

ФАКУЛЬТЕТ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ
КИЇВСЬКОГО НАЦІОНАЛЬНОГО УНІВЕРСИТЕТУ
ІМЕНІ ТАРАСА ШЕВЧЕНКА

КАФЕДРА ПРОГРАМНИХ СИСТЕМ І ТЕХНОЛОГІЙ

БИЧКОВ О.С., МЕРКУЛОВА К.В., ЖАБСЬКА Є.О.

**МЕТОДИКИ ІНТЕГРАЦІЇ КОМП'ЮТЕРНОГО ЗОРУ В
ПРОГРАМНІ СИСТЕМИ**

Лабораторний практикум
для здобувачів спеціальності

F2 (121) «Інженерія програмного забезпечення»

Київ 2025

Рецензенти:

Толюпа С. В. – доктор технічних наук, професор, професор кафедри кібербезпеки та захисту інформації факультету інформаційних технологій Київського національного університету імені Тараса Шевченка

Лактіонов І. С. – доктор технічних наук, професор, професор кафедри програмного забезпечення комп'ютерних систем Національного технічного університету «Дніпровська політехніка»

Рекомендовано до публікації кафедрою програмних систем і технологій Київського національного університету імені Тараса Шевченка в електронному вигляді (протокол №7 від 11 листопада 2025 року).

Рекомендовано до публікації вченою радою факультету інформаційних технологій Київського національного університету імені Тараса Шевченка (протокол №7 від 29 грудня 2025 року).

Методики інтеграції комп'ютерного зору в програмні системи: лабораторний практикум для здобувачів спеціальності F2 (121) «Інженерія програмного забезпечення» **Бичков О.С., Меркулова К.В., Жабська Є.О. / Меркулова К.В. – К.: КНУ імені Тараса Шевченка, 2025. – 80 с.**

Лабораторний практикум призначений для здобувачів другого курсу освітнього ступеня “магістр” спеціальності F2 (121) «Інженерія програмного забезпечення», що навчаються за освітньою програмою «Інженерія програмного забезпечення».

Лабораторний практикум містить завдання та рекомендації до виконання лабораторних робіт з дисципліни «Методики інтеграції комп'ютерного зору в програмні системи», описано приклади виконання завдань, контрольні запитання за тематикою лабораторних робіт та завдання для самостійного опрацювання.

Публікується в авторській редакції

© Бичков О.С., Меркулова К.В. Жабська Є.О.

ЗМІСТ

ВСТУП.....	4
ЛАБОРАТОРНА РОБОТА №1. АВТОМАТИЧНЕ ВИЯВЛЕННЯ ТА ДЕТЕКЦІЯ ДИНАМІЧНИХ ОБ'ЄКТІВ У ВІДЕОПОТОЦІ.....	5
ЛАБОРАТОРНА РОБОТА №2. ВІДСТЕЖЕННЯ ДИНАМІЧНИХ ОБ'ЄКТІВ, ФОРМУВАННЯ ТА КОРЕКЦІЯ ЇХ ТРАЄКТОРІЙ У ВІДЕОПОТОЦІ.....	22
ЛАБОРАТОРНА РОБОТА №3. АНАЛІЗ ОЗНАК ТА ВИЯВЛЕННЯ АНОМАЛЬНИХ РУХІВ ДИНАМІЧНИХ ОБ'ЄКТІВ У ВІДЕОПОТОЦІ.....	38
STEM ПРОЄКТ. КОМПЛЕКСНИЙ АНАЛІЗ ТА ПРОГНОЗУВАННЯ ПОВЕДІНКИ ДИНАМІЧНИХ ОБ'ЄКТІВ У ВІДЕОПОТОЦІ	61
ЛІТЕРАТУРНІ ДЖЕРЕЛА	79

ВСТУП

Знання, отримані в процесі вивчення дисципліни «Методики інтеграції комп'ютерного зору в програмні системи», базуються на принципах застосування сучасних методів цифрової обробки зображень, детекції та трекінгу об'єктів, а також аналізу динаміки та аномальних рухів у відеопотоках із використанням сучасного професійного програмного забезпечення. Дисципліна допомагає здобувачам набутти необхідних знань і практичних навичок роботи з цифровими зображеннями та відеопотоками, алгоритмами виділення ознак, а також методами ідентифікації та аналізу поведінки об'єктів у динамічних сценах.

У межах дисципліни вивчаються теоретичні основи обробки та аналізу цифрових зображень і відео, алгоритми виявлення та сегментації об'єктів, методи детекції аномалій, а також сучасні підходи до представлення та візуалізації результатів аналізу. Особлива увага приділяється практичному використанню стандартних бібліотек комп'ютерного зору та обробки зображень у різноманітних мовах програмування, а також інтеграції алгоритмів обробки відеопотоку для автоматичного аналізу динамічних об'єктів.

Завдання вивчення дисципліни полягає у формуванні у здобувачів компетенцій з основ цифрової обробки зображень, детекції та трекінгу об'єктів, а також здатності проводити аналітичний та візуальний аналіз аномальних рухів у відеопотоках. Виконання лабораторних робіт дозволяє здобувачам закріпити теоретичні знання на практиці, опанувати сучасні методи обробки та аналізу зображень і навчитися ефективно застосовувати їх для вирішення прикладних завдань у сфері комп'ютерного зору.

З кожної виконаної здобувачем лабораторної роботи формується індивідуальний звіт, який за результатами захисту оцінюється викладачем. Підсумкові оцінки, отримані за виконання лабораторних робіт, враховуються під час виставлення семестрової підсумкової оцінки з цієї навчальної дисципліни.

ЛАБОРАТОРНА РОБОТА №1. АВТОМАТИЧНЕ ВИЯВЛЕННЯ ТА ДЕТЕКЦІЯ ДИНАМІЧНИХ ОБ'ЄКТІВ У ВІДЕОПОТОЦІ

Мета: навчитися автоматично виявляти об'єкти у відеопотоці, усувати шумові детекції та об'єднувати розділені частини одного об'єкта для подальшого аналізу його параметрів.

ТЕОРЕТИЧНІ ВІДОМОСТІ

Детекція об'єктів у відеопотоці є однією з базових задач комп'ютерного зору. Вона передбачає автоматичне виявлення та визначення місцезнаходження об'єктів на кожному кадрі відео з метою подальшого аналізу їх руху, поведінки або взаємодії. Динамічні об'єкти, які підлягають детекції, можуть включати пішоходів, транспортні засоби, дрони та інші рухомі елементи середовища, що характеризуються зміною позиції, розміру, форми та швидкості.

Проблематика детекції об'єктів у відео пов'язана з низкою складностей, серед яких можна виділити:

1. Перекривання об'єктів – часткове або повне перекриття одного об'єкта іншим, що ускладнює точне виділення контурів.
2. Зміни форми та розміру об'єктів – наприклад, об'єкти, що наближаються або віддаляються від камери, змінюють свої проєкції на кадрі.
3. Шумові детекції – випадкові або короточасні зміни пікселів, які не відповідають реальному руху об'єктів, але можуть бути виявлені алгоритмом.
4. Варіації освітлення та фону – зміни освітлення, тіні або рухомий фон можуть ускладнювати правильне виділення об'єктів.

Ефективне вирішення задачі детекції об'єктів у відеопотоці є передумовою для подальших етапів аналізу: відстеження траєкторій, класифікації об'єктів, виявлення аномалій та прогнозування руху. Використання методів детекції, таких як віднімання фону, порогова обробка та виділення контурів із морфологічними операціями, дозволяє виділити об'єкти навіть у складних умовах та підготувати

дані для подальшого збереження у структурованому форматі для аналітичних та дослідницьких цілей.

Методи детекції об'єктів у відеопотоці

Для автоматичного виявлення об'єктів у відеопотоці існує кілька основних категорій методів, що відрізняються не лише принципами роботи, але й вимогами до обчислювальних ресурсів, доступністю навчальних даних та точністю детекції. Кожен метод має свої переваги та обмеження і підбирається залежно від конкретних умов: складності сцени, наявності рухомого фону, кількості об'єктів та вимог до швидкодії. Розглянемо більш детально основні категорії методів детекції об'єктів у відеопотоці.

Класичні алгоритмічні методи детекції базуються на аналізі пікселів зображень, контурів об'єктів, координат їх руху та локальних ознак кадру і не потребують навчання на великих датасетах. Такі методи забезпечують відносно просту та швидку реалізацію детекції, що робить їх зручними для програмних систем із обмеженими обчислювальними ресурсами. Основні підходи включають:

1. Віднімання фону та порогова обробка – дозволяє виділити рухомі об'єкти на статичному фоні шляхом порівняння поточного кадру з фоновим зображенням. Пікселі, зміни інтенсивності яких перевищують заданий поріг, вважаються частиною об'єкта. Метод ефективний для статичних сцен, проте його точність знижується при складному фоні, перекритті об'єктів або різких змінах освітлення.
2. Виділення контурів та морфологічні операції – полягає у визначенні меж об'єктів на бінарному зображенні та подальшій обробці для усунення шуму і об'єднання розділених частин об'єкта. Використовуються такі операції, як розширення, стискання, а також відкриття та закриття, що дозволяє покращити якість сегментації і точність детекції.
3. Оптичний потік – оцінює рух пікселів між кадрами для визначення напрямку і швидкості руху об'єктів. Алгоритми, такі як Lucas-Kanade або Farneback, дозволяють виявляти рух навіть при зміні масштабу об'єктів і на складному

фоні. Цей метод ефективний для динамічних сцен, де об'єкти постійно переміщуються.

4. Методи на основі локальних ознак – використовують ключові точки та дескриптори для детекції та відстеження об'єктів. До найпоширеніших алгоритмів належать SIFT, SURF та ORB. SIFT забезпечує інваріантність до масштабу і повороту об'єктів та стійкість до змін освітлення, SURF є швидшою альтернативою SIFT, а ORB оптимізований для роботи в реальному часі з обмеженими обчислювальними ресурсами.

Сучасні методи детекції об'єктів на основі глибинного навчання набули широкого застосування завдяки високій точності та здатності працювати у складних умовах, таких як рухомий фон, перекриття об'єктів, зміни освітлення або наявність об'єктів різної форми та масштабу. На відміну від класичних алгоритмів, ці методи не покладаються на аналіз пікселів або контурів, а використовують згорткові нейронні мережі для автоматичного виділення ознак та класифікації об'єктів. Основні підходи включають:

1. Однорівневі детектори – такі як YOLO (You Only Look Once) та SSD (Single Shot MultiBox Detector). Ці алгоритми здійснюють детекцію об'єктів за один прохід через нейронну мережу, що дозволяє отримувати координати об'єктів та їх класи одночасно. Завдяки цьому вони забезпечують високу швидкодію, що робить їх ефективними для застосувань у реальному часі. Недоліком є відносно нижча точність у порівнянні з дворівневими детекторами при складних сценах.
2. Дворівневі детектори – наприклад, Faster R-CNN. На першому етапі таких методів пропонуються регіони інтересу, які потенційно містять об'єкти, а на другому етапі здійснюється їх точна класифікацію та уточнення координат. Цей підхід забезпечує високу точність, проте потребує більшої обчислювальної потужності та є повільнішим за однорівневі методи.
3. Методи сегментації об'єктів – прикладом є Mask R-CNN. Такі методи не лише визначають координати об'єктів, а й створюють маски, які точно описують форму кожного об'єкта на зображенні. Такий підхід особливо корисний у

випадках, коли важлива детальна інформація про межі об'єкта для подальшого аналізу або відстеження.

4. Методи відстеження на основі нейронних мереж – наприклад, Deep SORT. Такі методи поєднують детекцію об'єктів із їх відстеженням у відеопотоці, забезпечуючи стабільну ідентифікацію кожного об'єкта протягом часу. В алгоритмах додатково використовуються дескриптори зовнішнього вигляду об'єктів та інформація про їх рух для запобігання плутанини при перекритті або схожості об'єктів.

На рівні з класичними та сучасними методами, останнім часом активно застосовуються гібридні підходи, що поєднують алгоритмічні методи та нейронні мережі. Такі комбіновані методи дозволяють підвищити точність детекції та стабільність роботи у складних умовах, наприклад, при наявності рухомого фону, перекритті об'єктів або зміні освітлення. У гібридних системах зазвичай на першому етапі використовуються класичні методи для попереднього виділення рухомих областей, а на другому етапі нейронна мережа уточнює детекцію та класифікацію об'єктів. Такий підхід дозволяє оптимізувати обчислювальні ресурси та скоротити час обробки відеопотоку, зберігаючи при цьому високу точність.

Наступним підходом до детекції об'єктів є методи на основі правил та статистичних моделей, при застосуванні яких виявлення об'єктів здійснюється шляхом аналізу закономірностей у зображеннях або відеопотоці, сформульованих на основі попередніх знань або статистичних властивостей кадрів. На відміну від класичних алгоритмічних методів, ці підходи дозволяють враховувати ймовірнісні взаємозв'язки між ознаками об'єктів, що підвищує стабільність детекції у складних або шумних умовах.

До основних принципів роботи таких методів належать:

1. Методи на основі правил – детекція здійснюється за заздалегідь визначеними критеріями, наприклад, мінімальний розмір об'єкта, колірна гама, форма або швидкість руху. Для кожного кадру алгоритм порівнює піксельні або контурні характеристики із встановленими правилами і визначає наявність об'єктів.

Цей підхід ефективний у контрольованих середовищах, де структура сцени та характеристики об'єктів відомі заздалегідь.

2. Статистичні методи – використовують ймовірнісні моделі для оцінки того, чи належить певна область кадру до об'єкта. Прикладами є методи на основі гаусових сум для моделювання фону, статистичне виявлення змін або байєсівські підходи до класифікації пікселів. Ці методи дозволяють більш гнучко адаптуватися до варіацій освітлення, рухомого фону та невизначеності у вигляді об'єктів.

Методи на основі правил та статистики часто використовуються у комбінації з класичними алгоритмічними методами, наприклад, для попередньої сегментації кадру перед застосуванням оптичного потоку або для уточнення детекції у шумних умовах.

Особливості об'єктів та відео для детекції

Ефективність детекції об'єктів у відеопотоці значною мірою залежить від характеристик самих об'єктів та властивостей відео, у якому вони спостерігаються. Розуміння цих особливостей є необхідною умовою для правильного вибору методів детекції та налаштування параметрів алгоритмів.

Об'єкти, що підлягають детекції, можуть значно відрізнятися за розміром, формою, кольором, швидкістю та траєкторією руху. До основних характеристик належать:

- Розмір і масштаб – об'єкти на відео можуть змінювати свої розміри залежно від відстані до камери. Наближення об'єкта призводить до збільшення його проєкції на кадрі, тоді як віддалені об'єкти можуть займати лише кілька пікселів. Такі зміни розміру потрібно враховувати при детекції для коректного визначення координат і меж об'єкта.
- Форма та контур – об'єкти можуть мати нерегулярні або змінні форми протягом часу, що впливає на точність виділення їх контурів. Важливо враховувати можливі деформації або зміни конфігурації об'єкта при аналізі кадрів.

- Колір і текстура – характеристики поверхні об’єктів, такі як однорідність або контрастність, можуть ускладнювати їх відокремлення від фону. Зміни кольору, відблиски або тіні також впливають на якість детекції.
- Швидкість та траєкторія руху – об’єкти можуть рухатися з різною швидкістю та змінювати напрямок руху. Динамічні зміни позиції об’єкта між кадрами необхідно враховувати для забезпечення коректного визначення його присутності та координат у відеопотоці.

Відеопотік має ряд характеристик, які безпосередньо визначають точність і надійність детекції об’єктів. До основних з них належать:

- Частота кадрів (FPS) – при низькій частоті кадрів швидко рухомі об’єкти можуть істотно змінювати своє положення між кадрами, що ускладнює їх коректне відстеження та детекцію. Висока частота кадрів дозволяє точніше фіксувати переміщення об’єктів та забезпечує більш стабільні результати аналізу відеопотоку.
- Роздільна здатність – підвищена роздільна здатність відео забезпечує краще відображення дрібних деталей об’єктів, що сприяє більш точному визначенню їх контурів і розмірів. Низька роздільна здатність може зменшувати ефективність детекції, особливо для невеликих об’єктів.
- Шум і артефакти – цифровий шум сенсора камери, компресія відео та артефакти обробки кадрів можуть призводити до помилкових або спотворених детекцій. Для їх мінімізації застосовують методи попередньої обробки, такі як згладжування, фільтрація шуму та видалення спорадичних спотворень.
- Освітлення та тіні – зміни рівня освітлення, відблиски або тіні впливають на яскравість і контраст об’єктів, ускладнюючи виділення їх меж на кадрі.
- Рухомий фон – наявність рухомих елементів у сцені, таких як коливання листя, потік води або транспортні засоби на задньому плані, створює додаткові візуальні зміни, що ускладнюють виділення об’єктів.

Додатковим фактором, що впливає на ефективність методів детекції об'єктів, є взаємне розташування об'єктів у кадрі та складність сцени:

- Перекриття об'єктів – часткове або повне перекриття одного об'єкта іншим ускладнює точне виділення та відстеження.
- Скупчення об'єктів – велика кількість об'єктів у одному кадрі може призводити до поділу одного об'єкта на декілька детекцій або, навпаки, об'єднання кількох об'єктів в одну детекцію.

Розуміння цих особливостей дозволяє більш обґрунтовано вибирати підходи до детекції, налаштовувати параметри алгоритмів, застосовувати додаткові етапи обробки та забезпечувати коректне формування даних для подальшого аналізу та відстеження.

Шумові детекції та методи їх компенсації

Однією з суттєвих проблем при детекції об'єктів у відеопотоці або на зображеннях є виникнення шумових детекцій, які не відповідають реальним рухомим об'єктам сцени. Теоретично шумові детекції можуть з'являтися внаслідок короткочасних або спорадичних змін інтенсивності пікселів, артефактів компресії відео, випадкових сплесків освітлення або технічних особливостей сенсорів камери.

Короткочасні зміни пікселів – це локальні та тимчасові коливання значень яскравості або кольору пікселів, які можуть виникати внаслідок електронного шуму сенсора камери, коливань сигналу в аналоговій або цифровій обробці, а також через незначні коливання сцени (наприклад, рух повітря або дрібні об'єкти на фоні). Такі зміни зазвичай спостерігаються на одиничних кадрах або протягом дуже короткого часу, що ускладнює їх розпізнавання як шуму без додаткової обробки.

