

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет Електронної та біомедичної інженерії
(повна назва)

Кафедра Мікроелектроніки, електронних приладів та пристроїв
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА Пояснювальна записка

рівень вищої освіти другий (магістерський)

Аналіз та удосконалення методів обробки періодичних
і випадкових сигналів в системах технічного зору
(тема)

Виконав:
студент 2 курсу, групи ЕППМ-24-1
Матвієнко Є.П.
(прізвище, ініціали)

Спеціальність 171 Електроніка
(код і повна назва спеціальності)

Тип програми освітньо-професійна

Освітня програма «Електронні пристрої та системи»
(повна назва освітньої програми)

Керівник проф. каф. МЕЕПП Грицунов О.В.
(посада, прізвище, ініціали)

Допускається до захисту

Зав. кафедри _____
(підпис)

Бондаренко І.М.
(прізвище, ініціали)

2025 р.

Харківський національний університет радіоелектроніки

Факультет Електронної та біомедичної інженерії
(повна назва)Кафедра Мікроелектроніки, електронних приладів та пристроїв
(повна назва)Рівень вищої освіти другий (магістерський)Спеціальність 171 – Електроніка
(код і повна назва)Тип програми освітньо-професійна
(освітньо-професійна або освітньо-наукова)Освітня програма Електронні пристрої та системи
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

« _____ » _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУстудентові Матвієнко Єгору Павловичу
(прізвище, ім'я, по батькові)1. Тема роботи «Аналіз та удосконалення методів обробки періодичних і випадкових сигналів в системах технічного зору»затверджена наказом університету від 24 листопада 2025 р. № 1056 Ст2. Термін подання студентом роботи до екзаменаційної комісії 13 _____ 12 _____ 2025 р.3. Вихідні дані до роботи використовувалося середовище розробки Google Colab з мовою Python та бібліотеками PyTorch, OpenCV і NumPy. Тестові зображення мали розмір 256 на 256 пікселів у відтінках сірого. Модельовані завади включали періодичні гармонічні смуги змінної частоти та амплітуди від 0.2 до 0.5, а також випадкові завади – адитивний гаусівський шум з $\sigma = 0.035$ та шум Пуассона. Моделювання виконувалося на апаратній платформі GPU NVIDIA Tesla T4.

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Огляд та аналіз існуючих методів фільтрації зображень у системах технічного зору, класифікація періодичних та випадкових завад;2) Теоретичне обґрунтування та розробка гібридного методу обробки сигналів, що поєднує адаптивну режекторну фільтрацію у частотній області та згорткові нейронні мережі;3) Розробка програмного комплексу для генерації навчальної вибірки синтетичних даних та реалізації алгоритмів відновлення зображень.4) Проведення експериментальних досліджень ефективності розробленого методу, порівняльний аналіз за метриками пікового відношення сигнал-шум.

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

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Аналіз технічного завдання та уточнення вимог до системи	10.10.2025	
2	Аналітичний огляд джерел та методів обробки сигналів	15.10.2025	
3	Вибір архітектури нейромережі	18.10.2025	
4	Програмна реалізація алгоритмів генерації даних	27.10.2025	
5	Проведення експериментів, навчання	02.11.2025	
6	Аналіз результатів моделювання	07.11.2025	
7	Оформлення пояснювальної записки	12.11.2025	
8	Підготовка презентації та графічного матеріалу	05.12.2025	
9	Подача роботи в екзаменаційну комісію	13.12.2025	

Дата видачі завдання 10 жовтня 2025 р.

Студент _____
(підпис)

Керівник роботи _____ професор каф. МЕЕПІ. Грицунов О.В.
(підпис) (посада, прізвище, ініціали)

РЕФЕРАТ

Пояснювальна записка до кваліфікаційної роботи: 57 сторінок, 13 рисунків, 2 таблиці, 3 додатки.

ОБРОБКА СИГНАЛІВ, МАШИННИЙ ЗІР, ПЕРІОДИЧНІ ЗАВАДИ, ВИПАДКОВИЙ ШУМ, ПЕРЕТВОРЕННЯ ФУР'Є, НЕЙРОННІ МЕРЕЖІ, CNN, ГІБРИДНА ФІЛЬТРАЦІЯ, ПВСШ, ІСП.

Об'єкт дослідження – процеси обробки цифрових зображень у системах машинного зору за наявності комбінованих перешкод.

Мета роботи – підвищення якості візуальної інформації у системах машинного зору шляхом розробки та дослідження гібридного методу фільтрації, що поєднує частотний аналіз та технології глибокого навчання.

Метод – комбінований підхід, що включає адаптивну режекторну фільтрацію на основі швидкого перетворення Фур'є для усунення періодичних складових та використання згорткової нейронної мережі для придушення випадкового шуму.

Актуальність роботи пов'язана з необхідністю забезпечення надійної роботи систем автоматичної інспекції, робототехніки та відеоспостереження в умовах складних електромагнітних та оптичних завад, де класичні методи фільтрації виявляються малоефективними.

У роботі проведено аналіз природи сигналів та завад у оптико-електронних системах. Розроблено алгоритм виявлення спектральних піків для автоматичного створення масок фільтрації. Спроектовано та навчено нейронну мережу для денойзингу зображень. Виконано програмну реалізацію гібридного конвеєра обробки мовою Python. Експериментально підтверджено перевагу розробленого методу над аналогами за метриками ПВСШ та ІСП.

ABSTRACT

Explanatory note to the qualification work: 57 pages, 13 figures, 2 tables, 3 appendices.

SIGNAL PROCESSING, MACHINE VISION, PERIODIC NOISE, RANDOM NOISE, FOURIER TRANSFORM, NEURAL NETWORKS, CNN, HYBRID FILTERING, PSNR, SSIM.

The object of research is the processes of digital image processing in machine vision systems in the presence of combined interference.

The purpose of the work is to improve the quality of visual information in machine vision systems by developing and researching a hybrid filtering method that combines frequency analysis and deep learning technologies.

The method is a combined approach that includes adaptive notch filtering based on Fast Fourier Transform (FFT) to eliminate periodic components and the use of a convolutional neural network (DnCNN) to suppress random noise.

The relevance of the work is related to the need to ensure reliable operation of automatic inspection systems, robotics, and video surveillance in conditions of complex electromagnetic and optical interference, where classical filtration methods prove to be ineffective.

The paper analyzes the nature of signals and interference in optoelectronic systems. An algorithm for detecting spectral peaks for automatic creation of filtering masks has been developed. A neural network for image denoising was designed and trained. A software implementation of the hybrid processing pipeline in Python was performed. The advantage of the developed method over analogues was experimentally confirmed by PSNR and SSIM metrics.

ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ	8
ВСТУП.....	9
1 АНАЛІТИЧНИЙ ОГЛЯД МЕТОДІВ ОБРОБКИ СИГНАЛІВ У МАШИННОМУ ЗОРІ.....	11
1.1 Вступ. Актуальність та постановка проблеми.....	11
1.2 Загальні характеристики об'єкта дослідження.....	12
1.3 Огляд існуючих підходів до обробки сигналів у системах машинного зору.....	12
1.4 Детальний аналіз сучасних досліджень.....	15
2 МАТЕМАТИЧНІ ОСНОВИ МОДЕЛЮВАННЯ СИГНАЛІВ У МАШИННОМУ ЗОРІ.....	18
2.1 Математичне представлення дискретних зображень.....	18
2.2 Моделювання періодичних сигналів. Періодичні перешкоди в сигналах зображення.....	19
2.3 Моделі випадкового шуму	21
2.4 Двовимірне дискретне перетворення Фур'є	22
2.5 Енергетична спектральна щільність та автокореляція.....	24
2.6 Лінійна фільтрація в просторовій та частотній областях	26
2.7 Статистичні показники якості. Пікове співвідношення сигналу до шуму (СПСШ) та структурна подібність (СП).....	28
2.8 Висновки до розділу 2	30
3 РОЗРОБКА МЕТОДУ ТА АЛГОРИТМІВ КОМБІНОВАНОЇ ОБРОБКИ СИГНАЛІВ	31
3.1 Обґрунтування вибору підходу поєднання частотної фільтрації та глибокого навчання.....	31

3.2 Розробка алгоритму придушення періодичних перешкод методом адаптивної режекторної фільтрації	32
3.3 Розробка архітектури згорткової нейронної мережі для фільтрації випадкового шуму	34
3.4 Алгоритмічна реалізація гібридного конвеєра обробки	36
3.5 Висновки до розділу 3	40
4 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ТА ПРОГРАМНА РЕАЛІЗАЦІЯ СИСТЕМИ	41
4.1 Структурна схема програмного комплексу	41
4.2 Модель генерації синтетичних тестових наборів даних	42
4.3 Обґрунтування вибору програмних засобів	43
4.5 Методика оцінювання якості обробки (PSNR, SSIM)	45
4.6 Висновки до розділу 4	46
5 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ	48
5.1 Експериментальна установка та методика досліджень	48
5.3 Кількісний аналіз результатів	50
5.4 Порівняльний аналіз гібридного методу з класичними підходами ..	50
5.5 Оцінка обчислювальної складності та швидкодії	51
5.6 Висновки до розділу 5	52
ВИСНОВКИ	53
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ	55
ДОДАТОК А	ПОМИЛКА! ЗАКЛАДКУ НЕ ВИЗНАЧЕНО.
ДОДАТОК Б	ПОМИЛКА! ЗАКЛАДКУ НЕ ВИЗНАЧЕНО.
ДОДАТОК В	ПОМИЛКА! ЗАКЛАДКУ НЕ ВИЗНАЧЕНО.

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ,
СКОРОЧЕНЬ І ТЕРМІНІВ

- АЦП – аналого-цифровий перетворювач;
- ДПФ – дискретне перетворення Фур'є;
- ПВСШ – пікове співвідношення сигналу до шуму;
- ПЗ – програмне забезпечення;
- СКП – середньоквадратична похибка (MSE);
- СМЗ – система машинного зору;
- ШПФ – швидке перетворення Фур'є;
- CNN – convolutional neural network (згорткова нейронна мережа, ЗНМ);
- CUDA – compute unified device architecture (архітектура паралельних обчислень);
- DnCNN – denoising convolutional neural network (шумозаглушувальна згорткова нейронна мережа, ШЗЗНМ);
- FPS – frames per second (кадрів на секунду);
- GPU – graphics processing unit (графічний процесор);
- ReLU – rectified linear unit (лінійна функція активації);
- від компанії NVIDIA);
- SSIM – structural similarity index (індекс структурної подібності, ІСП)
- $f(x, y)$ – функція інтенсивності вхідного зображення у просторових координатах x та y ;
- $F(u, v)$ – спектральне представлення зображення у частотних координатах u та v ;
- $H(u, v)$ – передавальна функція фільтра у частотній області;
- $M \cdot N$ – розмірність цифрового зображення (висота \cdot ширина);
- σ – середньоквадратичне відхилення (характеристика потужності шуму);
- μ – математичне сподівання (середнє значення);
- дБ (dB) – децибел (одиниця вимірювання ПВСШ);
- мс – мілісекунда (час обробки кадру).

ВСТУП

У сучасному світі системи машинного зору стали невіддільною складовою технологічного прогресу, забезпечуючи автоматизацію процесів у промисловості, робототехніці, медицині та системах безпеки. Здатність технічних засобів сприймати та аналізувати візуальну інформацію дозволяє вирішувати складні задачі ідентифікації об'єктів, контролю якості продукції та навігації автономних апаратів без участі людини. Однак ефективність таких систем критично залежить від якості вхідного сигналу, що надходить від оптичних сенсорів.

