

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Тернопільський національний економічний університет
Навчально-науковий інститут інноваційних освітніх технологій
Кафедра комп'ютерної інженерії

ДЕРІЙ Михайло Володимирович

Алгоритми зменшення простору ознак при
класифікації біомедичних зображень / Feature
Space Reduction Algorithms for Biomedical Images
Classification

спеціальність: 123 - Комп'ютерна інженерія
магістерська програма - Комп'ютерна інженерія

Магістерська робота

Виконав студент групи КІзм-21
М. В. Дерій

Науковий керівник:
к.т.н., Г. М. Мельник

Магістерську роботу допущено
до захисту:

"31" 01 2018 р.

Завідувач кафедри

О. М. Березький

ТЕРНОПІЛЬ - 2018

Тернопільський національний економічний університет
Навчально-науковий інститут інноваційних освітніх технологій
Факультет комп'ютерних інформаційних технологій
Кафедра комп'ютерної інженерії
Освітній ступінь «магістр»
спеціальність: 123 - Комп'ютерна інженерія
магістерська програма - Комп'ютерна інженерія

ЗАТВЕРДЖУЮ

Завідувач кафедри

_____ О.М. Березький

“ _____ ” _____ 20__ р.

ЗАВДАННЯ НА МАГІСТЕРСЬКУ РОБОТУ СТУДЕНТУ

Дерій Михайло Володимирович

(прізвище, ім'я, по батькові)

1. Тема магістерської роботи «Алгоритми зменшення простору ознак при класифікації біомедичних зображень / Feature Space Reduction Algorithms for Biomedical Images Classification»

керівник роботи к.т.н., Г.М. Мельник

затверджені наказом по університету від 17 листопада 2016 р. № 669.

2. Строк подання студентом роботи «15» січня 2018 року

3. Вихідні дані до магістерської роботи

Об'єкт дослідження – процес аналізу біомедичних зображень.

Предмет дослідження – методи і алгоритми зменшення простору ознак та класифікації біомедичних зображень.

4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити)

- проаналізувати особливості гістологічних зображень та їх ознаки;
- здійснити огляд алгоритмів класифікації зображень;
- здійснити огляд алгоритмів зменшення простору ознак;
- запропонувати числові ознаки для оцінки структурної текстури гістологічного зображення;
- розробити алгоритм зменшення простору ознак на основі методу головних компонент;
- здійснити програмну реалізацію розроблених алгоритмів;
- провести опрацювання тестової вибірки фрагментів гістологічних зображень.

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень):
- мета роботи, об'єкт та задачі дослідження
 - текстурні ознаки матриці розподілу рівнів сірого;
 - порівняння програмного забезпечення САМ;
 - умови класифікації;
 - текстурні ознаки локальні бінарні шаблони;
 - формування бібліотек текстур і етапи класифікації;
 - ілюстрація методу головних компонент;
 - схема алгоритму головних компонент;
 - структура програмного забезпечення;
 - експериментальне дослідження розроблених алгоритмів.

6. Консультанти розділів магістерської роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		Завдання видав	Завдання прийняв
Антиплагіат	Мельник Г.М., доцент		
Нормо-контроль	Гураль І. В., викладач		

7. Дата видачі завдання «20» листопада 2016 р.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів магістерської роботи	Строк виконання етапів магістерської роботи	Примітка
1	Огляд алгоритмів класифікації біомедичних зображень	20.11.2016 – 1.01.2017	
2	Алгоритми зменшення простору ознак	2.01.2017 – 31.05.2017	
3	Експериментальне дослідження розроблених алгоритмів	1.06.2017 – 25.01.2018	
4	Нормоконтроль, попередній захист	16.01.2018 – 31.01.2018	
5	Захист	2.02.2017	

Студент _____ Дерій М.В.
(підпис)

Керівник магістерської роботи _____ к.т.н., Г.М. Мельник
(підпис)

РЕЗЮМЕ

Магістерська робота на тему «Алгоритми зменшення простору ознак при класифікації біомедичних зображень» зі спеціальності 123 «Комп'ютерна інженерія» написана обсягом 88 сторінок і містить 12 ілюстрації, 5 таблиць, 3 додатки та 50 джерела за переліком посилань.

Метою роботи є розроблення алгоритмів зменшення простору ознак при класифікації біомедичних зображень на основі методу головних компонент, що дозволяють отримати компактну множину ознак та зменшити час класифікації зображень.

Методи дослідження включають методи: штучного інтелекту, комп'ютерного зору, теорію алгоритмів і систем, основні положення алгебри логіки, положень теорії алгоритмів.

У результаті виконання дипломного проекту здійснено програмну реалізацію розроблених алгоритмів. Проведено експериментальне дослідження алгоритмів зменшення простору ознак при класифікації біомедичних зображень на основі методу головних компонент. Для експериментів обрано базу даних гістологічних зображень Breast Cancer Dataset. Зображення розбиті на три класи: фон, ядро клітини, з'єднувальна тканина. Вихідний простір текстурних ознак складається із ознак на основі МРРС: контраст, несхожість, однорідність, другий кутовий момент. Простір ознак зменшено до двох, що дозволили класифікувати три типи тканини на гістологічному зображенні.

Результати роботи можуть бути використані при побудові інтелектуальних систем аналізу біомедичних зображень.

Можливими напрямками подальших досліджень є продовження робіт по класифікації гістологічних зображень: розробка алгоритмів класифікації зображень на основі структурних ознак та ознак мікрооб'єктів.

КЛЮЧОВІ СЛОВА: ТЕКСТУРА, КЛАСИФІКАЦІЯ, ПРОСТІР ОЗНАК, МЕТОД ГОЛОВНИХ КОМПОНЕНТ.

RESUME

Master's thesis on the topic «Feature Space Reduction Algorithms for Biomedical Images Classification» from the specialty 123 "Computer Engineering". Thesis contains 88 pages, 12 figures, 5 tables, 3 appenixes and 50 references sources.

The aim is to develop algorithms for feature space reduction in the classification of biomedical images on the basis of principal components that provide a compact set of signs and reduce the image classification.

Research Methods based on the use of artificial intelligence techniques, the main provisions of the logic algebra, the provisions of the theory of algorithms, computer vision techniques.

As a result of the completion of the diploma project implemented program implementation of the developed algorithms. Experimental research of algorithms for reducing the space of signs in the classification of biomedical images based on the method of the main components has been carried out. For experiments, the Breast Cancer Dataset histological images database is selected. The images are divided into three classes: background, cell nucleus, connective tissue. Output space texture features consists of features based on GLCM: contrast, dissimilarity, homogeneity, second angular momentum. The space of features is reduced to two, which allowed to classify three types of tissue on the histological image.

The results of the work can be used in the construction of intelligent systems for the analysis of biomedical images.

Possible areas of future research is to continue work on the classification of histological images: development of algorithms for image classification based on the structural characteristics and microscopic signs.

KEYWORDS: TEXTURE, CLASSIFICATION, FEATURE SPACE, PRINCIPAL COMPONENT ANALYSIS

ЗМІСТ

Вступ.....	7
1 Огляд алгоритмів класифікації біомедичних зображень	10
1.1 Текстурний аналіз біомедичних зображень	10
1.2 Класифікація зображень на основі текстурних ознак.....	16
1.3 Програмне забезпечення аналізу біомедичних зображень.....	26
1.4 Постановка завдань дипломної роботи	30
2 Алгоритми зменшення простору ознак.....	31
2.1 Текстурні ознаки на основі локальних бінарних шаблонів.....	31
2.2 Двокроковий алгоритм класифікації.....	35
2.3 Зменшення простору ознак на основі методу головних компонент.....	37
3 Експериментальне дослідження розроблених алгоритмів.....	51
3.1 Інструментальні засоби	51
3.2 Об'єктна модель системи онкологічної діагностики	59
3.3 Експериментальні дослідження.....	65
Висновки	71
Список використаних джерел.....	72
Додаток А Вихідний текст реалізованих алгоритмів аналізу зображень.....	77
Додаток Б Довідка про використання	86
Додаток В Копія публікації.....	87

ВСТУП

Актуальність теми. На даний момент більшість етапів гістологічного дослідження здійснюються людиною. Автоматизований аналіз є об'єктивнішим і дає можливість отримувати не лише якісні, але і кількісні оцінки структурних змін елементів тканини. Одним з головних етапів автоматизації вимірювань оптичних і геометричних параметрів є виділення об'єктів на гістологічних препаратах. Основною причиною відсутності автоматизації в гістології є висока варіабельність і слабкий контраст більшості гістологічних структур.

Одна з найбільших сфер застосування текстурного аналізу - це медицина. Медики за допомогою текстурного аналізу здатні виявити пухлину або патології на медичних знімках, а також визначити об'єми тканин і органів. Найчастіше він застосовується для виявлення злоякісних новоутворень на рентгенівських знімках. Однак на сьогоднішній день такий підхід не досить точний для того, щоб повністю на нього покластися і прибрати людський фактор при аналізі рентгенівських знімків. Але він набув широкого поширення в якості допоміжного механізму діагностики.

Текстурний аналіз знімка далеко не тривіальна задача. Першим кроком обробки зазвичай являється сегментація фото на області різного типу. Однак потрібно не просто розбити зображення на області, а й виявити аномалії - місця, які явно виділяються з однорідного фону. Крім того, в результаті виявлення області зі схожими властивостями повинні бути і позначені схожим чином. Для цього за допомогою аналізу відбувається виділення характерних властивостей кожної області. Цей аспект задачі і розглядається текстурною класифікацією.

Основною складністю завдання текстурного аналізу зображень являється підбір методів сегментації і текстурної ідентифікації, котрі враховують особливості предметної області і підбір дескрипторів, які максимально точно описують саме текстури природного походження

Мета і завдання дослідження. Метою роботи є розроблення алгоритмів зменшення простору ознак при класифікації біомедичних зображень на основі

методу головних компонент, що дозволяють отримати компактну множину ознак та зменшити час класифікації зображень.

Об'єкт дослідження – процес аналізу біомедичних зображень.

Предмет дослідження – методи і алгоритми зменшення простору ознак та класифікації біомедичних зображень.

Для досягнення поставленої мети необхідно розв'язати такі задачі:

- проаналізувати особливості гістологічних зображень та їх ознаки;
- здійснити огляд алгоритмів класифікації зображень;
- здійснити огляд алгоритмів зменшення простору ознак;
- запропонувати числові ознаки для класифікації текстури гістологічного зображення;
- розробити алгоритм зменшення простору ознак на основі методу головних компонент;
- здійснити програмну реалізацію розроблених алгоритмів;
- провести опрацювання тестової вибірки біомедичних зображень.

