

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
ДОНЕЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ВАСИЛЯ СТУСА

АБДУЛА ОЛЕГ ЮРІЙОВИЧ

Допускається до захисту:

В.о. завідувача кафедри  
інформаційних технологій,  
к.т.н., доцент

\_\_\_\_\_ О.В. Зелінська

« \_\_\_\_\_ » \_\_\_\_\_ 2024р.

**ДОСЛІДЖЕННЯ НЕЙРОМЕРЕЖЕВИХ МЕТОДІВ КЛАСИФІКАЦІЇ  
ЗОБРАЖЕНЬ СІЛЬСЬКОГОСПОДАРСЬКИХ ТЕРИТОРІЙ**

Спеціальність 122 «Комп'ютерні науки»

Кваліфікаційна (магістерська) робота

Науковий керівник:

Федоров Є.Є., д.т.н., професор

кафедри інформаційних технологій

\_\_\_\_\_  
(підпис)

Оцінка: \_\_\_\_\_ / \_\_\_\_\_ / \_\_\_\_\_  
(бали за шкалою ЄКТС/за національною шкалою)

Голова ЕК: \_\_\_\_\_  
(підпис)

Вінниця — 2024

## АНОТАЦІЯ

**Абдула О.Ю.** Дослідження нейромережових методів класифікації зображень сільськогосподарських територій. Спеціальність 122 «Комп'ютерні науки», Освітня програма «Компютерні технології обробки даних (Data Science)». Донецький національний університет імені Василя Стуса, Вінниця, 2024.

У кваліфікаційній роботі досліджено розпізнавання об'єктів та класифікацію зображень сільськогосподарських територій нейромережовим методом. Показано що дослідження є актуальним завданням в сучасному сільському господарстві. Встановлено що такі дослідження можуть мати практичний застосунок у багатьох сферах, включаючи агрономію, сільське господарство, екологію, моніторинг рослин, земельний кадастр і багато інших.

Ключові слова: дослідження, нейромережові методи, класифікація зображень, сільськогосподарські території.

89с., 5 рис., 1 дод., 22 джерела.

Abdula O.U. Research of neural network classification methods of agricultural territories images. Specialty 122 "Computer science", Educational program "Computer technologies of data processing (Data Science)". Vasyl' Stus Donetsk National University, Vinnytsia, 2024.

In the qualification work, object recognition and classification of images of agricultural territories using the neural network method were investigated. It is shown that research is an urgent task in modern agriculture. It has been established that such research can have practical applications in many areas, including agronomy, agriculture, ecology, plant monitoring, land cadaster and many others.

Keywords: research, neural network methods, image classification, agricultural territories.

89 p., 5 fig, 1 add., 22 sources.

## ЗМІСТ

ВСТУП	4
РОЗДІЛ 1	11
ПОСТАНОВКА ЗАДАЧІ І ОГЛЯД ТЕОРІЇ РОЗПІЗНАВАННЯ ТА МЕТОДІВ КЛАСИФІКАЦІЇ ЗА ДАНОЮ ТЕМАТИКОЮ .....	11
1.1 Опис актуальності дослідження розпізнавання зображень методами машинного навчання.....	11
1.2 Теорія розпізнавання зображень .....	20
1.3 Методи класифікації зображень.....	27
Висновок до розділу 1 .....	36
РОЗДІЛ 2 .....	38
ЗГОРТКОВА НЕЙРОННА МЕРЕЖА.....	38
2.1 Гібридні архітектури нейронних мереж.....	40
2.2 Шаблон архітектури згорткової нейронної мережі.....	52
Висновок до розділу 2 .....	61
РОЗДІЛ 3 .....	65
МЕТОДИКА НАВЧАННЯ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ .....	65
3.1 Методи навчання нейронних мереж .....	65
3.2 Навчання з учителем.....	70
3.3 Навчання без учителя .....	73
Висновок до розділу 3 .....	76
ВИСНОВКИ.....	80
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	85
ДОДАТКИ.....	87

## ВСТУП

Актуальність теми розпізнавання об'єктів та класифікації зображень сільськогосподарських територій дійсно зростає в сучасному світі. Існує кілька ключових причин, що пояснюють це зростання інтересу:

По-перше це автоматизація в сільському господарстві, сучасні технології дозволяють використовувати автономні робочі процеси, такі як роботи та дрони, для вирішення різних завдань у галузі сільського господарства. Розпізнавання об'єктів є ключовим елементом цих автоматизованих систем, які допомагають збільшити продуктивність та зменшити витрати. Також це може бути корисним для визначення стану рослин, виявлення хвороб та шкідників, контролю за поливом та добривами. Це сприяє зростанню врожаю та зниженню втрат.

По-друге інтелектуальні системи керування та застосування штучного інтелекту та машинного навчання у системах керування дозволяє створювати більш розумні та адаптивні рішення для оптимізації сільськогосподарських процесів. Тобто допомагає ефективно використовувати ресурси, такі як паливо, час та людські ресурси, шляхом автоматичного визначення проблем і виконання відповідних завдань.

Втретє оптимізація розпізнавання об'єктів та класифікації зображень сільськогосподарських територій може сприяти зниженню впливу сільського господарства на довкілля та збереженню ресурсів (екологічний аспект).

Усі ці фактори роблять дуже актуальною та перспективною темою для досліджень та розвитку технологій у сфері сільського господарства.

Дослідження нейромережових методів класифікації зображень сільськогосподарських територій є актуальним завданням в сучасному сільському господарстві і в областях, пов'язаних із земельним господарством та аграрним сектором. Такі дослідження можуть мати практичний застосунок у багатьох сферах, включаючи агрономію, сільське господарство, екологію, моніторинг рослин, земельний кадастр і багато інших.

Такі дослідження можуть мати значний практичний вплив в управлінні ресурсами на забруднених територіях після ведення бойових дій або на інших територіях з екологічними проблемами. Ось деякі засоби, за якими це може бути корисним:

1. Виявлення забруднень та змін в рослинному покриві: Нейромережеві моделі можуть виявляти забруднення, деградацію ґрунту та зміни в рослинному покриві на зображеннях з високою точністю. Це може бути корисним для моніторингу впливу бойових дій на природу та земельні ресурси.

2. Оцінка забруднення повітря та води: Зображення зі супутників та дронів можуть використовуватися для виявлення забруднень повітря та води. Моделі можуть аналізувати кольори та текстури, щоб виявити зміни у стані навколишнього середовища.

3. Моніторинг екологічних та природних ресурсів: Дослідження може допомогти в моніторингу стану екологічних заповідників, лісів, водних ресурсів та інших природних ресурсів, щоб вчасно виявляти можливі проблеми і втручатися.

4. Планування реконструкції та відновлення: Інформація, отримана в результаті класифікації зображень, може бути використана для планування та відновлення територій після ведення бойових дій або екологічних катастроф.

5. Повідомлення громадськості та влади: Дані, зібрані із застосуванням нейромережевих методів, можуть служити основою для інформування громадськості та прийняття рішень владою щодо екологічної політики та реагування на екологічні кризи.

Основні кроки та аспекти дослідження нейромережевих методів класифікації зображень сільськогосподарських територій можуть включати такі:

1. Збір та підготовка даних:
  - Зібрати набір зображень сільськогосподарських територій, які потрібно класифікувати.

Зображення можуть бути отримані зі спутникових знімків, дронів, камер віджимання, тощо.

- Провести попередню обробку зображень, таку як зменшення шуму, розміром та нормалізацію, щоб покращити якість даних та прискорити навчання моделі.

2. Вибір архітектури нейромережі:

- Вибрати архітектуру нейромережі, яка відповідає вашій задачі класифікації.

3. Навчання моделі:

- Розділити ваші дані на тренувальний, валідаційний і тестовий набори.

- Навчати модель на тренувальних даних, використовуючи підходящий оптимізатор та функцію втрат.

- Використовувати валідаційний набір для моніторингу процесу навчання і уникнення перенавчання.

4. Оцінка моделі:

- Використовувати тестовий набір для оцінки продуктивності моделі, розрахунку метрик, таких як точність, відновлення т. д.

- Виправляти та покращувати модель на основі отриманих результатів.

5. Застосування моделі:

- Після успішного навчання моделі ви можете застосовувати її для класифікації сільськогосподарських територій на нових зображеннях або для моніторингу змін на існуючих територіях.

6. Вдосконалення та оптимізація:

- Продовжуйте вдосконалювати модель, додаючи більше даних, оптимізуючи гіперпараметри, використовуючи техніки переднього та зворотного розповсюдження помилок та інші методи покращення продуктивності.

Усі ці застосування можуть сприяти покращенню ефективності моніторингу та управління сільськогосподарськими ресурсами на забруднених територіях та зменшити негативний вплив бойових дій та екологічних проблем на навколишнє середовище.

Тому удосконалення реалізації розпізнавання комп'ютерними системами зображень є актуальною, та є найбільш перспективним напрямком в діяльності будь-якого сільськогосподарського комплексу (підприємства) і є невід'ємною частиною економічного розвитку країни.

Застосування штучних нейронних мереж і нейрокомп'ютерів є одним із найбільш прогресивних напрямків для вирішення завдань розпізнавання об'єктів на сільськогосподарських територіях. Ось деякі переваги цього підходу:

Глибоке навчання (Deep Learning), штучні нейронні мережі здатні працювати з великою кількістю даних та розпізнавати об'єкти з високою точністю.

Нейронні мережі можуть бути навчені автоматично, шляхом подачі великої кількості маркованих даних. Це дозволяє моделям самостійно вивчати та адаптуватися до нових умов і об'єктів, що розширює їхню застосовність.

Після налагодження і навчання нейронні мережі можуть досягати високої точності у завданнях розпізнавання об'єктів, що робить їх ефективними інструментами для вирішення сільськогосподарських завдань.

Моделі нейронних мереж можуть бути адаптовані до різних сільськогосподарських сценаріїв та завдань.

Нейронні мережі можуть бути використані в поєднанні з дронами та системами Інтернету речей для збору даних та автоматизації сільськогосподарських процесів.

Усе це робить застосування штучних нейронних мереж і нейрокомп'ютерів надзвичайно важливим і перспективним напрямком для вирішення завдань розпізнавання об'єктів на сільськогосподарських

територіях та покращення продуктивності та ефективності у галузі сільського господарства.

В сфері розпізнавання об'єктів на зображеннях і величезній кількості даних є велика різноманітність завдань та вимог до моделей. Тому існує безліч різних архітектур нейронних мереж, кожна з яких має свої переваги і недоліки, і яка може бути більш або менш ефективною в конкретних умовах.

Пошук найкращої архітектури нейромережі часто є завданням ітеративним і вимагає експериментів, налаштування параметрів, використання різних метрик якості та оцінки результатів. Цей процес називається "налаштуванням гіперпараметрів", і він є важливою частиною роботи з нейронними мережами.

Крім того, вибір нейронної мережі може залежати від конкретного завдання. Наприклад, для виявлення об'єктів у великих сільськогосподарських полях можуть бути корисними більш легкі та швидкі архітектури.

У майбутньому можливо виникнуть нові архітектури та методи, які будуть більш ефективними для конкретних завдань розпізнавання об'єктів на сільськогосподарських територіях. Тому важливо вести дослідження та використовувати сучасні найкращі практики у цій сфері для досягнення найкращих результатів.

Для сучасного сільськогосподарського бізнесу важливо налагодити всі процеси, від вибору постачальників до доставки готової продукції клієнту-покупцю. При цьому одна з найважливіших і витратних областей – це отримання достовірної і своєчасної інформації для прийняття управлінських рішень на кожному етапі використання сільськогосподарських територій.

Підвищення продуктивності сільськогосподарського виробництва: Використання нейромереж для класифікації сільськогосподарських територій дозволяє точно визначати різні аспекти земельного використання, що може бути використано для підвищення продуктивності та ефективності сільськогосподарського виробництва. Наприклад, виявлення врожаїв, визначення потреб у зрошенні або обробці ґрунту.



Моніторинг та управління ресурсами: Класифікація сільськогосподарських територій дозволяє вчасно виявляти зміни в використанні земельних ресурсів, що може бути корисним для ефективного управління цими ресурсами, включаючи зменшення споживання води та хімічних добрив.

Збереження довкілля: Завдяки класифікації зображень можна виявляти випадки незаконного вирубування багаторічних насаджень, деградації ґрунтів, ерозії та інших негативних впливів на природні ресурси, що допомагає вживати заходи для їх збереження.

Автоматизація та оптимізація процесів: Застосування нейромереж дозволяє автоматизувати процеси аналізу сільськогосподарських територій, що дозволяє зменшити витрати часу та зусиль, потрібних для збору та аналізу інформації.

Моніторинг змін клімату: Дослідження сільськогосподарських територій також важливо для моніторингу впливу змін клімату на сільське господарство та природні ресурси.

Об'єктом дослідження в рамках науково-дослідницької практичної підготовки є процес класифікації зображень, способи організації засобів нейромережевого розпізнавання об'єкта на зображенні з використанням графічних прискорювачів.

Предметом дослідження є методи і алгоритми класифікації на підставі згорткових нейронних мереж.

Створення нейромережевої системи розпізнавання об'єктів на зображеннях з використанням власної архітектури згорткової нейронної мережі та ієрархічного класифікатора є важливим завданням у сфері машинного навчання та комп'ютерного зору. Ось деякі кроки та підходи, які можуть бути корисними у виконанні цієї роботи:

Збір і підготовка набору даних є першим та одним з найважливіших етапів. Потрібно мати набір зображень, розмічених з об'єктами, які ви хочете розпізнавати. Також важливо розподілити дані на тренувальний, валідаційний і тестовий набори.

Створення власної архітектури згорткової нейронної мережі вимагає обрання кількості шарів, розмірів фільтрів, функцій активації та інших гіперпараметрів. Варто ретельно продумати структуру мережі, щоб вона була ефективною для вирішення завдання.

Тренування моделі, потребує використовувати тренувальний набір даних для навчання моделі. З моніторингом процесу тренування та використання валідаційних наборів для оцінки її продуктивності.

Виправлення гіперпараметрів та оптимізація можуть покращити продуктивність моделі. Варто використовувати техніки, такі як збільшення даних, регуляризація та оптимізатори для покращення результатів.

Ієрархічний класифікатор може допомогти покращити точність розпізнавання, дозволяючи спершу визначити загальний клас, а потім точніше класифікувати об'єкт в середині цього класу.

Після тренування та налаштування моделі важливо оцінити її продуктивність на тестовому наборі даних та визначити метрики якості, такі як точність, відновлення та інші.

Цей процес може бути трудовитратним і складним, але він надає можливість створити потужний інструмент для розпізнавання об'єктів на зображеннях у сільському господарстві.

Усі ці фактори роблять тему дослідження нейромережевих методів класифікації зображень сільськогосподарських територій вкрай актуальною, адже вона дозволяє вирішувати реальні завдання, пов'язані з покращенням сільськогосподарського сектору, збереженням довкілля та ефективним використанням ресурсів.

## РОЗДІЛ 1

### ПОСТАНОВКА ЗАДАЧІ І ОГЛЯД ТЕОРІЇ РОЗПІЗНАВАННЯ ТА МЕТОДІВ КЛАСИФІКАЦІЇ ЗА ДАНОЮ ТЕМАТИКОЮ

#### 1.1 Опис актуальності дослідження розпізнавання зображень методами машинного навчання

Дослідження розпізнавання зображень методами машинного навчання є надзвичайно актуальним і важливим завданням у сучасному світі з ряду ключових причин:

1. Зростання обсягу зображень: За останні кілька років обсяги цифрових зображень значно зросли завдяки доступності камер на мобільних пристроях, відеоспостереженню, дронах та інших джерел. Це створює потребу в розробці систем розпізнавання для обробки цього великого обсягу візуальних даних.
2. Застосування в автономних системах: Розпізнавання зображень використовується в автономних системах, таких як автомобілі з автопілотом, дрони та роботи, для автоматичного розпізнавання об'єктів, перешкод, підкреслення шляхів тощо.
3. Безпека і відеоспостереження: Розпізнавання об'єктів та подій на відеозаписах має важливе значення для забезпечення безпеки в навколишньому середовищі.
4. Оптимізація бізнес-процесів: Впровадження систем розпізнавання зображень може покращити різні бізнес-процеси, включаючи інвентаризацію земель, якість контролю їх використання, відстеження змін та інше.
5. Автоматизація та збільшення продуктивності: Використання розпізнавання зображень дозволяє автоматизувати багато завдань, що раніше вимагали б великого обсягу ручної праці, що сприяє підвищенню продуктивності та зменшенню витрат.

6. Розвиток штучного інтелекту: Розпізнавання зображень є однією з ключових галузей штучного інтелекту, і дослідження в цій області сприяє розвитку та вдосконаленню алгоритмів машинного навчання.

Усі ці аспекти свідчать про важливість і актуальність дослідження розпізнавання зображень методами машинного навчання в багатьох сферах, і вони мають потенціал для перетворення способу, яким ми взаємодіємо з технологією та вирішуємо реальні завдання.

Машинне навчання як головна складова теорії штучного інтелекту, це галузь, яка вивчає розробку алгоритмів та моделей, які навчаються з даних і роблять прогнози або приймають рішення без явного програмування. Вона включає в себе велику кількість методів, технік та алгоритмів для аналізу та використання даних.

Ось декілька основних аспектів математики, які використовуються в машинному навчанні:

Математична статистика, вона використовується для вивчення інференції, оцінки параметрів та визначення статистичної достовірності результатів. Математичні статистичні методи допомагають аналізувати дані та визначати розподіли.

Теорія ймовірностей, вона відображає важливу роль в оцінці ризиків та стохастичних процесах. Вона використовується для моделювання невизначеності та ймовірних подій.

Лінійна алгебра, вона грає ключову роль у векторних просторах даних та матричних операціях, які використовуються в багатьох алгоритмах машинного навчання.

Оптимізація, методи оптимізації використовуються для налаштування параметрів моделей таким чином, щоб мінімізувати функцію втрат і покращити ефективність навчання.

Математична операційна теорія, ця галузь математики може бути використана для вирішення проблем оптимізації та прийняття рішень в реальному часі.

