо в плані підвищення їх ефективності та скорочення часу обробки даних для можливості їх використання в режимі реального часу. Також важливим аспектом є розробка методів, які можуть ефективно працювати з обмеженими наборами даних або в умовах, де зібрани дані не повністю марковані.

На підставі проведеного аналізу, запропоновано ряд напрямків для подальших досліджень. Серед них:

- розробка гібридних моделей, що інтегрують переваги класичних методів обробки зображень із здатністю до глибокого навчання для підвищення точності та надійності трекінгу;
- використання технологій трансферного навчання для покращення результатів трекінгу без необхідності збору величезних наборів даних;
- експериментування з новими архітектурами нейронних мереж, зокрема генеративно-змагальними мережами (GAN), для вирішення специфічних задач трекінгу пасажиропотоку;
- розробка ефективних стратегій для збалансування між точністю та швидкістю трекінгу, щоб забезпечити можливість їх застосування в реальному часу.

Розглядаючи перспективи досліджень і розвитку в області відстеження пасажиропотоку з використанням комп’ютерного зору, слід враховувати великий потенціал для подальшого розвитку і впровадження інтелектуальних систем у сфері громадського транспорту.

Перш за все, швидкий розвиток технологій у сфері комп’ютерного зору, глибокого навчання і нейронних мереж відкриває безліч нових можливостей для розвитку систем відстеження пасажиропотоку. Використання передових алгоритмів та технологій дозволяє створити точні та ефективні системи трекінгу, які можуть працювати в реальному часі і адаптуватися до різних умов.

Дослідження в області алгоритмів комп’ютерного зору відкриває можливість для подальшого удосконалення методів виявлення та відстеження об’єктів на відеозаписах. Розвиток алгоритмів, які працюють навіть у складних умовах, таких як низьке освітлення або швидка зміна об’єктів в кадрі, є важливим напрямком досліджень.

Особливу увагу слід приділяти аналізу великих обсягів даних. Збільшення кількості відеоданих і їх обробка стають все більш важливими завданнями. Розробка методик анотування даних та вдосконалення підходів до аналізу дозволить отримати більш точні результати і розвинути область.

Також важливо враховувати можливість застосування вбудованих систем для громадського транспорту, де обмежені обчислювальні ресурси ставлять виклик для оптимізації алгоритмів та розробки легких, але ефективних систем [15].

Враховуючи швидкий розвиток технологій, переконаний, що вказані напрями досліджень допоможуть досягти значного прогресу в області відстеження пасажиропотоку і стануть основою для створення нового покоління інтелектуальних систем громадського транспорту. З використанням передових методів комп’ютерного зору та нейронних мереж, ми можемо покращити безпеку та ефективність громадського транспорту, забезпечити комфорт та задоволеність пасажирів, а також відкрити нові можливості для подальшого розвитку цієї галузі.

РОЗДІЛ 2

АНАЛІЗ МЕТОДІВ ВІДСТЕЖЕННЯ ПАСАЖИРОПОТОКУ В ГРОМАДСЬКОМУ ТРАНСПОРТІ

2.1 Аналіз існуючих методів трекінга в громадському транспорті

З появою перших систем відеонагляду, які базувалися на простих детекторах руху, відкрилися нові можливості для моніторингу і безпеки громадських просторів, включаючи транспортні засоби [16]. Початкові системи були досить примітивними і використовували зміну інтенсивності пікселів між кадрами для визначення руху. Це було здійснено через порогову обробку, де значення пікселя було визначено як «рухливе», якщо різниця між послідовними кадрами перевищувала заданий поріг.

Ці ранні системи, хоча і були революційними для свого часу, стикалися з великими обмеженнями. Однією з основних проблем була їх нездатність до розрізnenня рухомих об'єктів в умовах низької візуальної контрастності або коли об'єкти переміщалися повільно. Це було особливо проблематично в громадському транспорті, де висока щільність пасажирів і різноманітність руху створювали складні умови для трекінгу.

З розвитком технологій, системи відеонагляду почали використовувати більш складні методи для визначення руху, такі як аналіз текстур та розрізnenня патернів. Це дозволило вдосконалити здатність систем до ідентифікації об'єктів, навіть коли вони частково перекриті або в русі. Такі методи як фонове віднімання стали популярними, оскільки вони дозволяли відокремлювати рухомі об'єкти від статичного фона, навіть у складних умовах освітлення та руху.

Подальший прогрес в області комп'ютерного зору привів до впровадження машинного навчання та штучного інтелекту у системи відеонагляду. Алгоритми, засновані на штучних нейронних мережах, почали використовуватися для автоматичного виявлення і класифікації об'єктів на

відео, що забезпечило значно більшу точність і гнучкість в порівнянні з традиційними методами. Нейронні мережі могли навчатися на великих наборах даних та адаптуватися до нових умов, що робило їх ідеальними для застосування в громадському транспорті, де сцени постійно змінюються [17].

Такі інновації дозволили створення інтелектуальних систем відеонагляду, здатних аналізувати поведінку та траєкторії руху пасажирів, оптимізувати потоки людей та забезпечити вищий рівень безпеки і сервісу. Сучасні системи можуть автоматично виявляти незвичайні поведінкові патерни, такі як біг або агресивні рухи, що можуть вказувати на потенційні загрози або надзвичайні ситуації.

З урахуванням швидкого розвитку технологій, в майбутньому можна очікувати ще більших досягнень у цій області. Вже сьогодні ведуться розробки систем трекінгу, що включають розширену реальність та інші новітні технології, які обіцяють перевести можливості відеонагляду на новий рівень.

Розвиток алгоритмів трекінга і відеонагляду є свідченням еволюції в області комп’ютерного зору та обробки зображень. З ранніх методів, які покладалися на прості порогові операції, до сучасних алгоритмів, заснованих на глибокому навчанні, кожен етап розвитку приносив покращення в точності та надійності систем відстеження.

Фільтр Калмана став одним із перших і найбільш впливових інструментів в цьому напрямку. Це було величезним кроком вперед для систем, де потрібна була висока точність і надійність, особливо в динамічних умовах громадського транспорту. Він дозволив аналізувати часові послідовності даних та прогнозувати майбутні стани системи на основі неповних або зашумлених вимірювань, як це видно з рисунку 2.1

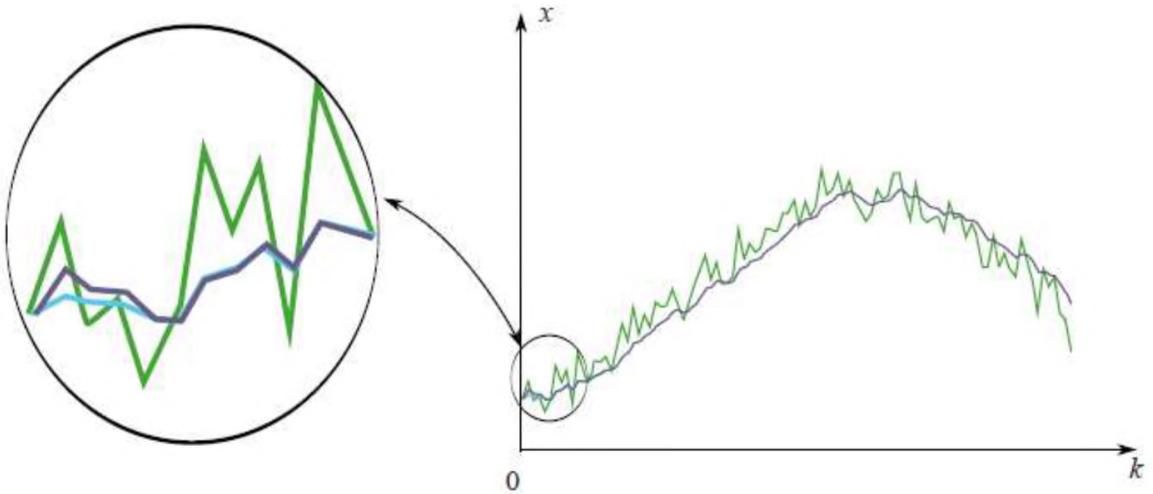


Рисунок 2.1 – Приклад фільтрації по Калману

Mean-Shift і Cam-Shift алгоритми принесли концепцію не параметричного пошуку щільності ймовірності, яка дозволяла алгоритмам трекінгу «слідувати» за об’єктом за його характеристиками яскравості [18]. Ці методи показали, що системи можуть бути більш гнучкими та адаптивними, здатними відстежувати об’єкти навіть у випадку, коли їх форма чи зовнішній вигляд змінюються. Приклад роботи алгоритма трекінгу Mean-Shift представлено на рисунку 2.2

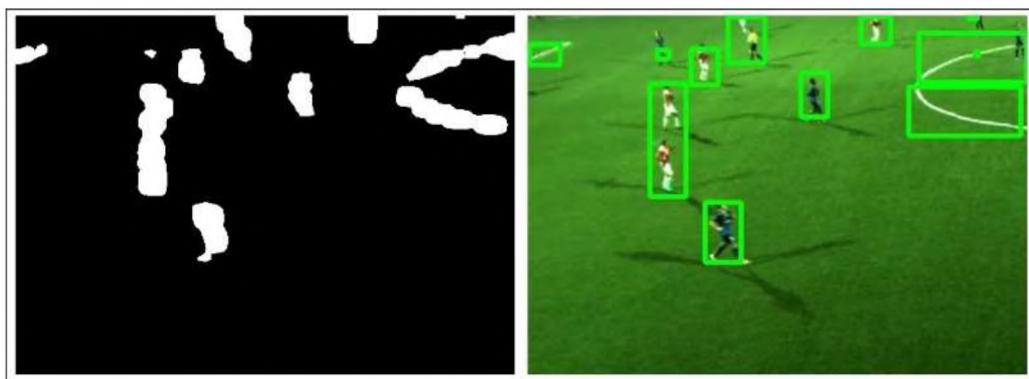


Рисунок 2.2 – Приклад роботи алгоритма трекінгу Mean-Shift

Оптичний потік вніс значний внесок у здатність систем візуалізації працювати з високою точністю в режимі реального часу. Аналіз змін пікселів між кадрами дав можливість системам відстеження визначати не тільки

наявність руху, але й його напрямок та швидкість, що є критично важливим для контролю за пасажиропотоками.

Останнім і, можливо, найбільш значним проривом у сфері трекінга стало використання глибинних нейронних мереж. Їх здатність до самонавчання, розпізнавання та класифікації складних образів зробила їх ідеальними для застосування в системах відеонагляду. Нейронні мережі змогли вирішити багато викликів, з якими не могли впоратися традиційні методи, надаючи системам можливість розпізнавати об'єкти в найбільш складних і непередбачуваних сценах.

З введенням алгоритмів на основі штучного інтелекту, системи відеонагляду тепер можуть виконувати завдання, які раніше вимагали людського втручання, такі як ідентифікація особистостей або аналіз поведінки пасажирів. Ці системи не тільки підвищують рівень безпеки, але й оптимізують роботу транспортних засобів, вносячи значний вклад у покращення обслуговування пасажирів.

Визначення ефективності алгоритмів трекінга є ключовим аспектом при впровадженні систем відеонагляду в громадському транспорті. Ефективність може бути оцінена за допомогою комплексного аналізу метрик, які відображають якість та швидкість роботи системи під час відстеження пасажиропотоку.