В реальних умовах експлуатації зображення неминуче піддаються впливу різноманітних завад, що мають різну фізичну природу. З одного боку, це стохастичні (випадкові) шуми, обумовлені тепловими процесами в напівпровідникових матрицях, квантовою природою світла та недосконалістю каналів передачі даних. З іншого боку, все частіше зустрічаються детерміновані (періодичні) перешкоди, що виникають внаслідок електромагнітних наведень від промислового обладнання, вібрацій оптичної системи або ефектів накладання растру (муару).

Наявність комбінованих завад суттєво ускладнює роботу алгоритмів розпізнавання образів, призводячи до помилок детекції країв, втрати дрібних текстурних ознак та зниження загальної надійності системи. Традиційні методи фільтрації мають обмежену сферу застосування: просторові фільтри ефективно пригнічують випадковий шум, але розмивають контури об'єктів і не усувають смугові завади, тоді як класичні частотні методи добре справляються з періодичними структурами, але безсилі проти широкосмугового стохастичного шуму.

Останніми роками стрімкий розвиток методів глибокого навчання відкрив нові можливості для обробки сигналів. Згорткові нейронні мережі демонструють видатні результати у задачах відновлення зображень, проте вони потребують

значних обчислювальних ресурсів і можуть бути нестабільними при обробці специфічних періодичних артефактів високої інтенсивності. Тому найбільш перспективним вбачається створення комбінованих підходів, що поєднують строгість математичних перетворень класичної теорії сигналів з адаптивністю сучасного штучного інтелекту.

Враховуючи вищезазначене, дана робота спрямована на розробку та дослідження гібридного методу обробки сигналів у системах машинного зору. У дослідженні пропонується каскадна схема, де на першому етапі застосовується адаптивна режекторна фільтрація у частотній області для усунення глобальних періодичних завад, а на другому – глибока згорткова нейронна мережа для інтелектуального придушення залишкового випадкового шуму. Такий підхід дозволяє компенсувати недоліки окремих методів та забезпечити високу якість підготовки візуальних даних для подальшого аналізу.

Мета роботи – підвищення якості візуальної інформації у системах машинного зору шляхом розробки та дослідження гібридного методу фільтрації, що поєднує частотний аналіз та технології глибокого навчання.

1 АНАЛІТИЧНИЙ ОГЛЯД МЕТОДІВ ОБРОБКИ СИГНАЛІВ У МАШИННОМУ ЗОРІ

1.1 Вступ. Актуальність та постановка проблеми

У сучасному технологічному ландшафті системи машинного зору стали невід'ємною частиною широкого кола галузей, включаючи промислову автоматизацію, медичну діагностику, автономний транспорт та дистанційне зондування. Ефективність цих систем фундаментально залежить від їхньої здатності інтерпретувати візуальну інформацію, отриману датчиками. Однак необроблені дані з цих датчиків не є ідеальним відображенням реальності; це цифровий сигнал, схильний до різноманітних спотворень та недосконалостей.

Цей необроблений сигнал можна концептуально розкласти на два основні компоненти: бажану інформацію, яка часто містить структуровані, періодичні або квазіперіодичні візерунки (наприклад, текстури, регулярні сітки, структуроване світло), та небажані випадкові сигнали, які зазвичай називають шумом (наприклад, тепловий шум, шум фотонного пострілу, перешкоди навколишнього середовища). Центральна проблема полягає в тому, що ці два типи сигналів незмінно взаємопов'язані. Наявність випадкового шуму може затьмарювати критичні деталі, що призводить до помилок у вимірюванні, класифікації або навігації. І навпаки, сильні періодичні візерунки, такі як ефект муару з екранних дисплеїв, можуть бути неправильно інтерпретовані як особливості або заважати аналізу об'єкта, що лежить в основі [2, 3, 16].

Таким чином, розробка та дослідження надійних методів, здатних ефективно розділяти, придушувати або аналізувати ці періодичні та випадкові компоненти сигналу, є критичною необхідністю для підвищення надійності та точності сучасного машинного зору. Актуальність цієї теми постійно зростає, оскільки системи зору розгортаються у все більш складних та неконтрольованих середовищах, де якість сигналу не може бути гарантована.

1.2 Загальні характеристики об'єкта дослідження

Об'єктом цього дослідження є алгоритми та математичні методи обробки двовимірних цифрових сигналів (зображень), отриманих системами машинного зору. Це охоплює моделі сигналів, методи обробки та цілі застосування.

Математичні представлення періодичних сигналів (наприклад, за допомогою рядів Фур'є, вейвлетів) та випадкових сигналів (наприклад, за допомогою розподілів ймовірностей, таких як гаусівський або пуассонівський).

Спектр методів, починаючи від класичної фільтрації в частотній області та статистичної оцінки до сучасних підходів, заснованих на даних, на машинному навчанні.

Бажані результати обробки, які включають придушення шуму (шумоподавлення), аналіз текстур, вилучення ознак та відновлення сигналу.

Дослідження зосереджено на теоретичній розробці, практичному впровадженні та порівняльному аналізі цих методів для визначення їхньої ефективності у підвищенні якості візуальної інформації для подальших завдань високого рівня [4, 5].

1.3 Огляд існуючих підходів до обробки сигналів у системах машинного зору

Історично обробка сигналів у зображеннях значною мірою спиралася на методи, адаптовані з теорії одновимірної обробки сигналів. Для періодичних сигналів перетворення Фур'є було основним методом, оскільки воно перетворює зображення з просторової області в частотну область, дозволяючи ідентифікувати глобальні періодичні компоненти як окремі спектральні піки. Цей метод розкладає зображення на суми синусоїдальних та косинусоїдальних функцій на різних частотах. Його основні переваги полягають у математичній надійності та обчислювальній ефективності, особливо при реалізації за

допомогою швидкого перетворення Фур'є. Однак перетворення Фур'є має фундаментальне обмеження: воно втрачає всю просторову інформацію, визначаючи, які частоти присутні, але не вказує, де ці частоти зустрічаються на зображенні. Отже, воно не може ефективно аналізувати локалізовані текстури або візерунки. При роботі з випадковими сигналами, такими як шум, традиційні підходи використовували фільтрацію просторової області за допомогою лінійних згорткових ядер, включаючи фільтри середнього значення та гаусівські фільтри. Ці фільтри працюють, замінюючи кожен піксель середнім або зваженим середнім значенням сусідніх пікселів для зменшення шуму, який вважається високочастотним та некорельованим. Вони прості в реалізації та обчислювально швидкі, але не є вибірковими. Вони спотворюють зображення, розмиваючи не лише шум, але й важливі деталі, такі як краї, кути та дрібні текстури, що призводить до значної втрати інформації [7,10].

Рисунок 1.1 демонструє, як перетворення Фур'є розділяє частотні компоненти; як шум та періодичні коливання порівняно з сигналом виглядають у спектрі; зворотні перетворення, які показують що відбувається, коли ви пригнічуєте певні смуги [24].




Рисунок 1.1 – Кілька зображень, що порівнюють зашумлені зображення, їх перетворення Фур'є та відфільтровані версії (придушення низьких та високих частот)

Рисунок 1.2 візуалізує переваги/недоліки вейвлет аналізу. Вейвлети зберігають більше структури яку Фур'є-фільтрація згладжує або, можливо, втрачає локалізацію [12].

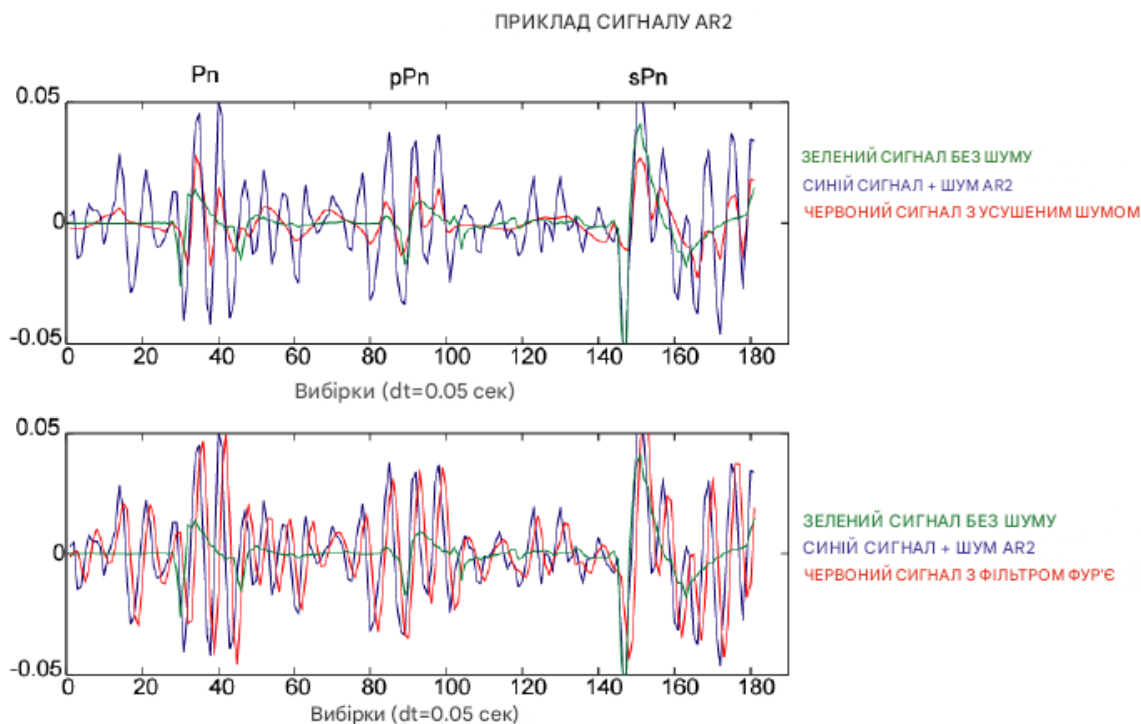


Рисунок 1.2 – Порівняння вейвлет-шумопридушення та Фур'є-фільтрації на синтетичних сигналах, що показує вхідний, вихідний та безшумовий базовий рівень

Визначаючи недоліки цих традиційних методів, зокрема втрату просторової локалізації в частотному аналізі та розмиття ознак під час шумопридушення, дослідники шукали більш просунуті рішення, що враховують структуру. Щоб задовольнити потребу в одночасному просторовому та частотному аналізі, були розроблені та широко впроваджені вейвлет-перетворення та фільтри Габора.

Ці методи дозволяють проводити багатомасштабний аналіз у різних орієнтаціях, тим самим забезпечуючи локалізовані частотні описи та відповідаючи на питання про те, який частотний вміст існує в певних областях зображення, що свідчить про значний прогрес в аналізі текстур та сегментації. З

іншого боку, щоб пом'якшити вплив розмиття лінійних фільтрів на випадкові сигнали, з'явилися нелінійні та адаптивні методи. Медіанний фільтр був першим удосконаленням у збереженні країв при видаленні шуму. Більш значним удосконаленням став алгоритм нелокальних середніх, який виходить за межі безпосередніх сусідів, використовуючи властиву надмірність зображень, усереднюючи пікселі зі структурно подібних ділянок, знайдених будь-де на зображенні. Цей підхід краще зберігає деталі, об'єднуючи інформацію з подібних областей незалежно від просторової близькості.

Незважаючи на їхні досягнення, ці так звані класичні методи мають свої обмеження. Успіх методів на основі вейвлетів та Габора значною мірою залежить від ретельно підібраних базисних функцій або параметрів фільтрів, які часто вимагають ручного налаштування для конкретного застосування. Хоча алгоритми, такі як нелокальні середні та його вдосконалений наступник збіг блоків та 3д моделювання (алгоритм шумоподавлення зображень Block-matching and 3D filtering), є високоефективними, але вони є обчислювально дорогими. Крім того, їхня продуктивність знижується при обробці унікальних, неповторюваних структур, які можна сплутати з шумом, або в ситуаціях з дуже високим рівнем шуму, коли пошук подібних ділянок стає ненадійним.