Усі ці математичні концепції та методи інтегруються в машинному навчанні для розробки і вдосконалення алгоритмів та моделей, які можуть аналізувати дані, робити передбачення та приймати рішення. Математика є основним інструментом у розвитку та використанні широкого спектру методів машинного навчання.

Відзначимо два типи машинного навчання: індуктивне навчання та дедуктивне навчання. Ці два підходи відрізняються за своєю природою та методами використання даних:

Індуктивне навчання (Inductive Learning):

Цей підхід полягає в тому, щоб вивчати загальні правила або закономірності з вхідних даних, на основі яких можна робити узагальнені висновки.

У індуктивному навчанні модель намагається знайти шаблони, закономірності та правила, що діють в даних, і використовувати їх для прийняття рішень або зроблення прогнозів для нових даних, які вона раніше не бачила.

Індуктивне навчання часто використовується в задачах класифікації, регресії та кластеризації.

Дедуктивне навчання (Deductive Learning):

Базується на вже відомих правилах, закономірностях чи знаннях і використовує їх для прийняття рішень або виведення нової інформації.

В цьому підході модель використовує передбачені або відомі правила, щоб робити висновки та приймати рішення для конкретних ситуацій.

Дедуктивне навчання часто використовується в експертних системах, де правила і знання вводяться вручну або на основі експертної інформації.

Обидва ці типи машинного навчання можуть бути корисними в різних сценаріях та задачах. Важливо обирати підхід, який найкраще відповідає

конкретному завданню та доступним даним. Індуктивне навчання зазвичай використовується там, де не відомі конкретні правила, і модель має навчитися цих правил з даних. Дедуктивне навчання може бути ефективним у випадках, коли є чіткі та відомі правила, які можуть бути застосовані до нових ситуацій.

Машинне навчання (Machine Learning, ML) є результатом розвитку науки про нейронні мережі та включає в себе елементи з різних наук та областей, таких як математична статистика, теорія дискретного аналізу та інші.

Вивчення штучних нейронних мереж відіграло важливу роль у розвитку машинного навчання. Протягом багатьох років ця область досліджень була ключовою в розробці алгоритмів навчання та мережевих архітектур.

Машинне навчання взяло у своє основу концепції математичної статистики, такі як методи регресії, класифікації, кластеризації та оцінки параметрів. Статистичні методи допомагають оцінювати, моделювати та аналізувати дані.

Машинне навчання використовує ідеї з теорії дискретного аналізу для обробки та обчислення даних, зокрема у випадках, коли дані є дискретними та категоріальними.

Машинне навчання активно вивчає зразки та патерни у великих об'ємах даних, розвиваючи алгоритми, які можуть "навчитися" з цього досвіду та робити прогнози для нових даних.

З розвитком обчислювальної технології та збільшенням обчислювальної потужності стали можливими більш складні та потужні методи машинного навчання, такі як глибоке навчання (deep learning).

Машинне навчання стало важливою галуззю в рамках науки про штучний інтелект і сьогодні широко використовується для вирішення різних завдань, включаючи обробку зображень.

Розпізнавання необхідної інформації-важливий аспект у сучасному використанні штучного інтелекту. Для реалізації даного завдання людство вигадало таке поняття, як нейронна мережа.

Штучні нейронні мережі (ШНМ) дійсно частково відповідають принципу функціонування біологічних нейронних мереж (БНМ) у живих організмах. Штучні нейронні мережі є математичними моделями, які спроектовані для моделювання обробки інформації та прийняття рішень, подібно до того, як це відбувається (з точки зору сучасної науки) в мозку та нервовій системі живих організмів.

Основні аспекти, на яких базуються ШНМ на основі БНМ:

Нейрони: в ШНМ нейрони моделюються як обчислювальні вузли, які приймають вхідні сигнали, обробляють їх та видають вихідні сигнали. Кожен нейрон взаємодіє з іншими нейронами через зв'язки.

Зв'язки: зв'язки в ШНМ відповідають синаптичним з'єднанням між нейронами в БНМ. Зв'язки містять ваги, які визначають важливість інформації, яка передається від одного нейрона до іншого.

Активація: штучні нейрони активуються, коли сума вагованих вхідних сигналів перевищує певний поріг. Цей процес схожий на відповідь БНМ на стимул.

Шари: ШНМ може бути організована у вигляді шарів нейронів. Вхідний шар приймає дані, а потім інформація передається через приховані шари до вихідного шару.

Функції активації: ШНМ використовують функції активації для визначення виходів нейронів після обчислень.

Навчання: ШНМ можуть бути навчені за допомогою алгоритмів навчання, таких як зворотнє поширення помилки (backpropagation), які допомагають визначити оптимальні ваги зав'язків.

ШНМ знайшли застосування в різних галузях. Вони допомагають вирішувати завдання, які вимагають аналізу та розуміння складних даних та структур, і вони є важливим інструментом в галузі штучного інтелекту та машинного навчання.

Системи, архітектура і принцип дії штучних нейронних мереж (ШНМ) базуються на аналогії з мозком живих істот і, зокрема, на імітації біологічних

нейронів. Це дозволяє ШНМ виконувати завдання обробки інформації і прийняття рішень, подібно до того, як це робить мозок та нервова система у живих організмів. Ця аналогія з біологічними нейронами допомагає ШНМ вирішувати різноманітні завдання, такі як класифікація, регресія, обробка зображень.

Ключовий елемент штучних нейронних мереж (ШНМ) - це штучний нейрон, який є імітаційною моделлю біологічного нейрона мозку. Термін "нейрон" в цьому контексті походить від спроби імітувати функції та структуру біологічних нейронів в мозку, а ця ідея вперше була розглянута Маккалоком і Піттсом у їхній роботі в 1943 році.

Маккалок та Піттс розглядали біологічні нейрони як обчислювальні одиниці, які приймають сигнали, обробляють їх та генерують вихідні сигнали на основі певних порогових значень. Вони використовували математичні моделі, щоб описати цей процес. Ця ідея стала основою для подальшого розвитку штучних нейронних мереж.

Сучасні ШНМ використовують аналогічний підхід, де штучний нейрон приймає вхідні сигнали, обчислює їхню суму з вагами, застосовує функцію активації та генерує вихідний сигнал. Це моделювання дозволяє ШНМ вирішувати різноманітні завдання.

Таким чином, ідея моделювання штучними нейронами функцій біологічних нейронів в мозку стала фундаментом для розвитку штучних нейронних мереж та глибокого навчання, і вона дала початок сучасній галузі машинного навчання, яка активно використовується в різних сферах технологій.

Процес подачі вхідних сигналів на штучний нейрон, а також інтерпретацію цього процесу на прикладі біологічного нейрона:

Вхідні сигнали, позначені як  $x_1, x_2, \dots, x_N$ , представляють собою інформацію, яка подається на вхід до штучного нейрона. У біологічних нейронах ці сигнали відповідають електричним потенціалам, які надходять через синапси.



Кожен синапс або зв'язок має свою вагу, яка визначає важливість вхідного сигналу, який проходить через цей синапс. Вага впливає на те, наскільки сильно вхідний сигнал впливає на внутрішні обчислення нейрона.

Штучний нейрон обчислює ваговану суму вхідних сигналів, де кожний сигнал множиться на відповідну вагу і додається до інших вагованих сигналів. Ця сума позначається як вагована сума (weighted sum) і може бути представлена у вигляді математичної операції.

Після обчислення вагової суми вхідних сигналів, штучний нейрон може застосовувати функцію активації. Ця функція визначає, чи буде нейрон активним (віддасть вихідний сигнал) на основі значення вагової суми.

Вихідний сигнал штучного нейрона, який зазвичай позначається як "у", є результатом функції активації. Цей вихід може бути поданий як вхід для інших нейронів або використовуватися в якості вихідного значення штучного нейрона.

Цей процес імітує спосіб функціонування біологічного нейрона у мозку, де вхідні сигнали надходять через синапси з різними вагами, і результатом є видача вихідного сигналу, який передає інформацію до інших частин нервової системи. У штучних нейронних мережах цей процес дозволяє моделювати різні види обчислень та приймати рішення в залежності від вхідних даних.




Рис.1. - Модель штучного нейрона

Функція активації грає ключову роль у визначенні нелінійності та поведінки штучного нейрона. Функція активації є необхідною для того, щоб нейрони штучної нейронної мережі могли вирішувати складні завдання, які вимагають нелінійних залежностей між вхідними та вихідними даними.

Функція активації приймає ваговану суму вхідних сигналів (після застосування ваг) як свій аргумент і генерує вихідний сигнал нейрона. Вихідний сигнал може бути дійсним або цілим числом і визначається конкретним видом функції активації.

Вибір підходящої функції активації залежить від конкретної задачі та може впливати на продуктивність та навчання нейронної мережі. Наявність функції активації дозволяє штучним нейронам надавати мережі здатність навчатися та адаптуватися до складних залежностей у вхідних даних.

Як наслідок, після розробки алгоритмів навчання, отримані моделі стали використовуватися в практичних цілях: в задачах прогнозування, для розпізнавання образів, в задачах керування та інших [1].

Актуальними на сьогоднішній день є задачі використання нейромережових методів для розпізнавання зображень. Перспектива їх використання досить яскрава в світлі вирішення нетрадиційних проблем і є ключем до цілої технології.

Це пов'язано з рядом факторів:

Завдяки розвитку технологій, доступ до великих обсягів даних та зображень стає все більш доступним. Це створює можливість навчати глибокі нейронні мережі на великих наборах даних, що підвищує їхню ефективність у розпізнаванні об'єктів на зображеннях.

З'явилися нові архітектури нейронних мереж, які спеціалізуються на задачах розпізнавання об'єктів. Сверточні нейронні мережі стали стандартом у багатьох завданнях обробки зображень.

Розпізнавання об'єктів на зображеннях має безліч застосувань у різних галузях. Це робить цю технологію дуже важливою.

Сучасні нейронні мережі здатні досягати високої точності у завданнях розпізнавання об'єктів на зображеннях, навіть у складних умовах та з великою кількістю класів об'єктів.

З'явилися спеціалізовані апаратні рішення, такі як графічні процесори (GPU) та тензорні прискорювачі, які сприяють ефективному навчанню та виконанню нейронних мереж для розпізнавання зображень.

У результаті цих факторів, нейромережеві методи стали важливим інструментом для розв'язання різноманітних завдань у сфері обробки зображень. Вони використовуються для вдосконалення автоматичного розпізнавання об'єктів, аналізу зображень. Розвиток цієї галузі продовжується, і її перспективи залишаються дуже обіцяючими для подальших досягнень в області штучного інтелекту.

Мета роботи, огляд та дослідження нейромережевих методів для розпізнавання графічних образів, є дуже цікавою і важливою. Такий огляд може стати важливим внеском у галузь обробки зображень та машинного навчання. Ця робота може стати корисною для тих, хто цікавиться обробкою зображень, машинним навчанням та розпізнаванням

## 1.2 Теорія розпізнавання зображень

Теорія розпізнавання зображень - це галузь інформатики та обробки зображень, яка вивчає методи та алгоритми для автоматичного аналізу та інтерпретації зображень. Основна мета цієї теорії полягає в тому, щоб розробити алгоритми та системи, які дозволяють комп'ютерам розпізнавати об'єкти, форми, образи та інші характеристики на цифрових зображеннях або відео.

Основні поняття та аспекти теорії розпізнавання зображень включають таке:

1. Попередня обробка зображень: Цей етап передбачає фільтрацію, підсилення контрасту, видалення шуму та інші методи підготовки зображення перед подальшим аналізом.
2. Витягнення ознак (фіч): Під час цього етапу система виділяє характеристики або ознаки з зображення, які можуть бути корисними для розпізнавання. Це можуть бути текстурні ознаки, контурні ознаки, колірні характеристики тощо.
3. Класифікація: На цьому етапі система використовує витягнуті ознаки для класифікації зображення на певну категорію або клас. Це може бути задачею бінарної класифікації (наприклад, "є об'єкт на зображенні" чи "немає об'єкта на зображенні") або багатокласовою класифікацією (розпізнавання багатьох класів об'єктів).
4. Навчання: Багато систем розпізнавання зображень вимагають попереднього навчання на підготовчих даних. Під час навчання модель вивчає, які ознаки є характерними для різних класів об'єктів.
5. Оцінка і валідація: Для визначення точності та ефективності системи розпізнавання зображень важливо проводити оцінку і валідацію, які включають у себе тестування моделі на нових даних.
6. Застосування: Розпізнавання зображень має багато практичних застосувань, включаючи розпізнавання образів, автоматичну індексацію та

пошук зображень, відеоспостереження, автоматичну навігацію безпілотного транспорту, та багато інших областей.

Теорія розпізнавання зображень спирається на концепції машинного навчання, нейромереж та комп'ютерного зору, і вона є важливою складовою для багатьох інноваційних технологій та застосувань, які мають вплив на багато аспектів нашого життя.

Теорія розпізнавання образів існує як розділ інформатики та суміжних дисциплін, що розвиває методи класифікації та ідентифікації об'єктів різної природи: сигналів, ситуацій, предметів, що характеризуються вичерпною кількістю деяких ознак [3]

Для розпізнавання окремих зображень використовують наступні види нейронних мереж:

- багат шарові нейронні мережі (БНМ) або нейронні мережі глибокого навчання є дуже потужними інструментами для розпізнавання окремих зображень і багатьох інших завдань у сфері обробки зображень та машинного навчання. Архітектура багат шарової нейронної мережі складається з декількох типів шарів, які працюють разом для виконання завдання розпізнавання об'єктів на зображеннях. Основні типи шарів, що використовуються в БНМ, включають:

Вхідний шар - цей шар приймає вхідні дані, які можуть бути зображеннями, іншими векторами або даними різних типів. Зазвичай, зображення розкладаються на пікселі, і кожен піксель стає входом для нейронної мережі.

Приховані шари - є проміжними шарами між вхідним та вихідним шарами. Вони складаються з нейронів (узлів), які виконують лінійні операції та активаційні функції. Багат шаровість полягає в тому, що може бути декілька прихованих шарів, що дозволяє моделі навчатися вищим рівням абстракції та складнішим залежностям у даних.

Вихідний шар - цей шар відповідає за вихідні дані моделі. У завданні розпізнавання об'єктів на зображеннях, вихідний шар може мати нейрони, кожен з яких відповідає певному класу або категорії об'єктів. Функція

активації вихідного шару зазвичай використовується для створення ймовірнісних оцінок класів.

Функції активації - кожен нейрон у прихованих та вихідних шарах використовує функцію активації для нелінійного перетворення вхідних сигналів.

Зв'язки між шарами - кожен нейрон в одному шарі з'єднаний з нейронами в попередньому та наступному шарі. Зв'язки між нейронами мають ваги, які навчаються під час процесу навчання, і вони використовуються для передачі інформації від одного шару до іншого.

У процесі навчання багатошарової нейронної мережі ваги змінюються так, щоб модель могла навчитися розпізнавати об'єкти на зображеннях. Навчання може вимагати великої кількості даних та обчислювальних ресурсів. Після навчання модель може бути використана для класифікації нових зображень.

Багатошарові нейронні мережі демонструють вражаючі результати в задачах розпізнавання образів, і їх архітектура може бути додатково оптимізована та модифікована для конкретних завдань та даних.

- нейронні мережі високого порядку (НМВП), які мають лише один шар, представляють собою цікавий клас нейронних мереж, які відрізняються від багатошарових нейронних мереж (БНМ) за кількістю шарів, але також можуть бути дуже ефективними у розпізнаванні об'єктів та формуванні складних розділяючих поверхонь. Основна особливість НМВП полягає в їхній архітектурі та способі обчислення.

Основні риси та принципи роботи Нейронних Мереж Високого Порядку:

Один шар нейронів, НМВП складаються з одного шару нейронів, який отримує вхідні дані і генерує вихідні дані. Це означає, що вони не мають прихованих шарів, які зазвичай присутні в БНМ.

Складні розділяючі поверхні, основна особливість НМВП полягає в їхній здатності формувати складні розділяючі поверхні, навіть з одного шару. Це

досягається завдяки великій кількості нейронів у цьому шарі та використанню нелінійних функцій активації.

Функція активації, НМВП використовують нелінійну функцію активації для того, щоб нейрони в цьому шарі могли виявляти складні залежності між вхідними та вихідними даними.

Навчання, НМВП може вимагати методів оптимізації, таких як зворотній розподіл помилки (Backpropagation), для коригування ваг та забезпечення відповідності вихідних даних бажаним цілям.

Застосування, НМВП можуть бути використані для багатьох завдань, включаючи класифікацію, регресію, розпізнавання об'єктів та інші завдання обробки зображень та машинного навчання.

Основна відмінність від БНМ полягає в простоті архітектури НМВП, але вони можуть бути дуже потужними, особливо, коли використовуються великі кількості нейронів та нелінійні функції активації. Вони можуть бути особливо корисними для задач, де важливо виявлення складних взаємозв'язків у даних без необхідності глибокого навчання.

Звісно, вибір між БНМ та НМВП залежить від конкретної задачі та доступних ресурсів, і у багатьох випадках може бути корисним спробувати обидва підходи та порівняти їх ефективність.

- НМ Хопфілда (НМХ) буває одношарова і повношарова (зв'язки нейронів на самих себе відсутні), її виходи пов'язані з входами [1]. Нейронні мережі Хопфілда (НМХ) представляють собою особливий тип нейронних мереж, які відрізняються від багатошарових нейронних мереж (БНМ) та мають деякі унікальні властивості. Одна з основних особливостей НМХ - це їх релаксаційна природа.

Основні характеристики та застосування Нейронних Мереж Хопфілда:

НМХ функціонують у релаксаційному режимі, що означає, що вони перебувають у стані, поки не досягнуть стабільного стану. Вони обчислюють вихідні значення повільно, і в цьому контексті вони можуть служити для

вирішення оптимізаційних завдань, знаходження локальних мінімумів функцій енергії тощо.

НМХ використовуються в різних областях, включаючи оптимізацію, асоціативну пам'ять, розпізнавання образів, вирішення комбінаторних задач і навіть в нейрокомп'ютерах для моделювання деяких аспектів роботи мозку.