Методи досліджень базуються на використанні методів текстурного аналізу зображень, методів комп'ютерного зору, положень теорії алгоритмів і аналітичної геометрії.

Наукова новизна одержаних результатів. Розроблено алгоритм зменшення простору текстурних ознак при класифікації біомедичних зображень на основі методу головних компонент, що дозволило отримати компактну множину ознак.

Практичне значення отриманих результатів. У рамках даної роботи розроблений модуль класифікації зображень для системи онкологічної діагностики. Експериментально доведена ефективність запропонованих алгоритмів.

Публікації та апробація дипломної роботи. Отримані результати апробовані в межах 72-ї науково-технічної конференції професорсько-викладацького складу, науковців, аспірантів та студентів Одеської національної академії зв'язку ім. О.С. Попова та опубліковано одні тези доповіді по темі роботи [1].

Впровадження результатів ДР. Результати роботи планується використати в роботі науково-дослідному інституті інтелектуальних комп'ютерних систем (додаток Б).

Дипломна робота складається із трьох розділів, висновків, списку використаної літератури та додатків. У першому розділі розділі визначено основні поняття текстурного аналізу. Проведено огляд існуючих методів та алгоритмів вирішення задач текстурного аналізу. Розглянуто задачу Класифікація зображень на основі текстурних ознак. Визначено проблеми побудови простору текстурних ознак та визначено вимоги до ознак. Розглянуто структуру та функції програмного забезпечення аналізу біомедичних зображень. Підсумовано переваги і недоліки систем автоматизованої мікроскопії.

Другий розділ присвячений аналізу текстурні ознаки на основі локальних бінарних шаблонів. З метою скорочення розміру текстур і підвищення точності опису вводиться модифікований, інваріантний щодо повороту, оператор. Розроблено двокроковий алгоритм класифікації на основі оператора локальних бінарних шаблонів. Розроблено алгоритм Зменшення простору ознак на основі методу головних компонент.

У третьому розділі здійснено програмну реалізацію розроблених алгоритмів. Проведено експериментальне дослідження алгоритмів класифікації зображень та алгоритмів зменшення простору ознак при класифікації біомедичних зображень на основі методу головних компонент.

1 ОГЛЯД АЛГОРИТМІВ КЛАСИФІКАЦІЇ БІОМЕДИЧНИХ ЗОБРАЖЕНЬ

1.1 Текстульний аналіз біомедичних зображень


Злоякісні зміни у тканинах людини призводять до спотворення порядку в якому розміщені клітини всередині шару тканини в нормальному стані. Якщо розглядати клітини як окремі елементи і аналізувати порядок їх розміщення, то для аналізу гістологічних зображень (ГЗ) можна застосувати методи і алгоритми аналізу текстур. Текстура в загальному випадку – це функція просторової зміни розподілу інтенсивностей пікселів. Більшість дослідників погоджуються, що зображення текстури повинне бути просторово однорідне, і зазвичай містить повторювані структури, часто з деякою випадковими змінами (наприклад, зміною позиції, орієнтації або кольору). Текстура відображає фізичні властивості поверхні об'єкту. Для опису текстури [19] використовують структурні методи, моделі базовані на випадкових марківських процесах, фрактальну, геометричну модель і модель оброблення сигналів [2-4].

Опишемо основні поняття текстурного аналізу.

Будемо називати текстурою зображення, що складається з довільних елементів, що повторюються і відображають будь які візуальні властивості фізичного об'єкта. За типом і розміром примітивів текстуру можна розділити на регулярні, коли структурні елементи текстури розподілені рівномірно, нерегулярні, коли елементи розташовані нерівномірно і фрактальні, коли структурні елементи утворюють фрактал. На рисунку 1.1 показані приклади різних типів текстур.

Дескриптором текстури називається функція, яка описує текстуру за основними характеристиками. Можна вважати дескриптор текстури альтернативним представленням текстур для якого можна ввести міру схожості. Приклади дескрипторів:

- словесний опис (назва);
- гістограма;
- багатомірний вектор.



а)



б)



в)



г)

Рисунок 1.1 - Приклади різних текстур: а) регулярна, б) нерегулярна фрактальна, в) нерегулярна, г) має ознаки як регулярної, так і нерегулярної текстури.

Сегментацією зображення називається процес розбиття на кілька зв'язаних замкнутих непересічних областей, при цьому зв'язки між елементами всередині однієї області сильніші зв'язків між елементами різних областей.

Класифікацією текстур називається визначення належності текстури до одного із заданих наперед типів (класів) текстур.

Узагальнений алгоритм обробки біомедичних зображень:

1. Обробка. Даний етап включає в себе корекцію освітлення для занадто темних або занадто освітлених фотознімків, підвищення контрастності. Цей етап не є обов'язковим, але в деяких випадках значно підвищує точність подальшої обробки.

2. Сегментація на текстурні блоки. Все зображення розбивається на окремі області.

3. Після проведення сегментації можуть виникнути області, площа яких недостатня для проведення класифікації. Тому для обробки необхідно об'єднати кожну область з пов'язаною з нею найбільш схожою областю. У підсумку отримуємо набір областей, розмір кожної з яких, достатній для текстурної класифікації. На цьому етапі належить визначити критерій «прилягання» областей і підібрати мінімальну класифіковану площу.

4. Класифікація текстур кожної області. Для всіх отриманих на третьому кроці регіонів обчислюється дескриптор, за яким за допомогою міри схожості обчислюється ступінь приналежності текстури розглянутій області кожного класу текстур. База текстур з уже обчисленими для кожного класу дескрипторами підбирається заздалегідь і не залежить від використаного

алгоритму класифікації та сегментації, але залежить від предметної області. На цьому етапі необхідно вибрати тип дескриптора (безпосередньо пов'язаний з методом класифікації), міру схожості (ввести метрику на безлічі дескрипторів) і підібрати базу текстур найбільш точно відображає особливості предметної області.

5.Об'єднання областей одного класу. Це дозволить скоротити об'єм інформації і прискорити будь-яку подальшу роботу з результатами обробки фотознімки за рахунок скорочення числа областей.

Проведемо огляд існуючих методів та алгоритмів вирішення задач текстурного аналізу.

При обробленні ГЗ методи текстурного аналізу використовують для задач сегментації, класифікації, розпізнавання та пошуку і вибірки зображень із баз даних.

Узагальнена класифікація текстур базується на визначенні закономірності розміщення її елементів і, власне, можливості їх ідентифікації. Регулярні текстури – це набір примітивів із строгим правилом розміщення (правильна решітка, мозаїка). Такі зображення утворені паралельним переносом певного елемента (фрагмента, примітива). Кожен такий примітив можна обмежити паралелограмом або шестикутником, відповідно може існувати два типи решітки переносів – чотирикутна та шестикутна. Якщо решітка розміщення елементів починає спотворюватись то текстуру можна назвати близькорегулярною. Примітиви на ній виділити легко, правило розміщення нестроге. Якщо і далі спотворювати правило розміщення наближаючи його до хаотичного отримаємо нерегулярну текстуру. Примітиви, все ще, виділити легко, але правило розміщення випадкове. На близькостохастичних примітиви володіють однорідністю точок і складністю форми. На стохастичних текстурах відсутні легко ідентифіковані примітиви.

Текстурна сегментація полягає у визначенні областей із однаковими текстурними ознаками, таким чином, що подальший аналіз може виконуватися лише на відповідних областях. Знайдені однорідні області відповідають певним типам тканин органів. Складність текстурної сегментації зображень [5] пояснюється статистичною різноманітністю текстур, великою кількістю

розроблених ознак, великою кількістю параметрів алгоритмів та ручним вибором параметрів.

Класифікація зображень на основі текстурних ознак полягає у віднесенні однорідних областей до певних класів. В найпростішому випадку класами є міжклітинна рідина (фон), цитоплазма клітин, ядра клітин, міжклітинна з'єднувальна тканина, перерізи судин, шари клітин та ін. Однією з основних проблем класифікації текстур є великий простір ознак [6].

Методи, що застосовуються для аналізу текстур, можна розділити так: структурні (геометричні), статистичні, методи засновані на моделях, методи обробки сигналів. Мікрооб'єкти одного класу (клітини, ворсинки) на ГЗ відрізняються по формі, кольору, текстурі і розміру в певних межах. Тому кореляційний метод детекції текстурних елементів та метод на основі характерних точок контуру мікрооб'єкта дають неточний результат.

Структурні або геометричні методи аналізу припускають, що текстури складені з текстурних елементів (ТЕ), розміщених згідно певного правила. Дані методи і алгоритми застосовуються для регулярних, близькорегулярних і нерегулярних текстур. Структурний аналіз складається з двох основних етапів: детекція елементів текстури і опис правил розміщення. На гістологічні зображеннях біологічних тканин текстурним елементом є клітина.

Методи пошуку ТЕ на зображеннях природних об'єктів розглянуті в роботах [7, 8]. Виділимо два підходи до детекції ТЕ та опису зв'язків між ними. Перший підхід полягає в детекції та пошуку сусідніх ТЕ шляхом кореляції з еталоном. При цьому на основі знайдених значень трансляції між ТЕ будується графова модель зв'язків. Переваги такого підходу: здатність виявляти ТЕ тільки на частині зображення, здатності групувати подібні ТЕ, які перебувають під впливом завад. Недоліком є звуження області застосування до зображення з чіткими контурами ТЕ, які не повернуті один відносно одного.

Автори [9] для пошуку ТЕ застосовують розбиття поверхні на багатокутники Вороного. Геометричні властивості багатокутників Вороного служать текстурними ознаками.

У роботі [10] зображення текстур розглядаються як симетричні зображення заповнені рапортами, відповідно до однієї з 17 груп симетрії

площини. Запропоновано міри геометричної деформації сітки і регулярності кольору ТЕ, які дали змогу віднести текстурні зображення до трьох класів: регулярні, близькорегулярні і нерегулярні.

На другому етапі структурного підходу для опису правил розміщення використовуються наступні зв'язки між знайденими ТЕ: сусідство, трансляція, дотик, включення, перекриття, топологічні відношення. Однією з найбільш часто застосовуваних структур є граф сусідства областей, кожна вершина якого представляє певну область зображення. Дві вершини зв'язані ребром тоді і лише тоді, коли відповідні області мають спільну границю. Граф сусідства створюється на основі розмітки шляхом прослідковування границі кожної області та зберігання ідентифікаційних міток сусідніх областей або у вигляді квадродерева. В статті [11] запропоновано 8 елементарних топологічних відношень між областями (рисунки 1.2): роз'єднані, зовні пов'язані, рівні, частково перекриваються, дотична власна частина, інверсна дотична власна частина, не дотична власна частина, інверсна не дотична власна частина. Алгоритм обчислення даних відношень використовується в ПЗ ImageJ для знаходження відповідності окремо знайдених ядер і цитоплазми клітин і знаходження ядерно-цитоплазматичного коефіцієнту. Недоліками простих систем просторових відношень є відсутність врахування орієнтації ТЕ та її форми.