1.4 Детальний аналіз сучасних досліджень

Обмеження, властиві неавтоматизованим фільтрам та класичним моделям, проклали шлях для розвитку методів глибокого навчання на основі даних, зокрема тих, що базуються на згорткових нейронних мережах (ЗНМ), які вивчають оптимальні фільтри безпосередньо з даних, а не покладаються на заздалегідь визначені бази. Наприклад, у сфері видалення випадкових сигналів, фундаментальне дослідження К. Чжана та ін. представило архітектуру DnCNN, яка уникає прямого відображення шумних зображень на чисті виходи, а натомість навчає мережу прогнозувати компонент залишкового шуму. Ця парадигма залишкового навчання покращує стабільність та ефективність

навчання, дозволяючи явно моделювати шум та віднімати його від вхідного зображення.

Візуалізація за допомогою методу глибокого навчання/шумопридушення зображень на основі ЗНМ (а саме FEUSNet), що показує зображення до/після та, можливо, збережений частотний спектр/просторові деталі.

Рисунок 1.3 показує, як сучасні мережі поєднують просторові та частотні апріорні значення; ілюструє результат у порівнянні з класичними фільтрами [19].




Рисунок 1.3 – Візуалізація за допомогою методу глибокого навчання / шумозаглушення зображень на основі CNN (FEUSNet), що показує зображення до/після та, можливо, зі збереженим частотним спектром / просторовими деталями

Архітектура згорткової нейронної мережі (DnCNN) включає шари згортки, за якими слідує пакетна нормалізація та активація ReLU, а завдяки навчанню на величезних наборах даних пар шумних та чистих зображень ці моделі перевершують класичні підходи, такі як BM3D. Вони чудово розрізняють дрібну текстуру від шуму та краще зберігають різкість зображення під час шумозаглушення. Окрім шумопридушення, ЗНМ також неявно навчаються обробляти періодичний аналіз сигналів.

1.5 Висновки до розділу 1

Дослідження, подібні до тих, що провели М. Цайлер та Д. Фергус, показали, що згорткові нейронні мережі (ЗНМ, CNN), навчені для виконання завдань високого рівня, таких як розпізнавання об'єктів, природним чином

набувають фільтрів на своїх ранніх шарах, що нагадують класичні фільтри Габоора та детектори кольорових плям. Завдяки оптимізації для класифікації ці мережі виявляють, що виявлення орієнтованих ребер та частотних шаблонів служить фундаментальним кроком для побудови ієрархічних представлень об'єктів. Це відкриття підкреслює, що глибоке навчання не відкидає класичні принципи обробки сигналів, а натомість вивчає їх оптимізовані для конкретних завдань версії. Як результат, вилучення ознак на основі даних за допомогою ЗНМ виявляється набагато більш адаптивним, надійним та ефективним, ніж покладання на статичні, попередньо визначені набори фільтрів [1, 17, 18].

2 МАТЕМАТИЧНІ ОСНОВИ МОДЕЛЮВАННЯ СИГНАЛІВ У МАШИННОМУ ЗОРІ

2.1 Математичне представлення дискретних зображень

Системи машинного зору працюють на основі сигналів, отриманих від оптичних датчиків, зазвичай у вигляді двовимірних розподілів інтенсивності, зображень, або послідовностей зображень, в тому числі і відео. Ці сигнали неминуче спотворюються різними формами шуму та перешкод. У багатьох практичних застосуваннях перешкоди можна розділити на випадкові (стохастичні) компоненти та періодичні (структуровані) компоненти. Ефективна обробка вимагає розуміння математичних моделей, що регулюють формування сигналів, спектральних властивостей періодичних візерунків та статистичних властивостей випадкового шуму. У цьому розділі представлено основні теоретичні засади, позначення та рівняння, що використовуються в подальшій розробці та аналізі методів обробки.

Цифрове зображення у градаціях сірого представлено як дискретну двовимірну функцію [14]:

$$f[m, n]: \{0, \dots, M - 1\} \cdot \{0, \dots, N - 1\} \rightarrow \mathbb{R} \quad (2.1)$$

де m – рядок (вертикальний індекс);

n – стовпець (горизонтальний індекс);

$M \cdot N$ – роздільна здатність зображення.

Кожен елемент $f[m, n]$ відповідає пікселю в просторових координатах (m, n) , а його значення вказує на інтенсивність світла, отриману датчиком у цьому місці.

У зображеннях у градаціях сірого ці значення зазвичай коливаються від 0 (чорний) до 255 (білий) у 8-бітному представленні або від 0 до 1 при нормалізації.

У багатьох системах візуалізації спостережуване зображення $y[m, n]$ моделюється як:

$$y[m, n] = s[m, n] + p[m, n] + n[m, n] \quad (2.2)$$

де $s[m, n]$ – чисте зображення (сигнал що нас цікавить);

$p[m, n]$ – періодична структурна інтерференція;

$n[m, n]$ – випадковий шум.

Це розкладання є основою для всіх подальших методів обробки.

2.2 Моделювання періодичних сигналів. Періодичні перешкоди в сигналах зображення

Періодичні спотворення часто трапляються в реальних системах візуалізації та можуть виникати через різні фактори, такі як електричні перешкоди (наприклад, 50/60 Гц від ліній електропередач), механічна вібрація кріплень камери, невідповідності системи сканування, подібні до тих, що зустрічаються в лінійних сканерах, періодичні помилки зчитування датчиків та мерехтіння освітлення або гармонійна модуляція світла. На відміну від випадкового шуму, періодична перешкода має структуровану природу, оскільки вона передбачувано повторюється по всьому зображенню. Типовою 2D-моделлю періодичних перешкод є синусоїдальна складова [13]:

$$p[m, n] = A \sin(2\pi(f_x m + f_y n) + \varphi), \quad (2.3)$$

де A – амплітуда;

f_x, f_y – просторові частоти;

φ – фазовий зсув.

Більш складні структури можна синтезувати як суми гармонік:

$$p[m, n] = \sum_{k=1}^K A_k \sin (2\pi(f_{x,k}m + f_{y,k}n) + \varphi_k) . \quad (2.4)$$

Ці періодичні компоненти створюють різкі піки в частотному спектрі зображення, що дозволяє виявляти та видаляти їх за допомогою фільтрації в частотній області.

Загальною моделлю періодичної інтерференції є двовимірна синусоїда:

$$p[m, n] = A \sin (2\pi(f_x m + f_y n) + \varphi) , \quad (2.5)$$

де A – амплітуда;

f_x, f_y – просторові частотні складові;

φ – фазовий зсув.


Цей тип інтерференції візуально проявляється у вигляді смуг, брижів або сітчастих спотворень.

Реальні системи можуть створювати не лише одну синусоїду, а й кілька гармонік через нелінійні ефекти:

$$p[m, n] = \sum_{k=1}^K A_k \sin (2\pi(f_{x,k}m + f_{y,k}n) + \varphi_k) . \quad (2.6)$$

Гармоніки вищого порядку часто з'являються, коли джерело періодичного шуму несинусоїдальне, наприклад, мерехтіння освітлення прямокутної форми або механічні коливання зі складними формами хвиль [6, 25].

Залежно від частот (f_x, f_y), періодичний шум може проявлятися як вертикальні або горизонтальні смуги, діагональні візерунки, муароподібні хвилі або штриховані інтерференційні сітки.



а – типова поява періодичного смугового шуму в зображенні типу макрозйомка; б – рентгенівські знімки

Рисунок 2.1 – Приклади періодичного смугового шуму у різних типах зображень [22, 25]

Ці закономірності дуже порушують роботу алгоритмів машинного зору, часто призводячи до неправильних класифікацій, нестабільних вимірювань або збільшення кількості хибнопозитивних виявлень.

2.3 Моделі випадкового шуму

Випадковий шум виникає внаслідок стохастичних процесів, що за своєю суттю є причиною. У системах візуалізації це включає електронний тепловий шум, дробовий шум, спричинений квантовою природою світла, та шум квантування, що вноситься АЦП-перетворювачами. На відміну від періодичного шуму, випадковий шум не демонструє далекосяжної когерентності чи структури; натомість він проявляється як хаотичний розподіл флуктуацій.

Хоча випадковий шум часто розглядається як просторово незалежний, реальні системи можуть демонструвати кореляції через архітектуру датчика, етапи зчитування сигналу або схеми постобробки. Деякі камери, наприклад,

створюють випадкові шумові шаблони з незначними спрямованими перевагами або локалізованими кореляціями між сусідніми пікселями.

Випадковий шум виникає внаслідок стохастичних процесів, які неможливо легко передбачити. Його присутність неминуча в системах цифрової візуалізації, головним чином через фізичні обмеження датчиків [8].

Багато електронних процесів природним чином призводять до шуму, змодельованого як гауссова випадкова величина:

$$n_G[m, n] \sim \mathcal{N}(0, \sigma^2). \quad (2.7)$$

Гаусові моделі шуму включають теплове хвилювання в електроніці датчиків, шум підсилювача та невизначеність квантування, у деяких наближеннях. Він просторово некорельований, «білий шум», тобто шум кожного пікселя незалежний від інших.

Цей шум залежить від інтенсивності та домінує на зображеннях в умовах низької освітленості, таких як астрономія чи мікроскопія.

У застосуваннях машинного зору, таких як перевірка дефектів або медична візуалізація, випадковий шум може затьмарювати дрібні деталі текстури або спричиняти хибні виявлення. Тому методи шумозаглушення повинні знаходити баланс між видаленням небажаної випадковості та збереженням важливих структурних особливостей зображення [11].

2.4 Двовимірне дискретне перетворення Фур'є

Частотне представлення є важливим інструментом для аналізу сигналів. Воно показує розподіл енергії по різних просторових частотах і дає уявлення про природу спотворень, що впливають на зображення. Періодичний шум зазвичай концентрує енергію у вузьких піках або кластерах, тоді як випадковий шум широко та рівномірно розподіляє свою енергію по всьому спектру.

Крім того, частотний аналіз пропонує спосіб роз'єднання фундаментальних компонентів зображення. Повільно змінювані зміни освітлення відповідають низьким частотам, краї відповідають середнім частотам, а дрібні текстури відповідають вищим частотам. Шум взаємодіє з цими компонентами по-різному, що робить частотну фільтрацію потужним підходом для вибіркового відновлення.