Одним з основних застосувань НМХ є асоціативна пам'ять. Вони можуть використовуватися для асоціювання вхідних шаблонів з вихідними, тобто можуть відновлювати асоціативні зв'язки між різними патернами.

НМХ працюють на основі енергійних функцій, і їхнім завданням є мінімізація цих функцій для досягнення стабільного стану. Ця властивість дозволяє їм знаходити локальні мінімуми функцій енергії, що може бути корисним для оптимізаційних завдань.

НМХ мають одношарову архітектуру, що означає, що вони мають просту структуру з одним шаром нейронів та зв'язками між ними.

Хоча НМХ мають свої унікальні застосування, вони також мають обмеження, і їх ефективність обмежена певними класами завдань. Вони відмінно підходять для розв'язання завдань асоціативної пам'яті та деяких оптимізаційних завдань, але для більш складних завдань розпізнавання образів і класифікації, частіше використовуються багатошарові нейронні мережі.

Застосування даної мережі відзначається хорошим результатом відновлення трьохвимірної форми (також для зображень облич) і високою швидкістю.

- самоорганізуючі нейронні мережі Кохонена (СНМК) забезпечують топологічне упорядкування вхідного простору образів, також відомі як карти Кохонена, є типом нейронних мереж, які використовуються для топологічного упорядкування вхідного простору образів. Основною особливістю СНМК є їх здатність до безперервного топологічного відображення вхідних даних на нейрони в вихідному шарі.

Основні характеристики та принципи роботи Самоорганізованих Нейронних Мереж Кохонена:



- СНМК мають топологічну структуру, що передбачає певне співвідношення між нейронами в вихідному шарі. Це означає, що сусідні нейрони в мережі Кохонена відображають схожі вхідні образи, а віддалені нейрони відображають відмінні образи.

- СНМК мають здатність до навчання, в процесі якого вони адаптуються до вхідних даних. Під час навчання нейрони в мережі підлаштовують свої ваги так, щоб найбільше активуватися на певні вхідні образи.

- Основний принцип навчання СНМК - це конкурентний процес, в якому нейрони конкурують між собою за можливість стати "переможцем" і відобразити поточний вхідний образ. Переможцем стає нейрон, чий простір у вхідному просторі образів найбільше співпадає з поточним вхідним образом.

- Процес навчання СНМК призводить до самоорганізації, тобто нейрони у вихідному шарі утворюють топологічну карту, де схожі вхідні образи відображаються близько одне до одного, створюючи топологічну структуру.

- СНМК використовуються для завдань, де важлива структурна організація вхідних даних, таких як кластеризація, впорядкування та асоціативна пам'ять. Вони також застосовуються в областях машинного зору та розпізнавання образів.

Вони дозволяють топологічно безперервно відображати вхідний  $n$ -мірний простір в вихідний  $m$ -мірний,  $m \ll n$ . Вхідний образ проектується на деяку позицію в мережі, кодованих як положення активованого вузла. На відміну від більшості інших методів класифікації і кластеризації, топологічне упорядкування класів зберігає на виході подобу у вхідних образах [2].

Самоорганізовані нейронні мережі Кохонена можуть бути корисним інструментом для вирішення завдань, де важливо виявлення структури та топологічних залежностей у даних. Вони дозволяють створювати внутрішню топологічну карту, яка допомагає в розумінні відношень між вхідними образами.

- когнітрон - це нейронна мережа, розроблена Джефрі Гінтоном, Терренсом Сейджом та Девідом Амералом в 1979 році, яка була інспірована

структурою та функціями зорової кори мозку людини. Когнітрон має ієрархічну багат шарову організацію, схожу на будову зорової кори, і був розроблений для завдань розпізнавання образів.

Основні характеристики Когнітрона включають наступне:

Когнітрон має ієрархічну структуру, подібну до шарів зорової кори мозку. Він складається з різних рівнів або шарів, де кожен шар відповідає за розпізнавання певних абстрактних ознак або патернів.

В Когнітроні використовуються фільтри Габора, що дозволяють виділяти різні текстурні та формові характеристики вхідних зображень. Ці фільтри стаються базовими блоками для розпізнавання ознак.

Когнітрон виявляє локальні залежності між пікселями вхідних зображень, аналізуючи малий регіон на вхідному зображенні та виділяючи важливі ознаки в цьому регіоні.

Мережа також має механізм локальної інгібіції, який допомагає відсіяти менш важливі ознаки і підсилити важливіші.

Когнітрон навчається шляхом пропускання тренувальних зображень через мережу і змінюючи ваги фільтрів так, щоб вони найкраще виявляли важливі ознаки.

Когнітрон був однією з перших спроб створення моделі для розпізнавання образів, яка інспіровалася біологічною структурою мозку. Він є попередником багатьох інших моделей глибокого навчання та конволюційних нейронних мереж, які використовуються у сучасних системах розпізнавання образів, обробки зображень та машинного навчання.

Когнітрон є потужним засобом розпізнавання зображень, але потребує високих обчислювальних затрат, які на сьогодні недосяжні[4].

### 1.3 Методи класифікації зображень

Методи класифікації зображень використовуються для автоматичної ідентифікації об'єктів, патернів, класів або категорій на цифрових зображеннях. Це важлива задача в областях комп'ютерного зору, машинного навчання та обробки зображень. Ось декілька основних методів класифікації зображень:

1. Метод опорних векторів (SVM): SVM - це метод машинного навчання, який використовується для бінарної та багатокласової класифікації. Він шукає гіперплощину, яка найкраще розділяє дані у просторі ознак, забезпечуючи максимальний відступ між класами.

2. Нейронні мережі: Глибокі нейронні мережі, такі як згорткові нейронні мережі (CNN), є потужними для класифікації зображень. Вони автоматично визначають характеристики та здатні вирішувати складні завдання класифікації на основі зображень.

3. Древа рішень: Древа рішень розділяють дані на основі набору правил, які можуть бути використані для класифікації зображень. Вони прості для інтерпретації та можуть застосовуватися для обробки зображень.

4. Random Forest і Bagging: Random Forest - це ансамбль дерев рішень, який дозволяє покращити точність класифікації. Bagging використовується для створення багатьох класифікаторів і об'єднання їх результатів.

5. Методи глибокого навчання: Окрім CNN, існують інші глибокі архітектури, такі як рекурентні нейронні мережі (RNN) і довільні глибокі нейронні мережі, які можуть використовуватися для класифікації зображень.

6. Метод градієнтного бустінгу: Градієнтний бустінг - це метод, який поєднує багато слабких класифікаторів для отримання сильного класифікатора. Він добре працює для класифікації зображень.

7. Методи основані на гістограмах: Ці методи використовують статистичну інформацію, зібрану з пікселів зображення, для класифікації.

8. Методи основані на байесовському класифікаторі: Вони використовують теорію ймовірності і правила Байеса для класифікації зображень.

9. Передвідборні методи: Методи передвідбору допомагають вибрати найважливіші ознаки або патерни на зображеннях перед їх класифікацією.

10. Передні витягувачі ознак: Застосування передніх витягувачів ознак, які навчаються попередньо на великому наборі даних (наприклад, ImageNet), є дієвим способом отримати ознаки для класифікації.

Вибір конкретного методу залежить від завдання, доступних даних, обсягу даних та багатьох інших факторів. Комбінування різних методів та технік часто призводить до досягнення найкращих результатів у класифікації зображень.

При постановці класичної задачі розпізнавання об'єктів, незалежно від того, чи використовуються нейронні мережі, чи інші методи, дуже важливо використовувати математичну мову і логічні міркування для формалізації завдання і розв'язання його. Математична мова надає можливість чітко визначити вхідні та вихідні дані, побудувати математичні моделі для опису процесу розпізнавання, інтерпретувати результати та оцінити точність роботи системи.

Основні етапи постановки класичної задачі розпізнавання об'єктів включають:

Спершу потрібно чітко визначити, що саме потрібно розпізнавати і які завдання повинні бути вирішені. Це може включати в себе вибір класів об'єктів для розпізнавання, визначення характеристик або ознак для аналізу, та встановлення критеріїв успішного розпізнавання.

Отримання набору даних, які використовуються для навчання та тестування системи розпізнавання. Дані можуть бути зібрані, анотовані та підготовлені для подальшої обробки.

Вибір математичної моделі або алгоритму, які будуть використовуватися для розпізнавання об'єктів. Це може бути нейронна мережа, метод опорних векторів (SVM), метод глибокого навчання або інший алгоритм.

Вибір і визначення ознак або характеристик, які будуть використовуватися для опису об'єктів на вхідних зображеннях або даних. Це можуть бути розмір, колір, текстура, форма тощо.

Застосування навчання до моделі з використанням набору даних для створення моделі, яка може розпізнавати об'єкти.

Використання тестового набору даних для оцінки точності та ефективності моделі. Визначення метрик оцінки, таких як точність, чутливість, специфічність тощо.

У разі необхідності налаштування параметрів моделі або оптимізація процесу розпізнавання.

Після успішного тестування і відповідної оцінки можна впровадити систему розпізнавання в реальній виробничий або дослідницький процес.

Математична мова допомагає систематизувати і структурувати роботу над задачею розпізнавання об'єктів, що дозволяє досягти кращих результатів і розуміння процесу.

При постановці класичної задачі розпізнавання об'єктів можна використовувати математичну мову та логічні міркування, що базуються на математичних принципах. Цей підхід відомий як "класичний" або "традиційний" підхід до розпізнавання об'єктів. Він зазвичай використовує створені правила і фільтри для аналізу вхідних даних і прийняття рішень.

Однак існують альтернативні підходи до розпізнавання об'єктів, які використовують машинне навчання і штучні нейронні мережі. Ці підходи дозволяють системам самостійно вивчати залежності в даних і вирішувати задачу розпізнавання об'єктів на основі великої кількості прикладів навчання.

Основні особливості підходу з використанням машинного навчання та нейронних мереж:

Замість ручного створення правил і фільтрів, система навчається на основі даних. Це означає, що модель вивчається адаптуватися до вхідних даних і визначати важливі ознаки та залежності самостійно.

Машинне навчання може використовувати методи автоматичного витягнення ознак, що дозволяє моделі визначити найважливіші ознаки для розпізнавання об'єктів.

Машинне навчання дозволяє моделям виявляти складні залежності в даних, які можуть бути важко або неможливо виразити за допомогою класичних правил.

Глибоке навчання, зокрема глибокі нейронні мережі, дозволяє створювати моделі зі складною архітектурою, які виявляють глибокі залежності в даних.

Моделі, навчені за допомогою машинного навчання, можуть легко адаптуватися до змін в даних, що робить їх гнучкими.

Обираючи між класичним і підходом машинного навчання для розпізнавання об'єктів, важливо враховувати специфіку завдання, доступні дані та потреби проекту. У багатьох випадках сучасні підходи на основі машинного навчання та нейронних мереж можуть забезпечити кращу продуктивність і точність.

Варто відзначити, що терміни "розпізнавання" та "класифікація" не є повністю взаємозамінними і мають різні сфери застосування. Кожен з цих термінів відображає певний аспект аналізу та обробки даних. Давайте розглянемо загальні елементи моделі класифікації:

Модель класифікації використовується для призначення об'єктів або даних до одного з певних класів або категорій на основі їх характеристик або ознак.

Основні елементи моделі класифікації включають:

Класи, це категорії або мітки, до яких ми хочемо призначити об'єкти. Наприклад, якщо ми аналізуємо зображення зелених насаджень (наприклад садів), класами можуть бути "яблука", "груші", "банани" і т.д.

Ознаки або характеристики представляють собою властивості об'єктів, які використовуються для призначення класів. Наприклад, для розпізнавання сільськогосподарських культур ознаками можуть бути кольори, форми, розміри і т.д.

Модель класифікації, це алгоритм або система, яка вивчає залежності між ознаками та класами на основі навчальних даних. Модель вирішує, до якого класу належить кожен об'єкт.

Навчальні дані, це набір прикладів, для яких відомі правильні класи. Модель навчається на цих даних для побудови правильних залежностей між ознаками і класами.

Тестові дані, це набір об'єктів, для яких потрібно визначити класи на основі навченої моделі. Тестові дані використовуються для оцінки точності та ефективності моделі.

Метрики класифікації, це метрики або показники, які використовуються для визначення того, наскільки ефективно модель класифікації працює. Прикладами метрик є точність, чутливість, специфічність і т.д.

Загальна ідея моделі класифікації полягає в тому, щоб навчити систему визначати класи для нових об'єктів на основі їх ознак.

Додатково розглянемо загальні елементи моделі класифікації.

*Клас* - множина об'єктів, що мають спільні властивості. Для об'єктів одного класу передбачається наявність «схожості». Для задачі розпізнавання може бути визначено довільну кількість класів, більше одного. Кількість класів позначається числом  $S$ . Кожен клас має свою ідентифікуючу мітку класу [3].

*Класифікація* - процес призначення міток класу об'єктам, відповідно до певного опису властивостей цих об'єктів.

Класифікатор – це інструмент для присвоєння міток класам, який в якості вхідних даних отримує перелік ознак об'єкта. До одного з найпоширеніших способів класифікації можна віднести спосіб, що базується на описі об'єктів з використанням ознак, де кожен об'єкт характеризується набором числових або нечислових ознак.

Проте існують типи даних для яких відкриті ознаки не дають високої точності класифікації, наприклад, колір точок зображень. Загальна класифікація зображень собак і автомобілів є дуже простою для людини і водночас складною для машини. Причиною цього є можливість людини сприймати «приховані ознаки» недоступні для машини, такі як морда собаки або колеса автомобіля [3].

*Верифікація* - процес зіставлення досліджуваного об'єкта із однією моделлю об'єкта або описом класу. [3]

Визначимо терміни "образ" та "простір ознак" в контексті задач розпізнавання об'єктів.

Образ (зображення, паттерн): Образ - це представлення об'єкта, яке включає в себе значення різних ознак або характеристик, що описують цей об'єкт. Образ може бути представлений у вигляді вектора ознак, де кожен компонент вектора відповідає одній певній ознаці. Наприклад, якщо ми розглядаємо зображення частки земельної ділянки, то образом може бути вектор ознак, що включає кольори, текстури, форму і т.д. Іншими словами, образ - це репрезентація об'єкта у вигляді даних.

Простір ознак - це  $N$ -вимірний простір, де  $N$  відповідає кількості ознак, що описують об'єкти. Кожна ознака представляє собою одне вимірення у цьому просторі. Простір ознак може бути використаний для геометричного аналізу та порівняння об'єктів. Наприклад, якщо ми розглядаємо зображення частки земельної ділянки та маємо ознаки, такі як розмір, колір та текстура, то кожна земельна ділянка може бути представлений як точка у просторі ознак, де кожна координата відповідає одній ознаці.



Простір ознак і образи є важливими поняттями в задачах розпізнавання об'єктів, оскільки вони допомагають структурувати та аналізувати дані, що використовуються для класифікації або розпізнавання об'єктів. Розуміння цих понять допомагає інженерам та дослідникам створювати ефективні моделі та алгоритми для обробки і аналізу даних.

Сутність розпізнавання образів полягає в тому, щоб призначити вхідним даним (зображенням) певні класи або категорії, виділяючи важливі та істотні ознаки або характеристики, які характеризують об'єкти цих класів. Це допомагає відокремити суттєву інформацію від незначущих деталей і робить можливим автоматичне розпізнавання та класифікацію об'єктів.

Основні кроки у розпізнаванні образів включають в себе:

Вибір важливих ознак або характеристик, які найкраще описують об'єкти і можуть бути використані для їх класифікації.

Витягнення значень обраних ознак з вхідних даних. Наприклад, для зображень це може бути витягнення кольорів, текстур, форм та інших характеристик.

Використання алгоритмів або моделей для визначення до якого класу належить об'єкт на основі витягнутих ознак.

Оцінка точності та ефективності розпізнавання шляхом порівняння прогнозів з реальними мітками класів.

Він допомагає автоматизувати аналіз та розуміння великих обсягів даних, що має велике значення в сучасному світі.

Іншими словами, розпізнавання образів можна визначити, як віднесення вихідних даних до певного класу за допомогою виділення істотних ознак або властивостей, які характеризують ці дані, із загальної маси несуттєвих деталей.

Найчастіше вихідним матеріалом служить отримане із камери зображення. Постановку завдання можна сформулювати, як одержання векторів, що складаються з ознак для кожного класу на зображенні. Процес

можна розглядати як процес кодування, що полягає в присвоєнні значення кожної ознаки із простору ознак для кожного класу.

Іншим завданням розпізнавання є виділення із вихідних зображень характерних ознак та/або властивостей. Це завдання можна віднести до попередньої обробки. Ознака повинна являти собою характерну властивість конкретного класу, при цьому загальну для цього класу.

Міжкласові ознаки – це ознаки, що визначають відмінності між класами. Загальні ознаки, що властиві усім класам, не несуть корисної інформації, тому для задачі розпізнавання об'єктів не розглядаються як характерні.

Вибрати правильні ознаки - одна із важливих задач побудови систем розпізнавання.

Вибір правильних ознак (функцій) є однією з найважливіших задач у побудові систем розпізнавання об'єктів на зображеннях, пов'язане з обробкою даних. Правильні ознаки допомагають моделі визначати важливі патерни та залежності у даних і забезпечують її здатність до точного розпізнавання та класифікації.

Ось кілька важливих аспектів вибору правильних ознак:

1. Знання галузі або сфери, з якою пов'язані дані, дуже важливе для вибору правильних ознак. Розуміння того, які ознаки можуть бути важливими для завдання, допомагає визначити, які функції слід використовувати.
2. Перед вибором ознак важливо аналізувати самі дані. Це може включати в себе візуалізацію даних, статистичний аналіз та вивчення розподілу ознак.
3. Деякі ознаки можуть бути непотрібними або корельованими іншими. Важливо використовувати методи відбору ознак, щоб вибрати найкращі та видалити зайві.
4. Інженерія ознак включає в себе створення нових ознак на основі існуючих. Це може покращити здатність моделі до розпізнавання, додавши додаткові контекстні або важливі ознаки.

5. Зазвичай, дані слід нормалізувати або стандартизувати перед використанням у моделі, щоб уникнути проблем з різницею в масштабі між ознаками.