Точність трекінга є фундаментальною метрикою, яка вимірює спроможність системи відстежувати рух об'єктів з високою вірогідністю. Це включає в себе правильне визначення траєкторії об'єкта, а також його ідентифікацію серед інших об'єктів у кадрі. В громадському транспорті, де пасажири часто рухаються групами або перетинають траєкторії один одного, висока точність трекінга є вирішальною для забезпечення надійності системи.

Швидкість обробки даних має вирішальне значення в динамічному середовищі громадського транспорту. Системи відеонагляду повинні оперативно обробляти вхідний потік даних для забезпечення миттєвого реагування на зміни у пасажиропотоці. Алгоритми з високою швидкістю

обробки забезпечують, що відеоаналітика ведеться в реальному часі, що дозволяє оперативно приймати управлінські рішення.

Стабільність при перешкодах вказує на спроможність алгоритмів зберігати консистентність трекінгу незважаючи на зовнішні перешкоди, такі як зміна освітлення, візуальні блоки від інших об'єктів, або раптові рухи камери. Стабільність системи забезпечує, що відстеження не переривається та даний об'єкт не «втрачається», навіть якщо він тимчасово виходить із поля зору камери [19].

Здатність до масштабування є критично важливою для міських транспортних систем, де потрібно відстежувати велику кількість пасажирів одночасно. Алгоритми трекінга мають бути здатні масштабуватися без втрати продуктивності при збільшенні кількості об'єктів для аналізу або коли система розширюється на більшу кількість камер.

Для оцінки наведених вище метрик, можуть застосовуватися стандартні набори даних та бенчмарки, такі як MOTChallenge або VOT, що містять велику кількість анотованих відео з різноманітними сценами громадського транспорту. Також використовуються спеціалізовані інструменти для вимірювання продуктивності, як, F1-середнє, а також метрики, які враховують точність просторового та часового трекінгу.

Для візуалізації даних можна створити наступні типи графіків та візуальних елементів, які допоможуть ілюструвати ключові аспекти аналізу:

- F1-середнє дозволяє швидко порівняти різні алгоритми за їх здатністю одночасно забезпечувати високу точність та повноту. Стовпчаста діаграма з умовними F1-середніми для кількох алгоритмів трекінгу представлена на рисунку 2.3

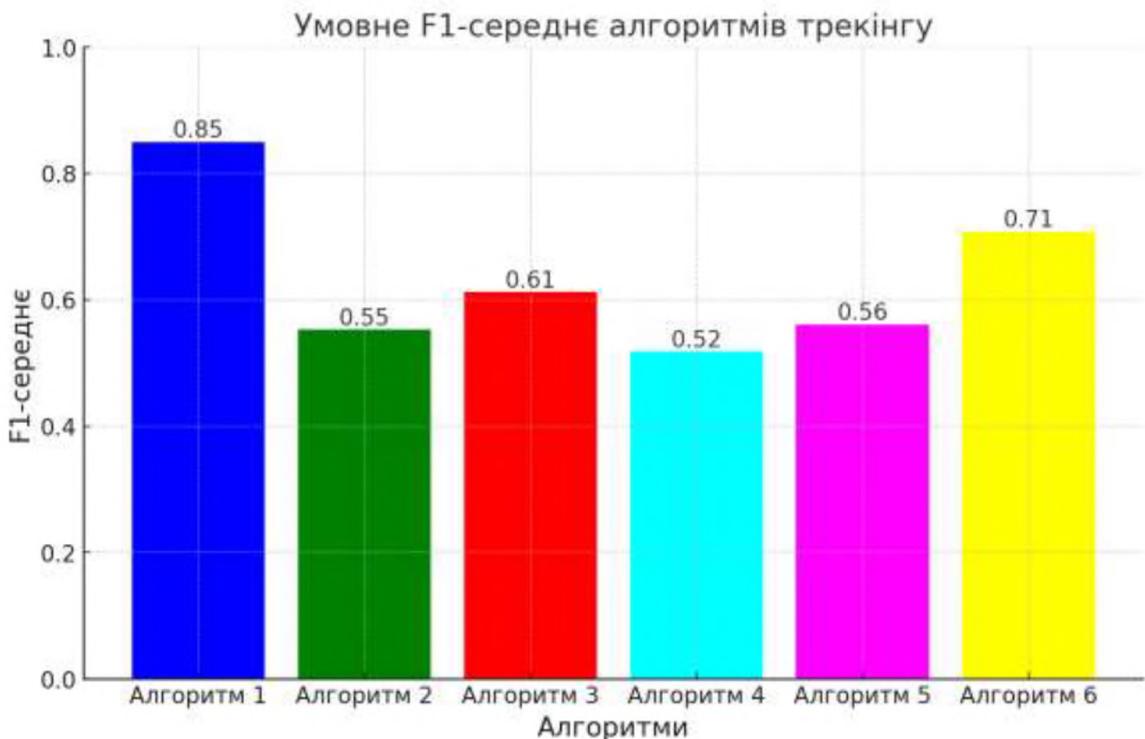


Рисунок 2.3 – Діаграма з умовними F1-середніми для кількох алгоритмів трекінгу

Дані є умовними та не відображають реальні результати, але такий графік може буде використаний для ілюстрації порівняння ефективності різних алгоритмів.

Кожен стовпець представляє умовний алгоритм, а висота стовпця показує його F1-середнє;

– стовпчаста діаграма, яка демонструє умовну продуктивність (вимірюну у середньому FPS) для різних алгоритмів трекінгу представлена на рисунку 2.4

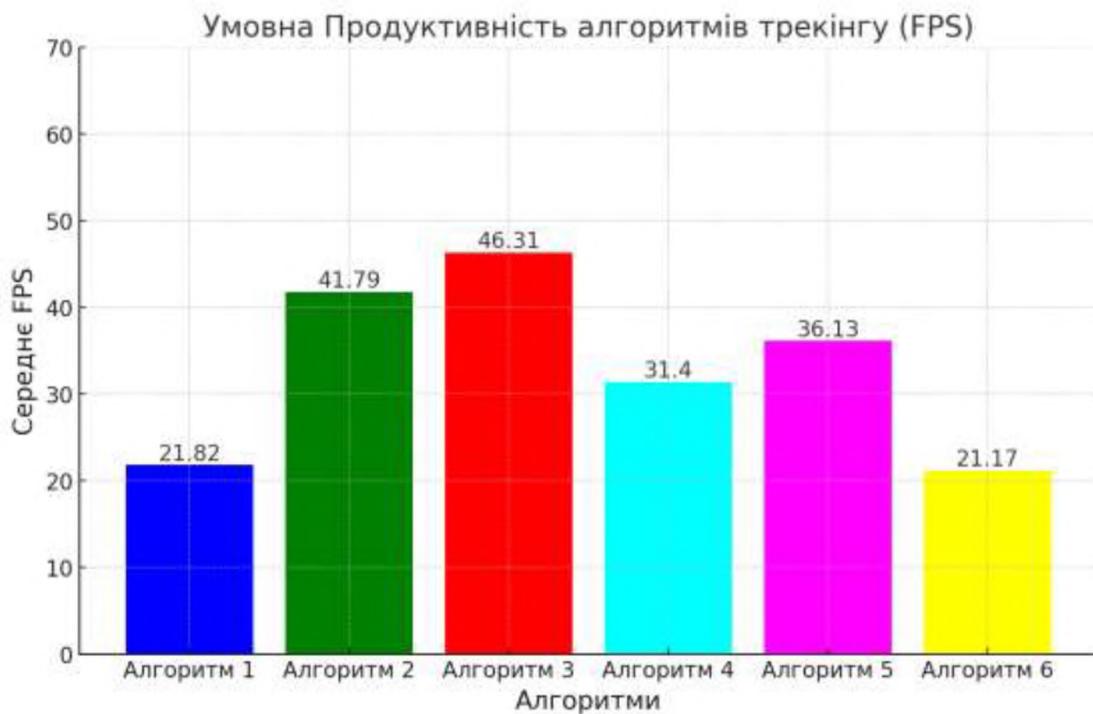


Рисунок 2.4 – Діаграма з умовою продуктивністю кількох алгоритмів трекінгу

На цьому графіку висота кожного стовпця показує середню кількість кадрів за секунду, яку може обробити кожен алгоритм.

Цей тип візуалізації корисний для демонстрації, наскільки швидко кожен алгоритм може обробляти відеодані, що є важливим аспектом при виборі алгоритму для реальних застосувань, особливо в сценаріях, де необхідна висока швидкість обробки, таких як моніторинг пасажиропотоку в громадському транспорті.

Комплексний аналіз ефективності алгоритмів трекінга є важливим для вибору та оптимізації систем відеонагляду в громадському транспорті. Через ретельну оцінку можливо ідентифікувати ті алгоритми, які найкраще задовольняють специфічні вимоги до безпеки, точності та ефективності.

Обчислювальні технології та методи машинного навчання розвиваються стрімкими темпами, пропонуючи все новіші можливості для поліпшення систем відеоспостереження. Глибоке навчання, особливо, виокремлюється як

потужний інструмент для аналізу візуальних даних, що може докорінно змінити підходи до трекінгу пасажиропотоку в громадському транспорті.

Сучасні алгоритми трекінга все частіше інтегрують глибокі нейронні мережі, які здатні ефективно впоратися з розпізнаванням та класифікацією об'єктів на зображеннях великої складності. Застосування конволюційних нейронних мереж (CNN) дозволяє системам відеонагляду точніше визначати локації пасажирів та їхні траєкторії, навіть у умовах поганої видимості або перекриття об'єктів.

Одним із найбільших викликів у трекінгу є здатність системи адаптуватися до постійно змінюваних умов середовища. Розвиток технологій самонавчання, зокрема з використанням механізмів зміщеного навчання та навчання без учителя, може дозволити системам трекінга самостійно оптимізувати свою поведінку, що значно підвищить їх ефективність та надійність.

Інтеграція систем трекінга з іншими технологіями, як системами управління транспортними потоками, системами геолокації та мобільними додатками, може відкрити нові шляхи для створення комплексних рішень, які забезпечать більш ефективне управління пасажиропотоками та підвищення рівня безпеки у громадському транспорті.

З огляду на необхідність мінімізації енергоспоживання, особливу увагу слід приділити розробці енергоефективних алгоритмів трекінга, які б могли працювати на портативних пристроях і вбудованих системах [20]. Це дозволить розширити область застосування систем відеоспостереження, зробивши їх доступними навіть для транспортних засобів з обмеженими обчислювальними та енергетичними ресурсами.

Майбутні дослідження мають зосередитися не тільки на підвищенні точності розпізнавання об'єктів, але й на здатності систем розуміти контекст, в якому відбуваються ті чи інші події. Розробка алгоритмів, здатних аналізувати поведінку пасажирів та прогнозувати потенційні небезпечні

ситуації, може внести значний вклад у підвищення безпеки та комфорту під час поїздок.

З урахуванням вищезазначеного, перспективи розвитку систем трекінга в громадському транспорті є надзвичайно захоплюючими та багатообіцяючими, і їх впровадження має великий потенціал для поліпшення ефективності та безпеки пасажирських перевезень.

2.2 Критичний аналіз методів та їх ефективності

Використання нейронних мереж для відстеження пасажиропотоку в громадському транспорті є важливим напрямком досліджень у сучасному світі [21]. Ця гіпотеза виникла від необхідності вирішення актуальних проблем управління та контролю пасажиропотоком в містах і на транспорті. З введенням нейронних мереж у дану сферу можна очікувати значного покращення якості та ефективності систем контролю пасажиропотоку.