Артефакти компресії відео – виникають у результаті алгоритмів стиснення, які застосовують дискретизацію, квантування та предиктивне кодування пікселів для зменшення об'єму даних. У відео з високим ступенем стиснення можуть з'являтися блокові або кольорові спотворення, зміщення меж об'єктів, а також псевдорухи, які алгоритми детекції можуть помилково трактувати як наявність об'єкта.

Випадкові сплески яскравості – пов’язані з неочікуваними змінами освітлення у сцені, наприклад, відблисками сонця, віддзеркаленнями на блискучих поверхнях або короткочасними включеннями джерел світла. Такі сплески створюють локальні області високої інтенсивності пікселів, які можуть інтерпретуватися детектором як рухомий об’єкт.

Такі артефакти здатні істотно спотворювати результати алгоритмів детекції, оскільки короткочасні відхилення можуть помилково трактуватися як наявність об’єкта. З теоретичної точки зору, для зменшення впливу шуму застосовують різні принципи попередньої обробки відео та зображень. До основних підходів належать:

1. Просторове згладжування – полягає у використанні фільтрів, які усереднюють значення інтенсивності пікселів у сусідніх областях зображення. Це дозволяє зменшити локальні сплески та випадкові варіації, які не відповідають реальним об’єктам. Прикладом таких методів є гаусові фільтри або середньоквадратичне усереднення.
2. Часове згладжування – передбачає аналіз змін пікселів у послідовних кадрах для відсіву короткочасних аномалій. Алгоритми такого типу враховують тривалість появи сигналу: пікселі, що змінюють значення лише на одному або кількох кадрах, можуть ігноруватися як шумові.
3. Медіанне фільтрування – ефективний спосіб видалення спорадичного шуму, який ґрунтується на заміні значення пікселя медіаною сусідніх пікселів. Такий метод добре справляється з одиночними яскравими або темними артефактами, що часто виникають у відеопотоках низької якості або при стиску.
4. Порогові методи для видалення короткочасних сигналів – передбачають встановлення мінімальної тривалості або інтенсивності сигналу, необхідної для його розпізнавання як об’єкта. Це дозволяє ігнорувати короткочасні зміни, які виникають випадково, забезпечуючи більш стабільну детекцію.

Таким чином, на рівні теорії, ефективна компенсація шумових детекцій передбачає комбінацію просторових і часових методів згладжування, а також

застосування статистичних чи порогових критеріїв для відсіву випадкових сигналів. Розуміння цих принципів є ключовим для налаштування алгоритмів детекції та забезпечення стабільності результатів при обробці відеопотоків із різними характеристиками якості та освітлення.

Об'єднання окремих сегментів об'єкту

Один об'єкт у відеопотоці може бути представлений декількома сегментами через різні фактори: нерівномірне освітлення, шум відео, контурні розриви або обмежену роздільну здатність камери. В результаті цього один фізичний об'єкт може бути розпізнаний алгоритмом як декілька окремих частин, що призводить до фрагментованої детекції. Такий випадок ускладнює подальше відстеження об'єктів, аналіз їх траєкторій і поведінки, а також погіршує точність статистичних і класифікаційних моделей.

Для коректного об'єднання розділених сегментів застосовуються різні підходи, які враховують просторові, часові та характеристичні ознаки об'єкта:

1. Близькість сегментів – сегменти об'єкта, що фізично розташовані поряд на кадрі або просторово наближені у послідовності кадрів, можуть бути об'єднані в одну детекцію. Цей підхід базується на принципі, що сегменти одного об'єкта, як правило, не віддалені один від одного на значну відстань. Алгоритми можуть використовувати, наприклад, евклідову відстань між центрами сегментів, а також враховувати розміри і форму сегментів для визначення можливості їх агрегації.
2. Подібність ознак – сегменти одного об'єкта зазвичай мають схожі характеристики: колір, текстуру, інтенсивність або контурні особливості. Аналіз цих ознак дозволяє визначити, які сегменти належать одному об'єкту, навіть якщо вони просторово віддалені через фрагментацію контуру або шум у кадрі. Для цього застосовуються методи порівняння гістограм кольору, дескрипторів текстури, або оцінка схожості контурів.
3. Зв'язність у просторі та часі – враховується безперервність руху об'єкта між кадрами. Сегменти, які зберігають стабільні траєкторії або демонструють узгоджене переміщення у відеопотоці, можуть бути об'єднані в єдину

детекцію. Це дозволяє алгоритму не лише коректно формувати цілі об'єкти на поточному кадрі, а й підтримувати стійкий ідентифікатор об'єкта для подальшого відстеження. Принципи часової зв'язності також застосовуються для відсіювання короткочасних шумових сегментів, які не належать реальним об'єктам.

Об'єднання сегментів є ключовим етапом перед відстеженням об'єктів і формує основу для подальшого аналізу: стабільності ідентифікації, прогнозування траєкторій та оцінки поведінкових моделей. Коректна агрегація забезпечує більш точну детекцію та зменшує кількість помилкових ідентифікаторів, що особливо важливо при роботі зі складними відеопотоками з великою кількістю об'єктів і шумних сцен.

Оцінка впевненості детекції

Параметр впевненості детекції відображає ймовірність того, що визначена детектором область кадру дійсно відповідає реальному об'єкту. Високий показник впевненості сигналізує про ймовірно коректну детекцію, тоді як низький – про можливу помилку або часткову сегментацію. Цей показник є критично важливим для подальшого відстеження, аналізу траєкторій та статистичної обробки результатів.

Для обчислення показника впевненості використовуються різні підходи, що враховують ймовірнісні та характеристичні ознаки об'єкта:

1. Ймовірнісні моделі – алгоритм оцінює ймовірність того, що певна область кадру належить об'єкту, використовуючи статистичні або байєсівські підходи. Наприклад, у методах на основі гаусових сум або глибинних нейронних мереж для кожного сегмента обчислюється ймовірність класу об'єкта. Такі моделі дозволяють формувати узагальнену оцінку впевненості на основі локальних та глобальних ознак сегмента.
2. Аналіз нормалізованих ознак – оцінка ґрунтується на характеристиках сегмента, що відображають його наявність та стабільність:

- Величина оптичного потоку – сегменти з узгодженим рухом між кадрами отримують вищу впевненість, тоді як випадкові зміни інтенсивності знижують її.
 - Контраст контурів – чіткі, стабільні контури сигналізують про реальний об'єкт, слабкі або розмиті зменшують значення впевненості.
 - Статистична значущість сигналу – порівняння локальних змін інтенсивності з фоновими варіаціями дозволяє оцінити ймовірність того, що детекція є суттєвою, а не випадковою.
3. Комбіновані підходи – часто впевненість обчислюється як комплексна метрика, що враховує просторову та часову стабільність сегмента, подібність ознак і якість виділення контурів. Це дозволяє отримати більш надійні значення, особливо у складних або шумних сценах, де короточасні артефакти можуть створювати хибні детекції.

Застосування параметра впевненості дозволяє відсіяти шумові або короточасні спрацьовування; виділити надійні детекції для подальшого відстеження та аналізу; забезпечити стандартизовані результати для збереження у структурованих форматах з координатами, розмірами, ідентифікатором та значенням впевненості; підвищити точність прогнозування траєкторій та поведінкових моделей об'єктів.

Формалізація та структуроване збереження результатів

Після детекції та оцінки впевненості кожного об'єкта важливим етапом є формалізація результатів та їх структуроване збереження для подальшого аналізу. Збереження даних у стандартизованому вигляді дозволяє автоматизувати обробку, спростити відстеження об'єктів у відеопотоці, а також забезпечити коректну роботу алгоритмів класифікації та статистичного аналізу.

Ключові параметри, які необхідно зберігати для детекції кожного об'єкта:

1. Координати – визначають положення об'єкта на кадрі і дозволяють будувати траєкторії руху.

2. Розміри – забезпечують інформацію про масштаб об'єкта та його зміну у часі, що важливо для аналізу наближення/віддалення об'єкта та коректного виділення сегментів.
3. Ідентифікатор об'єкта (ID) – унікальний номер або тег, що дозволяє зберігати послідовність детекцій одного об'єкта між кадрами і підтримувати стабільне відстеження навіть при перекритті або зміні форми.
4. Показник впевненості детекції – значення, що відображає ймовірність того, що детекція відповідає реальному об'єкту; дозволяє відсівати шумові спрацьовування та фільтрувати ненадійні детекції.

Структуроване збереження таких даних забезпечує ефективну інтеграцію з іншими алгоритмами, такими як відстеження, класифікація об'єктів, прогнозування траєкторій або статистичний аналіз поведінки об'єктів у відеопотоці.

Основні формати збереження даних:

1. CSV (Comma-Separated Values) – простий текстовий формат, де кожен рядок відповідає одній детекції, а стовпці містять координати, розміри, ID та впевненість. CSV зручний для швидкого збереження, імпорту в таблиці та обробки у скриптах або аналітичних інструментах.
2. JSON (JavaScript Object Notation) – формат, який дозволяє зберігати дані у вигляді структурованих об'єктів із вкладеними полями. JSON підходить для збереження складніших структур, наприклад, групування детекцій за кадрами або відеопотоками, і забезпечує легку інтеграцію з веб-сервісами та сучасними бібліотеками обробки даних. Принципи структуризації:
 - Кожен кадр повинен містити список усіх детекцій із повним набором параметрів.
 - Для кожної детекції зберігаються координати, розміри, ID та впевненість.
 - При необхідності можна додавати додаткові ознаки об'єкта (клас, швидкість, траєкторія).
 - Формат повинен забезпечувати легкий доступ до даних для автоматизованої обробки алгоритмами відстеження, статистики або візуалізації.

Стандартизоване і структуроване збереження результатів є необхідною умовою для побудови надійних систем аналізу відеопотоків. Воно дозволяє забезпечити відтворюваність досліджень, зменшити кількість помилок у обробці та спростити інтеграцію з іншими аналітичними або навчальними модулями.

Практичне застосування

Автоматична детекція об'єктів у відеопотоці є ключовою технологією сучасних інформаційно-аналітичних систем і знаходить широке застосування в різних сферах, де важлива оперативна та точна інформація про рухомі об'єкти:

1. Відеоспостереження – системи автоматичного моніторингу дозволяють контролювати рух людей і транспортних засобів у громадських місцях, на перехрестях, вокзалах та аеропортах. Детекція об'єктів забезпечує раннє виявлення підозрілих ситуацій, відстеження поведінки відвідувачів або транспортних потоків, а також підтримує функції безпеки, такі як сигналізація при вторгненні у заборонені зони.
2. Аналітика трафіку – у транспортних системах автоматична детекція дозволяє оцінювати інтенсивність руху на дорогах, виявляти скупчення та затори, а також прогнозувати транспортні потоки. Зібрані дані можна використовувати для оптимізації світлофорного регулювання, планування маршрутів та оцінки ефективності транспортної інфраструктури.
3. Автономні транспортні засоби – для роботизованих і автономних автомобілів детекція об'єктів на дорозі є критичною для безпечного пересування. Системи розпізнають пішоходів, транспортні засоби, перешкоди та дорожні знаки, що дозволяє забезпечувати своєчасне прийняття рішень, планування траєкторій і уникнення аварійних ситуацій.
4. Дрони та робототехніка – у сфері безпілотних літальних апаратів та мобільної робототехніки детекція об'єктів дозволяє відстежувати рухомі цілі в реальному часі, виконувати розвідувальні та оглядові місії, а також координувати роботу автономних систем у динамічному середовищі. Точне визначення позицій і швидкостей об'єктів є основою для навігації та планування безпечного маршруту.

5. Спортивна аналітика та поведінкові дослідження – у спортивних системах детекція об’єктів дозволяє аналізувати траєкторії руху гравців або снарядів, оцінювати швидкість та ефективність дій, а також проводити детальні статистичні дослідження. У поведінкових дослідженнях автоматична детекція допомагає відслідковувати взаємодії між об’єктами, моделювати шаблони поведінки та оцінювати ефективність різних сценаріїв.

У всіх зазначених сферах точність детекції безпосередньо впливає на ефективність прийняття рішень та надійність аналітичних висновків.

Наведемо приклад реалізації одного з підходів до детекції об’єктів – виділення контурів та морфологічні операції. Такий метод дозволяє виявляти об’єкти на кадрах відео, усувати шумові детекції та об’єднувати розділені частини об’єктів. Приклад псевдокоду у стилі Python, який ілюструє логіку роботи алгоритму:

```
def detect_objects_contours(video):
    for frame in video:
        # Перетворення кадру у відтінки сірого
        gray_frame = convert_to_grayscale(frame)

        # Порогова бінаризація (виділення об’єктів)
        binary_mask = empty_matrix(frame.width, frame.height)
        for x in range(frame.width):
            for y in range(frame.height):
                if gray_frame[x,y] > threshold:
                    binary_mask[x,y] = 1
                else:
                    binary_mask[x,y] = 0

        # Морфологічні операції для усунення шуму
        binary_mask = dilation(binary_mask, iterations=1) #розширення
        binary_mask = erosion(binary_mask, iterations=1) #стискання
        binary_mask = closing(binary_mask, iterations=1) # закриття
        binary_mask = opening(binary_mask, iterations=1) # відкриття

        # Пошук контурів
        contours = find_contours(binary_mask)
```

```
# Збереження об'єктів
for contour in contours:
    x, y, width, height = bounding_box(contour)
    save_result(frame.number, x, y, width, height)
```

Перетворення зображення у відтінки сірого дозволяє спростити обробку, аналізуючи лише інтенсивність пікселів. Порогова бінаризація визначає, чи пікселі належать об'єкту або фону. Морфологічні операції об'єднують розділені частини об'єктів і усувають шум. Пошук контурів виділяє окремі об'єкти у кадрі, а їх координати та розміри зберігаються для подальшого аналізу або відстеження.

ЗАВДАННЯ ДЛЯ ВИКОНАННЯ

Загальні умови

- Предметна область: динамічні об'єкти у відеопотоках або серіях зображень.
- Вхідні дані: відео тривалістю 30-60 секунд або серія 50-100 кадрів.
- Кількість об'єктів на кадр: 3-6.
- Об'єкти мають перекриватися та змінювати швидкість і форму принаймні на трьох кадрах.
- Вихідні дані: CSV/JSON (ID кадру, ID об'єктів, координати, розмір, швидкість, напрям руху)
- Приклади наборів даних для використання: MOTChallenge, UA-DETRAC, KITTI Tracking, UCSD Pedestrian Dataset, VisDrone, Oxford Town Centre Dataset, Stanford Drone Dataset, DTB70 Drones for Object Tracking.

Етапи виконання лабораторної роботи

1. Детектувати об'єкти на кожному кадрі.

Реалізувати програмний алгоритм, який автоматично завантажує відеофайл або серію кадрів, послідовно опрацьовує кожен кадр та виконує на ньому детекцію об'єктів. Програма має забезпечувати коректне зчитування даних у форматі, придатному для подальшої обробки, застосовувати вибраний метод виявлення об'єктів та повертати для кожного кадру список знайдених областей. Для кожної

детекції необхідно автоматично визначати координати та розміри обмежувального прямокутника, формуючи результат, придатний для подальших етапів обробки.

2. Усунути шумові детекції на кожному кадрі.

Додати до програми реалізацію алгоритму, який аналізує результати детекції на кожному кадрі та виявляє області, що не відповідають реальним об'єктам. Фільтрація може враховувати тривалість появи детекції в послідовності кадрів, її розмір, стабільність положення та інтенсивність змін. Програма має автоматично відкидати короточасні або випадкові спрацьовування, які з'являються лише на одному або кількох кадрах і не мають просторово-часової узгодженості з рухомими об'єктами сцени. Це забезпечить очищення потоку від помилкових детекцій перед подальшими етапами обробки.

3. Об'єднати окремі сегменти одного об'єкта в єдину детекцію.

Додати до програми реалізацію алгоритму, який аналізує множину детекцій на одному кадрі та визначає, чи належать окремі знайдені області до одного й того самого об'єкта. Якщо кілька сегментів мають значний ступінь перекриття або розташовані так, що логічно утворюють один об'єкт, програма повинна автоматично об'єднувати їх у спільну детекцію. Після об'єднання потрібно повторно обчислити координати (x, y) та розміри інтегрованого обмежувального прямокутника, щоб отримати коректне представлення об'єкта для подальших етапів аналізу.

4. Додати параметр впевненості для кожної детекції.

Додати до програми реалізацію алгоритму, який для кожної детекції автоматично обчислює числовий показник впевненості. Програмно інтегрувати цей параметр у структуру результатів кожної детекції та забезпечити можливість його подальшого використання для фільтрації або ранжування об'єктів. Значення впевненості має автоматично формуватися для кожного обмежувального прямокутника та зберігатися разом з іншими атрибутами детекції.

5. Зберегти результати у CSV/JSON.

Додати до програми реалізацію алгоритму, який автоматично формує структуровані вихідні дані після завершення обробки всіх кадрів. Для кожної

детекції необхідно записати номер кадру, унікальний ID об'єкта, координати, розміри та обчислену впевненість. Результати зберігати в одному з форматів файлів: CSV або JSON. У разі JSON потрібно забезпечити вкладену структуру записів, а у випадку CSV зберегти таблицю з чітко визначеними стовпцями.

Вимоги до звіту

1. Титульний лист.
2. Лист завдання.
3. Опис ходу виконання кожного завдання лабораторної роботи з переліком використаних функцій мови програмування та аналізом отриманих результатів.
4. Лістинг програми з коментарями до ключових частин коду.
5. Скриншоти результатів виконання програми на кожному етапі роботи.
6. Висновки.

Для отримання оцінки за лабораторну роботу обов'язковими є захист роботи та виконання звіту. За умов, коли роботу не захищено та/або звіт відсутній, лабораторна робота не зараховується.

Питання для самоконтролю

1. Для яких задач використовується детекція об'єктів у відеопотоці?
2. Які типи динамічних об'єктів найчастіше підлягають детекції?
3. У чому полягають основні складності детекції об'єктів у відео?
4. Чому перекривання об'єктів ускладнює роботу алгоритмів детекції?
5. Як впливають зміни масштабу та освітлення на точність виявлення?
6. Що таке шумові детекції та чому їх необхідно фільтрувати?
7. Яку роль відіграє стабільність фону та освітлення у методах детекції?
8. У чому суть методу віднімання фону і які його обмеження?
9. Які морфологічні операції застосовують для покращення сегментації?
10. У яких випадках гібридні методи детекції є більш ефективними?