Статистичні методи аналізу текстур [12-14] описують просторовий розподіл рівнів сірого точок зображення. Однією з найпоширеніших статистичних текстурних ознак є матриці розподілу рівнів сірого (MPPC), що описують статистику другого порядку. Матриці MPPC використовуються перш за все в задачах класифікації текстури. Однак обчислювальна складність алгоритмів обмежує область застосування цієї ознаки малими за розміром зображеннями в градаціях сірого.

Для класифікації ГЗ у роботі [15] зображення спочатку розбиваються на епітеліальний шар та просвіт. Використовується метод сегментації на основі ознак просторового розміщення, кольору та текстури. Використано такі статистичні ознаки, як MPPC, матриці довжин повторів графу (GRLM) та число Ейлера. Для наступної класифікації ГЗ молочної залози використовується

лінійний дискримінантний аналіз (LDA). Продуктивність LDA класифікатора порівняно з класифікаторами k-NN та SVM. Показано, що LDA класифікатор при класифікації доброякісних та злоякісних утворень перевершує інші на 100% та 80% відповідно.




Рисунок 1.2 – Система топологічних відношень

Для сегментації у роботі [16] розроблено два нових варіанти відомого оператора локальних бінарних шаблонів (LBP). Автори зосередили увагу на конкретному наборі зображень, де колір відіграє важливу роль у процесі фарбування біологічних зразків. Доведено, що поєднання кольорових та текстурних ознак, обчислених окремо, стало кращим для наборів даних, що мають велику варіабельність розподілу кольорів. Проте одночасне обчислення колірних та текстурних ознак рекомендовано лише для більш стандартизованих по фарбуванню наборів зображень.

Для проведення автоматичної текстурної класифікації зображень гістологічних слайдів в умовах нормального та ракового станів у роботі [17] застосовано статистичне квазі-навчання зі вчителем. Для обчислення векторів текстурних ознак областей, котрі відповідають сегментам тканин, було використано MPPC.

Набори зображень із нерівномірним освітленням та варіацією розподілу кольорів потребують попереднього опрацювання. Для ідентифікації раку автори [18] пропонують поєднати дескриптори текстури на основі області та дескриптори кольорів. Розроблені текстурні характеристики базуються на використанні аналітичних фільтрів Габора (для компенсації варіацій освітлення). Після чого для значень відгуку фільтрів обчислюються статистичні

показники першого та другого порядку. Колірні ознаки отримано за допомогою гомоморфної фільтрації, із наступним застосуванням методу bag-of-words, щоб отримати найбільш типові значення кольорів у зображенні.

1.2 Класифікація зображень на основі текстурних ознак

У даний час існує множина задач, у яких потрібно прийняти деякий рішення залежно від присутності на зображенні об'єкта або класифікувати його. Здатність «розпізнавати» вважається основною властивістю біологічних істот, у той час як комп'ютерні системи цією властивістю повною мірою не мають.

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 визначена довільна кількість класів, більше 1. Кількість класів позначається числом S . Кожний клас має свою ідентифікуючу мітку класу.

Класифікація – процес призначення міток класу об'єктам, згідно з деяким описом властивостей цих об'єктів. Класифікатор – пристрій, який у якості вхідних даних одержує набір ознак об'єкта, а в якості результату, що видає мітку класу.

Верифікація – процес зіставлення екземпляра об'єкта з однією моделлю об'єкта або описом класу.

Під «образом» будемо розуміти найменування області в просторі ознак, у якій відображається множина об'єктів або явищ матеріального світу. Ознака – кількісний опис тієї або іншої властивості досліджуваного предмета або явища.

Простір ознак це N -мірний простір, визначене для даної задачі розпізнавання, де N – фіксоване число вимірюваних ознак для будь-яких об'єктів. Вектор із простору ознак x , що відповідає об'єкту задачі розпізнавання це N -мірний вектор з компонентами (x_1, x_2, \dots, x_n) , які є значеннями ознак для даного об'єкта.

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

Прикладами задач класифікації є:

- встановлення медичного діагнозу;
- розпізнавання символів;
- розпізнавання мови;
- розпізнавання осіб
- класифікація документів і ін.

Найчастіше вихідним матеріалом служить отримане з цифрової камери зображення. Задачу можна сформулювати як одержання векторів ознак для кожного класу на розглянутому зображенні. Процес можна розглядати як процес кодування, що полягає в присвоєнні значення кожній ознаці із простору ознак для кожного класу.

Якщо розглянути 2 класи об'єктів: дорослі й діти. У якості ознак можна вибрати ріст і вага. Як впливає з рисунка ці два класи утворюють дві непересічні множини, що можна пояснити обраними ознаками. Однак не завжди вдається вибрати правильні вимірювані параметри як ознаки класів. Наприклад обрані параметри не підійдуть для створення непересічних класів футболістів і баскетболістів.

Другою задачею розпізнавання є виділення характерних ознак або властивостей з вихідних зображень. Цю задачу можна віднести до попередньої обробки. Якщо розглянути задачу розпізнавання мови, можна виділити такі ознаки як голосні й приголосні звуки. **Ознака повинна представляти із себе характерну властивість конкретного класу, при цьому спільну для цього класу. Ознаки, що характеризують відмінності між класами – міжкласові ознаки. Ознаки спільні для всіх класів не несуть корисної інформації й не розглядаються як ознаки в задачі розпізнавання. Вибір ознак є однією з важливих задач, пов'язаних з побудовою системи розпізнавання.**

Після того, як визначені ознаки необхідно визначити оптимальну вирішуючу процедуру для класифікації. Розглянемо систему розпізнавання образів, призначену для розпізнавання різних M класів, позначених як

m_1, m_2, \dots, m_3 . Тоді можна вважати, що простір образів складається з M областей, кожна містить точки, що відповідають образу з одного класу. Тоді задача розпізнавання може розглядатися як побудова границь, що розділяють M класів, виходячи із прийнятих векторів вимірів.

Розв'язок задачі попередньої обробки зображення, виділення ознак і задачі одержання оптимального розв'язку й класифікації звичайно пов'язаний з необхідністю зробити оцінку ряду параметрів. Це приводить до задачі оцінки параметрів. Крім того виділення ознак може використовувати додаткову інформацію виходячи із природи класів.

Порівняння об'єктів можна робити на основі їх представлення у вигляді векторів вимірів. Дані вимірювань зручно представляти у вигляді дійсних чисел. Тоді подібність векторів ознак двох об'єктів може бути описана за допомогою евклідової відстані.

$$\|x_1 - x_2\| = \sqrt{\sum_{i=1,d} (x_1[i] - x_2[i])^2},$$

де d – розмірність вектора ознаки.

Виділяють 3 групи методів розпізнавання образів:

Порівняння зі зразком. У цю групу входить класифікація по найближчому середньому, класифікація по відстані до найближчого сусіда. Також у групу порівняння зі зразком можна віднести структурні методи розпізнавання.

Статистичні методи. Статистичні методи використовують деяку статистичну інформацію при розв'язку задачі розпізнавання. Метод визначає приналежність об'єкта до конкретного класу на основі ймовірності. В ряді випадків це зводиться до визначення апостеріорної ймовірності приналежності об'єкта до певного класу, за умови, що ознаки цього об'єкта прийняли відповідні значення. Прикладом служить метод на основі байєвського вирішального правила.

Нейронні мережі. Окремий клас методів розпізнавання. Відмінною рисою від інших є здатність навчатися.

Далі розглянемо різні методи стосовні до різних груп.

Класифікація по найближчому середньому значенню.

У класичному підході розпізнавання образів, у якому невідомий об'єкт для класифікації представляється у вигляді вектора елементарних ознак. Система розпізнавання на основі ознак може бути розроблена різними способами. Ці вектори можуть бути відомі системі заздалегідь у результаті навчання або прогнозовані в режимі реального часу на основі яких-небудь моделей.

Простий алгоритм класифікації полягає в групуванні еталонних даних класу з використанням вектора математичного очікування класу (середнього значення).

$$\bar{x}_i = \frac{1}{n_i} \sum_{j=1, n_i} x_{i,j}$$

де $x_{(i,j)}$ – j -а еталонна ознака класу i ,

n_j – кількість еталонних векторів класу i .

Тоді невідомий об'єкт буде відноситься до класу i , якщо він суттєво ближче до вектора математичного очікування класу i , ніж до векторів математичних очікувань інших класів. Цей метод підходить для задач, у яких точки кожного класу розташовуються компактно й далеко від точок інших класів (рисунок 1.3,а).

Труднощі виникнуть, якщо класи будуть мати дещо більш складну структуру, наприклад, як на рисунку. У цьому випадку клас 2 розділений на дві непересічні ділянки, які погано описуються одним середнім значенням. Також клас 3 занадто витягнутий, зразки 3-го класу з більшими значеннями координат x_2 ближче до середнього значення 1-го класу, ніж 3-го. рисунок 1.3,б.

Описана проблема в деяких випадках може бути вирішена зміною обчислення відстані.




Рисунок 1.3 – Простір текстурних ознак

Будемо враховувати характеристику «розкиду» значень класу – σ_i , уздовж кожного координатного напрямку i . Середньоквадратичне відхилення дорівнює квадратному кореню з дисперсії. Шкальована евклідова відстань між вектором x і вектором математичного очікування x_c рівна

$$\|x - x_c\| = \sqrt{\sum_{i=1,d} \left(\frac{x[i] - x_c[i]}{\sigma_i} \right)^2}.$$

Ця формула відстані зменшить кількість помилок класифікації, але на ділі більшість задач не вдається представити таким простим класом.

Класифікація по відстані до найближчого сусіда.

Інший підхід при класифікації полягає у віднесенні невідомого вектора ознак x до того класу, до окремого зразка якого цей вектор найбільш близький. Це правило називається правилом найближчого сусіда. Класифікація по найближчому сусіду може бути більш ефективна, навіть якщо класи мають складну структуру або коли класи перетинаються.