6. Після вибору та інженерії ознак важливо спостерігати за роботою моделі та враховувати її відгуки. Якщо модель має низьку точність або робить невірні передбачення, може бути необхідно переглянути та вдосконалити ознаки.

Вибір правильних ознак - це творчий та емпіричний процес, який вимагає спроб та помилок. Досвід та специфіка завдання великою мірою впливають на успіх цього процесу.

## Висновок до розділу 1

У даному розділі було розглянуто постановку задачі роботи, а також проведений огляд існуючих нейромережевих методів класифікації зображень з даної тематики, були окреслені їх плюси та мінуси. Загалом до переваг розглянутих нейронних мереж можна віднести надійне розпізнавання зображень, швидке навчання та високу швидкодію.

Спостереження відносно переваг нейронних мереж щодо надійного розпізнавання зображень, швидкого навчання та високої швидкодії в багатьох випадках вірні, але також існують деякі важливі відомості, які варто враховувати:

1. Надійне розпізнавання зображень, глибокі нейронні мережі, зокрема згорткові нейронні мережі (CNN), показали вражаючі результати в завданнях розпізнавання зображень, зокрема в областях, таких як класифікація об'єктів та семантична сегментація. Вони здатні автоматично виявляти складні ознаки та залежності від зображень.

2. Швидке навчання, нейронні мережі можуть бути швидко навчені на великих обсягах даних завдяки розпаралеленому обчисленню та використанню GPU. Багато бібліотек та фреймворків (наприклад, TensorFlow та PyTorch) пропонують оптимізації для ефективного навчання.

3. Висока швидкодія, деякі архітектури нейронних мереж можуть бути вдосконалені для виконання інференсу (прогнозування) з високою швидкістю, що робить їх придатними для реальних застосувань, включаючи вбудовані системи та мобільні додатки.

Проте, важливо відзначити, що ефективність нейронних мереж може залежати від кількох факторів, таких як обсяг доступних даних, якість навчання, вибір архітектури моделі, гіперпараметри, ресурси обчислення та інші. Також, глибокі нейронні мережі можуть бути вимогливими до ресурсів, і для деяких завдань може бути необхідно використовувати спеціалізовану апаратну або хмарну інфраструктуру.

Окрім того, нейронні мережі не завжди є найкращим рішенням для всіх завдань. У деяких випадках спеціалізовані методи чи алгоритми можуть бути більш ефективними або менш вимогливими до ресурсів. Таким чином, вибір підходу до розпізнавання та моделей повинен базуватися на конкретних потребах і обставинах завдання.

Проте при застосуванні цих методів до зображень тривимірних об'єктів виникають труднощі, пов'язані з просторовими поворотами і зміною умов освітленості. Зображення для різних кутів повороту об'єкта суттєво різняться, частина інформації на зображенні втрачається, виникає нова, специфічна для даного кута. Такі обмеження зазвичай долаються шляхом пред'явлення всіляких варіацій зображення (різні повороти і освітленість) при навчанні, але побудова такого навчального набору - важке завдання, і найчастіше такі набори недоступні.

Як показує світовий досвід, ці проблеми не можуть бути повністю вирішені вибором вихідного представлення даних. Отже необхідно, щоб система самостійно витягала характеристики, інваріантні до змін всередині класу і максимально репрезентативні по відношенню до міжкласових змін. Таке завдання в загальному вигляді для систем розпізнавання осіб ще не вирішене, але існують методи, які показують можливості вирішення окремих аспектів [1] (інваріантність до освітлення, синтез повернутих в просторі зображень на основі навчання). Вказана вище проблема і є головним недоліком використання існуючих нейронних мереж для розпізнавання образів, і потребує подальшого вивчення та вирішення у майбутньому.

Наступний розділ буде присвячений аналізу існуючих методів вирішення задачі класифікації зображень сільськогосподарських територій за допомогою нейромережових методів.

## РОЗДІЛ 2. ЗГОРТКОВА НЕЙРОННА МЕРЕЖА

Згорткова нейронна мережа (Convolutional Neural Network або CNN) - це вид штучної нейронної мережі, який особливо ефективний у роботі з багатовимірними даними, такими як зображення та відео. Цей тип нейронних мереж спеціалізується на виявленні патернів та характерних ознак у вхідних даних.

Основна ідея згорткових нейронних мереж полягає у використанні фільтрів (які також називають ядром) для сканування вхідних даних та виділення важливих ознак. Кожен фільтр шукає конкретний ознаку в даних, такі як риси предмету у зображенні або текстурні особливості.

Основні складові згорткової нейронної мережі включають в себе:

1. Згорткові шари (Convolutional Layers): Вони використовують фільтри для виявлення ознак у вхідних даних. Кожен фільтр проводить операцію згортки над вхідними даними та створює вихідну карту ознак.
2. Пулінгові шари (Pooling Layers): Ці шари використовуються для зменшення розмірності вихідних даних після згортки, зберігаючи при цьому найважливіші ознаки.
3. Повнозв'язані шари (Fully Connected Layers): Після згорткових та пулінгових шарів, інформація переводиться в повнозв'язані шари для прийняття рішення на основі зібраної інформації.

Згорткові нейронні мережі широко використовуються у завданнях комп'ютерного зору, таких як розпізнавання об'єктів, класифікація зображень та багато інших. Вони також можуть бути застосовані в інших областях, де важливий аналіз багатовимірних даних.

Так, Convolutional Neural Networks (CNN) дійсно є популярною та ефективною архітектурою для обробки зображень сільськогосподарських територій і великої кількості інших завдань комп'ютерного зору. Ось деякі основні причини, чому CNN підходять для таких задач:

1. Здатність розпізнавати візуальні ознаки: CNN можуть ефективно виявляти різні візуальні ознаки, такі як форми, текстури, кольори та шаблони на зображеннях, що дозволяє їм класифікувати об'єкти та області на землі.

2. Збереження просторової інформації: CNN зберігають просторову структуру зображень завдяки операції згортки, що дозволяє їм легко виявляти об'єкти та залежності між пікселями.

3. Глибокі неймережі: Можливість побудови глибоких неймережей дозволяє моделям навчатися складним шар за шаром представленням, що може підвищити точність класифікації.

4. Перенавчання і аугментація даних (на цьому етапі створюються нові навчальні дані із вже існуючих): CNN можуть бути добре впоратися з перенавчанням, коли є достатньо даних. Також можна використовувати аугментацію даних, щоб розширити тренувальний набір і покращити загальну продуктивність моделі. На цьому етапі збільшується розмір початкових даних, що покращує результати побудованої моделі.

5. Передне навчання та трансферне навчання: Можна використовувати передне навчання на великих наборах зображень, таких як ImageNet, і застосовувати трансферне навчання для задач класифікації сільськогосподарських територій, що може допомогти в розв'язанні завдань з обмеженими даними.

Зазначена архітектура стала стандартом у багатьох задачах комп'ютерного зору, включаючи розпізнавання об'єктів на зображеннях, сегментацію та класифікацію. Використання CNN в дослідженнях сільськогосподарських територій може допомогти в розв'язанні багатьох практичних завдань, пов'язаних з сільським господарством і земельним використанням.

Архітектура згорткових нейронних мереж призначена і використовується для ефективного розпізнавання зображень, де чергуються

згорткові шари (convolutions) з нелінійними функціями активації (ReLU або гіперболічний тангенс tanh) і шари об'єднання або підвибірки (pooling layers).

На відміну від мережі прямого поширення, де кожен вхідний нейрон з'єднується з вихідним нейроном в наступному шарі, взгорткових мережах для отримання вихідних значень застосовуються згортки над кожним вхідним шаром. В операції згортки використовується матриця ваг невеликого розміру, яка проходить повсюду поточному шарі, формуючи після кожного зсуву сигнал активації для нейрона наступного шару з аналогічною позицією. Ця матриця називається ядром згортки; вона використовується для різних нейронів вихідного шару.

## 2.1 Гібридні архітектури нейронних мереж

Гібридні архітектури нейронних мереж - це архітектури, які комбінують різні типи нейронних мереж та їхні компоненти для досягнення певних завдань. Це означає, що в одній моделі можуть бути об'єднані різні типи штучних нейронних мереж, такі як згорткові мережі (CNN), рекурентні мережі (RNN), локальні та глобальні зв'язки, а також підмережі.

Основні переваги гібридної архітектури нейронних мереж включають:

1. Покращення точності, комбінування різних типів мереж може допомогти вирішити завдання, для яких окремі типи мереж не є належними.
2. Універсальність, гібридні моделі можуть використовуватися для різних задач машинного навчання та обробки даних, оскільки вони поєднують у собі різні компоненти.
3. Адаптованість, можемо налаштовувати та модифікувати гібридні архітектури, щоб вони відповідали конкретним потребам вашого завдання.



4. Зниження обчислювальних витрат, деякі гібридні архітектури можуть бути оптимізовані для зменшення кількості параметрів та обчислювальних операцій.

Прикладами гібридної архітектури можуть бути моделі, які поєднують у собі CNN для виявлення ознак у вхідних зображеннях та RNN для обробки послідовних даних, таких як текст. Також можна комбінувати автокодери з CNN для здійснення глибокого навчання зі зменшенням розмірності даних.

Гібридні архітектури нейронних мереж є потужним інструментом в галузі глибокого навчання та машинного навчання і використовуються для вирішення складних завдань, які вимагають обробки різних типів даних та інформації.

Результат роботи нейронної мережі залежить від декількох факторів: якості та кількості навчальних даних; типу архітектури нейронної мережі; кількості параметрів обраної мережі.

Існує велика кількість різновидів архітектур нейронних мереж, і кожен з них має свої властивості та застосування. Давайте коротко розглянемо деякі з них: перцептрон, мережі радіально-базисних функцій, рекурентні мережі та згорткові нейронні мережі.

Перцептрон (Perceptron), це одношарова нейронна мережа, яка використовується для бінарної класифікації. Вона складається з вхідного шару, який приймає ознаки, і вихідного шару, який виробляє результат класифікації. Перцептрон використовує функцію активації для прийняття рішення.

Основними компонентами перцептрона є вхідний шар, ваги, функція сумування та функція активації:

Вхідний шар: Вхідні дані подаються на вхід перцептрону. Зазвичай кожна вхідна ознака має свою вагу, яка визначає її важливість.

Ваги: Кожна вхідна ознака множиться на вагу, і отримані значення сумуються.

Функція сумування: Сума вагових добутків вхідних даних та їхніх ваг обчислюється.

Функція активації: Результат сумування передається через функцію активації, яка визначає вихід перцептрону. Зазвичай для бінарної класифікації використовується порігова функція, яка може приймати значення 0 або 1 в залежності від входу.

Перцептрон може використовуватися для класифікації об'єктів на два класи. Проте важливо зазначити, що одношаровий перцептрон не здатний вирішити складні задачі, які мають складні нелінійні залежності між ознаками. Для вирішення більш складних завдань розпізнавання, використовуються багатошарові нейронні мережі з багатьма шарами (глибокі нейронні мережі), які можуть набагато краще апроксимувати складні функції та здійснювати більш точну класифікацію.

Мережі радіально-базисних функцій (Radial Basis Function Networks, RBFN): ці мережі використовуються для апроксимації функцій та регресії. Вони мають шар вузлів, які використовують радіально-базисні функції для обчислення вихідних значень [3].

Функція Гаусса часто використовується як радіально-базисна функція (RBF) в мережах радіально-базисних функцій (RBFN). Функція Гаусса має такий вигляд:  $\rho(\gamma) = \exp(-\gamma^2)$

Де  $\gamma$  (гамма) - параметр, який впливає на форму та ширину функції Гаусса. Зазвичай, вартість  $\gamma$  визначається під час навчання мережі та може бути підібрана таким чином, щоб вона найкраще відповідала конкретній

задачі. Функція Гаусса є корисною для апроксимації складних функцій, оскільки вона може моделювати локальні залежності між вхідними та вихідними даними. Коли вона використовується як RBF, кожен вузол мережі буде мати свій центр, а параметр  $\gamma$  визначатиме ширину впливу цього вузла на вихідні дані.

RBFN може використовуватися для різних завдань, включаючи апроксимацію функцій, регресію, класифікацію і кластеризацію даних. Функція Гаусса допомагає RBFN моделювати складні нелінійні залежності в даних та робити точні прогнози або класифікації.

Рекурентні мережі (Recurrent Neural Networks, RNN), ці мережі мають зв'язки, які дозволяють інформації передаватися з одного часового кроку в інший. Це робить їх підходящими для обробки послідовних даних, таких як мовний текст, часові ряди та інші дані з часовою залежністю.

Основні компоненти RNN включають в себе:

**Вхідний шар:** Вхідні дані на кожному часовому кроці подаються на вхід мережі.

**Прихований шар:** Цей шар містить нейрони, які мають зв'язки з самими собою та з попередніми часовими кроками. Це дозволяє мережі зберігати та оновлювати інформацію з попередніх часових кроків.

**Вихідний шар:** Вихідні дані можуть бути згенеровані на кожному часовому кроці або тільки на певних кроках, залежно від конкретної задачі.

Рекурентні мережі дуже корисні для обробки послідовних даних, таких як текст, часові ряди, мовлення тощо. Вони здатні виявляти залежності та структуру в таких даних завдяки зв'язкам між часовими кроками. Проте звичайні RNN мають проблему зі зниклим градієнтом (vanishing gradient problem), яка може обмежити їхню здатність до вивчення довгострокових залежностей в даних.

Згорткові нейронні мережі (Convolutional Neural Networks, CNN), ці мережі спеціалізуються на обробці зображень. Вони мають здатність виявляти шаблони та ознаки в різних частинах зображення, що робить їх ідеальними для завдань класифікації зображень та розпізнавання об'єктів на зображеннях.

Основні компоненти згорткової нейронної мережі включають в себе:

**Шари згортки:** Вони використовують фільтри (ядра) для виділення особливостей в зображенні. Згортки дозволяють мережі виявляти локальні патерни, такі як грані, кутові точки, текстурні ознаки та інше.

**Шари пулінгу:** Вони використовуються для зменшення розмірності зображення та підвищення інваріантності до масштабу та позиції. Найпоширенішою операцією пулінгу є максимальний пулінг, де вибирається максимальне значення з кожного області зображення.

**Повнозв'язані шари:** Ці шари використовуються для класифікації або регресії на основі властивостей, визначених попередніми шарами. Вони зазвичай використовують функцію активації, таку як ReLU (Rectified Linear Unit).

**Шар виходу:** Визначає рішення моделі. В залежності від завдання, він може мати різну кількість нейронів та функцію активації.

Згорткові нейронні мережі демонструють вражаючу ефективність у завданнях, таких як розпізнавання об'єктів на зображеннях, сегментація зображень та інші задачі, пов'язані із зображеннями. Вони навчаються автоматично виділяти важливі ознаки зображень і можуть досягати дуже високої точності.

Ці типи нейронних мереж використовуються в різних областях та завданнях, і їх вибір залежить від конкретної задачі та типу даних, з якими ви працюєте. Крім того, існують багато інших архітектур та модифікацій

нейронних мереж, які розвиваються та використовуються в даний час для вирішення різних завдань машинного навчання і штучного інтелекту.

Основна відмінність між згортковими нейронними мережами (CNN) і мережами прямого поширення, такими як перцептрони полягає в обробці зображень.

У згорткових нейронних мережах вхідні дані представляють собою зображення, і ця інформація використовується для розпізнавання властивостей зображення. Основна ідея полягає в тому, що CNN використовує фільтри або ядра, які просуваються по зображенню та виділяють локальні особливості, такі як грані, форми, текстури тощо. Кожен фільтр має свої ваги, які визначаються під час навчання. Це дозволяє мережі автоматично вивчати властивості зображень і зменшити кількість параметрів, оскільки ваги фільтрів спільно використовуються для різних частин зображення.

У мережах прямого поширення, таких як перцептрони, кожен вхід має зв'язки з кожним нейроном на наступному шарі, і всі ці зв'язки мають власні ваги. Тобто, кількість параметрів може значно зростати зі збільшенням кількості вхідних ознак, що робить такі мережі менш ефективними для обробки зображень, оскільки зображення мають велику кількість пікселів.

Отже, згорткові нейронні мережі є більш ефективними для обробки зображень, оскільки вони використовують локальну інформацію та спільно використовують параметри фільтрів, що робить їх ефективними та здатними до навчання складних функцій на зображеннях.

Рекурентні нейронні мережі (RNN) і згорткові нейронні мережі (CNN) - це два різні типи нейронних мереж, які призначені для різних видів завдань і мають свої особливості. Ось деякі основні відмінності між ними:

### Завдання:

RNN: Рекурентні мережі призначені для обробки послідовних даних, де кожен елемент послідовності має зв'язок з попередніми та наступними елементами. Вони підходять для завдань, таких як мовний переклад, аналіз тексту, мовлення, часові ряди і т. д.

CNN: Згорткові мережі призначені для обробки зображень і виявлення локальних особливостей в них. Вони ефективні в завданнях розпізнавання об'єктів на зображеннях, сегментації, класифікації тощо.

### Архітектура:

RNN: У рекурентних мережах існують зв'язки між нейронами в кожному часовому кроці, які дозволяють інформації передаватися від одного кроку до іншого.

CNN: Згорткові мережі використовують згортки та пулінг шари для виявлення локальних особливостей на зображеннях та зменшення розмірності даних.

### Зберігання інформації:

RNN: Рекурентні мережі можуть зберігати інформацію з попередніх кроків в найпростіших випадках, але можуть стикатися з проблемою зниклого градієнта при навчанні довгострокових залежностей.

CNN: Згорткові мережі зазвичай не зберігають інформацію між кроками та працюють з кожним зображенням незалежно.

### Завдання обробки даних:

RNN: Рекурентні мережі відмінно підходять для задач, де важлива послідовність та залежності між елементами послідовності.

CNN: Згорткові мережі найкраще підходять для завдань, де важливі локальні особливості та структура в зображеннях.

Важливо визначити, який тип нейронної мережі слід використовувати в залежності від конкретного завдання та типу даних, з якими ви працюєте. В деяких випадках комбінація обидвох типів мереж (наприклад, використання CNN для вилучення ознак зображення, а потім RNN для аналізу послідовностей ознак) може бути дуже ефективною.