ЛАБОРАТОРНА РОБОТА №2. ВІДСТЕЖЕННЯ ДИНАМІЧНИХ ОБ'ЄКТІВ, ФОРМУВАННЯ ТА КОРЕКЦІЯ ЇХ ТРАЄКТОРІЙ У ВІДЕОПОТОЦІ

Мета: навчитися автоматично відстежувати об'єкти у відеопотоці, усувати шумові траєкторії, об'єднувати розірвані траєкторії при перекриттях, відновлювати відсутні положення об'єктів та обчислювати параметри їх руху.

ТЕОРЕТИЧНІ ВІДОМОСТІ

Відстеження динамічних об'єктів у відеопотоці є ключовою задачею комп'ютерного зору, що забезпечує можливість аналізу руху, побудови моделей поведінки та виявлення аномалій. На відміну від детекції, яка визначає положення об'єктів у кожному окремому кадрі, відстеження передбачає встановлення відповідності між детекціями у різних кадрах, формування траєкторій та оцінку параметрів руху. Основна мета відстеження полягає у збереженні унікальної ідентичності кожного об'єкта протягом часу, навіть за умов перекриття, часткової втрати видимості, зміни масштабу або ракурсу.

Відеопотік може містити значну кількість динамічних об'єктів, що рухаються з різними швидкостями та взаємодіють між собою. Це створює низку складнощів, які необхідно враховувати при розробці алгоритмів відстеження:

1. Перекриття об'єктів – під час руху об'єкти можуть частково або повністю перекриватися, що призводить до втрати стабільної детекції або розриву траєкторії.
2. Шумові траєкторії – короточасні помилкові детекції можуть створювати хибні треки, які необхідно фільтрувати або видаляти.
3. Розриви у траєкторіях – унаслідок втрати детекції через зміну освітлення, ракурсу або високої швидкості руху траєкторії можуть містити пропуски.
4. Зміна швидкості та напрямку руху – динамічні об'єкти можуть прискорюватися, сповільнюватися або різко змінювати траєкторію.

5. Схожість об'єктів – у сценах з кількома однотипними об'єктами виникає ризик невірної асоціації траєкторій траєкторій та втрати унікальних ідентифікаторів.

Ефективне відстеження об'єктів передбачає застосування алгоритмів зіставлення детекцій між кадрами, прогнозування положень об'єктів, а також корекції та об'єднання траєкторій після тимчасових втрат видимості.

Методи відстеження об'єктів у відеопотоці

Методи відстеження об'єктів поділяються на кілька груп залежно від підходу до обробки даних, використання моделей руху та здатності адаптуватися до змін середовища. Основні групи включають:

1. Методи на основі зіставлення детекцій між кадрами – базуються на пошуку максимальної відповідності між положеннями об'єктів у поточному та попередньому кадрах, використовуючи просторові та візуальні ознаки, наприклад, відстань між центрами об'єктів, подібність розмірів або колірних гістограм. Такі підходи забезпечують просте та швидке зіставлення, проте є чутливими до різких змін позиції або перекриття об'єктів.
2. Методи прогнозування траєкторій (фільтри стану) – застосовують математичні моделі руху, зокрема фільтр Калмана або частинковий фільтр, для прогнозування наступного положення об'єкта та корекції траєкторії на основі нових спостережень. Фільтри стану дозволяють згладжувати траєкторії, відновлювати пропущені позиції та підвищувати стійкість до шуму.
3. Методи оптимального зіставлення детекцій та треків – алгоритми, такі як угорський алгоритм (алгоритм Куна-Мункреса), мінімізують сумарну вартість зіставлення між прогнозованими позиціями та фактичними детекціями. Це забезпечує стабільність траєкторій та збереження унікальних ID об'єктів, навіть коли кілька об'єктів розташовані близько один до одного.
4. Методи на основі ознак зовнішнього вигляду об'єктів – у складних сценах додатково використовуються ознаки форми, текстури або локальні дескриптори об'єкта. Наприклад, в алгоритмі DeepSORT траєкторії

коригуються за допомогою векторів ознак, що дозволяє уникнути помилкової ідентифікації схожих об'єктів.

5. Гібридні методи – поєднують класичні та сучасні підходи, наприклад прогнозування за допомогою фільтру Калмана разом з аналізом ознак зовнішнього вигляду через нейронні мережі. Такі методи забезпечують високу точність і стійкість до перекриттів, зміни швидкості руху та тимчасової втрати видимості об'єктів.

На практиці відстеження об'єктів також передбачає обробку та корекцію траєкторій: видалення короткочасних або шумових треків, об'єднання сегментів однієї траєкторії після перекриття та згладжування руху за допомогою фільтрів або регресійних моделей.

Розглянемо більш детально деякі алгоритми, що використовуються для відстеження об'єктів. Серед класичних підходів до вирішення завдання відстеження об'єктів особливе місце займає SORT (Simple Online and Realtime Tracking). Цей алгоритм поєднує прогнозування положень об'єктів за допомогою фільтру Калмана та оптимальне зіставлення прогнозованих позицій із новими детекціями за угорським алгоритмом.

Фільтр Калмана є статистичним методом оцінки стану системи, що змінюється з часом, на основі послідовних спостережень із шумом. У контексті відстеження об'єктів він прогнозує наступне положення об'єкта на основі його попередньої позиції та моделі руху, а потім коригує прогноз за допомогою нових спостережень. Це дозволяє згладжувати траєкторії, відновлювати пропущені позиції та зменшувати вплив шуму на оцінку руху об'єкта. Завдяки цьому фільтр Калмана підвищує точність відстеження навіть за умов неточних детекцій та тимчасової втрати видимості об'єкта.

Угорський алгоритм (алгоритм Куна-Мункреса) застосовується для оптимального зіставлення прогнозованих положень об'єктів із фактичними детекціями на новому кадрі. Він формалізує задачу як мінімізацію сумарної вартості відповідностей між прогнозованими та фактичними позиціями об'єктів. Завдяки цьому алгоритму кожен об'єкт отримує унікальний ідентифікатор, а

ймовірність помилкового присвоєння детекцій різним об'єктам значно зменшується, навіть коли об'єкти розташовані близько один до одного або перекриваються.

Поєднання цих двох методів у SORT дозволяє ефективно видаляти короткочасні шумові траєкторії, підтримувати стабільність ідентифікаторів об'єктів та забезпечує високу швидкість роботи та простоту реалізації. Проте алгоритм залишається чутливим до схожих об'єктів і тривалих перекриттів, що згодом частково компенсується у розширеному варіанті підходу DeepSORT.

DeepSORT доповнює класичний SORT використанням ознак зовнішнього вигляду об'єктів. Для цього застосовуються векторні представлення об'єктів або ознак, отримані з нейронної мережі, що дозволяє уникнути плутанини схожих об'єктів та підвищує стабільність збереження унікальних ідентифікаторів. Алгоритм DeepSORT поєднує прогнозування за допомогою фільтру Калмана та оптимальне зіставлення з використанням угорського алгоритму, що забезпечує високу точність відстеження навіть за умов перекриття та зміни зовнішнього вигляду об'єктів. Основним обмеженням цього підходу є значна обчислювальна складність та потреба у попередньому навчанні моделі для формування ознак.

Інший підхід до відстеження представлений IOU Tracker, який базується на оцінці коефіцієнта перекриття обмежувальних прямокутників між детекціями та існуючими траєкторіями. Для кожного нового кадру детекції зіставляються з наявними треками на основі максимального перекриття. Якщо перекриття не досягає заданого порога, створюється нова траєкторія. Цей метод характеризується простотою та ефективністю для невеликих або середніх сцен, проте не враховує швидкість і напрямок руху об'єктів і є чутливим до перекриттів.

Для більш складних рухів і нелінійних траєкторій застосовуються частинкові фільтри. Цей підхід використовує множину частинок для апроксимації ймовірного розподілу положень об'єкта. Кожна частинка прогнозує можливе положення, після чого обчислюється її вага відповідно до відповідності детекції. Траєкторія об'єкта формується як середнє зважене положень частинок, що дозволяє

точно відстежувати об'єкти зі складними рухами, проте обчислювальна складність зростає при великій кількості об'єктів.

Метод центроїдного трека належить до простих, але ефективних алгоритмів відстеження об'єктів, які працюють на основі координат центроїдів детектованих об'єктів. Основна ідея полягає в тому, що для кожного об'єкта на кадрі обчислюється його центроїд, після чого в наступному кадрі цей центроїд зіставляється з найбільш близьким центроїдом серед нових детекцій. Для пошуку відповідностей зазвичай використовується матриця евклідових відстаней та алгоритм найближчого сусіда або оптимальні методи зіставлення, такі як угорський алгоритм. Якщо між кадрами об'єкт не знайдено, трек не видаляється одразу – вводиться лічильник, який дозволяє зберегти об'єкт певну кількість кадрів у разі тимчасової втрати видимості. Центроїдний трекер добре працює для сцен з помірною кількістю об'єктів, стабільним рухом і відносно чіткими детекціями, але не враховує деформації, повороти чи складну динаміку об'єктів. Метод широко використовується в системах з обмеженими обчислювальними ресурсами, оскільки не потребує глибоких моделей і має високу швидкість роботи.

Методи оптичного потоку (наприклад, Lucas-Kanade, Farnebäck) базуються на припущенні, що інтенсивність пікселя на зображенні залишається приблизно сталою між двома послідовними кадрами, а зміни у зображенні обумовлені переміщенням об'єктів. Такий підхід дозволяє оцінити поле векторів руху для кожної точки або області на кадрі.

Метод Lucas-Kanade є локальним підходом, який передбачає, що рух у невеликому вікні навколо пікселя є приблизно однаковим. При використанні цього методу розв'язується система рівнянь, що описує зміни інтенсивності, та оцінює вектор руху для кожного ключового пікселя. Такий підхід дозволяє точно відстежувати текстуровані ділянки сцени, наприклад кути чи особливості, що добре контрастують. Lucas-Kanade ефективний, швидкий і широко використовується у реальному часі.

Метод Farnebäck є глобальним підходом до оптичного потоку. Він використовує апроксимацію інтенсивності пікселя багатовимірним поліномом, що

дозволяє отримати щільне поле оптичного потоку для всього зображення. У результаті утворюється карта руху з вектором для кожного пікселя, що дає змогу застосовувати його для деталей високої точності: аналізу деформацій, жестів, мікрорухів, нелінійних траєкторій. Farnebäck працює повільніше за Lucas-Kanade, але надає значно багатші дані про динаміку сцени.

Методи оптичного потоку часто комбінуються з детекторами об'єктів і трекерами, забезпечуючи точнішу оцінку руху між кадрами, особливо коли детекції не виконуються на кожному кадрі або коли необхідно поліпшити плавність траєкторій.

Також ефективним методом є відстеження на основі фільтрів кореляції. Для визначення положення об'єкта на наступному кадрі створюється шаблон, який корелюється з поточним кадром для знаходження максимальної відповідності. Цей підхід підходить для відстеження в реальному часі та об'єктів із відносно стабільним зовнішнім виглядом, але є чутливим до змін масштабу, освітлення і часткових перекриттів.

У практичному застосуванні сучасні алгоритми відстеження часто поєднують кілька з наведених методів, що дозволяє компенсувати обмеження окремих підходів, підвищити точність відстеження, забезпечити стійкість траєкторій при перекриттях та тимчасовій втраті видимості об'єктів.

Корекція та обробка траєкторій руху об'єктів

Після відстеження об'єктів у відеопотоці наступним важливим етапом є корекція та обробка траєкторій для забезпечення їхньої безперервності та точності. Однією з основних проблем цього етапу є наявність короткочасних шумових треків, які виникають через помилкові детекції або випадкові спостереження, не пов'язані з реальними об'єктами сцени. Шумові траєкторії представляють собою треки, що з'являються через випадкові детекції або артефакти відеоаналізу. Вони зазвичай мають коротку тривалість, хаотичне переміщення та не відповідають загальній динаміці об'єктів сцени.

Для виявлення та видалення шумових траєкторій використовують кілька взаємодоповнюючих методів, що дозволяють підвищити точність і надійність

відстеження. Один із найбільш поширених підходів – фільтрація за довжиною траєкторії. Ідея цього методу полягає в тому, що короточасні треки, які існують менше певного числа кадрів, зазвичай є результатом помилкових детекцій або випадкових артефактів відеопотоку, а не реальними об'єктами. Такі треки автоматично виключаються з подальшого аналізу, що дозволяє зменшити кількість хибних траєкторій і звільнити ресурси для обробки справжніх об'єктів.

Додатково застосовується порогова оцінка стабільності руху об'єкта. Цей метод передбачає аналіз послідовних координат об'єкта та порівняння їх із фізично можливим або очікуваним рухом. Якщо положення об'єкта змінюються хаотично, різко стрибкоподібно або суперечать передбачуваній траєкторії, відповідний трек позначається як шумовий і видаляється. Така оцінка часто базується на аналізі швидкості та прискорення об'єкта, а також на порівнянні напрямків руху між послідовними кадрами.

Для підвищення точності також застосовується метод порівняння з іншими траєкторіями. Цей підхід полягає у зіставленні коротких або нестабільних треків із сусідніми або раніше зафіксованими траєкторіями, які демонструють узгоджений рух. Якщо аналіз показує, що трек не відповідає жодній логічній послідовності руху, він розглядається як шумовий і виключається. У деяких системах цей метод доповнюється оцінкою зовнішніх ознак об'єкта, наприклад кольору або текстури, щоб уникнути помилкового відкидання треків, що належать реальним об'єктам, але тимчасово змінюють зовнішній вигляд через освітлення або ракурс камери.

У комплексі ці методи дозволяють ефективно відокремлювати справжні об'єкти від випадкових детекцій, забезпечувати логічну послідовність ідентифікаторів та підвищувати точність подальшого аналізу руху у відеопотоці. Такий підхід особливо важливий у сценах з великою кількістю динамічних об'єктів, де хаотичні або короточасні детекції можуть істотно спотворювати результати відстеження.

Наступною ключовою проблемою при відстеженні об'єктів є розрив траєкторій, що виникає у випадках тимчасової втрати об'єкта з поля зору камери або при частковому перекритті іншими об'єктами. Такі розриви створюють

прогалини у послідовності координат і ускладнюють збереження унікального ідентифікатора об'єкта. Для відновлення сегментованих траєкторій застосовують методи прогнозування руху, що базуються на фільтрах стану, які дозволяють оцінити ймовірне положення об'єкта навіть у відсутності прямих спостережень.

Найпоширенішим підходом є використання фільтра Калмана. Цей статистичний метод передбачає побудову моделі руху об'єкта та прогнозування його наступної позиції на основі попередніх координат і швидкості. Коли нові детекції стають доступними, фільтр здійснює корекцію прогнозованого положення, згладжуючи випадкові коливання та шум у траєкторії. Завдяки цьому забезпечується безперервність руху об'єкта та підвищується точність відстеження навіть при неточних або пропущених детекціях.

Для більш складних сценаріїв, коли рух об'єктів є нелінійним або траєкторії мають значні перериви, застосовують частинковий фільтр. Він моделює ймовірнісний розподіл можливих положень об'єкта за допомогою множини частинок, кожна з яких представляє потенційне положення. Після отримання нових детекцій обчислюються ваги кожної частинки відповідно до того, наскільки добре її положення відповідає спостережуваному кадру. Після цього здійснюється ресемплінг, який дозволяє зосередити обчислювальні ресурси на найбільш ймовірних позиціях. Такий підхід дозволяє відновлювати траєкторії навіть у складних умовах із тривалими перекриттями, різкими змінами швидкості та напрямку руху, а також забезпечує більшу стійкість до шумових детекцій у порівнянні з класичним фільтром Калмана.

Комплексне використання фільтра Калмана для лінійних або відносно передбачуваних рухів разом із частинковим фільтром для складних сценаріїв дозволяє досягати високої точності відновлення траєкторій, підтримувати безперервність ідентифікаторів об'єктів та підвищувати надійність систем відстеження у реальному часі.

Для підвищення точності корекції траєкторій також часто застосовується комбінований підхід: прогнозування положень об'єктів фільтром Калмана поєднується із зіставленням траєкторій за критерієм найближчої відповідності або

максимальної схожості, що дозволяє об'єднувати окремі сегменти траєкторій і зберігати унікальні ідентифікатори об'єктів. Крім того, використовуються методи згладжування координат, такі як ковзне середнє або регресійні моделі, які зменшують вплив шуму на відновлені траєкторії та забезпечують більш природний рух об'єктів у відеопотоці. Ці методи дозволяють усувати різкі стрибки координат, що виникають через неточні детекції або випадкові коливання в позиціях об'єктів, і створюють плавну траєкторію, яка відповідає реальній динаміці руху. Використання ковзного середнього забезпечує просте та ефективне згладжування короткочасних шумів, тоді як регресійні моделі дозволяють враховувати загальну тенденцію руху об'єкта, передбачати його майбутні позиції та коригувати траєкторію у випадках швидких змін швидкості чи напрямку. У складніших сценаріях застосовують адаптивні або гаусові регресійні методи, які більш точно моделюють нелінійні рухи та зменшують вплив випадкових помилок на загальний аналіз поведінки об'єктів у відеопотоці. Комплексний підхід до прогнозування та згладжування координат значно підвищує надійність відстеження та забезпечує природне відтворення рухів у системах комп'ютерного зору.

Об'єднання сегментів траєкторії одного об'єкта є важливим завданням, оскільки у відеопотоці траєкторії об'єктів часто розриваються через тимчасову втрату видимості, перекриття іншими об'єктами, зміни освітлення або короткочасні помилкові детекції. Розбиті на сегменти траєкторії не дозволяють правильно оцінити повний шлях руху об'єкта та можуть призвести до дублювання ідентифікаторів, що знижує точність аналізу динаміки сцени.

Процес об'єднання сегментів передбачає пошук логічної відповідності між кінцем однієї траєкторії та початком іншої. Для цього зазвичай застосовують комбінацію кількох критеріїв:

- Просторову близькість – оцінюється відстань між останньою точкою сегмента і потенційними наступними точками інших сегментів;
- Часову сумісність – перевіряється, чи не перевищує інтервал між сегментами допустимий проміжок часу, протягом якого об'єкт міг бути тимчасово не видимим;

- Схожість руху – враховується напрямок і швидкість руху, порівнюються вектори швидкості в кінці одного сегмента та на початку іншого;
- Візуальні ознаки об'єкта – при наявності інформації про колір, текстуру або ознаки зовнішнього вигляду оцінюється, чи належать сегменти одному й тому ж об'єкту.

