

Хмельницький національний університет
Факультет інформаційних технологій
Кафедра комп'ютерних наук

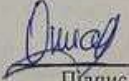
КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА


на тему Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях


Галузь знань 12 – Інформаційні технології
Шифр і назва галузі знань


Спеціальність 122 – Комп'ютерні науки

Освітня програма Комп'ютерні науки
Шифр і назва спеціальності

Виконав: студент 2 курсу, група КНм-22-1  С.С. Онікієнко
Підпис Ініціали, прізвище

Керівник: д.т.н., професор кафедри КН  Е.А. Манзюк
Підпис Ініціали, прізвище

Нормоконтроль: к.т.н., доцент кафедри КН  Р.О. Багрій
Підпис Ініціали, прізвище

До захисту допускаю:
Зав. кафедри КН, д.т.н., професор  О.В. Бармак
Підпис Ініціали, прізвище

08 Чудня 2023 р.

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
Факультет інформаційних технологій
Кафедра комп'ютерних наук
Освітній ступінь магістр
Галузь знань 12 – Інформаційні технології
Спеціальність 122 – Комп'ютерні науки

ЗАТВЕРДЖУЮ
Завідувач кафедри комп'ютерних наук


(підпис)

д.т.н., професор О.В. Бармак

« 1 » 09 2023 року

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ МАГІСТРА

1. Тема кваліфікаційної роботи магістра: Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях
2. Завдання видано студенту Онікієнко Сергію Сергійовичу
(прізвище, ім'я, по батькові)
3. Керівник роботи д.т.н. Манзюк Едуард Андрійович
(прізвище, ім'я, по батькові)
4. Затверджені наказом університету від « 15 » 08 2023 р. № 30
5. Зміст пояснювальної записки (перелік задач) та вихідні дані:

Мета роботи – розробка методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях, особливістю якого є використання генеративної змагальної мережі для об'єктів із покращеними контурами та високою роздільною здатністю для покращення якості супутникових зображень. У дослідженні використовуються різноманітні детекторні мережі в режимі зв'язку, де втрати, отримані в ході виявлення об'єктів, передаються генеративній змагальній мережі з покращеними контурами для підвищення ефективності процесу виявлення. Цей метод спрощує завдання виявлення малих об'єктів на супутникових знімках, дозволяючи вдосконалити процес тренування сучасних моделей виявлення об'єктів та точно визначити місце їх розташування на зображеннях.

Реферат

Кваліфікаційна робота магістра розв'язує науково-практичну задачу розробка методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях, особливістю якого є використання генеративної змагальної мережі для об'єктів із покращеними контурами та високою роздільною здатністю для покращення якості супутникових зображень.

Актуальність теми. Виявлення та локалізація об'єктів на зображеннях, які отримуються з супутників або безпілотних апаратів, є проблемою нагальної актуальності та важливості в сучасному світі. Ця проблема має широкий спектр застосувань у різних галузях, включаючи екологічний моніторинг, спостереження за лісовими ресурсами, забезпечення національної безпеки та управління дорожнім рухом.

Однак існуючі методи та детектори об'єктів часто не відповідають вимогам роботи з низькороздільними та зашумленими супутниковими знімками, особливо при виявленні дрібних об'єктів. На високороздільних зображеннях також спостерігається зниження ефективності виявлення дрібних об'єктів, що потребує розробки нових підходів.

До того ж існуючі набори даних та стандартні тести не враховують специфічні вимоги роботи з супутниковими знімками та вимоги виявлення об'єктів менших розмірів, що робить актуальними подальші дослідження та вдосконалення методів.

Зважаючи на вищезазначені виклики, розробка ефективних методів для виявлення об'єктів на супутникових знімках стає актуальною задачею. Це вимагає вивчення та розробки нових підходів, які враховували б особливості цього типу зображень та забезпечували високу точність та надійність виявлення об'єктів, навіть незважаючи на їхні розміри та умови зйомки. Такі дослідження мають потенціал поліпшити якість та ефективність використання супутникових знімків в різних сферах, що робить цю проблему актуальною.

Крім того, зростаючий обсяг і доступність супутникових та безпілотних знімків створює необхідність у більш точних та швидких методах обробки цих даних. Актуальність цього завдання стає ще більшою у зв'язку з ростом кількості супутників та безпілотних апаратів, які здійснюють зйомку.

Покращення ефективності виявлення об'єктів на супутникових знімках є важливим етапом у впровадженні сучасних технологій та розвитку важливих галузей, таких як геоінформаційні системи, екологічний моніторинг, міське планування, а також у справах національної безпеки.

Досягнення успішних результатів у виявленні об'єктів на супутникових знімках в умовах обмеженої роздільної здатності та зашумленості відкриває нові можливості для використання супутникової та безпілотної технології у сучасному світі. Це може допомогти при розробці стратегій для ефективного управління ресурсами, уникнення екологічних катастроф, забезпечення безпеки та багато інших аспектів, які вимагають аналізу великих масивів даних та виявлення об'єктів.

Загалом, актуальність вирішення проблем виявлення об'єктів на супутникових знімках зниженої роздільної здатності і зашумлених даних є нагальною, і вона відображає потребу у подальших дослідженнях та інноваціях у цій області.

Мета і задачі роботи. Кваліфікаційна робота магістра націлена на розв'язання складної науково-практичної задачі, яка стосується автоматичного виявлення об'єктів на зображеннях з невеликою роздільною здатністю.

Мета кваліфікаційної роботи магістра полягає в створенні ефективного методу, який здатний автоматично виділяти та аналізувати об'єкти на зображеннях із низькою роздільною здатністю, поліпшуючи якість супутникових та інших зображень.

Одним із аспектів цієї проблеми є необхідність виявлення та аналізу об'єктів на супутникових знімках та інших зображеннях, де доступна обмежена якість та деталізація.

Основною особливістю розглянутого методу є його здатність використовувати генеративну змагальну мережу для поліпшення роздільної здатності та контурів об'єктів на зображеннях. Використання генеративних мереж дозволяє підвищити якість та деталізацію зображень, що особливо важливо для виявлення об'єктів з невеликою роздільною здатністю.

Використання генеративних мереж тут виступає як ключовий інструмент для досягнення цієї мети та вдосконалення способів обробки та аналізу обмежених за якістю зображень.

Завдання дослідження магістерської роботи:

1. Провести дослідження наукових робіт та публікацій у галузі обробки зображень, генеративних технологій, та методів виявлення об'єктів.

2. Здійснити збір даних, які включають супутникові зображення об'єктів з невеликою роздільною здатністю та їх відповідні покращені зображення після застосування генеративних мереж.

3. Розробити методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.

4. Провести експериментальні дослідження для оцінки ефективності розробленого методу.

Об'єкт дослідження – процес навчання нейронних мереж, а також генеративних мереж.

Предмет дослідження – методи, моделі, алгоритми та засоби навчання нейронних мереж для виявлення об'єктів на зображеннях з невеликою роздільною здатністю.

Методи дослідження, які застосовані для вирішення поставлених завдань є такими: методи інтелектуального аналізу даних, методи проєктування систем штучного інтелекту, методи глибоких мереж, алгоритми згорткових нейронних мереж, алгоритми генеративних мереж.

Наукова новизна одержаних результатів полягає в тому, що поєднується створення зображень високої роздільної здатності на основі вихідних низькороздільних супутникових знімків і одночасне виявлення об'єктів

на високороздільних зображеннях. Цей метод використовує глибоку генеративну змагальну мережу, яка має значний потенціал у покращенні якості зображень. В роботі вирішується проблема відсутності важливої високочастотної інформації на покращених зображеннях, яка стосується деталей та граничних контурів об'єктів. Ця проблема впливає на точність виявлення дрібних об'єктів на відновлених і зашумлених зображеннях з низькою роздільною здатністю. Вирішення цієї проблеми є ключовим аспектом наукової новизни даного дослідження та може мати важливі наслідки для сфер, де важливий аналіз низькороздільних супутникових знімків для виявлення дрібних об'єктів.

В результаті проведеної роботи було отримано такі результати:

– розроблено метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях, який дозволяє покращити виявлення невеликих об'єктів, що досягається за рахунок використання генеративної змагальної мережі для поліпшення роздільної здатності та контурів об'єктів на зображеннях.

Практичне значення одержаних результатів. Отримані результати цього дослідження мають значуще практичне застосування. Розроблений новий підхід до виявлення об'єктів на супутникових знімках з низькою роздільною здатністю, що базується на використанні генеративної змагальної мережі, який має великий потенціал у розв'язанні практичних завдань у різних сферах. Використання генеративної змагальної мережі допомагає підвищити якість супутникових зображень шляхом покращення контурів та деталей об'єктів. Це корисно для великої кількості застосувань, включаючи картографію, геодезію, моніторинг земельного використання та інші. Підхід, який поєднує покращення зображень і виявлення об'єктів, робить можливим автоматичне виділення та аналіз об'єктів на супутникових знімках. Це має важливе значення для багатьох галузей, включаючи рятувальні операції, аналіз екологічних проблем та інші.

Розроблений метод спрощує завдання виявлення малих об'єктів на великих супутникових знімках, що охоплюють значні території. Це дозволяє

ефективно тренувати моделі виявлення об'єктів та точно визначати місцезнаходження об'єктів на зображеннях навіть у великому масштабі.

Отже, практичне значення цього дослідження полягає в можливості поліпшення супутникових зображень, автоматизації процесу виявлення об'єктів та ефективному аналізі великих територій, що є критичним для багатьох галузей, включаючи геодезію, картографію, екологію, та інші.

Апробація результатів кваліфікаційної роботи магістра та публікації.

Одержані наукові і практичні результати кваліфікаційної роботи магістра доповідались в доповіді на тему «Детектування об'єктів на зображеннях з невеликою роздільною здатністю» на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» (17-18 листопада 2023 року); за темою роботи автором виконано наукову публікацію:

Онікієнко С.С., Глухов В.Ю., Манзюк Е.А. Детектування об'єктів на зображеннях з невеликою роздільною здатністю. Збірник наукових праць за матеріалами XV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023». Хмельницький, 2023. с. 236-238.

Структура і обсяг роботи. Кваліфікаційна робота магістра складається з наступного: реферату, завдання, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань з 42 найменування й 2-х додатків. Загальний обсяг кваліфікаційної роботи магістра становить 98 сторінок, із них 75 сторінок основного тексту й 12 сторінок додатків. В роботі наведено 17 рисунків й однієї таблиці.

Ключові слова: нейронна мережа, згорткова нейронна мережа, генеративна мережа, інформаційна система, роздільна здатність зображення.

Зміст

Вступ.....	4
Розділ 1	
Аналіз систем штучного інтелекту з виявлення об'єктів на зображеннях	9
1.1 Задача виявлення об'єктів на зображеннях.....	9
1.2 Аналіз предметної області з детектування об'єктів малих розмірів	10
1.3 Детектування об'єктів на основі глибокого навчання	16
Постановка задачі.....	20
Висновки до розділу 1	21
Розділ 2	
Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.....	23
2.1 Архітектура глибокого навчання для виявлення дрібних об'єктів на зображеннях.....	23
2.2 Архітектура генеративної мережі.....	26
2.3 Мережа покращення меж об'єктів	28
2.4 Дискримінатор визначення об'єктів	33
2.5 Втрати дискримінатора при визначенні об'єктів.....	37
2.6 Навчання системи виявлення об'єктів.....	40
Висновки до розділу 2	42
Розділ 3	
Формування множини даних та навчання з виявлення об'єктів з невеликою роздільною здатністю	43
3.1 Система анотування об'єктів на зображеннях.....	43
3.2 Вплив високої роздільної здатності на завдання виявлення об'єктів	47
3.3 Маркування об'єктів та робота системи з виявлення об'єктів з невеликою роздільною здатністю на зображеннях	47
3.4 Навчання системи з виявлення об'єктів з невеликою роздільною здатністю на зображеннях.....	50
3.5 Тестування системи виявлення об'єктів з невеликою роздільною здатністю на зображеннях.....	52
Висновки до розділу 3	53

Розділ 4

Експериментальне дослідження виявлення об'єктів з невеликою роздільною здатністю на зображеннях	55
4.1 Умови проведення експериментальних досліджень	55
4.2 Використання контекстного набору даних	55
4.3 Метрики оцінки виявлення об'єктів на зображеннях	57
4.4 Визначення ефективності детекторів.....	59
4.5 Визначення об'єктів на зображеннях високої роздільної здатності.....	61
4.6 Залежність точності класифікації від коефіцієнту перетину	63
4.7 Вплив розміру масиву даних на показники якості визначення об'єктів.....	65
Висновки до розділу 4	72
Загальний висновок.....	73
Перелік посилань.....	75
Додатки.....	80

Вступ

Кваліфікаційна робота магістра розв'язує науково-практичну задачу розробка методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях, особливістю якого є використання генеративної змагальної мережі для об'єктів із покращеними контурами та високою роздільною здатністю для покращення якості супутникових зображень.

Актуальність теми. Виявлення та локалізація об'єктів на зображеннях, які отримуються з супутників або безпілотних апаратів, є проблемою великої актуальності та важливості в сучасному світі. Ця проблема має широкий спектр застосувань у різних галузях, включаючи екологічний моніторинг, спостереження за лісовими ресурсами, забезпечення національної безпеки та управління дорожнім рухом.

Однак існуючі методи та детектори об'єктів часто не відповідають вимогам роботи з низькороздільними та зашумленими супутниковими знімками, особливо при виявленні дрібних об'єктів. На високороздільних зображеннях також спостерігається зниження ефективності виявлення дрібних об'єктів, що потребує розробки нових підходів.

До того ж існуючі набори даних та стандартні тести не враховують специфічні вимоги роботи з супутниковими знімками та вимоги виявлення об'єктів менших розмірів, що робить актуальними подальші дослідження та вдосконалення методів.

Зважаючи на вищезазначені виклики, розробка ефективних методів для виявлення об'єктів на супутникових знімках стає актуальною задачею. Це вимагає вивчення та розробки нових підходів, які враховували б особливості цього типу зображень та забезпечували високу точність та надійність виявлення об'єктів, навіть незважаючи на їхні розміри та умови зйомки. Такі дослідження мають потенціал поліпшити якість та ефективність використання супутникових знімків в різних сферах, що робить цю проблему актуальною.

Крім того, зростаючий обсяг і доступність супутникових та безпілотних знімків створює необхідність у більш точних та швидких методах обробки цих даних. Актуальність цього завдання стає ще більшою у зв'язку з ростом кількості супутників та безпілотних апаратів, які здійснюють зйомку.

Покращення ефективності виявлення об'єктів на супутникових знімках є важливим етапом у впровадженні сучасних технологій та розвитку важливих галузей, таких як геоінформаційні системи, екологічний моніторинг, міське планування, а також у справах національної безпеки.

Досягнення успішних результатів у виявленні об'єктів на супутникових знімках в умовах обмеженої роздільної здатності та зашумленості відкриває нові можливості для використання супутникової та безпілотної технології у сучасному світі. Це може допомогти при розробці стратегій для ефективного управління ресурсами, уникнення екологічних катастроф, забезпечення безпеки та багато інших аспектів, які вимагають аналізу великих масивів даних та виявлення об'єктів.

Загалом, актуальність вирішення проблем виявлення об'єктів на супутникових знімках умовно зниженої роздільної здатності і зашумлених даних є нагальною, і вона відображає потребу у подальших дослідженнях та інноваціях у цій області.

Мета і задачі роботи. Кваліфікаційна робота магістра націлена на розв'язання складної науково-практичної задачі, яка стосується автоматичного виявлення об'єктів на зображеннях з невеликою роздільною здатністю

Мета кваліфікаційної роботи магістра полягає в створенні ефективного методу, який здатний автоматично виділяти та аналізувати об'єкти на зображеннях із низькою роздільною здатністю, поліпшуючи якість супутникових та інших зображень.

Одним із аспектів цієї проблеми є необхідність виявлення та аналізу об'єктів на супутникових знімках та інших зображеннях, де доступна обмежена якість та деталізація.

Основною особливістю розглянутого методу є його здатність використовувати генеративну змагальну мережу для поліпшення роздільної здатності та контурів об'єктів на зображеннях. Використання генеративних мереж дозволяє підвищити якість та деталізацію зображень, що особливо важливо для виявлення об'єктів з невеликою роздільною здатністю.

Використання генеративних мереж тут виступає як ключовий інструмент для досягнення цієї мети та вдосконалення способів обробки та аналізу обмежених за якістю зображень.

Завдання дослідження магістерської роботи:

1. Провести дослідження наукових робіт та публікацій у галузі обробки зображень, генеративних технологій, та методів виявлення об'єктів.

2. Здійснити збір даних, які включають супутникові зображення об'єктів з невеликою роздільною здатністю та їх відповідні покращені зображення після застосування генеративних мереж.

3. Розробити методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.

4. Провести експериментальні дослідження для оцінки ефективності розробленого методу.

Об'єкт дослідження – процес навчання нейронних мереж, а також генеративних мереж.

Предмет дослідження – методи, моделі, алгоритми та засоби навчання нейронних мереж для виявлення об'єктів на зображеннях з невеликою роздільною здатністю.

Методи дослідження, які застосовані для вирішення поставлених завдань є такими: методи інтелектуального аналізу даних, методи проєктування систем штучного інтелекту, методи глибоких мереж, алгоритми згорткових нейронних мереж, алгоритми генеративних мереж.

Наукова новизна одержаних результатів полягає в тому, що поєднується створення зображень високої роздільної здатності на основі вихідних низькороздільних супутникових знімків і одночасне виявлення об'єктів

на високороздільних зображеннях. Цей метод використовує глибоку генеративну змагальну мережу, яка має значний потенціал у покращенні якості зображень. В роботі вирішується проблема відсутності важливої високочастотної інформації на покращених зображеннях, яка стосується деталей та граничних контурів об'єктів. Ця проблема впливає на точність виявлення дрібних об'єктів на відновлених і зашумлених зображеннях з низькою роздільною здатністю. вирішення цієї проблеми є ключовим аспектом наукової новизни даного дослідження та може мати важливі наслідки для областей, де важливий аналіз низькороздільних супутникових знімків для виявлення дрібних об'єктів.

В результаті проведеної роботи було отримано такі результати:

– розроблено метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях, який дозволяє покращити виявлення невеликих об'єктів, що досягається за рахунок використання генеративної змагальної мережі для поліпшення роздільної здатності та контурів об'єктів на зображеннях.

Практичне значення одержаних результатів. Отримані результати цього дослідження мають значуще практичне застосування. Розроблений новий підхід до виявлення об'єктів на супутникових знімках з низькою роздільною здатністю, що базується на використанні генеративної змагальної мережі, виявляє великий потенціал у розв'язанні практичних завдань у різних сферах. Використання генеративної змагальної мережі допомагає підвищити якість супутникових зображень шляхом покращення контурів та деталей об'єктів. Це корисно для великої кількості застосувань, включаючи картографію, геодезію, моніторинг земельного використання та інші. Підхід, який поєднує покращення зображень і виявлення об'єктів, робить можливим автоматичне виділення та аналіз об'єктів на супутникових знімках. Це має важливе значення для багатьох галузей, включаючи рятувальні операції, аналіз екологічних проблем та інші.

Розроблений метод спрощує завдання виявлення малих об'єктів на великих супутникових знімках, що охоплюють значні території. Це дозволяє

ефективно тренувати моделі виявлення об'єктів та точно визначати місцезнаходження об'єктів на зображеннях навіть у великому масштабі.

Отже, практичне значення цього дослідження полягає в можливості поліпшення супутникових зображень, автоматизації процесу виявлення об'єктів та ефективному аналізі великих територій, що є критичним для багатьох галузей, включаючи геодезію, картографію, екологію, та інші.

Апробація результатів кваліфікаційної роботи магістра та публікації
Одержані наукові і практичні результати кваліфікаційної роботи магістра доповідались в доповіді на тему «Детектування об'єктів на зображеннях з невеликою роздільною здатністю» на XV Всеукраїнській науково-практичній конференції «Актуальні проблеми комп'ютерних наук АПКН-2023» (17-18 листопада 2023 року); за темою роботи автором виконано наукову публікацію:

Онікієнко С.С., Глухов В.Ю., Манзюк Е.А. Детектування об'єктів на зображеннях з невеликою роздільною здатністю. Збірник наукових праць за матеріалами XV Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКН-2023». Хмельницький, 2023. с. 236-238.

Структура і обсяг роботи. Кваліфікаційна робота магістра складається з наступного: реферату, завдання, змісту, переліку скорочень, вступу, 4 розділів, висновків, переліку посилань з 42 найменування й 2-х додатків. Загальний обсяг кваліфікаційної роботи магістра становить 98 сторінок, із них 75 сторінок основного тексту й 12 сторінок додатків. В роботі наведено 17 рисунків й однієї таблиці.

Розділ 1

Аналіз систем штучного інтелекту з виявлення об'єктів на зображеннях

1.1 Задача виявлення об'єктів на зображеннях

Виявлення та локалізація об'єктів на зображеннях, отриманих із супутників або безпілотних апаратів, демонструє широкий потенціал застосування в різних галузях, включаючи екологічний моніторинг, спостереження за лісовими ресурсами, забезпечення національної безпеки та управління дорожнім рухом [4, 6, 35, 36, 41]. Проте наявні дослідження вказують на недоліки ефективності виявлення, особливо в умовах низької роздільної здатності і зашумленості зображень, особливо при об'єктах невеликих розмірів. При цьому, на високороздільних зображеннях ефективність виявлення дрібних об'єктів також падає порівняно із великими об'єктами [8, 24, 26, 27].

Сучасні детектори продемонстрували високу точність на стандартних наборах даних, які включають зображення з помітними і відносно великими об'єктами [9, 11, 15, 32]. Однак такі набори даних не враховують специфічні вимоги роботи з супутниковими знімками та вимоги виявлення об'єктів менших розмірів. Розробка ефективних методів для подолання цих викликів стає актуальною проблемою для подальшого вдосконалення систем виявлення об'єктів в реальних умовах дистанційного спостереження.

На супутникових знімках спостерігаються різноманітні об'єкти, такі як будинки, автомобілі, різні резервуари, басейни тощо, які займають обмежену площу. Сучасні детектори проявляють істотний розрив у продуктивності між низькороздільними зображеннями та їхніми високороздільними аналогами. Цей розрив пояснюється відсутністю вхідних ознак для виявлення невеликих об'єктів [5, 22, 23, 25, 31].