По-перше, використання нейронних мереж дозволяє отримувати більш точну та деталізовану інформацію про пасажирів та їхній рух. Традиційні методи відстеження можуть бути обмежені у розпізнаванні об'єктів або у здатності працювати в умовах обмеженого освітлення. Нейронні мережі здатні адаптуватися до різних умов і навчатися розпізнавати об'єкти на відеозображеннях з високою точністю.

По-друге, перевагою використання нейронних мереж є їхній успіх у схожих завданнях у галузі комп'ютерного зору та машинного навчання. Моделі глибокого навчання, такі як згорткові нейронні мережі, здатні до складних обчислень та аналізу великої кількості даних. Це дозволяє їм відстежувати пасажирів з високою швидкістю та точністю.

По-третє, використання нейронних мереж може допомогти зменшити залежність від традиційних методів відстеження, які можуть бути менш адаптивними до змінних умов та потреб. Це означає, що системи відстеження,

які базуються на нейронних мережах, можуть бути більш гнучкими та ефективними у різних ситуаціях та середовищах.

Отже, гіпотеза про використання нейронних мереж для відстеження пасажиропотоку має обґрунтовану підставу та відкриває широкі можливості для покращення систем контролю пасажиропотоку в громадському транспорті. Далі дослідження та аналіз методів будуть спрямовані на перевірку цієї гіпотези та визначення її практичної застосовності у реальних умовах.

Критичний аналіз різних поглядів на використання нейронних мереж для відстеження пасажиропотоку в громадському транспорті є важливим етапом дослідження. Дано тема викликає значний інтерес через потенційні переваги та виклики, які можуть виникнути при впровадженні таких систем.

Однією з головних переваг використання нейронних мереж є покращена точність відстеження пасажирів. Моделі глибокого навчання можуть бути навчені розпізнавати пасажирів на зображеннях з високою точністю. Це дозволяє отримувати більш достовірну інформацію про кількість пасажирів та їхній рух у транспортних засобах. Висока точність є важливою для забезпечення надійності системи контролю пасажиропотоку та визначення ефективності громадського транспорту.

Ще однією перевагою є здатність нейронних мереж розпізнавати об'єкти у різних умовах освітлення та складних сценаріях. Традиційні методи відстеження пасажирів можуть бути вразливими до змін у середовищі, таким як низьке освітлення або переповненість транспортного засобу. Нейронні мережі можуть навчатися адаптуватися до різних умов, що робить їх більш універсальними.

Проте існують і недоліки використання нейронних мереж для відстеження пасажиропотоку. По-перше, реалізація таких систем може бути витратною в плані обладнання та обчислювальних ресурсів. Нейронні мережі вимагають значної обчислювальної потужності для навчання та інференсу, що може становити виклик для бюджету проекту [22].

Крім того, існують питання щодо приватності та безпеки даних, зібраних за допомогою систем відстеження на основі нейронних мереж. Збір і зберігання зображень пасажирів може викликати обурення з точки зору приватності та безпеки даних, і потребує дотримання високих стандартів захисту даних.

Критичний аналіз різних поглядів на використання нейронних мереж для відстеження пасажиропотоку вказує на потенційні переваги та виклики. Необхідно балансувати високу точність та потреби в обчислювальних ресурсах, а також забезпечити захист приватності та безпеку даних для успішної імплементації таких систем у громадському транспорті.

Наукова класифікація питань та аспектів, пов'язаних з використанням нейронних мереж для відстеження пасажиропотоку, є важливою складовою для розуміння глибоких аспектів цієї проблематики [23]. Вона дозволяє систематизувати та дослідити різні аспекти, які впливають на використання нейронних мереж у системах контролю пасажиропотоку. Нижче представлено декілька ключових категорій для наукової класифікації цих питань:

- технічні аспекти нейронних мереж. Сюди включаються питання, пов'язані з технічними аспектами використання нейронних мереж для відстеження пасажиропотоку. Це може включати в себе архітектуру нейронних мереж, методи навчання, використання попередньо навчених моделей тощо. Дослідження в цій категорії допомагають зрозуміти, як покращити технічну реалізацію систем відстеження;
- приватність та безпека даних. Один з ключових аспектів, пов'язаних з використанням нейронних мереж для відстеження пасажиропотоку, - це захист приватності та безпеки зібраних даних. Дослідження в цій області спрямовані на розробку методів захисту конфіденційності та запобігання можливим загрозам безпеці;
- ефективність та продуктивність. Іншою важливою категорією є дослідження, спрямовані на покращення ефективності та продуктивності систем відстеження пасажиропотоку на основі нейронних мереж. Це може

включати в себе оптимізацію алгоритмів, використання апаратного прискорення та інші технологічні підходи;

- практичні аспекти впровадження. Ця категорія охоплює питання, пов’язані з реальним впровадженням систем відстеження пасажиропотоку на основі нейронних мереж у громадському транспорті. Це може включати в себе вибір обладнання, інтеграцію з існуючими системами, вартість впровадження та інші практичні аспекти;

- соціальні та етичні питання. Використання нейронних мереж для відстеження пасажиропотоку також породжує соціальні та етичні питання, пов’язані з приватністю пасажирів та можливими впливами на суспільство. Дослідження в цій області допомагають розробити стандарти та політики для забезпечення справедливого та етичного використання таких систем.

Аналіз ефективності методів відстеження пасажиропотоку на основі нейронних мереж є ключовим етапом для визначення переваг та обмежень таких систем. Цей аналіз вимагає збору та обробки великої кількості даних, а також детальної оцінки різних аспектів продуктивності та точності. Нижче представлено деякі аспекти, які варто враховувати під час аналізу ефективності методів відстеження пасажиропотоку на основі нейронних мереж:

- точність відстеження. Однією з ключових метрик ефективності є точність відстеження пасажирів. Ця метрика вимірює, наскільки точно система може визначити наявність та рух пасажирів у транспортних засобах. Важливо враховувати, що низька точність може призвести до неточних даних та недооцінки пасажиропотоку;

- продуктивність. Продуктивність системи також грає важливу роль, оскільки швидкість обробки даних впливає на здатність системи відстеження працювати в реальному часі. Важливо аналізувати час обробки кадрів, завантаження обчислювальних ресурсів та швидкість реакції системи на зміни у відеопотоці;

- здатність до адаптації. Системи відстеження повинні бути здатні адаптуватися до різних умов освітлення, погодних умов та складних сценаріїв. Аналізуючи ефективність, важливо визначити, наскільки система може працювати у різних ситуаціях та які адаптаційні стратегії вона використовує;
- витрати ресурсів. Однією з обмежуючих факторів є витрати обчислювальних ресурсів та енергії. Аналізуючи ефективність, слід оцінювати, як ефективно система використовує ресурси та чи можливо зменшити ці витрати;
- масштабованість. Для реалізації систем великих розмірів важливо аналізувати, наскільки легко можна масштабувати систему для використання в різних громадських транспортних мережах та на різних масштабах;
- стійкість до спотворень і шуму. Нейронні мережі повинні бути стійкими до спотворень та шуму в відеопотоці. Аналізуючи ефективність, важливо враховувати, наскільки добре система може працювати в умовах обмеження доступності даних;
- робочий час та завантаження. Важливо визначити, наскільки система може працювати без збоїв та як вона веде себе при тривалому робочому часі та під великим завантаженням.

Аналізуючи ці аспекти ефективності, можна прийти до висновків щодо придатності систем відстеження пасажиропотоку на основі нейронних мереж для конкретного застосування та розробити рекомендації для подальшого вдосконалення таких систем.

Аналіз ефективності різних алгоритмів відстеження пасажиропотоку, доступних в OpenCV, грає важливу роль у визначенні найбільш підходящого методу для конкретної системи контролю пасажиропотоку [24]. Нижче подано докладний аналіз різних алгоритмів та їх ефективності:

- MOG2 (Mixture of Gaussians 2). Цей алгоритм є популярним методом для відокремлення переднього плану від тла. Він добре працює у відносно статичних умовах, де освітлення майже не змінюється. Проте, він може бути менш ефективним у складних умовах зі значними змінами освітлення;

- KNN (K-Nearest Neighbors). Алгоритм KNN є іншою популярною опцією. Він дозволяє враховувати динамічні зміни в сцені, але він може бути вразливим до шуму та має потенційно велику витрату обчислювальних ресурсів;
- CNT (Counting-based Background Subtractor). Цей алгоритм використовує підрахунок пікселів переднього плану та тла для визначення об'єктів. Він може бути ефективним у вимірюванні пасажиропотоку, але може вимагати налаштувань для різних умов
- GMG (Graph-cuts for Moving Object Detection). GMG використовує графові методи для виділення об'єктів переднього плану. Цей алгоритм може бути досить ефективним, але вимагає більше обчислювальних ресурсів порівняно з деякими іншими методами;
- GSOC (Global Self-Organizing Cluster-based Subtraction). Алгоритм GSOC базується на кластеризації пікселів. Він може бути ефективним у визначенні рухливих об'єктів, але також може бути вимогливим до ресурсів;
- LSBP (Local SVD Binary Pattern). Цей алгоритм використовує локальні бінарні шаблони для виділення переднього плану. Він може бути швидким та відносно точним, але його ефективність може залежати від налаштувань та умов сцени;
- K-Means - це алгоритм кластеризації, який може використовуватися для виділення об'єктів переднього плану шляхом групування пікселів за подібністю кольору або інших ознак. Він може бути ефективним у випадках, коли об'єкти переднього плану мають яскраві кольори або текстури;
- GMM (Gaussian Mixture Model) - це модель, яка розглядає пікселі як суму гауссівських розподілів. Цей метод може бути ефективним у визначенні рухливих об'єктів, особливо у складних умовах освітлення;
- VIBE (Visual Background Extractor). Алгоритм VIBE базується на моделі видозмінного середовища та може використовуватися для відокремлення переднього плану від тла. Його відмінність полягає в тому, що він може працювати на реальному часі та бути стійким до змін освітлення.

Порівнюючи ці алгоритми, слід враховувати особливості конкретної системи контролю пасажиропотоку, такі як умови освітлення, рух транспортних засобів та потребу в реальному часі. Важливо також звертати увагу на витрати обчислювальних та інших ресурсів при виборі методу для практичного впровадження [25].

Обрані алгоритми для аналізу є досить репрезентативними та різноманітними у своєму складі, оскільки вони представляють різні підходи до відстеження пасажиропотоку в громадському транспорті. Також вони є частиною бібліотеки OpenCV, яка є однією з найпопулярніших та добре підтримуваних бібліотек у галузі комп’ютерного зору. Алгоритми легко доступні для використання та мають документацію, що полегшує їхнє впровадження та налаштування.

У контексті дослідження, спрямованого на аналіз алгоритмів відстеження пасажиропотоку, важливо зосередитись на методах, які найбільш ефективні та адекватні поставленим задачам. Хоча такі популярні алгоритми, як K-Means, GMM (Gaussian Mixture Model) та VIBE (Visual Background Extractor), мають свої переваги, їх виключення з дослідження потребує обґрунтування.

K-Means є алгоритмом кластеризації, що часто використовується для задач сегментації та групування даних, а не для відстеження об’єктів чи виділення фону. У контексті відстеження об’єктів або виділення фону K-Means може бути менш ефективним через його чутливість до викидів та неспроможність адаптуватися до динамічно змінюваних умов сцени.