Як правило будь-яка архітектура мережі має свої певні недоліки та переваги. Одним з методів вирішення проблеми недоліків конкретної архітектури – гібридизація мереж.

Гібридизація мереж (або гібридні моделі) є одним із методів для вирішення проблем і недоліків конкретних архітектур нейронних мереж. Гібридні моделі поєднують у собі різні типи нейронних мереж або методів машинного навчання з метою покращення результатів та розв'язання складних завдань. Ось деякі переваги і приклади гібридних моделей:

Покращення результатів, гібридні моделі можуть поєднувати переваги різних типів мереж для підвищення точності та ефективності вирішення завдань. Наприклад, поєднання згорткових нейронних мереж (CNN) для вилучення ознак із рекурентними мережами (RNN) для аналізу послідовностей може бути корисним у завданнях обробки або розпізнавання.

Робустність, гібридні моделі можуть бути більш робустними до шуму та непередбачуваних ситуацій, оскільки вони комбінують інформацію з різних джерел або архітектур.

Універсальність, гібридні моделі можуть використовувати найкращі практики з різних галузей машинного навчання та нейронних мереж, що дозволяє їм вирішувати ширший спектр завдань.

Зменшення перевантаження, гібридизація може допомогти зменшити кількість параметрів в мережі та скоротити час навчання, особливо у великих і складних завданнях.

Приклади гібридних моделей включають у себе комбінації CNN і RNN, CNN і Transformer, а також гібриди глибоких нейронних мереж і класичних методів машинного навчання.

Важливо розуміти, що гібридизація моделей може призвести до більшої складності та вимагати більше обчислювальних ресурсів. Ось деякі аспекти, які варто враховувати при розгляді гібридних моделей:

Обчислювальна складність, кожен доданий компонент до гібридної моделі може збільшити обчислювальну складність. Це може вимагати більш потужних обчислювальних ресурсів, включаючи GPU або TPU для навчання та інференсу.

Навчання, гібридні моделі можуть вимагати більше часу для навчання через більшу кількість параметрів і складнішу оптимізаційну задачу.

Розмір моделі, кількість параметрів у гібридних моделях може бути значною, що робить їх великими і складними для розгортання на ресурсах з обмеженою потужністю.

Збалансованість, важливо збалансувати компоненти гібридної моделі, щоб досягти бажаних результатів. Неправильно підібрана комбінація моделей може призвести до погіршення продуктивності.

Дані, гібридні моделі можуть вимагати різних типів даних для різних компонентів. Це вимагає наявності та підготовки відповідних даних.

Інтерпретація і пояснення, гібридні моделі можуть бути складними для інтерпретації та пояснення результатів, оскільки вони об'єднують різні методи та компоненти.

Перед тим як використовувати гібридизацію моделей, важливо чітко зрозуміти потреби завдання та ресурсні обмеження. Також варто ретельно налаштувати та оптимізувати гібридну модель для досягнення бажаних результатів.



Головним принципом при побудові гібридної архітектури є використання сильних сторін кожної моделі та уникання слабких сторін. Це означає, що ви повинні вибирати ті моделі або компоненти, які відомі своєю ефективністю в вирішенні конкретних аспектів завдання, і поєднувати їх таким чином, щоб компенсувати недоліки і підвищити загальну продуктивність.

Для цього можуть бути використані наступні підходи:

**Комплементарність моделей.** Вибирайте моделі, які добре впораються з різними аспектами задачі. Наприклад, якщо вам потрібно обробити послідовності та виконати класифікацію, то можливо поєднання рекурентних мереж (RNN) та згорткових мереж (CNN) буде корисним.

**Ансамбль моделей.** Використовуйте ансамбль, де кілька моделей об'єднуються для прийняття рішення. Кожна модель може мати свої сильні сторони, і ансамбль допоможе знизити ризик недоліків окремих моделей.

**Фінетюнінг та оптимізація.** Після об'єднання моделей проведіть фінетюнінг і оптимізацію, щоб покращити взаємодію компонентів і забезпечити їх оптимальну роботу.

**Оцінка результатів.** Ретельно оцінюйте результати гібридної моделі на тестових даних, щоб переконатися в її ефективності.

**Збалансованість.** Важливо збалансувати внесок кожної моделі і компонента так, щоб досягти бажаних результатів. Уникайте перекосу в бік однієї моделі, яка може призвести до недооцінки інших.

Застосування гібридних архітектур вимагає експертного розуміння завдання та моделей, а також ретельної настройки та тестування, але це може призвести до значного покращення результатів у вирішенні складних завдань.

Для підбору оптимальної архітектури нейронної мережі і навчання її з заданою точністю, існують різні методи і алгоритми. Декілька з них включають:

Перехрестний перевірка (Cross-Validation), цей метод дозволяє оцінити ефективність моделі на основі розділення навчальних даних на навчальний та тестовий набори. Ви можете використовувати різні конфігурації моделі та оцінювати їх продуктивність на тестовому наборі. Таким чином, ви можете визначити оптимальну архітектуру, яка дає найкращі результати.

Гіперпараметризація (Hyperparameter Tuning), цей процес включає в себе підбір оптимальних гіперпараметрів для нейронної мережі, таких як кількість шарів, кількість нейронів у кожному шарі, швидкість навчання (learning rate), функція активації і т.д. Можна використовувати алгоритми оптимізації, такі як Random Search або Grid Search, для пошуку оптимальних гіперпараметрів.

Байєсівська оптимізація (Bayesian Optimization), цей метод використовує байєсівську модель для оптимізації гіперпараметрів. Він дозволяє ефективно визначити оптимальні параметри моделі, зменшуючи кількість експериментів.

Еволюційні алгоритми (Evolutionary Algorithms), вони можуть бути використані для ефективного пошуку оптимальної архітектури мережі та гіперпараметрів шляхом генерації та оцінки різних кандидатів.

Автоматичне машинне навчання (AutoML), це підходи, де моделі машинного навчання, включаючи нейронні мережі, автоматично вибираються і налаштовуються на основі даних та задачі.

Алгоритми зворотного поширення помилки (Backpropagation) та оптимізатори, важливо використовувати підходи для навчання нейронної мережі, такі як алгоритми зворотного поширення помилки та оптимізатори, які допоможуть збільшити точність моделі.

Кожен з цих методів має свої переваги і недоліки, і вибір методу залежить від конкретної задачі та ресурсних обмежень. Зазвичай, комбінування кількох методів і експерименти є ключем до досягнення оптимальної архітектури нейронної мережі з заданою точністю.

Для формування загальної відповіді гібридної нейронної системи часто використовуються різні методи комбінації результатів з різних компонентів системи. Два з найпоширеніших підходів - це зважене підсумовування результатів і динамічний вибір однієї нейронної мережі.

Зважене підсумовування (Weighted Summation), в цьому методі кожен компонент системи (наприклад, окрема нейронна мережа) має свій ваговий коефіцієнт. Вихід кожного компонента множиться на його ваговий коефіцієнт, і результати сумуються. Це дозволяє враховувати різний внесок кожного компонента в загальну відповідь. Вагові коефіцієнти можуть бути встановлені на підставі експертних оцінок, результатів навчання або інших методів.

Динамічний вибір однієї мережі (Dynamic Selection), цей метод полягає в тому, що система динамічно вибирає одну з компонент на основі вхідних даних або інших факторів. Наприклад, система може визначити, яка мережа найкраще підходить для конкретного вхідного зображення та використовувати результати цієї мережі. Цей метод може бути особливо корисним, коли різні мережі спеціалізуються на різних аспектах задачі і можуть бути використані в залежності від контексту.

Вибір конкретного методу залежить від конкретної задачі і обмежень системи. Обидва методи можуть бути ефективними, якщо правильно налаштувати параметри і вагові коефіцієнти.

## 2.2 Шаблон архітектури згорткової нейронної мережі

Згорткова нейронна мережа (Convolutional Neural Network або CNN) має загальний шаблон архітектури, який включає в себе декілька основних компонентів. Цей шаблон може бути адаптований та розширений для вирішення різних завдань обробки зображень. Ось основні компоненти шаблону архітектури CNN:

1. Вхідний шар:
  - Приймає вхідні дані, які можуть бути зображеннями або іншими багатовимірними даними.
  - Зазвичай використовується тензор зображення з розмірами (ширина, висота, кількість каналів), наприклад, (224, 224, 3) для зображень RGB.
2. Згорткові шари (Convolutional Layers):
  - Використовуються для виявлення локальних ознак у вхідних даних за допомогою фільтрів або ядер.
  - Може бути декілька згорткових шарів, що дозволяє виявити більш складні ознаки на різних рівнях абстракції.
3. Пулінгові шари (Pooling Layers):
  - Використовуються для зменшення розмірності вихідних даних з згорткових шарів, зберігаючи при цьому важливі ознаки.
  - Зазвичай використовується пулінг Max або Average для отримання результуючої картини ознак меншого розміру.
4. Повнозв'язані шари (Fully Connected Layers):
  - Після згорткових і пулінгових шарів можуть бути додані один або декілька повнозв'язаних шарів, щоб обробити агреговані ознаки та прийняти рішення.

- Зазвичай використовується зворотний прохід (backpropagation) для навчання моделі.

#### 5. Вихідний шар:

- Генерує вихідні дані, які відповідають кількості класів або категорій у завданні класифікації.
- У вихідному шарі може використовуватися функція активації, така як Softmax, для отримання імовірностей класів.

#### 6. Функція втрат (Loss Function):

- Використовується для оцінки того, наскільки модель вдало вирішила завдання.
- Найпоширеніша функція втрат для класифікації - категоріальна кросс-ентропія (Categorical Cross-Entropy).

#### 7. Оптимізатор:

- Використовується для підгонки ваг моделі для мінімізації функції втрат.
- Популярні оптимізатори включають Adam, SGD (Stochastic Gradient Descent), і RMSprop.

Це загальний шаблон архітектури згорткової нейронної мережі. Можемо змінювати кількість та конфігурацію шарів, їх розмірність, функції активації та інші параметри, щоб відповідати конкретним потребам вашого завдання.

Як відомо, багатошарові штучні нейронні мережі отримують вхідні дані (наприклад один вектор), після чого трансформують інформацію, проводячи її через ряд прихованих шарів. Кожен прихований шар складається з безлічі нейронів, де кожний нейрон має сильний зв'язок з усіма нейронами в попередньому шарі і де нейрони в якості одного шару повністю незалежні один від одного і не мають спільних з'єднань. Останній повно зв'язну шар

називається вихідним шаром, і в налаштуваннях класифікації він демонструє число класів[4].

Звичайні штучні нейронні мережі погано масштабуються у випадку з зображеннями великих розмірів. Так, в системі комп'ютерного зору CIFAR-10, картинка становить  $[32 \times 32 \times 3]$  (32 - ширина, 32 - висота, 3 - канали кольорів), тому один повністю підключений нейрон в першому прихованому шарі звичайної нейронної мережі має вагу  $32 * 32 * 3 = 3072$ . Здається, що це значення можна змінювати, але повнозв'язна структура не масштабується для великих зображень. Картинка обсягом більше, наприклад,  $[200 \times 200 \times 3]$ , приведе до того, що повністю підключений нейрон буде важити 120 000. Крім того, потрібно залучити кілька таких нейронів, що призведе до додавання параметрів. Недоліком повнозв'язності буде величезна кількість параметрів, що швидко повинно привести до перенавчання.

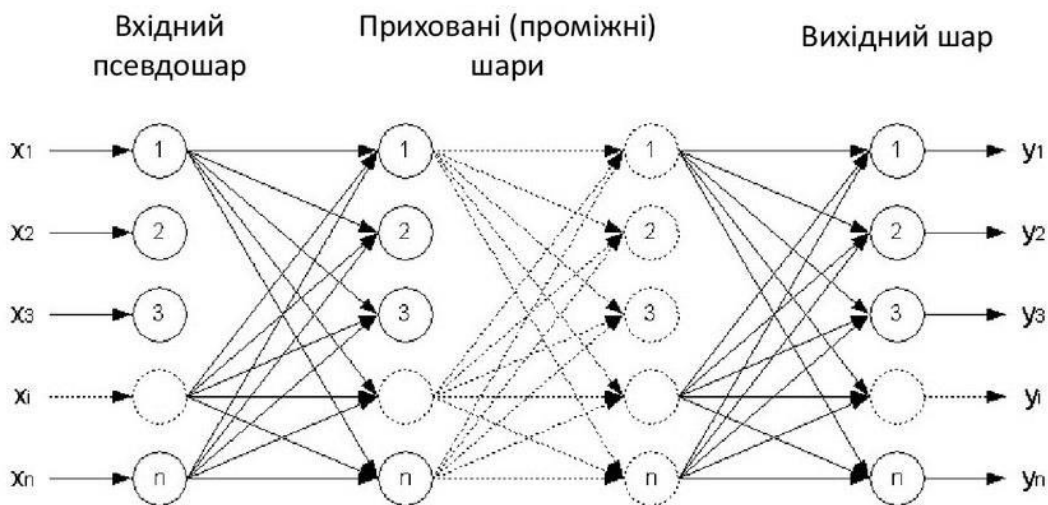


Рис.2.1 – Багатошарова нейронна мережа

Згорткові нейронні мережі (Рис 2.2) спеціалізуються на обробці зображень та мають ряд переваг у порівнянні зі звичайними нейронними мережами (наприклад, перцептронами). Ось деякі з цих переваг:

Розпізнавання образів, згорткові нейронні мережі спеціалізуються на розпізнаванні образів у зображеннях, таким чином, вони добре підходять для

завдань, пов'язаних з обробкою візуальної інформації, таких як розпізнавання об'єктів, класифікація зображень та сегментація об'єктів.

Локальні зв'язки, в згорткових шарах мережі використовуються локальні зв'язки, які дозволяють моделі реагувати на локальні особливості зображення, такі як грані, кути і текстурні ознаки. Це допомагає моделі автоматично виділяти важливі ознаки зображення.

Спільні ваги, згорткові шари мережі використовують однакові ваги для різних областей зображення. Це робить модель менш обчислювально вимогливою та зменшує кількість параметрів, що потрібні для навчання.

Пулінгові шари дозволяють зменшити розмір області зображення, зберігаючи важливі ознаки. Це допомагає скоротити кількість параметрів і зменшити об'єм обчислень.

Автоматичне виділення ознак, згорткові мережі можуть автоматично вивчати важливі ознаки зображення під час навчання, що робить їх ефективними для завдань розпізнавання образів без необхідності вручну вибирати ознаки.

Усі ці функції допомагають згортковим нейронним мережам домінувати в області обробки зображень.

На відміну від звичайної нейронної мережі, згорткових нейронних мережах (CNN) шари складаються з нейронів, розташованих у трьох вимірах: ширині, висоті і глибині (або каналах). Ця тривимірна структура використовується для обробки тривимірних даних, таких як зображення.

Основні компоненти згорткового шару включають:

Ядро (Kernel) або фільтр. Ядро - це невеликий фільтр або вагова матриця, яка накладається на вхідне зображення або попередній шар. Ядро переміщується по всій області вхідних даних і виконує згортку (поступове переміщення та обчислення суми добутоків) для виділення ознак.

Канали. Глибина шару визначається кількістю каналів у шарі. Кожен канал відповідає за виявлення певної ознаки або фільтрацію певних аспектів даних.

Стрид (Stride). Цей параметр визначає крок переміщення ядра під час згортки. Великий стрид може зменшити вихідний розмір шару.

Пулінг (Pooling). Пулінгові операції використовуються для зменшення розміру вихідних даних і виділення найважливіших ознак. Зазвичай використовуються операції максимального або середнього пулінгу.

Така тривимірна структура шарів дозволяє згортковим нейронним мережам ефективно розпізнавати локальні ознаки та шари абстракції в зображеннях, зберігаючи при цьому просторову ієрархію і структуру зображення. Це робить їх особливо підходящими для обробки зображень та інших тривимірних даних.

Наприклад, зображення на вході CIFAR-10 є вхідним и активаційними об'ємами, а об'єм сформований вимірами  $32 \times 32 \times 3$ . Як буде описано далі, нейрони будуть підключені тільки до невеликої області шару. Крім того, результуючий вихідний шар для даної системи комп'ютерного зору складе  $1 \times 1 \times 10$ , оскільки до кінця побудови ЗНМ зображення перетвориться в єдиний вектор оцінок класу, розташованих по вимірюванню глибини [4].




Рис.2.2 Згорткова нейронна мережа



Основними будівельними блоками є шари, і кожен шар виконує певну функцію обробки даних. В залежності від призначення та ролі шару в архітектурі мережі вони можуть бути різних типів. Основні типи шарів у згорткових нейронних мережах включають:

Згортковий шар (Convolutional Layer), цей шар використовує ядра (фільтри) для виконання операції згортки над вхідними даними. Він відповідає за виявлення локальних ознак та структур у зображенні. Згорткові шари мають ваги, які навчаються під час процесу навчання.

Пулінговий шар (Pooling Layer), зменшує розмір областей даних і зберігає найважливіші ознаки. Він може використовувати операції максимального пулінгу або середнього пулінгу.

Повністю зв'язаний шар (Fully Connected Layer), повністю зв'язані шари приймають вхідні дані з попереднього шару та виконують операції лінійної комбінації та активації. Вони допомагають об'єднати інформацію з різних частин зображення для остаточного прийняття рішення.

Функція активації (Activation Function), шари також можуть включати функції активації, які нелінійно перетворюють вихідні дані.

Інші спеціалізовані шари, у деяких архітектурах мережі можуть використовуватися інші спеціалізовані шари, такі як шари нормалізації (Batch Normalization), шари уваги (Attention Layers) та інші.

Кожен шар має свою функцію і допомагає моделі виконувати певні операції під час обробки даних. Вони комбінуються разом, щоб створити повну архітектуру згорткової нейронної мережі, яка здатна вирішувати різні завдання, такі як розпізнавання образів чи сегментація зображень.