Крім загальних детекторів об'єктів, запропоновано спеціалізовані методи, алгоритми та мережеві архітектури для виявлення конкретних типів об'єктів на

спутникових зображеннях, такі як транспортні засоби або будівлі. Ці методи орієнтовані на конкретні класи об'єктів та використовують фіксовану роздільну здатність для виділення та виявлення характерних ознак.

Для підвищення точності виявлення об'єктів на знімках, використовують методи високої роздільної здатності, що базуються на глибоких згорткових нейронних мережах. Ці методи передбачають створення штучних високороздільних зображень і подальше використання їх для ефективного виявлення об'єктів, що призводить до підвищення якості та надійності процесу виявлення на супутникових знімках.

1.2 Аналіз предметної області з детектування об'єктів малих розмірів

Методи з використанням високої роздільної здатності, ґрунтовані на згорткових нейронних мережах, виявилися дієвими у створенні високороздільних зображень на основі вхідних даних низької роздільної здатності [3, 17, 29, 33]. Ці методи охоплюють як згорткові мережі зі здатністю обробки високороздільних зображень на основі єдиного вхідного зображення, так і алгоритми, які використовують глибокі згорткові мережі для підвищення роздільності зображень.

Зокрема, генеративні мережі, такі як генеративні змагальні мережі з високою роздільною здатністю та покращені ГЗМ з високою роздільною здатністю, виявилися ефективними у покращенні якості низькороздільних зображень, які можуть містити шум або бути відновленими [2, 10, 13, 14, 38, 42]. Ці моделі складаються з двох підмереж: генератора та дискримінатора, і обидві мають глибокі згорткові архітектури.

Для тренування і оцінки використовуються набори даних, що містять пари зображень високої та низької роздільної здатності. Ці методи виявляються дієвими у вирішенні задачі підвищення роздільності зображень, роблячи їх більш якісними і придатними для подальшого аналізу та обробки.

Генератор відтворює високороздільні зображення на основі низькороздільної вхідної інформації, в той час як дискримінатор використовується для прогнозування, чи є створене зображення високої роздільної здатності реальним або результатом підвищення роздільності низькороздільного зображення. Після належного навчання генератор стає здатним створювати високороздільні зображення, які мають аналогічний ступінь реалістичності зі справжніми високороздільними зображеннями, і дискримінатор перестає ефективно розрізняти між справжніми та створеними зображеннями.

Архітектура глибоких згорткових генеративних мереж зображена на рисунку 1.1. Основний принцип функціонування ГЗМ полягає в створенні генератором G фальшивих даних, які якомога ближче до розподілу реальних даних. З іншого боку, дискримінатор D має завдання відрізняти справжні дані від фальшивих.

На вхід генератора подається випадковий вектор шуму z , який зазвичай має рівномірний або нормальний розподіл. Генератор G перетворює цей шум в новий простір даних, створюючи фальшиву вибірку $G(z)$, яка є багатовимірним вектором.

Дискримінатор D функціонує як бінарний класифікатор. Він приймає на вхід як справжні дані з набору даних, так і фальшиву вибірку, згенеровану генератором G . На виході дискримінатора D отримуємо ймовірність того, що зразок є справжнім, а не синтезованим.

Коли дискримінатор D не може однозначно визначити, чи дані походять з реального набору даних чи з генератора, досягається оптимальний стан. У цей момент отримуємо модель генератора G , яка навчилася відтворювати розподіл реальних даних.

Ця архітектура ГЗМ відіграє важливу роль у завданнях глибокого навчання та генерації даних.

Генеративні змагальні мережі складаються із двох компонентів: генератора і дискримінатора. Генератор виробляє штучні зображення на основі випадкового шуму, тоді як дискримінатор спробує розрізнити створені

генератором штучні зображення від реальних зображень, які використовуються для тренування.

Отримані зображення можуть виглядати відповідним чином з компенсованими деякими деталями, такими як граничні контури на зображеннях. Однак в деяких наукових дослідженнях було показано, що ця компенсація може вплинути на класифікацію у негативному напрямку.




Рисунок 1.1 – Схема генеративної змагальної мережі [28]

Інформація про граничні контури є суттєвою для ефективного виявлення об'єктів, і тому її збереження на покращених зображеннях є важливим аспектом для забезпечення високої точності у завданні виявлення об'єктів на зображеннях.

Для отримання необхідної інформації про граничні контури було запропоновано кілька методів, які використовують глибокі ознаки граничних меж. Результати цих методів виявилися задовільними для стандартних зображень, але їх продуктивність погіршується на зображеннях з низькою роздільною здатністю та у випадку наявності шуму на супутникових знімках. З метою отримання якісних результатів з належною кількістю інформації про граничні контури було розроблено новий метод, який використовує підсилену мережу для виділення граничних меж на основі генеративної змагальної мережі.

У генеративній змагальній мережі використовуються дві підмережі для генератора. Одна із них створює проміжні високороздільні значення, тоді як інша генерує незашумлені граничні контури з додаткових зображень. Для

виділення граничних контурів у цьому методі застосовується оператор Лапласа, і для отримання чистих граничних контурів використовується маска об'єкта. Цей підхід дозволяє зберегти достатню інформацію про граничні контури, але внаслідок додавання шуму для поліпшення граничних контурів кінцеві зображення можуть виявитися розмитими, що погіршує ефективність виявлення об'єктів.

Ще однією важливою задачею є виявлення малих об'єктів, яка ускладнюється отриманням зображень високої роздільної здатності. Багато систем вимагають постійного моніторингу великих територій для цілей регулювання або організації дорожнього руху. Однак часте використання супутникових знімків високої роздільної здатності стає проблематичним через велику відстань дискретизації. Для виявлення невеликих об'єктів, таких як будівлі та автомобілі, комерційні супутникові знімки стають більш підходящими альтернативами до загальнодоступних супутникових знімків, таких як LoveDA і MiniFrance.

Супутникові знімки загальнодоступного характеру, такі як LoveDA і MiniFrance, не є ідеальними для виявлення дрібних об'єктів через велику відстань дискретизації. У випадку, коли потрібно виявити малі об'єкти, такі як будівлі чи автомобілі, більш придатними для цього виявляються комерційні супутникові знімки.

Запропоновано ряд методів, які використовують глибокі згорткові нейронні мережі. Зокрема, була розроблена високороздільна згорткова нейронна мережа для поліпшення зображень низької роздільної здатності в процесі наскрізного навчання. Цей підхід виявився ефективнішим порівняно з попередніми методами високороздільної здатності. Згодом, глибокі нейронні мережі для високороздільної здатності стали швидко розвиватися, і вдосконалили їх, додавши залишкові блоки та мережі зі щільними зв'язками для поліпшення результатів.

На рисунку 1.2 показана архітектура генеративної змагальної мережі, яка включає в себе генераторну та дискримінаційну мережі.

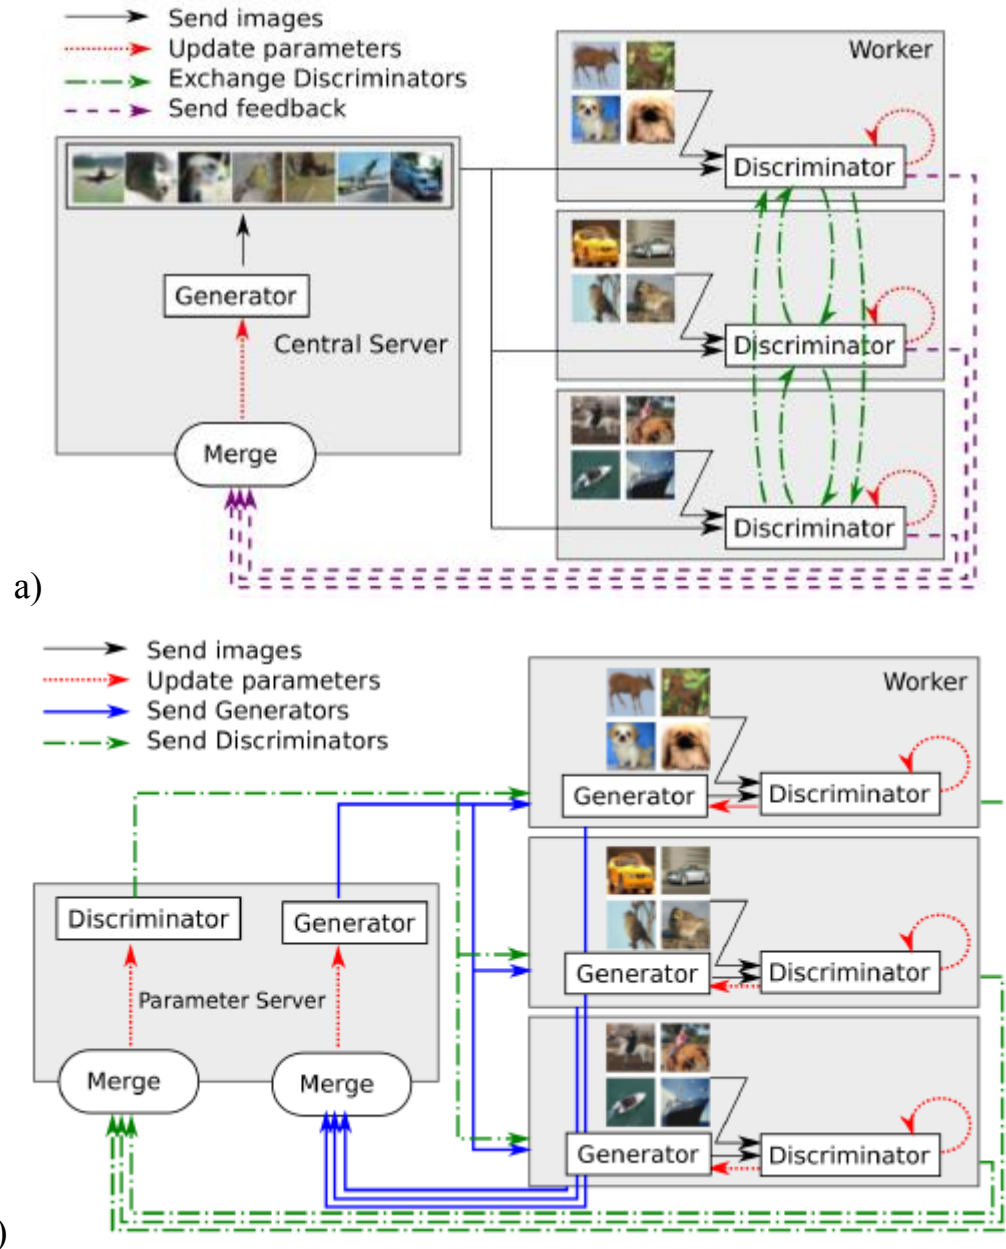


Рисунок 1.2 – Архітектура генеративної змагальної мережі з використанням конкурентів за розподілу ГЗМ: а) модель зв'язку MDGAN б) моделлю FLGAN [18]

Фреймворк генеративної змагальної мережі був представлений як засіб для генерування фотореалістичних природних зображень з високим коефіцієнтом збільшення. Автори вперше впровадили функцію перцептивних втрат, яка комбінує втрати від змагальності та втрати від змісту. Втрата від змагальності сприяла створенню зображення високої роздільної здатності, схожі

на вихідні фотореалістичні зображення, і сприяла дискримінатору у розрізненні зображень високої роздільної здатності від вихідних фотореалістичних зображень. Також була використана втрата вмісту для забезпечення подібності перцептивного вмісту.

FLGAN – федеративне навчання, адаптоване до ГЗМ [7, 19, 21, 39]. MDGAN використовує один генератор, розміщений на сервері. FLGAN використовує генератори на сервері та на кожній робочій станції. MDGAN обмінюється дискримінаторами між працівниками за принципом рівний-рівному, тоді як у FLGAN вони залишаються фіксованими і усереднюються сервером після отримання. У системі генератор відповідає за створення нових зображень, тоді як завданням дискримінатора є розрізнення між реальними зображеннями і тими, які були згенеровані. Генератор включає залишкові блоки з пропусковими з'єднаннями і функцією активації ReLU [1, 12, 40]. У цих блоках використовуються ядра розміром 3×3 та містять 72 карти ознак і крок, рівний одиниці для згорткових шарів. Генератор також включає шари підвищеної дискретизації для поліпшення роздільної здатності зображень.

Дискримінатор складається зі згорткових блоків з функцією активації ReLU та повністю пов'язаного шару з кінцевою сигмоїдальною активацією. У дискримінаторі використовуються ядра розміром 3×3 з різною кількістю карт ознак і різними кроками. Важливо відзначити, що в цій системі використовуються глибокі нейронні мережі без використання шару пакетної нормалізації, що призвело до значного покращення продуктивності та стабільного навчання глибокої мережі. Ці дослідження проводилися на звичайних зображеннях. Додатково була запропонована глибока мережа високої роздільної здатності для обробки багатоспектральних супутникових зображень [16, 37]. Автори цього методу досягли хороших результатів порівняно з традиційними методами інтерполяції. Також був розроблений метод, який дозволяє створювати гіперспектральні зображення високої роздільної здатності зі зображень низької роздільної здатності шляхом використання трансферного навчання.

Для навчання моделі використовувалися природні зображення, аби надалі використовувати цю модель для аналізу гіперспектральних зображень, використовувалось трансферне навчання. Був запропонований метод, що базується на генеративній змагальній мережі для покращення роздільної здатності супутникових зображень. Автори вирішили зменшити споживання пам'яті та час обчислень у генераторі, видаливши шари пакетної нормалізації.

Щоб подолати виклик нестачі навчальних даних у багатьох застосунках для обробки зображень, використали техніку трансферного навчання у своєму підході. Так було розроблено нову архітектуру для високої роздільної здатності супутникових зображень на основі генеративної змагальної мережі. Також вводили мережу для посилення граничних меж, яка сприяла отриманню більш плавних граничних меж між частинами зображення на кінцевому результаті. Для отримання чітких граничних меж на супутникових зображеннях була запропонована багатозадачна глибока нейронна мережа, яка одночасно вирішує завдання високої роздільної здатності і колоризації зображень. Для процесу колоризації комбінували природні зображення зі супутниковими знімками. Щодо завдання високої роздільної здатності зображень, була запропонована багатомасштабна симетрична архітектура глибокого кодера-декодера. Інша архітектура високої роздільної здатності, відома як локально-глобальна комбінована мережа. Ця архітектура була навчена для багаторівневого відтворення супутникових зображень, здатного враховувати як локальні деталі, так і глобальне контекстне оточення.

1.3 Детектування об'єктів на основі глибокого навчання

Можна провести поділ детекторів об'єктів на основі глибокого навчання на дві основні категорії: моделі згорткових нейронних мереж з двоетапним виявленням і одноетапні моделі. До групи з двоетапним виявленням відносяться такі моделі як RCNN, Fast RCNN, та Faster RCNN, в той час як представником найбільш використовуваних одноетапних детекторів є You Only Look Once

(YOLO). У двоетапних детекторах на першому етапі визначаються області інтересу, за допомогою селективного пошуку або мережі пропозицій областей. Наступним кроком є оцінка вибраних областей на предмет наявності певних типів об'єктів та генерація мінімальних обмежувальних рамок для виявлених об'єктів. На рисунку 1.3 показано високорівневу архітектуру швидшої RCNN, що складається з етапів.

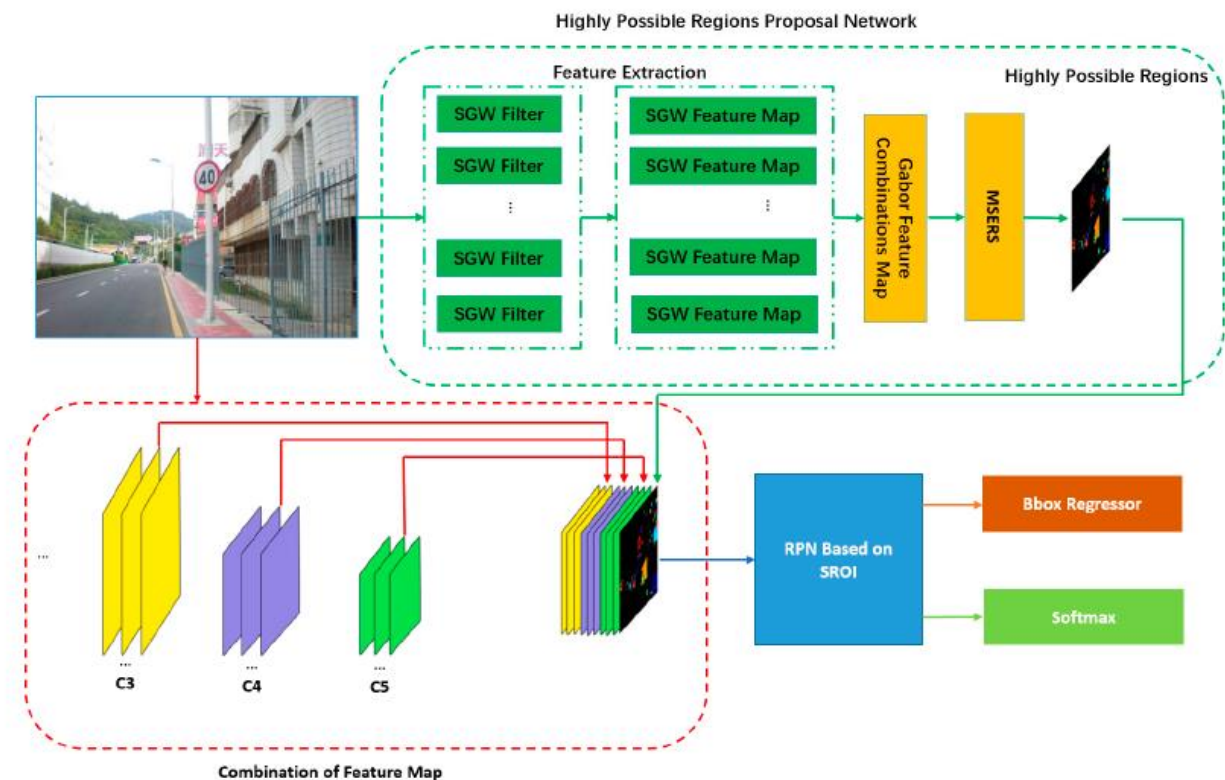


Рисунок 1.3 – Faster RCNN двоетапний детектор із мережею пропозиції регіонів і класифікації [30]

На відміну від цього, одноетапні детектори знижують потребу у мережі пропозицій регіонів і здійснюють виявлення на щільній вибірці всіх можливих місць. Це робить їх швидшими, але, як правило, менш точними в порівнянні з двоетапними аналогами. RetinaNet, наприклад, вирішує проблему дисбалансу даних, спричинену великою кількістю фонових об'єктів, за допомогою фокальної функції втрат, і часто досягає продуктивності, яка схожа на двоетапні підходи.

Для ефективного виявлення та підрахунку дрібних об'єктів, таких як транспортні засоби на супутникових знімках, було запропоновано різноманітні

глибокі детектори об'єктів на основі згорткових нейронних мереж. Зокрема, була представлена нейронна мережа зі згортковою регресією для виявлення транспортних засобів на супутникових знімках. Крім того, був розроблений глибокий детектор на основі згорткових нейронних мереж.

Для ефективного виявлення різнонаправлених транспортних засобів на супутникових знімках було розроблено метод, який комбінує глибоку згорткову нейронну мережу для отримання ознак і метод опорних векторів для класифікації об'єктів. Також була внесена модифікація до швидкісного детектора RCNN з метою виявлення дрібних об'єктів на супутникових знімках. Ця модифікація включала зміни у мережі пропозиції регіонів та додавала контекстну інформацію до детектора. Деякі автори також пропонували модифіковані версії швидкісного RCNN-детектора, де використовувалася мережа гіперрегіонів для покращення здатності до запам'ятовування та застосовувався каскадний класифікатор з посиленням для перевірки регіонів-кандидатів [20, 34]. Цей класифікатор допомагав зменшити кількість помилкових виявлень шляхом ідентифікації жорстких негативних прикладів.

Крім того, було запропоновано також підходи, які використовують наскрізний детектор літаків на основі мережі SSD з використанням трансферного навчання. Автори успішно навчали ці моделі, навіть при обмеженій кількості доступних зображень літаків. Щоб подолати проблему обмеженості розміру вхідних даних, вони застосовували метод розбиття великих зображень на менші фрагменти. На цих менших фрагментах відбувалося виявлення об'єктів, а потім результати співставлялися з вихідними зображеннями.

Проведені дослідження підтвердили, що метод виявлення об'єктів на супутникових знімках працює більш ефективно, ніж SSD-модель. Важливо відзначити, що оптимізація параметрів глибоких згорткових нейронних мереж позитивно впливає на результати виявлення об'єктів на супутникових знімках. Для цієї мети використовували детектор об'єктів YOLO для оптимізації параметрів і отримання результатів.

Деякі наукові дослідження також продемонстрували хороші результати в області виявлення дрібних об'єктів на супутникових знімках. Була запропонована архітектура піраміди ознак, яка використовує спадну архітектуру з бічними зв'язками. Ця архітектура дозволяє створювати високорівневі семантичні карти ознак на різних масштабах. Використання цих карт ознак як екстракторів ознак для швидшого RCNN виявилось ефективним методом поліпшення виявлення об'єктів, особливо при обробці дрібних об'єктів.

Була розроблена нова архітектура блоку рецептивних полів, на основі рецептивних полів в зоровій системі людини. Цей модуль використовує залежність між розміром і ексцентриситетом рецептивних полів для покращення розрізнення ознак та збільшення надійності виявлення об'єктів. У результаті використання цього модуля у верхніх загорткових шарах виявлення об'єктів покращилася ефективність виявлення об'єктів різних розмірів.

З метою покращення точності виявлення об'єктів та прискорення процесу обробки інформації було запропоновано використовувати одноетапний детектор, відомий як нейронна мережа з одномоментним уточненням. Цей детектор продемонстрував високу ефективність при виявленні дрібних об'єктів. У структурі цього детектора використовуються два ключові модулі: модуль уточнення якорів, призначений для видалення невдало підібраних якорів, та модуль виявлення об'єктів, який отримує дані від уточнених якорів. Ця процедура уточнення дозволяє досягти більш ефективного виявлення дрібних об'єктів, в порівнянні з попередніми методами.