GMM (Gaussian Mixture Model) зазвичай застосовується для моделювання розподілу даних та виявлення структур у даних. Він може бути використаний у алгоритмах виділення фону, але має свої обмеження. На відміну від спеціалізованих алгоритмів для відстеження чи виділення фону, GMM може бути менш ефективним у умовах змінного освітлення, динамічних сцен та при наявності шуму в зображенні.

VIBE (Visual Background Extractor) – це алгоритм для виділення фону, який використовує випадкові зразки та здатний адаптуватися до змін у сцені.

Обмеження: VIBE може бути виключений з дослідження, якщо він не забезпечує достатньої точності в конкретних умовах експерименту, або якщо він менш ефективний порівняно з іншими алгоритмами при обробці певних типів рухів чи змін у сцені.

Деякі алгоритми, такі як MOG2 та KNN, відомі своєю ефективністю та відносною легкістю використання та налаштування. Це важливо для практичного застосування у системах контролю пасажиропотоку [26].

Обрані алгоритми мають параметри, які можна налаштовувати, що дозволяє налаштувати їх під конкретні умови та завдання в громадському транспорті.

Після ретельного аналізу різних методів відстеження пасажиропотоку на основі нейронних мереж та їхньої ефективності, виокремлено кілька ключових висновків, які роблять цю тему особливо актуальною та обґрунтують вибір обраних методів.

По-перше, варто відзначити, що застосування нейронних мереж у відстеженні пасажиропотоку має великий потенціал для покращення систем контролю пасажиропотоку в громадському транспорті. За допомогою нейронних мереж можна досягти високої точності та надійності відстеження, що важливо для отримання точної інформації про кількість пасажирів, їхній рух та розподіл у транспортних засобах.

Слід також враховувати, що доступність нейронних мереж та їхній успіх у вирішенні схожих завдань в області комп’ютерного зору та машинного навчання роблять їх дуже привабливими для використання в системах контролю пасажиропотоку [27]. Це означає, що в майбутньому цей підхід може стати стандартом у галузі.

Різноманітність обраних методів також підкреслює важливість вибору конкретного методу в залежності від конкретних завдань та умов використання. Наприклад, алгоритми MOG2, KNN, CNT можуть бути

корисними в ситуаціях, коли важлива продуктивність та точність відстеження. У той же час, алгоритм GSOC може добре працювати у складних сценаріях зі змінною освітленістю.

Налаштування параметрів кожного методу є важливою частиною роботи з ним, і варто вкласти час і зусилля у визначення оптимальних параметрів для конкретних умов використання [28].

Також важливо враховувати, що в деяких випадках може знадобитися попереднє навчання моделей на конкретних даних для досягнення найкращих результатів.

Важливими критеріями вибору є точність, швидкість обробки, адаптивність до умов освітлення та динаміки сцени. Методи MOG2, CNT, GMG та GSOC були вибрані як оптимальні для вирішення цих завдань, враховуючи їхню здатність ефективно працювати в різноманітних умовах, що є характерним для громадського транспорту. З іншого боку, методи, такі як K-Means, GMM і VIBE, були виключені через їхню меншу ефективність у контексті даного дослідження. Таким чином, даний аналіз дозволяє зробити обґрунтований вибір алгоритму для оптимізації процесу відстеження пасажиропотоку, відповідаючи вимогам точності та продуктивності.

Загалом, аналіз методів відстеження пасажиропотоку на основі нейронних мереж вказує на перспективність цього напряму досліджень і можливість його успішного впровадження у системи контролю пасажиропотоку в громадському транспорті з метою покращення якості та ефективності цих систем.

РОЗДІЛ 3. АЛГОРИТМІЗАЦІЯ ТА ОЦІНКА ПРОДУКТИВНОСТІ НЕЙРОННИХ МЕРЕЖ ДЛЯ ВІДСТЕЖЕННЯ ПАСАЖИРОПОТОКУ В ГРОМАДСЬКОМУ ТРАНСПОРТІ

3.1 Порівняльний аналіз алгоритмів трекінга з використанням нейронних мереж

Однією з ключових переваг глибокого навчання є його здатність до використання передбачуваних функцій або ознак, які дозволяють точно виділяти та розрізняти об'єкти на зображеннях [29]. Використовуючи глибоке навчання, можливо створити моделі, які автоматично навчаються розпізнавати об'єкти та їхні характеристики з тренувальних даних. Це спрощує процес трекінгу та робить його більш точним та надійним.

Згорткові нейронні мережі дозволяють здійснювати аналіз об'єктів на рівні їх структурних ознак, таких як форма, розмір, текстура тощо. Це дає можливість отримувати більш докладну інформацію про об'єкти, яка може бути використана для трекінгу та класифікації.

Окрім покращення точності, глибоке навчання також може вплинути на швидкість трекінгу. Моделі, навчені з використанням глибокого навчання, можуть бути оптимізовані для роботи в реальному часі, забезпечуючи високу швидкість обробки відеоданих та відстеження об'єктів у режимі реального часу [30].

Одним із методів оцінки є аналіз точності виявлення та трекінгу об'єктів. Для цього використовуються метрики, такі як точність виявлення (Detection Accuracy) і точність трекінгу (Tracking Accuracy). Точність виявлення визначає, наскільки ефективно нейронна мережа може виявляти об'єкти на відеозображеннях, тоді як точність трекінгу показує, наскільки добре вона може слідкувати за рухом об'єктів та підтримувати їхню ідентифікацію в часі. Оцінка цих метрик дозволяє визначити, наскільки надійно та точно працює нейронна мережа в завданні трекінгу пасажиропотоку.

Ще одним методом оцінки є вимірювання швидкості роботи алгоритмів трекінгу. Визначення швидкості роботи є критично важливим для застосувань в реальному часі, таких як системи відстеження в громадському транспорті. Ми проведемо детальний аналіз продуктивності нейронних мереж, вимірюючи час, необхідний для виявлення та трекінгу об'єктів на відеозображеннях. Ця інформація дозволить зробити висновки про те, чи можуть нейронні мережі працювати в реальному часі та як вони порівнюються з традиційними методами.

Крім того, ми проведемо порівняльний аналіз між нейронними мережами та традиційними методами трекінгу, такими як алгоритми на основі комп'ютерного зору та обробки зображень. Цей аналіз допоможе визначити переваги та недоліки кожного підходу і визначити, в яких випадках нейронні мережі є більш відповідними для вирішення конкретної задачі трекінгу пасажиропотоку.

Перш за все, нейронні мережі володіють високою точністю та надійністю виявлення об'єктів на відеозображеннях [31]. Їхні алгоритми, навчені на великих обсягах даних, можуть ефективно впізнавати пасажирів та інші об'єкти навіть в умовах обмеженого освітлення, різких кутів огляду та інших складних умов.

Крім того, нейронні мережі можуть бути гнучкими у налаштуванні та підлаштуванні до конкретної задачі трекінгу. Вони можуть бути навчені розпізнавати конкретних пасажирів або інші важливі об'єкти, що дозволяє підвищити точність та придатність системи для конкретних потреб.

Глибоке навчання та згорткові нейронні мережі, використовуючи власні архітектури та алгоритми, можуть покращити швидкість обробки відеоданих та зменшити обчислювальну складність завдяки паралельним обчислениям.

Ще однією важливою перевагою є можливість використання нейронних мереж у реальному часі [32]. Завдяки високій швидкості та точності роботи, системи на основі нейронних мереж можуть бути використані для миттєвого моніторингу та реагування на події в громадському транспорті.

У підсумку, використання нейронних мереж у відстеженні пасажиропотоку та аналізі громадського транспорту може покращити ефективність та точність моніторингу, що є критичним для покращення якості обслуговування та безпеки пасажирів. Використання сучасних методів глибокого навчання та нейронних мереж відкриває нові перспективи у цій галузі та сприяє подальшому розвитку технологій в громадському транспорті.

3.2 Методологія дослідження продуктивності нейронних мереж

Дослідження продуктивності нейронних мереж у вирішенні завдань трекінгу об'єктів на відеозображеннях є критично важливим для оцінки ефективності моделей та алгоритмів. Для досягнення цієї мети були визначені та використані конкретні науково обґрунтовані методи оцінки продуктивності, які включають такі ключові критерії:

- частота кадрів (FPS). Цей показник відображає кількість кадрів, які нейронна мережа може обробити за одну секунду. Вищий FPS свідчить про більшу продуктивність моделі та алгоритмів трекінгу, дозволяючи виконувати обчислення в реальному часі;
- точність виявлення. Цей критерій вимірює, наскільки правильно модель може визначити та виділити об'єкти на відео. Він оцінюється порівнянням результатів, отриманих нейронною мережею, з передбаченими та відомими даними;
- процент правильних треків (Tracking Accuracy). Ця метрика вказує на той час, коли модель правильно відстежує рух об'єктів та зберігає стабільні траєкторії. Вона визначає, наскільки успішно модель впоралася з завданням трекінгу.

Усі ці методи оцінки продуктивності були використані під час досліджень та тестування для об'єктивного порівняння різних підходів та

визначення найбільш оптимальних з них для подальшого використання в практичних застосуваннях [33].

Для проведення досліджень та вимірювання продуктивності алгоритмів трекінгу пасажиропотоку був використаний спеціально підготовлений набір відеоданих. Цей набір містить відеозаписи з камер громадського транспорту, зафіковані в різний час та в різних умовах освітлення. Кожен відеозапис містить різну кількість пасажирів, що рухаються в різних напрямках, що дозволяє оцінити продуктивність алгоритмів в різних сценаріях.

Для вимірювання точності і швидкості алгоритмів трекінгу пасажиропотоку розроблено наступні процедури:

- для вимірювання частоти кадрів в кожному відеозаписі була використана вбудована функція бібліотеки OpenCV, яка визначає кількість кадрів, оброблених за одну секунду;
- для вимірювання точності виявлення пасажирів на кожному кадрі були використані позначені даними про розташування пасажирів на відеозаписах. Результати виявлення алгоритмів порівнювалися з цими даними для розрахунку точності;
- для вимірювання процента правильних треків проводилося відстеження руху пасажирів на відеозаписах та порівняння отриманих траєкторій з референсними даними. Процент правильних треків розраховувався як відношення часу, коли трек був відстежений правильно, до загального часу трекінгу.

Всі ці процедури вимірювання виконано для кожного алгоритму трекінгу на кожному відеозаписі з набору даних [34]. Це дозволило отримати об'єктивні результати та порівняти продуктивність різних алгоритмів у різних умовах, сприяючи визначення найбільш ефективних алгоритмів для вирішення завдання трекінгу пасажиропотоку в громадському транспорті.

Експериментальна установка була створена для проведення досліджень у сфері трекінгу пасажиропотоку в громадському транспорті. Основним

завданням установки є аналіз продуктивності різних алгоритмів трекінгу та їх порівняння на основі обраних метрик [35].

Для розробки експериментальної установки та реалізації функціональності, пов'язаної з трекінгом пасажиропотоку, було обрано програмне забезпечення, що включає в себе бібліотеку OpenCV (Open Source Computer Vision Library). OpenCV є відкритою бібліотекою комп'ютерного зору та машинного навчання, яка надає широкий спектр інструментів для обробки відеоданих, включаючи трекінг об'єктів.