Після визначення найбільш ймовірного зв'язку між сегментами здійснюється їхнє злиття в єдину неперервну траєкторію, при цьому координати можуть додатково згладжуватися методами ковзного середнього або регресійними моделями для усунення різких стрибків і забезпечення природного руху. У складніших системах застосовуються адаптивні алгоритми об'єднання, які враховують динамічні зміни швидкості та напрямку руху, а також ймовірнісні моделі на кшталт частинкових фільтрів для більш точного з'єднання сегментів у випадках тривалих перекриттів або складних нелінійних траєкторій.

Об'єднання сегментів траєкторії є критичним для збереження унікальних ідентифікаторів об'єктів, підвищення точності аналітичних показників руху та коректного подальшого аналізу поведінки об'єктів у відеопотоці. Цей етап особливо важливий у сценах з великою кількістю динамічних об'єктів, де часті перекриття та тимчасові втрати видимості можуть значно спотворювати результати відстеження.

Аналіз параметрів руху об'єктів

Наступним важливим кроком після етапу корекції та обробки траєкторій об'єктів є детальний аналіз параметрів руху, який дозволяє кількісно оцінити динаміку кожного об'єкта у відеопотоці. Основними характеристиками руху є швидкість, напрямок, довжина та форма траєкторії, а також прискорення та додаткові векторні характеристики, які допомагають описати поведінку об'єкта у просторі та часі.

Швидкість об'єкта $\vec{v}$ визначається як відношення зміни координат до інтервалу часу між кадрами. Для двовимірної траєкторії $(x(t), y(t))$ швидкість на кадрі t можна обчислити за формулами:

$$v_x(t) = \frac{x(t) - x(t-1)}{\Delta t}, v_y(t) = \frac{y(t) - y(t-1)}{\Delta t},$$

де Δt – час між кадрами (часто це обернена величина частоти кадрів відео, наприклад, 1/30 с для 30 fps). Вектор швидкості обчислюється як:

$$\vec{v}(t) = (v_x(t), v_y(t)),$$

а його величина, тобто модуль швидкості, визначається як:

$$|\vec{v}(t)| = \sqrt{v_x(t)^2 + v_y(t)^2}.$$

Величина швидкості дозволяє оцінити інтенсивність руху об'єкта, виявляти моменти зупинки, прискорення або уповільнення, а також фіксувати аномальні зміни, які можуть вказувати на несподівані події у сцені або помилки детекції. Наприклад, різке зростання швидкості між двома кадрами може сигналізувати про пропущений кадр або артефакт відео.

Напрямок руху $\theta(t)$ визначається як кут між віссю X і вектором зміни координат, що описує переміщення об'єкта між кадрами. Він обчислюється за формулою:

$$\theta(t) = \arctan 2(v_y(t), v_x(t)),$$

де функція $\arctan 2$ враховує знак обох координат, щоб правильно визначити кут у всіх чотирьох квадрантах. Напрямок руху дозволяє не лише відстежувати зміну курсу об'єкта, але й прогнозувати його подальшу траєкторію. При аналізі сцени з багатьма об'єктами напрямки руху дозволяють визначати взаємодію об'єктів, їх зближення або розходження, а також відстежувати нестандартні шаблони поведінки.

Довжина траєкторії L обчислюється як сума відстаней між послідовними координатами об'єкта на всьому проміжку спостереження:

$$L = \sum_{t=1}^{N-1} \sqrt{(x(t+1) - x(t))^2 + (y(t+1) - y(t))^2},$$

де N – кількість кадрів, у яких об'єкт був відстежений. Цей параметр дозволяє оцінити повний шлях, пройдений об'єктом, визначати активність та порівнювати

поведінку різних об'єктів. Довжина траєкторії також може слугувати основою для кластеризації рухів, пошуку типових маршрутів та виявлення аномалій, таких як об'єкти, що раптово змінюють траєкторію або рухаються нетиповим шляхом.

Форма траєкторії та її кривизна κ описують характер руху і дозволяють оцінювати, наскільки траєкторія відхиляється від прямолінійного руху. Кривизна в кожній точці може обчислюватися як:

$$\kappa(t) = \frac{|x'(t)y''(t) - y'(t)x''(t)|}{(x'(t)^2 + y'(t)^2)^{\frac{3}{2}}},$$

де $x'(t), y'(t)$ – перші похідні координат по часу (тобто компоненти швидкості), а $x''(t), y''(t)$ – другі похідні (компоненти прискорення). Кривизна дозволяє виявляти зигзагоподібні або кругові рухи, а також різкі маневри, що важливо для аналізу поведінки об'єктів, наприклад у відеоспостереженні людей або транспортних засобів.

Прискорення $\vec{a}(t)$ розраховується як зміна вектора швидкості між двома послідовними кадрами:

$$\vec{a}(t) = \frac{\vec{v}(t) - \vec{v}(t-1)}{\Delta t}, |\vec{a}(t)| = \sqrt{a_x(t)^2 + a_y(t)^2}.$$

Аналіз прискорення дозволяє визначати моменти різкого збільшення або зниження швидкості, що є важливим для виявлення аномалій у поведінці об'єктів або для точного прогнозування подальшого руху.

У практичних системах обчислення швидкості та напрямку часто доповнюється застосуванням методів інтерполяції та згладжування, таких як ковзне середнє або регресійні моделі, для усунення впливу випадкових шумів або пропущених кадрів. Наприклад, для інтерполяції координат у кадрах без детекції застосовують лінійну інтерполяцію:

$$x(t) = x(t_0) + \frac{t - t_0}{t_1 - t_0} \cdot (x(t_1) - x(t_0)), y(t) = y(t_0) + \frac{t - t_0}{t_1 - t_0} \cdot (y(t_1) - y(t_0)),$$

де t_0 і t_1 – кадри з наявними детекціями, а t – кадр без детекції. Такий підхід дозволяє зберігати безперервність траєкторій і отримувати більш точні оцінки швидкості та прискорення, навіть якщо об'єкт тимчасово зник із поля зору.

У системах з великою кількістю об'єктів обчислені параметри руху використовують для побудови аналітичних графіків і візуалізацій. Векторні графіки швидкості та напрямку дозволяють наочно відобразити рух об'єктів у сцені, графіки прискорення показують динаміку зміни швидкості, а кривизна траєкторії дозволяє оцінити характер маневрів. Такі візуалізації корисні як для дослідницьких задач, так і для автоматизованого аналізу відеопотоків, наприклад, у системах безпеки або транспортного моніторингу.

Векторна швидкість, напрямок руху, довжина, форма траєкторії та прискорення формують комплексну характеристику поведінки об'єкта, дозволяючи не лише відстежувати його рух у реальному часі, але й проводити прогнозування, класифікацію типів руху та виявлення аномалій. Комбіноване використання математичних формул, інтерполяції та графічного аналізу забезпечує точність і надійність систем комп'ютерного зору, відеоспостереження та аналітики динамічних сцен.

Практичне застосування

Розглянемо приклад реалізації підходу до виявлення аномальної поведінки, який поєднує центроїдне відстеження об'єктів та оцінку їхнього руху на основі оптичного потоку. Приклад псевдокоду у стилі Python:

```
def track_objects(video):
    previous_frame = None
    object_id_counter = 0
    objects = {} # словник ID -> центроїд

    for frame_number, frame in enumerate(video):
        gray_frame = convert_to_grayscale(frame)

        # Отримання детекцій об'єктів (наприклад, контури)
        detections = detect_objects_contours(frame)

        # Якщо це перший кадр
        if previous_frame is None:
            for det in detections:
                x, y, w, h = bounding_box(det)
                objects[object_id_counter] = centroid(x, y, w, h)
                object_id_counter += 1
        else:
            # Обчислення оптичного потоку між попереднім і поточним кадром
```

```

flow = compute_optical_flow(previous_frame, gray_frame)

# Оновлення позицій об'єктів за центроїдами і вектором руху
for obj_id, center in objects.items():
    dx, dy = estimate_displacement(flow, center)
    new_center = (center[0]+dx, center[1]+dy)
    objects[obj_id] = new_center

# Зіставлення нових детекцій з оновленими центроїдами
for det in detections:
    det_center = centroid(*bounding_box(det))
    matched_id = match_to_existing(objects, det_center)
    if matched_id is None:
        objects[object_id_counter] = det_center
        object_id_counter += 1

previous_frame = gray_frame.copy()

```

Детекції об'єктів отримуються за допомогою виділення контурів і морфологічних операцій, що дозволяє усунути шум і об'єднати розділені частини об'єктів. Центроїдний трекер забезпечує підтримку унікальних ID і логічне об'єднання сегментів траєкторії після тимчасової втрати об'єкта. Метод оптичного потоку дозволяє оцінювати вектор переміщення кожного об'єкта між кадрами, навіть якщо детекції не збігаються точно за центроїдом. Комбінація цих методів дає змогу отримувати неперервні траєкторії, визначати параметри руху і підвищувати точність подальшого аналітичного аналізу відеопотоку.

ЗАВДАННЯ ДЛЯ ВИКОНАННЯ

Загальні умови

Лабораторна робота №2 виконується на основі лабораторної роботи №1 та є її логічним продовженням, тому загальні умови залишаються незмінними.

Етапи виконання лабораторної роботи

1. Відстежити всі об'єкти у кожному кадрі.

Реалізувати програмний алгоритм, який автоматично обробляє відеофайл або серію кадрів та відстежує всі об'єкти, що були детектовані у лабораторній

роботі №1. Програма має підтримувати унікальні ID для кожного об'єкта протягом всього відео та забезпечувати послідовну прив'язку детекцій до об'єктів.

2. Усунути короточасні або шумові траєкторії.

Додати до програми реалізацію алгоритму фільтрації, який аналізує рух об'єктів і відкидає траєкторії, що виникли короточасно або не відповідають реальному руху об'єкта (наприклад, випадкові спрацьовування або нестабільні позиції).

3. Об'єднати сегменти траєкторії руху одного об'єкта.

Програмно визначати випадки, коли одна траєкторія об'єкта переривається або розбивається на декілька сегментів через часткове перекриття або шумові ефекти, і об'єднати ці сегменти в єдину неперервну траєкторію, зберігаючи коректний ID об'єкта.

4. Відновити траєкторії об'єктів у кадрах, де вони не були детектовані.

Реалізувати алгоритм, який відновлює неперервність траєкторій об'єктів у кадрах, де вони не були детектовані, на основі даних про позиції об'єктів з попередніх та наступних кадрів.

5. Обчислити швидкість та напрямок руху об'єктів.

Для кожного об'єкта обчислити вектор швидкості та напрямок руху на основі зміни координат між послідовними кадрами.

6. Зберегти результати у CSV/JSON.

Після завершення обробки формувати структурований файл у форматі CSV або JSON, де для кожного кадру фіксуються: унікальний ID об'єкта, координати (x, y), швидкість та напрям руху.

Вимоги до звіту

1. Титульний лист.
2. Лист завдання.
3. Опис ходу виконання кожного завдання лабораторної роботи з переліком використаних функцій мови програмування та аналізом отриманих результатів.
4. Лістинг програми з коментарями до ключових частин коду.

5. Скриншоти результатів виконання програми на кожному етапі роботи.
6. Висновки.

Для отримання оцінки за лабораторну роботу обов'язковими є захист роботи та виконання звіту. За умов, коли роботу не захищено та/або звіт відсутній, лабораторна робота не зараховується.

Питання для самоконтролю

1. Що таке шумова траєкторія у відеопотоці і які основні методи її виявлення та вилучення?
2. Поясніть, чому короточасні треки зазвичай вважаються шумовими, і як фільтрація за довжиною траєкторії допомагає підвищити точність відстеження.
3. Які критерії використовують для виділення та видалення нестабільних траєкторій об'єктів на основі їхньої швидкості, прискорення та напрямку руху?
4. Опишіть, що таке розрив траєкторії і як методи прогнозування допомагають відновити неперервність руху об'єкта.
5. Поясніть принцип об'єднання сегментів траєкторії одного об'єкта та які критерії використовуються для визначення логічної відповідності сегментів.
6. Як застосовуються методи згладжування координат (ковзне середнє, регресійні моделі, адаптивні методи) для поліпшення якості траєкторій і чому це важливо для точного аналізу руху?
7. Як обчислюється вектор швидкості об'єкта між двома кадрами та які формули використовуються для визначення компонентів швидкості і її модуля?
8. Як визначається напрямок руху об'єкта у вигляді кута або вектора?
9. Поясніть, як обчислюються довжина траєкторії та кривизна руху об'єкта, і яке значення мають ці параметри для аналізу характеру руху.
10. Опишіть, як прискорення об'єкта обчислюється із зміни вектора швидкості та як аналіз прискорення допомагає виявляти аномальні або швидкі маневри в траєкторії.

ЛАБОРАТОРНА РОБОТА №3. АНАЛІЗ ОЗНАК ТА ВИЯВЛЕННЯ АНОМАЛЬНИХ РУХІВ ДИНАМІЧНИХ ОБ'ЄКТІВ У ВІДЕОПОТОЦІ

Мета: ознайомитися з методами обчислення характеристик відстежених об'єктів, ідентифікації аномальних рухів, оцінки ефективності методів класифікації та здійснення наочної візуалізації результатів для подальшого аналізу.

ТЕОРЕТИЧНІ ВІДОМОСТІ

Динамічні об'єкти у відеопотоці являють собою елементи сцени, які змінюють своє просторове положення, форму та інші характеристики в часі. Аналіз їх поведінки вимагає системного підходу до виділення та опису ознак, що характеризують рух і стан об'єктів у послідовності кадрів. Такі ознаки дозволяють кількісно оцінювати переміщення об'єктів, досліджувати їх взаємодію та моделювати шаблони руху у динамічних системах.

До ключових характеристик динамічних об'єктів належать просторові ознаки, такі як геометрична форма, розмір, контур об'єкта, а також тимчасові параметри, що відображають швидкість, прискорення та напрямок переміщення. Додатково значну інформаційну цінність мають локальні текстурні та візуальні характеристики об'єкта, які забезпечують можливість його ідентифікації та диференціації серед інших елементів сцени.

Виникнення аномальних рухів об'єктів, що суттєво відрізняються від характерних закономірностей поведінки, є предметом особливої уваги при аналізі відеоданих. Такі аномалії можуть проявлятися у нетипових швидкостях або напрямках руху, зміні траєкторії, а також у несподіваних змінах форми чи текстури об'єкта. Дослідження аномальних подій дозволяє отримати глибоке розуміння динаміки системи та виявляти відхилення, які можуть мати критичне значення в прикладних та наукових задачах.

Обчислення ознак і параметрів динаміки руху об'єктів у відеопотоці є фундаментальною складовою сучасних методів комп'ютерного зору та

відеоаналітики. Це забезпечує можливість формалізованого опису поведінки об'єктів у складних динамічних середовищах, відкриваючи перспективи для подальшого моделювання, класифікації та прогнозування їх рухів.

Ознаки динамічних об'єктів у відеопотоці

Для всебічного аналізу рухомих об'єктів у відеопотоці необхідним є виділення та формалізація їх характерних ознак, що дозволяють відстежувати об'єкт протягом часу та кількісно оцінювати його поведінку. Ознаки динамічних об'єктів можна умовно розділити на просторові, тимчасові та функціональні, що забезпечує комплексне розуміння їх динаміки та взаємодії у сцені. Основні ознаки динамічних об'єктів:

- Геометрична форма – контур або силует об'єкта, що може змінюватися внаслідок руху або деформацій. Аналіз форми дозволяє оцінювати структурні зміни об'єкта, його положення у просторі та взаємодію з іншими елементами сцени. Зміни форми можуть свідчити про специфічні шаблони поведінки або аномальні події, що відрізняються від типових рухів об'єкта.
- Розмір – площа або масштаб об'єкта у кадрі, який може корелювати з відстанню до камери або зміною перспективи. Відстеження розміру дозволяє оцінювати рух у тривимірному просторі, прогнозувати наближення або віддалення об'єкта, а також виділяти нетипові зміни його стану.
- Швидкість переміщення – величина зміни положення об'єкта між послідовними кадрами, що характеризує темп руху та дозволяє виявляти прискорені або уповільнені рухи, що можуть свідчити про нетипові динамічні шаблони.
- Прискорення та зміна швидкості – показники динамічності руху, які дозволяють визначати раптові або різкі зміни поведінки об'єкта. Такі ознаки є важливими для виявлення аномалій, оскільки відхилення від

звичної швидкісної поведінки об'єкта часто сигналізує про несподівані події у сцені.

- Напрямок руху – кут або вектор переміщення об'єкта, який визначає його траєкторію у кадрі. Аналіз напрямку руху дозволяє оцінювати закономірності переміщення об'єкта, передбачати його майбутнє положення та вивчати взаємодію з іншими об'єктами сцени.
- Зміни форми та орієнтації – обертання, деформації або інші трансформації об'єкта під час руху. Вивчення цих змін дозволяє оцінювати складні рухові шаблони та взаємодію з оточенням, а також визначати нетипові або аномальні стани об'єкта.
- Локально-текстурні характеристики – деталі поверхні об'єкта, які забезпечують можливість його ідентифікації та диференціації серед інших елементів сцени. Використання текстурних ознак підвищує точність відстеження, дозволяє враховувати зміни візуальних властивостей об'єкта та оцінювати його стан у процесі руху.
- Колірні характеристики та інтенсивність пікселів – кольорні ознаки, гістограми інтенсивностей або спектральні ознаки, що дозволяють ідентифікувати об'єкт і відокремлювати його від фону. Ці ознаки особливо корисні у складних сценах з мінливою освітленістю або подібними об'єктами.
- Взаємне розташування з іншими об'єктами – просторові відносини між об'єктами, що дозволяють аналізувати групові рухи та оцінювати контекст поведінки об'єкта. Дана ознака важлива для виявлення закономірностей у колективній поведінці або взаємодії об'єктів.
- Траєкторії та кумулятивні параметри руху – інтегровані характеристики, такі як довжина траєкторії, кривизна руху або відхилення від середньої траєкторії. Вони забезпечують комплексний опис рухової поведінки об'єкта у часі та дозволяють виділяти відхилення від нормальних шаблонів.

- Функціональні ознаки руху – регулярність, частота або повторюваність рухів, які дозволяють ідентифікувати характерні шаблонів поведінки. Ці ознаки використовуються для аналізу ритмічних або циклічних рухів, а також для виявлення нетипових динамічних подій.