Також був запропонований метод злиття ознак, в якому ознаки з різних шарів мережі і різних масштабів об'єднуються, а потім за допомогою блоків пониження роздільності створюються нові піраміди ознак. Ці об'єднані ознаки подаються на мультибоксовий детектор для передбачення об'єктів. Процес злиття ознак дозволив підвищити ефективність виявлення як для великих, так і для дрібних об'єктів. Було здійснено навчання детекторів об'єктів з використанням лише одного знімка, та цей підхід показав високі результати на різних стандартних наборах даних. Для підвищення ефективності виявлення

дрібних об'єктів було проведено модифікації. Зокрема, був видалений перший шар понижувальної дискретизації, і введено кореневий блок з модифікованими фільтрами для отримання більше локальної інформації зображення. Ця модифікація дозволила детектору витягти більш потужні ознаки, що сприяло виявленню дрібних об'єктів.

Варто зазначити, що всі розглянуті дослідження були спрямовані на роботу зі звичайними зображеннями. Проте, був розроблений метод для виявлення дрібних об'єктів на супутникових знімках. У цьому методі використовувалася модифікована версія швидкої RCNN для виявлення об'єктів, які можуть бути як великими, так і дрібними. Важливою частиною цього методу була мережа щільних пірамід ознак обертання, яка дозволила покращити ефективність виявлення дрібних об'єктів.

Постановка задачі

Метою магістерської дисертації є розробка ефективного методу, спроможного автоматично виділяти та аналізувати об'єкти на зображеннях з низькою роздільною здатністю, зокрема на супутникових та інших знімках, де якість та деталізація обмежені.

Важливість цієї проблеми впливає з потреби виявлення та аналізу об'єктів на зображеннях, де доступна обмежена роздільна здатність та деталі. Основною особливістю розглянутого методу є його здатність використовувати генеративну змагальну мережу для покращення роздільної здатності та чіткості контурів об'єктів на зображеннях. Застосування генеративних мереж дозволяє підвищити якість та деталізацію зображень, що має особливе значення для ефективного виявлення об'єктів при обмеженій роздільній здатності.

Завдання дослідження магістерської роботи:

1. Провести дослідження наукових робіт та публікацій у галузі обробки зображень, генеративних технологій, та методів виявлення об'єктів.

2. Здійснити збір даних, які включають супутникові зображення об'єктів з невеликою роздільною здатністю та їх відповідні покращені зображення після застосування генеративних мереж.

3. Розробити метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.

4. Провести експериментальні дослідження для оцінки ефективності розробленого методу.

Використання генеративних мереж тут виступає як ключовий інструмент для досягнення цієї мети та вдосконалення способів обробки та аналізу обмежених за якістю зображень.

Висновки до розділу 1

У цьому розділі було проведено глибокий аналіз систем штучного інтелекту, спрямований на виявлення об'єктів на зображеннях.

У процесі аналізу систем штучного інтелекту було виявлено, що проблема виявлення об'єктів малих розмірів є актуальною та важливою в багатьох галузях, включаючи медицину, астрономію та навколишнє середовище. Різноманітні аспекти цієї задачі включають низьку роздільну здатність, непередбачувані особливості та неоднорідність об'єктів.

Детальний огляд літератури та існуючих систем розкрив велику різноманітність методів, що застосовуються для вирішення цієї проблеми. Деякі підходи базуються на глибокому навчанні, тоді як інші використовують класичні методи обробки зображень. Виявлено, що в області об'єктів малих розмірів виклики полягають не лише в самому розмірі об'єктів, але також у їх контексті та специфікації. Висновки з літературного огляду стали основою для постановки конкретної задачі магістерської роботи. Сформульована постановка задачі визначає напрямки подальших досліджень та встановлює параметри для оцінки ефективності розроблюваного методу.

Результатом першого розділу є розуміння сучасного стану галузі та

розкриття ключових аспектів, що будуть враховані в подальшому аналізі та розробці нового методу виявлення об'єктів на зображеннях малих розмірів. Суттєвий вклад у дослідження полягає в розкритті особливостей та викликів виявлення об'єктів малих розмірів. Виявлено, що існуючі підходи не завжди впораються з контекстом та особливостями об'єктів, що призводить до необхідності розробки нового методу, здатного враховувати ці особливості.

Визначено, що використання штучного інтелекту, зокрема глибокого навчання, є ключовим напрямком для вирішення поставленої задачі. Однак, необхідно ретельно розглядати та вдосконалювати існуючі методи з огляду на їхню ефективність у виявленні об'єктів малих розмірів. Проаналізовано різні аспекти задачі виявлення об'єктів, такі як роздільна здатність, контекст та особливості об'єктів, що стане основою для подальших етапів дослідження.

Узагальнюючи, перший розділ надав систематизований погляд на сучасний стан галузі та визначив проблематику, яку необхідно вирішити. Отримана інформація визначить напрямок подальших досліджень та допоможе розробити новий, більш ефективний метод виявлення об'єктів на зображеннях малих розмірів.

Розглянута ключова задача виявлення об'єктів на зображеннях, визначено її значущість у різних областях застосування, включаючи детектування об'єктів малих розмірів. Проведений докладний аналіз предметної області, зосереджений на викликах та особливостях, пов'язаних із виявленням об'єктів невеликих розмірів. Представлений огляд існуючих систем та підходів у сфері виявлення об'єктів малих розмірів. Визначені переваги та обмеження різних підходів, що є важливим фундаментом для подальшого дослідження. Сформульовано постановку задачі, визначено основні аспекти та цілі подальшого дослідження, включаючи аспекти використання штучного інтелекту та виявлення об'єктів на зображеннях низької роздільної здатності.

Цей розділ надає основу для подальшого дослідження та розвитку методів виявлення об'єктів у сфері малих розмірів, використовуючи принципи штучного інтелекту.

Розділ 2

Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях

2.1 Архітектура глибокого навчання для виявлення дрібних об'єктів на зображеннях

У роботі визначили завдання поліпшення ефективності виявлення невеликих об'єктів на супутникових знімках. Для досягнення цієї мети пропонуємо використовувати архітектуру наскрізної мережі, що складається з двох модулів: мережі високої роздільної здатності на основі генеративно-змагальної мережі та детекторної мережі. Увесь комплекс навчається наскрізним чином, використовуючи пари зображень високої і низької роздільної здатності.

Мережа високої роздільної здатності включає генератор (G), дискримінатор (DsRa) і мережу для посилення граничних меж (МПМ). У методі використовуємо наскрізне навчання, що дозволяє градієнтам втрат детектора передаватися назад в генератор. Таким чином, детектор виступає не лише як інструмент виявлення, але і як дискримінатор, на основі чого генератор генерує реалістичні зображення, подібні до справжніх. Мережева структура поділяється на дві частини: Генератор, включаючи МПМ, і дискримінатор, який об'єднує DsRa та мережу детекторів. Роль детектора як дискримінатора також відображена на рисунку 2.1.

Далі в роботі розглядаємо конкретні компоненти архітектури та їхню взаємодію. Модуль генератора (G) відповідає за створення зображень високої роздільної здатності з низької роздільної здатності. Для досягнення цієї мети він використовує генеративно-змагальну мережу (ГЗМ), яка конкурує з дискримінатором (DsRa) у створенні реалістичніших зображень. Мережа посилення граничних меж (МПМ) вдосконалює границі об'єктів на згенерованих зображеннях.

Детекторна мережа визначає області, де знаходяться об'єкти, і передає цю інформацію генератору для поліпшення зображень. Детектор виступає також як дискримінатор, оцінюючи реалістичність згенерованих та реальних зображень. Таким чином, він сприяє підвищенню реалістичності згенерованих зображень.

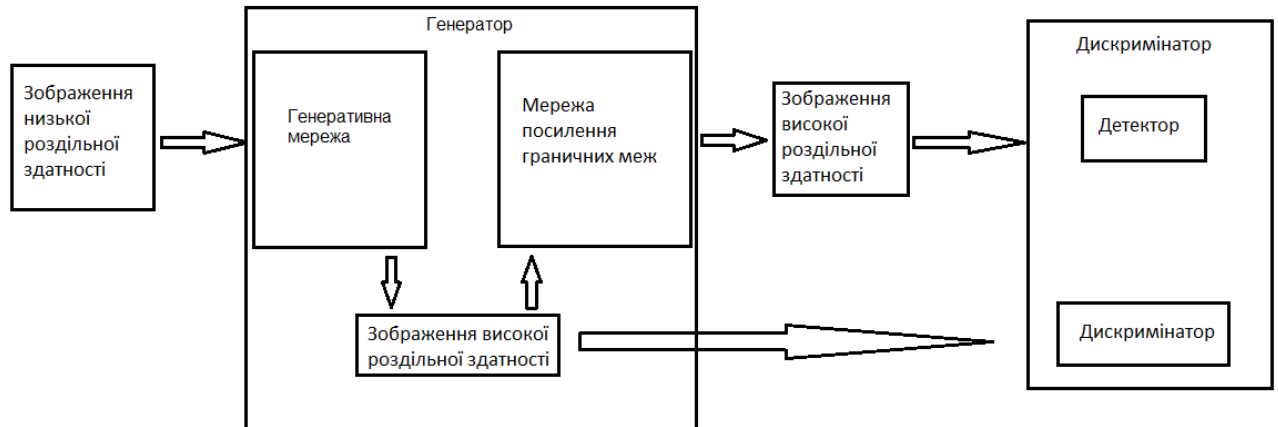


Рисунок 2.1 – Загальна архітектура мережі з генератором і модулем дискримінатора.

Генератор G формує проміжні зображення високої роздільної здатності (ПЗВРЗ). Після застосування мережі МПМ формуються остаточні зображення високої роздільної здатності. Дискримінатор ($DsRa$) відрізняє справжні зображення високої роздільної здатності від проміжних зображень високої роздільної здатності. Зворотні градієнти $DsRa$ передаються назад у генератор G для створення ВРЗ-зображень, що дозволяє точно виявляти об'єкти. Інформація про граничні межі витягується з ПЗВРЗ, а мережа МПМ підсилює ці граничні межі. Після віднімання вихідних граничних меж, виділених оператором Лапласіана, поліпшені граничні межі знову додаються до ПЗВРЗ, і отримуємо на виході зображення високої роздільної здатності з поліпшеними краями. Об'єкти виявляються на зображеннях високої роздільної здатності за допомогою мережі детекторів.

МПМ використовує дві різні функції втрат: одна порівнює різницю між ВРЗ та істинними зображеннями, а інша - різницю між витягнутим краєм з

ПЗВРЗ та істиннім. Для отримання ознак також використовується мережа VGG19, що застосовується для перцептивних втрат. Таким чином, вона генерує більш реалістичні зображення з більш точною інформацією про граничні межі. Усе це об'єднано у генератор, що включає в себе мережу G та МПМ. Далі розділяємо конвеєр на генератор і дискримінатор, надаючи детальний опис кожного компонента.

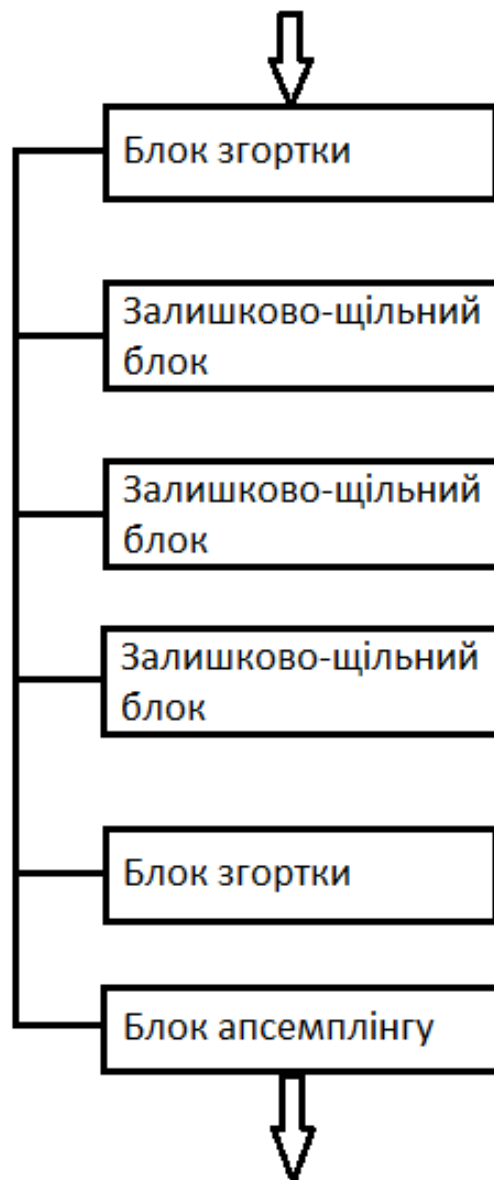


Рисунок 2.2 – Генератор G з ЗЩБ (залишково-щільними блоками), загортковими та апсемплювальними блоками

В архітектурі генератора, використаної у генеративній змагальній мережі, були вилучені всі шари пакетної нормалізації (ПН), і застосовано зворотні зв'язки. Загалом, структура генератора G представлена на рисунку 2.1, а ЗЩБ відображено на рисунку 2.2.

2.2 Архітектура генеративної мережі

На основі архітектури генеративної змагальної мережі, було прийнято рішення вилучити шари пакетної нормалізації (ПН), щоб підвищити продуктивність генератора G і зменшити обчислювальну складність. Це рішення призначене для уникнення артефактів, які можуть внести ПН-шари, і сприяє покращенню здатності узагальнення генератора, особливо коли статистика навчального та тестового наборів даних відрізняється значно.




Рисунок 2.3 – Внутрішня схема ЗЩБ (залишково-щільні блоки).

В якості основних блоків генеративної мережі G використано блоки зі зворотним зв'язком, де застосовується багаторівнева залишкова мережа з щільними зв'язками. Використання щільних зв'язків підвищує пропускну спроможність мережі, а масштабування залишків використовується для стабілізації процесу навчання та уникнення нестабільних станів. Для щільних блоків використовується параметричний випрямлений лінійний (ReLU) активаційний шар для ефективного навчання параметрів з іншими параметрами нейронної мережі. В якості дискримінатора (DsRa) використано релятивістський усереднений дискримінатор.

Для формулювання релятивістського усередненого дискримінатора в даній архітектурі, важливо врахувати тісний зв'язок між генератором G та дискримінатором DsRa. Дискримінатор DsRa в цьому контексті передбачає ймовірність того, що реальне зображення є більш реалістичним, ніж згенероване проміжне зображення яке генератор намагається створити.

Дискримінатор виступає як критик, оцінюючи якість зображень, і вказує генератору на те, наскільки вдало йому імітувати реальність. Релятивістський підхід полягає в тому, що дискримінатор не просто визначає, чи є зображення реалістичним, але порівнює його з іншим зображенням, в даному випадку, згенерованим проміжним зображенням.

Такий взаємозв'язок надає релятивістському дискримінатору здатність оцінювати не лише сам факт реалістичності зображення, а й в порівнянні з іншими зображеннями. Це дозволяє генератору не тільки намагатися створити реалістичні зображення, але також враховувати контекст та взаємодію з іншими елементами в архітектурі.

Отже, релятивістський усереднений дискримінатор створює більш докладну та дає оцінку генерованих зображень, сприяючи поліпшенню навчання та результатів у моделі.

Для формулювання релятивістського усередненого дискримінатора в даній архітектурі, варто зазначити, що генератор G тісно пов'язаний з дискримінатором DsRa. Дискримінатор передбачає ймовірність того, що реальне

зображення (I_{BP3}) більш реалістичне, ніж згенероване проміжне зображення ($I_{ПЗBP3}$). Це взаємозв'язок визначає, наскільки точно генератор може створювати зображення, які виглядають як реальні.

$$D_{Ra}(I_{BP3}, I_{ПЗBP3}) = \sigma(C(I_{BP3}) - E_{I_{ПЗBP3}}[C(I_{ПЗBP3})]) \rightarrow 1 \quad (2.1)$$

$$D_{Ra}(I_{ПЗBP3}, I_{BP3}) = \sigma(C(I_{ПЗBP3}) - E_{I_{BP3}}[C(I_{BP3})]) \rightarrow 0$$

Функція $E_{I_{ПЗBP3}}$ представлена сигмоїдальною функцією, що є виходом дискримінатора, і включає в себе операцію обчислення середнього для всіх згенерованих проміжних зображень у міні-партії. Згенеровані проміжні зображення отримуються від генератора, де $I_{ПЗBP3} = G(I_{HP3})$.

Втрати генератора містять як I_{BP3} , так і $I_{ПЗBP3}$, тому в процесі навчання використовуються градієнти як для згенерованого, так і для істинного зображень.

Додатково для генератора G використано ще дві втрати: перцептивна (L_{per}) і контентна (L_I). Втрати перцептивності розраховуються за картами ознак ($vgg_{fa}()$), розташованими перед шарами активації тонко налаштованої мережі VGG19, тоді як втрати контенту обчислюють L_I -норму відстані між $I_{ПЗBP3}$ і I_{BP3} . Втрати перцептивності і контенту представлені в рівнянні 2.2.

$$L_{per} = E_{I_{HP3}} \| vgg_{fa}(G(I_{HP3}) - vgg_{fa}(I_{BP3})) \|_1 \quad (2.2)$$

2.3 Мережа покращення меж об'єктів

Мережа МПМ видаляє шуми та підсилює визначені граничні межі зображення. Загальний вигляд мережі представлений на рисунку 2.4. На початку для виділення граничних меж з вхідного зображення використовується оператор Лапласіана. Після виділення граничних меж проходить через блоки згортки,

ЗЩБ і апсемплінгу. Гілка маски із сигмоїдальною активацією використовується для видалення крайового шуму. Посилені граничні межі додаються до вхідних зображень, з яких видалено граничні межі, виділені оператором Лапласіана.

Мережа МПМ аналогічна підмережі покращення меж, запропонованій раніше, з двома важливими змінами. По-перше, щільні блоки замінено на ЗЩБ, що призводить до покращеної продуктивності згідно з даними генеративної змагальної мережі.

Отже, для підвищення продуктивності мережі МПМ використовується ЗЩБ замість щільних блоків. По-друге, введено нову функцію втрат для покращення реконструкції граничних меж. Інформація про граничні межі витягується з ПЗВРЗ і підсилюється за допомогою підмережі посилення граничних меж, результат якої додається до ПЗВРЗ.

Для навчання мережі пропонується використовувати функцію втрат, яка представляє собою середню квадратичну помилку між ПЗВРЗ і вихідним зображенням високої роздільної здатності. Ця функція втрат називається втратою узгодженості для зображень (L_{imgcst}) і сприяє отриманню візуально належних результатів із інформацією про граничні межі.

Дослідження показують, що іноді граничні межі деяких об'єктів можуть спотворюватися, створюючи шуми і, як наслідок, надаючи неякісну інформацію про граничні межі.

Це явище може виникнути через різноманітні фактори, такі як неправильне освітлення, артефакти обробки зображень або природні перешкоди на зображенні. Такі спотворення граничних меж можуть впливати на точність об'єктного виявлення та локалізації, адже модель може неправильно інтерпретувати ці спотворення як частини об'єкта.

Для подолання цього виклику досліджуються методи аугментації даних, які спрямовані на зменшення впливу шумів та спотворень границь об'єктів. Використання різних технік аугментації, таких як розмиття, розтягування та обрізання, може допомогти покращити роботу моделі на зображеннях з

граничними умовами та забезпечити більш стійкий та точний процес виявлення об'єктів.

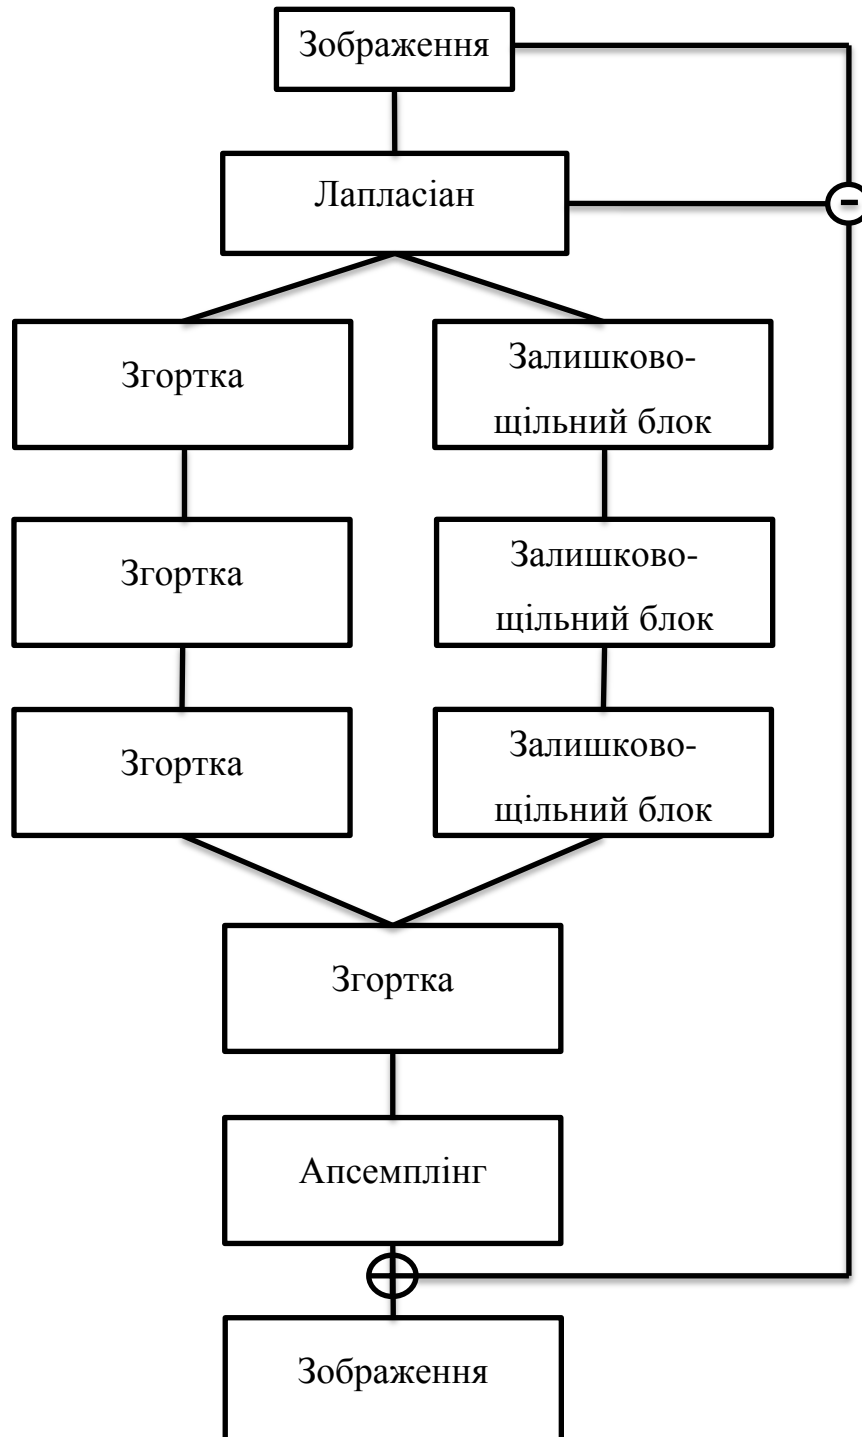


Рисунок 2.4 – Мережа посилення граничних меж, де на вході зображення ПЗВРЗ, а на виході зображення високої роздільної здатності

Таким чином, вводимо втрати узгодженості і для граничних меж ($L_{edgecst}$). Для розрахунку $L_{edgecst}$ оцінюємо втрати між витягнутими краями ($I_{edgeBP3}$) з ПЗВРЗ і витягнутими краями ($I_{edgeBP3}$) з I_{BP3} . Ці дві втрати узгодженості представлені у рівнянні 2.3 і рівнянні 2.4. В підсумку обчислюється загальна втрата узгодженості для зображень і граничних меж шляхом додавання індивідуальних втрат.