Обране програмне забезпечення дозволило налагодити необхідні алгоритми трекінгу, обробки відеоданих, а також вимірювання ключових метрик, необхідних для оцінки продуктивності нейронних мереж.

Для роботи експериментальної установки було використано наступне апаратне забезпечення:

- установка працює на високопродуктивному комп'ютері з достатньою кількістю оперативної пам'яті та потужними графічними процесорами. Це дозволяє виконувати обчислення в реальному часі та обробку великих обсягів відеоданих;
- для зйомки відеоматеріалу використовується веб-камера з можливістю регулювання параметрів зйомки, таких як роздільна здатність та кількість кадрів в секунду;
- для візуалізації результатів трекінгу та керування експериментальною установкою використовується великий монітор з високою роздільною здатністю.

Експериментальна установка на базі обраного програмного забезпечення дозволяє виконувати наступні функції та операції:

- захоплення відеоданих. Установка забезпечує можливість захоплення відеопотоку з використанням веб-камери;
- обробка відеоданих. За допомогою бібліотеки OpenCV відеодані обробляються для вилучення об'єктів пасажиропотоку та визначення їхніх параметрів,

- трекінг об'єктів. Установка реалізує алгоритми трекінгу для відстеження руху пасажирів на відеозаписах,
- вимірювання продуктивності. За допомогою обраного програмного забезпечення вимірюються ключові метрики, такі як частота кадрів (FPS), точність виявлення та процент правильних треків,
- візуалізація результатів. Отримані результати відображаються на моніторі для подальшого аналізу та оцінки продуктивності алгоритмів.

Розроблена експериментальна установка на базі обраного програмного забезпечення має широкий спектр застосувань. Вона може бути використана для дослідження та аналізу продуктивності різних алгоритмів трекінгу пасажиропотоку в громадському транспорті, що має важливе значення для впровадження систем моніторингу та безпеки в громадському транспорті.

Крім того, експериментальна установка може бути використана для навчання та підготовки фахівців у сфері комп'ютерного зору та машинного навчання, а також для досліджень в області розробки нових алгоритмів трекінгу та вдосконалення існуючих методик [36].

Експериментальна установка на базі обраного програмного забезпечення є важливим інструментом для дослідження та аналізу продуктивності алгоритмів трекінгу пасажиропотоку в громадському транспорті. Вона дозволяє проводити об'єктивні вимірювання та оцінку різних алгоритмів, сприяючи подальшому розвитку цієї важливої галузі комп'ютерного зору та машинного навчання. Розробка та використання таких установок важливі для впровадження інноваційних рішень у сфері громадського транспорту та безпеки пасажирів.

3.3 Практична реалізація та оцінювання алгоритмів

OpenCV (Open Source Computer Vision Library) була обрана як основна бібліотека для реалізації алгоритмів трекінгу з численних причин:

- відкритість та безкоштовність. OpenCV є відкритою бібліотекою з вільним доступом, що дозволяє використовувати її у комерційних і наукових проектах без обмежень;
- багатий функціонал. OpenCV надає широкий спектр функцій та алгоритмів для обробки відеоданих, розпізнавання об'єктів, відстеження руху і багато іншого;
- підтримка Python. OpenCV інтегрується з Python, що робить її доступною для широкого кола розробників та дослідників;
- продуктивність. OpenCV оптимізована для виконання обчислень у реальному часі, що важливо для задач трекінгу.

Для реалізації алгоритмів трекінгу пасажиропотоку були виконані наступні основні кроки:

Процес реалізації алгоритмів трекінгу об'єктів пасажиропотоку в громадському транспорті, використовуючи мову програмування Python та бібліотеку OpenCV, розглядається в даному описі крок за кроком:

- імпорт бібліотек та підготовка даних. У першому рядку імпортується необхідні бібліотеки, такі як cv2, sys, та os. Це дозволяє використовувати функціонал OpenCV для обробки відеоданих та роботи з файловою системою;
- створення детектора по імені. Функція `create_detector_by_name(detector_type)` призначена для створення обраного детектора на основі переданого імені `detector_type`. У вашому випадку, ви обираєте між різними алгоритмами відокремлення переднього плану від тла, такими як MOG2, KNN, CNT тощо. Це дозволяє вам легко змінювати детектор за потребою;
- визначення основних параметрів. Ви визначаєте деякі основні параметри, такі як кольори для позначення різних детекторів, список доступних детекторів `detector_types` і ведете облік точності трекінгу для кожного з них у словнику `track_accuracy`;
- захоплення відеоданих. Вибір відеофайлу або веб-камери за допомогою `cv2.VideoCapture()`. Цей об'єкт дозволяє захоплювати кадри з

джерела відеоданих. Якщо джерело не вдалося відкрити, програма видає відповідне повідомлення і завершує роботу;

- основний цикл обробки кадрів. У цьому циклі ви обробляєте кожен кадр відеопотоку окремо. Спочатку ви застосовуєте обраний детектор до кожного кадру для виділення переднього плану від тла. Далі ви виконуєте обробку з виділенням об'єктів і визначенням їхніх контурів;

- визначення точності трекінгу. Ви використовуєте параметри контурів та їхніх пропорцій, щоб визначити точність трекінгу для кожного детектора. Якщо контур має правильне співвідношення сторін, ви вважаєте його правильним треком;

- розрахунок FPS та виведення інформації. Розрахунок кадрів в секунду (FPS) дозволяє вам визначити продуктивність вашої системи. Якщо час, який пройшов з попереднього вимірювання, більше однієї секунди, то розраховується нове значення FPS та виводиться на екран;

- збереження відео та очищення ресурсів. Ви зберігаєте оброблений кадр у відеофайл за допомогою cv2.VideoWriter. Після завершення обробки всіх кадрів відео та натискання клавіші «q», ви звільняєте ресурси, зберігаєте результати та завершуєте роботу програми.

Алгоритми трекінгу пасажиропотоку, реалізовані з використанням Python та OpenCV, можуть бути використані в різних сферах, включаючи:

- моніторинг пасажиропотоку в громадському транспорті: дані алгоритми можуть бути використані для відстеження кількості та руху пасажирів у громадському транспорті, що дозволяє покращити організацію руху та безпеку пасажирів;

- безпека в об'єктах громадського споживання: алгоритми трекінгу можуть бути використані для моніторингу руху людей в об'єктах громадського споживання, таких як аеропорти, стадіони або торгові центри, з метою забезпечення безпеки та контролю доступу;

– дослідження в області комп’ютерного зору: розроблені алгоритми можуть бути використані для дослідження та вдосконалення методів трекінгу об’єктів в реальному часі, що є актуальною галуззю комп’ютерного зору.

Практична реалізація алгоритмів трекінгу пасажиропотоку в громадському транспорті за допомогою Python та OpenCV є важливим етапом для досягнення мети дослідження та впровадження систем моніторингу та безпеки. Розроблені алгоритми та експериментальна установка відкривають широкі можливості для використання в різних сферах та дослідженнях в галузі комп’ютерного зору та машинного навчання. Робота програми, яка визначає точність трекінгу представлена на рисунку 3.1



Рисунок 3.1 – Скріншот монітору с робочою програмою, яка визначає точність трекінгу

Робота програми, яка визначає точність алгоритмів MOG2, KNN, CNT, GMG, GSOC, LSBP представлена на рисунку 3.2



Рисунок 3.2 – Скріншот монітору с робочою програмою, яка визначає точність алгоритмів

Робота програми, яка відображає кількість кадрів, які нейронна мережа може обробити за одну секунду представлена на рисунку 3.3



Рисунок 3.3 – Скріншот монітору с робочою програмою, яка відображає FPS алгоритму GSOC

Отримані результати вказують на кілька важливих аспектів та проблем, які варто врахувати при подальшому використанні алгоритмів у практичних застосуваннях.

Отримані значення FPS для різних алгоритмів трекінгу пасажиропотоку демонструють різну продуктивність. Зокрема, алгоритми MOG2 та KNN відзначаються більш високою частотою кадрів (блізько 50 FPS), що дозволяє виконувати обчислення в реальному часі. В той час як алгоритми GSOC та LSBP демонструють меншу продуктивність (блізько 31-42 FPS). Для візуалізації середнього кількості кадрів за секунду (FPS) різних алгоритмів трекінгу, було використано аналогічну стовпчасту діаграму, яка представлена на рисунку 3.4

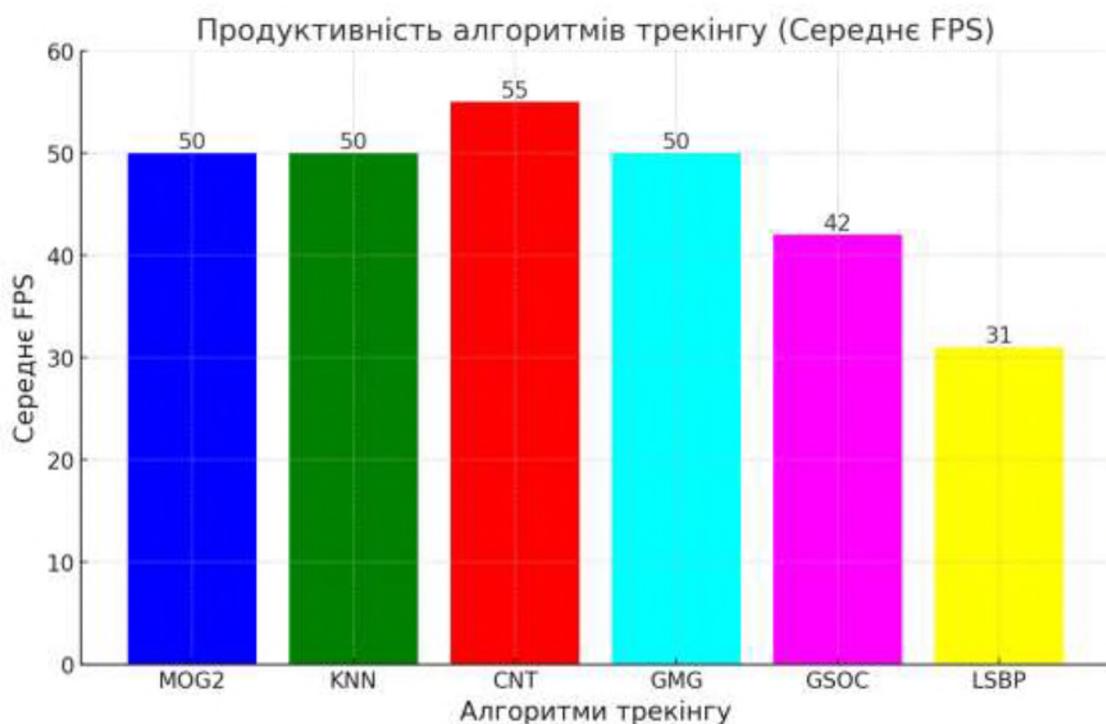


Рисунок 3.4 – Діаграма, яка демонструє продуктивність алгоритмів трекінгу

Оцінюючи точність виявлення об'єктів пасажиропотоку, було визначено, що різні алгоритми мають різні результати. Алгоритми GMG та GSOC досягають високого рівня точності виявлення (34-38%), в той час як CNT та LSBP мають меншу точність (24-39%). Для візуалізації результатів

точності виявлення різних алгоритмів трекінгу, створено діаграму, яка чітко демонструватиме порівняльну ефективність кожного алгоритму та яка представлена на рисунку 3.5