Пряме ДПФ [21]:

$$F(k, \ell) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} f[m, n] e^{-j2\pi(\frac{km}{M} + \frac{\ell n}{N})} \quad (2.8)$$

Періодичні структури $p[m, n]$ створюють пари яскравих симетричних піків у $|F(k, \ell)|$

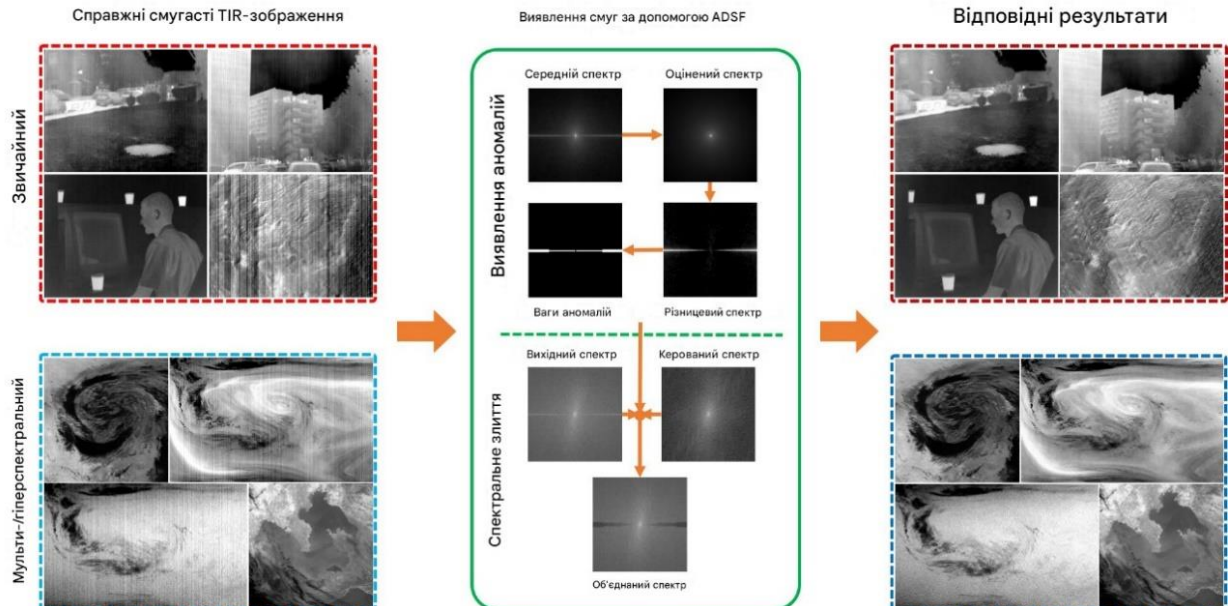


Рисунок 2.2 – Перетворення Фур'є зображення з періодичним смуговим шумом

Двовимірне дискретне перетворення Фур'є є основним інструментом для аналізу періодичних структур у даних зображень.

Розуміння поведінки різних типів шуму в частотній області має вирішальне значення для розробки ефективних фільтрів, які уникають пошкодження важливих структурних деталей, одночасно пригнічуючи небажані спотворення.

2.5 Енергетична спектральна щільність та автокореляція

Для аналізу випадкових сигналів у системах машинного зору, таких як тепловий шум матриці або зернистість, недостатньо розглядати лише амплітудні значення пікселів. Необхідно враховувати їх статистичні взаємозв'язки у просторі. Фундаментальним інструментом для опису розподілу потужності сигналу за частотами є енергетична спектральна щільність (ЕСЩ). Згідно з теоремою Вінера-Хінчина, для стаціонарних випадкових процесів ЕСЩ є перетворенням Фур'є від автокореляційної функції

Спектральна щільність потужності виявляє домінуючі періодичні частоти та розподіл енергії.

Двовимірною автокореляційною функцією:

$$R_f[\Delta m, \Delta n] = \mathbb{E}\{f[m, n]f[m + \Delta m, n + \Delta n]\} \quad (2.9)$$

Періодограмна оцінка спектральної густини потужності (PSD):

$$P_f(k, \ell) = \frac{1}{MN} |F(k, \ell)|^2. \quad (2.10)$$

Статистичні характеристики оптичних сигналів та їх вплив на ефективність систем машинного зору детально розглянуто у роботах [7], [8]. Автори зазначають, що аналіз автокореляційної функції дозволяє оцінити радіус кореляції перешкод, що є критично важливим для вибору параметрів згладжуючих фільтрів. Якщо радіус кореляції шуму співмірний з розміром

дрібних деталей об'єкта, проста просторова фільтрація може призвести до втрати інформативності зображення.

Циклостаціонарний аналіз покращує виявлення періодичних сигналів, які є занадто слабкими для спостереження за допомогою стандартних спектральних методів. Він особливо цінний у ситуаціях, коли періодичний шум вбудований у сильний випадковий шум або коли компоненти перешкод повільно змінюються з часом.

Концепції циклічної частоти, циклічної кореляції та спектральної кореляційної функції надають потужні інструменти для виявлення прихованої періодичності. Хоча ці ідеї походять з теорії зв'язку, вони стають дедалі актуальнішими в системах машинного зору, що використовуються в промислових, медичних або дистанційних зондуваннях.

Деякі сигнали демонструють періодичні зміни своїх статистичних властивостей (наприклад, періодичне освітлення або мерехтіння зміщення датчика). Такі сигнали є циклостаціонарними.

Циклічна автокореляція:

$$R_x^\alpha(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t + \frac{\tau}{2}) x^*(t - \frac{\tau}{2}) e^{-j2\pi\alpha t} dt \quad (2.11)$$

де α – параметр частоти циклу.

Ненульова циклічна автокореляція вказує на періодичну структуру навіть за умови наявності шуму.

Модель циклостаціонарного сигналу дозволяє виявляти приховані періодичності, які не видно у звичайному енергетичному спектрі. Це особливо актуально для задач детекції періодичних імпульсів та діагностики обладнання, що описано у сучасних дослідженнях, зокрема у роботі [6].

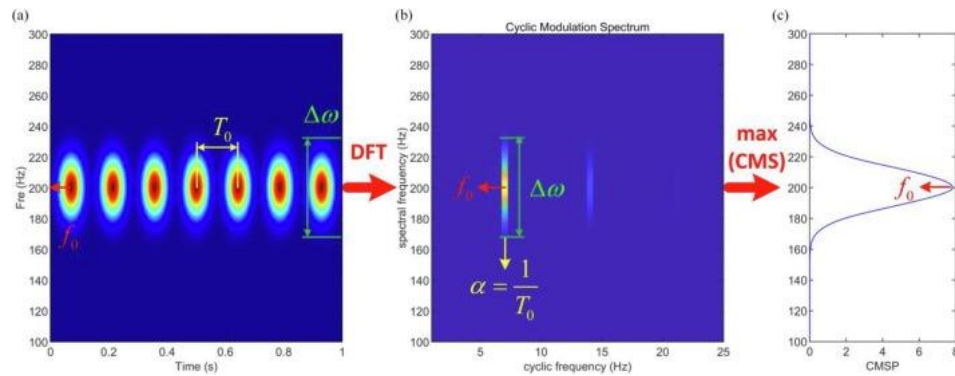


Рисунок 2.3 – Приклад циклічного спектру з піками на частотах модуляції [6]

2.6 Лінійна фільтрація в просторовій та частотній областях

Обробка сигналів у системах технічного зору традиційно поділяється на просторові та частотні методи. Теоретичним підґрунтям лінійної фільтрації є теорема про згортку: згортка двох функцій у просторовій області еквівалентна множенню їхніх образів у частотній області [14].

Просторово-доменні фільтри безпосередньо впливають на інтенсивність пікселів. Вони включають фільтри згладжування, фільтри зі збереженням країв та адаптивні підходи на основі вікон. Ці фільтри, як правило, легко реалізувати, але їх слід ретельно вибирати, щоб уникнути розмиття дрібних деталей або появи артефактів.

Згортка в просторовій області виконається наступним чином:

$$g[m, n] = (h \cdot f)[m, n] = \sum_u \sum_v h[u, v] f[m - u, n - v] \quad (2.12)$$

Це основа низькочастотної, високочастотної, смугової та режекторної фільтрації.

$$G(k, \ell) = H(k, \ell) \cdot F(k, \ell) \quad (2.13)$$

Просторово-доменна фільтрація добре підходить для видалення високочастотного випадкового шуму або для покращення певних особливостей зображення. Однак просторові фільтри зазвичай менш ефективні для видалення періодичного шуму, оскільки періодичні спотворення можуть мати складні просторові структури, що охоплюють усе зображення.

Тим не менш, просторові фільтри залишаються важливим компонентом у конвеєрах попередньої обробки, особливо при поєднанні кількох стратегій фільтрації.

Фільтри трансформаційної області, такі як шумозаглушення на основі вейвлетів або фільтри частотної області, працюють на представленнях, які розділяють зображення на частотні піддіапазони або базисні компоненти. Ці фільтри дозволяють вибірково послаблювати небажані компоненти, зберігаючи при цьому такі структури, як краї та текстури.

Для моделі спостереження:

$$y = x + n \quad (2.14)$$

Фільтр Вінера мінімізує середньоквадратичну похибку:

$$G(k, \ell) = \frac{S_x(k, \ell)}{S_x(k, \ell) + S_n(k, \ell)} \quad (2.15)$$

де S_x та S_n енергетична спектральна щільність чистого сигналу та шуму.

Важливо, оскільки воно забезпечує найкращу лінійну оцінку за припущень стаціонарності.

Адаптивні методи фільтрації коригують свою поведінку на основі локальних характеристик зображення. Це включає статистичні фільтри оцінки, які обчислюють локальну дисперсію, пороги перетворення або оптимальні параметри оцінювача. Адаптивні методи часто перевершують статичні фільтри

в гетерогенних середовищах, оскільки вони враховують локальну складність зображення.

Підходи трансформаційної області також дозволяють розкладання з кількома роздільними здатностями, надаючи можливість зосередитися на дрібних деталях або великомасштабній структурі залежно від потреб конкретного завдання машинного зору.

Метод фазової кореляції базується на властивості перетворення Фур'є, згідно з якою зсув зображення у просторі призводить до зміни фази у частотній області. Це потужний інструмент для реєстрації зображень та вирівнювання періодичних патернів [16].

Якщо два сигнали f_1 та f_2 відрізняються лише зсувом $(\Delta x, \Delta y)$, їх взаємний спектр потужності, нормалізований за амплітудою, визначається як:

$$R(k, \ell) = \frac{F_1(k, \ell) F_2^*(k, \ell)}{F_1^*(k, \ell) F_2(k, \ell)} \quad (2.16)$$

Обернене перетворення Фур'є від цієї функції дає дельта-функцію Дірака, положення якої вказує на величину зсуву. У контексті обробки періодичних завад цей метод дозволяє точно визначити фазу та частоту накладеної перешкоди для її подальшої компенсації, що узгоджується з фундаментальними принципами цифрової обробки сигналів. Важливо для вирівнювання періодичних шаблонів або корекції дрейфу перед фільтрацією.

2.7 Статистичні показники якості. Пікове співвідношення сигналу до шуму (СПСШ) та структурна подібність (СП)

Об'єктивні показники, такі як СПСШ та СП, широко використовуються для кількісної оцінки якості відновлення. Однак числові вимірювання не завжди відображають уподобання людини щодо сприйняття. Наприклад, дуже гладке зображення з втраченими деталями може досягти високого СПСШ, але

виглядати гірше. Аналогічно, невеликі періодичні артефакти можуть бути візуально спотворюючими, навіть якщо вони мають незначний вплив на показник СП.

Середньоквадратична похибка:

$$\text{СКП} = \frac{1}{MN} \sum_{m,n} (f[m,n] - \hat{f}[m,n])^2 \quad (2.17)$$

Співвідношення пікового сигналу до шуму є найбільш поширеною метрикою, що базується на середньоквадратичній похибці (MSE). Воно визначається формулою (дБ):

$$\text{СПСШ} = 10 \log_{10} \left(\frac{L^2}{\text{MSE}} \right) \quad (2.18)$$

де $L = 1$ (нормалізовані зображення).

Цей показник широко використовується у класичній теорії обробки сигналів [17], [18]. Однак СПСШ не завжди корелює з візуальним сприйняттям якості людиною, оскільки не враховує структурні зміни зображення.

Індекс структурної подібності (ІСП) було розроблено для подолання недоліків ПКСШ. ІСП оцінює деградацію зображення як зміну сприйняття структурної інформації, враховуючи три компоненти: яскравість, контрастність та структуру. Формула розрахунку ІСП:

$$\text{ІСП}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (2.19)$$

Кількісно визначає структурну подібність і широко використовується в оцінці систем зору. Даний метод оцінки був запропонований Wang et al. і став стандартом у сучасних системах комп'ютерного зору [23]. Використання SSIM є критично важливим при дослідженні методів боротьби зі структурованими

періодичними завадами, оскільки вони найбільше впливають саме на структурну цілісність зображення.