Виділення та аналіз зазначених ознак здійснюється шляхом обробки відеопотоку або послідовності кадрів із застосуванням алгоритмів детекції та відстеження об'єктів. Комплексне використання просторових, тимчасових та функціональних ознак забезпечує формалізований опис поведінки динамічних об'єктів і є необхідною умовою для подальшого виявлення закономірностей руху та аномалій у відеопотоці.

Методи обчислення ознак динамічних об'єктів у відеопотоці

Виділення та кількісне оцінювання ознак динамічних об'єктів у відеопотоці здійснюється за допомогою різноманітних методів обробки зображень та аналізу руху. Основна мета цих методів полягає у формалізації просторових, тимчасових та функціональних характеристик об'єктів для подальшого відстеження, класифікації та виявлення аномалій.

Методи обчислення геометричних ознак динамічних об'єктів у відеопотоці охоплюють широкий комплекс підходів, спрямованих на формальне визначення форми, розміру, меж та просторової структури об'єкта. Геометричні ознаки є базовим рівнем опису, оскільки саме вони дозволяють відокремити об'єкт від фону, відстежувати його положення у просторі та оцінювати зміни структури в часі. До таких ознак належать контур, силует, площа, периметр, компактність, еквівалентний діаметр, аспектичне співвідношення, а також різноманітні дескриптори форми на основі моментів чи контурних характеристик.

Виділення цих ознак базується на алгоритмах сегментації та локалізації об'єкта у відеокадрі. Порогова сегментація, як один з найпростіших та найпоширеніших методів, передбачає класифікацію пікселів на об'єкт і фон на основі значення яскравості або кольору. Використання глобального або адаптивного порогу дозволяє об'єднати пікселі із подібними характеристиками в

єдиний кластер. Незважаючи на простоту, порогові методи ефективні в умовах контрольованого освітлення та однорідного фону.

Для точнішого виділення меж об'єкта застосовуються оператори градієнтного аналізу, такі як Sobel або Canny. Оператор Sobel обчислює наближені похідні інтенсивності зображення у горизонтальному та вертикальному напрямках, що дозволяє виділити ділянки з різкими змінами яскравості, характерними для контурів. Оператор Canny є більш комплексним методом, який включає згладжування за допомогою фільтра Гауса, визначення градієнтів, подавлення немаксимальних значень і двопорогову процедуру відбору контурів. Це забезпечує високу точність локалізації меж, зменшує кількість шумових відгуків і дозволяє отримувати добре структуровані контури об'єкта.

Морфологічні операції, такі як ерозія, дилатація, відкриття і закриття, застосовуються як до результатів сегментації, так і до контурних зображень. Ці операції дають змогу усувати незначні шумові фрагменти, заповнювати розриви у силуеті, згладжувати межі та формувати коректну бінарну маску об'єкта. Ерозія видаляє дрібні елементи та звужує структуру, тоді як дилатація розширює її. Комбінація цих операцій дозволяє досягати морфологічної стабільності та структурної узгодженості виділених меж.

Ще одним важливим класом методів є активні контури. Такі моделі описують контур об'єкта як гнучку криву, яка еволюціонує під дією внутрішніх і зовнішніх сил. Внутрішні сили відповідають за гладкість і безперервність кривої, тоді як зовнішні формуються градієнтною інформацією зображення та «притягують» контур до істинних меж об'єкта. Активні контури придатні для точного виділення об'єктів складної форми та в умовах неоднорідного фону, проте їх ефективність залежить від початкового наближення і параметрів моделі.

Отримані контури та силуети є основою для обчислення геометричних параметрів. Площа визначається як кількість пікселів у масці об'єкта, периметр — як довжина замкненого контуру, а форма може оцінюватися через різноманітні дескриптори: компактність (площа, нормована на квадрат периметра), ексцентриситет, коефіцієнт видовженості, круглість, а також моменти H_u чи

Zernike, що забезпечують інваріантність до поворотів, масштабування та віддзеркалення. Такий підхід дозволяє отримувати комплексний, формально визначений опис об'єкта, який може бути використаний для подальшого аналізу руху, класифікації або виявлення аномалій.

Методи оцінки розміру та масштабу динамічних об'єктів у відеопотоці ґрунтуються на аналізі просторових характеристик їхнього силуету, контуру або виділеної області інтересу. Основною метою є отримання кількісних показників, що описують площу, периметр, висоту, ширину або інші метричні властивості об'єкта, а також визначення їх змін у часі. Оцінка масштабу є важливою для коректної інтерпретації руху, оскільки зміна розміру об'єкта у кадрі може бути пов'язана як із реальним переміщенням у глибину простору, так і з перспективною деформацією.

Першим етапом зазвичай є сегментація об'єкта, після якої отримують його маску або бінарне представлення. На основі цієї області обчислюється площа, що визначається як кількість пікселів, які належать об'єкту. Периметр отримують шляхом підрахунку довжини контуру, виділеного алгоритмами визначення меж. Ці базові характеристики використовуються для подальшої оцінки масштабних змін.

Для більш детального аналізу широко застосовуються методи обчислення обмежувальних прямокутників та еліпсів. Орієнтований обмежувальний прямокутник дає змогу визначати основні розміри об'єкта з урахуванням його нахилу відносно осей координат, що підвищує точність у випадках складних поз чи деформацій. Обмежувальний еліпс, побудований на основі моментів другої та третьої порядків, дозволяє оцінювати головні осі розподілу маси та форму об'єкта, забезпечуючи стійкість до локальних нерівностей силуету. Обидва методи дозволяють отримувати параметри, інваріантні до незначних деформацій контуру, що має важливе значення для аналізу рухомих об'єктів.

Для задач, де необхідно враховувати перспективні спотворення, використовуються методи нормалізації масштабу. Перспективна корекція ґрунтується на апроксимації моделі камери та відстані до об'єкта, що дозволяє перетворити виміряні геометричні параметри у метрично релевантні величини.

Якщо модель камери невідома, застосовують відносні метрики, наприклад співвідношення висоти до ширини або нормовану площу, що залишаються стабільними у межах однієї сцени.

Додаткові точніші методи включають аналіз опорних ключових точок та локальних дескрипторів, таких як SIFT або ORB. Вони дозволяють відстежувати масштаб окремих характерних областей, використовуючи масштабно-інваріантні функції. Зміна масштабу ключових точок у часі може інтерпретуватися як зміна відстані до камери, що є корисним для аналізу глибини руху.

Оцінка розміру та масштабу є важливою складовою високорівневого аналізу поведінки об'єктів у відеопотоці, оскільки зміни цих параметрів часто сигналізують про появу аномалій, взаємодію з іншими об'єктами або порушення типової динаміки руху.

Методи визначення швидкості та прискорення динамічних об'єктів у відеопотоці базуються на кількісному аналізі зміни їх положення у часі. Основою таких методів є відстеження координат об'єкта або його ключових точок на послідовності кадрів, після чого обчислюються похідні першого та другого порядку, що відповідають швидкості та прискоренню відповідно. Ці характеристики дозволяють оцінювати інтенсивність руху, виявляти різкі зміни динаміки та визначати потенційно аномальні поведінкові шаблони.

Класичний підхід передбачає використання траєкторії, тобто послідовності положень об'єкта у кожному кадрі. Якщо відома дискретна координата центру мас або іншої характерної точки, швидкість визначається як відношення зміни положення до інтервалу часу між кадрами. Прискорення, відповідно, є зміною швидкості між сусідніми моментами часу. Такий підхід є базовим, але його точність значною мірою залежить від якості детекції та стабільності трекінгу.

Більш точні методи використовують оптичний потік, що описує поле векторів переміщення пікселів між кадрами. За допомогою диференціальних методів, таких як підхід Lucas-Kanade або метод Horn-Schunck, обчислюється локальний рух у вигляді векторів, які можна агрегувати для цілого об'єкта. Швидкість у цьому випадку визначається як середнє або зважене значення векторів оптичного потоку

в межах сегментованої області. Прискорення обчислюється шляхом аналізу зміни цих векторів у часі. Перевагою оптичного потоку є здатність враховувати складні деформаційні та нерівномірні рухи, особливо у випадках, коли об'єкт має неоднорідну структуру.

Для високоточної оцінки швидкості застосовуються методи трекінгу ключових точок. Локальні дескриптори, такі як Harris, Shi-Tomasi або сучасні ORB, дозволяють вибирати стійкі точки, які легко відстежувати у часі. Зміна координат цих точок використовується для оцінки локальної та глобальної швидкості. Такий підхід є стійким до часткових перекриттів, оскільки при втраті деяких точок інші продовжують забезпечувати коректну оцінку. Прискорення визначається шляхом аналізу динаміки переміщення набору ключових точок.

Окрему групу становлять методи, що враховують кінематичні моделі руху. При використанні фільтра Калмана або розширених стохастичних моделей прогнозується стан об'єкта, що включає його положення, швидкість та прискорення. Зіставлення прогнозу та фактичних спостережень дозволяє коригувати оцінки та зменшувати вплив шуму, що значно підвищує точність визначення динамічних параметрів у реальних відеосценах.

Швидкість і прискорення є фундаментальними ознаками, що характеризують рух, а їх точний розрахунок має критичне значення для виявлення аномалій. Раптові зміни прискорення, різкі коливання швидкості або невідповідність динамічним шаблонам сцени можуть сигналізувати про небезпечні або нетипові події, що зумовлює широке використання цих методів у системах відеоспостереження, автономній навігації та аналізі поведінки об'єктів.

Методи аналізу змін форми та орієнтації динамічних об'єктів ґрунтуються на вимірюванні геометричних і структурних властивостей силуету, контуру або поверхневих характеристик об'єкта в часі. Формальні ознаки форми, такі як пропорції, ступінь видовженості, компактність та коефіцієнти деформації, є інформативними для оцінювання стабільності поведінки об'єкта та виявлення аномальних трансформацій. Одним із ключових підходів є аналіз геометричних моментів, зокрема центральних, нормованих та інваріантів Ну. Використання

набору моментних коефіцієнтів дає змогу описувати форму об'єкта у вигляді компактного векторного представлення, стійкого до змін масштабу, повороту та часткових деформацій. Зміна таких коефіцієнтів у часовій послідовності дозволяє кількісно оцінювати ступінь трансформації форми та виявляти нетипові модифікації.

Крім моментних описів, поширено застосовується аналіз контуру об'єкта на основі методів диференціювання та кривизни. Оцінювання радіуса кривизни, напрямку нормалі та локальних деформацій по контуру дає змогу визначати, чи зазнає об'єкт нелінійних трансформацій під час руху, наприклад, розтягувань, стискань або скручувань. Методи порівняння контурів у часі, такі як зіставлення форм або відстеження контуру, використовують метрики подібності, включно з відстанями Hausdorff або Fréchet, що забезпечують кількісне вимірювання відхилень форми між сусідніми кадрами.

Орієнтація об'єкта визначається шляхом аналізу головної осі його форми або напрямки розподілу маси. Для цього використовують методи головних компонент (PCA), які обчислюють напрямки максимальної дисперсії контурних точок або пікселів силуету. PCA дає змогу описувати орієнтацію як вектор головної осі та аналізувати її зміни між кадрами. Різкі або нетипові коливання цього вектора можуть вказувати на аномалії, пов'язані з раптовими поворотами, падіннями чи зіткненнями об'єктів.

Додатково застосовуються локальні текстурні дескриптори, чутливі до орієнтаційних змін, зокрема локальні бінарні шаблони, гістограми орієнтованих градієнтів та інші градієнтні методи. Вони дозволяють виявляти локальні трансформації, що не завжди помітні на рівні геометрії, наприклад, появу нових структурних елементів або деформації поверхні. Аналіз часової послідовності таких дескрипторів забезпечує виявлення як глобальних, так і локальних змін орієнтації та форми.

Комплексне поєднання моментних ознак, контурних метрик, орієнтаційних характеристик та локальних текстурних дескрипторів дає змогу сформувати всебічну модель форми об'єкта та її змін у часі. Такий підхід забезпечує підвищену

точність і стійкість аналізу, що є критичним для виявлення аномальних трансформацій у відеопотоці.

Виділення локально-текстурних характеристик є критично важливим для точного опису візуальної структури об'єктів у відеопотоці. Текстурні ознаки забезпечують диференціацію об'єктів з подібними геометричними параметрами та стійкість алгоритмів до шумів, зміни освітленості та часткових перекриттів. В основі цих методів лежить аналіз локальних шаблонів інтенсивності пікселів, градієнтів та структурних елементів поверхні об'єкта.

Одним із класичних підходів є локальні бінарні шаблони (LBP). Цей метод формує бінарний код для кожного пікселя, порівнюючи його інтенсивність з інтенсивністю сусідніх пікселів у визначеному локальному вікні. Отримані коди збираються у гістограми, що формують дескриптор текстури. LBP відрізняється високою інваріантністю до змін освітленості та локальних контрастних варіацій, а також дозволяє оцінювати дрібні структурні деталі поверхні об'єкта. Розширені варіанти, такі як уніформні LBP або інваріантні до обертання LBP, дозволяють забезпечити інваріантність до обертання об'єкта та зменшують розмірність дескриптора, що підвищує швидкодію алгоритмів відстеження.

Для більш складного опису локальних ознак широко застосовується метод гістограм орієнтованих градієнтів (HOG). Даний метод передбачає розбиття зображення на невеликі комірки, обчислення градієнтів інтенсивності по кожному пікселю та побудову гістограм напрямків градієнтів у кожній комірці. Потім гістограми нормалізуються в межах більших блоків для забезпечення інваріантності до локальних змін освітленості. Завдяки такому підходу можна виділяти орієнтовані структурні елементи текстури, що особливо ефективно для виявлення контурів та локальних шаблонів рухомих об'єктів.

Потужним класом методів є інваріантне до масштабу перетворення ознак (SIFT), та прискорене вилучення стійких однак (SURF). SIFT дозволяє виділяти ключові точки на різних масштабах зображення та формувати дескриптори на основі градієнтних шаблонів у локальному оточенні ключової точки. Це забезпечує інваріантність до масштабних змін, обертання та часткових деформацій об'єкта.

SURF є прискореною версією SIFT, яка використовує апроксимацію гаусових фільтрів та інтегральні зображення для швидкого обчислення дескрипторів. Обидва методи дозволяють надійно відстежувати об'єкти між кадрами, навіть при зміні перспективи або частковому перекритті іншими елементами сцени.

Додатково застосовуються методи, що комбінують статистичні підходи та локальне фільтрування текстурних ознак. Наприклад, фільтри Габора використовуються для виділення текстурних компонент із певною частотою та орієнтацією, що дозволяє отримати спектрально-селективні ознаки локальної структури. Також використовуються адаптивні гістограми локальних інтенсивностей, які враховують контекст навколишніх пікселів, підвищуючи стійкість до шумів та зміни фону.

Комплексне застосування цих методів дозволяє формувати багатовимірні дескриптори локальної текстури, які інтегруються з геометричними та динамічними ознаками об'єктів. Це створює підґрунтя для високоточних алгоритмів відстеження, класифікації та виявлення аномальних рухів у відеопотоці, забезпечуючи надійний аналіз поведінки об'єктів навіть у складних умовах сцени.

Колірні та інтенсивні характеристики дозволяють відокремлювати об'єкти від фону, оцінювати зміни освітленості, виявляти часткові деформації та доповнюють геометричні й текстурні ознаки для більш надійного опису об'єкта.

Оцінка кольорних характеристик зазвичай базується на аналізі гістограм розподілу інтенсивності в різних кольорних просторах. Найпоширенішими є простори RGB, HSV та Lab. У просторі RGB окремо аналізуються інтенсивності червоного, зеленого та синього каналів, що дозволяє визначати кольірні шаблони об'єкта. Простір HSV (Hue, Saturation, Value) дає змогу виділити інформацію про відтінок, насиченість та яскравість, що робить метод інваріантним до часткових змін освітленості. Простір Lab забезпечує перцепційно рівномірну шкалу кольору та дозволяє точніше порівнювати кольірні ознаки об'єктів у різних кадрах.

Для оцінки інтенсивності використовуються методи статистичного аналізу значень пікселів об'єкта, такі як обчислення середньої яскравості, стандартного відхилення, контрасту та гістограм локальної інтенсивності. Такі показники

дозволяють кількісно оцінити зміни освітлення, тіні та виділення об'єкта на фоні. Для більш складних випадків застосовуються адаптивні гістограми та нормалізація локальних блоків, що забезпечує стійкість до нерівномірного освітлення та шумів у відеопотоці.

Крім статичних характеристик, колірні та інтенсивні ознаки можна аналізувати у часовому вимірі, оцінюючи їх зміни між кадрами. Це дозволяє виявляти рух об'єкта, часткові перекриття або аномальні зміни, що не відповідають типовій поведінці об'єкта у сцені.

Комплексне використання колірних та інтенсивних характеристик у поєднанні з геометричними, текстурними та динамічними ознаками забезпечує багатовимірне і точне описання об'єктів, створюючи надійне підґрунтя для відстеження, класифікації та виявлення аномальних рухів у відеопотоці.

Аналіз взаємного розташування об'єктів є важливою складовою кількісного опису динаміки сцени, оскільки він дозволяє оцінювати просторові відносини між об'єктами, виявляти закономірності їх руху та визначати потенційні аномальні взаємодії. Взаємне розташування характеризується відстанями, кутами, співвідношенням траєкторій та просторовою координацією об'єктів у кадрі.

Класичним підходом до аналізу взаємного розташування є обчислення евклідових та геометричних відстаней між центрами мас або ключовими точками об'єктів. Цей метод дозволяє кількісно оцінювати близькість об'єктів, визначати групування або утворення скупчень, а також відстежувати зміни цих параметрів у часі. Для більш складних випадків застосовують метрики, інваріантні до масштабу та обертання, що забезпечує коректне порівняння взаємного розташування незалежно від перспективи камери.

Іншим підходом є аналіз траєкторій руху об'єктів з подальшим обчисленням відхилень від типових шаблонів взаємного розташування. Для цього використовуються методи динамічної часової кореляції, відстані Fréchet або Hausdorff між траєкторіями, що дозволяють оцінювати, наскільки рух об'єкта узгоджується з рухом інших об'єктів, а також виявляти нетипові зміни взаємного розташування, що можуть вказувати на аномальні події.

Для побудови просторових моделей взаємного розташування застосовуються графові підходи, де об'єкти виступають як вершини графа, а відстані або зв'язки між ними формують ребра з відповідними вагами. Аналіз таких графів дозволяє визначати групові закономірності руху, взаємну координацію об'єктів та аномальні зміни структури сцени. При цьому можуть використовуватися як статичні графи для окремих кадрів, так і динамічні графи, що відображають зміну взаємних відносин у часі.