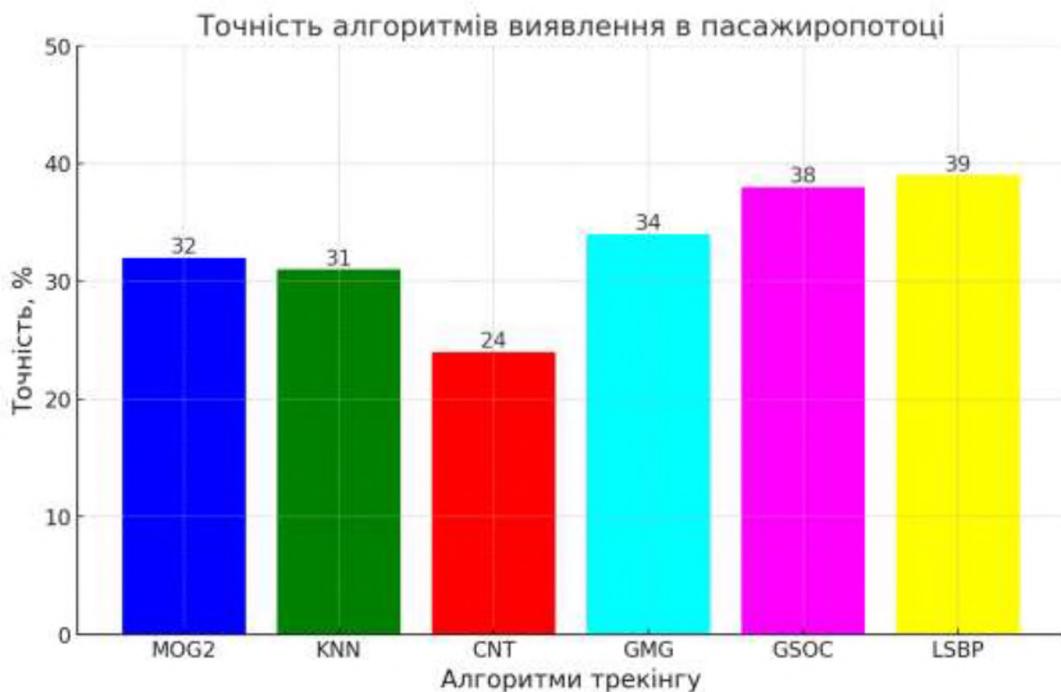


Рисунок 3.5 – Діаграма, яка демонструє точність виявлення об’єктів пасажиропотоку

Для вимірювання точності роботи алгоритмів було визначено метрику «Precision». Результати показують, що алгоритм MOG2 має найвищу точність (блізько 0.62), тоді як LSBP має найнижчу (0.36). Для візуалізації точності (Precision) різних алгоритмів трекінгу, використано стовпчасту діаграму, яка представлена на рисунку 3.6

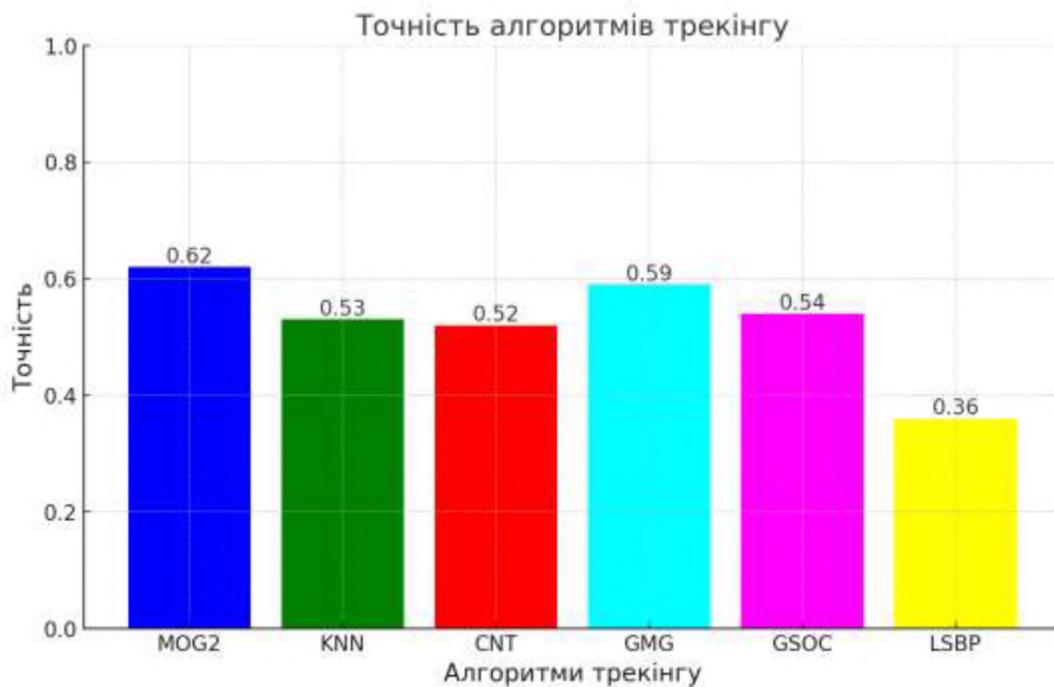


Рисунок 3.6 – Діаграма, яка демонструє точність алгоритмів трекінгу

Цей тип діаграми дозволяє ефективно порівняти точність алгоритмів за допомогою візуального представлення.

Оцінка ефективності алгоритмів:

- MOG2 продемонстрував стабільність у середній кількості кадрів (50 FPS), але мав порівняно низьку точність виявлення об'єктів пасажиропотоку (32%) та досить високу точність (0.62).
- KNN показав аналогічну продуктивність за кількістю кадрів (50 FPS), але незначно нижчу точність виявлення об'єктів (31%) та меншу точність (0.53) порівняно з MOG2.
- CNT вирізняється кращою продуктивністю (55 FPS), але має найнижчу точність серед усіх алгоритмів виявлення (24%) при прийнятній точності (0.52).
- GMG, з продуктивністю на рівні 50 FPS, показав кращу точність виявлення об'єктів пасажиропотоку (34%) та досить високу точність (0.59).
- GSOC має нижчу продуктивність (42 FPS), але вищу точність виявлення об'єктів (38%) та прийнятну точність (0.54).

- LSBP, показавши найнижчу продуктивність (31 FPS), має найвищу точність виявлення (39%), але значно нижчу точність (0.36) порівняно з іншими алгоритмами.

Аналізуючи отримані дані, зроблено висновок, що обрана архітектура нейронної мережі має значний вплив на продуктивність системи. Зокрема, існує компроміс між швидкістю обробки (FPS) та точністю відстеження (Accuracy та Precision). Наприклад, алгоритми з вищою продуктивністю (CNT) можуть мати нижчу точність, тоді як алгоритми з кращою точністю (LSBP) можуть мати нижчу продуктивність.

Загальний аналіз результатів свідчить про те, що різні алгоритми мають свої переваги та недоліки в контексті трекінгу пасажиропотоку. Вибір конкретного алгоритму повинен базуватися на конкретних вимогах та обмеженнях практичної задачі [37]. Наприклад, якщо потрібна висока швидкість обробки в реальному часі, то MOG2 або KNN можуть бути оптимальним вибором, незважаючи на меншу точність.

Проблемні аспекти, які були виявлені під час досліджень, включають в себе:

- необхідність збільшення точності виявлення та трекінгу для забезпечення надійної ідентифікації пасажирів;
- оптимізація продуктивності алгоритмів з низькою частотою кадрів для роботи в реальному часі;
- розгляд можливості використання ансамблю алгоритмів для покращення результатів.

Для подальших досліджень та вдосконалення системи трекінгу пасажиропотоку рекомендується враховувати вищезазначені аспекти та вибирати алгоритми відповідно до конкретних завдань та обмежень додатку.

З метою оптимізації та масштабування системи для використання в реальних умовах, запропоновано врахувати наступні аспекти.

Розглянуто можливість використання апаратного прискорення, зокрема GPU (графічний процесор), для обробки відеоданих та виконання алгоритмів

трекінгу. Використання GPU сприяє суттєвому підвищенню продуктивності та дозволяє виконувати обчислення в реальному часі.

Для поліпшення продуктивності системи запропоновано оптимізувати самі алгоритми трекінгу. Це включає в себе покращення алгоритмів відокремлення переднього плану від тла, оптимізацію фільтрації даних та вдосконалення алгоритмів визначення руху об'єктів.

Запропоновано використовувати кешування для зберігання попередніх результатів обчислень [38]. Це може допомогти уникнути зайвих обчислень та покращити продуктивність системи.

Зауважено, що вибір алгоритму трекінгу повинен залежати від конкретного сценарію використання. Якщо точність є пріоритетом, рекомендовано використовувати алгоритми з вищою точністю, навіть якщо це веде до меншої частоти кадрів.

Запропоновано впровадити систему моніторингу та можливість налаштування параметрів алгоритмів в реальному часі [39]. Це дозволить адаптувати систему до змінних умов та покращити результати трекінгу.

Зазначено, що систему слід розробляти з урахуванням можливості масштабування. Рекомендовано враховувати можливість додавання нових обчислювальних ресурсів, які можуть забезпечити більшу продуктивність при збільшенні обсягу вхідних даних.

Запропоновано акцентувати увагу на покращенні точності виявлення об'єктів [40]. Рекомендується використовувати більш складні алгоритми або додаткові датчики, якщо це необхідно для досягнення надійної ідентифікації об'єктів.

Зазначено, що необхідно проводити валідацію системи та тестування з реальними вхідними даними для ідентифікації проблем та покращення продуктивності в реальних умовах.

Запропоновано постійно контролювати якість роботи системи та забезпечувати підтримку для виявлення та виправлення можливих проблем.

3.4 Оцінка затрат на проект

В контексті реалізації проекту з використанням програмного забезпечення для обробки відео з метою відстеження пасажиропотоку, необхідно здійснити оцінку затрат на інформаційні технології (ІТ). Задля досягнення визначених цілей, обсяг інвестицій в ІТ вимагає ретельного аналізу.

На першому етапі оцінки затрат розглядаються два ключових моменти: первісні інвестиції та витрати на утримання ІТ протягом їх життєвого циклу.

Первісні інвестиції включають закупівлю обладнання, програмного забезпечення, а також витрати на встановлення і налагодження системи. Для даного проекту можуть бути такі витрати:

- технічне забезпечення. Потрібні потужні сервери для обробки відеоданих у реальному часі, що вимагають інвестицій у високопродуктивне обладнання;
- програмне забезпечення. Ліцензії на спеціалізоване ПЗ для відеоаналітики та машинного навчання;
- розробка та адаптація. Послуги розробників для адаптації існуючих рішень під конкретні потреби організації;
- тестування та впровадження. Витрати на тестування системи, її оптимізацію та інтеграцію з існуючими системами організації.

Окрім первісних інвестицій, необхідно також врахувати витрати на утримання ІТ:

- технічна підтримка та сервіс. Регулярне обслуговування обладнання та програмного забезпечення для забезпечення безперебійної роботи;
- оновлення та масштабування. Потенційні оновлення ПЗ та апгрейд обладнання для підтримки зростаючого обсягу даних та збільшення кількості камер;

– енергоспоживання та інші експлуатаційні витрати. Витрати на електроенергію, охолодження та інші витрати, пов'язані з експлуатацією серверного обладнання;

– навчання персоналу. Витрати на тренінги та освітні курси для персоналу, який буде працювати з новою системою.