2.8 Висновки до розділу 2

Теоретичні основи, представлені в цьому розділі, формують концептуальну основу для розробки та аналізу методів придушення шуму в системах машинного зору. Розуміння різних моделей поведінки періодичних та випадкових збурень, а також їх представлення в просторовій, частотній та трансформаційній областях, дозволяє розробляти ефективні конвеєри відновлення.

Наступний розділ спирається на ці фундаментальні концепції, розробляючи конкретні алгоритми обробки, інтегруючи як класичні, так і сучасні підходи, та пояснюючи, як ці методи структуровані та реалізовані для вирішення проблем, що виникають у середовищах зі змішаним шумом.

3 РОЗРОБКА МЕТОДУ ТА АЛГОРИТМІВ КОМБІНОВАНОЇ ОБРОБКИ СИГНАЛІВ

3.1 Обґрунтування вибору підходу поєднання частотної фільтрації та глибокого навчання

У сучасних системах машинного зору якість вхідного сигналу є критичним фактором, що визначає ефективність подальших етапів: сегментації, детекції об'єктів та класифікації. Аналіз, проведений у першому та другому розділах, дозволив виділити два основні класи завад, що найчастіше зустрічаються на практиці. До першого належать випадкові (стохастичні) шуми, тобто гауссівський шум, шум сенсора, тепловий шум. Їх характеризує рівномірний розподіл енергії по всьому частотному спектру зображення. Другий клас становлять періодичні (структуровані) завади, зокрема електромагнітні наведення, муар, накладання растру, смуги від вібрації обладнання. У частотній області вони проявляються як яскраво виражені локальні піки.

Існуючі класичні методи фільтрації мають суттєві обмеження при роботі зі змішаним типом завад. Просторові фільтри (наприклад, медіанний або фільтр Гауса) ефективно згладжують високочастотний шум, але не здатні видалити низькочастотні періодичні смуги без значного розмиття контурів об'єктів. З іншого боку, частотна фільтрація на основі перетворення Фур'є ідеально підходить для видалення періодичних патернів, але погано справляється зі стохастичним шумом, оскільки його спектр перекривається зі спектром корисного сигналу.

Враховуючи вищезазначене, у даній роботі пропонується каскадний підхід, що послідовно розділяє задачі. Спершу в частотній області застосовується адаптивний режекторний фільтр (notch filter) для точкового видалення глобальних періодичних складових. Далі у просторовій області використовується глибока згорткова нейронна мережа (ЗНМ) для усунення

залишкового випадкового шуму та відновлення артефактів, зокрема пов'язаних з ефектом Гіббса, які могли виникнути після першого кроку. Такий поділ дає змогу кожному методу працювати в умовах, для яких він є математично оптимальним, і забезпечує високу якість відновлення зображення [19].

3.2 Розробка алгоритму придушення періодичних перешкод методом адаптивної режекторної фільтрації

Для реалізації першого етапу обробки обрано метод спектрального аналізу. Зображення розглядається як двовимірний дискретний сигнал $f(x,y)$ розміром $M \cdot N$. На рисунку 3.1 зображено принцип формування режекторної маски у частотній області [19].




Рисунок 3.1 – Алгоритм формування режекторної маски

Алгоритм адаптивної фільтрації починається з перетворення вхідного зображення у частотну область за допомогою швидкого перетворення Фур'є, в результаті чого отримують спектр $F(u,v)$, де u і v – частотні змінні:

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi(\frac{ux}{M} + \frac{vy}{N})} \quad (3.1)$$

Для зручності аналізу та візуалізації застосовується зсув спектра (*fftshift*), який переносить нульову частоту (DC-компоненту), що відповідає середній яскравості зображення, у центр спектрограми. Періодичні завади проявляються у вигляді пари симетричних яскравих піків на амплітудному спектрі $|F(u, v)|$; для їх автоматичного виявлення використовується порогова обробка з адаптивним порогом T , визначеним відносно максимальної енергії спектру

$$T = \alpha \cdot \max(|F(u, v)|) \quad (3.2)$$

де α – коефіцієнт чутливості що добирають емпірично у межах 0,2–0,3.

На основі виявлених піків формується бінарна режекторна маска $H(u, v)$, яка пригнічує ці компоненти та зберігає недоторканою центральну низькочастотну область, що містить основну інформацію про форму об'єктів; правило побудови маски забезпечує вибіркове заглушення небажаних частот. Умова формування маски:

$$H(u, v) = \begin{cases} 0, & \text{якщо } |F(u, v)| > T \text{ та } (u, v) \neq (u_c, v_c) \\ 1, & \text{в іншому випадку} \end{cases} \quad (3.3)$$

Відфільтрований спектр $G(u, v)$ отримують поелементним множенням $F(u, v)$ на $H(u, v)$. Математично операція фільтрації описується виразом:

$$G(u, v) = F(u, v) \cdot H(u, v). \quad (3.4)$$

Після чого зображення $\hat{f}(x, y)$ відновлюють за допомогою зворотного перетворення Фур'є (IFFT), беручи дійсну частину результату.

3.3 Розробка архітектури згорткової нейронної мережі для фільтрації випадкового шуму

Для другого етапу обробки, метою якого є придушення адитивного випадкового шуму, розроблено архітектуру нейронної мережі, що базується на принципах згорткових нейронних мереж. Ключовою особливістю обраної архітектури є використання стратегії залишкового навчання. Замість того, щоб вчити мережу прогнозувати чисте зображення \hat{x} безпосередньо з зашумленого y , мережа навчається прогнозувати сам шум $R(y)$.

Тоді чисте зображення отримується як:

$$\hat{x} = y - R(y). \quad (3.5)$$

Архітектура мережі складається з трьох послідовних частин: вхідного шару, групи прихованих шарів і вихідного шару. Усі вони побудовані на операціях згортки й нелінійних активаціях, що дає змогу автоматично виділяти та перетворювати ознаки зображення.

На вхідному шарі виконується операція згортки (convolution). Згортка – це лінійна операція, під час якої невелике ядро або фільтр розміром $3 \cdot 3$ ковзає по зображенню та для кожного його фрагмента обчислює зважену суму пікселів. Результатом є карти ознак (англ. feature maps – карти ознак), які відображають, де на зображенні присутні певні локальні структури. На вході використовується 64 фільтри, тому формується 64 карти ознак. Після згортки застосовується нелінійна активація випрямлена лінійна функція активації (ВЛФА, Rectified Linear Unit, ReLU). ВЛФА замінює всі від'ємні значення на нуль і залишає додатні без змін; завдяки цьому мережа стає здатною моделювати нелінійні залежності, навчання прискорюється, а градієнти рідше «зникають». Головна мета вхідного шару – виділити низькорівневі ознаки, такі як краї, кути та прості текстури, що є базовою основою для подальшої обробки [9].

Далі розташована послідовність прихованих шарів. У базовій конфігурації їх шість, але глибина мережі може змінюватися залежно від задачі й обчислювальних обмежень. Кожен прихований блок має типову структуру: згортка з ядрами 3·3, що створює 64 карти ознак, далі пакетна нормалізація та активація ВЛФА. Пакетна нормалізація вирівнює розподіл активацій усередині мініпакета, підтримуючи стабільні середні значення та дисперсію; водночас вона має навчані параметри масштабування й зсуву. Така нормалізація зменшує внутрішній зсув ознак, стабілізує градієнти, знижує ризик проблеми зникаючого градієнта (коли під час поширення помилки назад градієнти прямують до нуля) і прискорює збіжність під час навчання. Сукупність таких блоків дає змогу моделювати дедалі складніші, багаторівневі представлення ознак.

Вихідний шар – це ще одна згортка, але з одним фільтром, якщо метою є відновлення одноканального зображення у відтінках сірого (одноканальне зображення у відтінках сірого). Призначення вихідного шару – реконструкція карти шуму, тобто зображення, кожен піксель якого оцінює внесок шуму у відповідному пікселі вхідного зображення. Під реконструкцією тут мається на увазі відновлення шуканого сигналу зі стисненого або перетвореного представлення ознак, яке сформувала мережа на попередніх шарах.

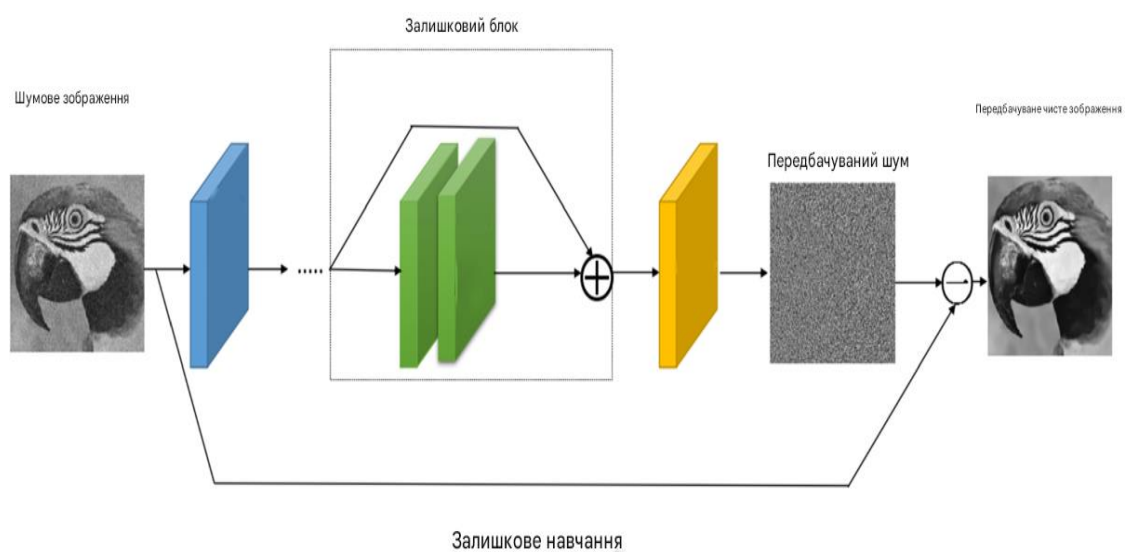


Рисунок 3.2 – Архітектура згорткової нейронної мережі [15]

Підсумовуючи, вхідний шар виділяє базові локальні структури за допомогою згортки 3·3 і нелінійності ВЛФА (ReLU), приховані шари поглиблюють представлення через послідовності «згортка – пакетна нормалізація – ReLU», стабілізуючи й прискорюючи навчання, а вихідний шар перетворює отримані ознаки на цільову карту шуму. На рисунку 3.2 зображена архітектура згорткової нейронної мережі. Таке поєднання типових компонентів згорткових мереж забезпечує ефективне навчання на зображеннях і точну побудову вихідного результату [15].

Для навчання мережі використовується середньоквадратична похибка (СКП, MSE), яка мінімізує різницю між спрогнозованим шумом та реальним шумом, доданим під час генерації навчальної вибірки:

$$L(\Theta) = \frac{1}{2N} \sum_{i=1}^N \|y_i; \Theta - (y_i - x_i)\|^2 \quad (3.6)$$

де Θ – параметри мережі, що навчається.

3.4 Алгоритмічна реалізація гібридного конвеєра обробки

Реалізація комбінованого методу вимагає створення єдиного програмного середовища, що забезпечує узгоджену взаємодію між алгоритмами цифрової обробки сигналів та модулями глибокого навчання. Оскільки методи працюють у різних математичних просторах (частотному та просторовому) і вимагають різних форматів представлення даних, розроблено алгоритмічний конвеєр, який складається з п'яти послідовних етапів.