Втрати МПМ показані у рівнянні 2.5.

$$L_{cls} = -1/N_{cls} \sum [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)], \quad (2.3)$$

де: N_{cls} – кількість класів;

y_i – індикатор (0 або 1), який вказує, чи вірно визначено клас об'єкта;

p_i – імовірність, що об'єкт належить до класу i .

Регресійні втрати:

$$L_{reg} = 1/N_{reg} \sum [smooth_{L_1}(\delta_x, \delta_y, \delta_w, \delta_h)] \quad (2.4)$$

де: N_{reg} – кількість регресійних цілей;

$\delta_x, \delta_y, \delta_w, \delta_h$ – різниця між прогнозованими і правильними координатами об'єкта.

Загальні втрати:

$$L_{det} = L_{cls} + \lambda L_{reg} \quad (2.5)$$

де: λ – гіперпараметр, який контролює важливість класифікаційних і регресійних втрат

Отже, отримуємо загальні втрати для генераторного модуля, додаючи втрати генератора G та мережі МПМ. Формула загальних втрат для

генераторного модуля представлена у рівнянні 2.6, де λ_1 , λ_2 , λ_3 і λ_4 - вагові параметри для забезпечення балансу різних складових втрат. Емпірично були встановлені значення $\lambda_1 = 1.5$, $\lambda_2 = 0.02$, $\lambda_3 = 0.2$ і $\lambda_4 = 3$ для досягнення оптимального балансу між різними аспектами навчання. Ця загальна втрата враховує важливість кількох компонентів та втрати узгодженості для зображень L_{imgcst} . Цей підхід дозволяє збалансувати різні аспекти процесу навчання для досягнення кращих результатів у завданні виявлення об'єктів на високороздільних зображеннях.

$$L_{Geen} = \lambda_1 L_{per} + \lambda_2 L_{HP3} + \lambda_3 L_1 + \lambda_4 L_{Leen} \quad (2.6)$$

Також подамо втрати для класифікаційних і регресійних втрат, а також загальних втрат для алгоритму Faster RCNN:

Класифікаційні втрати:

$$L_{cls}(p, p^*) = -\log(p_{y^*}), \quad (2.7)$$

де p – прогнозована ймовірність;

p^* – істинна ймовірність;

y^* – істинний клас.

Регресійні втрати:

$$L_{reg}(t, t^*) = \sum_{i \in \{x, y, w, h\}} L_{smooth_{L1}}(t_i - t_i^*), \quad (2.8)$$

де t – прогнозований вектор регресії;

t^* – істинний вектор регресії;

$L_{smooth_{L1}}$ – функція гладкості L1.

Загальні втрати:

$$L_{det}(p, p^*, t, t^*) = L_{cls}(p, p^*) + \lambda L_{reg}(t, t^*), \quad (2.9)$$

де λ – гіперпараметр, який контролює важливість класифікації порівняно з регресією.

2.4 Дискримінатор визначення об'єктів

Для навчання генератора G використано релятивістський дискримінатор $DsRa$, який має архітектуру, взяту з генеративно-змагальної мережі, і використовується архітектура VGG для дискримінатора. Додатково, в якості детекторних мереж були використані Faster RCNN і SSD, які виконують роль дискримінатора для модуля генератора. Коротко розглянемо обидва детектори.

Faster RCNN це двоетапний детектор об'єктів, який включає в себе мережу пропозицій регіонів (МПП) і мережу для виявлення об'єктів. Задачею МПП є генерація пропозицій регіонів на зображенні з високою ймовірністю містить об'єкт. Ця мережа використовує опорну мережу, таку як VGG, ResNet або ResNet з мережею пірамід ознак, як екстрактор ознак. Відмінність в екстракторах ознак може бути обрана на основі їх продуктивності на відомих наборах даних.

Мережа для виявлення об'єктів працює на основі пропозицій, згенерованих МПП, і визначає, чи є об'єкт на кожному регіоні. Крім того, вона може підігнати обмежувальні рамки навколо виявлених об'єктів для точного визначення їхнього положення. Таким чином, ці дві детекторні мережі разом грають роль дискримінатора для модуля генератора, визначаючи точність та реалістичність створених високороздільних зображень.

Використовували ResNet-50-FPN як опорну мережу для Faster RCNN. Обрана саме ця мережа через її вищу точність порівняно з VGG-19 і ResNet-50 без FPN, особливо в області виявлення дрібних об'єктів. Навіть за умови

можливого підвищення продуктивності більшими мережами, врахували відносно невисокі апаратні вимоги і ефективний час збіжності ResNet-50-FPN.

Після МПР використовуємо дві гілки для виявлення об'єктів: класифікатор і регресор. Гілка класифікації призначена для визначення приналежності регіону конкретному класу об'єкта, в той час як гілка регресії визначає точні координати граничного положення об'єкта. У наборах даних містяться об'єкти лише одного класу, тому класифікатор виводить лише два класи: клас фону і клас об'єкта.

МПР є ефективним підходом для виявлення об'єктів в зображеннях. Після використання МПР, процес виявлення об'єктів може бути поділений на дві ключові гілки: гілку класифікації і гілку регресії.

Гілка класифікації відповідає за приналежність регіону конкретному класу об'єкта. У випадку, коли на зображенні може бути кілька класів об'єктів, класифікатор визначає, до якого саме класу належить кожен виявлений регіон. В наборах даних, які використовуються для навчання, об'єкти належать лише одному класу. Таким чином, класифікатор виводить всього два класи: клас фону наприклад, відсутність об'єкта і клас об'єкта.

Гілка регресії відповідає за точне визначення координат границь об'єкта. Це означає, що разом із класифікацією, модель також здатна передбачити, де саме на зображенні розташований об'єкт. Використовуючи регресор, можна отримати точні значення для координат границь об'єкта, що сприяє більш точному і докладному виявленню об'єктів на зображенні.

Загальний підхід МПР забезпечує велику гнучкість у виявленні об'єктів і дозволяє враховувати як інформацію про класифікацію, так і просторові характеристики об'єктів, що робить його ефективним і універсальним для різноманітних завдань виявлення об'єктів на зображеннях.

Додатково, важливо відзначити, що в контексті МПР може використовуватися метод об'єднаного навчання, який дозволяє оптимізувати обидві гілки класифікації і регресії одночасно. Це забезпечує взаємозв'язок між

виявленими регіонами і відповідними класифікаційними та регресійними мітками.

Оскільки набори даних містять об'єкти лише одного класу, це може впливати на процес навчання, забезпечуючи моделі чітку відмінність між класом фону і класом об'єкта даного типу. Використання такого підходу спрощує завдання класифікації, але водночас робить його ефективним для конкретних сценаріїв, де об'єкти на зображенні належать лише одному класу.

Однак важливо також враховувати можливі виклики, такі як надмірна чутливість до змін у контексті зображення та непередбачувані зміни в зовнішніх умовах. До цього можна використовувати додаткові стратегії аугментації даних для забезпечення стійкості моделі в різних умовах. Загалом, комбінування гілок класифікації і регресії в рамках МПР дозволяє ефективно виявляти та локалізувати об'єкти на зображеннях, що робить цей підхід важливим інструментом у сферах комп'ютерного зору та обробки зображень.

Після отримання результатів виявлення об'єктів за допомогою гілок класифікації і регресії, можуть використовуватися різноманітні стратегії для подальшої обробки та використання цих даних.

Однією з можливих стратегій є застосування порогового значення до виведених результатів класифікації для визначення, які регіони вважатимуться виявленими об'єктами. Наприклад, якщо ймовірність належності до класу об'єкта перевищує певний поріг, можна вважати, що об'єкт був успішно виявлений. Це дозволяє фільтрувати локалізовані регіони з врахуванням впевненості моделі.

Крім того, після виявлення об'єктів може проводитися додаткова обробка для поліпшення точності локалізації. Наприклад, техніки постпроцесингу, такі як non-maximum suppression, можуть використовуватися для видалення зайвих областей або об'єднання областей перекриття. Також, може бути важливим розглядати використання глибокого навчання для поєднання інших даних або інформації, такої як контекст зображення або історія виявлення об'єктів на попередніх кадрах. Це може допомогти моделі краще розуміти сцену та збільшити надійність виявлення.

Загалом, розвиток і вдосконалення методів виявлення об'єктів з використанням гілок класифікації і регресії відкриває широкі перспективи для застосувань у багатьох галузях, включаючи автономні автомобілі, медичне зображення, безпеку та багато інших.

SSD як багатобоксовий детектор з одним проходом, вирізняється можливістю виявлення об'єктів за один етап. У цьому випадку одноетапність означає, що класифікація і локалізація об'єктів виконуються під час одного проходу через мережу. Схоже до Faster RCNN, SSD також використовує мережу екстрактора ознак, існують різні варіанти таких мереж. З метою досягнення основної мети SSD - швидкості, як мережу екстрактора ознак було обрано VGG-16.

Після етапу екстракції ознак SSD включає кілька згорткових шарів меншого розміру. Це можна уявити як пірамідальне представлення зображень з різними масштабами. Таким чином, об'єкти виявляються на різних рівнях, а результатом є виявлення об'єкта з вказуванням його класу та координат обмежувальних рамок. Модель SSD використовує кілька згорткових шарів меншого розміру для подальшої обробки інформації. Це призводить до створення пірамідального представлення зображень, де кожен рівень має різний масштаб і дозволяє виявлення об'єктів на різних рівнях деталізації.

Пірамідальна структура важлива для ефективного виявлення об'єктів різних розмірів. Згорткові шари меншого розміру дозволяють моделі уважніше реагувати на дрібні деталі та області зображення, тоді як шари більшого розміру допомагають виявляти більші об'єкти та глобальні особливості. Така піраміда масштабів створює універсальний інструмент для виявлення об'єктів різних розмірів та забезпечення моделі інформацією про різні аспекти сцени.

Кожен шар піраміди відповідає певному масштабу об'єктів, і на кожному шарі використовується набір якірних коробок - це фіксовані прямокутники з різними аспектами, співвідношення ширина та висота. Для кожного якоря модель прогнозує ймовірності класів об'єктів та корекції координат обмежувальних рамок. Це забезпечує точне виявлення об'єктів та їх локалізацію

на різних рівнях деталізації. Далі, після виявлення об'єктів на різних рівнях масштабів за допомогою якірних коробок і прогнозування ймовірностей класів, модель SSD використовує алгоритм non-maximum suppression. Цей алгоритм використовується для усунення дублюючих та непотрібних областей виявлення, що можуть виникати через велику кількість якірних коробок.

Алгоритм працює наступним чином. Спочатку, відсортовуються виявлені області за ймовірністю класу об'єкта. Потім вибирається область з найвищою ймовірністю, і всі інші області, які мають значення перекриття з обраною областю більше певного порогового значення, видаляються. Цей процес повторюється для кожного об'єкта в порядку спадання ймовірностей, що допомагає забезпечити, що лише найбільш впевнені та області неперекриття залишаються в кінцевому результаті.

Отримані результати мають вигляд класифікованих областей з визначеними координатами обмежувальних рамок та відповідними ймовірностями класів. Це може бути використано для подальшого аналізу та взаємодії з іншими системами, наприклад, системами відстеження або вбудованими в системи реального часу, такими як автономні автомобілі або робототехніка.

SSD надає значний внесок в область виявлення об'єктів, завдяки своїй здатності виявляти об'єкти на різних рівнях деталізації та в реальному часі, що робить його відмінним вибором для багатьох завдань комп'ютерного зору. Результатом роботи моделі є виявлення об'єкта з вказуванням його класу та координат обмежувальних рамок. Ця інформація може використовуватися для подальшого визначення положення та класифікації об'єктів на зображенні, що робить SSD популярним методом в області виявлення об'єктів у реальному часі.

2.5 Втрати дискримінатора при визначені об'єктів

Релятивістські втрати дискримінатора, як вже було описано, додаються до втрат детектора для отримання остаточної втрати дискримінатора. Якщо

порівнювати Faster RCNN та SSD, обидва мають схожі втрати при регресії та локалізації, однак вони використовують різні методи для класифікації.

У контексті релятивістських втрат дискримінатора, цей підхід використовується в генеративних мережах для навчання об'єктного детектора, яким може бути Faster RCNN чи SSD. Релятивістські втрати для дискримінатора додаються до загальних втрат детектора, щоб удосконалити процес навчання та покращити стабільність моделі. В контексті об'єктного детектора, яким є Faster RCNN чи SSD, завдання регресії та локалізації передбачає точне визначення координат об'єктів на зображенні. Релятивістські втрати, які додаються до загальних втрат, допомагають забезпечити, що дискримінатор враховує контекст зображення та вивчає якісні особливості об'єктів, що підвищує якість виявлення.

Щодо порівняння Faster RCNN та SSD, обидва вони використовують схожі методи для завдань регресії та локалізації. Вони використовують якірні коробки для прогнозування координат областей, що містять об'єкти. Але різниця полягає у методах класифікації.

Faster RCNN використовує два окремих шари – пропозиції регіонів та класифікатор областей для виявлення та класифікації об'єктів. У той час як SSD використовує вбудовані класифікатори на різних рівнях масштабу зображення, створюючи пірамідальне представлення. Це дозволяє SSD ефективно виявляти об'єкти на різних рівнях деталізації та масштабу, роблячи його більш адаптованим для обробки об'єктів різних розмірів на зображенні.

Після використання релятивістських втрат для дискримінатора та обчислення загальних втрат, що включають втрати класифікації, регресії та локалізації, отримані результати можуть бути використані для подальшого удосконалення та оптимізації моделі об'єктного детектора.

Результати, отримані після врахування релятивістських втрат, можуть бути використані для налаштування параметрів об'єктного детектора. Це може включати зміну гіперпараметрів моделі, таких як розмір анкорних коробок, архітектура мережі тощо.

Параметри релятивістських втрат, такі як ваги, можуть бути додатково оптимізовані для досягнення найкращих результатів. Це може включати експерименти з різними значеннями ваг та порогів, які використовуються для врахування втрат дискримінатора. Додаткова обробка та аугментація даних можуть допомогти покращити стійкість та стійкість моделі. Це може включати зміну розміру зображення, обертання тощо. Детальний аналіз помилок, зроблених моделлю, може вказати на слабкі сторони та можливості для покращень. Це може включати вивчення випадків, де релятивістські втрати допомагають або не допомагають в досягненні правильних виявлень.

Врахування релятивістських втрат у процесі навчання може вимагати ітеративного підходу. Після кожної ітерації можуть бути внесені корективи для збалансування втрат та покращення результатів.

Релятивістські втрати та їх вплив на процес навчання можуть слугувати ключовим елементом для досягнення стабільного та високоефективного об'єктного детектора у глибокому навчанні.

Отже, обидва методи використовують різні стратегії для класифікації, але спільно використовують релятивістські втрати дискримінатора для покращення навчання та забезпечення кращої стійкості виявлення об'єктів на зображенні.

Для регресії та локалізації обидва підходи використовують гладкі втрати L1, які вимірюють відмінності між виявленими та істинними координатами обмежувального поля. Класифікаційні (L_{cls}) і регресійні втрати (L_{reg}), а також загальні втрати (L_{det}) для Faster RCNN представлені нижче:

$$L_{cls} = E_{I_{HP3}}[-\log(Det_{cls}(G_{Gen}(I_{HP3})))]. \quad (2.10)$$

$$L_{reg} = E_{I_{HP3}}[smooth_{L1}(Det_{reg}(G_{Gen}(I_{HP3})))]. \quad (2.11)$$

$$L_{det} = L_{cls} + \lambda L_{reg} \quad (2.12)$$

Тут параметр λ використовується для забезпечення балансу між втратами і емпірично встановлюється на рівні 1. Det_{cls} і Det_{reg} представляють класифікатор і регресор для Faster RCNN. Функції втрат для класифікації (L_{cls}), регресії (L_{reg}) і загальних втрат (L_{det}) для SSD мають такий вигляд:

$$L_{cls} = E_{I_{HP3}}[-\log(\text{softmax}(Det_{cls}(G_{Gen}(I_{HP3})))))] \quad (2.13)$$

$$L_{reg} = E_{I_{HP3}}[\text{smooth}_{L1}(Det_{reg}(G_{Gen}(I_{HP3}))))] \quad (2.14)$$

$$L_{det} = L_{cls} + \alpha L_{reg} \quad (2.15)$$

У цьому випадку, параметр α використовується для забезпечення балансу між втратами і емпірично встановлюється на рівні 1. Det_{cls} і Det_{reg} використовуються як класифікатор і регресор для SSD.

2.6 Навчання системи виявлення об'єктів

Під час роздільного навчання використовується поділ на два етапи: навчання мережі високої роздільної здатності, включаючи модуль генератора та дискримінатор DsRa і навчання детектора. Основна відмінність полягає в тому, що втрати детектора не враховуються під час зворотного поширення для модуля генератора. Наприклад, у рівнянні 2.10, під час обчислення втрати L_{CLS} , помилка в модуль G_{Gen} не передається, і мережа генератора від'єднується на час розрахунку втрат детектора.

У випадку наскрізного навчання відбувається одночасне навчання всієї архітектури, і втрати детектора передаються на модуль генератора. Таким чином, генератор отримує градієнти як від детектора, так і від дискримінатора DsRa. Підсумкові втрати дискримінатора (L_{Ddet}) визначаються так:

$$L_{Ddet} = L_D + \eta L_{det} . \quad (2.16)$$

Тут параметр η використовується для балансування внеску втрат детектора, і його значення емпірично встановлено як 1. Втрати при виявленні за допомогою SSD або Faster RCNN позначаються як L_{det} . Загальні втрати (L) для архітектури отримуються таким чином.

$$L = L_{Geen} + L_{Ddet} . \quad (2.17)$$

У випадку наскрізного навчання втрати детектора передаються для зворотного поширення у генератор. Таким чином, генератор отримує градієнти як від детектора, так і від дискримінатора

Такий підхід дозволяє узгоджено навчати обидва модулі та забезпечує взаємодію між генератором і детектором для поліпшення загальної продуктивності системи.

У випадку наскрізного навчання втрати детектора передаються для зворотного поширення у генератор. Цей підхід дозволяє створити взаємозалежний процес навчання між генератором та детектором, сприяючи поліпшенню загальної продуктивності системи. Ключовою особливістю є те, що генератор отримує градієнти як від детектора, так і від дискримінатора .

Детектор в контексті об'єктного виявлення відповідає за розпізнавання та локалізацію об'єктів на зображенні. Дискримінатор , який може бути частиною генеративної мережі, використовується для оцінки якості згенерованих зображень та сприяє навчанню генератора.

Втрати детектора, що включають втрати класифікації та регресії, передаються генератору для корекції його параметрів. Це включає зворотне поширення градієнтів через генератор, щоб покращити якість згенерованих зображень. Такий взаємний обмін градієнтами між детектором і генератором дозволяє системі ефективно вчитися вирішувати завдання виявлення об'єктів та генерації зображень одночасно.

Цей взаємозв'язок сприяє створенню більш узгодженої та оптимізованої системи, оскільки генератор отримує зворотний зв'язок від обох модулів. Такий підхід підсилює взаємодію між генератором і детектором, сприяючи подальшій адаптації та удосконаленню їхньої ефективності в рамках конкретного завдання комп'ютерного зору.

Висновки до розділу 2

В розділі розглянуті два типи навчання для архітектури: роздільне навчання та наскрізне навчання. Кожен з цих підходів має свої особливості та впливає на взаємодію між компонентами системи.

У роздільному навчанні мережа високої роздільної здатності модуль генератора і дискримінатор та детектор навчаються окремо. Втрати детектора не передаються у зворотному напрямі в модуль генератора. Це визначає відсутність зворотного зв'язку від детектора до генератора під час розрахунку втрат. Такий підхід може мати свої переваги, зокрема, у випадку, коли важливо розглядати обидві компоненти незалежно.

У наскрізному навчанні відбувається взаємне навчання всієї архітектури, де втрати детектора передаються в зворотному напрямі в модуль генератора. Генератор отримує градієнти як від детектора, так і від дискримінатора. Це може призвести до більш ефективного і згуртованого навчання, де обидві частини системи взаємодіють для досягнення кращої сумісності.

Обираючи між роздільним та наскрізним навчанням, слід враховувати конкретні завдання та вимоги до системи, зокрема, розглядаючи ступінь взаємодії між генератором і детектором для досягнення оптимальних результатів.

В обох випадках важливо розглядати взаємозв'язок між різними етапами навчання та вплив кожного етапу на кінцевий результат системи. Це дозволить покращити ефективність та точність архітектури в цілому.

Розділ 3

Формування множини даних та навчання з виявлення об'єктів з невеликою роздільною здатністю

3.1 Система анотування об'єктів на зображеннях

Для анотування супутникових знімків важливо мати доступ до систем маркування. На ринку існують програми, які спеціалізуються на анотуванні та виявленні об'єктів на супутникових зображеннях, такі як Image Labeler. Однак, варто відзначити, що такі програми можуть вимагати значних фінансових ресурсів або бути досить дорогими.