### 2.2.1 Шари згортки

Шари згортки (Convolutional Layers) є одним із ключових компонентів згорткових нейронних мереж (CNN) і відповідають за виявлення ознак і особливостей у вхідних даних, таких як зображення. Вони використовують фільтри або ядра для сканування вхідних даних та виділення важливих ознак. Ось деякі основні характеристики та функції шарів згортки:

**Фільтри (ядра):** представляють собою невеликі матриці, які скользять (згортаються) по вхідних даних. Кожен фільтр виявляє конкретну ознаку, таку як краї, текстурні особливості, форми тощо. Якщо у вас є багато фільтрів, то мережа може виявляти багато різних ознак одночасно.

**Згортка:** це операція, в якій фільтр переміщується по вхідних даних, а потім обчислюється скалярний добуток між фільтром і частиною вхідних даних, що під ним розташована. Результат згортки створює вихідну карту ознак, яка вказує на наявність цієї ознаки в різних частинах вхідних даних.

**Розмір фільтра:** визначається його шириною і висотою, і він може бути, наприклад, 3x3 або 5x5. Розмір фільтра підбирається залежно від завдання та архітектури мережі.

**Крок згортки (Stride):** вказує на відстань між кожним зсувом фільтра під час згортки. Зазвичай використовують значення 1 для кроку, але його можна налаштувати вручну.

**Заповнення (Padding):** визначається додаванням додаткових пікселів навколо вхідних даних перед згорткою. Зазвичай використовують "заповнення нулями" (zero-padding), щоб зберегти розмірність вихідної картини ознак, особливо коли використовуються багато шарів згортки.

Згорткові шари дозволяють мережі автоматично вчити локальні ознаки та її ієрархію, що допомагає в розпізнаванні більш абстрактних ознак на більш вищих рівнях. Це робить згорткові нейронні мережі особливо ефективними

для завдань обробки зображень, таких як розпізнавання об'єктів та класифікація.

Головним шаром згорткової нейронної мережі беззаперечно можна вважати шар згортки [4], робота якого є основою даної мережі. Параметри шару згортки складаються з набору фільтрів для навчання (також можна зустріти назву - ядра Кернела). Кожен фільтр має невеликі просторові габарити (ширину і висоту), але проходить по всій глибині вхідного об'єму. Наприклад, стандартний фільтр першого шару згорткової нейронної мережі може бути розміром  $[5 \times 5 \times 3]$ . Під час проходження вперед, виконується ніби ковзання кожного фільтру по ширині і висоті вхідних даних і обчислюється скалярний добуток між записами фільтра і входом у будь-яке положення. У міру проходження фільтра по ширині і висоті зображення, складається двовірна активаційна карта, яка надає відгук цього фільтра на кожній просторовій позиції (Рис. 2.3). Мережа навчає фільтри, що активуються при виявленні певної візуальної особливості. Це може бути грань деякої спрямованості, плямистість конкретного кольору на першому шарі або кільцеподібні візерунки на більш високих рівнях мережі. Після мережа працює з цілим набором фільтрів в кожному шарі згортки, і кожен з цих фільтрів буде формувати окрему двовірну карту активації або карту ознак. Карти ознак складаються вздовж «глибини» вхідного об'єму і будуть формувати вихідний об'єм.

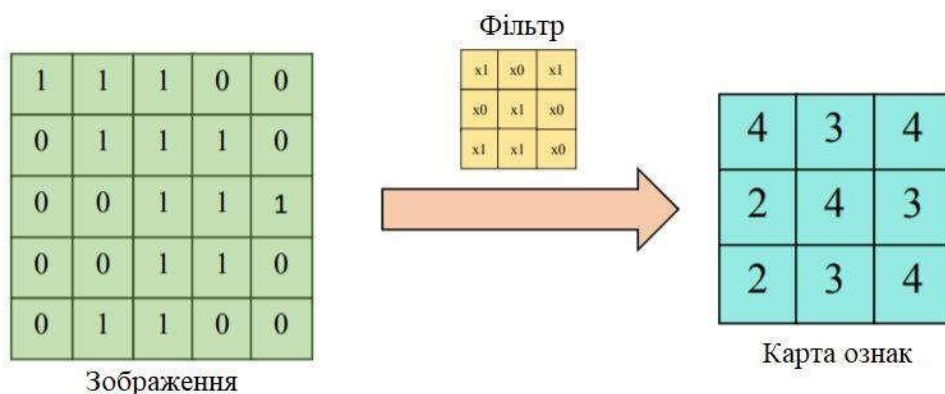


Рис.2.3- Формування карти ознак. Операція згортки.

При роботі з вхідною інформацією високою розмірністю, установка зв'язку між нейронами і всіма нейронами з попереднім об'ємом є недоцільною.

Замість цього потрібно застосовувати кожен нейрон тільки до локальної області вхідного об'єму. Просторова протяжність його зв'язку є гіперпараметром і називається рецептивним полем (полем сприйнятливості). Ідея рецептивного поля полягає в тому, щоб об'єднати нейрони прихованого шару лише з такими нейронами попереднього шару, які входять в деяку маленьку область  $n \times n$ . Причому для кожного нейрона вибирається своя окрема область. Дана область і називається локальним рецептивним полем. Рецептивні поля виявляють елементарні візуальні ознаки такі, як кут або край, а їх комбінації дають можливість отримати складніші ознаки [4].

Важливо розуміти поняття рецептивного поля і асиметрії в розгляді просторових вимірів.

Рецептивне поле (Receptive Field), це поняття вказує на область вхідних даних, яку окремий нейрон в згортковому шарі "бачить" і аналізує. Рецептивне поле визначається розміром фільтра (ядро) в згортковому шарі. Якщо, наприклад, рецептивне поле має розмір  $3 \times 3$ , то кожен нейрон в цьому шарі аналізує область  $3 \times 3$  пікселів з вхідного зображення.

Глибина (Depth), вказує на кількість каналів або фільтрів в згортковому шарі. Нейрони в одному і тому ж рецептивному полі в одному шарі ділять однакові ваги, але вони аналізують різні канали глибини. Це допомагає моделі розрізняти різні ознаки в зображенні.

Асиметрія полягає в тому, що з'єднання між шарами є локальними по ширині і висоті, що дозволяє моделі виявляти локальні ознаки в різних частинах зображення. Проте, з'єднання завжди проходять через всю глибину вхідного об'єму, що дозволяє нейронам в одному шарі аналізувати різні ознаки в одному й тому ж рецептивному полі.

Ця асиметрія дозволяє CNN ефективно виявляти та інтерпретувати локальні ознаки в зображенні, що робить їх дуже потужними для задач обробки зображень, таких як розпізнавання образів, сегментація та багато інших завдань у комп'ютерному зорі.

## Висновок до розділу 2

Так, згорткові нейронні мережі (Convolutional Neural Networks або CNN) дійсно знайшли широке застосування при обробці зображень. Вони стали домінуючим методом у галузі комп'ютерного зору та обробки зображень завдяки своїм вражаючим результатам у багатьох завданнях. Ось деякі з основних областей застосування згорткових нейронних мереж у обробці зображень: розпізнавання об'єктів (згорткові мережі використовуються для виявлення та класифікації об'єктів на зображеннях), семантична сегментація (згорткові мережі можуть розділяти зображення на піксельні сегменти, призначаючи кожному пікселю клас або категорію), визначення ключових точок та дескрипторів (можна використовувати згорткові мережі для визначення ключових точок та їхніх дескрипторів на зображеннях), автоматична обробка та покращення зображень (таких як видалення шуму, покращення роздільної здатності, кольорова корекція тощо), генерація зображень (у деяких задачах генеративних мереж, зокрема у стилізації зображень, використовуються згорткові мережі для створення нових зображень, які мають певні характеристики або стиль), перенесення стилю (дозволяють виконувати перенесення стилю між двома зображеннями, створюючи результат, який поєднує стиль одного зображення з контентом іншого).

Це лише кілька прикладів. Згорткові нейронні мережі використовуються в широкому спектрі застосувань, де обробка зображень є ключовим елементом. Вони продемонстрували великий успіх у вирішенні складних завдань обробки зображень та виявленні ознак у великих обсягах вхідних даних.

Згорткові нейронні мережі знайшли своє застосування при обробці зображень. Якщо уявити, що зображення – двовимірні функції, то різні перетворення зображень – це операція згортка функції зображення з

локальною функцією, яка називається ядром згортки. Операція згортки чергується з операцією підвибірки.

Підвибірка застосовується для зменшення загального розміру зображення і збільшення ступеня інваріантності застосовуваних до нього фільтрів. При розгляді архітектури мережі спираються на факт, що наявність якої-небудь ознаки на зображенні набагато важливіше, ніж точне знання її координат. Таким чином, суттю підвибірки є вибір максимального нейрона з декількох сусідніх. Потім, цей нейрон приймаємо за елемент наступної, але вже зменшеної карти ознак. Дана операція допомагає збільшити інваріантність до масштабу вхідного зображення.

Після проходження декількох шарів карта ознак вироджується в вектор або скаляр, і таких карт ознак стає сотні. На виході згорткових шарів мережі додатково встановлюють кілька шарів повнозв'язної нейронної мережі, що виконують роботу класифікатору.

У розділі 2 було розглянуто загальну топологію згорткових нейронних мереж, також описано основні складові їх архітектури та значення параметрів і гіперпараметрів згорткових мереж. У розділі пояснено суть нормалізації вхідних даних для шарів та важливість запобігати зниженню швидкості навчання мережі та кількості її параметрів.

Нормалізація вхідних даних - це важливий етап обробки даних у нейронних мережах, і вона має декілька важливих об'єктивів та переваг:

1. Запобігання зниженню швидкості навчання, нейронні мережі часто використовують методи оптимізації, такі як градієнтний спуск, для навчання. Ці методи можуть працювати краще, коли вхідні дані нормалізовані, тобто коли вони мають середнє значення близько до нуля і стандартне відхилення близьке до одиниці. Нормалізація допомагає уникнути проблем зі збійністю градієнтів та надмірною зміною ваг під час навчання.

2. Зменшення залежності від шкали, без нормалізації ваги мережі можуть залежати від шкали вхідних даних. Це означає, що те саме навчання на даних різної шкали може призводити до різних результатів. Нормалізація дозволяє зробити мережу більш шкалонезалежною.

3. Зменшення кількості параметрів, нормалізація може допомогти знизити кількість параметрів мережі, що вимагається для навчання. Це стосується зокрема рекурентних мереж, де може бути багато шарів і ваг, і нормалізація може покращити збіжність.

Для досягнення цих цілей часто використовують два основних види нормалізації:

1. Стандартизація (зсув і масштабування). Для кожної ознаки віднімається середнє значення та результат ділиться на стандартне відхилення. Це робить розподіл даних нормальним (з середнім значенням близьким до нуля та стандартним відхиленням близьким до одиниці).

2. Міні-макс нормалізація. Значення кожної ознаки перетворюються так, щоб вони були у межах певного діапазону, наприклад, від 0 до 1 або від -1 до 1. Це дозволяє нормалізувати дані до певного діапазону значень.

Нормалізація сприяє більш ефективному та стабільному навчанню нейронних мереж та забезпечує більш прогнозовану поведінку моделі.

Розділ, в якому розглянута загальна топологія згорткових нейронних мереж, є важливим для розуміння основних складових архітектури цих мереж і визначення значення параметрів та гіперпараметрів. Згорткові мережі є дуже ефективними у завданнях обробки зображень, а також знайшли застосування у багатьох інших областях. Ось деякі ключові аспекти цього розділу:

1. У цьому розділі розглядаються основні складові згорткових мереж, включаючи:

- Згорткові шари (Convolutional Layers), шари використовуються для виявлення локальних ознак у вхідних зображеннях за допомогою згорткових фільтрів.
- Пулінг шари (Pooling Layers), використовується для підвищення роздільної здатності та зменшення обчислювальних витрат шляхом підсумовування значень в окремих областях.
- Повні зв'язані шари (Fully Connected Layers), ці шари використовуються для розпізнавання вищорівневих патернів та зав'язків між ознаками.

2. Розділ також пояснює різницю між параметрами та гіперпараметрами в контексті згорткових мереж. Параметри, такі як ваги згорткових фільтрів та повні зв'язані ваги, навчаються під час процесу навчання. Гіперпараметри, такі як розмір фільтрів, кількість шарів, розмір пулінгу, швидкість навчання тощо, встановлюються перед початком навчання та впливають на архітектуру мережі і її здатність.

3. Розділ надає важливі рекомендації щодо значень гіперпараметрів. Наприклад, важливо вибрати правильний розмір фільтрів для згорткових шарів, який відповідає розміру ознак у вхідних зображеннях. Встановлення занадто великого значення може призвести до збільшення кількості параметрів і обчислювальних ресурсів, а занадто малого - до втрати інформації.

4. У розділі також наведено приклади типових архітектур згорткових мереж. Ці архітектури використовуються для різних завдань обробки зображень і можуть слугувати вихідною точкою для створення власних архітектур.

Розуміння цих основних аспектів згорткових мереж є ключовим для успішного використання їх у завданнях обробки зображень та інших задачах.



## РОЗДІЛ 3. МЕТОДИКА НАВЧАННЯ ЗГОРТКОВОЇ НЕЙРОННОЇ МЕРЕЖІ

### 3.1 Методи навчання нейронних мереж

Навчання нейронних мереж - це процес встановлення або оптимізації ваг та параметрів мережі з використанням навчальних даних, щоб модель могла виконувати потрібні завдання. Існує кілька методів навчання нейронних мереж, серед них основні такі:

Навчання з учителем (Supervised Learning), цей метод використовується для задач класифікації та регресії.

- Модель навчається на парах вхідних даних та відповідних вихідних міток (цілей).
- Популярні функції втрат для навчання з учителем включають середньоквадратичну помилку (MSE) для регресії та категоріальну кросс-ентропію для класифікації.

Навчання без учителя (Unsupervised Learning):

- Використовується для завдань кластеризації та редукції розмірності даних.
- Модель навчається на вхідних даних без відповідних вихідних міток.
- Популярні методи включають кластеризацію К-середніх та автокодування (autoencoders).

Навчання з підкріпленням (Reinforcement Learning):

- Використовується для навчання моделей взаємодіяти з довкіллям та вчиняти дії, щоб максимізувати деяку винагороду або функцію винагороди.
- Модель навчається на основі взаємодії з середовищем та отримує нагороди або покарання за виконані дії.

Напівконтрольоване навчання (Semi-Supervised Learning):

- Використовує як навчальні дані з відомими вихідними мітками, так і ненавчальні дані без вихідних міток.
- Цей метод може використовувати ненавчальні дані для покращення якості моделі, навченої на обмеженій кількості вхідних даних.

#### Навчання з перенесенням навчання (Transfer Learning):

- Використовується попередньо навчена модель для вирішення нового завдання.
- Модель, навчена на одному завданні, може бути адаптована для іншого завдання шляхом заморожування певних шарів і/або донавчання інших шарів для нового завдання.

#### Самонавчання (Self-Supervised Learning):

- Використовується для навчання моделей на основі вхідних даних без відомих вихідних міток.
- Модель навчається вирішувати певне завдання, яке генерується з вхідних даних, таке як реконструкція вхідних даних.

Ці методи навчання можуть бути комбіновані та адаптовані для різних типів завдань та видів даних. Вибір методу навчання залежить від конкретного завдання та доступних даних.

Здатність до навчання виступає як фундаментальна особливість людського мозку, та може розвиватися на протязі життя. Якщо говорити про навчання в контексті нейронних мереж, то тут варто розглядати налаштування архітектури мережі, ваги нейронів мережі, їх зв'язків. Все це має свій вплив на ефективне виконання поставленої задачі перед мережею. Зазвичай нейронна мережа повинна налаштувати свої параметри (такі як вага кожного нейрону) за поданими навчальними прикладами. Властивість мереж навчатися за поданими прикладами робить їх більш досконалими у порівнянні з системами, що працюють за прописаними заздалегідь правилами. Серед усіх чинних

методів навчання мереж можна виділити два класи: детермінований та стохастичний.

Детермінований клас методів інтерактивно корегує параметри мережі, спираючись на стан поточних параметрів, величини входів, фактичних та бажаних виходів. Ілюстрацією такого методу являється метод зворотнього поширення помилки.

Стохастичний клас методів навчання мереж змінює параметри мережі випадковим чином. При цьому збереженими залишаються лише ті зміни, що призвели до покращення. В якості прикладу стохастичного методу можна привести такий алгоритм:

1. Обрати параметри мережі випадковим чином та підкорегувати їх на невелику випадкову величину. Обрахувати отримані значення виходів за запропонованими значеннями входів.
2. Порівняти ці виходи з бажаним результатом та обчислити різницю значень. Ця різниця називається помилкою. Ціль навчання полягає у тому, щоб мінімізувати значення помилки.
3. Значення помилки зменшено, корегування збережено. У негативному випадку значення корегування відкидається і вибирається заново.

Кроки 2 та 3 повторюють поки мережу не буде навчено.

Необхідно зауважити, що стохастичні методи навчання можуть потрапити до «пастки» локального мінімуму (Рис 3.1).

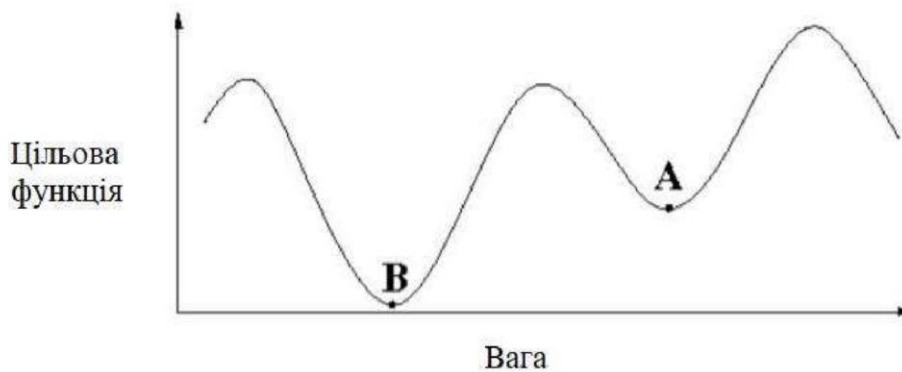


Рис3.1- Проблема локального мінімуму

Розглянемо зображення рисунку 3.1. Нехай початкове значення помилки рівно чи близьке до значення у точці А. Якщо випадкові кроки корегування дуже малі, то будь-які відхилення від точки А збільшать помилку та не будуть братися до уваги. Таким чином найменше значення у точці В ніколи не буде знайдено. При дуже великих випадкових кроках корегування параметрів мережі помилка буде піддаватися зміні так різко, що ніколи не закріпиться за одним із мінімумів.