Комплексне використання методів евклідових та інваріантних відстаней, аналізу траєкторій та графових моделей дозволяє будувати багатовимірне представлення взаємного розташування об'єктів. Це забезпечує точне моделювання просторових взаємодій, інтегрується з іншими ознаками об'єктів і створює підґрунтя для виявлення аномальних рухів, прогнозування поведінки та систем автоматичного відеоаналізу.

Аналіз функціональних характеристик руху динамічних об'єктів у відеопотоці спрямований на кількісне оцінювання їх поведінки у часі та просторі. Функціональні характеристики описують не лише просторові параметри переміщення, а й динамічні властивості об'єкта, такі як швидкість, прискорення, кривизна траєкторії, амплітуда коливань та регулярність рухових шаблонів. Такий аналіз дозволяє виявляти аномальні стани, прогнозувати рух та оцінювати взаємодію об'єктів у складних сценах.

Одним із основних підходів є статистичний аналіз похідних характеристик руху. Після побудови траєкторій об'єкта обчислюються миттєві та середні значення швидкості, прискорення та зміни напрямку. Для зменшення впливу шумів і неточностей детекції застосовуються ковзні середні, фільтри Калмана та гаусові згладжування. Такі методи дозволяють отримати більш стабільну оцінку функціональних параметрів та забезпечують надійний базис для подальшого аналізу.

Іншим підходом є спектральний аналіз та аналіз частотних компонент руху, який дозволяє оцінювати періодичність та коливання руху об'єкта. Наприклад, перетворення Фур'є використовується для виявлення циклічних шаблонів та

аномальних частотних компонент, що можуть свідчити про нетипову поведінку або збої в русі.

Для багатовимірного опису руху застосовуються методи інтеграції просторових та динамічних ознак, що дозволяють оцінювати взаємозв'язок між швидкістю, прискоренням, кривизною траєкторії та просторовим розташуванням об'єктів. Це створює комплексний функціональний профіль руху об'єкта, який може використовуватися для класифікації поведінки, виявлення аномальних шаблонів та прогнозування подальшого розвитку подій у сцені.

Для виявлення відхилень від нормальної поведінки об'єкта застосовуються методи порогового та статистичного контролю, які оцінюють функціональні характеристики у порівнянні зі встановленими середніми або типовими значеннями. Такі підходи дозволяють швидко ідентифікувати нетипові стани руху та інтегруються з іншими ознаками об'єктів, забезпечуючи комплексний аналіз відеопотоку.

Виявлення аномальних рухів об'єктів

Аномальні рухи динамічних об'єктів у відеопотоці характеризуються істотними відхиленнями від типової поведінки об'єкта або групи об'єктів на сцені. Такі відхилення можуть свідчити про непередбачувані події, помилки в системі відстеження або появу нетипових ситуацій у середовищі спостереження. Виявлення аномалій є важливим етапом аналізу відеоданих, оскільки воно дозволяє системам автоматичного моніторингу оперативно реагувати на потенційні ризики або нетипові події.

До основних типів аномалій належать відхилення швидкісних параметрів, нетипові траєкторії та зміни структурних або текстурних характеристик об'єктів. Аномалії швидкості проявляються у вигляді надто високих або надто низьких швидкостей порівняно зі середніми значеннями руху об'єкта або групи об'єктів. Такі відхилення дозволяють виявляти раптові прискорення, уповільнення або зупинки, що не відповідають нормальній поведінці сцени.

Нетипова траєкторія руху включає різкі зміни напрямку, коливання або рухи, які суперечать загальній закономірності переміщення об'єктів. Для її виявлення

здійснюється аналіз відхилення траєкторій від середніх шаблонів, оцінка кривизни руху, а також порівняння відносного розташування об'єктів на кадрах. Такий підхід дозволяє ідентифікувати зміни взаємодії між об'єктами або їх несподівані маневри, що можуть мати прикладне значення у безпеці, транспортному аналізі або поведінкових дослідженнях.

Неочікувані зміни форми або текстурних ознак об'єктів виникають у випадках деформацій, часткового перекриття або змін візуальних характеристик. Для їх виявлення застосовуються методи порівняння локальних та глобальних дескрипторів форми, текстури та кольору, що дозволяє оцінювати відхилення від типових моделей об'єкта. Це забезпечує стійкість системи до зміни освітлення, часткових перекриттів і деформацій, одночасно дозволяючи виділяти нетипові явища, які вимагають додаткової уваги.

Методи виявлення аномалій можна умовно поділити на дві групи. Перша група методів виявлення аномальних рухів у відеопотоці базується на порівнянні поточних ознак об'єкта з його попередніми станами або типовими шаблонами поведінки. Такий підхід дозволяє оперативно оцінювати відхилення від нормальної поведінки та виявляти аномалії в реальному часі без необхідності навчання складних моделей на великих наборах даних. Основною ідеєю є формування базової моделі поведінки об'єкта або групи об'єктів та постійне порівняння поточних параметрів з цією моделлю.

У цій групі методів виділяють кілька підходів. Один із класичних – метод ковзного вікна, при якому поточні ознаки об'єкта порівнюються з усередненими значеннями або статистичними параметрами ознак за попередні кадри. Відхилення, що перевищують певний пороговий рівень, інтерпретуються як потенційна аномалія. Такий підхід є простим у реалізації та дозволяє оперативно реагувати на зміни в поведінці об'єкта.

Іншим підходом є метод порівняння з історичними шаблонами траєкторій, коли для кожного об'єкта або категорії об'єктів створюється набір типових траєкторій або шаблонів руху. Поточна траєкторія порівнюється з цими шаблонами за допомогою метричних методів, таких як евклідова відстань, відстані Fréchet або

Hausdorff. Значні відхилення вказують на нетипову поведінку об'єкта, що дозволяє виділяти аномальні події навіть у складних сценаріях, де швидкість і напрям руху змінюються динамічно.

Також важливим методом є пороговий аналіз динамічних ознак, який застосовується до похідних характеристик руху – швидкості, прискорення, зміни розміру або форми. Для кожного параметра визначається нормальний діапазон на основі попередніх кадрів або статистичних характеристик сцени. Відхилення за межі цього діапазону сигналізує про потенційну аномалію. Такий підхід особливо ефективний для виявлення раптових змін або екстремальних значень параметрів руху.

Методи порівняння з попередніми станами дозволяють інтегрувати різні типи ознак у єдину модель поведінки об'єкта, що забезпечує багатовимірне представлення нормальної поведінки та підвищує точність виявлення аномалій навіть у складних і динамічних сценах. Дані методи добре масштабуються для обробки реального часу, що робить їх ефективними для систем відеомоніторингу та автоматичного контролю безпеки.

Друга група методів виявлення аномальних рухів у відеопотоці базується на статистичному та машинному аналізі багатовимірних ознак об'єктів – це дозволяє виявляти складні та нетипові шаблони поведінки, які не завжди піддаються прямому порівнянню з попередніми станами.

Одним із класичних підходів є кластеризація та виявлення викидів. До популярних алгоритмів відносяться k-середніх, DBSCAN та моделі гаусівських сумішей (GMM). Кластеризація дозволяє виділяти природні групи подібних траєкторій або поведінкових шаблонів – об'єкти, які не входять до жодного кластера або значно віддалені від центру кластера, інтерпретуються як аномалії. Цей підхід ефективний для виявлення нетипових рухів у складних середовищах із багатьма взаємодіючими об'єктами.

Іншим підходом є класифікація на основі моделей машинного навчання. Для цього застосовуються алгоритми підтримки векторних машин (SVM), Random Forest, k найближчих сусідів (k-NN) та сучасні методи на основі глибоких

нейронних мереж. Такі моделі навчаються на множині коректних шаблонів поведінки та здатні виявляти відхилення, які статистично значущо відрізняються від навчальних зразків. Глибокі нейронні мережі, зокрема рекурентні (RNN) та згорткові (CNN), дозволяють автоматично виділяти ознаки з відеопотоку та інтегрувати їх у багатовимірні репрезентації для точного виявлення аномалій.

Статистичні методи також включають пороговий аналіз багатовимірних показників, використання змінних коваріаційних матриць та оцінку ймовірнісних розподілів ознак. Наприклад, для кожного об'єкта або групи об'єктів обчислюється ймовірність поточного стану на основі попередніх спостережень – низька ймовірність сигналізує про аномалію. Такі підходи ефективні при обробці великих обсягів даних і дозволяють інтегрувати як просторові, так і динамічні ознаки.

Комплексне застосування статистичних та машинних методів дозволяє виявляти аномальні рухи у складних сценах, де просте порівняння з попередніми станами недостатнє. Вони забезпечують високоточне і стійке розпізнавання нетипової поведінки, інтегруються з іншими типами аналізу, створюють багатовимірні моделі поведінки об'єктів та підвищують ефективність систем автоматичного відеомоніторингу і прогнозування аномальних подій.

Методи класифікації даних у відеопотоці

Класифікація даних у відеопотоці є важливим етапом обробки інформації, оскільки дозволяє систематизувати ознаки, виділяти закономірності та виявляти нетипові стани або події. Основна мета класифікації полягає у побудові моделей, які відображають залежності між вимірюваними ознаками і категоріями об'єктів, рухів або аномалій, забезпечуючи можливість автоматичного розпізнавання та прогнозування поведінки сцени. Для досягнення цих цілей використовуються різноманітні методи, які можна умовно поділити на класичні алгоритми машинного навчання, методи кластеризації, статистичні та порогові підходи, а також глибокі нейронні мережі.

До класичних методів відносяться алгоритми, що потребують попередньо виділених ознак і навчальної вибірки. Серед них найпоширенішими є:

- k-Nearest Neighbors (k-NN) – алгоритм, який класифікує об’єкт на основі відстаней до k найближчих сусідів у багатовимірному просторі ознак. Цей метод простий у реалізації і добре працює при достатній кількості навчальних даних, проте його продуктивність знижується при високій розмірності ознак або наявності шуму.
- Support Vector Machines (SVM) – метод, що будує гіперплощину або множину гіперплощин, які розділяють класи у багатовимірному просторі. SVM ефективний при невеликій кількості зразків і здатний моделювати нелінійні залежності завдяки використанню функцій ядра.
- Random Forest – ансамблевий метод, що поєднує кілька дерев рішень для підвищення точності та стабільності класифікації. Він добре справляється з шумними даними та багатовимірними ознаками, забезпечуючи надійне розпізнавання як типових, так і нетипових шаблонів.
- Naïve Bayes – ймовірнісний метод, що використовує припущення про незалежність ознак для обчислення ймовірності належності об’єкта до певного класу. Метод ефективний для великих наборів даних і швидкий у виконанні, але його точність може знижуватися при сильній кореляції між ознаками.

Методи кластеризації дозволяють групувати дані без попередньо визначених класів, виявляючи природні групи або аномалії:

- k-means – алгоритм, який розбиває дані на k кластерів на основі мінімізації відстані всередині кластера. Ефективний для великих наборів даних, проте чутливий до вибору k і початкових центрів кластерів.
- DBSCAN (Density-Based Spatial Clustering of Applications with Noise) – метод, що виділяє кластери на основі щільності точок у просторі ознак. Він дозволяє виявляти аномальні елементи як точки, що не належать жодному кластеру, та ефективний для складних розподілів даних.
- Gaussian Mixture Models (моделі гаусівських сумішей) – ймовірнісний підхід, що моделює розподіл даних як суму гаусівських компонент. GMM дозволяє

враховувати розмиті кордони між класами та оцінювати ймовірність належності елементів до різних категорій.

Статистичні підходи використовуються для швидкого визначення нетипових станів або аномалій на основі багатовимірних ознак:

- Пороговий аналіз – визначення аномальних значень шляхом порівняння ознак з допустимими діапазонами або середніми значеннями.
- Методи контролю якості та контрольних карт (SPC) – оцінка відхилень ознак від нормальних шаблонів з урахуванням дисперсії та коваріацій між параметрами.
- Методи оцінки ймовірнісного розподілу ознак – визначення аномалій на основі низької ймовірності поточного стану у порівнянні з навчальною вибіркою.

Сучасні підходи широко застосовують глибоке навчання, яке дозволяє автоматично виділяти ознаки та інтегрувати їх у багатовимірні моделі:

- Згорткові нейронні мережі (CNN) – ефективні для аналізу просторових ознак, таких як форма, текстура та колір.
- Рекурентні нейронні мережі (RNN, LSTM, GRU) – здатні враховувати часові залежності та моделювати послідовності ознак, що особливо важливо для рухів або динамічних змін у відеопотоці.
- Гібридні моделі CNN-RNN – поєднують просторовий та часовий аналіз, що дозволяє класифікувати складні поведінкові шаблони або аномалії у відео.

Для порівняння ефективності методів використовуються кількісні показники:

- Точність класифікації – відсоток правильно визначених класів або аномалій.
- Стабільність – здатність методів працювати коректно при різних вхідних даних та наявності шуму.
- Обчислювальні витрати – час виконання та вимоги до ресурсів, що особливо важливо для реального часу.

Комплексне застосування описаних методів дозволяє створювати надійні багатовимірні моделі для класифікації будь-яких типів даних, забезпечувати виявлення закономірностей та прогнозування нетипових станів у відеопотоці.

Практичне застосування

Розглянемо приклад реалізації одного з підходів до виявлення аномальних рухів – порівняння поточних ознак об'єкта з його попередніми станами. Такий метод дозволяє оперативно визначати відхилення від типової поведінки об'єктів, наприклад, різкі зміни швидкості, напрямку руху або розміру, що можуть свідчити про аномалію. Приклад псевдокоду у стилі Python:

```
def detect_anomalies(objects_history, current_frame, thresholds):
    for obj_id, current_features in current_frame.objects.items():
        # Отримання історії ознак об'єкта
        previous_features = objects_history.get(obj_id, None)

        if previous_features is None:
            # Якщо об'єкт новий, ініціалізуємо його історію
            objects_history[obj_id] = current_features
            continue

        # Обчислення відхилень по основних ознаках
        speed_diff = abs(current_features.speed - previous_features.speed)
        direction_diff = angle_difference(current_features.direction,
previous_features.direction)
        size_diff = abs(current_features.size - previous_features.size)

        # Перевірка на аномалію за порогоми
        if speed_diff > thresholds['speed'] or \
            direction_diff > thresholds['direction'] or \
            size_diff > thresholds['size']:
            mark_as_anomalous(obj_id, current_frame.number)

        # Оновлення історії об'єкта
        objects_history[obj_id] = current_features
```

У цьому підході кожен об'єкт характеризується основними ознаками – швидкістю, напрямом руху та розміром. Поточні значення порівнюються з історичними даними для того ж об'єкта, що дозволяє виявляти нетипові зміни. Якщо відхилення перевищують задані порогові значення, рух об'єкта класифікується як аномальний. Такий метод простий у реалізації, дозволяє

працювати в реальному часі та є ефективним для моніторингу поведінки динамічних об'єктів у відеопотоці.

ЗАВДАННЯ ДЛЯ ВИКОНАННЯ

Загальні умови

Лабораторна робота №3 виконується на основі лабораторних робіт №1-2 та є їх логічним продовженням, тому загальні умови залишаються незмінними.

Етапи виконання лабораторної роботи

1. Обчислити ознаки відстежених об'єктів.

Реалізувати програмний алгоритм аналізу відео або послідовності кадрів, який для кожного відстеженого об'єкта обчислює та зберігає його ознаки: геометричну форму, розмір, швидкість переміщення, напрям руху та локальні текстурні характеристики.

2. Виявити аномальні рухи об'єктів.

Розробити програмний метод, який аналізує динаміку руху кожного об'єкта та визначає випадки аномальної поведінки. До аномалій належать: надто велика або надто мала швидкість, нетипова траєкторія руху (різкі зміни напрямку, коливання), нехарактерні зміни форми або текстурних ознак об'єкта. Програма має автоматично формувати позначки аномалій для подальшої візуалізації та аналізу.

3. Порівняти методи класифікації та описати їх ефективність.

Реалізувати та протестувати не менше п'яти методів класифікації для виявлення та групування типів об'єктів, рухів чи аномалій. Виконати порівняльний аналіз ефективності кожного методу за показниками точності, стабільності та обчислювальних витрат. У звіті навести висновки щодо доцільності використання кожного методу.

4. Зберегти результати у CSV/JSON.

Після завершення аналізу сформувати структурований файл у форматі CSV або JSON, у якому для кожного кадру фіксуються такі дані: унікальний ID об'єкта, обчислені ознаки (форма, розмір, швидкість, напрям руху, текстура), а також

позначки виявлених аномалій. Файл має відповідати структурі та формату, узгодженому у попередніх лабораторних роботах.

5. Візуалізувати аномалії на відео та графічно. Реалізувати програмну візуалізацію, що дозволяє відображати аномальні об'єкти на відео (наприклад, за допомогою кольорових рамок, маркерів або підписів). Створити графічні візуалізації (графіки швидкостей, траєкторій, зміни ознак), що демонструють аномальні події. Візуалізація має забезпечувати наочність та можливість подальшого використання у звіті.

Вимоги до звіту

1. Титульний лист.
2. Лист завдання.
3. Опис ходу виконання кожного завдання лабораторної роботи з переліком використаних функцій мови програмування та аналізом отриманих результатів.
4. Лістинг програми з коментарями до ключових частин коду.
5. Скриншоти результатів виконання програми на кожному етапі роботи.
6. Висновки.

Для отримання оцінки за лабораторну роботу обов'язковими є захист роботи та виконання звіту. За умов, коли роботу не захищено та/або звіт відсутній, лабораторна робота не зараховується.

Питання для самоконтролю

1. Які основні категорії ознак динамічних об'єктів використовуються для їх аналізу?
2. Поясніть роль та значення геометричної форми, масштабних характеристик, швидкості та напрямку руху як ключових ознак динамічних об'єктів у відеопотоці.
3. Які методи використовуються для обчислення геометричних ознак об'єктів?

4. Що таке локально-текстурні характеристики і які алгоритми застосовуються для їх виділення?
5. Як визначаються колірні та інтенсивні характеристики об'єктів і яку інформацію вони надають?
6. Що розуміють під аномальними рухами та які типи відхилень від нормальної поведінки об'єктів існують?
7. Опишіть методи виявлення аномальних рухів на основі порівняння поточних ознак із попередніми станами або шаблонами поведінки.
8. Які методи класифікації даних застосовуються для групування об'єктів, рухів або аномалій?
9. Які показники використовуються для оцінки ефективності методів класифікації та виявлення аномалій?
10. Як комбіноване застосування різних методів підвищує точність, стабільність та швидкодію систем аналізу відеопотоку?