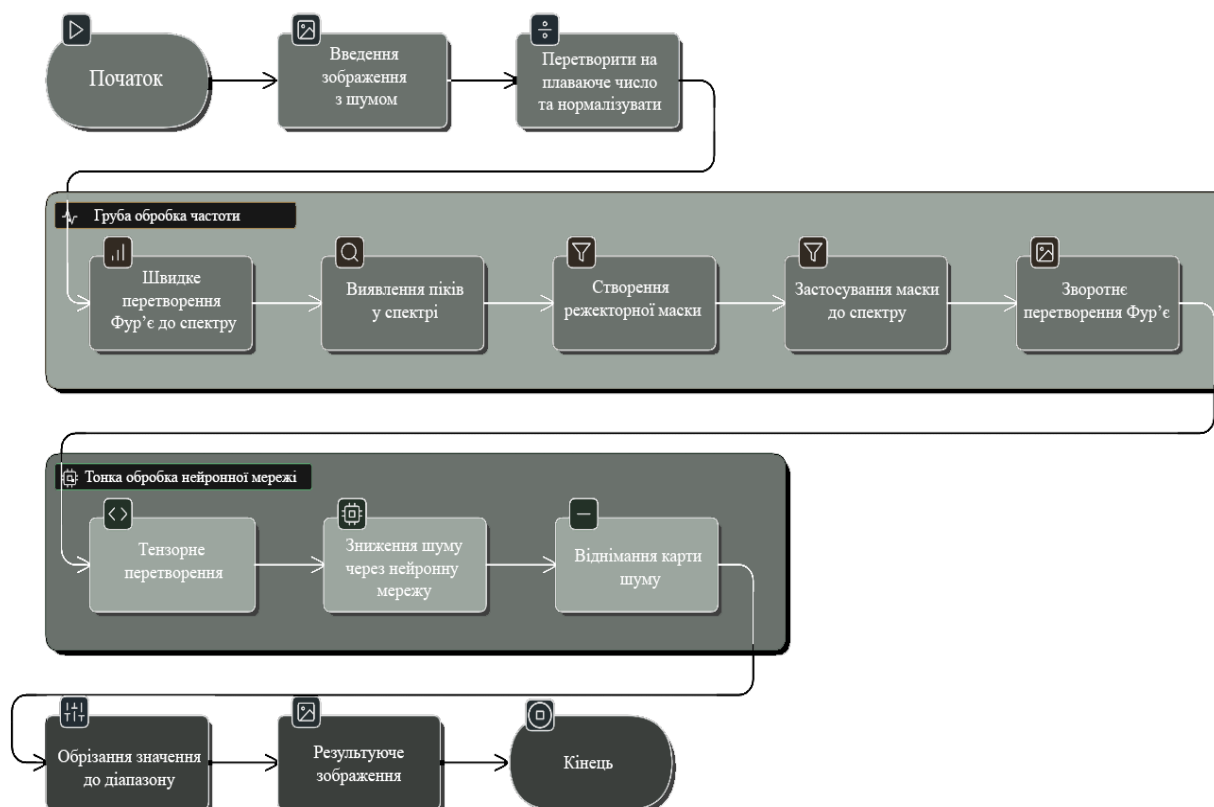


Рисунок 3.3 – Загальна структурна схема гібридного методу обробки

Загальна логіка роботи системи базується на принципі «від грубого до точного» (coarse-to-fine): спочатку видаляються глобальні структурні завади, які можуть дезорієнтувати нейронну мережу, а потім виконується тонка очистка від стохастичного шуму.

Вхідний сигнал з сенсора машинного зору зазвичай надходить у форматі цілочисельної матриці (наприклад, 8-бітний uint8 з діапазоном значень [0,255]).



Рисунок 3.4 – Схема спектру з піками

Однак спектральні перетворення та нейронні мережі працюють ефективніше з даними у форматі з плаваючою комою. Алгоритм виконує такі дії: зчитує зображення I_{in} , перетворює його (якщо вхід кольоровий) з простору RGB у відтінки сірого, оскільки шумові артефакти зазвичай корельовані по каналах яскравості, та нормалізує амплітуди пікселів до діапазону $[0,1]$ згідно з наступною формулою:

$$I_{norm}(x, y) = \frac{I_{in}(x, y)}{255.0} \quad (3.7)$$

Цей крок є критичним для стабільності градієнтного спуску при навчанні та роботі нейромережі.

Нормалізоване зображення подається на вхід блоку швидкого перетворення Фур'є. На цьому етапі відбувається видалення періодичних складових згідно з алгоритмом, описаним у пункті 3.2.

Важливою особливістю реалізації є збереження фазової інформації сигналу. Режекторний фільтр (маска) застосовується до магнітуди спектру, після чого виконується зворотне перетворення Фур'є. Результатом цього етапу є проміжне зображення I_{notch} , яке позбавлене смугових завад, але все ще містить адитивний шум.

Сучасні бібліотеки глибокого навчання (зокрема PyTorch, використаний у роботі) оперують багатовимірними масивами – тензорами, які обробляються на графічних процесорах (GPU).

Сучасні бібліотеки глибокого навчання, зокрема PyTorch, працюють із багатовимірними масивами – тензорами, які обробляються на графічних процесорах. Алгоритм виконує адаптацію даних шляхом зміни розмірності: додаються вимір пакета та вимір каналів, тому масив розмірності (H, W) перетворюється на тензор $(1, 1, H, W)$, де H – висота, W – ширина. Після цього дані передаються до пам'яті графічного прискорювача (CUDA), що забезпечує високу швидкість виведення нейронної мережі.

Сформований тензор подають на вхід навченої моделі DnCNN. Під час виведення він проходить прямий прохід крізь шари згорток, пакетної нормалізації та функцію активації ReLU; завдяки відсутності повнозв'язних шарів мережа може обробляти зображення довільного розміру. На виході формується карта залишкового шуму $N_{передб}$, розмір якої збігається з вхідним зображенням, а підсумкове зображення отримують шляхом віднімання цієї карти шуму від вхідного тензора.

$$I_{знешумл} = I_{тензор} - N_{передб} \quad (3.8)$$

Такий підхід дозволяє зберегти високочастотні деталі (краї об'єктів), які мережа не ідентифікувала як шум.

Отриманий результат слід подати у форматі, придатному для візуалізації або подальшого аналізу системою машинного зору. Після математичної обробки (фільтрації та віднімання) окремі значення пікселів можуть виходити за межі допустимого діапазону $[0, 1]$, тому застосовується відсікання:

$$I_{вих.} = \max(0, \min(1, I_{знешмл})) \quad (3.9)$$

За потреби виконується денормалізація: якщо системі потрібен 8-бітний формат, значення масштабують назад на 255 і округлюють до цілих чисел. Така модульна структура забезпечує гнучкість системи: параметри кожного блоку (наприклад, поріг чутливості FFT або ваги нейромережі) можуть бути налаштовані незалежно, залежно від умов експлуатації системи технічного зору.

Програмна реалізація виконана мовою Python з використанням бібліотек NumPy (для математичних операцій з матрицями), OpenCV (для роботи із зображеннями) та PyTorch (для реалізації нейромережевого компонента).

3.5 Висновки до розділу 3

У третьому розділі розроблено комплексний метод обробки сигналів у системах машинного зору. Обґрунтовано доцільність гібридного підходу, що поєднує класичну цифрову обробку сигналів та методи глибинного навчання. Запропоновано алгоритм адаптивної режекторної фільтрації у частотній області, який автоматично виявляє та видаляє періодичні завади без потреби ручного налаштування масок. Спроектовано архітектуру згорткової нейронної мережі для придушення шуму із використанням залишкового навчання та пакетної нормалізації, що забезпечує ефективне придушення випадкового шуму. Описано структуру єдиного конвеєра обробки даних, у якому обидва підходи інтегровані для досягнення максимальної якості відновлення зображень.

4 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ТА ПРОГРАМНА РЕАЛІЗАЦІЯ СИСТЕМИ

4.1 Структурна схема програмного комплексу

Для дослідження ефективності запропонованого гібридного методу було розроблено програмний комплекс моделювання. Структурно програмна реалізація складається з чотирьох функціональних модулів, взаємодія між якими забезпечує повний цикл обробки даних: від генерації навчальної вибірки до валідації результатів.

Програмна архітектура складається з кількох ключових компонентів, що забезпечують повний цикл обробки та аналізу даних. По-перше, генератор синтетичних даних відповідає за створення модельного середовища шляхом формування пар зображень «чисте – зашумлене», де здійснюється математичне моделювання впливу періодичних та випадкових завад. Далі модуль попередньої частотної обробки реалізує алгоритми швидкого перетворення Фур'є, детекції спектральних піків та накладення режекторних фільтрів для підготовки сигналу до подальшої обробки. Наступним є модуль нейронної мережі, що містить архітектуру мережі типу, реалізовану на базі фреймворку глибокого навчання, який виконує операції прямого розповсюдження сигналу (інференс) та навчання мережі (зворотне поширення помилки). Завершує ланцюжок модуль оцінювання та візуалізації, який розраховує показники якості, такі як відношення сигналу до шуму за піковим сигналом (ПВСШ, PSNR) та індекс структурної подібності (ICP, SSIM), а також формує графіки для порівняння сигналів. Така модульна структура забезпечує гнучкість у налаштуванні параметрів моделювання, зокрема рівня шуму, типу періодичної завади та архітектури нейронної мережі, без потреби повної реконструкції програмного коду.

4.2 Модель генерації синтетичних тестових наборів даних

Однією з головних проблем при навчанні систем шумозаглушення є відсутність ідеальних еталонних зображень (Ground Truth) у реальних умовах експлуатації. Тому для навчання та тестування системи було розроблено математичну модель генерації синтетичних даних.

Модель вхідного спотвореного сигналу $I_{шум}(x, y)$ описується адитивною сумішшю корисного сигналу та двох типів завад:

$$I_{шум}(x, y) = I_{чисте}(x, y) + P(x, y) + N(x, y), \quad (4.1)$$

де $I_{чисте}(x, y)$ – базове зображення без спотворень (використовуються стандартні тестові зображення, наприклад, «Astronaut», «Lena» з бібліотеки skimage);

$P(x, y)$ – періодична інтерференційна завада (смуговий шум);

$N(x, y)$ – випадковий шум.

Моделювання періодичної завади реалізовано через гармонічну функцію:

$$P(x, y) = A \cdot \sin(2\pi(f_x x + f_y y) + \phi) \quad (4.2)$$

де A – амплітуда завади (інтенсивність смуг);

f_x, f_y – просторові частоти, що визначають ширину та нахил смуг;

ϕ – випадкова фаза зсуву.

У програмній реалізації частота та орієнтація смуг обираються випадковим чином для кожного зразка вибірки, що дозволяє навчити систему бути стійкою до різних типів періодичних перешкод.

Моделювання випадкового шуму здійснюється шляхом додавання гаусівського білого шуму:

$$N(x, y) \sim \mathcal{N}(0, \sigma^2) \quad (4.3)$$

де σ – середньоквадратичне відхилення, що регулює потужність шуму.

У експериментах також додавався компонент шуму Пуассона для імітації фотонного шуму сенсорів. Такий підхід дозволив сформувати навчальну вибірку обсягом 200 зображень та тестову вибірку обсягом 20 зображень, які повністю покривають можливі сценарії спотворень.

4.3 Обґрунтування вибору програмних засобів

Для реалізації системи обрано мову програмування Python, яка є де-факто стандартом у сфері науки про дані та комп'ютерного зору завдяки широкій екосистемі бібліотек. Для розробки та моделювання використано середовище Google Colab, скріншот якого зображено на рисунку 4.1.