Щоб уникати проблеми локального мінімуму [11] можна поступово зменшити випадковий середній розмір кроків корегування. Коли середній розмір кроків завеликий, значення помилки буде приймати усі значення з рівною імовірністю. При плавному зменшенні розміру кроків буде дотримано умови при якому значення помилки буде на деякий час «застрягати» в точці В. Коли значення кроку буде ще більше зменшено, значення помилки буде «зупинятися» на короткий проміжок часу і в точці А і в точці В. При зменшенні кроку безперервно то у кінці буде досягнуто величину кроку, що буде достатньою для подолання локального мінімуму А, але не локального мінімуму В.

Математичне представлення навчання мереж зводиться до наступного вигляду:

Нехай ми маємо рівняння  $Y = F(X)$  яке вирішує задачу і набір вхідних-вихідних даних  $(X_1, Y_1), (X_2, Y_2) \dots (X_n, Y_n)$ . При навчанні мережі потрібно знайти таку функцію, що буде близькою до функції з помилкою. Тобто знаючи всі ці параметри завдання зводиться до задачі багатовимірної оптимізації функції. А для її рішення застосовуються такі алгоритми:

1. Алгоритми локальної оптимізації з обчисленням часткових похідних першого порядку [11]:
  - градієнтний алгоритм (метод найшвидшого спуску);
  - методи з одновимірною і двовимірною оптимізацією цільової функції в напрямку антиградієнта;
  - методи, що враховують напрямок антиградієнта на декількох кроках алгоритму.
2. Алгоритми локальної оптимізації з обчисленням часткових похідних першого і другого порядку:
  - метод Ньютона;
  - методи оптимізації з розрідженими матрицями Гессе;
  - метод Левенберга-Марквардта та ін.
3. Стохастичні алгоритми оптимізації:
  - пошук у випадковому напрямку;
  - метод Монте-Карлотайн.
4. Алгоритми глобальної оптимізації (задачі глобальної оптимізації вирішуються за допомогою перебору значень змінних, від яких залежить цільова функція).

### 3.2 Навчання з учителем

Метод навчання з учителем включає в себе розв'язання задачі машинного навчання, де модель створюється та оптимізується для функції виведення (вихідної інформації), використовуючи відомі навчальні дані, де кожен приклад в навчальних даних супроводжується відповідним значенням або міткою.

Основним завданням навчання з учителем є розробка моделі, яка може узагальнювати залежність між вхідними даними і відповідними цілями, тобто вона може здійснювати прогнози або класифікацію для нових даних, які не використовувалися під час навчання.

Цей метод використовується для широкого спектру завдань, включаючи класифікацію, регресію, детекцію об'єктів, аналіз тексту та багато інших, і він є одним із найпоширеніших та ефективних підходів в машинному навчанні.

Визначення методу навчання з учителем можна сформулювати так:

задача машинного навчання у реалізації функції виведення на підставі відомих навчальних даних.

Структура навчальних даних складається з набору прикладів для виконання навчання. В даному методі навчання кожен приклад представляє собою пару, що складається з вхідного об'єкта (зазвичай вектора) і бажаного вихідного значення (контрольний сигнал). Необхідно прорахувати значення функції на момент входу даних, потім порівняти значені із значенням очікуваного результату, вирахувати помилку і скорегувати параметри (ваганейронів) мережі на цю помилку.

Алгоритм навчання з учителем[12]:

1. Взяті дані для навчання мережі розділити на дві частини. Першою половиною буде навчальна вибірка, другою - тестова вибірка.(можливо розділити дані 70/30).

2. Прорахувати значення функції для навчальної вибірки та знайти значення функції помилки.
3. Провести корегування ваг синапсів у мережі.
4. Повторювати пункти 2 і 3 до тих пір поки значення функції помилки не буде мінімальним. Повторювати ці дії можна як для кожного екземпляра навчальної вибірки так і для всієї вибірки в цілому. У першому випадку навчання буде повільніше, але з більшою точністю. У другому випадку, показник точності занепадає, але навчання буде відбуватися швидше.
5. Перевірити всі значення за тестовою вибіркою, щоб зрозуміти наскільки добре система змогла узагальнити дані (навчитися).

Якщо нейронна мережа навчається з використанням заздалегідь відомих правильних відповідей, то такий алгоритм навчання називається навчання з учителем. У навчанні з учителем модель навчається на основі пар вхідних даних і відповідних вихідних даних або міток, які називаються правильними відповідями. Мета полягає в тому, щоб модель навчилася відтворювати або передбачати відповіді на нових вхідних даних, користуючись цими навчальними прикладами.

Навчання з учителем використовується в багатьох завданнях, таких як класифікація (де модель визначає клас об'єкта на зображенні або тексті), регресія (де модель передбачає числове значення на основі вхідних даних), машинний переклад, розпізнавання мови, і багато інших. Цей тип навчання є одним із найпоширеніших підходів у машинному навчанні і глибокому навчанні.

Необхідно відзначити, що при навчанні з учителем потрібна велика вибірка, щоб в достатній мірі сформувати робочу і гнучку нейронну мережу.

Потреба в великій вибірці є важливим фактором при розвитку робочої і гнучкої нейронної мережі.

Основні причини цього включають:

- Уникнення перенавчання;

Велика вибірка допомагає запобігти перенавчанню (overfitting). Якщо модель навчається на досить обмеженій кількості прикладів, вона може добре працювати на навчальних даних, але погано справлятися з новими, реальними даними. Велика вибірка дозволяє моделі здійснювати більш загальні та стійкі узагальнення.

- Здатність до виявлення складних закономірностей;

Велика вибірка дозволяє моделі виявляти складні та глибокі закономірності в даних, що може бути особливо важливим для завдань з високою складністю.

- Покращення точності;

Більша кількість прикладів зазвичай призводить до покращення точності та ефективності моделі.

Проте варто також зауважити, що для деяких завдань, особливо у випадку передбачення рідкісних подій або у сферах, де збір великої кількості даних складний чи дорогий, можуть використовуватися методи підвищення даних (data augmentation) або препроцесингу для підвищення ефективності навчання з обмеженою вибіркою.

Методи підвищення даних (data augmentation) та препроцесингу є важливими стратегіями для підвищення ефективності навчання в умовах обмеженої вибірки. Вони дозволяють отримати більше даних або покращити якість наявних даних, що може покращити здатність моделі до узагальнення та підвищити її продуктивність.

Ось деякі основні методи:

- Data Augmentation, цей метод полягає в генерації нових прикладів шляхом зміни наявних даних. В залежності від завдання це може включати відзеркалення, обертання, зміну масштабу, зміну яскравості і контрастності,



афінні перетворення і багато інших операцій. Наприклад, для задачі класифікації зображень можна згенерувати нові зображення за допомогою збільшення/зменшення масштабу та поворотів.

- Препроцесинг даних, це включає в себе обробку та очищення даних перед навчанням. До таких операцій можуть входити видалення шуму, нормалізація даних, видалення аномалій, виділення важливих ознак і багато іншого. Вірний препроцесинг може покращити якість та стабільність навчання моделі.

Генеративні адверсаріальні мережі (GANs), у випадках, коли даних дуже мало, GANs можуть використовуватися для генерації нових прикладів, які подібні до наявних даних. GANs навчаються генерувати нові приклади, які можуть бути використані для розширення вибірки.

Особливості проектування (Feature Engineering), включає в себе створення нових ознак або вибір важливих ознак з вхідних даних. Вірний попередній обробник може значно поліпшити здатність моделі до навчання з обмеженою кількістю прикладів.

Використання цих методів може допомогти покращити навчання моделі, коли ви маєте обмежену кількість доступних даних.

Загалом, велика вибірка є однією з ключових складових успіху в багатьох завданнях навчання з учителем, і вона допомагає створювати більш потужні та загальні моделі.

### 3.3. Навчання без учителя

Метод навчання без учителя, також називають методом неконтрольованого навчання, який має змогу знайти структуру або відносини між різними входами.

Метод навчання без учителя, який також називають методом неконтрольованого навчання (unsupervised learning), спрямований на

виявлення структури або відносин в даних без наявності вихідних міток або учителя, який би вказував моделі, як варто класифікувати дані. У таких методах модель самостійно аналізує вхідні дані і намагається виявити приховані закономірності, кластери або регулярності.

Прикладами методів навчання без учителя є кластеризація (наприклад, алгоритми кластеризації k-середніх або ієрархічна кластеризація), зменшення розмірності (наприклад, метод головних компонентів або t-SNE) і виявлення асоціаційних правил (наприклад, апіорі алгоритм).

Методи навчання без учителя використовуються для різних завдань, таких як сегментація даних, зменшення розмірності для візуалізації даних, пошук аномалій, групування схожих об'єктів і багато інших. Вони допомагають отримати більше розуміння даних та допомагають покращити процеси аналізу та вибору подальших кроків в роботі з даними.

Головна відмінність від методу навчання "з вчителем", це те що в наявності є тільки вхідні дані. Алгоритм навчання без вчителя застосовується по суті тоді, коли відомі тільки вхідні дані. На основі їх мережа вчиться видавати найкращі вихідні результати. Поняттям «найкращих результатів» визначається самим алгоритмом навчання. Зазвичай алгоритм підлаштовує параметри так, щоб мережа видавала однакові результати для достатньо близьких вхідних значень [12].

Метод навчання без учителя (unsupervised learning). Цей метод машинного навчання використовується для розробки моделей, які можуть виявляти приховану структуру або залежності в навчальних даних без використання відомих міток чи цільових значень. Іноді цей метод також називають методом неконтрольованого навчання.

Основні завдання, пов'язані з навчанням без учителя, включають:

1. Кластеризація це розділення навчальних прикладів на групи або кластери на основі подібності між ними. Прикладами алгоритмів кластеризації є k-середніх (k-means), ієрархічна кластеризація та інші.
2. Знання асоціацій це виявлення асоціацій або зав'язків між різними об'єктами чи ознаками у навчальних даних. Прикладами є асоціативні правила та алгоритми асоціативного аналізу.
3. Редукція розмірності це зменшення кількості ознак у навчальних даних з метою збереження важливої інформації та зменшення шуму. Прикладами є методи зменшення розмірності, такі як аналіз головних компонент (PCA) та автоенкодера.
4. Генерація даних це створення нових прикладів даних, які схожі на вхідні дані. Генеративні моделі, такі як варіаційні автоенкодера (VAE) та генеративні прийняття мереж (GANs), використовуються для цієї задачі.

Навчання без учителя важливо в багатьох областях, таких як аналіз даних, видобуток знань із навчальних даних, аналіз тексту, обробка зображень та інші. Він дозволяє виявляти приховану структуру в даних, що може бути важливою для розуміння та використання цих даних.

Найбільш важливим неконтрольованим навчанням є кластеризація, яка створює різні кластери введення і зможе вносити будь-які нові дані до відповідного кластеру. Крім кластеризації є інші методи неконтрольованого навчання: виявлення аномалій, навчання і навчання в теорії Хебба. Приховані змінні моделі, такі як алгоритм максимізації очікувань, метод моментів і методи поділу сліпих сигналів.

Хоча даний метод і часто використовується у прикладних задачах, він часто піддається критиці вчених через свою біологічну схильність. Важко уявити, що у мозку присутній механізм порівняння отриманих результатів з бажаними.

### Висновок до розділу 3

Так, нейронні мережі, особливо глибокі нейронні мережі, мають велику перевагу в задачах класифікації та розпізнавання, завдяки їхній здатності до навчання. Ось декілька причин, чому нейронні мережі є потужним інструментом у цих завданнях:

Нейронні мережі можуть автоматично вивчати корисні ознаки з вхідних даних, що включають в себе навіть складні та абстрактні ознаки, які може бути важко задати вручну. Це дозволяє моделям ефективно робити класифікацію або розпізнавання на різних рівнях абстракції.

Глибокі нейронні мережі, такі як глибокі згорткові мережі (Deep Convolutional Neural Networks або CNNs) і глибокі рекурентні мережі (Deep Recurrent Neural Networks або RNNs), можуть мати багато шарів, що дозволяє їм виражати складні залежності між даними та здійснювати багато різних операцій на кожному рівні.

Нейронні мережі можуть бути навчені на різних завданнях і адаптовані до різних видів даних. Це робить їх відмінними для різних застосувань, включаючи зображення, текст, аудіо, відео тощо.

Нейронні мережі можуть навчатися з учителем, використовуючи великі набори даних з відомими відповідями (мітками), і це дозволяє їм вирішувати завдання класифікації та розпізнавання з високою точністю.

Нейронні мережі мають здатність до генералізації, тобто вони можуть робити прогнози для нових даних, які не були частиною навчального набору. Ця здатність допомагає у створенні моделей, які можуть успішно застосовуватися в реальних умовах.

Важливо відзначити, що успішність нейронних мереж у багатьох випадках також залежить від якості та обсягу навчальних даних, а також від правильного вибору архітектури мережі та гіперпараметрів.

Так, здатність до генералізації є однією з ключових переваг нейронних мереж та багатьох інших методів машинного навчання. Генералізація вказує на здатність моделі впоратися з новими, раніше не баченими даними та робити коректні прогнози чи висновки.

Основні аспекти генералізації в контексті нейронних мереж:

Уникнення перенавчання, однією з головних загроз генералізації є перенавчання, коли модель "запам'ятовує" тренувальні дані, а не навчається виявляти патерни та залежності. Застосування методів регуляризації, таких як викидання (dropout), додавання шуму, або обмеження норми ваг, може допомогти уникнути перенавчання.

Робастність до шуму, моделі, які генералізують добре, зазвичай мають вбудовану робастність до шуму чи нев'язкості в даних. Вони можуть ігнорувати випадкові аномалії чи шум у тренувальних даних та здатні правильно працювати на реальних даних.

Перевірка на тестовому наборі, для оцінки генералізації, навчені моделі перевіряють на тестовому наборі даних, який не використовувався під час навчання. Гарна відповідність моделі на тренувальних та тестових даних свідчить про її здатність до генералізації.

Крос-валідація, для підвищення достовірності оцінки генералізації може бути використана крос-валідація. Цей метод дозволяє розділити тренувальний набір на кілька піднаборів для оцінки моделі на різних комбінаціях навчання та валідації.

Здатність до генералізації робить нейронні мережі корисними в багатьох різних задачах, де важко передбачити всі можливі варіанти даних, з якими модель може зіткнутися в реальних умовах. Ця властивість дозволяє нейронним мережам виявляти складні залежності та робити прогнози в різних областях, таких як медицина, фінанси, обробка природних мов, комп'ютерне зорове сприймання та багато інших.

У задачах класифікації або розпізнавання величезною перевагою нейронних мереж над спеціалізованими алгоритмами постає їх здатність до навчання, тому у розділі 3 розглянуті основні ідеї та методи реалізації цього складного процесу. Щоб покращити та пришвидшити процес навчання, а також уникнути такої події, як перенавчання, мереж звертаються до математичних засобів, таких як алгоритм зворотнього поширення помилки або процедур нормалізації.

Оцінити якість мереж допомагають такі показники, як точність та втрата (обраховується функцією втрат), побудувавши графік яких, чи подавши у вигляді таблиць, можна провести аналітику напрацьованих результатів. У розділі 3 було запропоновано архітектуру згорткової мережі із ієрархічним класифікатором (базової моделі).

Точність і втрата (обчислена функцією втрат) - це два ключові показники для оцінки якості нейронних мереж, зокрема в завданнях класифікації. Ці показники можуть бути використані для аналізу результатів моделі та її здатності до генералізації.

Точність це відсоток правильних прогнозів, який розраховується як кількість правильних прогнозів поділена на загальну кількість прикладів у тестовому наборі. Точність вимірює, наскільки добре модель впоралася з класифікацією даних. Більша точність вказує на кращу якість моделі.

Втрата це числова величина, яка відображає рівень помилок моделі у прогнозуванні. Зазвичай це функція втрат, така як середньоквадратична втрата (MSE) для задач регресії або крос-ентропія для задач класифікації. Зменшення втрати свідчить про покращення якості моделі.

Аналіз точності та втрат можна проводити різними способами:

Графіки точності та втрат на тренувальному та валідаційному наборах даних можуть допомогти візуалізувати процес навчання та виявити епоху

перенавчання (коли втрата на валідаційному наборі збільшується, а точність падає).

Звіти або таблиці можуть бути створені для порівняння точності та втрат різних моделей або конфігурацій. Це дозволяє зробити об'єктивну оцінку моделей.

Крім точності та втрати, існують інші метрики якості, такі як матриця плутанини, точність, відзив, F1-показник, ROC-крива, AUC і так далі, які можуть надати більше інформації про роботу моделі.

Повторювана крос-валідація допомагає отримати середню точність та втрату для моделі на різних піднаборах даних. Це дозволяє отримати більш об'єктивну оцінку моделі.

Аналіз точності та втрат є важливою частиною процесу розробки та налаштування нейронних мереж, і він допомагає визначити, наскільки добре модель впоралася зі своєю завданням і чи не відбувається перенавчання.

## ВИСНОВКИ

Важливою властивістю нейронних мереж є їх здатність до навчання на основі даних навколишнього середовища та у результаті навчання підвищити свою продуктивність. Ця здатність називається "навчанням з учителем" (supervised learning) і полягає в тому, що модель навчається за допомогою пар вхідних даних і відповідних вихідних даних або міток. Після навчання модель здатна генерувати прогнози або класифікувати нові вхідні дані на основі здобутих знань.

Проте важливо зауважити, що нейронні мережі також можуть використовуватися для навчання без учителя (unsupervised learning) та для роботи з невеликими наборами даних, де відсутні мітки. У таких випадках модель намагається виявити приховані закономірності в даних і створити репрезентацію або кластеризувати дані без зовнішнього навчального сигналу.

Здатність нейронних мереж до навчання та адаптації до різних завдань робить їх потужними інструментами в багатьох галузях, включаючи машинне навчання, комп'ютерне зорове сприйняття і багато інших.