STEM ПРОЄКТ. КОМПЛЕКСНИЙ АНАЛІЗ ТА ПРОГНОЗУВАННЯ ПОВЕДІНКИ ДИНАМІЧНИХ ОБ'ЄКТІВ У ВІДЕОПОТОЦІ

Мета: навчитися прогнозувати положення, швидкість та напрям руху об'єктів, виявляти аномальні події на основі аналізу траєкторій і параметрів руху, а також оцінювати ефективність алгоритмів прогнозування динаміки об'єктів.

ТЕОРЕТИЧНІ ВІДОМОСТІ

Динамічні об'єкти у відеопотоці характеризуються постійною зміною положення, швидкості та напрямку руху, що створює складну часову динаміку сцени. Для всебічного аналізу їх поведінки недостатньо лише відстежувати координати на кадрах або обчислювати базові ознаки; необхідним є прогнозування майбутніх станів об'єктів. Прогнозування руху дозволяє передбачати координати, швидкість та напрямки об'єктів на кілька кадрів уперед, що забезпечує основу для своєчасного виявлення потенційно аномальних подій і точнішого моделювання динаміки системи.

До основних характеристик, що використовуються при прогнозуванні, належать траєкторії переміщення, швидкість та прискорення об'єктів, зміни напрямку руху та взаємодія з іншими елементами сцени. Аналіз цих параметрів дає змогу визначати нетипові або небезпечні ситуації, такі як раптові відхилення траєкторії, вихід за допустимі межі, очікувані зіткнення чи неприродне прискорення об'єктів, ще до їх фактичного настання.

Використання методів прогнозування та оцінки потенційних аномалій є ключовим елементом сучасних систем комп'ютерного зору та відеоаналітики. Такий підхід дозволяє формалізовано описувати поведінку об'єктів у динамічних середовищах, підвищує точність прогнозів та створює можливості для автоматизованого контролю, моніторингу та підтримки прийняття рішень у реальному часі. Реалізація алгоритмів прогнозування руху об'єктів та виявлення потенційних аномалій має особливе значення у прикладних задачах безпеки, управління рухом та аналізу складних динамічних систем.

Прогнозування руху об'єктів у відеопотоці

Прогнозування руху об'єктів у відеопотоці полягає у визначенні очікуваних координат, швидкості та напрямку руху на наступні кадри на основі історичних даних про траєкторії об'єктів. Це дозволяє не лише передбачати майбутню позицію об'єкта, а й оцінювати потенційні аномалії, що можуть виникнути в динамічних середовищах. Методи прогнозування базуються на математичному моделюванні руху та статистичному аналізі історичних траєкторій, враховуючи як закономірності, так і можливі відхилення від типових сценаріїв.

Лінійна екстраполяція є найпростішим підходом до прогнозування руху об'єктів. Даний метод передбачає прямолінійний рух об'єкта зі сталою швидкістю та напрямком, що визначаються на основі попередніх кадрів. Формально координати об'єкта $x_{t+\Delta t}, y_{t+\Delta t}$ у наступному кадрі обчислюються за формулами:

$$x_{t+\Delta t} = x_t + v_x \cdot \Delta t, y_{t+\Delta t} = y_t + v_y \cdot \Delta t,$$

де v_x та v_y – компоненти швидкості по відповідних осях, а Δt – інтервал часу до прогнозованого кадру.

Метод лінійної екстраполяції відзначається простотою реалізації та мінімальними обчислювальними витратами, проте його точність суттєво знижується у випадках різких змін швидкості або напрямку, при прискоренні або поворотах траєкторії.

Для більш точного прогнозування враховують не лише швидкість, але й прискорення об'єкта. Кінематичні моделі описують рух за допомогою рівнянь:

$$x_{t+\Delta t} = x_t + v_x \cdot \Delta t + \frac{1}{2} a_x \cdot (\Delta t)^2, y_{t+\Delta t} = y_t + v_y \cdot \Delta t + \frac{1}{2} a_y \cdot (\Delta t)^2,$$

де a_x та a_y – компоненти прискорення.

Основною перевагою цього підходу є покращена точність прогнозів у порівнянні з простими лінійними моделями, тоді як недоліком є чутливість до шуму у даних і потреба в точному визначенні прискорення для стабільної роботи алгоритму.

Фільтр Калмана є ефективним методом для прогнозування станів об'єктів у випадках, коли спостережувані траєкторії містять шумові спотворення та неповні

дані. Його основна ідея полягає у комбінуванні апарату математичного моделювання руху об'єкта з фактичними вимірюваннями для отримання оптимальної оцінки стану об'єкта, що мінімізує середньоквадратичну похибку прогнозу.

У стандартній формалізації фільтр Калмана оперує вектором стану $X_t = [x_t, y_t, v_x, v_y]^T$, який містить поточні координати об'єкта та його швидкість по відповідних осях. Зміни стану описуються матрицею переходу F , яка визначає, як стан об'єкта еволюціонує у часі на основі кінематичних моделей, та ковариаційною матрицею шуму процесу Q , що враховує невизначеність або похибки у моделі руху.

Спостережувані дані відображаються через матрицю спостережень H , яка перетворює вектор стану у вимірювані величини, і ковариаційну матрицю шуму вимірювань R , що характеризує точність сенсорних даних. Робота фільтра Калмана складається з двох циклічних етапів: прогнозу та корекції. На етапі прогнозу обчислюється очікуваний стан об'єкта на наступний кадр на основі моделі руху та попередніх оцінок. На етапі корекції прогноз уточнюється з урахуванням фактичних вимірювань, що дозволяє зменшити вплив шуму та неточностей спостережень.

Фільтр Калмана відзначається високою стійкістю до шуму та забезпечує точне прогнозування координат і швидкостей навіть у випадках неповних або частково спотворених даних. Однак класична реалізація припускає лінійність моделі руху та гаусовий розподіл шуму, що може обмежувати точність при складних або різко змінних траєкторіях. Для подолання цих обмежень застосовуються розширені варіанти фільтра, такі як розширений фільтр Калмана (EKF) та неколінеарний фільтр Калмана (UKF), які дозволяють прогнозувати стан об'єктів при нелінійних рухах та більш складних сценаріях динаміки.

Частинкові фільтри застосовуються для прогнозування станів об'єктів у випадках, коли рух є нелінійним або має багатомодальні розподіли ймовірностей, що не можуть бути адекватно змодельовані лінійними методами на кшталт фільтра Калмана. Метод полягає у використанні великого набору частинок, де кожна

частинка представляє можливий стан об'єкта, включно з координатами та швидкістю. Кожна частинка має власну ймовірність (вагу), яка оновлюється на основі спостережуваних даних та моделі руху об'єкта.

Алгоритм роботи частинкового фільтра циклічно складається з трьох основних етапів: генерація прогнозованих частинок, оновлення ваг частинок згідно з ймовірністю спостережень і ресемплінг, який забезпечує підтримання достатньої різноманітності частинок і запобігає їхньому виродженню. Цей підхід дозволяє ефективно апроксимувати складний ймовірнісний розподіл станів і прогнозувати траєкторії об'єктів навіть у ситуаціях з різкими змінами руху, багатомодальними сценаріями або високим рівнем шуму.

Головною перевагою частинкових фільтрів є висока гнучкість і здатність моделювати складні, нелінійні та непередбачувані траєкторії об'єктів. Недоліком цього методу є значні обчислювальні витрати, оскільки точність прогнозу прямо залежить від кількості частинок. Для отримання стабільних і надійних оцінок необхідно використовувати велику кількість частинок, що збільшує навантаження на процесор та час обробки відеопотоку.

Метод ковзного середнього застосовується для прогнозування руху об'єктів у відеопотоці на основі усереднення попередніх значень координат або швидкостей об'єкта. Ідея методу полягає у згладжуванні короткострокових коливань траєкторії та зменшенні впливу шуму у вимірюваннях, що дозволяє отримати більш стабільний прогноз для наступного кадру. Формально координати об'єкта у прогнозованому кадрі обчислюються як середнє значення N попередніх координат:

$$x_{t+\Delta t} = \frac{1}{N} \sum_{i=0}^{N-1} x_{t-i}, y_{t+\Delta t} = \frac{1}{N} \sum_{i=0}^{N-1} y_{t-i},$$

де x_{t-i}, y_{t-i} – координати об'єкта у попередніх кадрах, а N – розмір ковзного вікна.

Метод ковзного середнього відзначається простотою реалізації та мінімальними обчислювальними витратами, що робить його придатним для швидкої оцінки руху об'єктів у реальному часі. Проте точність прогнозу суттєво знижується у випадках різких змін швидкості або напрямку руху об'єкта, а також

при прискоренні або поворотах траєкторії. Таким чином, метод найкраще підходить для плавного, монотонного руху без значних відхилень від середньої траєкторії.

Метод авторегресії використовується для прогнозування руху об'єктів у відеопотоці на основі попередніх значень координат або швидкостей. Суть методу полягає у моделюванні поточного стану об'єкта як лінійної комбінації його попередніх станів:

$$x_{t+\Delta t} = c + \sum_{i=1}^p \phi_i x_{t-i}, y_{t+\Delta t} = c + \sum_{i=1}^p \phi_i y_{t-i},$$

де x_{t-i}, y_{t-i} – попередні координати об'єкта, ϕ_i – коефіцієнти моделі авторегресії, p – порядок моделі, а c – константа. Вибір порядку моделі дозволяє враховувати певну кількість попередніх кадрів, що дає змогу враховувати тренди та закономірності у траєкторії руху.

Метод авторегресії забезпечує точніше прогнозування порівняно з простим ковзним середнім, оскільки враховує історичні залежності та може передбачати трендові зміни в русі об'єкта. До переваг методу належать відносно проста реалізація та можливість прогнозування рухів з певними закономірностями без складних обчислень. Недоліком є припущення лінійності залежностей між станами об'єкта, що обмежує точність прогнозів при складних або нелінійних траєкторіях. Крім того, точність прогнозу залежить від правильного вибору порядку моделі, і невдалий підбір параметрів може призвести до значних похибок у результатах.

Методи регресії та машинного навчання застосовуються для прогнозування руху об'єктів у відеопотоці у випадках, коли траєкторії є складними, нелінійними або багатомодальними. Класичні підходи регресії дозволяють моделювати координати або швидкості об'єкта як функцію попередніх значень, використовуючи лінійну або поліноміальну залежність. Сучасні підходи машинного навчання, зокрема рекурентні нейронні мережі (RNN) та їх модифікації – LSTM (Long Short-Term Memory) і GRU (Gated Recurrent Unit), здатні враховувати довгі послідовності даних та складні часові залежності між станами об'єкта.

У моделях RNN стан мережі оновлюється на кожному кроці часу, зберігаючи інформацію про попередні кадри, що дозволяє прогнозувати наступні координати об'єкта на основі повної історії його руху. Модифікації LSTM та GRU додають спеціальні механізми запам'ятовування та забування інформації, що зменшує ефект згасання градієнта та дозволяє ефективно моделювати довгі часові залежності.

До переваг цих методів належить здатність моделювати складні, нелінійні та багатомодальні траєкторії, а також висока точність прогнозів для об'єктів зі змінною швидкістю та напрямком руху. Недоліком є значні обчислювальні витрати, потреба у великій кількості навчальних даних та складність налаштування моделей. Крім того, існує ризик перенавчання при недостатній кількості даних або неправильно підібраних параметрах, що може знизити загальну стабільність прогнозування.

Методи на основі фізичних моделей використовують класичні закони механіки для прогнозування руху об'єктів у відеопотоці. Такі моделі враховують кінематичні та динамічні характеристики об'єктів, зокрема координати, швидкість, прискорення та сили, що діють на об'єкт. Прогнозування будується на рівняннях руху, що можуть включати прямолінійний або криволінійний рух, вплив гравітації, тертя, опору середовища та інші фізичні параметри.

Класичні кінематичні моделі описують положення об'єкта у наступному кадрі через його поточні координати, швидкість і прискорення за формулами:

$$x_{t+\Delta t} = x_t + v_x \Delta t + \frac{1}{2} a_x (\Delta t)^2, y_{t+\Delta t} = y_t + v_y \Delta t + \frac{1}{2} a_y (\Delta t)^2,$$

де v_x, v_y – компоненти швидкості, a_x, a_y – компоненти прискорення, а Δt – інтервал часу до прогнозованого кадру. У складніших моделях можуть враховуватися також моменти інерції, опір середовища та інші сили, що впливають на рух.

Перевагою фізичних моделей є висока інтерпретованість прогнозів, точність при добре визначених параметрах руху та можливість прогнозування при різких змінах напрямку чи прискоренні об'єкта. Недоліком є необхідність точної оцінки фізичних параметрів та обмежена гнучкість при складних або непередбачуваних траєкторіях, які не підкоряються класичним законам руху. Також методи фізичного

моделювання можуть вимагати додаткових обчислювальних ресурсів при врахуванні багатьох сил та взаємодій у складних середовищах.

Отже, вибір методу прогнозування руху об'єктів у відеопотоці визначається характером траєкторій, рівнем шуму у вимірюваннях та обчислювальними ресурсами. Прогнозовані координати, швидкість та напрямок руху об'єктів формують основу для подальшого аналізу динаміки, оцінки зміни параметрів руху та виявлення потенційних аномалій у відеопотоці.

Виявлення прогнозованих аномалій у відеопотоці

Виявлення аномалій у відеопотоці полягає у порівнянні фактичних координат, швидкості та напрямку руху об'єктів з їх прогнозованими значеннями, отриманими за допомогою методів прогнозування. Суттєві відхилення фактичних траєкторій від очікуваних свідчать про нетипову поведінку об'єктів і можуть вказувати на потенційні аномалії, які потребують уваги. Такий підхід дозволяє автоматично ідентифікувати події, що виходять за межі характерних сценаріїв, та реалізувати контроль динамічних систем у режимі реального часу.

Порогові методи є одними з найпростіших і найпоширеніших підходів до виявлення аномалій у відеопотоці. Сутність методу полягає у визначенні аномалії шляхом порівняння фактичного стану об'єкта з його прогнозованим значенням та перевірки, чи перевищує величина відхилення заздалегідь заданий поріг. Фактичний стан може включати координати, швидкість, прискорення, траєкторію руху або комбінацію цих параметрів. Якщо відхилення перевищує встановлену межу, об'єкт вважається таким, що демонструє аномальну поведінку.

Формально пороговий метод можна записати як для виявлення аномалії A :

$$A = \begin{cases} 1, & \text{if } |S_{\text{fact}} - S_{\text{predict}}| > T, \\ 0, & \text{if } |S_{\text{fact}} - S_{\text{predict}}| \leq T, \end{cases}$$

де S_{fact} – фактичний стан об'єкта, S_{predict} – прогнозований стан, T – порогове значення. Поріг може визначатися на основі статистичних характеристик руху об'єкта, дослідного підбору або з використанням навчання на історичних даних.

Основною перевагою порогових методів є їх простота реалізації та мінімальні обчислювальні витрати, що робить їх придатними для роботи у режимі реального часу навіть на обмежених ресурсах. Вони дозволяють швидко виявляти явні відхилення від прогнозованих траєкторій і є корисними в системах попередження про нетипові події.

Однак порогові методи мають і суттєві обмеження. В першу чергу, вони високо чутливі до шуму у вимірюваннях, що може призводити до частих помилкових спрацьовувань. Крім того, ефективність методу критично залежить від правильного підбору порогу: занадто малий поріг викликає надмірну кількість хибнопозитивних спрацьовувань, тоді як занадто великий може пропускати дійсні аномалії. Метод також обмежений у випадках складних або багатомодальних траєкторій, коли природні відхилення руху можуть значно варіюватися, що робить встановлення єдиного порогу недостатньо ефективним.

Для підвищення точності порогові методи часто комбінують з іншими підходами, такими як статистичні оцінки дисперсії, коваріаційні матриці або прогностичні моделі (лінійна екстраполяція, фільтр Калмана), що дозволяє встановлювати адаптивні пороги на основі очікуваних змін траєкторії. Така інтеграція значно підвищує надійність виявлення аномалій та зменшує кількість помилкових сигналів у відеопотоці.

Статистичні методи виявлення аномалій у відеопотоці базуються на аналізі розподілу характеристик руху об'єктів і визначенні відхилень від очікуваних статистичних закономірностей. Цей підхід передбачає побудову математичної моделі нормальної поведінки об'єктів, наприклад, на основі середніх значень, дисперсії, коваріаційної структури або багатовимірних розподілів ймовірностей, а потім порівняння фактичних спостережень із цією моделлю.

Одним із класичних прикладів статистичних методів є використання гаусівських моделей розподілу для окремих параметрів руху. У цьому випадку відхилення стану об'єкта від середнього значення оцінюється через стандартне відхилення σ або через ймовірність появи спостереження в рамках нормального

розподілу. Об'єкт вважається аномальним, якщо його стан потрапляє у низькоправдоподібний інтервал розподілу.

Формально для виявлення аномалії A це можна виразити :

$$A = P(S_{\text{fact}}) < \alpha,$$

де $P(S_{\text{fact}})$ – ймовірність фактичного стану об'єкта за побудованим розподілом, а α – порогове значення ймовірності, нижче якого стан вважається аномальним.

Статистичні методи дозволяють ефективно виявляти відхилення, що статистично значущі, враховуючи природну мінливість руху об'єктів. Вони добре працюють у випадках, коли аномалії проявляються як рідкісні події у порівнянні з типовими закономірностями руху.

Перевагами цього підходу є:

- можливість формального обґрунтування критеріїв виявлення аномалій;
- здатність обробляти багатовимірні дані та враховувати залежності між різними параметрами руху;
- гнучкість у визначенні порогів через статистичні оцінки.

Недоліками статистичних методів є:

- залежність від якості та обсягу навчальних даних для формування моделі нормальної поведінки;
- чутливість до неправильного припущення про форму розподілу даних (наприклад, гаусівська апроксимація може бути недостатньо точною для складних або багатомодальних траєкторій);
- обмежена ефективність у випадках швидко змінної або нелінійної поведінки об'єктів, коли статистичні характеристики постійно змінюються.