Для користувачів, які шукають альтернативні рішення, існують системи маркування з відкритим вихідним кодом, такі як Computer Vision Annotation Tool. Тим не менш, зауважується, що деякі з цих систем можуть мати обмеження щодо розмірів завантажуваних супутникових знімків, створення невеликих зображень для анотування та проведення навчання та тестування моделей.

Під час досліджень були виявлені основні проблеми, пов'язані з виявленням малих об'єктів на супутникових знімках. Точність виявлення дрібних об'єктів знижується навіть на зображеннях високої роздільної здатності через шуми сенсора та атмосферні ефекти.

Отримання доступу до знімків високої роздільної здатності не завжди є фізично можливим, але це важливо для поліпшення точності виявлення дрібних об'єктів на супутникових знімках низької роздільної здатності. У цьому контексті, пошук ефективного рішення для розв'язання виявлених проблем є важливим завданням.

Для поліпшення точності виявлення дрібних об'єктів на низькороздільних знімках можна використовувати комбіновану архітектуру, яка поєднує в собі мережу для посилення граничних меж та мережу для виявлення об'єктів. Ця архітектура може функціонувати в наскрізному режимі, що дозволяє

використовувати спільну оптимізацію для підвищення точності та результативності системи виявлення.

У роботі викладено концепцію наскрізної архітектури, де виявлення об'єктів та їхнє догенерування виконуються одночасно. На відміну від сучасних детекторів, які можуть пропустити об'єкти під час навчання на низькороздільних знімках, розроблений метод дозволяє успішно виявляти ці об'єкти. Застосування зображень високої роздільної здатності для виявлення об'єктів із двох різних наборів даних призводить до підвищення ефективності. Щоб наочно продемонструвати загальний результат на тестових наборах даних, були побудовані графіки, які відображають залежність середньої точності від різних значень коефіцієнта перетину (intersection over union, IoU) для обох роздільних здатностей. Результати показали, що запропонований наскрізний метод значно перевершує генеративну змагальну мережу для створення задовільних супутникових зображень з належною інформацією про граничні межі.

Архітектура цього методу включає в себе генеративну змагальну мережу та мережу детекторів, і базується на використанні генеративних змагальних мереж. Остання суттєво покращує якість супутникових зображень та забезпечує необхідну інформацію про граничні межі.

Для побудови нейронної мережі використано генеративну підмережу, дискримінаційну підмережу та підмережу підсилення меж. Для генератора і мережі підсилення меж використано щільні блоки, що містять багаторівневі залишкові шари зі щільними зв'язками. Ці блоки відзначаються високою ефективністю при поліпшенні зображень.

На поданому рисунку можна спостерігати процес виявлення об'єктів на зображеннях низької роздільної здатності, які мають 150 см/піксель, і на згенерованих зображеннях високої роздільної здатності, що становлять 15 см/піксель. Для цього використовується набір даних COWC (car overhead with context). Важливою метрикою є середня точність, яка порівнюється при різних значеннях IoU (intersection over union) для тестового набору низької роздільної здатності та згенерованих зображень високої роздільної здатності із зображень

низької роздільної здатності для наборів даних. Для спочатку виявлення об'єктів на зображеннях низької роздільної здатності використовується детектор регіонів.



Рисунок 3.1 – Детектування об'єктів на б) вихідному зображенні та в) покращеному

Замість використання низької роздільної здатності-зображень безпосередньо, застосовується запропонована наскрізна архітектура, в якій використовуються генеративна змагальна мережа і генеративна змагальна мережа для створення зображень високої роздільної здатності і одночасного виявлення об'єктів на зображеннях високої роздільної здатності. Червоні обмежувальні рамки позначають істинно позитивні результати роботи, які вимірюються значенням $IoU=0,8$.

Замість стандартного дискримінатора використано релятивістський дискримінатор, який доповнює втрати в генеративній змагальній мережі і дискримінаторі.

Також для досягнення більшої точності виявлення дрібних об'єктів на зображеннях високої роздільної здатності були використані різні детектори. Ці детектори діяли як дискримінатори, оскільки втрати, отримані в процесі виявлення, передавалися в мережу високої роздільної здатності, що призвело до покращення якості зображень високої роздільної здатності.

Крім того, була розроблена система для маркування, навчання та виявлення об'єктів на супутникових знімках, які охоплюють велику територію. Ця система спрощує процес створення менших зображень із великих супутникових знімків, навчання сучасних моделей виявлення об'єктів, виконання самого виявлення та отримання геолокаційних даних для виявлених об'єктів.

Метод, який був застосований до загальнодоступного набору даних COWC, дозволив порівняти ефективність виявлення об'єктів для різних сценаріїв використання. Під час навчання використовувалися пари зображень високої роздільної здатності і низької роздільної здатності, а під час тестування - тільки зображення низької роздільної здатності. В наборах даних метод продемонстрував високі результати.

3.2 Вплив високої роздільної здатності на завдання виявлення об'єктів

Висока роздільна здатність зображень має позитивний вплив на завдання виявлення об'єктів на супутникових знімках. Для проведення досліджень використовувалися набори даних супутника. Проводилося одночасне покращення зображень та виявлення об'єктів, використовуючи глибоку згорткову нейронну мережу та одномоментний мультибоксовий детектор.

Запропоновано використання глибокого генератора на основі згорткової нейронної мережі для перетворення зображень низької роздільної здатності на високій роздільної здатності. Також була використана багатозадачна мережа як дискримінатор, а також для локалізації та класифікації об'єктів. Дослідження проводилося на звичайних зображеннях, які вимагали наявності пар зображень низької і високої роздільної здатності.

Також був застосований метод одночасного використання високої роздільної здатності та виявлення об'єктів на супутникових знімках. Архітектура мережі була розроблена на основі циклічно узгодженої змагальної мережі.

3.3 Маркування об'єктів та робота системи з виявлення об'єктів з невеликою роздільною здатністю на зображеннях

Існують різноманітні системи для маркування наземних і супутникових знімків, що надають послуги анотування та виявлення об'єктів на супутникових знімках, а також для навчання та тестування моделей на анотованих даних. Декілька таких систем, як Labelbox і ENVI, пропонують ці послуги за певну плату для користувачів, вимагаючи витрат ресурсів.

Завдяки системам з відкритим вихідним кодом, таким як LabelImg, Supervise.ly і VGG Image Annotator, користувачі мають доступ до простих і легких у використанні інструментів для анотування зображень різного розміру, зокрема зображень малого і середнього розміру.

В даному дослідженні була використана система LabelImg, яка є графічним інтерфейсом для анотування зображень.

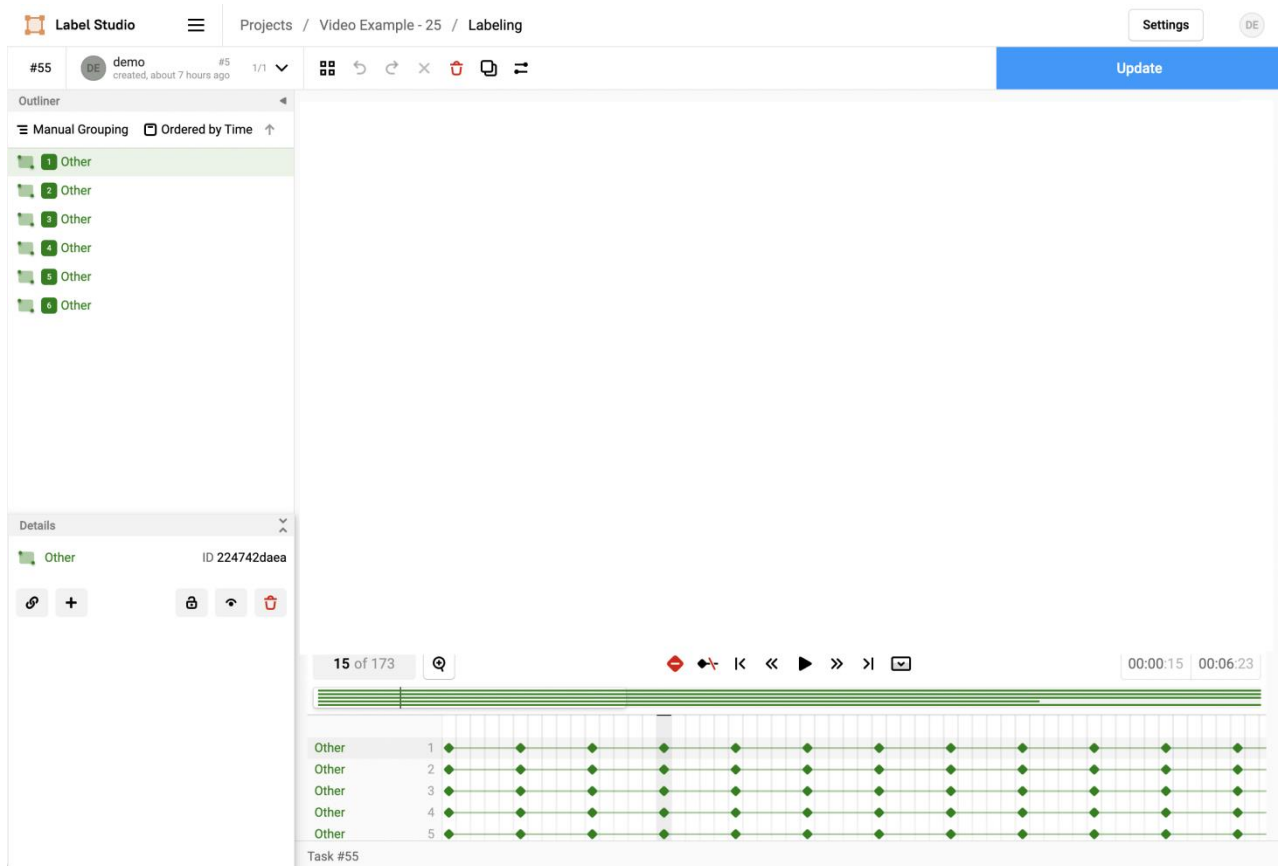


Рисунок 3.2 – Система LabelImg для анотування об'єктів на зображеннях

Ця система надає можливість користувачеві анотувати великі супутникові зображення та проводити навчання та тестування моделей. Використовуючи LabelImg, користувач може створювати невеликі фрагменти зображень з великого супутникового знімка, анотувати їх та створювати навчальні та тестові дані. Крім того, система дозволяє вибирати моделі для навчання та тестування.

Кінцеві результати детектування об'єктів можуть бути збережені у вигляді файлів географічних координат, що є зручним для подальшого використання у різних програмах для обробки та аналізу супутникових даних.

Застосунок для анотації та маркування зображень ґрунтується на репозиторії LabelImg на GitHub. Цей застосунок написаний мовою Python і

використовує графічний інтерфейс Qt для зручного використання. Для навчання та тестування моделей виявлення об'єктів використовується API Tensorflow.

Анотації об'єктів зберігаються у вигляді XML-файлів, які дотримуються стандарту ImageNet. Користувачі мають можливість використовувати різноманітні моделі глибокого навчання, включаючи Faster RCNN, Resnet, VGG та інші.




Рисунок 3.3 – Виявлення об'єктів на великому супутниковому знімку.

Продемонструємо можливості цієї системи виявлення об'єктів на великих супутникових знімках. Нижче наведено послідовні кроки для процедур маркування, навчання та тестування, які будуть детально описані в наступних розділах.

1. Збір та запуск системи здійснюються відповідно до інструкцій, наданих у репозиторії GitHub.

2. У меню вибрати пункт "Змінити папку збереження анотацій за замовчуванням", щоб визначити каталог для збереження файлів анотацій. Це дозволить користувачам зручно керувати анотаціями.

3. Вибрати "Відкрити директорію", і користувачі зможуть переглянути зображення, які містяться в обраній директорії.

4. Вибрати "Створити обмеження", щоб створити анотацію для об'єкта.

5. Клацнути і відпустити ліву кнопку миші, щоб виділити область прямокутного поля для анотування.

6. За допомогою правої кнопки миші можна перетягувати "прямокутне поле" для його копіювання або переміщення.

Цей опис подає загальний науковий підхід до використання системи для анотації та виявлення об'єктів на супутникових знімках.

Приклад екрана з маркуванням показано на рисунку 3.4.




Рисунок 3.4 – Приклад маркування об'єкту

3.4 Навчання системи з виявлення об'єктів з невеликою роздільною здатністю на зображеннях

Розглянемо кроки, необхідні для нарізки великих супутникових зображень на фрагменти та анотації цих фрагментів:

1. Вибрати опцію – відкрити зображення та фрагмент.
2. Обрати бажане супутникове зображення та вкажіть висоту та ширину фрагменту або фрагментів. Зазвичай використовується значення за замовчуванням - 512 пікселів.
3. Натиснути "Почати нарізку" для розділення великого зображення на менші фрагменти.
4. Після нарізки великого зображення з'явиться новий каталог з фрагментами зображень всередині нього.

5. Проанотувати кожне фрагмент зображення відповідно до інструкцій, розглянутих раніше, і зберегти файли анотацій у форматі .xml.

6. Обрати каталог, який містить всі файли .xml.

7. В каталозі, обраному на попередньому кроці, будуть створені файли для навчання та тестування.

8. Обрати опцію "Почати навчання" для ініціювання процесу навчання моделі.

9. Обрати файл для навчання моделі.

Ця послідовність кроків допомагає ефективно нарізати великі супутникові зображення на фрагменти, анотувати їх та підготувати дані для навчання та тестування моделей виявлення об'єктів.

Вибрати файл конфігурації з каталогу конфігурацій. Якщо потрібно використовувати певну модель, можете обрати відповідний файл, інакше, як варіант, використати файл за замовчуванням. Крім двох наведених моделей, існують інші доступні моделі в API виявлення об'єктів, які також можна використовувати.

Завантажити вибрану модель, розпакувати її та обрати файл моделі. Користувачі також мають можливість використовувати інші моделі за власним вибором.

Якщо необхідно використовувати інші моделі, можна завантажити їх із сховища API виявлення об'єктів в TensorFlow, а також відповідні файли конфігурації з того ж сховища.

Зараз можна розпочати процес навчання. Після завершення навчання користувач отримає файл, який можна використовувати для тестування на зображеннях.

Ці кроки дозволяють вибрати модель, підготувати її для навчання та розпочати процес навчання моделі виявлення об'єктів.

За замовчуванням, навчання проводиться з трьома мітками, які визначені у конфігураційному файлі детектора. Користувачі мають можливість створити власні мітки, редагуючи конфігураційний файл. Їм потрібно призначити

ідентифікатори, починаючи зі значення один і надати їм імена. Формат має відповідати формату, який вказаний в файлі конфігурації.

У конфігураційних файлах, які доступні в репозиторії в розділі мітки, користувачі можуть знайти число, яке представляє собою кількість кроків навчання. Користувачі можуть змінювати ці кроки відповідно до своїх потреб. Таким чином, можна навчати різні моделі, використовуючи цю систему.

Ці можливості дозволяють користувачам налаштовувати процес навчання відповідно до їх потреб та навчати різні моделі за допомогою даної системи.

3.5 Тестування системи виявлення об'єктів з невеликою роздільною здатністю на зображеннях

Опишемо кроки для тестування системи виявлення об'єктів:

– Обрати – завантажити тестове зображення для отримання результатів.

– Під час тестування великих зображень для виявлення об'єктів, необхідно нарізати їх на невеликі фрагменти, які перекриваються. Тому користувачеві потрібно ввести висоту і ширину цих фрагментів. За замовчуванням, висота і ширина дорівнюють 512 пікселів.

– Далі – обрати файл, який був створений на етапі навчання.

В подальших етапах обробки, після проведення операцій, таких як нарізка, виділення об'єктів та трансформація локальних координат виявлених меж на глобальні, система формує кінцеве змарковане зображення, на якому об'єкти виділені з чітко обведеними межами. Це забезпечує візуальний контекст та визначає положення виявлених об'єктів на зображенні для подальшого аналізу та використання.

Додатково, для управління ситуаціями перекриття об'єктів та підвищення точності виявлення, використовується метод немаксимального придушення. Цей метод дозволяє відфільтрувати лише найбільш визначені області та виключити можливі дублікати або невизначеності в результатах детекції.

На рисунку 3.5 наведено приклади виявлення з мітками.




Рисунок 3.5 – Приклад виявлення об'єктів

Висновки до розділу 3

У цьому розділі представлено новий підхід до вдосконалення якості та точності виявлення об'єктів на зображеннях високої роздільної здатності. Замість стандартного дискримінатора використовується релятивістський дискримінатор, який інтегрується в генеративну змагальну мережу і дискримінатор. Це доповнення сприяє покращенню якості згенерованих зображень високої роздільної здатності.

Також використано різні детектори для досягнення вищої точності виявлення дрібних об'єктів на зображеннях високої роздільної здатності. Ці детектори виступають як дискримінатори, що передають втрати в мережу високої роздільної здатності, забезпечуючи додатковий механізм зворотного зв'язку та поліпшення якості зображень.

Розроблена система для маркування, навчання та виявлення об'єктів на супутникових знімках з великою територією охоплення спрощує весь процес від створення зображень низької роздільної здатності до отримання геолокаційних даних для виявлених об'єктів.

Розроблена система для маркування, навчання та виявлення об'єктів на супутникових знімках, які охоплюють велику територію, представляє значний

крок у напрямку автоматизації та оптимізації процесів виявлення об'єктів. Ця система спрощує створення менших зображень з великих супутникових знімків, навчання сучасних моделей виявлення об'єктів, виконання самого виявлення та отримання геолокаційних даних для виявлених об'єктів.

Застосування розробленого методу до загальнодоступного набору даних COWC дозволило ефективно порівняти результати виявлення об'єктів для різних сценаріїв використання. Під час навчання використовувалися пари зображень високої роздільної здатності і низької роздільної здатності, а під час тестування - тільки зображення низької роздільної здатності. В наборах даних метод продемонстрував високі результати, свідчаючи про його ефективність та універсальність.

Маркування об'єктів та ефективна робота системи з виявлення об'єктів з невеликою роздільною здатністю на зображеннях є важливим компонентом для розвитку та застосування автоматизованих систем. У даному розділі було представлено результати роботи системи маркування та виявлення об'єктів, що працює з низькороздільними зображеннями.

Система маркування забезпечує точне виділення та позначення об'єктів на зображеннях, що є ключовим етапом для правильного навчання та оптимізації моделей виявлення. Розглянута система ефективно працює з великими територіями та різними типами об'єктів, що підвищує її універсальність та застосовність в різних областях.

У контексті виявлення об'єктів з невеликою роздільною здатністю, система продемонструвала високу точність та надійність в роботі з такими типами зображень. Вона ефективно впоралася із завданням виявлення об'єктів навіть на зображеннях обмеженої якості та деталізації.

Таким чином, результати даного дослідження підтверджують ефективність та потенціал системи маркування та виявлення об'єктів на зображеннях з невеликою роздільною здатністю, вказуючи на можливість її використання у різних галузях, включаючи геоінформаційні системи, картографію та аналіз супутникових знімків.

Розділ 4

Експериментальне дослідження виявлення об'єктів з невеликою роздільною здатністю на зображеннях

4.1 Умови проведення експериментальних досліджень

Мережу було навчено як окремо, так і наскрізним чином. У випадку роздільного навчання спершу досягалася збіжність мережі високої роздільної здатності генератора та дискримінатора, а потім мережі детектора навчалися на основі зображень високої роздільної здатності. При наскрізному навчанні використовувалося роздільне навчання як етап попереднього навчання для ініціалізації ваг. Після цього мережі високої роздільної здатності та мережі детектора навчалися спільно, з градієнтами від детектора, які передавалися у генераторну мережу.

Процес навчання включав встановлення швидкості навчання на рівні 0,01 та зменшення її вдвічі кожні 20000 ітерацій. Розмір партії був встановлений на рівні 5. Оптимізатор використовувався із параметрами $\beta_1 = 0,8$ та $\beta_2 = 0,9$. Ваги всієї архітектури оновлювались до збіжності. Для генератора G використовували 23 блоки ЗЦБ, а для мережі МПМ - 5 блоків ЗЦБ. Архітектура була реалізована та навчання і тестування проводились на графічному процесорі NVIDIA RTX 2060. Повний процес навчання зайняв 25 годин для 60 епох. Середня швидкість виведення становила приблизно 6 зображень на секунду при використанні Faster RCNN і 4 зображення на секунду для SSD.

4.2 Використання контекстного набору даних

Набір даних Cars overhead with context (COWC) включає 15-см супутникові знімки шести різних регіонів, де один піксель відповідає відстані 15 см на рівні землі. Цей набір даних охоплює регіони в Торонто (Канада), Селвін (Нова Зеландія), Потсдам і Вайхінген (Німеччина), Колумбус і Юта (США). При

зазначенні COWC мається на увазі набір даних із цих двох регіонів, де взято зображення супутникових переглядів. Приклад зображень з набору даних COWC показано на рисунку 4.1.



Рисунок 4.1 – Набір даних COWC (car overhead with context): пари зображень низької роздільної здатності (а), високої роздільної здатності (б)

В наборі даних міститься велика кількість унікальних автомобілів. Використовуються тільки RGB-зображення для навчання і тестування. Фрагменти зображень розміром 256 на 256 пікселів обираються так, щоб кожна частина містила принаймні один автомобіль. Довжина автомобіля в середньому коливається від 24 до 48 пікселів, а ширина - від 20 до 30 пікселів. Отже, площа автомобіля варіюється від 240 до 960 пікселів, вважаючи його невеликим об'єктом порівняно з іншими великими об'єктами на зображенні.

Для отримання зображень низької роздільної здатності з набору даних COWC використовувалася бікубічна понижувальна дискретизація. Коефіцієнт зменшення становив 4, що призвело до розміру зображень низької роздільної здатності 64 на 64 пікселі. Кожній частині зображення був призначений текстовий файл, який містив координати обмежувальної рамки для кожного автомобіля.

У проведених експериментах використовувався набір даних, який включав лише один клас - автомобілі, і не враховував жодних інших типів об'єктів. Для навчання і тестування використовувалося 6520 зображень. Розподіл на тренувальний і тестовий набори становив 80% для навчання та 20% для тестування. Тренувальний набір додатково був розділений на навчальний і перевірочний набори в співвідношенні 80% до 20%. Навчання проводилося на всій архітектурі з розширеним набором навчальних даних, включаючи випадкові горизонтальні відображення.

4.3 Метрики оцінки виявлення об'єктів на зображеннях

Результати виявлення представлені у вигляді обмежувальних коробок із відповідними класами. Для оцінки точності використовувалася середня точність, яка обчислюється за допомогою коефіцієнта перетину (IoU), точності (precision) і повноти (recall).