При такому підході не потрібно припущень про моделі розподілу векторів ознак у просторі. Алгоритм використовує тільки інформацію про відомі еталонні зразки. Метод розв'язку заснований на обчисленні відстані x до

кожного зразка в базі даних і знаходження мінімальної відстані. Переваги такого підходу очевидні:

- у будь-який момент можна додати нові зразки в базу даних;
- деревоподібні й сіткові структури даних дозволяють скоротити кількість відстаней, що обчислюються.

Крім того, рішення буде кращим, якщо шукати в базі не одного найближчого сусіда, а k . Тоді при $k > 1$ забезпечує найкращу вибірку розподілу векторів в d -мірному просторі. Однак ефективне використання значень k залежить від того, чи є достатня кількість у кожній області простору. Якщо є більше двох класів то прийняти вірне рішення виявляється складніше.

Методи, що застосовуються для аналізу текстур можна розділити наступним чином [6]: статистичні методи, геометричні методи, методи засновані на моделях, методи обробки сигналів. Статистичні методи включають метод обчислення матриці розподілу рівнів сірого (MPPC) [4], аналіз автокореляційної функції [5], обчислення просторових моментів [7]. Методи обробки сигналів включають двовимірну фільтрацію в просторовій і частотній області [8]. Методи засновані на моделях використовують модель Марківського випадкового поля (MRF) [4], моделі фракталів [3].

Сегментація зображення взагалі є розділенням або розбиттям зображення на області по схожості властивостей їх точок [2]. Сегментація текстури - це задача яка полягає в розбитті зображення на ділянки з постійною текстурою [4, 5]. Сегментація текстури включає як представлення текстури, так і обчислення базису, в якому визначатимуться границі сегментів. Об'єднання пікселів вихідного зображення в окремих однорідні регіони здійснюється на основі деяких специфічних властивостей пікселів, що належать одній і тій же текстурі.

Процес текстурної сегментації [8,4] можна розділити на 3 етапи:

- формування з вихідного зображення набору особливостей (характерних ознак), що утворюють багатовимірний простір ознак зображення, кожен вектор якого характеризує особливості певної текстури;

- етап класифікації, на якому кожна точка зображення співвідноситься з певним класом на основі оцінки вектора ознак відповідного цієї точці в просторі ознак;

– етап сегментації вихідного зображення заснований на інформації отриманою після класифікації.

Ознака визначається як функція від значень, що містяться в одному або більше пікселях, і обчислюється так, що чисельно виражає деяку значиму характеристику об'єкту. Загальні ознаки (колір, текстура, форма) поділяють на ознаки піксельного рівня (колір, координата), локальні ознаки (обчислюються у певні області або вікні), глобальні ознаки (обчислюються для всього зображення, наприклад, гістограма, дисперсія).

Простір текстурних ознак, кожна точка якого є значенням ознаки для відповідної точки вихідного зображення назвемо текстурним полем.

Алгоритм текстурної сегментації складається з наступних кроків: (а) обчислити статистичні текстурні ознаки для кожної точки зображення в межах ковзаючого вікна розміром $W \times W$, (б) провести сегментацію створеного текстурного поля.

Одна з найбільш широко вживаних ознак текстури це матриці розподілу рівнів сірого (MRPC) [15]. Матриця P_d для вектора зміщення $d = (dx, dy)$ значення елемента $p_{i,j}$ є кількістю входжень пари значень рівнів сірого i та j , які розміщені на відстані d . Кожній точці зображення $f(x, y)$ відповідає матриця суміжності P_d , яка характеризує розподіл яскравості у вікні розміром $W \times W$ з центром в точці з координатами (x, y) . Елементи матриці P_d визначаються таким чином:

$$P_d(i, j) = \sum_{(m,n) \in D} f_{i,j}(x_{m,n}; x_{m+d,n+d}),$$

де

$$f_{i,j}(x_{m,n}; x_{m+d,n+d}) = \begin{cases} 1, & (x_{m,n} = i \text{ та } x_{m+d,n+d} = j) \\ & \text{або } (x_{m,n} = j \text{ та } x_{m+d,n+d} = i) \\ 0, & \text{інакше} \end{cases}$$

де D – квадрат розміром $W \times W$ (W - непарне число),

$i, j = 0..255$ – значення яскравості точок,

$x_{m,n}$ – яскравість точки з координатами (m,n) .

Функція $f_{i,j}(x_{m,n}; x_{m+d,n+d})$ є індикатором того, що точки, які знаходяться на заданій відстані, мають певні рівні яскравості. Параметр d визначає відстань, на якій проводиться аналіз сусідніх точок. На основі матриць суміжності визначаються такі текстурні ознаки як енергія, ентропія, контраст, однорідність, кореляція та ін.

По матриці розподілу $P(i, j)$, що описує розподіл яскравості всередині області з центром в точці (x, y) , обчислюються ознаки текстур ($F1...$, $F6$). Після оброблення всього зображення для кожної ознаки формується матриця, що зберігає значення ознаки у всіх оброблюваних точках – поле текстурних ознак. Допоміжні величини: $m_j = \sum_j jP(i, j)$; $p_j = \sum_j P(i, j)$; математичне сподівання

$Mx = \sum_i ip_i$; Нижче наведені формули для обчислення ознак.

1. Сумарне середнє значення:

$$F_1 = \sum_i m_i p_i$$

2. Інерція:

$$F_2 = \sum_i \sum_j (i - j)^2 P(i, j)$$

3. Другий кутовий момент:

$$F_3 = \sum_i \sum_j P^2(i, j)$$

4. Сумарна кореляція:

$$F_4 = \sum_i \sum_j m_i m_j$$

5. Ентропія:

$$F_5 = - \sum_i \sum_j \ln(P(i, j)) P(i, j)$$

6. Кореляція:

$$F_6 = \sum_i \sum_j (i - Mx)(j - Mx)P(i, j)$$

Haralick визначив матрицю суміжності, як матрицю частот пар пікселів певної яскравості, розташованих відносно один одного на зображенні певним чином. Формально матриця суміжності Z по зображенню I розміром $N \times M$ визначається в такий спосіб:

$$C(i, j) = \sum_{p=1}^N \sum_{q=1}^M \begin{cases} 1, & \text{якщо } I(p, q) = i, \quad I(p + \Delta x, q + \Delta y) = j \\ 0, & \text{інакше} \end{cases}$$

де $(\Delta x, \Delta y)$ - параметр зсуву, що задає взаємне розташування пікселів;

$I(p, q)$ - рівень яскравості пікселя зображення, розташованого в точці (p, q) .

Приклад обчислення матриці суміжності для області зображення при $(\Delta x, \Delta y) = (1, 0)$ показаний на рисунку 1.4.

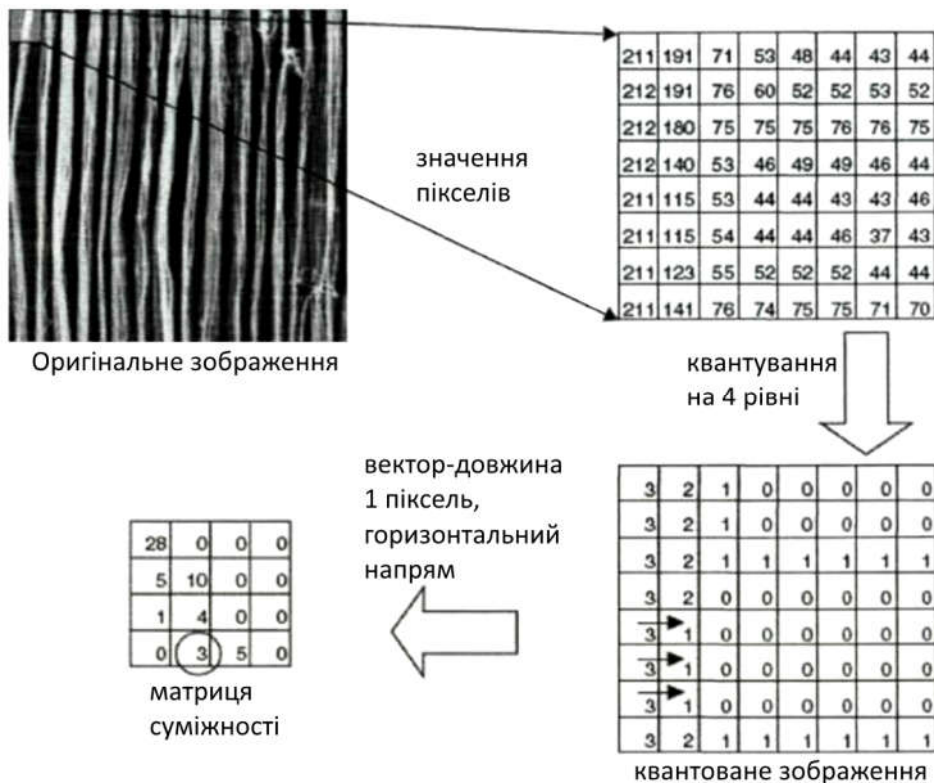


Рисунок 1.3 - Приклад обчислення МРРС для області зображення при $(\Delta x, \Delta y) = (1, 0)$

Нескладно помітити, що параметр зсуву (Δx , Δy) робить таке представлення текстурної характеристики чутливим до повороту зображення, що звичайно небажано. Тому для опису зображення потрібно будувати кілька матриць із різними параметрами зсуву, відповідними до повороту зображення на 0° , 45° , 90° , 135° [11].

Далі по матрицях суміжності можна обчислити різні статистичні показники, за значеннями яких згодом порівнюються два зображення між собою. Nagalick і співавтори запропонували 14 показників [50], серед яких були другий кутовий момент (*angular second moment*), контрастність (*contrast = variance = difference moment*), кореляція й інші. Кожний з них описує яку-небудь властивість текстури. Наприклад, другий кутовий момент показує близькість розподілу матриці суміжності до розподілу діагональної матриці, що відповідає ступеню однорідності текстури. Кореляція вимірює кількість локальних змін рівня яскравості, тобто "строкатість" зображення. Але використання всіх чотирнадцяти показників, поряд з необхідністю побудови декількох матриць суміжності для того самого зображення (для різних параметрів зсуву), зробило б будь-яку систему пошуку (або класифікації) зображень дуже повільною через велику кількість обчислень, які доводилося б проробляти для кожного зображення. Тому велика кількість робіт [20-30] було присвячено виділенню серед різних статистичних показників, які можуть бути отримані по МРРС, тих, що щонайкраще здатні описати особливості текстури.

Процесу сегментації передуює процес формування простору ознак, заснований на дослідженні текстур. Виходячи із цього, актуальною задачею є вибір ознак для сегментації текстурних областей, візуально близьких за значеннями кольору й структури.