Для підвищення надійності статистичних методів часто застосовують адаптивні підходи, у яких параметри моделі оновлюються динамічно на основі нових даних, або поєднують із прогнозуючими моделями, такими як фільтр Калмана чи частинкові фільтри. Це дозволяє враховувати тимчасові залежності та

зменшувати вплив шуму, забезпечуючи більш точне та стабільне виявлення аномалій у відеопотоці.

Методи на основі ймовірностей та моделей щільності використовують ймовірнісний підхід для опису поведінки об'єктів у відеопотоці та визначення відхилень, що вказують на аномалії. Основна ідея полягає у побудові моделі ймовірнісного розподілу характеристик руху об'єктів, таких як координати, швидкість, прискорення або локальні ознаки траєкторій, і порівнянні фактичних спостережень з очікуваним розподілом. Якщо ймовірність спостережуваного стану об'єкта є низькою або значно відрізняється від типових значень, то цей стан класифікується як аномальний.

Одним із класичних підходів є використання моделей гаусівської суміші (GMM), де поведінка об'єкта описується комбінацією кількох нормальних розподілів, що дозволяє враховувати багатомодальні закономірності траєкторій. У цьому випадку ймовірність появи конкретного стану об'єкта обчислюється як зважена сума ймовірностей по всіх компонентах моделі. Стан вважається аномалією, якщо ця ймовірність нижча за заздалегідь визначений поріг.

Більш складні ймовірнісні методи використовують непараметричні моделі щільності, такі як ядрові оцінки щільності (KDE), які дозволяють апроксимувати розподіл даних без припущень щодо конкретної форми функції щільності. Це особливо корисно для складних, нелінійних або багатомодальних траєкторій, де параметричні моделі можуть бути недостатньо точними. У таких методах оцінка ймовірності фактичного стану здійснюється через суму вагових внесків сусідніх спостережень у багатовимірному просторі ознак.

Головною перевагою ймовірнісних методів є здатність ефективно виявляти аномалії навіть у випадках складних та багатомодальних закономірностей руху, враховуючи невизначеність у спостереженнях та природну мінливість поведінки об'єктів. Ці методи дозволяють формалізувати критерії виявлення аномалій і забезпечують гнучкість у визначенні порогів та адаптації до динаміки системи.

Недоліком ймовірнісних підходів є значні обчислювальні витрати, особливо при використанні великого числа компонентів у моделях сумішей або при

непараметричних оцінках щільності в багатовимірних просторах. Крім того, ефективність цих методів сильно залежить від достатньої кількості навчальних даних, які точно відображають типову поведінку об'єктів, і від правильно обраних параметрів моделі. У випадках різко змінних або непередбачуваних траєкторій можуть виникати помилкові спрацьовування або пропуски аномалій.

Поєднання ймовірнісних методів із прогнозуванням траєкторій об'єктів, наприклад через фільтри Калмана або частинкові фільтри, дозволяє підвищити точність та стабільність виявлення аномалій, оскільки прогнозовані значення використовуються для оцінки ймовірності відхилень від очікуваної поведінки. Інтегрований підхід забезпечує більш надійне та адаптивне виявлення аномальних подій у відеопотоці.

Методи машинного навчання та нейромережі застосовуються для виявлення аномалій у відеопотоці у випадках, коли траєкторії об'єктів є складними, нелінійними або багатомодальними, а традиційні порогові та ймовірнісні методи не забезпечують достатньої точності. Головна ідея таких методів полягає у навчанні моделі на нормальних прикладах поведінки об'єктів, після чого відхилення від вивчених закономірностей інтерпретується як аномалія.

Серед популярних підходів виділяються автоенкодери та їх модифікації. Автоенкодер навчається відтворювати вхідні дані, стискаючи їх у низьковимірне представлення і потім відновлюючи у вихід. У випадку нормальної поведінки об'єктів модель відтворює траєкторії з низькою похибкою. Аномальні рухи, які відрізняються від тренувальних даних, відновлюються з більшою похибкою, що слугує критерієм їх виявлення. Такий підхід дозволяє моделювати складні часові та просторові закономірності без явного визначення правил або порогів.

Рекурентні нейронні мережі (RNN) та їх модифікації, зокрема LSTM і GRU, дозволяють враховувати довгі послідовності даних про рух об'єктів. Мережа аналізує історію траєкторій і прогнозує наступні координати або характеристики руху. Відхилення фактичного стану від прогнозованого сигналізує про потенційну аномалію. LSTM та GRU завдяки механізмам запам'ятовування і забування

ефективно працюють із довгими часовими залежностями, що робить їх придатними для прогнозування складних та непередбачуваних рухів об'єктів.

Інші підходи включають глибокі згорткові нейронні мережі (CNN) для аналізу відеопотоку як послідовності кадрів. CNN здатні виділяти просторово-часові ознаки руху об'єктів, що потім передаються у RNN або LSTM для аналізу часових закономірностей. Комбінація CNN і RNN дозволяє ефективно виявляти аномалії у динамічних сценах із численними об'єктами та складними взаємодіями.

Перевагою методів машинного навчання та нейромереж є висока точність виявлення аномалій при складних, нелінійних, багатомодальних траєкторіях, здатність моделювати складні часові та просторові залежності, а також можливість автоматичного навчання без потреби задавати ручні пороги чи складні ймовірнісні моделі. Недоліком цих методів є значні обчислювальні витрати, потреба у великому обсязі тренувальних даних, складність налаштування архітектури мережі та ризик перенавчання при недостатній кількості або неповноті навчальних прикладів.

Інтеграція методів машинного навчання з прогнозуванням траєкторій об'єктів дозволяє підвищити стабільність та надійність виявлення аномалій, оскільки модель використовує як історичні дані, так і прогнозовані значення стану для визначення відхилень від очікуваної поведінки. Такий підхід особливо ефективний для складних сцен із численними динамічними об'єктами та непередбачуваними сценаріями руху.

Методи на основі графів та аналізу взаємодій об'єктів застосовуються для виявлення аномалій у відеопотоці шляхом моделювання динамічних взаємозв'язків між об'єктами в просторі та часі. У таких підходах кожен об'єкт у кадрі розглядається як вершина графа, а взаємодії між об'єктами – як ребра, що можуть мати вагу, яка характеризує відстань, швидкість зближення, кутову взаємодію чи інші показники взаємозв'язку. Це дозволяє описувати не лише поведінку окремого об'єкта, а й складні колективні закономірності, які виникають у групах об'єктів.

Графові методи ефективні для аналізу аномалій у сценаріях, де важливе не тільки відхилення від типового руху окремого об'єкта, але й нетипові взаємодії між об'єктами, наприклад несподіване наближення, уникнення чи порушення типових

траєкторій у скупченнях людей чи транспортних потоках. Для аналізу графових структур застосовуються класичні алгоритми на основі відстаней та центральностей, а також сучасні методи глибокого навчання на графах (GNN), які дозволяють враховувати топологічні характеристики графа та нелінійні взаємозв'язки між об'єктами.

Перевагою графових методів є здатність враховувати комплексні взаємодії та контекстну інформацію про середовище, що підвищує точність виявлення аномалій у групових сценаріях і складних динамічних сценах. Недоліком є підвищені обчислювальні витрати та складність побудови та оновлення графової структури в режимі реального часу, особливо при великій кількості об'єктів та швидких змінах їхніх взаємозв'язків.

Інтеграція графових методів з прогнозуванням руху об'єктів дозволяє не тільки оцінювати відхилення траєкторії конкретного об'єкта, а й виявляти нетипові колективні шаблони поведінки, що робить ці методи особливо корисними для моніторингу скупчень людей, транспортних потоків та складних динамічних систем. Таке поєднання дозволяє отримати більш повну та контекстно-залежну оцінку аномалій у відеопотоці, що підвищує ефективність відеоаналітики у реальних умовах.

Практичне застосування

Розглянемо приклад реалізації одного з підходів до виявлення аномальних рухів на основі прогнозованих траєкторій – порівняння фактичного положення об'єкта з його прогнозованою позицією.

Такий метод дозволяє оперативно визначати відхилення від типової поведінки об'єктів, наприклад, різкі зміни положення, які можуть свідчити про аномалію.

Приклад псевдокоду у стилі Python:

```
def detect_anomalies_threshold(predicted_trajectories, current_frame,
                                thresholds):
    for obj_id, current_position in current_frame.objects.items():
        # Отримання прогнозованої позиції об'єкта
        predicted_position = predicted_trajectories.get(obj_id, None)
```

```

if predicted_position is None:
    # Якщо об'єкт новий, ініціалізуємо прогноз
    predicted_trajectories[obj_id] = current_position
    continue

# Обчислення відхилення між фактичним і прогнозованим положенням
position_diff = ((current_position.x - predicted_position.x)**2 +
                  (current_position.y - predicted_position.y)**2)**0.5

# Перевірка на аномалію за порогом
if position_diff > thresholds['position']:
    mark_as_anomalous(obj_id, current_frame.number)

# Оновлення прогнозованої позиції об'єкта
predicted_trajectories[obj_id] = current_position

```

У цьому підході кожен об'єкт порівнюється зі своєю прогнозованою позицією, що обчислюється на основі історії руху за допомогою обраного методу прогнозування. Якщо відхилення фактичного положення від прогнозованого перевищує заданий поріг, рух об'єкта класифікується як аномальний.

ЗАВДАННЯ ДЛЯ ВИКОНАННЯ

Загальні умови

- STEM проєкт виконується на основі лабораторних робіт №1-3 та є їх логічним продовженням.
- Предметна область: динамічні об'єкти у відеопотоках або серіях зображень.
- Вхідні дані: відео тривалістю 30-60 секунд або серія 50-100 кадрів.
- Кількість об'єктів на кадр: 3-6.
- Об'єкти мають перекриватися та змінювати швидкість і форму принаймні на трьох кадрах.
- Вихідні дані: CSV/JSON (ID кадру, ID об'єктів, координати, розмір, швидкість, напрям руху)
- Приклади наборів даних для використання: MOTChallenge, UA-DETRAC, KITTI Tracking, UCSD Pedestrian Dataset, VisDrone, Oxford Town Centre Dataset, Stanford Drone Dataset, DTB70 Drones for Object Tracking.

Етапи виконання STEM проєкту

1. Інтегрувати результати попередніх лабораторних робіт у єдину структуру даних.

Реалізувати програмний алгоритм, який об'єднує результати лабораторних робіт №1-3 у єдину структуру даних, збережену у форматі CSV або JSON. Для кожного об'єкта необхідно забезпечити коректне поєднання детекцій, траєкторій, ознак руху та характеристик аномалій, збережених у попередніх роботах. Структура даних має бути узгоджена та придатна для подальшого аналізу та прогнозування.

2. Створити відео з комплексною візуалізацією об'єктів, траєкторій та аномалій.

Розробити програмний алгоритм обробки відео, який накладає на кожен кадр інформацію про положення об'єктів, їхні траєкторії, швидкість, напрям руху та наявні аномалії. Забезпечити генерацію вихідного відеофайла, що містить усі позначення, потрібні для подальшого аналізу та створення аналітичних матеріалів.

3. Побудувати аналітичні графіки характеристик руху об'єктів.

Реалізувати побудову графічних візуалізацій на основі об'єднаних даних. Необхідно створити графіки зміни швидкості та напрямку руху, а також теплові карти або інші методи відображення зон концентрації об'єктів. Графічні матеріали мають забезпечувати можливість інтерпретації поведінки об'єктів та ідентифікації нетипових подій.

4. Прогнозувати положення об'єктів на наступні кадри відео.

Розробити програмний алгоритм прогнозування руху об'єктів на 5-10 кадрів уперед. Для кожного об'єкта передбачити обчислення майбутніх координат на основі попередніх траєкторій, швидкості та зміни напрямку. Результати прогнозування зберігати в узгодженій структурі та використовувати для подальшого аналізу аномалій.

5. Прогнозувати швидкість та напрям руху об'єктів.

Реалізувати програмний алгоритм оцінювання майбутньої швидкості та напрямку руху для кожного об'єкта. Модель прогнозування має враховувати

історичні дані руху та забезпечувати стійкі результати для різних типів траєкторій. Передбачити можливість порівняння фактичних і прогнозованих значень у подальших візуалізаціях.

6. Візуалізувати фактичні та прогнозовані положення об'єктів на відео.

Додати до відеовізуалізації можливість відображення прогнозованих позицій об'єктів одночасно із фактичними позиціями. Використовувати відповідні позначення, що чітко розрізняють фактичні та прогнозовані траєкторії. Забезпечити коректне поєднання реальних даних, прогнозів та виявлених аномалій у єдиному відео.

7. Виявити аномальні події.

Розробити програмний алгоритм аналізу прогнозованих траєкторій та параметрів руху для визначення потенційних аномалій. До прогнозованих аномалій відносять: вихід об'єкта за допустимі межі, раптові зміни напрямку руху згідно прогнозу, очікувані зіткнення або нетипове прискорення тощо. Система має формувати відповідні позначки для подальшої візуалізації та аналізу.

8. Розробити API для інтеграції обробки відео в інформаційно-аналітичні системи.

Створити універсальний модуль або API, що надає функції для завантаження відео, обробки кадрів, отримання детекцій, ознак, прогнозів і аномалій. Забезпечити можливість використання модуля у сторонніх системах або програмних комплексах.

9. Підготувати аналітичний звіт про результати роботи алгоритмів.

Сформувати звіт, який містить узагальнену інформацію про результати інтеграції, прогнозування, виявлення аномалій та візуалізації. У звіті подати графіки, приклади кадрів, опис структури даних, порівняння фактичних і прогнозованих значень, а також оцінку точності прогнозів. Зробити висновки щодо ефективності реалізованих алгоритмів та можливості їх подальшого використання.

Вимоги до звіту

1. Титульний лист.
2. Лист завдання.

3. Опис ходу виконання кожного завдання STEM проєкту з переліком використаних функцій мови програмування та аналізом отриманих результатів.
4. Лістинг програми з коментарями до ключових частин коду.
5. Скриншоти результатів виконання програми на кожному етапі роботи.
6. Висновки.

Для отримання оцінки за STEM проєкт обов'язковими є захист STEM проєкту та виконання звіту. За умов, коли STEM проєкт не захищено та/або звіт відсутній, STEM проєкт не зараховується.

Питання для самоконтролю

1. Що таке прогнозування руху об'єктів у відеопотоці та які основні цілі цього процесу?
2. Які фактори враховуються при побудові моделей прогнозування руху об'єктів?
3. Опишіть принцип роботи методу лінійної екстраполяції та його обмеження.
4. Як кінематичні моделі покращують точність прогнозу порівняно з простими лінійними методами?
5. У чому полягає ідея фільтра Калмана та які основні компоненти його стандартної моделі?
6. Опишіть принцип роботи частинкових фільтрів та їхні основні переваги і недоліки.
7. У чому суть методу ковзного середнього та для яких сценаріїв руху він найбільш ефективний?
8. Які обмеження методів регресії та класичного машинного навчання у прогнозуванні складних траєкторій?
9. Які переваги і недоліки методів на основі фізичних моделей при прогнозуванні руху об'єктів?

10. Як обрати найбільш придатний метод прогнозування та виявлення аномалій залежно від типу руху об'єктів, рівня шуму та обчислювальних ресурсів?

ЛІТЕРАТУРНІ ДЖЕРЕЛА

1. R. Szeliski, Computer Vision: Algorithms and Applications, 2nd ed. Cham, Switzerland: Springer, 2022.
2. R. C. Gonzalez and R. E. Woods, Digital Image Processing, 4th ed. New York, NY, USA: Pearson, 2020.
3. G. Bradski and A. Kaehler, Learning OpenCV 4: Computer Vision with Python and C++, 2nd ed. Sebastopol, CA, USA: O'Reilly Media, 2020.
4. A. Rosebrock, Deep Learning for Computer Vision with Python. Las Vegas, NV, USA: PyImageSearch Press, 2020.
5. S. Bhandari and P. Shukla, Machine Learning and Deep Learning in Real-Time Computer Vision Applications. Cham, Switzerland: Springer, 2022.
6. Z. Zhang, Y. Zhang, and Y. Guo, Deep Learning for Vision Systems. Singapore: Springer, 2021.
7. R. Sharma and R. Vashisht, Computer Vision Using OpenCV, Python, and Deep Learning. Boca Raton, FL, USA: CRC Press, 2021.
8. C. Sanderson and R. Curtin, Practical Computer Vision Applications Using Deep Learning with CNNs. Birmingham, UK: Packt Publishing, 2021.
9. C. C. Aggarwal, Neural Networks and Deep Learning: A Textbook. Cham, Switzerland: Springer, 2023.
10. B. Wilson, Machine Learning Engineering in Action. Shelter Island, NY, USA: Manning Publications, 2022.
11. D. Situnayake and J. Plunkett, AI at the Edge: Solving Real-World Problems with Embedded Machine Learning. Sebastopol, CA, USA: O'Reilly Media, 2023.
12. I. Goodfellow, Y. Bengio, and A. Courville, Deep Learning. Cambridge, MA, USA: MIT Press, 2016.
13. Z. Liu et al., Swin Transformer and Vision Transformer Architectures. Cham, Switzerland: Springer (Lecture Notes in Computer Science series), 2022.

14. S. Khan et al., Transformers in Vision. New York, NY, USA: ACM Press, 2022.
15. W. Zhao and R. Chellappa, Face Recognition: Deep Learning-Based Approaches. Cham, Switzerland: Springer, 2020.
16. Z. Boulkenafet, R. Raghavendra, and C. Busch, Face Recognition and Biometric Applications Using Deep Learning. Amsterdam, Netherlands: Elsevier, 2021.
17. M. Tan and Q. Le, EfficientNet and Model Scaling for Convolutional Neural Networks. Cham, Switzerland: Springer, 2021.
18. OpenMMLab Development Team, MMDetection: Open-Source Object Detection Toolbox. Singapore: OpenMMLab Press, 2023.
19. Ultralytics, YOLOv8: Real-Time Object Detection and Computer Vision Models. Open-source technical documentation, 2023.

Навчальне видання

**МЕТОДИКИ ІНТЕГРАЦІЇ КОМП'ЮТЕРНОГО ЗОРУ В
ПРОГРАМНІ СИСТЕМИ**

Лабораторний практикум
для здобувачів спеціальності
F2 (121) «Інженерія програмного забезпечення»

Укладачі

Бичков Олексій Сергійович,
Меркулова Катерина Володимирівна,
Жабська Єлизавета Олегівна

ЕЛЕКТРОННЕ ВИДАННЯ