Множину правильно виявлених об'єктів позначаємо як істинно позитивні (TP), а множину помилково виявлених об'єктів - як помилково позитивні (FP).

Точність тепер представляє собою відношення числа TP до загальної кількості передбачених об'єктів:

$$\text{Точність} = \frac{|TP|}{|TP| + |FP|} \quad (4.14)$$

$$\text{Повнота} = \frac{|TP|}{|TP| + |FN|} \quad (4.15)$$

Множину об'єктів, які не були виявлені детектором, позначаємо як хибно негативні (FN). Тоді запам'ятовування визначається як відношення числа виявлених об'єктів (TP) до загальної кількості об'єктів у наборі даних.

Для вимірювання помилки локалізації передбачених обмежувальних блоків використовується IoU, який розраховує перекриття двох обмежувальних блоків: виявленого та істинного. Якщо всі блоки з $\text{IoU} \geq \tau$ вважати TP, а всі інші виявлення - FP, то отримаємо точність при заданому значенні IoU (τ). Середня точність для конкретного IoU розраховується усередненням значень точності за різними значеннями повноти. Змінюючи τ від 0,6 до 0,9 з кроком 0,1, отримуємо десять різних значень точності, які можна об'єднати в середню точність за $\text{IoU}=0,6:0,9$.

У випадку багатокласової класифікації необхідно розрахувати середню точність для кожного класу об'єктів окремо. Для отримання загальної оцінки ефективності виявлення об'єктів використовується середнє значення середньої точності, яке є найбільш популярним показником якості виявлення об'єктів.

Оскільки набори даних містять лише один клас, для оцінки використовувалася метрика середньої точності. Зазвичай демонстрували результати середньої точності при $\text{IoU}=0,6:0,9$, оскільки зі зростанням значень IoU метод продемонстрував покращення ефективності в порівнянні з іншими моделями.

4.4 Визначення ефективності детекторів

Було запущено два детектори для оцінки ефективності виявлення об'єктів на зображеннях низької та високої роздільної здатності. Використовували SSD і Faster RCNN. Навчання обох моделей проводилося на високороздільних та низькороздільних зображеннях, зменшених у 2 рази. Тестування також виконувалось на зображеннях обох роздільних здатностей.

Результати ефективності детекторів при різних комбінаціях навчання та тестування показали, що при використанні лише низькороздільних зображень для навчання та тестування Faster RCNN досягав 64% середньої точності. При навчанні на високороздільних зображеннях і тестуванні на низькороздільних середня точність зменшилася для обох детекторів. Додатково були включені результати виявлення з використанням низькороздільних зображень для навчання/тестування для SSD з RFB-модулями, де середня точність трохи збільшилася, порівняно з базовим SSD.

У останніх двох рядках таблиці 4.1 подані значення середньої точності детекторів під час навчання і тестування на високороздільних зображеннях. Використання детектора Faster RCNN дозволило досягти до 98% середньої точності, що свідчить про значний вплив роздільної здатності на виявленні об'єкти.

Якість виявлення встановлює природну верхню межу того, наскільки близько може підійти метод, заснований на низькороздільній здатності зображень. Отримані аналогічні результати виявлення на наборі даних COWC. В подальшому демонструється, що підходи значно покращують якість виявлення на низькороздільних зображеннях і наближаються до результатів, отриманих при роботі з високороздільними зображеннями.

Виявлення об'єктів на зображеннях можливе як з використанням низькороздільної, так і високороздільної здатності. Детектори були навчені на обох типах зображень, і значення середньої точності розраховувалися для 5 різних значень IoU (відношення перетину до об'єднання).

Три згадані моделі є популярними архітектурами для об'єктної детекції в комп'ютерному зорі. Коротко розглянемо кожен з них, щоб отримати більше уявлення:

1. SSD.

SSD є однією з перших моделей, яка пропонує підхід – одна спроба, багато об'єктів для об'єктної детекції. Вона використовує мережу глибокого навчання для виявлення об'єктів на різних масштабах та положеннях.

SSD використовує набір призначених для виявлення об'єктів на різних рівнях мережі, що дозволяє виявляти об'єкти різних розмірів.

2. Faster RCNN.

Faster RCNN використовує два окремі модулі для визначення регіонів об'єктів і для класифікації цих регіонів. Вона використовує регіональні пропозиції для визначення областей зображення, які ймовірно містять об'єкти, і потім класифікує та регресує їх.

Faster RCNN є потужною моделлю з високою точністю, але може бути трошки повільною порівняно з іншими підходами.

3. SSD-RFB.

SSD-RFB є варіацією SSD, де додані блоки зі зворотніми з'єднаннями. Ці блоки допомагають вдосконалювати роботу мережі в розпізнаванні об'єктів на різних рівнях.

Додавання зворотніх з'єднань може поліпшити здатність моделі розпізнавати об'єкти, особливо ті, що знаходяться в областях з високим рівнем деталей.

Кожна з цих моделей має свої переваги та недоліки, і вибір залежить від конкретних вимог задачі та обмежень обчислювальних ресурсів.

Набір даних:

1. Дані COWC (для виявлення об'єктів одного класу з роздільною здатністю 15 см)

Результати на датасеті COWC (середня точність при IoU=0.6:0.9):

– Для SSD, результат на низькій роздільній здатності (HP3-HP3) склав 68%, а на високій роздільній здатності (BP3-HP3) - 72%.

– Для Faster RCNN , результат на низькій роздільній здатності (HP3-HP3) склав 78%, а на високій роздільній здатності (BP3-HP3) - 76%.

Результати SSD-RFB на датасеті COWC (середня точність при IoU=0.6:0.9):

– Для низької роздільної здатності (HP3-HP3), SSD-RFB досяг результату 67%.

– Для високої роздільної здатності (BP3-HP3), SSD-RFB досяг результату 79%.

Результати на високороздільних зображеннях :

– Для SSD результат склав 93%.

– Для Faster RCNN результат склав 96%.

Ці результати надають оцінку продуктивності моделей для завдань виявлення об'єктів за різних умов, включаючи роздільну здатність зображень та набори даних. Вищі значення середньої точності свідчать про кращу продуктивність, і вибір моделі та роздільної здатності залежить від конкретних вимог і обмежень застосування.

4.5 Визначення об'єктів на зображеннях високої роздільної здатності

У цьому експерименті для обробки вхідних зображень низької роздільної здатності використовували бікубічне апсемплювання та різні методи ВРЗ. Важливо відзначити, що для застосування бікубічного апсемплювання не було необхідності у навчанні, оскільки це є функцією без параметрів. Згенеровані зображення ВРЗ використовувалися як тестові дані для двох типів детекторів. У порівнянні були включені три архітектури генеративно-змагальних мереж: нова архітектура, архітектура генеративно-змагальних мереж та генеративно-змагальна мережа. Кожну мережу навчали окремо на навчальній вибірці перед навчанням детектора об'єктів. Для оцінки результатів порівнювали детектори,

навчені на високороздільних зображеннях конкретної архітектури, і детектори, навчені безпосередньо на високороздільних зображеннях.

Таблиця 4.1 – Виявлення об'єктів на зображеннях ВРЗ за допомогою окремо навченої мережі для ВРЗ

Модель	Тренування	Тестування	IoU=0.6:0.9
SSD	ВРЗ	ВРЗ	70.2%
	НРЗ	ВРЗ	55.6%
Faster RCNN	ВРЗ	ВРЗ	74.3%
	НРЗ	ВРЗ	59.7%
GSSD	ВРЗ	ВРЗ	85.3%
	НРЗ	ВРЗ	82.7%
GFaster RCNN	ВРЗ	ВРЗ	91.8%
	НРЗ	ВРЗ	90.1%
EGSSD	ВРЗ	ВРЗ	92.7%
	НРЗ	ВРЗ	91.4%
EGFaster RCNN	ВРЗ	ВРЗ	93.4%
	НРЗ	ВРЗ	92.3%

Детектори були піддані навчанню на зображеннях із нефотореалістичним відтворенням та високої роздільної здатності (ВРЗ), а значення середньої точності розраховувалися за допомогою 5 різних значень IoU.

Ця таблиця містить результати для різних моделей та методів на різних наборах даних та роздільній здатності зображень тестування.

Представлені результати виявлення для різних поєднань методів ВРЗ та детекторів при різних комбінаціях тренування та тестування. Як видно, нова архітектура генеративної змагальної мережі показала найкращі результати, наблизившись до показників виявлення, спостережених при використанні виключно високороздільних зображень. Дослідження також підтвердило, що генеративна змагальна мережа може ефективно застосовуватися до

низькороздільних зображень, де відсутні дані щодо високороздільних зображень, та при цьому досягнуті високі результати. Крім того, інші методи ВРЗ, такі як генеративна змагальна мережа, також суттєво покращили продуктивність виявлення при попередній обробці низькороздільних зображень. Дослідження вказують на перевагу генеративної змагальної мережі порівняно з двома іншими методами.

4.6 Залежність точності класифікації від коефіцієнта перетину

У даному експерименті використали наскрізне навчання для мережі генеративної змагальної мережі і детекторів. Дискримінатор та детектори виконували роль дискримінатора для цілої архітектури. Втрати від детекторів передавалися назад у мережу ВРЗ, що сприяло поліпшенню зображень низької роздільної здатності.

Під час тренування пари зображень низької та високої роздільної здатності використовувались для навчання частини генеративної змагальної мережі, а потім згенеровані ВРЗ-зображення передавалися у детектор для навчання. Під час тестування мережі подавалися тільки зображення низької роздільної здатності. В архітектурі перед виявленням об'єкта спочатку формується зображення високої роздільної здатності з низької роздільної здатності-входу. Також порівняли результати з різними архітектурами, використовуючи генеративну змагальну мережу та інші детектори для порівняння. Встановлено, що запропонований метод показує вищі результати порівняно з іншими.

Розрахували значення середньої точності для різних значень IoU. На рисунку 4.2 представлена крива залежності середньої точності IoU для наборів даних, включаючи продуктивність генеративної змагальної мережі-Faster RCNN, наскрізної генеративної змагальної мережі-Faster RCNN і окремо навченої Faster RCNN.

Мережева система генеративної змагальної мережі Faster RCNN виявилася більш ефективною, порівняно з окремо навченою мережею. Різниця особливо помітна для високих значень IoU на наборі даних COWC. Отримані результати свідчать про хорошу продуктивність у порівнянні з максимально можливими значеннями середньої точності, отриманими за допомогою окремої Faster RCNN навченої та протестованої на зображеннях високої роздільної здатності.

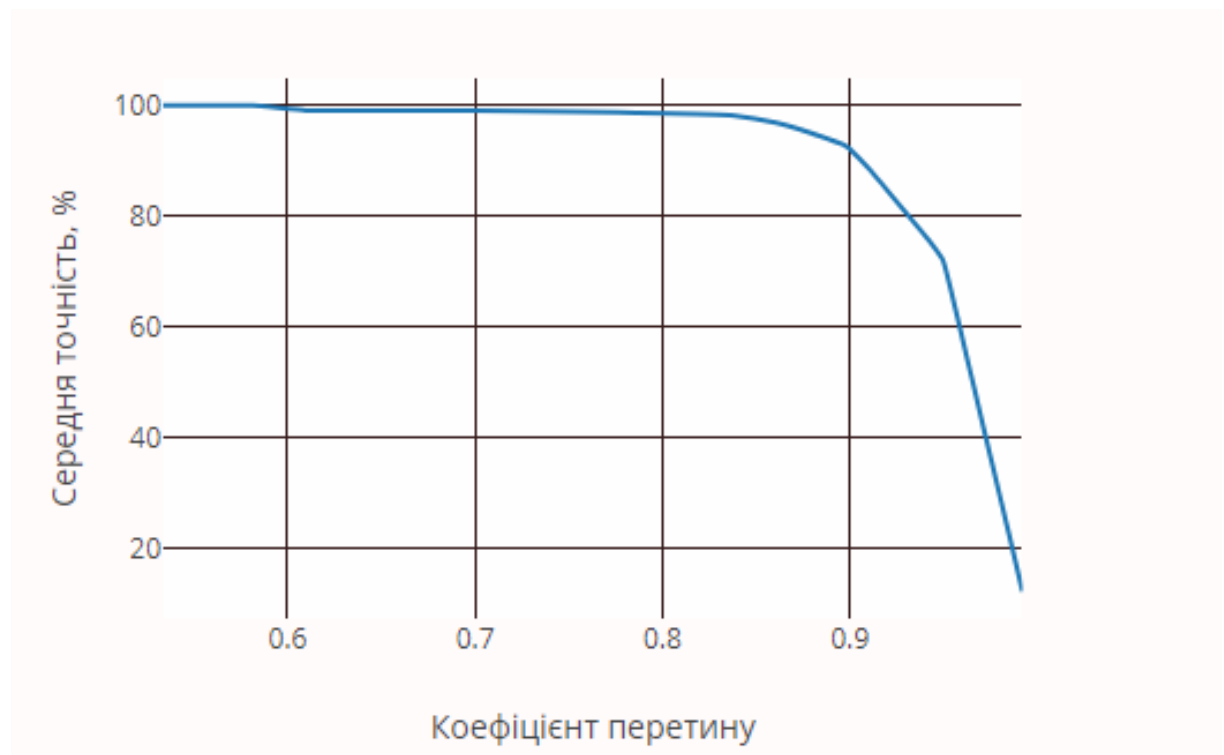


Рисунок 4.2 – Крива середня точність – коефіцієнт перетину для наборів даних

На рисунку представлено результати ефективності виявлення окремої Faster RCNN на зображеннях високої роздільної здатності порівняно з пропонованим методом з наскрізним навчанням на високороздільних зображеннях.

Зауважимо, що наскрізне навчання нової архітектури суттєво поліпшило результати для різних наборів даних. Зокрема, точність і повнота для даних

показали, що запропонований метод має вищі значення точності та вищі значення відкликання порівняно з окремими моделями Faster RCNN. Моделі з наскрізним навчанням продемонстрували кращі результати, зокрема в наборі даних COWC, де виявлено понад 87% автомобілів із 92% середньої точності.

4.7 Вплив розміру масиву даних на показники якості визначення об'єктів

Навчали архітектуру на різних обсягах навчальних наборів та тестували на фіксованому тестовому наборі. Графік на рисунку 4.3 відображає значення середньої точності $IoU=0,6:0,9$ залежно від кількості помічених об'єктів для різних розмірів навчальних наборів даних: 5000, 10000, 40000, 80000, 100000, які використовувалися для навчання моделі з і без наскрізного налаштування.

Максимальне значення середньої точності, яке складає 96%, було досягнуте при використанні повного навчального набору даних COWC (100000 автомобілів). Це відбувалося незалежно від комбінацій навчального набору даних з наскрізним налаштуванням, де використовувався один і той же тестовий набір даних 1000 автомобілів. Перевірку також проводили на іншому наборі із 1000 позначених автомобілів. З використанням 6000 автомобілів було отримано значення середньої точності, що наближалось до максимального, як показано на графіку залежності середньої точності від розміру набору даних.

Значення середньої точності виявилось набагато нижчим при використанні лише 3000 позначених автомобілів для навчання. Мінімальне значення середньої точності було зафіксоване при використанні всього 500 помічених автомобілів, і далі спостерігалася тенденція до зменшення середньої точності. Таким чином, можна зробити висновок, що для досягнення точності понад 90% для набору даних COWC потрібно мати приблизно 6000 помічених автомобілів. Спостерігалось дещо менше значення середньої точності для всіх розмірів навчальних наборів даних COWC, коли не використовувалося налаштування end-to-end. Також була вища різниця між двома налаштуваннями з

end-to-end і без end, коли використовувалося менш як 6000 помічених автомобілів.

Набір даних COWC продемонстрував 83,2% середню точність з наскрізним налаштуванням при використанні повного навчального набору. Тим часом, 100 автомобілів використовувалися як тестові та перевірочні дані для всіх комбінацій навчального набору даних. Значення середньої точності залишалося високим при використанні лише 50% від усього навчального набору даних.

З іншого боку, при подальшому зменшенні обсягу навчальних даних значення середньої точності впадало нижче 80%. Аналогічно до випадку з набором даних COWC, також відзначили порівняно низькі значення середньої точності для різних розмірів навчальних наборів даних COWC. Як видно залежності середньої точності від розміру набору даних - набір COWC, різниця між двома налаштуваннями з end-to-end і без end була дещо вищою, коли навчальний набір даних складався менше ніж із 400 помічених автомобілів.

Для навчання використали 90% навчального набору даних COWC, а також 80% для тестового набору даних COWC. Середня точність тестових даних (COWC) трошки збільшилася, коли було додано більше навчальних даних.

Таким чином, для набору даних COWC виявилось корисним використовувати більший відсоток навчальних даних порівняно з набором даних COWC, що, в свою чергу, сприяло поліпшенню відносно низького показника точності тестових даних COWC. Збільшення обсягу навчальних даних може бути ключовим елементом у вирішенні проблем недостатнього представлення об'єктів на зображеннях та надмірної чутливості моделі до конкретних нюансів в навчальному наборі. Це дозволяє моделі краще узагальнювати та адаптуватися до різних умов, що сприяє поліпшенню її ефективності та точності на тестовому наборі.

Важливо враховувати, що оптимальний розподіл між навчальними та тестовими даними може варіюватися в залежності від конкретної задачі та характеристик даних. Ефективне використання більшого обсягу навчальних

даних може сприяти кращому навчанню моделі та допомогти подолати виклики, пов'язані з обмеженим обсягом даних в тестовому наборі COWC.

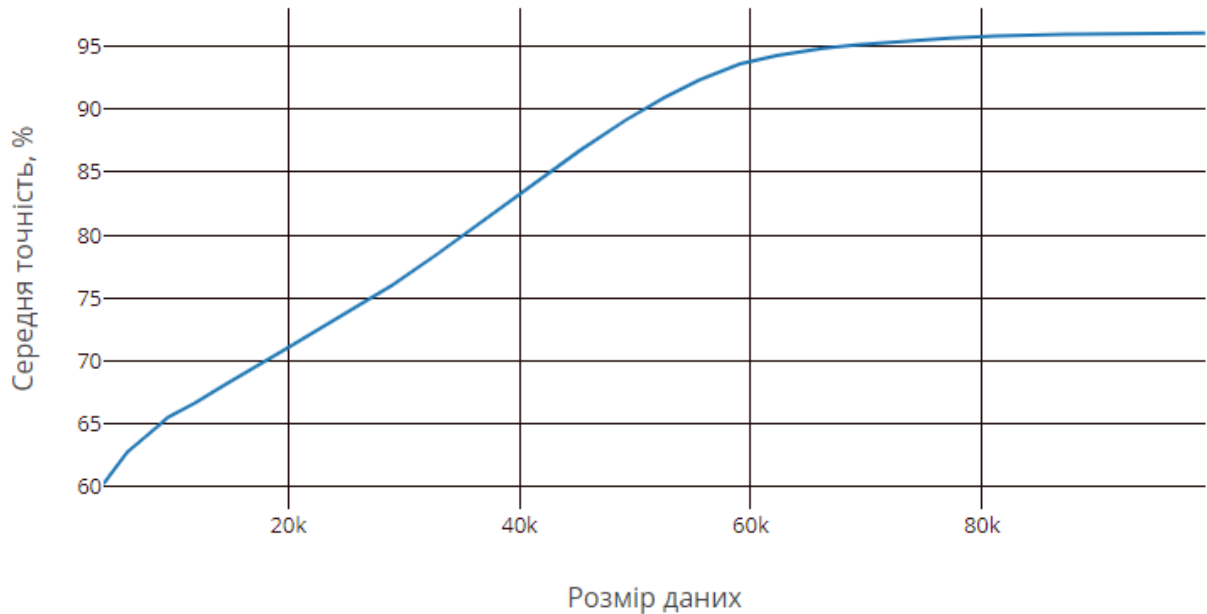


Рисунок 4.3 – Середня точність за різної кількості навчальних наборів даних

На представленому графіку відображено ефективність виявлення запропонованого методу, який включає наскрізне навчання на зображеннях з високою роздільною здатністю.

На зображеннях показано вхідні дані низької роздільної здатності, відповідно згенероване зображення високої роздільної здатності, покращену інформацію про границі та остаточне виявлення. Вдосконалення якості зображення допомогло детекторам досягти високих значень середньої точності та зробило зображення візуально привабливими, що спрощує ідентифікацію об'єктів.

Візуальна якість згенерованих ВРЗ-зображень досить висока в порівнянні з відповідними низькою роздільною здатністю-зображеннями, і детектор Faster RCNN правильно виявив більшість об'єктів.

Приклади зображень ВРЗ, отриманих на основі вхідних зображень низької роздільної здатності, наведено на рисунку 4.4 разом із покращеними границями.




Рисунок 4.4 – Визначення об'єктів на вихідних зображеннях та результати детектування об'єктів

У системі генеративно-змагальних мереж для підсилення граничних меж використовувалася втрата зв'язності зображення (L_{imgcst}). Ця втрата призводила до введення шумів на граничні межі, що спричиняло розмиття кінцевих зображень високої роздільної здатності. Результат з розмитими зображеннями і

зашумленими краями, отриманий внаслідок використання лише втрат L_{imgcst} . Розмите зображення мають меншу точність виявлення в порівнянні з чіткими.

З цією метою була додана втрата узгодженості граничних меж ($L_{edgecst}$). Втрати L_{imgcst} дозволили отримати розширену інформацію про граничні межі без шумів, аналогічно краям, виділеним на істинних зображеннях. Вплив втрат $L_{edgecst}$ показано на рисунку 4.5.



Рисунок 4.5 – Вплив втрати цілісності граничних меж ($L_{edgecst}$) на зображенні ВРЗ і поліпшені граничні межі порівняно з краями, виділеними із зображень високої роздільної здатності

Результати виявлення методу, як представлено у розділі, свідчать про покращення точності порівняно з іншими методами. Підхід виявився ефективнішим, ніж окремі сучасні методи, такі як SSD або швидший RCNN, особливо при роботі зі знімками супутника низької роздільної здатності. Використання генеративно-змагальних мереж та детекторів у системі дозволило

досягти кращих результатів, а зокрема, генеративна змагальна мережа з детекторами проявила себе краще в порівнянні з іншими методами.

Дослідження також вказує на те, що посилення граничних меж допомагає підвищити точність виявлення. Поліпшення точності виявлення було особливо помітним при високих значеннях IoU, хоча і при низьких значеннях IoU покращення було менш виразним. Дослідження також вказує на те, що з підвищенням роздільної здатності збільшується точність виявлення.