Основне питання при виборі ознак полягає в тому, щоб визначити які й скільки ознак необхідно виділити для надійної класифікації текстурних областей із близькими значеннями кольору й текстури на зображенні. Відомо, що надмірне збільшення вихідної системи ознак не приносить позитивного ефекту через те, що ступінь репрезентативності вибірки того самого обсягу обернено пропорційна розмірності простору ознак.

Найбільш важливі вимоги до ознак, використовуваних для розв'язку задачі сегментації областей зображень, можуть бути сформульовані в такий спосіб .

1. Ознака повинна бути інформативною, тобто містити інформацію, істотну для даного зображення в контексті розв'язуваної задачі, і сприяти точній сегментації об'єктів.

2. Ознака повинна допускати обробку алгоритмом сегментації зображень, тобто мати формат, прийнятний для обраного алгоритму сегментації.

3. Ознака повинна дозволяти будувати модель зображення.

4. Ознака повинна входити в мінімальний набір ознак (або модель зображення), що відбиває специфіку сегментованого об'єкта в контексті задачі.

5. Часова складність обчислення ознаки не повинна перевищувати вигоди від його використання для розв'язку даної проблеми.

Таким чином, розв'язок задачі побудови мінімальної множини найбільш інформативних ознак є одним з головних факторів при розробці алгоритмів класифікації текстурних областей зображень.

Формування набору ознак для сегментації текстурних областей зображень може здійснюватися в три етапи. На першому етапі проводився попередній вибір ознак методом експертного аналізу. За результатами експертного аналізу як ознак були обрані статистичні й спектральні ознаки об'єктів. На другому й третьому етапах формування набору ознак проводилася статистична й експериментальна оцінка, а також перевірка відповідності ознак наведеним вище вимогам. Далі у роботі в якості ознак для класифікації будуть використані МРРС та локальні бінарні шаблони.

1.3 Програмне забезпечення аналізу біомедичних зображень

На даний час аналіз медико-біологічних препаратів (цитологічних і гістологічних мазків) в діагностичних лабораторіях проводиться візуально. Цей процес є рутинним і трудомістким. Тому з'явилися системи автоматизованої

мікроскопії (САМ) – програмно-апаратні комплекси для цифрової обробки мікроскопічних зображень. САМ є апаратно-програмними системами, до складу яких входять моторизований керований мікроскоп, відеокамера, комп'ютер, функціональні програми-методики.

САМ в цілому поділяють на дослідницькі та спеціалізовані [8, 27]. Дослідницькі САМ використовуються для розроблення нових методів діагностування. Спеціалізовані САМ забезпечують виконання певного одного стандартизованого клінічного дослідження. Особливістю дослідницьких САМ є використання багатофункціональних мікроскопів і камер із збільшеною чутливістю і роздільною здатністю. Методика дослідження не задана наперед, а формується користувачем.

Для задач мікробіології на світовому ринку пропонують САМ або окремі їх компоненти такі фірми як Carl Zeiss (Німеччина), Leica, Olympus, Nikon, Микромед (Росія), Motic (Китай), Konus (Італія).

Наведемо узагальнено процес дослідження з допомогою САМ. Спочатку препарат встановлюється на предметний стіл мікроскопа. Зображення поля зору виводиться на екран монітора. У реальному часі проводяться всі необхідні налаштування і захоплення зображення. Зображення може бути оброблене за допомогою фільтрів, на нього можна нанести текстові коментарі і калібрувальний маркер. САМ дозволяє виділяти мікрооб'єкти на зображенні в автоматичному, напівавтоматичному або ручному режимах. Виділені мікрооб'єкти вимірюються автоматично і результати вимірів відображаються в табличній формі. По будь-якому із виміряних параметрів мікрооб'єкти можуть класифікуватися. Результати аналізу виводяться на друк і зберігаються в базі даних.

Для побудови узагальненої структури САМ було досліджено склад і функції існуючих програмних засобів (таблиця 1.1).

Зокрема порівняння проводилось за наступними параметрами:

- спосіб вводу інформації: зображення приймається із давача в реальному часі (підтримка технології MCI/TWAIN) чи завантаження з диску;
- режими роботи алгоритмів сегментації: ручний (оператор в ручному режимі виділяє мікрооб'єкти), автоматизований (оператор попередньо

проводить навчання алгоритму) чи автоматичний (параметри алгоритму вибираються автоматично);

Таблиця 1.1 – Порівняння програмного забезпечення САМ

№	Назва програми	Підтримка додаткових форматів файлів	Конвертування файлу в інший формат	Редагування зображення	Конвертація в інші кольорові бази	Виділення мікрооб'єктів в ручному / автоматизованому / автоматичному режимах	Визначення координат обмежуючого прямокутника	Використання сценаріїв	Формування звітів	Передача даних в програмне забезпечення 3-х сторін	Друк	Налаштування параметрів роботи програми	Калібрування камери	Наявність системи допомоги
1	ImageTool v.2.00	+	+	+	+	+/-/-	-	+	+	-	+	+	-	+
2	ImageWarp	-	+	+	-	+/-/-	-	+	+	-	+	+	-	+
3	„ИМАДЖЕР-ЦГ”	-	+	+	-	+/-/-	-	-	+	-	+	+	-	+
4	ВидеоТест-Морфо 3.2	+	+	+	+	+/+/-	-	+	+	-	+	+	-	+
5	ВидеоТест-Морфология 5.0	+	+	+	+	+/+/+	-	+	+	+	+	+	+	+
6	Micromed Images	+	+	+	-	+/-/-	-	+	+	-	+	+	-	+
7	ScreenMeter	-	-	-	-	+/-/-	-	-	+	-	-	+	-	+
8	ImageExpert Pro 3	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
9	ImageExpert™ Gauge	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
10	AnalySIS Five	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
11	BioVision	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
12	QCapture PRO 6.0	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
13	Motic Images Advanced 3.2	+	+	+	+	+/+/+	+	+	+	+	+	+	-	+
14	MCID™ Core	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
15	Image-Pro Plus 6.2	+	+	+	+	+/+/-	-	+	+	-	+	+	-	+
16	MetaMorph 7.5	-	+	+	+	+/+/-	-	+	+	-	+	+	-	+
17	ImageJ (NIH, USA)	-	+	+	+	+/-/-	-	+	+	-	+	+	-	+
18	PIXELs	-	-	+	-	+/-/-	-	-	+	-	+	+	-	+
19	NIH Image	-	+	+	+	+/+/+	+	+	+	+	+	+	-	+
20	Xite v3.45	-	-	+	-	+/-/-	-	-	+	-	+	+	-	+
21	ДиаМорф	-	+	+	+	+/+/+	+	+	+	+	+	+	-	+

– попереднє оброблення зображення: зменшення шумів, корекція яскравості, контрасту, фільтрація, виділення області інтересу, тощо;

- обчислення числових ознак мікрооб'єктів: периметр, площа, ядерно-цитоплазматичне відношення, діаметр, кут між двома відрізками, тощо;
- обчислення статистичних ознак: математичне сподівання, середньоквадратичне відхилення, максимальне (мінімальне) значення, тощо;
- представлення результатів у вигляді діаграм, гістограм, графіків, тощо;
- взаємодія з іншим програмним забезпеченням: MS Word, MS Excel, MS Access, FoxPro, тощо;
- використання скриптів – присутність вбудованої мови для пакетного оброблення даних;
- наявність детальної технічної документації.

Типова структура апаратної частини САМ складається з мікроскопа, відеокамери або фотокамери, комп'ютера, принтера і монітора. Підсистема вводу зображення складається з світлового мікроскопа, камери, фотоадаптера, пристрою зміни поточного об'єктива, пристрою фокусування, пристрою переміщення предметного стола, пристрою подачі зразків та пристрою освітлення. Світловий мікроскоп прохідного світла складається із штатива, до якого кріпляться всі основні вузли: система освітлення, предметний стіл, системи відтворення та візуалізації зображення. Основними характеристиками мікроскопа є його клас, кратність збільшення, оптична роздільна здатність, розмір лінійного поля на предметі і ступінь виправлення аберацій. У САМ для цитології і гістології застосовують біологічні прямі мікроскопи робочого, лабораторного та дослідницького класів. **В даному розділі визначено основні поняття текстурного аналізу. Проведено огляд існуючих методів та алгоритмів вирішення задач текстурного аналізу. Розглянуто задачу Класифікація зображень на основі текстурних ознак. Визначено проблеми побудови простору текстурних ознак та визначено вимоги до ознак. Розглянуто структуру та функції програмного забезпечення аналізу біомедичних зображень. Підсумовано переваги і недоліки систем автоматизованої мікроскопії.**

1.4 Постановка завдань дипломної роботи

Для досягнення поставленої в роботі мети необхідно розв'язати наступні задачі:

- проаналізувати особливості гістологічних зображень та їх ознаки;
- здійснити огляд алгоритмів класифікації зображень;
- здійснити огляд алгоритмів зменшення простору ознак;
- запропонувати числові ознаки для класифікації текстури гістологічного зображення;
- розробити алгоритм зменшення простору ознак на основі методу головних компонент;
- здійснити програмну реалізацію розроблених алгоритмів;
- провести опрацювання тестової вибірки біомедичних зображень.

2 АЛГОРИТМИ ЗМЕНШЕННЯ ПРОСТОРУ ОЗНАК

2.1 Текстульні ознаки на основі локальних бінарних шаблонів

Для порівняння аналізованої текстури із відомими (еталонними) потрібно створити бібліотеку текстур. Від вибору бази текстур залежить точність роботи алгоритмів класифікації. При недостатньому обсязі бібліотеки висока ймовірність виявлення області, для яких не виконується необхідна умова класифікації. Під недостатнім обсягом бібліотеки в цьому випадку розуміють як обсяг всіх зразків, так і число класів.

Необхідною умовою приналежності текстури даному класу є вимога, щоб значення функції схожості текстури з цим класом було вище деякого порога впевненості.

$$f(S, T) > \eta$$

де $f(S, T)$ - міра приналежності текстури S класу T ,

η - поріг впевненості.

Необхідною умовою класифікації текстури являється виконання необхідної умови приналежності текстури хоча б для одного класу.

$$\max \{f(S, T_i) > \eta\} \quad i=1, N$$

де $f(S, T_i)$ - міра приналежності текстури S класу T_i ,

N - число можливих класів, η - поріг впевненості.

Поріг впевненості η задається користувачем і дозволяє регулювати точність класифікації. За замовчуванням $\eta = 0$, тобто необхідні класифікації виконується завжди. У цьому випадку кожна текстура належить класу, міра приналежності до якого більша за міру приналежності до інших класів.