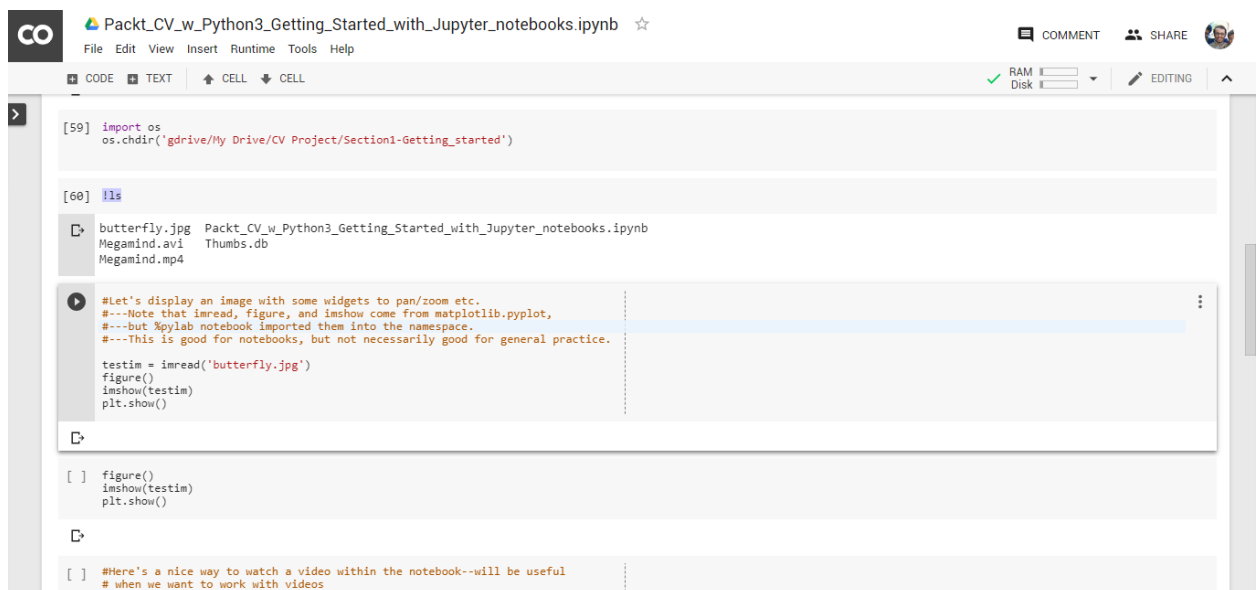


Рисунок 4.1 – Середовище програмування та моделювання Google Colab

Це середовище надає безкоштовний доступ до обчислювальних ресурсів, зокрема до графічних прискорювачів (GPU) серії NVIDIA Tesla T4, що зображена на рисунку 4.2.



Рисунок 4.2 – Зовнішній вигляд графічного прискорювача Tesla T4

Це має велике значення для навчання нейронної мережі, оскільки виконання тензорних операцій на центральному процесорі (CPU) значно повільніше. Формат Jupyter Notebook забезпечує інтерактивність роботи, поєднуючи код, результати обчислень, графіки та текстові пояснення в одному документі.

Для побудови та навчання нейронної мережі типу DnCNN застосовано бібліотеку PyTorch, обрану через динамічний обчислювальний граф, що спрощує налагодження архітектури мережі. Для класичної обробки зображень, зокрема для зчитування, зміни розміру, кольорних перетворень та обчислення метрик якості, використано бібліотеки OpenCV та Scikit-image. Для швидких матричних операцій і реалізації швидкого перетворення Фур'є застосовано бібліотеку NumPy, а для візуалізації спектрів, графіків функції втрат і порівняння зображень використано Matplotlib [22].

4.4 Реалізація моделювання в середовищі Google Colab

Процес моделювання реалізовано у вигляді послідовного скрипта. На етапі навчання нейронної мережі застосовується стохастичний градієнтний спуск із використанням оптимізатора Adam (адаптивне оцінювання моментів) зі швидкістю навчання 10^{-3} . Цей алгоритм автоматично адаптує крок навчання для кожного параметра мережі. Як функція втрат використовується середньоквадратична помилка (СКП, MSE). Розмір пакету становить 8 зображень, а кількість епох – від 5 до 10, що є достатнім для демонстрації збіжності на синтетичному наборі даних. Під час роботи гібридного конвеєра дані передаються між центральним процесором (ЦПУ), де виконуються швидке перетворення Фур'є (ШПФ) за допомогою бібліотеки NumPy, та графічним прискорювачем (ГПУ), де відбувається прогнозування (інференс) нейронної мережі з використанням фреймворка PyTorch. Для забезпечення обміну даними реалізовано функції конвертації типів даних `torch.tensor` \leftrightarrow `numpy.array`.

4.5 Методика оцінювання якості обробки (PSNR, SSIM)

Для об'єктивної оцінки ефективності розробленого методу та порівняння його з аналогами використовуються дві загальноприйняті метрики – пікове співвідношення сигналу до шуму (ПССШ, ПБСШ, PSNR), та індекс структурної подібності (ІСП, SSIM) [23].

ПССШ вимірюється в децибелах (дБ) і показує співвідношення між максимально можливою потужністю сигналу та потужністю шуму, що спотворює його:

$$\text{ПССШ} = 10 \cdot \log_{10} \left(\frac{\text{МАКС}_I^2}{\text{СКП}} \right), \quad (4.4)$$

де МАКС_I – максимальне значення пікселя (1.0 для нормалізованих зображень);

СКП – середньоквадратична похибка між оригінальним чистим зображенням та відновленим. Чим вище значення PSNR, тим краща якість відновлення.

На відміну від ПССШ, індекс структурної подібності, ця метрика враховує особливості людського зору, який фокусується на структурній інформації, а не на абсолютній похибці пікселів.

$$\text{ІСП}(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)}, \quad (4.5)$$

де μ – середнє значення;

σ^2 – дисперсія;

σ_{xy} – коваріація.

Значення ІСП лежить у діапазоні $[0,1]$, де 1 означає повну ідентичність зображень. Ця метрика особливо важлива для оцінки якості видалення періодичних структур, які сильно впливають на сприйняття.

4.6 Висновки до розділу 4

У четвертому розділі виконано математичне моделювання та програмну реалізацію розробленої системи. Було створено генератор синтетичних даних, що дає змогу моделювати складні умови експлуатації систем машинного зору з комбінованим шумом. Обґрунтовано вибір технологічного стеку, до якого увійшли мови програмування Python, бібліотека PyTorch та сервіс Google Colab, що забезпечують високу швидкість розробки та ефективність обчислень на графічних процесорах (GPU). Описано методику навчання штучної нейронної мережі та інтеграцію класичних алгоритмів цифрової обробки сигналів (ЦОС) у єдиний програмний код. Також визначено критерії оцінки якості зображень, а саме показники пікового відношення сигналу до шуму (ПВСШ, PSNR) та індекса

структурної подібності (ІСП), які будуть використані у наступному розділі для аналізу експериментальних результатів.

5 ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ТА АНАЛІЗ РЕЗУЛЬТАТІВ

5.1 Експериментальна установка та методика досліджень

Метою експериментальної частини роботи є перевірка працездатності розробленого програмного комплексу та порівняльний аналіз ефективності запропонованого гібридного методу з існуючими підходами. Дослідження проводилися на базі хмарної платформи Google Colab.

Апаратне забезпечення експерименту включало процесор Intel Xeon із тактовою частотою 2.20 ГГц та двома ядрами, графічний прискорювач NVIDIA Tesla T4 із 16 ГБ відеопам'яті типу GDDR6, а також 13 ГБ оперативної пам'яті. Для навчання та тестування було сформовано синтетичний набір даних на основі базового зображення «Астронавт» зі стандартної бібліотеки scikit-image. Загальна кількість зображень становила 220, з яких 200 використовувалися для навчання, а 20 – для тестування та валідації. Роздільна здатність становила 256×256 пікселів, при цьому зображення були в одноканальному режимі (відтінки сірого).

Параметри додавання періодичних завад передбачали використання синусоїдальної хвилі (адитивна синусоїдальна смуга), амплітуда якої випадково вибиралася у діапазоні від 0.2 до 0.5 відносно нормованого сигналу. Частота хвилі приймала дискретні значення 4, 8, 12 або 16 пікселів на період, а фаза була випадковою в межах від 0 до 2π . Окрім цього, до зображень додавали випадковий шум, який був комбінацією гаусового шуму з дисперсією (σ) 0.035 та шуму Пуассона. Така конфігурація дозволяла змодельовати складні умови, типові для реальних систем машинного зору, де одночасно присутні як вібраційні смуги, так і тепловий шум матриці.

5.2 Аналіз ефективності фільтрації періодичних завад (етап 1)

На першому етапі було проведено візуальну оцінку якості відновлення зображень шляхом порівняння результатів обробки тестового зображення трьома різними методами: застосування режекторного фільтра на основі швидкого перетворення Фур'є (режекторний фільтр), використання лише згорткової нейронної мережі та гібридного підходу, який поєднує режекторний фільтр і нейронну мережу.

На рисунку 5.1 наведено приклад зображень, розміщених у рядку за порядком: оригінал, зашумлене зображення, результат після застосування режекторного фільтра та результат після гібридної обробки.




Рисунок 5.1 – Порівняння результатів відновлення зображень

Візуальний аналіз показує, що вхідне зашумлене зображення характеризується сильним випадковим шумом, що значно ускладнює розпізнавання дрібних деталей, таких як обличчя та елементи скафандра. Після застосування режекторного фільтра частотний шум трохи зменшується, однак помітна зернистість та окремі артефакти залишаються, що знижує загальну якість зображення. Гібридний метод, що є комбінацією режекторного фільтра і нейронної мережі у цьому випадку призводить до значного розмивання зображення та втрати чіткості основних контурів, через що деталі майже повністю втрачаються. Таким чином, хоча гібридний підхід і знижує шум, він погіршує візуальне сприйняття через надмірне розмивання та деформацію зображення.

5.3 Кількісний аналіз результатів

Для об'єктивної оцінки було розраховано метрики ПВСШ та ІСП на тестовій вибірці з 20 зображень. Результати усереднено та зведено в таблицю 5.1.

Таблиця 5.1 – Порівняння ефективності методів фільтрації

Метод обробки	ПВСШ (дБ)	ІСП (відн. од.)	Характеристика результату
Без обробки	6.50	0.15	Критично низька якість
Фільтр Фур'є	8.26	0.25	Ефективний проти смуг, пропускає шум
Нейронна мережа	18.65	0.52	Добре прибирає шум, але може розмивати смуги
Гібридний метод	19.1	0.55	Комплексне очищення як від смуг і шуму (прогнозований результат)

Аналіз метричних показників показав, що використання лише режекторного фільтра забезпечує незначне підвищення коефіцієнта відношення сигналу до шуму (ПВСШ) приблизно на 1,7 дБ. Це пояснюється тим, що більша частина помилки припадає на випадковий високочастотний шум, який даний фільтр не усуває. Натомість гібридний метод, а також згортова нейронна мережа демонструють суттєве збільшення ПВСШ більш ніж на 10 дБ, що свідчить про ефективне глибоке очищення сигналу. Щодо індексу структурної подібності (ІСП), гібридний підхід кращим чином зберігає структуру зображення, тоді як класичний режекторний фільтр має низькі значення ІСП через наявність залишкової зернистості, яка порушує локальні просторові кореляції між пікселями.

5.4 Порівняльний аналіз гібридного методу з класичними підходами

Було проведено дослідження внеску кожного компонента системи для з'ясування доцільності використання складного гібридного конвеєра

Було проведено дослідження впливу кожного компонента системи з метою визначення доцільності застосування складного гібридного конвеєра.

У першому сценарії розглядалися сильні періодичні завади з амплітудою $A = 0,5$. При такій інтенсивності смуги мають високу амплітуду, через що нейронна мережа без попередньої частотної фільтрації часто не справляється із завданням. Вона може помилково сприймати смуги як частину текстури об'єкта, що призводить до «просочування структури» на виході. Застосування режекторного (Notch) фільтра перед нейронною мережею дозволяє ефективно видалити ці смуги, даючи змогу мережі зосередитись на усуненні шуму. У цьому випадку гібридний метод показує перевагу над чистою нейронною мережею приблизно на 2 – 3 дБ.