Щодо порівняння результатів для COWC були трошки меншими, оскільки при обмежених даних їх розміри і кольори менше різноманітні порівняно з автомобільним повним набором даних COWC.

В результаті проведених експериментів виявлено, що значення середньої точності можуть трохи покращитися зі збільшенням обсягу навчальних даних. Також дослідження вказує на те, що можна досягти аналогічного рівня точності, використовуючи менше навчальних даних для наборів даних.

Аналіз показав, що більш швидкий детектор RCNN перевершив SSD за результатами виявлення, однак за цією швидкістю детектор RCNN вимагав більше часу в порівнянні з SSD-детектором. Якщо пріоритетними є швидкість та ефективність виявлення на великих площах, SSD може бути оптимальним вибором, навіть за умови втрати певного рівня точності порівняно з детектором RCNN. Потрібно уважно враховувати конкретні потреби завдання та вимоги для визначення оптимального варіанту між швидкістю та точністю виявлення об'єктів.

Важливо враховувати, що вибір між SSD та RCNN також може залежати від конкретного сценарію використання. У випадках, де критичним є моментальний відгук та велика площа зображення, SSD може ефективно забезпечувати швидкі результати, хоча із зазначеною компромісною точністю. З іншого боку, якщо вимагається висока точність, і вартість додаткового часу не така критична, то обрання RCNN може виявитися обґрунтованим для забезпечення більш докладного та надійного виявлення об'єктів.

У випадку набору даних COWC, що включає велику кількість автомобілів з різних регіонів, отримано високі значення середньої точності при використанні різних IoU. Однак слід зазначити, що набір даних COWC має свої обмеження, такі як використання даних з конкретного регіону і конкретного періоду, що може впливати на загальні результати виявлення і вимагає більше даних для надійного аналізу.

Щоб зробити метод більш надійним для виявлення автомобілів, ймовірно, слід розширити обсяг даних, включаючи зображення з різних регіонів і сезонів. Також важливо враховувати, що ефективність методу може змінюватися в залежності від типів об'єктів та ландшафтів. Набори даних, що містять лише один клас із меншою варіативністю, могли обмежити універсальність методу, і бажано провести подальші дослідження на різних типах об'єктів і ландшафтах.

У дослідженні для навчання архітектури використовували пари зображень низької і високої роздільної здатності. Низької роздільної здатності зображення були створені штучно на основі високої роздільної здатності аналогів. Зазначимо, що відсутність загальнодоступного набору супутникових даних із реальними парами зображень обмежило реалізацію відповідного дослідження. Створені низької роздільної здатності зображення не повністю відображають реальність, оскільки вони були синтезовані, а не отримані з реальних низької роздільної здатності джерел.

Виявилося, що підвищення роздільної здатності за допомогою глибокого навчання завжди призводить до покращення ефективності виявлення об'єктів на зображеннях, чи то штучні, чи реальні зображення низької роздільної здатності. В подальших дослідженнях необхідно детально вивчити методи розпізнавання, щоб створити більш точні методи детектування об'єктів на зображеннях низької роздільної здатності.

Висновки до розділу 4

Проведено експериментальні дослідження з виявлення об'єктів на зображеннях низької та високої роздільної здатності за допомогою різних методів, включаючи базові детектори та генеративно-змагальні мережі.

Встановлено, що точність виявлення суттєво залежить від роздільної здатності вхідних зображень. На високороздільних зображеннях отримано 92% точності, тоді як на низькороздільних - 64-78% залежно від детектора.

Встановлено залежність ефективності методу від обсягу навчальних даних. Для конкретного набору даних COWC виявлено оптимальний розмір в 6000 позначених об'єктів, що забезпечує 90% точності. Отримані результати свідчать про високу ефективність запропонованого підходу для виявлення об'єктів на зображеннях низької роздільної здатності. Метод дозволяє значно наблизити якість виявлення на низькороздільних зображеннях до рівня високороздільних.

SSD детектор, навчений та протестований на низькороздільних зображеннях, показав 64% середньої точності. Faster RCNN за аналогічних умов показав 78%. Запропонований метод з генеративно-змагальною мережею та детектором Faster RCNN досяг 92,3% середньої точності на низькороздільних зображеннях. Запропонований метод з наскрізним навчанням досяг 92% середньої точності та 87% повноти на наборі даних COWC. При збільшенні кількості навчальних зображень в наборі даних COWC з 5000 до 100000, середня точність зросла з 80% до 96%.

Загальний висновок

На основі результатів виконаної кваліфікаційної роботи магістра, було розроблено метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях за допомогою генеративно-змагальних мереж.

Під час виконання роботи, було вирішено наступні завдання:

– проведено аналіз різноманітних методів у сфері комп'ютерного зору та глибокого навчання з метою виявлення об'єктів на зображеннях. Особлива увага приділялась огляду архітектур нейронних мереж та вдосконаленню алгоритмів, спрямованих на ефективне виявлення об'єктів на супутникових знімках. Особливий акцент робився на ситуаціях, коли зображення мають низьку роздільну здатність та наявний великий рівень зашумлення.

– здійснено аналіз генеративно-змагальних мереж та їх застосування для підвищення якості зображень дозволив виявити передові можливості цих мереж у сфері обробки зображень. Детально розглянуті техніки та підходи до використання генеративно-змагальних мереж вказують на їхню здатність генерувати реалістичні зображення високої роздільної здатності на основі початкових низькороздільних зображень.

– розроблено метод автоматичного виявлення об'єктів на зображеннях з низькою роздільною здатністю, який ґрунтується на використанні генеративно-змагальних мереж, що визначає його новизну у порівнянні з існуючими методами. У ході дослідження була представлена архітектура розробленого рішення, проаналізовані ключові компоненти та визначені переваги в порівнянні із вже існуючими підходами до виявлення об'єктів.

– удосконалено процес виявлення об'єктів на супутникових знімках шляхом впровадження інноваційних підходів, таких як інтеграція генеративно-змагальних мереж та використання архітектури наскрізного навчання. Інтеграція генеративно-змагальних мереж виявилася ключовим елементом вдосконалення, забезпечуючи здатність генерувати високоякісні та деталізовані зображення з вихідних супутникових даних.

- проведено експериментальне тестування запропонованого методу на реальних даних супутникових знімків. Згідно з результатами тестування, розроблений підхід дозволяє досягти 92% точності виявлення об'єктів на зображеннях низької роздільної здатності. Встановлено залежність результатів від обсягу навчальних даних, для конкретного набору визначено оптимальний розмір у 6000 анотованих зразків, що забезпечує 90% точності. Порівняння з існуючими підходами підтверджує переваги розробленого методу, зокрема суттєве наближення результатів на низькороздільних зображеннях до показників на високороздільних.

Розроблений метод автоматичного виявлення об'єктів на супутникових знімках за допомогою генеративно-змагальних мереж можна покращити за рахунок наступних напрямків розвитку:

- розширити набір навчальних даних, включивши більше супутникових знімків з різних регіонів та умов зйомки;
- використати потужніші архітектури нейронних мереж, для подальшого підвищення якості генерованих зображень;
- інтегрувати додаткові модулі обробки зображень та комп'ютерного зору для врахування ширшого контексту сцени при виявленні об'єктів.

Отже, розроблений метод є ефективним рішенням для науково-прикладної задачі автоматичного виявлення об'єктів на зображеннях з обмеженою роздільною здатністю та може застосовуватися на практиці в різних сферах.

Після завершення роботи підготовлено та представлено тези для участі на всеукраїнській конференції АПКН 2023.

Перелік посилань

1. Agarap A. F. Deep learning using rectified linear units (relu). *arXiv preprint arXiv:1803.08375*. 2018.
2. Alqahtani H., Kavakli-Thorne M., Kumar G. Applications of generative adversarial networks (gans): An updated review. *Archives of Computational Methods in Engineering*. 2021. Vol. 28. Pp. 525–552.
3. Al-Saffar A. A. M., Tao H., Talab M. A. Review of deep convolution neural network in image classification: *2017 International conference on radar, antenna, microwave, electronics, and telecommunications (ICRAMET)*, IEEE, 2017. Pp.26–31.
4. Alvarez-Taboada F., Paredes C., Julián-Pelaz J. Mapping of the invasive species *Hakea sericea* using unmanned aerial vehicle (UAV) and WorldView-2 imagery and an object-oriented approach. *Remote Sensing*. 2017. Vol. 9, No. 9. Pp. 913.
5. Bengoufa S., Niculescu S., Mihoubi M. K., Belkessa R., Rami A., Rabehi W., Abbad K. Machine learning and shoreline monitoring using optical satellite images: case study of the Mostaganem shoreline, Algeria. *Journal of applied remote sensing*. 2021. Vol. 15, No. 2. Pp. 026509–026509.
6. Cao J., Leng W., Liu K., Liu L., He Z., Zhu Y. Object-based mangrove species classification using unmanned aerial vehicle hyperspectral images and digital surface models. *Remote Sensing*. 2018. Vol. 10, No. 1. Pp. 89.
7. Cao L., Li K., Du K., Guo Y., Song P., Wang T., Fu C. FL-Г3M: Feature Learning Generative Adversarial Network for High-Quality Face Sketch Synthesis. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*. 2021. Pp. 2020EAP1114.
8. Chen G., Choi W., Yu X., Han T., Chandraker M. Learning efficient object detection models with knowledge distillation. *Advances in neural information processing systems*. 2017. Vol. 30.
9. Chrabaszcz P., Loshchilov I., Hutter F. A downsampled variant of imagenet as an alternative to the cifar datasets. *arXiv preprint arXiv:1707.08819*. 2017.

10. Creswell A., White T., Dumoulin V., Arulkumaran K., Sengupta B., Bharath A. A. Generative adversarial networks: An overview. *IEEE signal processing magazine*. 2018. Vol. 35, No. 1. Pp. 53–65.
11. Darlow L. N., Crowley E. J., Antoniou A., Storkey A. J. Cinic-10 is not imagenet or cifar-10. *arXiv preprint arXiv:1810.03505*. 2018.
12. Daubechies I., DeVore R., Foucart S., Hanin B., Petrova G. Nonlinear approximation and (deep) ReLU networks. *Constructive Approximation*. 2022. Vol. 55, No. 1. Pp. 127–172.
13. Durgadevi M. Generative adversarial network (gan): a general review on different variants of gan and applications: *2021 6th International Conference on Communication and Electronics Systems (ICCES)*, IEEE, 2021. Pp.1–8.
14. Feng J., Feng X., Chen J., Cao X., Zhang X., Jiao L., Yu T. Generative adversarial networks based on collaborative learning and attention mechanism for hyperspectral image classification. *Remote Sensing*. 2020. Vol. 12, No. 7. Pp. 1149.
15. Giuste F. O., Vizcarra J. C. Cifar-10 image classification using feature ensembles. *arXiv preprint arXiv:2002.03846*. 2020.
16. Gudžius P., Kurasova O., Darulis V., Filatovas E. Deep learning-based object recognition in multispectral satellite imagery for real-time applications. *Machine Vision and Applications*. 2021. Vol. 32, No. 4. Pp. 98.
17. Guo T., Dong J., Li H., Gao Y. Simple convolutional neural network on image classification: *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)*, IEEE, 2017. Pp.721–724.
18. Hardy C., Le Merrer E., Sericola B. Md-gan: Multi-discriminator generative adversarial networks for distributed datasets: *2019 IEEE international parallel and distributed processing symposium (IPDPS)*, IEEE, 2019. Pp.866–877.
19. Li W., Chen J., Wang Z., Shen Z., Ma C., Cui X. Ifl-gan: Improved federated learning generative adversarial network with maximum mean discrepancy model aggregation. *IEEE Transactions on Neural Networks and Learning Systems*. 2022.

20. Ma W., Guo Q., Wu Y., Zhao W., Zhang X., Jiao L. A novel multi-model decision fusion network for object detection in remote sensing images. *Remote Sensing*. 2019. Vol. 11, No. 7. Pp. 737.
21. Ma Z., Liu Y., Miao Y., Xu G., Liu X., Ma J., Deng R. H. FL Γ 3M: Γ 3M-Based Unbiased Federated Learning under Non-IID Settings. *IEEE Transactions on Knowledge and Data Engineering*. 2023.
22. McAllister E., Payo A., Novellino A., Dolphin T., Medina-Lopez E. Multispectral satellite imagery and machine learning for the extraction of shoreline indicators. *Coastal Engineering*. 2022. Vol. 174. Pp. 104102.
23. Moskolai W. R., Abdou W., Dipanda A., Kolyang. Application of deep learning architectures for satellite image time series prediction: A review. *Remote Sensing*. 2021. Vol. 13, No. 23. Pp. 4822.
24. Muhammad K., Ahmad J., Lv Z., Bellavista P., Yang P., Baik S. W. Efficient deep CNN-based fire detection and localization in video surveillance applications. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. 2018. Vol. 49, No. 7. Pp. 1419–1434.
25. Müllerová J., Bruna J., Bartaloš T., Dvořák P., Vítková M., Pyšek P. Timing is important: Unmanned aircraft vs. satellite imagery in plant invasion monitoring. *Frontiers in Plant Science*. 2017. Vol. 8. Pp. 887.
26. Nguyen D. T., Nguyen T. N., Kim H., Lee H.-J. A high-throughput and power-efficient FPGA implementation of YOLO CNN for object detection. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*. 2019. Vol. 27, No. 8. Pp. 1861–1873.
27. Padilla R., Netto S. L., Da Silva E. A. A survey on performance metrics for object-detection algorithms: 2020 international conference on systems, signals and image processing (IWSSIP), IEEE, 2020. Pp.237–242.
28. Pan Z., Yu W., Yi X., Khan A., Yuan F., Zheng Y. Recent progress on generative adversarial networks (Γ 3Ms): A survey. *IEEE access*. 2019. Vol. 7. Pp. 36322–36333.

29. Rawat W., Wang Z. Deep convolutional neural networks for image classification: A comprehensive review. *Neural computation*. 2017. Vol. 29, No. 9. Pp. 2352–2449.
30. Shao F., Wang X., Meng F., Zhu J., Wang D., Dai J. Improved faster R-CNN traffic sign detection based on a second region of interest and highly possible regions proposal network. *Sensors*. 2019. Vol. 19, No. 10. Pp. 2288.
31. Tahir A., Munawar H. S., Akram J., Adil M., Ali S., Kouzani A. Z., Mahmud M. P. Automatic target detection from satellite imagery using machine learning. *Sensors*. 2022. Vol. 22, No. 3. Pp. 1147.
32. Thakkar V., Tewary S., Chakraborty C. Batch Normalization in Convolutional Neural Networks—A comparative study with CIFAR-10 data: *2018 fifth international conference on emerging applications of information technology (EAIT)*, IEEE, 2018. Pp.1–5.
33. Traore B. B., Kamsu-Foguem B., Tangara F. Deep convolution neural network for image recognition. *Ecological informatics*. 2018. Vol. 48. Pp. 257–268.
34. Tu Y., Song Y., Li B., Zhu Q., Cui S., Zhu H. A Deformable Spatial Attention Mechanism-Based Method and A Benchmark for Dock Detection. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*. 2023.
35. Ventura D., Bonifazi A., Gravina M. F., Belluscio A., Ardizzone G. Mapping and classification of ecologically sensitive marine habitats using unmanned aerial vehicle (UAV) imagery and object-based image analysis (OBIA). *Remote Sensing*. 2018. Vol. 10, No. 9. Pp. 1331.
36. Wang D., Shao Q., Yue H. Surveying wild animals from satellites, manned aircraft and unmanned aerial systems (UASs): A review. *Remote Sensing*. 2019. Vol. 11, No. 11. Pp. 1308.
37. Witharana C., Bhuiyan M. A. E., Liljedahl A. K., Kanevskiy M., Epstein H. E., Jones B. M., Daanen R., Griffin C. G., Kent K., Jones M. K. W. Understanding the synergies of deep learning and data fusion of multispectral and panchromatic high resolution commercial satellite imagery for automated ice-wedge polygon detection. *ISPRS Journal of Photogrammetry and Remote Sensing*. 2020. Vol. 170. Pp. 174–191.

38. Wu X., Xu K., Hall P. A survey of image synthesis and editing with generative adversarial networks. *Tsinghua Science and Technology*. 2017. Vol. 22, No. 6. Pp. 660–674.
39. Xin B., Yang W., Geng Y., Chen S., Wang S., Huang L. Private fl-gan: Differential privacy synthetic data generation based on federated learning: *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, IEEE, 2020. Pp.2927–2931.
40. Xu J., Li Z., Du B., Zhang M., Liu J. Reluplex made more practical: Leaky ReLU: *2020 IEEE Symposium on Computers and communications (ISCC)*, IEEE, 2020. Pp.1–7.
41. Yao H., Qin R., Chen X. Unmanned aerial vehicle for remote sensing applications—A review. *Remote Sensing*. 2019. Vol. 11, No. 12. Pp. 1443.
42. Zhu L., Chen Y., Ghamisi P., Benediktsson J. A. Generative adversarial networks for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*. 2018. Vol. 56, No. 9. Pp. 5046–5063.

ДОДАТКИ

Додаток А

Міністерство освіти і науки України
Хмельницький національний університет



ЗБІРНИК НАУКОВИХ ПРАЦЬ
за матеріалами XV Всеукраїнської науково-практичної конференції
«Актуальні проблеми комп'ютерних наук АПКН-2023»

17-18 листопада 2023

Хмельницький 2023

АКТУАЛЬНІ ПРОБЛЕМИ КОМП'ЮТЕРНИХ НАУК - 2023*XV Всеукраїнська науково-практична конференція*

Метою конференції є висвітлення актуальних проблем комп'ютерних наук, інформатики та інформаційних технологій.

СЕКЦІЇ КОНФЕРЕНЦІЇ:

1. Комп'ютерні науки та прикладні інформаційні технології.
2. Комп'ютерна інженерія та системи захисту інформації.
3. Математичне моделювання та інженерія програмного забезпечення
4. Телерадіокомунікації, медійні та комунікаційні системи.
5. Проблеми впровадження інформаційних технологій у виробництво та управління.

Робочі мови конференції: українська, англійська

ОРГКОМІТЕТ:

Олег СИНЮК – голова оргкомітету, проректор Хмельницького національного університету з наукової роботи, доктор технічних наук, професор

Олег САВЕНКО – заступник голови оргкомітету, декан факультету Інформаційних технологій ХНУ, доктор технічних наук, професор

Олександр БАРМАК – заступник голови оргкомітету, завідувач кафедри Комп'ютерних наук ХНУ, доктор технічних наук, професор

Тетяна ГОВОРУЩЕНКО – завідувач кафедри Комп'ютерної інженерії та інформаційних систем ХНУ, доктор технічних наук, професор

Олена ВИСОЦЬКА – доктор технічних наук, завідувач кафедри Радіоелектронних та біомедичних комп'ютеризованих засобів і технологій Національного аерокосмічного університету ім. М. Є. Жуковського «Харківський авіаційний інститут», професор

Євгеній ЛАВРОВ – доктор технічних наук, професор (Сумський державний університет)

Людмила ТИМОФЄЄВА – відповідальна за студентську науково-дослідну роботу ХНУ

Олександр МАЗУРЕЦЬ – секретар конференції, к.т.н., доцент кафедри Комп'ютерних наук ХНУ

Марина МОЛЧАНОВА – секретар конференції, викладач кафедри Комп'ютерних наук ХНУ

КОНТАКТНА ІНФОРМАЦІЯ:

e-mail для листування: apkt.khnu@gmail.com

Овчарук О.М., Мазурець О.В. Прогнозування значень параметрів за їх часовими рядами рекурентною темпоральною нейронною мережею	227
Олійник П.О. Удосконалений метод роботи з метриками покриття коду для забезпечення ефективного оцінювання результатів тестування програмного забезпечення	233
Онїкієнко С.С., Глухов В.Ю., Манзюк Е.А. Детектування об'єктів на зображеннях з невеликою роздільною здатністю	236
Охота В.В., Міхалевський В.Ц., Скрипник Т.К. Метод здійснення річкової переправи транспортних засобів за мурашиним алгоритмом	239
Павлова О.О., Рудик І.В. Пост-обробка сигналів тривоги систем відеоспостереження за допомогою нейромережі YOLOv8	242
Побережна А.Ю. Кіберфізична система моніторингу стану рослин в режимі реального часу	245
Присяжнюк О.О. Дослідження та проектування комп'ютерних систем штучного інтелекту	250
Рижий Я.О., Мельник М.М., Чешун О.В., Орленко В.С. Класифікація атрибутів особи і формування цифрового підпису на їх основі	252
Ровінчук Д.Ю. Метод та програмні засоби виявлення метаморфних комп'ютерних вірусів.....	257
Родін О.О., Яшина О.М. Метод спектральних характеристик звукового сигналу для визначення рівня психологічного стану людини за допомогою глибинного навчання	260
Савчук А.В. Розробка бібліотеки для побудови та обчислень електричних кіл.....	264
Сверба А.А. Удосконалення методу роботи з метрикою середнього часу між відмовами для забезпечення ефективного оцінювання результатів тестування програмного забезпечення.....	266
Свистун С.О., Мельниченко О.В., Скрипник Т.К. Проектування робочої місії безпілотних літальних апаратів в тривимірному просторі.....	269

УДК 004.4

Онiкiєнко С.С., Глухов В.Ю., Манзюк Е.А.

*Хмельницький національний університет***ДЕТЕКТУВАННЯ ОБ'ЄКТІВ НА ЗОБРАЖЕННЯХ З НЕВЕЛИКОЮ РОЗДІЛЬНОЮ ЗДАТНІСТЮ**

Створена та реалізована система для автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях шляхом застосування методів штучного інтелекту. Дані для аналізу були отримані з низки зображень, які мали обмежену якість і роздільну здатність. В рамках дослідження використовувалися як методи, які вимагали наявності зразків об'єктів, так і методи без них для виявлення цих об'єктів на низькороздільних зображеннях. Результати дослідження свідчать про високу ефективність запропонованих методів у виявленні об'єктів з невеликою роздільною здатністю на зображеннях.

A system for automatic detection of objects with low resolution on images has been developed and implemented using artificial intelligence methods. Data for analysis were obtained from a set of images with limited quality and resolution. The research encompassed methods that required the presence of object samples as well as methods that did not, for the detection of these objects on low-resolution images. The research results confirm the high effectiveness of the proposed methods in detecting objects with low resolution on images.