Прагнення до відсутності некласифікованих текстур може привести до зайвого збільшення числа класів бібліотеки. Неможливо створити універсальну базу текстур без шкоди точності і трудомісткості класифікації. В першу чергу шкідливі текстури, ймовірність появи яких на уже згадуваному зображенні

вкрай мала або взагалі дорівнює нулю. Важливою умовою ефективною класифікації є правильний вибір бібліотеки.

Перед безпосереднім збором зразків текстур для вирішення конкретної задачі слід визначити наступні моменти:

1. Визначити природу предметної області. Це можуть бути рентгенівські знімки, мікроскопічні, фото різних матеріалів, фото місцевості.

2. На основі предметної області можна визначити передбачувані класи текстур. По можливості виділення класів проводити від спільних, дроблячи їх на більш чатскові в процесі аналізу предметної області. Це дозволить уникнути перетинання класів і при необхідності дасть можливість забезпечити рівень деталізації без зайвих зусиль.

3. Визначити приблизний діапазон зміни масштабу текстур. Наприклад, на якому збільшенні робляться знімки мікроскопом. На основі цього проводити відбір текстур для кожного класу.

Розглянемо текстурні ознаки і оператори.

Локальний бінарний шаблон (Local Binary Pattern - LBP) оператор, що описує точку зображення за допомогою сусідніх пікселів.

Нехай $T = t(p_c, p_0, \dots, p_{n-1})$ - фрагмент текстури, p_i - точки, що його утворюють. Тоді локальний бінарний шаблон визначається наступним чином

$$LBP_{r,n} = \sum_{i=0}^{n-1} f(p_i - p_c) 2^i$$

де r - радіус кола, на якій беруться точки для опису центральної,
 n - кількість точок для опису центральної.

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$$

Класичний LBP-оператор не має інваріантності відносно повороту, що призводить до необхідності додавання в банк текстур однакових зразків, повернутих на різні кути. З метою скорочення розміру текстур і підвищення

точності опису вводиться модифікований, інваріантний щодо повороту, оператор LBP^i .

$$LBP_{r,n}^i \min \{ROR(LBP_{r,n}, i)\} \quad i = 0, n-1$$

де $ROR(X, i)$ - функція повороту блоку X на i пікселів за годинниковою стрілкою.

LBP-оператор в класичному уявленні вкрай чутливий до шуму, який неминучий на біомедичних зображеннях. Отже невеликий шум при використанні LBP, особливо на коротких відстанях, може привести до великої частки помилкових класифікацій.

Для забезпечення стійкості до шуму використовується усереднення. Якщо піксель описується за допомогою сусідніх точок, а усереднення проводиться по точках, то для опису кожного пікселя необхідно брати qn точок.

$$\bar{P}_{r,q} = \frac{1}{q} \sum_{i=0}^{q-1} \bar{P}_{r,kq+i}, \quad k = 0, n-1$$

Так як не завжди існує можливість підбору банку текстур таким чином, щоб масштаб текстур на зразках збігався з масштабом будь яких аналізованих текстур, постає необхідність забезпечити певний діапазон допустимої відмінності масштабів зображення і зразків з банку даних. Для LBP-операторів це можливо здійснити шляхом зміни їх радіусу. При цьому обчислюються відразу кілька дескрипторів з різними радіусами. Число різних радіусів можна міняти, тим самим контролювати складність і ефективність класифікації.

Для опису текстурних ознак областей і блоків використовуються функції-дескриптори, які отримують на вхід набір пікселів кожного блоку, а на виході визначають вектор ознак кожного блоку.

Визначимо дескриптор $LBP^i_{r,n}$, описує центральний піксель через сусідні. Нехай r - радіус LBP-оператора, q - число пікселів для опису однієї сусідньої точки, n - число сусідніх пікселів для опису центрального. Будемо

вважати, що $n = 8_r$, так як такий вибір сусідніх пікселів найбільш природний для растрових зображень. p_c - центральний піксель LBP-оператора, $\bar{p}_{r,n}$ визначений вище. Дескриптор $LBP^{ri}_{S_{r,n}}$ матиме вигляд

$$LBP_{S_{r,n}} = \sum_n^{i=0} f(\bar{p}_{r,i} - p_c) 2^i,$$

$$LBP_{S_{r,n}}^{ri} = \min\{\text{ROR}(LBP_{S_{r,n}}, i)\}, \quad i = 0, n-1.$$

Визначимо дескриптор $LBP^{ri}_{D_{r,n}}$ що описує ступінь відмінності між центральним пікселем і сусідніми.

$$z_{r,k} = \frac{1}{n} \sum_{i=0}^{n-1} |\bar{p}_{r,k+1} - p_c|, \quad i = \overline{0, n-1}$$

$$LBP_{D_{r,n}} = \sum_n^{i=0} f(z_{r,i} - \frac{1}{n} \sum_{j=0}^{n-1} z_{r,j}) 2^i$$

$$LBP_{D_{r,n}}^{ri} = \min\{\text{ROR}(LBP_{D_{r,n}}, i)\}, \quad i = 0, n-1$$

$$LBP_{r,n} = LBP_{S_{r,n}}^{ri} \cup LBP_{D_{r,n}}^{ri}$$

де під операцією об'єднання мається на увазі об'єднання гістограм $LBP_{S_{r,n}}^{ri}$ та $LBP_{D_{r,n}}^{ri}$

Підсумковим дескриптором, стійким до зміни масштабу, є дескриптор LBP:

$$LBP = \bigcup_{k=1}^m LBP_{k,8k}$$

де m - максимальний розглянутий радіус LBP-оператора.

Для кольорових зображень обчислюються LBP_R, LBP_G, і LBP_B, за значеннями насиченості відповідних каналів. Після чого одержані гістограми частот об'єднуються в загальний дескриптор LBP_RGB.

За замовчуванням вхідне зображення представлено в кольоровому просторі RGB. Перехід від інших колірних моделей, наприклад, YCbCr, HSV, CMYK, до RGB і назад здійснюється за виведеним для кожної моделі стандартними формулами.

2.2 Двокроковий алгоритм класифікації

При перетвоєнні кольорового зображення в градації сірого неминуча втрата інформації. Це призводить до того, що різним кольорам можуть відповідати однакові значення рівня сірого. Так як в природі колір відіграє основну роль, і забарвлення рослин, піску, ґрунту і т.д. ніколи не буває випадкове, а визначається групою екологічних і кліматичних чинників, то при класифікації в градаціях сірого результати можуть бути недостатньо точними. Однак часто дослідники стикаються з неможливістю збору бібліотеки текстур повністю з кольорових зразків. У цьому випадку доводиться працювати з усією бібліотекою в градаціях сірого, так як перехід до колірному простору для сірого зображення неоднозначний.

Двокроковий підхід до класифікації текстур полягає в роботі на різних етапах з різними представленнями зображень і банку текстур.

Етап 0. Для роботи з різними представленнями зображень необхідно провести перетворення бібліотеки текстур. Для цього вона ділиться на дві частини: кольорові зразки і зразки в градаціях сірого. Після чого формується дві нових бази текстур (рисунок 2.1) в градаціях сірого, яка формується шляхом об'єднання частини початкової бібліотеки в рівнях сірого і кольорових частин, перекладеної в рівні сірого, і повністю заповнені якимось кольором, що представляє собою кольорову частину початкової бібліотеки.

Етап 1. На даному етапі аналізуються структурні особливості текстури. Здійснюється перетворення копії аналізованої текстури представленої в градаціях сірого і наступна класифікація з використанням відповідної бібліотеки текстур. В результаті для кожного класу отримуємо ступінь

приналежності текстури до нього. На наступний етап передаються тільки ті класи, ступінь належності до яких вище порогового значення. Якщо такий клас один, то другий етап ігнорується. Якщо таких класів немає зовсім, то вибирається найбільш ймовірний клас і другий етап так само ігнорується. Можливий альтернативний підхід до відбору класів, згідно з яким вони сортуються за ступенем ймовірності і на другий етап передаються n найвірогідніших.

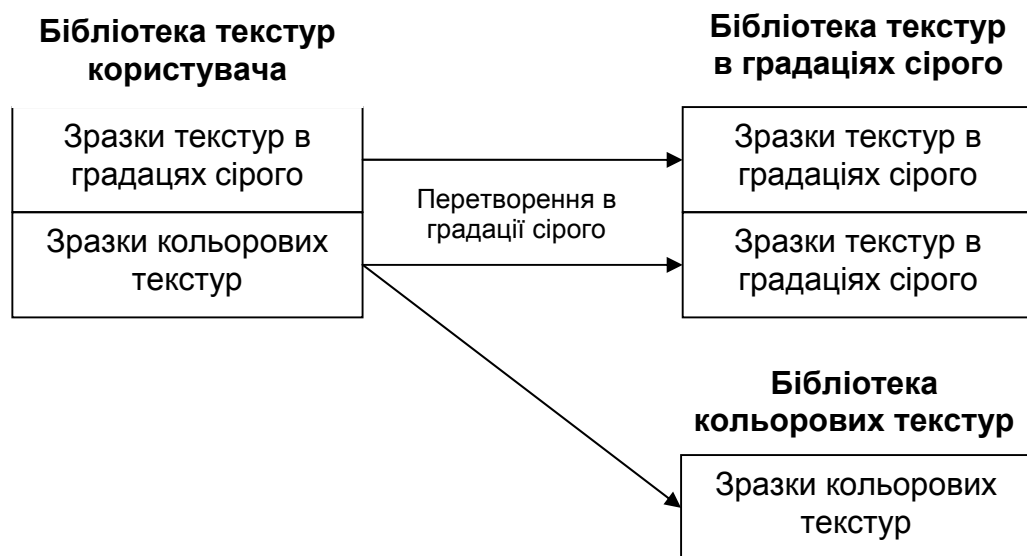


Рисунок 2.1 - Схема формування бібліотек текстур для кожного етапу класифікації

Етап 2. На даному етапі для найбільш схожих за фактурою з вихідним зображенням класів текстур проводиться колірний аналіз, що дозволяє уточнити результати. Обчислюються ймовірності приналежності текстур класам, представленим кольоровими зразками. Після чого обчислюється підсумкова ймовірність приналежності шляхом множення ймовірностей отриманих на першому і на другому етапах. У підсумку отримуємо клас текстури який являється клас з найбільшою ймовірністю приналежності.

Порівняння точності результатів роботи методів класифікації з різними бібліотеками текстур показано в таблиці 2.1.