Для оцінки витрат на проект впровадження інформаційних технологій використано наведену формулу:

$$B_{\Pi} = B_{T3} + B_{ППЗ} + B_{ОП} + B_{ВСЗ} + B_{ПСП} + B_{У} + B_{РПЗ} + B_I, \quad (3.1)$$

де B_{Π} – прямі витрати на проект впровадження інформаційних технологій, грн;

B_{T3} – витрати на придбання технічного забезпечення, грн;

$B_{ППЗ}$ – витрати на придбання програмного забезпечення, грн;

$B_{ОП}$ – витрати на оплату праці, грн;

$B_{ВСЗ}$ – витрати на відрахування на соціальні заходи, грн;

$B_{ПСП}$ – витрати за послуги, які виконують сторонні підприємства, грн;

B_U – витрати на управління інформаційними технологіями, грн;

$B_{РПЗ}$ – витрати на розробку прикладного програмного забезпечення власними силами, грн;

B_I – інші прямі витрати на впровадження, грн

Припущене, що організація планує впровадити систему обробки відеоданих для відстеження пасажиропотоку. Наведемо значення для кожної складової витрат:

B_{T3} – 200000 грн (закупівля серверів та іншого обладнання);

$B_{ППЗ}$ – 100000 грн (придбання ліцензій та спеціалізованого ПЗ);

$B_{ОП}$ – 300000 грн (зарплата розробників та технічної підтримки);

$B_{ВСЗ}$ – 90000 грн (відрахування на соціальні потреби працівників);

$B_{ПСП}$ – 150000 грн (послуги зовнішніх консультантів);

B_U – 50000 грн (управління проектом);

$B_{РПЗ}$ – 200000 грн (розробка спеціалізованого програмного забезпечення);

$B_I = 10000$ грн (непередбачені витрати).

Згідно з цими даними, розрахуємо загальні прямі витрати на проект:

$$B_P = 200000 + 100000 + 300000 + 90000 + 150000 + 50000 + 200000 + 10000 = 1100000.$$

Таким чином, загальні прямі витрати на проект складають 1100000 грн.

Для оцінки непрямих витрат на проект впровадження інформаційних технологій використовуємо формулу:

$$B_H = B_{H1} + B_{H2}, \quad (3.2)$$

де B_{H1} – витрати, пов’язані з простоями ІС з ряду причин;

B_{H2} – витрати, пов’язані з людським фактором.

Витрати, пов’язані з простоями B_{H1} :

- технічні несправності. Наприклад, простої через вихід з ладу серверного обладнання чи відмову ПЗ можуть коштувати організації 50000 грн на рік у вигляді упущеніх можливостей чи штрафів за невиконання умов контрактів;
- оновлення та технічне обслуговування. Планові оновлення системи можуть привести до короткочасних простоїв, кошт яких оцінюється в 30000 грн на рік.

Витрати, пов’язані з людським фактором B_{H2} :

- помилки персоналу. Невірне використання системи чи помилки при введенні даних можуть привести до неефективності, що оцінюється в 20000 грн на рік;
- навчання та адаптація персоналу. Навчання співробітників для роботи з новою системою та їх адаптація може коштувати 40000 грн.

Загальні непрямі витрати складуть:

$$B_H = B_{H1} + B_{H2} = 50000 + 30000 + 20000 + 40000 = 140000 \text{ грн}$$

Отже, загальні непрямі витрати на проект впровадження інформаційних технологій становитимуть 140000 грн.

Розраховано витрати на утримання інформаційних технологій, а також загальні витрати на проект впровадження ІТ за допомогою наступних формул:

$$B_{УТР} = B_{ОП} + B_{ВСЗ} + B_{П} + B_I, \quad (3.3)$$

- де $B_{УТР}$ – щорічні витрати на утримання інформаційних технологій, грн;
- $B_{ОП}$ – витрати на оплату праці по підтримці та удосконаленню інформаційної системи, грн;
- $B_{ВСЗ}$ – витрати на відрахування на соціальні заходи, грн;
- $B_{П}$ – витрати за послуги сторонніх підприємств, грн;
- B_I – інші витрати на утримання інформаційної системи, грн.

$$B_{ІТ} = B_{П} + B_{Н} + B_{УТР}, \quad (3.4)$$

- де $B_{ІТ}$ – загальні витрати на проект впровадження інформаційних технологій, грн.

Щорічні витрати на утримання ІТ для проекту становитимуть:

- $B_{ОП} = 120000$ грн. (оплата праці технічного персоналу);
- $B_{ВСЗ} = 30000$ грн. (соціальні відрахування);
- $B_{П} = 50000$ грн. (послуги сторонніх фірм, наприклад, за оренду обладнання або хмарні послуги);
- $B_I = 20000$ грн. (інші оперативні витрати, такі як ремонт обладнання, оновлення ПЗ тощо).

Розраховано щорічні витрати на утримання:

$$B_{УТР} = 120000 + 30000 + 50000 + 20000 = 220000 \text{ грн.}$$

За визначенням з формули (3.4) загальні витрати на проект впровадження ІТ складаються з прямих витрат $B_{П}$, непрямих витрат $B_{Н}$, та щорічних витрат на утримання $B_{УТР}$, які ми розраховано вище. Прямі витрати ($B_{П}$) та непрямі витрати ($B_{Н}$) розраховано раніше, що становило 1100000 грн. та 140000 грн. відповідно. Тоді:

$$B_{ІТ} = 1100000 + 140000 + 220000 = 1460000 \text{ грн.}$$

Отже, загальні витрати на проект впровадження інформаційних технологій складуть 1460000 грн. з урахуванням первісних, непрямих та щорічних витрат на утримання.

3.5 Оцінка обґрунтованості визначеної величини витрат на проект

Задля оцінки вигід від впровадження інформаційних технологій, визначено прямі, якісні, та стратегічні ефекти, що могли б виникнути в результаті реалізації проекту з використанням програмного забезпечення для обробки відеоданих.

Прямі ефекти включають збільшення доходів від зростання обсягу продажів чи зниження витрат за рахунок автоматизації процесів.

Впровадження системи дозволить:

- збільшити ефективність відстеження пасажиропотоку, що призведе до оптимізації маршрутів і, відповідно, до 10% зростання доходів;
- знизити витрати на персонал через автоматизацію, на 5%.

Якщо середній дохід компанії становить 1000000 грн. на рік, зростання на 10% призведе до додаткових 100000 грн. доходу. Зниження витрат на персонал може скласти 50000 грн. на рік.

Якісні ефекти важко кількісно оцінити, але вони можуть включати підвищення задоволеності клієнтів, поліпшення іміджу компанії та збільшення лояльності співробітників. Припущене, що поліпшення сервісу збільшить клієнтську базу на 5%, що також вплине на доходи.

Стратегічні ефекти включають довгострокові переваги, такі як зміцнення позицій на ринку, розширення ринку збуту тощо.

Ці ефекти можуть не мати негайного фінансового відображення, але вони можуть істотно впливати на вартість компанії в майбутньому. Наприклад, якщо компанія планує IPO, підвищення ефективності та якості послуг може збільшити її оцінку потенційними інвесторами.

Необхідно також врахувати зовнішні фактори, такі як зміни в законодавстві, економічному середовищі, технологічних трендах, які можуть вплинути на ефективність проекту.

Для порівняння отриманих даних з середніми показниками по галузі, можна використати галузеві звіти, публічно доступні дослідження або дані аналітичних агентств.

Також важливо оцінити ефективність існуючої системи та можливі вигоди від її заміни або модернізації.

Розглянуто прикладний розрахунок для організації, яка планує впровадити систему для відстеження пасажиропотоку з використанням обробки відеоданих.

Прибуток до оподаткування визначено за формулою:

$$\text{Пр} = \text{Виручка} - \text{Затрати}. \quad (3.5)$$

Тоді:

$$\text{Пр} = 1000000 - 450000 = 550000 \text{ грн.}$$

Податок на прибуток визначено за формулою:

$$\text{Под} = \text{Пр} \cdot Ст_{под}, \quad (3.6)$$

де $Ст_{под}$ – ставка податку на прибуток (0,25 – індексне вираження відсотків по податку на прибуток з розрахунку 25 %).

Тоді:

$$\text{Под} = 550000 \times 0.25 = 137500 \text{ грн.}$$

Чистий прибуток визначено за формулою:

$$\text{Пр}_{\text{ч}} = \text{Пр} - \text{Под}. \quad (3.7)$$

Чистий прибуток складе:

$$\text{Пр}_{\text{ч}} = 550000 - 137500 = 412500 \text{ грн.}$$

Результат від операційної діяльності визначено за формулою:

$$CF_2(t) = \text{Пр}_{\text{ч}} + A. \quad (3.8)$$

Результат від операційної діяльності складе:

$$CF_2(t) = 412500 + 20000 = 432500 \text{ грн.}$$

Розрахунки базуються на припущеннях, що показники будуть зростати на 5% щороку, що може відбивати позитивний ефект від впровадження ІТ-рішення на продуктивність та доходи компанії. Відображення операційної діяльності по проекту в умовних одиницях (тис. грн.) наведено у таблиці 3.1

Таблиця 3.1 – Операційна діяльність по проєкту

Показники	Значення на кроці, тис. грн				
	1	2	3	4	5
1. Обсяг продажів, тис. шт.	10.00	10.50	11.02	11.58	12.16
2. Ціна, грн./шт	100.00	105.00	110.25	115.76	121.55
3. Виручка, тис. грн. (п.1 х п.2)	1000.00	1102.50	1215.51	1340.10	1477.46
4. Оплата праці робітників, тис. грн.	200.00	210.00	220.50	231.53	243.10
5. Матеріали, тис. грн.	50.00	52.50	55.12	57.88	60.78
6. Постійні витрати, тис. грн.	150.00	157.50	165.38	173.64	182.33
7. Амортизація устаткування, тис. грн.	20.00	21.00	22.05	23.15	24.31
8. Відсотки по кредитах, тис. грн.	30.00	31.50	33.08	34.73	36.47
9. Сума витрат, тис. грн. (п.4 + п.5 + п.6 + п.7 + п.8)	450.00	472.50	496.12	520.93	546.98
10. Прибуток до оподаткування, тис. грн. (п.3 – п.9)	550.00	630.00	719.38	819.16	930.48
11. Податок на прибуток, тис. грн. (п.10 х ставка податку)	137.50	157.50	179.85	204.79	232.62
12. Проектований чистий прибуток, тис. грн. (п.10 – п.11)	412.50	472.50	539.54	614.37	697.86
13. Результат від операційної діяльності $CF_2(t) = \text{Пр}ч + A$, тис. грн. (п.12 + п.7)	432.50	493.50	561.59	637.53	722.17

3.6 Оцінка економічної ефективності проєкту впровадження інформаційних технологій

Розраховано чисту дисконтовану вартість (NPV) за формулою:

$$NPV = \sum_{t=1}^n \frac{CF_t}{(1+i)^t} - INV_0, \quad (3.9)$$

де CF_t – сума грошового потоку за період t , грн.;

t – крок (рік, квартал, місяць тощо) проєкту.