Здатність виявлення та точне визначення місця розташування об'єктів на зображеннях, отриманих з супутників або безпілотних апаратів, має широкий потенціал застосування у різних галузях, включаючи екологічний моніторинг, контроль лісових ресурсів, забезпечення національної безпеки та управління дорожнім рухом. Однак існуючі дослідження свідчать про обмежену ефективність виявлення, особливо у випадках, коли зображення мають низьку роздільну здатність і схильні до шуму, особливо в контексті малих об'єктів [2, 3]. Ця проблема залишається актуальною навіть для високороздільних зображень, де ефективність виявлення невеликих об'єктів падає в порівнянні з їх більшими аналогами.

Сучасні детектори виявили високу точність при використанні стандартних наборів даних, які містять зображення, де об'єкти помітні та великі, такі, як CIFAR. Проте такі набори даних не відображають специфічні вимоги роботи з супутниковими знімками та потреби виявлення менших об'єктів. Розробка ефективних методів для подолання цих викликів стає актуальним завданням для

поліпшення систем виявлення об'єктів в реальних умовах дистанційного спостереження.

У межах цього дослідження виникає завдання виявлення невеликих об'єктів на супутникових знімках із низькою роздільною здатністю. Ця проблема є складною через обмежену якість таких зображень. У цьому контексті розглядається метод, що передбачає створення зображень високої роздільної здатності на основі вихідних низькороздільних супутникових знімків і одночасне виявлення об'єктів на зображеннях високої роздільної здатності. Цей метод ґрунтується на використанні глибокої генеративної змагальної мережі [1], яка має потенціал у поліпшенні якості зображень.

В покращених зображеннях відсутня важлива інформація, яка стосується деталей та контурів об'єктів. Ця відсутність інформації негативно впливає на результати виявлення невеликих об'єктів на відновлених та зашумлених зображеннях із низькою роздільною здатністю.

З метою подолання цієї проблеми було розроблено новий підхід, який передбачає використання генеративної змагальної мережі для покращення контурів об'єктів та створення високої роздільної здатності для покращення якості супутникових зображень. У цьому контексті застосовуються різноманітні мережі для виявлення об'єктів в режимі співпраці, де втрачаються, що виникають під час виявлення об'єктів, передаються генеративної змагальної мережі з генерацією об'єктів із покращеними контурами з метою підвищення ефективності процесу виявлення.

Цей підхід сприяє покращенню можливостей виявлення об'єктів на супутникових знімках низької роздільної здатності після застосування заходів для відновлення інформації та підвищення загальної якості зображень.

В рамках цього підходу впроваджена інтегрована архітектура, яка включає у себе покращену генеративну змагальну мережу, мережу для покращення граничних контурів та мережу для виявлення об'єктів. Для реалізації генеративної змагальної мережі були використані блоки з залишковим з'єднанням, тоді як для детекторної мережі застосована швидка згорткова мережа, що базується на регіонах, і одноступінчастий мультибоксовий детектор. Розширені експерименти, проведені на наборі даних для супутникових знімків, підтвердили переваги цього методу в порівнянні з використанням окремих нейронних мереж.

Збільшена роздільна здатність зображень позитивно впливає на завдання виявлення об'єктів на супутникових знімках. У дослідженнях використано набори даних від супутників і проводили одночасне поліпшення зображень та виявлення об'єктів, використовуючи глибоку згорткову нейронну мережу та одноступінчастий мультибоксовий детектор.

Запропоновано використання глибокого генератора, побудованого на основі згорткової нейронної мережі, для перетворення низькороздільних зображень у високороздільні. Також використано багатозадачну мережу як дискримінатор і для локалізації та класифікації об'єктів. Дослідження проводяться на стандартних зображеннях, які вимагають пари зображень - низькороздільних і високороздільних.

Крім того, використовуємо метод одночасного використання високороздільності та виявлення об'єктів на супутникових знімках. Архітектура мережі розроблена на основі циклічно узгодженої глибокої змагальної мережі.

У ході розв'язання завдання виявлення об'єктів, було створено метод та відповідні системи для маркування, навчання та виявлення об'єктів на великих супутникових знімках, що охоплюють значні території. Цей метод спрощує завдання виявлення невеликих об'єктів на супутникових знімках, роблячи можливим оптимізацію процесу навчання сучасних моделей виявлення об'єктів та точне визначення їх розташування на зображеннях.

Перелік посилань

1. Durgadevi M. Generative adversarial network (gan): a general review on different variants of gan and applications: 2021 6th International Conference on Communication and Electronics Systems (ICCES), IEEE, 2021. Pp.1–8.i
2. Wang Z.-Z., Xie K., Zhang X.-Y., Chen H.-Q., Wen C., He J.-B. Small-object detection based on yolo and dense block via image super-resolution. IEEE Access. 2021. Vol. 9. Pp. 56416–56429.
3. Wu X., Hong D., Chanussot J. UIU-Net: U-Net in U-Net for infrared small object detection. IEEE Transactions on Image Processing. 2022. Vol. 32. Pp. 364–376.

Додаток Б

ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА

МЕТОД АВТОМАТИЧНОГО ВИЯВЛЕННЯ ОБ'ЄКТІВ З НЕВЕЛИКОЮ РОЗДІЛЬНОЮ ЗДАТНІСТЮ НА ЗОБРАЖЕННЯХ

Виконав: *студент групи КНМ-21-1*
Онікієнко Сергій Сергійович

1

Мета кваліфікаційної роботи

Мета кваліфікаційної роботи магістра полягає в створенні ефективного методу, який здатний автоматично виділяти та аналізувати об'єкти на зображеннях із низькою роздільною здатністю, поліпшуючи якість супутникових та інших зображень.

2

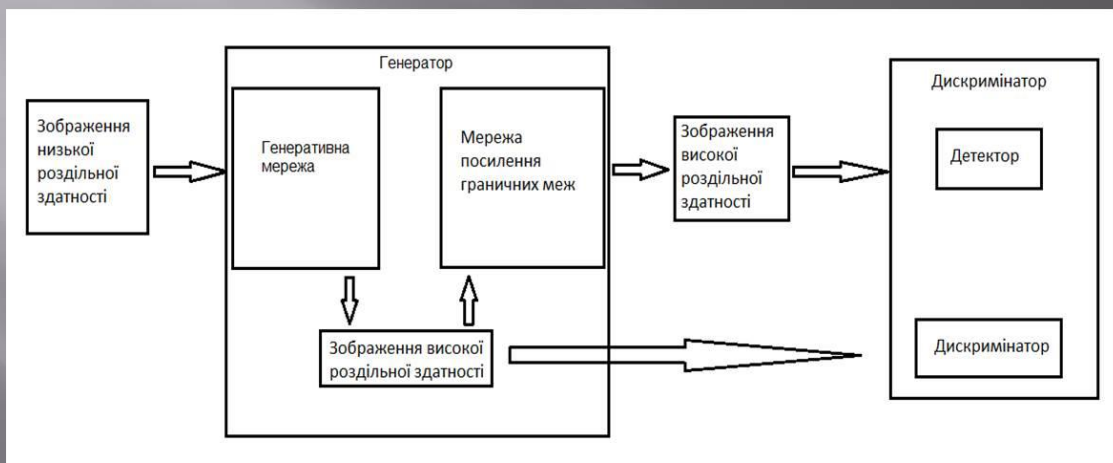
Задачі роботи

Для досягнення поставленої мети необхідно:

1. Провести дослідження наукових робіт та публікацій у галузі обробки зображень, генеративних технологій, та методів виявлення об'єктів.
2. Здійснити збір даних, які включають супутникові зображення об'єктів з невеликою роздільною здатністю та їх відповідні покращені зображення після застосування генеративних мереж.
3. Розробити методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.
4. Провести експериментальні дослідження для оцінки ефективності розробленого методу.

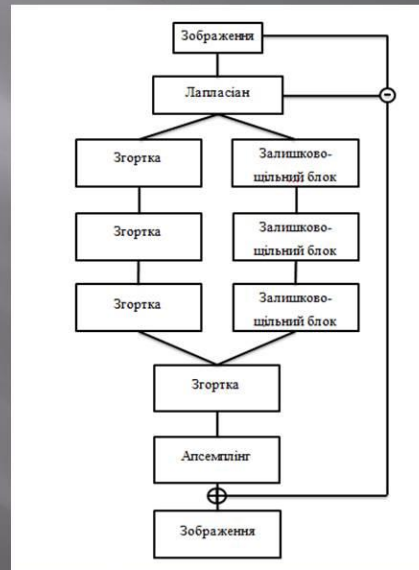
3

Загальна архітектура мережі з генератором і модулем дискримінатора



4

Мережа посилення граничних меж, де на вході проміжне зображення високої роздільної здатності, на виході зображення високої роздільної здатності



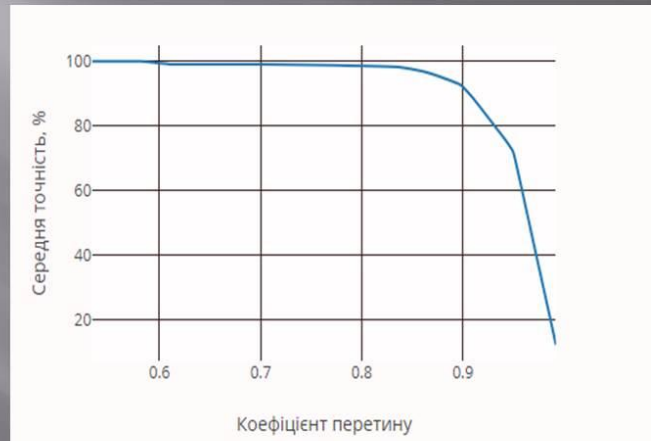
5

Виявлення об'єктів на зображеннях високої роздільної здатності за допомогою окремо навченої мережі для зображеннях низької роздільної здатності

Модель	Тренування	Тестування	IoU=0.6:0.9
SSD	BP3	BP3	70.2%
	HP3	BP3	55.6%
Faster RCNN	BP3	BP3	74.3%
	HP3	BP3	59.7%
GSSD	BP3	BP3	85.3%
	HP3	BP3	82.7%
GFaster RCNN	BP3	BP3	91.8%
	HP3	BP3	90.1%
EGSSD	BP3	BP3	92.7%
	HP3	BP3	91.4%
EGFaster RCNN	BP3	BP3	93.4%
	HP3	BP3	92.3%


6

Крива середня точність – коефіцієнт перетину для наборів даних



7

Середня точність за різної кількості навчальних наборів даних



8

Детектування об'єктів на а) вихідному зображенні та б) покращеному



а)



б)

9

Висновки

У дослідженні розроблена інтегрована архітектура, що обробляє супутникові знімки низької роздільної здатності та генерує результати виявлення об'єктів.

Створено систему, яка спрощує процес маркування, навчання та виявлення об'єктів на супутникових знімках. Запропонована архітектура включає в себе генеративну і мережу детекторів.

За результатами експериментів виявлено, що запропонована архітектура мережі продемонструвала найвищу ефективність у виявленні малих об'єктів на супутникових знімках.

Вирішено наступні завдання:

1. Проведено дослідження наукових робіт та публікацій у галузі обробки зображень, генеративних технологій, та методів виявлення об'єктів.
2. Здійснено збір даних, які включають супутникові зображення об'єктів з невеликою роздільною здатністю та їх відповідні покращені зображення після застосування генеративних мереж.
3. Розроблено метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.
4. Проведено експериментальні дослідження для оцінки ефективності розробленого методу.

10

Дякую за увагу!

Ім'я користувача:
Кафедра КН

ID перевірки:
1015974020

Дата перевірки:
05.12.2023 21:33:03 EET

Тип перевірки:
Doc vs Internet + Library

Дата звіту:
05.12.2023 21:49:06 EET

ID користувача:
100005671

Назва документа: КНм-22-1 Онікієнко

Кількість сторінок: 77 Кількість слів: 15476 Кількість символів: 119312 Розмір файлу: 1.36 MB ID файлу: 1015653340

10.1% Схожість

Найбільша схожість: 1.35% з джерелом з Бібліотеки (ID файлу: 1015646688)

9.47% Джерела з Інтернету

941

Сторінка 79

1.74% Джерела з Бібліотеки

59

Сторінка 89

0% Цитат

Вилучення цитат вимкнене

Вилучення списку бібліографічних посилань вимкнене

0% Вилучень

Немає вилучених джерел

Модифікації

Виявлено модифікації тексту. Детальна інформація доступна в онлайн-звіті.

Замінені символи

38

Anti-Plagiarism v-15.257

Максимальне співпадіння з одним документом 1.0%

Словники перевірки: en_US, ru_RU, ua_UA. Помилки в документах: 9%

ID: 121828 Назва: КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА на тему Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях Додано в БД: 2023-12-05 Автора: С.С. Онкієнко Керівники: Е.А. Манзюк Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	98371	1499	2102 (2%)	36 (2%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

**РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ КАФЕДРИ КОМП'ЮТЕРНИХ НАУК
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ**

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованою системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях

Автор: студент групи КНм-22-1 Онікієнко Сергій Сергійович

Спеціальність: 122 – Комп'ютерні науки

Освітня програма: освітньо-професійна

Науковий керівник: д.т.н., доцент Манзюк Е.А.

Після аналізу звіту подібності зроблено такий висновок:

№	Висновок	Позначка про відповідність
1	Запозичення, виявлені в роботі, є законними і не є плагіатом. Робота приймається до захисту.	<i>відповідає</i>
2	Виявлені запозичення не є плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота приймається до захисту, але має бути відкоригована. Відкоригований варіант має бути поданий на кафедру за 2 дні до захисту, разом із заявою щодо самостійності виконання письмової роботи та ідентичності друкованої та електронної версії роботи	
3	Виявлені запозичення не є плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. В зв'язку з цим мета роботи та поставлені завдання не були досягнені. Робота може бути допущена до захисту (наступного року) після того як буде відкоригована та допрацьована і успішно пройде повторну перевірку на академічний плагіат.	
4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	

Підтвердження:

Запозичення, виявлені в роботі Онікієнко С.С., не є плагіатом, оскільки: запозичення розміщені в розділі огляду існуючих підходів, не описують безпосередньо авторську роботу і не стосуються її результатів; усі запозичення фрагментарні; серед запозичень знаходяться загальновідомі терміни, скорочення.

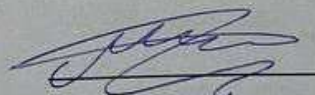
Обсяг запозичень, визначений системами виявлення збігів/ідентичності/схожості, складає:

- за системою Anti-Plagiarism: 1%;

- за системою Unichек: 10.1%.

Сумарний обсяг всіх запозичень, визначений системою виявлення збігів/ідентичності/схожості є допустимим.

Керівник роботи



Едуард МАНЗЮК

Гарант ОП



Руслан БАГРІЙ

Завідувач кафедри КН



Олександр БАРМАК



ВІДГУК ОПОНЕНТА

на кваліфікаційну роботу магістра

студента *гр. КНм-22-1 Онікієнка Сергія Сергійовича*

за темою *Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях*

1. Актуальність обраної теми

Виявлення та локалізація об'єктів на зображеннях, отриманих із супутників або безпілотних апаратів, представляє собою важливу та актуальну проблему в сучасному світі. Існуючі методи та детектори об'єктів часто непридатні для роботи з низькороздільними та зашумленими супутниковими знімками, особливо при виявленні дрібних об'єктів. Зменшення ефективності виявлення дрібних об'єктів також спостерігається на високороздільних зображеннях, що потребує розробки нових підходів. Розробка ефективних методів для виявлення об'єктів на супутникових знімках стає нагальною задачею, що вимагає дослідження та розробки нових підходів.

2. Відповідність роботи предметній області спеціальності 122 Комп'ютерні науки та загальним вимогам до наукових робіт

Тема дослідження, яка включає в себе використання методів машинного навчання для автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях, повністю відповідає галузі комп'ютерних наук (спеціальність 122). Робота відповідає всім необхідним вимогам для магістерської кваліфікаційної роботи в даній області.

3. Повнота розкриття мети та завдань дослідження

У кваліфікаційній роботі була повністю висвітлена зазначена мета та чітко сформульовані завдання для проведення дослідження. Автор докладно розглянув та розкрив кожний аспект мети дослідження, складові поставлених завдань були проаналізовані та висвітлені в роботі. Забезпечено повноту та чіткість у представленні мети та завдань.

4. Наявність наукової новизни

Отримані результати характеризуються науковою новизною, яка полягає в інтеграції процесів створення високороздільних зображень на основі низькороздільних супутникових знімків та одночасного виявлення об'єктів на високороздільних зображеннях. Цей інноваційний метод використовує глибоку генеративну змагальну

мережу, що демонструє значний потенціал для покращення якості отриманих зображень. У роботі вдається вирішити проблему відсутності важливої високочастотної інформації на покращених зображеннях, особливо щодо деталей та граничних контурів об'єктів.

5. Зміст кожного розділу роботи

Робота містить чотири розділи. В першому розділі здійснено аналіз систем штучного інтелекту з виявлення об'єктів на зображеннях. Сформульовано мету та основні задачі дослідження. Другий розділ присвячено розробці методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях. У третьому розділі представлено формування множини даних та навчання з виявлення об'єктів з невеликою роздільною здатністю на зображеннях. У четвертому розділі проведено експериментальне дослідження ефективності виявлення об'єктів на зображеннях з невеликою роздільною здатністю.

6. Ступінь розкриття теми роботи

Автор магістерської роботи чітко аргументує та освітлює тему свого дослідження. Проведено ретельний аналіз актуальності теми та наявних досліджень в даному напрямку. Завдання були сформульовані та успішно виконані, а результати розроблених методів та інструментів виявилися детально проаналізованими з огляду на їхнє практичне використання.

7. Якість оформлення кваліфікаційної роботи

Оформлення магістерської роботи відповідає вимогам та нормам, які передбачені для оформлення кваліфікаційних робіт.

8. Недоліки кваліфікаційної роботи

В роботі представлено виявлення об'єктів одного типу. Доцільно було б провести дослідження щодо виявлення об'єктів різних класів.

9. Загальний висновок (допускається чи не допускається до захисту), якої оцінки заслуговує кваліфікаційна робота

Враховуючи рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка *добре*.

Рецензент зас. проф. АКИТас Р Ш Д В. Морганік



ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ
МОН УКРАЇНИ

Кафедра комп'ютерних наук



ВІДГУК НАУКОВОГО КЕРІВНИКА
на кваліфікаційну роботу магістра

студента гр. КНМ-22-1 Онікієнка Сергія Сергійовича

за темою Метод автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях

1. Актуальність теми

Виявлення та локалізація об'єктів на зображеннях, отриманих від супутників або безпілотних апаратів, володіють значним потенціалом застосування у різних галузях, таких як екологічний моніторинг, спостереження за лісовими ресурсами, забезпечення національної безпеки та управління дорожнім рухом. Однак існуючі дослідження вказують на недоліки в ефективності виявлення, особливо в умовах низької роздільної здатності і зашумленості зображень, особливо при об'єктах невеликих розмірів. Кваліфікаційна робота магістра розв'язує науково-практичну задачу розробка методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях.

2. Відповідність роботи предметній області Стандарту спеціальності 122 Комп'ютерні науки

Мета, яка була поставлена в магістерській кваліфікаційній роботі, пов'язана із розробкою методу автоматичного виявлення об'єктів з невеликою роздільною здатністю на зображеннях. Ця мета повністю відповідає предметній області спеціальності 122 "Комп'ютерні науки" і вимогам до кваліфікаційної роботи.

3. Професійні та особистісні якості

У процесі виконання магістерської кваліфікаційної роботи Онікієнко Сергій Сергійович продемонстрував високий рівень компетентності та вмінь. Він ефективно вирішував завдання, вчасно виконуючи їх. Під час написання пояснювальної записки та розробки програмного забезпечення показав належний рівень компетентностей та отримав успішні результати у своєму навчанні. Його професійні вміння у галузі "Комп'ютерні науки" є високими.

4. Ступінь самостійності під час виконання кваліфікаційної роботи

Результати, які були отримані під час виконання кваліфікаційної роботи, представляють собою продукт самостійної праці студента. Висунуті в роботі положення дозволили удосконалити існуючі методи в області автоматичного виявлення об'єктів з невеликою роздільною здатністю.

5. Наукова новизна та оригінальність запропонованих підходів

Отримані результати поєднують створення високороздільних зображень з використанням низькороздільних супутникових знімків та одночасне виявлення об'єктів на високороздільних зображеннях. Основна наукова проблема, вирішена в роботі, стосується відсутності важливої високочастотної інформації на покращених зображеннях, особливо щодо деталей та граничних контурів об'єктів. Вирішення цієї проблеми є ключовим аспектом наукової новизни даного дослідження, що може мати важливі наслідки для областей, де важливий аналіз низькороздільних супутникових знімків для виявлення дрібних об'єктів.

6. Ступінь оволодіння методами дослідження

В ході виконання кваліфікаційної роботи було продемонстровано високий рівень компетентності та володіння необхідними методами, методиками і технологіями у галузі комп'ютерних наук.

7. Повнота та якість розкриття теми роботи

Обрана тема роботи була повністю обґрунтована і належним чином розкрита. Здійснено аналіз відомих досліджень в рамках обраної теми. Сформульовані завдання були успішно вирішені, і було розроблено програмне забезпечення для ефективної реалізації запропонованого методу.

8. Логічність, послідовність, аргументованість, літературна грамотність викладення матеріалу

Структура роботи та послідовність викладення логічні та відповідають поставленій меті. Викладення матеріалу послідовне, аргументоване, літературно грамотне.

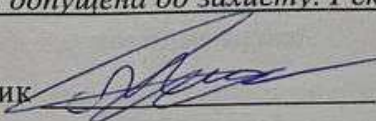
9. Можливість практичного застосування кваліфікаційної роботи, окремих її частин

Розроблений у роботі підхід, який поєднує покращення зображень і виявлення об'єктів, робить можливим автоматичне виділення та аналіз об'єктів на супутникових знімках. Це має важливе значення для багатьох галузей, включаючи рятувальні операції, аналіз екологічних проблем та інші.

10. Висновок про можливість допуску кваліфікаційної роботи до захисту, на яку оцінку заслуговує робота

Враховуючи належний рівень виконання та забезпечення усіх необхідних вимог, робота може бути допущена до захисту. Рекомендована оцінка «відмінно».

Керівник



д.т.н., професор каф. КН Едуард МАНЗЮК