Таблиця 2.1 - Точності результатів роботи методів класифікації

	Color Texture Base	Greyscale Texture Base	Two-step Texture Base
Точність	86%	95%	92%

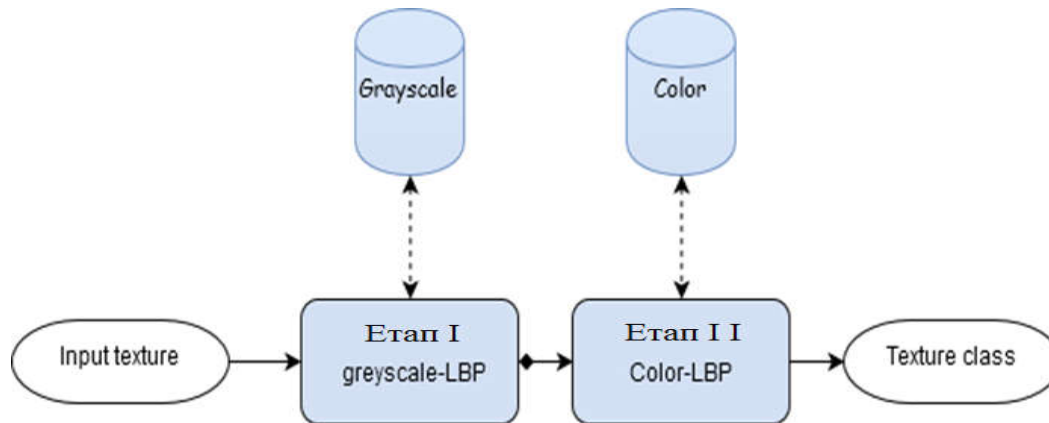


Рисунок 2.2 – Два етапи класифікації текстур

2.3 Зменшення простору ознак на основі методу головних компонент

При вирішенні різних завдань розпізнавання передбачається, що в наявності є деяка вибірка об'єктів, і для кожного об'єкта обчислений один і той же набір ознак. На практиці об'єкти можуть бути представлені складними багатовимірними даними, наприклад, зображеннями, набором кривих, текстом і т.д. Тому виникає задача витягнення з вхідних багатовимірних даних набору ознак, інформативних з точки зору подальшого вирішення задачі розпізнавання.

Будь-які багатовимірні дані завжди можна представити у вигляді вектора чисел. У разі зображень досить розгорнути матрицю пікселів в вектор. Подібні вектори чисел мають, як правило, більшу довжину, а ознаки що містяться в них, як правило, малоінформативні. Тому розглядається задача скорочення розмірності опису даних з метою отримання відносно компактної множини інформативних ознак.

Розглянемо задачу класифікації зображень рукописних цифр MNIST. тут є деяка кількість чорно-білих зображень, на кожному з яких представлена одна цифра (див. рис. 2). Завдання полягає в автоматичному визначенні цифри для вхідного зображення (задача класифікації на 10 класів).

Для того, щоб застосувати методи розпізнавання в цьому завданні, необхідно попередньо вибрати простір ознак, що характеризує зображення цифр. У простому випадку в якості ознак можна взяти вихідні інтенсивності пікселів зображення. Тоді для зображення розміру 28×28 отримуємо 784 ознаки. Такий спосіб формування простору ознак має ряд істотних недоліків. По-перше, виходить велика кількість ознак. Наприклад, для відносно невеликих зображень розміром 300×200 виходить 60 000 ознак. Велика кількість ознак призводить до високих часових витрат на обробку даних, великих обсягів пам'яті, необхідних для зберігання інформації, а також до необхідності збирання великої кількості прецедентів для впевненого відновлення прихованих залежностей в істотно багатомірному просторі. Іншим серйозним недоліком отриманого простору ознак є той факт, що близькі в просторі ознаки об'єктів не відповідають одним і тим же класам (див. Рис. 3а). Виконання гіпотез компактності є одним з основних вимог для більшості методів розпізнавання. Методи зменшення розміру в даних дозволяють отримувати представлення вибірок у маломірних просторах, які володіють рядом хороших властивостей. Зокрема, для зображень рукописних цифр метод головних компонент дозволяє отримати істотно більш якісний простір ознак.

Нехай є деяка вибірка об'єктів $X = \{X_n\}_{n=1}^N, X_n \in R^D$ завдання зменшення розмірності полягає в отриманні уявлення цієї вибірки в просторі меншою 2 розмірності $T = \{t_n\}_{n=1}^N, t_n \in R^d$ Тут $d \ll D$, але в окремих випадках d може і збігатися з D . Зменшення розмірності в описі даних може переслідувати безліч цілей:




Рисунок 2.3 – Проекція вибірки зображень об'єктів на дві ознаки, відповідних інтенсивностям пікселів (а) і на дві ознаки, отриманих за допомогою методу

$$\text{головних компонент (б)} \quad X = \left\{ x_n \right\}_{n=1}^N, x_n \in R$$

Скорочення обчислювальних витрат при обробці даних;

– Боротьба з перенавчанням. Чим менше кількість ознак, тим менше потрібно об'єктів для впевненого відновлення прихованих залежностей в даних і тим вище якість відновлення подібних залежностей;

– Стиснення даних для більш ефективного зберігання інформації. У цьому випадку крім перетворення $X \rightarrow T$ потрібно мати можливість здійснювати також зворотне перетворення $T \rightarrow X$;

– Візуалізація даних. Проектування вибірки на двохтрьохвимірному просторі дозволяє графічно представити вибірку;

– Витягнення нових ознак. Нові ознаки, отримані в результаті перетворення $X \rightarrow T$, можуть надавати значний внесок при подальшому вирішенні задач розпізнавання (наприклад, як метод головних компонент в разі рисунок 2.3, б).

Зауважимо, що описані далі методи зменшення розмірності відносяться до класу методів навчання без учителя, тобто в якості вихідної інформації виступає тільки ознакова опис об'єктів X . Зокрема, в завданні класифікації рукописних цифр результат, показаний на рисунку 2.3,б, був отриманий без використання інформації про цифри (мітках класу).

Метод головних компонент (розкладання Карунена-Лоева, principal

component analysis, PCA) є найпростішим методом зменшення розмірності в даних. Ідея методу полягає в пошуку в вихідному просторі гіперплощини заданої розмірності з подальшим проектуванням вибірки на дану гіперплощину. При цьому вибирається та гіперплощина, помилка проектування даних на яку є мінімальною в сенсі суми квадратів відхилень.

Нехай $D = 2$, $d = 1$, тобто завдання полягає в проектуванні двовірних даних на пряму. Припустимо далі, що пряма проходить через початок координат, а її напрямок задається одиничним вектором u , $\|u\| = 1$ (див. Рис. 4а). Тоді величина проекції вектора x на цю пряму становить $\|x_{pr}\| = u^T x$, а сам вектор проекції визначається як $x_{pr} = \|x_{pr}\| u$. По теоремі Піфагора квадрат помилки проектування обчислюється як

$$\|x_{err}\|^2 = \|x\|^2 - \|x_{pr}\|^2 = x^T x - u^T x x^T u$$

Таким чином, критерій середньої помилки проектування вибірки X на пряму, що задається одиничним вектором u , може бути записаний як:

$$J = \frac{1}{N} \sum_{n=1}^N (x_n^T x_n - u^T x_n x_n^T u) = \frac{1}{N} \sum_{n=1}^N x_n^T x_n - u^T \left[\frac{1}{N} \sum_{n=1}^N x_n x_n^T \right] u.$$

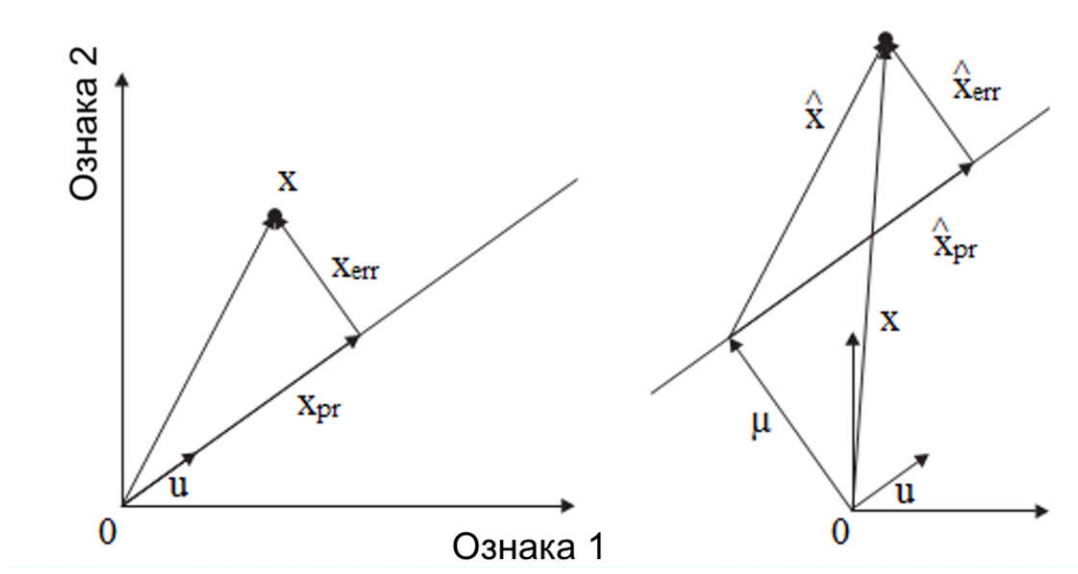


Рисунок 2.4 – Проекція об'єкта x на пряму, що задається направляючим вектором u і вектором зсуву μ .