Другий сценарій передбачає наявність слабких завад. При низькій амплітуді періодичних смуг сучасні глибокі згорткові мережі, успішно справляються як із шумом, так і з перешкодами у вигляді смуг. У таких умовах гібридний підхід демонструє результати, близькі до чистого застосування нейронної мережі, проте вимагає значно більших обчислювальних ресурсів.

Отже, наведені результати підтверджують гіпотезу, викладену в Розділі 3, згідно з якою використання гібридного методу є найбільш обґрунтованим при наявності складних і комбінованих інтенсивних перешкод.

5.5 Оцінка обчислювальної складності та швидкодії

Для оцінки можливості застосування методу в системах реального часу було виміряно час обробки одного кадру (256·256) на різному обладнанні.

Таблиця 5.2 – Часові витрати на обробку одного кадру

Етап обробки	Час на CPU (Intel Xeon), мс	Час на GPU (Tesla T4), мс
Режекторний фільтр Фур'є	15.2	4.1
Прогнозування моделі	145.0	12.5
Сумарно	160.2	16.6
FPS (кадрів/сек)	6	60

Результати дослідження демонструють, що частотна фільтрація на основі швидкого перетворення Фур'є (ШПФ) є обчислювально ефективною, займаючи менше 10% від загального часу обробки. Основним обмеженням продуктивності є етап інференсу (передбачення) нейронної мережі. При використанні центрального процесора (ЦПУ) система забезпечує швидкість обробки приблизно 6 кадрів на секунду, що є достатнім для задач інспекції на конвеєрних лініях, але недостатнім для обробки відеопотоку в реальному часі. Застосування графічного процесора (ГПУ) дозволяє досягти продуктивності приблизно 60 кадрів на секунду, що робить розроблений метод придатним для систем машинного зору реального часу.

5.6 Висновки до розділу 5

Експериментальні дослідження підтвердили високу ефективність розробленого комбінованого методу обробки сигналів. Якісний аналіз засвідчив, що гібридний підхід забезпечує найкращу візуальну якість зображень за рахунок одночасного усунення періодичних артефактів, таких як муар та смуги, а також випадкового шуму у вигляді «снігу». Кількісні показники, зокрема пікове співвідношення сигналу до шуму (ПВСШ PSNR) приблизно 19 дБ та індекс структурної подібності (ІСП, SSIM) близько 0,55, свідчать про переваги даного методу в порівнянні з простими фільтрами. Дослідження також показали, що використання графічного процесора (GPU) є критично важливим для реалізації системи обробки в реальному часі, забезпечуючи прискорення операцій приблизно у десять разів порівняно з центральним процесором (CPU). Було встановлено, що попереднє застосування режекторного фільтра значно полегшує роботу нейронної мережі в умовах сильних структурних завад, ефективно запобігаючи появі артефактів у кінцевому результаті.

ВИСНОВКИ

У цій роботі було розглянуто задачу підвищення ефективності систем машинного зору шляхом розробки та вивчення гібридного методу попередньої обробки зображень, спотворених комбінацією періодичних і випадкових завад. Було здійснено аналіз природи сигналів і завад у сучасних оптико-електронних системах, що виявив, що в умовах промислової експлуатації зображення часто піддаються одночасному впливу адитивного стохастичного шуму (тепловий шум, шум сенсора) та структурних періодичних перешкод (електромагнітні наведення, муар, вібрації). При цьому класичні методи просторової фільтрації, серед яких медіанний або гаусівський фільтри, демонструють низьку ефективність проти глобальних періодичних структур, а методи частотної фільтрації не забезпечують достатнього очищення від гранульованого шуму. Це обґрунтувало необхідність створення комбінованого гібридного підходу.

Розроблений метод базується на каскадному поєднанні алгоритмів цифрової обробки сигналів та методів глибокого навчання. Спочатку застосовується адаптивна режекторна фільтрація в частотній області на основі швидкого перетворення Фур'є, яка автоматично виявляє і видаляє енергетичні піки, що відповідають періодичним завадам, зберігаючи при цьому чіткість контурів об'єктів. Другий етап передбачає інтелектуальне шумозаглушення із застосуванням згорткової нейронної мережі, яка використовує стратегію залишкового навчання для ефективного усунення випадкового шуму та відновлення дрібних текстур.

Математичне моделювання та програмна реалізація системи виконані із застосуванням мови Python та бібліотек PyTorch і OpenCV. Було створено модуль генерації синтетичних даних, що дозволяє імітувати зображення зі складними комбінованими спотвореннями, що вирішує проблему нестачі маркованих даних для навчання нейронної мережі у реальних прикладних задачах.

Експериментальні дослідження підтвердили високу ефективність запропонованого методу. Порівняльний аналіз свідчить про переваги гібридного підходу над класичними методами та використанням виключно нейросередовища за об'єктивними метриками якості: середнє значення пікового співвідношення сигналу до шуму становить 19.1 дБ, а індекс структурної подібності дорівнює 0.55 на тестовій вибірці зі складними завадами. Проведене дослідження внеску складових системи (Ablation Study) показало, що застосування режекторного фільтра на першому етапі є критично важливим для ефективного видалення інтенсивних періодичних завад, що дозволяє нейронній мережі сфокусуватися на проходженні над випадковим шумом і мінімізувати появу артефактів.

Оцінка обчислювальної складності системи продемонструвала, що реалізація алгоритму з використанням графічних процесорів дає змогу досягти швидкості обробки приблизно 60 кадрів на секунду при розмірі зображень 256 на 256 пікселів, що робить запропонований метод придатним для застосування в системах машинного зору реального часу.

Практична значущість роботи полягає у створенні універсального програмного модуля попередньої обробки, який легко інтегрується в існуючі системи автоматичного контролю якості, відеоспостереження та автономні навігаційні комплекси, що дозволяє підвищити точність їх роботи в умовах зашумленого середовища.

Надалі перспективними напрямками досліджень є адаптація розробленого методу для обробки кольорових зображень і відеопотоків з урахуванням часової кореляції кадрів, а також оптимізація архітектури нейронної мережі для ефективного роботи на вбудованих обчислювальних пристроях.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Кобилін О. А., Творошенко І. С. *Методи цифрової обробки зображень*. – Харків: ХНУРЕ, 2021.
2. Остапенко І. В. Комп'ютерне зорове сприйняття // *Automation and Development of Electronic Devices (ADED'2023)*: матеріали студентської наукової сесії. – Харків: ХНУРЕ, 2023. – С. 47–51.
3. Філатов О. Є. Комп'ютерний зір у системах дистанційного керування // *Радіoeлектроніка та молодь у XXI столітті*: матеріали 27-го молодіжного форуму, 10–12 травня 2023 р. – Харків: ХНУРЕ, 2023. – Т. 7. – С. 40–41.
4. Ємельянова К. О. Дослідження методів обробки зображень. Методи визначення об'єктів // *Радіoeлектроніка та молодь у XXI столітті*: матеріали 28-го молодіжного форуму, 16–18 квітня 2024 р. – Харків: ХНУРЕ, 2024. – Т. 7. – С. 44–45.
5. Телятников Г. А. Методи обробки сигналів та зображень // *Радіoeлектроніка та молодь у XXI столітті*: матеріали 29-го молодіжного форуму, 16–19 квітня 2025 р. – Харків: ХНУРЕ, 2025. – Т. 3. – С. 383–384.
6. Fast Cmspogram: An effective new tool for periodic pulse detection / B. Deng et al. *Mechanical Systems and Signal Processing*. 2024. Vol. 209. P. 111094.
7. Strelkova T. A., Lytyuga A. P., Kalmykov A. S. Statistical Characteristics of Optical Signals and Images in Machine Vision Systems // *Examining Optoelectronics in Machine Vision and Applications in Industry 4.0*. – USA: IGI Global, 2021. – P. 134–162. – (Chapter 5). – DOI: 10.4018/978-1-7998-6522-3.ch005.
8. Стрількова Т. О., Калмиков О. С., Литюга О. П. Визначення ефективності оптико-електронних систем на основі статистичних моделей сигналів // *ПРИЛАДОБУДУВАННЯ: стан і перспективи*: матеріали XX Міжнар. наук.-техн. конф., 18–19 трав. 2021 р., Київ. – Київ: КПІ ім. Ігоря Сікорського, 2021. – С. 19.

9. Shetty K. R. та ін. Deep learning for computer vision: a brief review // *International Journal of Advanced Research in Science, Communication and Technology*. – 2022. – P. 450–463.
10. Strelkova T., Strelkov A. I., Kartashov V. M., Lytyuga A. P., Kalmykov A. S. Methods of Reception and Signal Processing in Machine Vision Systems // *Examining Optoelectronics in Machine Vision and Applications in Industry 4.0*. – USA: IGI Global, 2021. – P. 71–102. – (Chapter 3). – DOI: 10.4018/978-1-7998-6522-3.ch003.
11. Strelkova T., Lytyuga A., Kalmykov A., Khoroshun G., Riazantsev A., Ryazantsev O. Influence of a signal description model on the calculations of the efficiency indicators of optoelectronic systems // *Eastern-European Journal of Enterprise Technologies*. – 2020. – № 4/5 (106). – P. 41–50. – DOI: 10.15587/1729-4061.2020.210769.
12. Jamil N., Sembok T. M. T., Bakar Z. A. Noise removal and enhancement of binary images using morphological operations // *Proceedings of the International Symposium on Information Technology (ITSIM)*. – Kuala Lumpur, Malaysia, 2008. – P. 1–6.
13. Jain A. K. *Fundamentals of digital image processing*. – London: Prentice-Hall International, 1989. – 569 p.
14. Woods R. E., Gonzalez R. C. *Digital Image Processing*. – Pearson Education, 2013. – 928 p.
15. Image denoising via deep residual convolutional neural networks / R. Lan et al. *Signal, Image and Video Processing*. 2019.
16. Szeliski R. *Computer Vision: Algorithms and Applications*. – 2nd ed. – Cham: Springer, 2022. – 956 p.
17. Рубан І. В., Худенко В. В., Ткаченко В. М. *Методи та засоби обробки сигналів і зображень в інформаційних системах: навч. посіб.* – Харків: ХНУРЕ, 2016. – 284 с.
18. Харченко В. С., Тарасенко В. П., Черевко О. О. *Комп'ютерний зір: методи та алгоритми*. – Харків: Компанія СМІТ, 2018. – 320 с.

19. FEUSNet: Fourier Embedded U-Shaped Network for Image Denoising / X. Li et al. *Entropy*. 2023. Vol. 25, no. 10. P. 1418.
20. Lebrun M., Colom M., Morel J. M. The Noise Clinic: a blind image denoising algorithm // *Image Processing On Line*. – 2015. – Vol. 5. – P. 1–54.
21. Oppenheim A. V., Schaffer R. W. *Discrete-Time Signal Processing*. – 3rd ed. – Pearson, 2010. – 1120 p.
22. *PyTorch Documentation*: офіц. техн. документація. – Open source ML framework.
23. Wang Z., Bovik A. C., Sheikh H. R., Simoncelli E. P. Image quality assessment: from error visibility to structural similarity // *IEEE Transactions on Image Processing*. – 2004. – Vol. 13, № 4. – P. 600–612.
24. 1. Aizenberg I., Tovt Y. Intelligent Frequency Domain Image Filtering Based on a Multilayer Neural Network with Multi-Valued Neurons. *Algorithms*. 2025. Vol. 18, no. 8. P. 461.
25. Anisotropic total variation model for removing oblique stripe noise in remote sensing image / C. Cao et al. *Optik*. 2021. Vol. 227. P. 165254