Посилення продуктивності відбувається з часом у відповідності до певних правил. Загалом навчання нейронної мережі відбувається за допомогою інтерактивного процесу корекції синаптичних ваг нейронів в мережі. В ідеальному випадку нейронна мережа отримує знання із навколишнього середовища на кожній ітерації процесу свого навчання. У даній роботі розглянуто особливості основних методів, а також технік навчання нейронних мереж, описано складові частини згорткових мереж та їх взаємозв'язок.

Серед запропонованої кількості архітектур згорткових мереж критерії оцінки якості навчання виражаються через показники, а саме такі, як точність, число втрат (обраховує функція втрат) та інші.



Програмна реалізація згорткових нейронних мереж базується на використанні технологій глибокого навчання представлених у вигляді бібліотек та спеціальних пакетів, що дозволяють програмістам проектувати архітектури мереж та налаштовувати параметри.

Головною ідеєю вдосконалення способу класифікації згорткової нейронної мережі є ієрархічний класифікатор, котрий стане універсальним інструментом для обрахунку точності застосованим на багатьох вхідних наборах даних. Основа ієрархії класифікатора лежить у кластеризації поданих класів.

Важливим етапом покращення дії класифікації є також вибір базової моделі згорткової нейронної мережі та обрахунок її показників точності, параметрів в залежності від розміру кроку навчання та використаного алгоритму, аби надалі мати розуміння які саме архітектурні рішення вносити, що досягти оптимізації моделі та покращення роботи. Програмно модель згорткової нейронної мережі було реалізовано за допомогою бібліотеки Keras мовою Python, а для виконання складних математичних обчислень використовувалась бібліотека TensorFlow. Обрану базову модель було навчено на семивхідних наборах даних.

Для виконання даної роботи була поставлена мета – створити дослідження методів і алгоритмів класифікації на підставі згорткових нейронних мереж, які зможуть розпізнавати зображення.

Для цього були виконані наступні кроки:

- аналіз вже існуючих рішень розпізнавання, проведено їх порівняльна характеристика. На цьому етапі ми обґрунтували актуальність роботи та її необхідність для покращення розуміння методів класифікації зображень сільськогосподарських територій.

- було наведено математичний апарат для вирішення проблеми класифікації зображень. Було вирішено застосовувати нейронні мережі, адже

вони мають результати краще, ніж більш прості алгоритми машинного навчання.

- були наведені приклади вже існуючих архітектур нейронних мереж, їх детальний опис та порівняльний аналіз.

- було наведено опис підготовки даних до навчання нейронної мережі.

Згорткові мережі (Convolutional Neural Networks або CNNs) є потужними інструментами в області комп'ютерного зору та обробки зображень. Вони здатні автоматично виявляти різні об'єкти на зображеннях і використовуються в безлічі застосувань розпізнавання об'єктів.

Ось деякі питання, які можемо врахувати, щоб додати ще більшу корисність моделі:

#### 1. Дані:

Які дані були використані для навчання моделі? Які мають бути об'єкти для розпізнавання, і як вони були підготовлені?

#### 2. Архітектура моделі:

Яка конкретна архітектура CNN використовується в вашій моделі? Чи є можливість оптимізувати її для конкретних завдань чи об'єктів?

#### 3. Гіперпараметри:

Чи були налаштовані гіперпараметри моделі (наприклад, розмір ядра свертки, кількість шарів тощо)? Чи може бути поліпшена ефективність моделі через налаштування гіперпараметрів?

#### 4. Навчання та перенавчання:

Як було проведено навчання моделі, і чи було виявлено перенавчання? Чи використовувалися методи регуляризації для запобігання перенавчанню?

#### 5. Оцінка та тестування:

Як ви оцінювали ефективність вашої моделі? Чи були проведені тестування на незалежних даних для перевірки її продуктивності?

6. Результати та використання:

Які результати були отримані, і як вони можуть бути використані у практиці чи в конкретних застосунках?

7. Можливості покращення:

Чи є можливості для подальшого покращення моделі, додавання нових функцій чи використання додаткових даних?

За наявності відповідей на ці питання, ви можете розширити і вдосконалити свою модель для ще більш корисного та точного розпізнавання об'єктів зображень сільськогосподарських територій.

Результатом роботи стала розроблена модернізована модель, на основі базової архітектури, згорткової мережі для розпізнавання об'єкта, що може застосовуватися одразу до семи наборів даних завдяки такому універсальному інструменту, як ієрархічний класифікатор. Нову модель представлено з урахуванням таких змін, щодо базової моделі, як збільшення числа фільтрів вхідного шару, збільшення розміру підвибірки максимуму та вилучення нейронів зміщення у вихідних шарах. Значне підвищення значення відсотку точності розпізнавання майже для усіх запропонованих для тестування наборів даних, а також зменшення числа параметрів мережі було досягнуто завдяки новій моделі архітектури згорткової мережі у поєднанні з ієрархічним класифікатором.

Це важливий крок у розробці моделі для розпізнавання об'єктів. Оновлена модель, яка базується на згортковій мережі (CNN), може бути дуже корисною, оскільки CNN добре справляються з завданнями обробки зображень та розпізнавання об'єктів на них.

Здатність застосовувати цю модель до семи різних наборів даних свідчить про універсальність моделі і її можливість розв'язувати різні

завдання розпізнавання об'єктів. Ієрархічний класифікатор також може бути дуже корисним інструментом, оскільки він дозволяє організувати рівні класифікації та структурувати вихідні результати.

Ця модель може бути корисною в багатьох галузях, включаючи комп'ютерне зорове сприйняття, обробка сільськогосподарських зображень, автономне водіння, відслідковування об'єктів та інші області, де розпізнавання об'єктів на зображеннях є важливою задачею.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Дж. Ту, Р. Гонсалес. Принципы распознавания образов. М., Мир, 1978.
  2. Гонсалес Р., Вудс Р. Цифровая обработка изображений. М.: Техносфера, 2005. - 1072 с.
  3. Каллан Р. Основные концепции нейронных сетей The Essence of Neural Networks First Edition. — 1-ше. — «Вильямс», 2001. — С.
  4. Кудрявцев Л. Д. Математический анализ. — 2-е изд. — М.: Высшая школа, 1973. — Т.1.
  5. Т. Xiao, J. Zhanget al. ,“Error-driven incremental learning in deep convolutional neural network for large-scale image classification,” in International Conference on Multimedia, no. 22. ACM, 2014, pp. 177– 186.
  6. J. Ortigosa-Hernández, I. Inza, and J. A. Lozano, “Towards competitive classifiers for unbalanced classification problems: A study on the performance scores,” arXiv preprint arXiv:1608.08984, Aug. 2016.  
[Online]. Available: <https://arxiv.org/abs/1608.08984>
  7. F.Chollet,“Keras,”<https://github.com/fchollet/keras>, 2015
  8. M. Abadi, A. Agarwal et al., “Tensorflow: Large-scale machine learning on heterogeneous distributed systems,” arXiv preprint arXiv:1603.04467, Mar. 2016.  
[Online]. Available: <https://arxiv.org/abs/1603.04467>
  9. Тарасенко-Клятченко О.В., Буц В.В. стаття «Організація багатоступеняного методу навчання згорткової нейронної мережі».
- Журнал «Інтернаука» випуск 6 (березень 2018). [Інтернет-ресурс]  
Посилання: <https://www.inter-nauka.com/issues/2018/6/3624/>
10. Создаем нейронную сеть / Тарик Рашид : [пер. с англ. — СПб.: ООО “Альфа-книга”]. — Санкт-Петербург: “Альфа-книга”, 2017. — 272 с.
  11. Суворова Е. Ю. Анализ основных технологий вычислительного интеллекта/ Е. Ю. Суворова. // ЛНУ имени Тараса Шевченка. – №20.
  12. Згуровський М. З. Основи вычислительного интеллекта/ М. З. Згуровський, Ю. П. Зайченко. – Киев: Наукова думка, 2013. – 406 с.

13. A. Krizhevsky, I. Sutskever, G. E. Hinton, ImageNet Classification with Deep Convolutional Neural Networks // University of Toronto, 2012.
14. K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016, pp. 770-778, doi: 10.1109/CVPR.2016.90.
15. V. Hatzivassiloglou, K. McKeown Predicting the semantic orientation of adjectives. Proceedings of the Joint ACL/EACL Conference. 1997. P. 174–181. 68
16. G. Katz, N. Ofek, and B. Shapira Context-based sentiment analysis, KnowledgeBased Systems. ConSent. 2015. Vol. 84, No. 1. P. 162–178. 69
17. Hogenboom, A., Bal, D., Frasinca, F., Bal, M., De Jong, F., & Kaymak, U. Exploiting emoticons in polarity classification of text. Journal of Web Engineering, 2015. Vol. 14. P. 22–40.
18. LeNet-5-A Classic CNN Architecture URL: <https://mobilemonitoringsolutions.com/lenet5%E2%80%8A-%E2%80%8Aclassic-cnn-architecture/>
19. Simonyan K. Very deep convolutional networks for large-scale image recognition/ K. Simonyan, A. Zisserman. // Visual Geometry Group, Department of Engineering Science, University of Oxford. – 2015. – C. 2,3.
20. #013 B CNN AlexNet URL: <http://datahacker.rs/deep-learning-alexnetarchitecture/>.
21. Review: GoogLeNet (Inception v1)— Winner of ILSVRC 2014 (Image Classification) URL: <https://medium.com/coinmonks/paper-review-of-googlenetinception-v1-winner-of-ilsvlc-2014-image-classification-c2b3565a64e7>.
22. VGG16 – Convolutional Network for Classification and Detection URL: <https://neurohive.io/en/popular-networks/vgg16/>.

## ДОДАТКИ

## Додаток А Приклади зразків зображень з поясненнями.

Характеристика	Приклад зображення
<p>Ортофотоплан витоптаних (знищених) технікою посівів на полях, для подальшого розрахунку площі знищених посівів.</p>	
<p>Точковий обліт проблемних зон, виявлених при супутниковому моніторингу для проведення планових післясхідних обльотів усіх культур (необхідно виявлення можливих додаткових просівів).</p>	



Обстеження поля як звичайною камерою, так і спектральною.

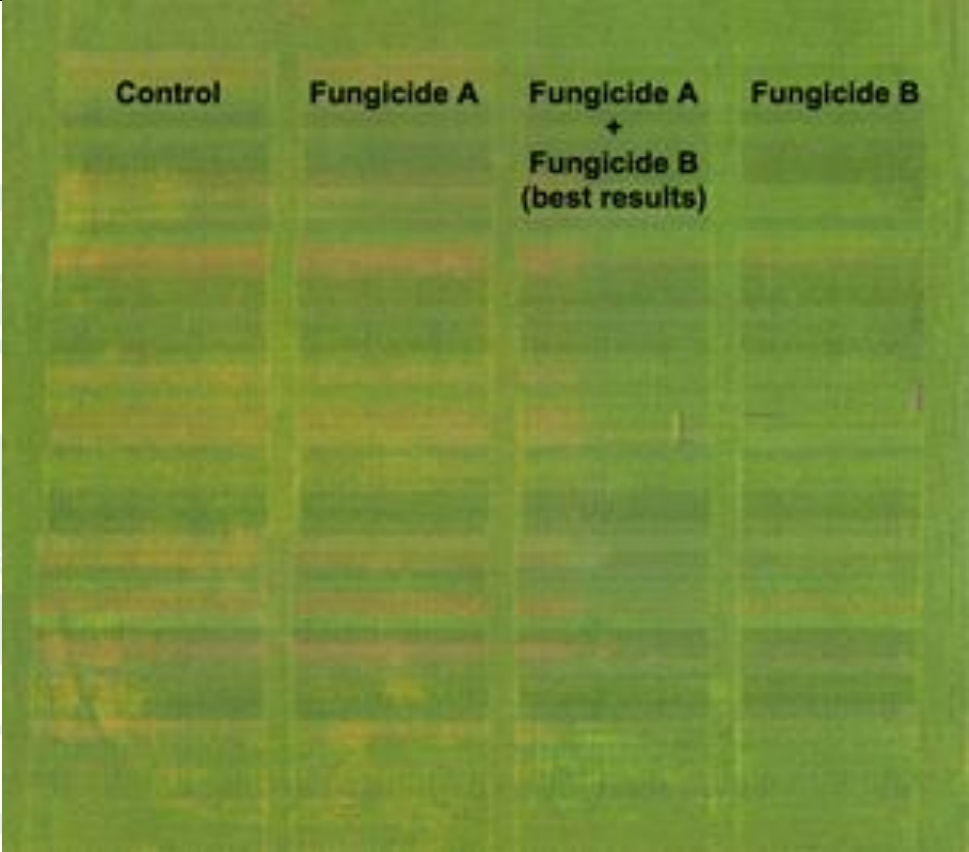
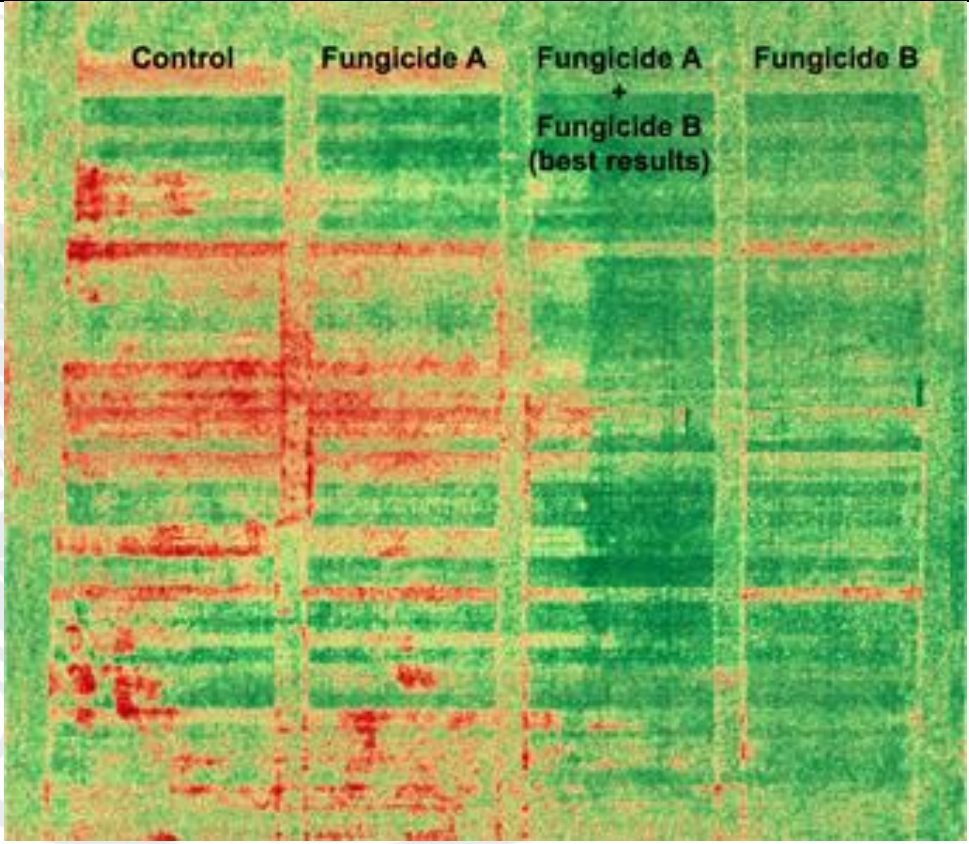


Зйомка на низькій висоті з прив'язкою до вибраних точок (це дозволяє визначити рівень засміченості, види бур'янів, пошкодження рослин).





<p>Дозволяє дати об'єктивну оцінку стану поля. Допомагає прийняти точне рішення щодо технологічної операції. І цим отримати очікувані параметри врожаю.</p>	
<p>Випробування сівозміни земель, у якій порівнювалися три рівні інтенсивності обробітку: традиційне обробіток, мінімальне обробіток ґрунту та без обробітку ґрунту.</p>	

<p>Обстеження з складанням карти-плану зволоження чи осушення ґрунту, рекультивації ділянок чи меліорації земель. Це дуже корисно для документування збитків урожаю та полям.</p>	
<p>Дослідження за допомогою інфрачервоного випромінювання – як прості (наприклад, вимірювання температури ґрунту), так і складні (визначення різниці зростання рослин).</p>	

Додаток 2 до наказу  
від «31» березня 2023 року  
№119/05

## ДЕКЛАРАЦІЯ

про дотримання академічної доброчесності

Я, \_\_\_\_\_

*Повністю вказується ПІБ та статус (посада для працівників, освітня (освітньо-наукова) програма – для здобувачів вищої освіти)*

що нижче підписалась/підписався, розуміючи та підтримуючи загально визнані засади справедливості, доброчесності та законності,

### **ЗОБОВ'ЯЗУЮСЬ:**

дотримуватися принципів та правил академічної доброчесності, що визначені законодавством України, локальними нормативними актами Донецького національного університету імені Василя Стуса, положеннями, правилами, умовами, визначеними іншими суб'єктами, та не допускати їх порушення.

### **ПІДТВЕРДЖУЮ:**

що мені відомі положення статті 42 Закону України «Про освіту»;  
що у даній роботі не представляла/представляв чийсь роботи повністю або частково як свої власні. Там, де я скористалася/скористався працею інших, я зробила/зробив відповідні посилання на джерела інформації;  
що дана робота не передавалась іншим особам і подається вперше, не порушує авторських та суміжних прав закріплених статтями 21-25 Закону України «Про авторське право та суміжні права», а дані та інформація не отримувались в недозволеній спосіб.

### **УСВІДОМЛЮЮ:**

що ця робота може бути перевірена університетом на плагіат або інші порушення академічної доброчесності, в тому числі з використанням спеціалізованих сервісів;  
що у разі порушення академічної доброчесності, до мене можуть бути застосовані процедури, передбачені законодавством України та Кодексом академічної доброчесності та корпоративної етики Донецького національного університету імені Василя Стуса, іншими локальними нормативними актами університету, та я можу бути притягнута/притягнутий до академічної відповідальності.

\_\_\_\_\_ (дата)

\_\_\_\_\_ (підпис)