За умовою проєкту обрано первісну інвестицію INV_0 розміром 1000 тис. грн. і ряд грошових потоків CF за 5 років з постійним зростанням 5% щороку від початкової суми 432.5 тис. грн. При ставці дисконтування 10% NPV проєкту складає:

$$NPV = \frac{432.5}{(1+0.1)^1} + \frac{432.5 \cdot 1.05}{(1+0.1)^2} + \frac{432.5 \cdot 1.05^2}{(1+0.1)^3} + \frac{432.5 \cdot 1.05^3}{(1+0.1)^4} + \frac{432.5 \cdot 1.05^4}{(1+0.1)^5} - 1000 = 795.13$$

$NPV = 795.13$ тис. грн.

Розраховано показник бухгалтерської рентабельності інвестиційного проекту (ROI) за формулою:

$$ROI = \frac{AP}{(INV_1+INV_2)/2} \times 100, \quad (3.10)$$

де AP – середньорічний чистий прибуток, грн.;

INV_1, INV_2 – обсяг інвестицій, відповідно, на початок і кінець досліджуваного періоду, грн.

Середній чистий прибуток за 5 років проекту становить 550 тис. грн., тому ROI складає:

$$ROI = \frac{550}{1000} \times 100\% = 55.00\%$$

$$C = (\sum T_j \cdot G_j) \cdot (I+R), \quad (3.11)$$

де T_j – необхідні витрати на вирішення задач по нормам і нормативам;

G_j – тариф на розрахункову одиницю послуг при використанні j -го ресурсу у разі нормативної прибутковості = 0;

R – розрахунковий норматив прибутковості при рішенні і передачі користувачеві результатів;

j – кількість різноманітностей використаних ресурсів.

Розраховано нормативу прибутковості R за формулою:

$$R = f(X_1, X_2, \dots, X_n), \quad (3.12)$$

де X – фактори, що впливають на R (терміновість рішення тощо).

Ураховуючи специфіку алгоритмізації дослідження продуктивності нейронних мереж для відстеження пасажиропотоку в громадському транспорті роботи, визначено наступні фактори, що впливають на розрахунковий норматив прибутковості (R) для проекту системи відстеження пасажиропотоку:

- швидкість надання послуги: 0.2. Важливий фактор, який впливає на оперативність обробки даних від детекторів у системі;
- точність послуги: 0.15. Критичний фактор для аналізу руху пасажирів та подальшого планування маршрутів;

- вартість послуги: 0.3. Включає витрати на обладнання, розробку програмного забезпечення та його впровадження;
- попит на послугу: 0.25. Оцінюється на основі даних про пасажиропотіки та потреби транспортних компаній;
- надійність послуги: 0.1. Забезпечує стабільність системи та мінімізацію збоїв у її роботі.

Визначено R як середнє значення п'яти факторів (X1 - X5), що впливають на прибутковість:

$$R = \frac{0.2 + 0.15 + 0.3 + 0.25 + 0.1}{5} = 0.2.$$

Середнє значення цих факторів R становить 0.2.

Обрано необхідні витрати на вирішення задач T_j як 5000 грн. і тариф на розрахункову одиницю послуги G_j як 100 грн. при кількості різноманітностей використаних ресурсів j = 5, вартість послуги С визначається як:

$$C = (5000 \times 100 \times 5) \times (1 + 0.2) = 3000000.$$

Кінцева вартість послуги з урахуванням прибутковості становить 3000000 грн.

На основі проведеного комплексного економічного аналізу інвестиційного проекту з розробки та впровадження системи відстеження пасажиропотоків у громадському транспорті можна сформовано наступні висновки:

- аналіз затрат на проект засвідчив, що загальні витрати включають значні капітальні інвестиції та поточні витрати, які несе підприємство впродовж реалізації проекту. Врахування всіх аспектів затрат, від первинних інвестицій на закупівлю обладнання і розробку програмного забезпечення до витрат на його впровадження та подальшу технічну підтримку, дало змогу забезпечити повну бюджетування проекту. Крім того, особлива увага була приділена потенційним ризикам, пов'язаним з затримками в реалізації проекту та можливим збільшенням вартості ресурсів, що може привести до неперебачуваних збільшень бюджету;

– визначення та оцінка вигід від реалізації проєкту показали, що крім прямих фінансових результатів, система обіцяє значні якісні та стратегічні переваги. Прямі фінансові вигоди очікуються у формі підвищення доходів завдяки збільшенню ефективності використання транспортних засобів та оптимізації маршрутів, а також за рахунок зменшення витрат на експлуатацію. Якісні вигоди включають покращення обслуговування пасажирів та збільшення задоволення користувачів послугами. Стратегічні вигоди проявляються у вигляді зміцнення ринкових позицій та створення основи для розширення бізнесу в майбутньому;

– проведені розрахунки NPV та ROI підтвердили, що проєкт є економічно доцільним. Позитивне значення NPV свідчить про те, що очікувані грошові потоки перевищують витрати, пов’язані з реалізацією проєкту, і демонструють його потенційну здатність приносити прибуток у довгостроковій перспективі. Високий показник ROI вказує на те, що проєкт принесе значну віддачу на вкладені інвестиції, що робить його привабливим для інвесторів та керівництва компанії.

Зазначені висновки підтверджують, що впровадження системи відстеження пасажиропотоків у громадському транспорті не тільки відповідає поточним потребам ринку, але й забезпечить стабільний розвиток компанії, покращення сервісу для пасажирів та збільшення конкурентоспроможності на ринку транспортних послуг.

ВИСНОВКИ

В ході дослідження було здійснено всебічний аналіз та розробку системи відстеження пасажиропотоків на основі сучасних технологій комп’ютерного зору та машинного навчання. Ця робота включала теоретичне обґрунтування алгоритмів, практичну реалізацію програмного забезпечення та експериментальну перевірку його ефективності. Отримані результати дозволяють не тільки оцінити потенціал застосування розробленої системи в реальних умовах експлуатації, але й надають цінний матеріал для наукової спільноти та спеціалістів у сфері міського пасажирського транспорту.

Розглянуті та аналізовані в роботі методи та інструменти відкривають нові можливості для оптимізації роботи громадського транспорту та підвищення комфорту пасажирів. Ретельний економічний аналіз підтверджив фінансову вигоду від імплементації проекту та його практичну доцільність. Запропоновані рекомендації щодо використання отриманих результатів мають важливе значення для стратегічного планування розвитку транспортної інфраструктури міста.

Наукові результати магістерської роботи відображаються у наступних аспектах:

- була створена комплексна алгоритмічна модель, яка інтегрує передові досягнення в області комп’ютерного зору та машинного навчання для ефективного відстеження пасажиропотоків. Модель здатна обробляти великі обсяги даних, забезпечуючи високу швидкість та точність обробки інформації, що є критично важливим для оперативного реагування на зміни в пасажиропотоках. Особлива увага приділялася розробці алгоритмів, які можуть адаптуватися до різноманітних умов експлуатації без значної втрати продуктивності;

- в роботі було виконано глибоке дослідження різних алгоритмів виявлення руху, таких як MOG2, KNN, CNT та інших. Були аналізовані їх переваги та недоліки у контексті задач визначення пасажиропотоків, їх

здатність до класифікації об'єктів та відповідність реальним умовам. Завдяки детальному порівняльному аналізу, вдалося визначити найбільш ефективні типи детекторів для конкретних сценаріїв використання, що суттєво підвищує ефективність моніторингу та знижує ймовірність помилок;

- були розроблені об'єктивні критерії оцінювання ефективності системи, які включають точність відстеження, надійність в роботі та легкість інтеграції з існуючими транспортними системами. Критерії дозволяють оцінити систему з різних точок зору, від технічної реалізації до практичної корисності та зручності для кінцевого користувача. Це забезпечує можливість не лише оцінити поточний стан системи, але й спрямувати подальший розвиток у відповідності з отриманими даними та зворотнім зв'язком від користувачів.

Ці результати є основою для подальшого розвитку та вдосконалення системи відстеження пасажиропотоків, вони можуть бути застосовані для розробки більш комплексних і масштабованих рішень, що враховують ширший спектр параметрів та забезпечують високий рівень задоволеності користувачів транспортних послуг.

У процесі реалізації магістерського проекту було досягнуто ряду практичних результатів, які мають значення для подальшого впровадження та вдосконалення системи відстеження пасажиропотоків. Серед них:

- ефективність системи підтверджена емпірично через ряд тестувань на даних, отриманих із відеозаписів реального руху пасажирів, що відображає здатність системи адаптуватися до різноманітних умов експлуатації та забезпечувати точний моніторинг;
- розроблено детальну економічну модель, що включає оцінку чистої приведеної вартості (NPV) та внутрішньої норми доходності (IRR), яка дозволяє з упевненістю стверджувати про інвестиційну привабливість проекту. Розрахунки виявили, що проект не тільки самоокупний, але й здатен генерувати значний прибуток при розгортанні на ширшу мережу транспортних вузлів;

– аналітична робота із визначення ризиків та їхнього впливу на проект допомогла встановити систему управління ризиками, яка охоплює не тільки технічні аспекти, але й зовнішні економічні та соціальні фактори. Це забезпечує засоби для прогнозування можливих проблем та розробки відповідних стратегій реагування.

На основі виконаного дослідження можна зробити висновок, що розроблена система відстеження пасажиропотоків має високий потенціал для впровадження та може суттєво підвищити ефективність роботи міського пасажирського транспорту. Отримані результати мають важливе значення для подальшого розвитку інформаційних систем і технологій в галузі транспорту та можуть бути використані для покращення сервісу та управління міським транспортом.

У межах проведеного дослідження було розроблено систему для відстеження пасажиропотоків в громадському транспорті, яка базується на використанні передових технологій комп’ютерного зору та обробки даних. Система була ретельно протестована та демонструє високу точність і надійність, що робить її придатною для реального впровадження. Проведений економічний аналіз, включаючи розрахунки NPV та ROI, вказує на фінансову доцільність проекту, що дозволяє розглядати його як інвестиційно привабливий та перспективний для масштабування.

Система відстеження пасажиропотоків є ефективним інструментом для оптимізації роботи громадського транспорту. Вона здатна забезпечити оперативне реагування на зміни в пасажиропотоках та допомогти в адаптації графіків руху для підвищення ефективності використання транспортних засобів.

Економічний аналіз проекту виявив його високу інвестиційну привабливість з можливістю отримання стабільного прибутку в довгостроковій перспективі. Розрахунки показали, що вкладені кошти можуть бути повернуті та принести значний дохід.

Система має потенціал для адаптації та використання в різних міських умовах, з урахуванням локальних особливостей та потреб пасажирів. Це дозволить підвищити рівень задоволеності користувачів громадського транспорту та сприяти покращенню загального сервісу.

Проект має великий потенціал для масштабування, у тому числі міжнародного, що може сприяти розвитку транспортних інновацій та обміну досвідом між містами та країнами, з метою оптимізації транспортних систем на глобальному рівні.

За результатами дослідження можна рекомендувати впровадження розробленої системи відстеження пасажиропотоків як інструменту для підвищення ефективності міського транспорту. Це дозволить не тільки знизити витрати на транспортне обслуговування, але й підвищити якість послуг для кінцевого споживача – пасажира.

Рекомендації до подальшого використання результатів дослідження включають інтеграцію з іншими інформаційними системами громадського транспорту, розвиток функціоналу для залучення нових користувачів, а також подальшу модернізацію системи з урахуванням отриманого досвіду та зворотного зв'язку від пасажирів.