Позначимо через S матрицю $(1/N) E_T x_n x_n^T$. Мінімізація критерії J по u еквівалентна наступній задачі умовної максимізації:

$$\begin{aligned} u^T S u &\rightarrow \max \\ u^T u &= 1. \end{aligned} \quad (2.1)$$

Записуючи функцію Лагранжа $L(u, \lambda)$ і прирівнюючи до нуля всі її похідні, одержимо необхідну умову екстремума:

$$\begin{aligned} \nabla u L(u, \lambda) &= 2Su - 2\lambda u = 0, \\ L(u, \lambda) &= u^T S u + \lambda(1 - u^T u), \Rightarrow Su = \lambda u, \end{aligned} \quad (2.2)$$

$$\frac{\partial}{\partial \lambda} L(u, \lambda) = 1 - u^T u = 0 \Rightarrow u^T u = 1 \quad (2.3)$$

Умова (2.2) означає, що оптимальний вектор u є власним вектором матриці S , що відповідає деякому власному значенню λ . Зауважимо, що власний вектор завжди визначений з точністю до норми, тому умові (3) завжди можна задовольнити. Умови (2.2), (2.3) є необхідними умовами екстремуму. Для того, щоб знайти точку глобального умовного максимуму критерію (2.1), підставимо умова (2.2) в критерій (2.1):

$$J = u^T S u = \lambda u^T u = \lambda.$$

Таким чином, оптимальний вектор u є власним вектором матриці S , відповідає її максимальному власному значенню λ_{\max} . Тепер розглянемо випадок, коли пряма не проходить через початок координат (рисунок 4b). Вектор зсуву прямої μ щодо початку координат завжди можна вибрати перпендикулярно прямий, тобто $\mu^T u = 0$. Завдання пошуку прямої з мінімальною помилкою проектування може бути зведена до розглянутої вище задачі шляхом переходу від об'єктів

x_n до об'єктів $x^n = x_n - \mu$:

$$\begin{aligned}
J &= \frac{1}{n} \sum ((x_n - \mu)^2 (x_n - \mu) u^T (x_n - \mu)^T u) = \\
&= \frac{1}{N} \sum ((x_n^T x_n - 2\mu^T x_n + \mu^T \mu - \mu^T x_n x_n^T u)) = \\
&= \frac{1}{N} \sum_{n=1}^N x_n^T x_n - 2\mu^T \left[\frac{1}{N} \sum_{n=1}^N x_n \right] + \mu^T \mu - u^T S u.
\end{aligned}$$

Прирівнюючи до нуля градієнт J по μ , отримуємо:

$$\nabla_{\mu} J = -2 \left[\frac{1}{N} \sum_{n=1}^N x_n \right] + 2\mu = 0 \Rightarrow \mu_{opt} = \frac{1}{N} \sum_{n=1}^N x_n.$$

Після того, як μ і u знайдені, залишилося спроектувати вибірку X на знайдену пряму:

$$t_n = u^T (x_n - \mu) \quad (2.4)$$

Самі об'єкти вибірки в вихідному просторі після проектування можна виділити наступним чином:

$$x_{n,pr} = t_n u + \mu \quad (2.5)$$

Тепер нехай d є довільним. Отже, нам потрібно знайти вектор зсуву μ і напрямні вектори гіперплощини u_1, \dots, u_d такі, щоб помилка проектування вибірки на цю гіперплощину була б мінімальна. Міркуючи аналогічно нагоди $d = 1$, легко показати, що

$$\mu = \frac{1}{N} \sum_{n=1}^N x_n$$

$$S u_i = \lambda_i u_i, i = 1, \dots, d,$$

$$\lambda_1 \geq \lambda_2 \geq \dots \lambda_D$$

Таким чином, оптимальні u_i є власними векторами матриці S , що відповідають її d найбільшим власним значенням. Позначимо через U матрицю $[u_1, \dots, u_d]$. Тоді редукція X при проектуванні на оптимальну гіперплощину обчислюється як

$$t_n = (x_n - \mu)^T U,$$

а самі точки проєкції визначаються як

$$x_{n,pr} = t_n^T U + \mu.$$

Метод головних компонент через критерій максимізації розкиду в даних.


Поряд з критерієм мінімізації помилки проектування можна розглянути альтернативний критерій пошуку гіперплощини, пов'язаний з максимізацією розкиду спроектованих точок вибірки. Розглянемо знову найпростішу ситуацію $D = 2, d = 1$.

Позначимо через t^i випадкову величину, що відповідає значенню i -ї ознаки. На рисунку 2.5,а показана вихідна вибірка в двомірному просторі разом з напрямленими, обумовленими власними векторами вибіркової матриці коваріації. На рисунку 2.5,б показаний перехід до некорелірованих ознак.


В редукованому просторі R^d характеристикою розкиду даних в одновимірному просторі є вибіркова дисперсія. Припустимо, що наша вибірка є центрованою, тобто $\sum_{n=1}^N x_n = 0$. Тоді

$$Et^1 = \frac{1}{N} \sum_{n=1}^N t_n = \frac{1}{N} \sum_{n=1}^N u^T x_n = u^T \frac{1}{N} \sum_{n=1}^N x_n = 0,$$

$$Dt^1 = \frac{1}{N} \sum_{n=1}^N (t_n - Et^1)^2 = \frac{1}{N} \sum_{n=1}^N u^T x_n x_n^T u = u^T S u.$$



а)



б)

Рисунок 2.5 – Приклад застосування методу головних компонент.

Таким чином, завдання максимізації дисперсії даних на прямий збігається із завданням оптимізації (2.1). Отже, оптимальна пряма визначається власним вектором матриці S , що відповідає найбільшому власному значенню λ_{\max} .

Розглянемо випадок довільного значення d . Характеристикою розкиду даних в багатовимірному просторі є вибіркова матриця коваріації. Як скалярного критерію розкиду виберемо слід вибіркової матриці коваріації, що еквівалентно сумі вибірових дисперсій по ортогональними напрямкам u_1, \dots, u_d . Тоді можна показати, що максимізація сліду вибіркової матриці коваріації призводить до вирішення (2.6). При цьому значення критерію складає

$$J = \sum_{i=1}^d Dt^i = \sum_{i=1}^d \lambda_i.$$

Тут $\lambda_1 \geq \lambda_2 \dots \geq \lambda_D$.

$$d : \frac{\sum_{i=d+1}^D \lambda_i}{\sum_{i=1}^D \lambda_i} < n.$$

Отже, метод головних компонент передбачає перехід від вихідного базису до базису з власних векторів матриці коваріації S з подальшим відкиданням проєкцій вибірки на власні вектора, що відповідають $D - d$ найменшим власним значенням. В базисі з власних векторів матриця коваріації

S має діагональний вигляд $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_D)$

Таким чином, **ознаки, одержувані за допомогою методу головних компонент, є некорельованими**. Перехід до некорельованих ознак часто є розумним




Рисунок 2.6 – Метод головних компонент може бути використаний для розв'язання задачі ідентифікації або методом предобробки вихідних даних

Тому метод головних компонент застосовується і в випадку $d = D$. Розглянемо простий модельний приклад застосування методу головних компонент. Нехай вихідна вибірка представляє собою дані в двовірному просторі (див. рисунок 2.5,а). При використанні методу головних компонент центр координат нового простору переноситься в центр вибірки, а осі визначаються власними векторами вибіркової матриці коваріації (див. рисунок 2.5,б). Таким чином, нові ознаки є некорреліованими. У тому випадку, якщо $d = 1$, то додатково здійснюється проєкція вибірки на напрямок, що відповідає найбільшому власному значенню (напрямок з найбільшою дисперсією). Для даного прикладу це координата x .

Рішення задачі ідентифікації.

Інтерпретація методу головних компонент за допомогою розкиду даних дозволяє використовувати його для розв'язання задачі ідентифікації. Ми

знаємо, що d найбільших власних значень λ_i вибіркової матриці коваріації визначають дисперсії вибірки Dt^i уздовж напрямків u_i . З нерівності Чебишева слід визначити, що ймовірність відхилення випадкової величини від свого математичного очікування на k стандартних відхилення не перевищує $1/k^2$. Отже, з ймовірністю не вище $1/k^2$ значення ознаки для n об'єкта в редуцьованому просторі знаходиться в інтервалі

$$-k\sqrt{\lambda_i} \leq t_{ni} \leq k\sqrt{\lambda_i}.$$

Якщо додатково відомо, що випадкова величина t^i є нормальною або наближено нормальною, то довірчий інтервал значно скорочується. Зокрема, ймовірність відхилення на 3 стандартних відхилення становить всього 0.3%. Цей результат відомий як «правило трьох сигма».

Таким чином, якщо виявилось, що тестовий об'єкт після проектування на u_1, \dots, u_d має хоча б одне значення проекції, яке не вкладається в довірчий інтервал, то це є приводом визнати цей об'єкт не відповідає генеральній сукупності об'єктів, представленої в навчальній вибірці. На рис. 6 показаний приклад ідентифікації за допомогою методу головних компонент. Розглядається задача розпізнавання рукописних

Зображення, відповідне цифрі (4), не вкладається в довірчий інтервал проекцій за першими двома власним векторами.

Вибір розмірності зменшеного простору d .

До цих пір передбачалося, скорої простору d задається користувачем заздалегідь. Це значення легко вибрати в тому випадку, якщо стоїть завдання візуалізації даних ($d = 2$ або $d = 3$) або завдання вкладення вибірки в заданий обсяг пам'яті. Однак, у багатьох інших випадках вибір d є далеко не очевидним з апіорних припущень. Для методу головних компонент існує простий евристичний прийом вибору величини d . Однією з особливостей методу є той факт, що всі скорочені простору для $d = 1, 2, \dots, D$ є вкладеними один в одного. Зокрема, одноразове обчислення всіх власних векторів і власних значень вибіркової матриці коваріації S дозволяє отримати редуцьованне простір

для будь-якого значення d . При цьому помилка проектування даних на відповідну гіперплощину визначається величиною $\sum_{i=d+1}^D \lambda_i$.




Рисунок 2.7 – Схема вибору розмірності скороченої простору для методу ГОЛОВНИХ КОМПОНЕНТ

Тому для вибору значення d можна відобразити на графіку власні значення в порядку убутання і вибрати поріг відсікання таким чином, щоб справа залишилися значення, незначущі відміне від нуля. Інший спосіб передбачає вибір порога так, щоб справа залишався певний відсоток від загальної площі під кривою (наприклад, 5% або 1%), тобто

$$d : \frac{\sum_{i=d+1}^D \lambda_i}{\sum_{i=1}^D \lambda_i} < \eta.$$

Площа під кривою визначається значенням $\text{tr}(S)$ і відповідає величині розкиду даних.

Ефективні обчислення при $D > N$.

При використанні методу головних компонент необхідно обчислювати вибірку матрицю коваріації, яка має розмір $D \times D$, а також її власні вектори і власні значення. Складність цих операцій становить $O(ND^2)$ і $O(D^3)$. У тому

випадку, якщо $D > N$, то існує спосіб більш економного обчислення власних векторів і власних значень матриці коваріації за допомогою матриці розміру $N \times N$ і складністю, відповідно, $O(DN^2)$ і $O(N^3)$. Дійсно, в просторі розмірності D безліч з N точок породжує лінійне різноманіття максимальної розмірності $N - 1$.

Тому не має сенсу застосовувати метод головних компонент для $d > N - 1$. З точки зору матриці коваріації це означає, що тільки $N - 1$ власних значень відмінні від нуля. Всі інші власні вектора не має сенсу обчислювати, тому що дисперсія вибірки уздовж цих напрямків свідомо дорівнює нулю.

Нехай $X \in R^{N \times D}$ - вихідна вибірка з нульовим центром, тобто $\frac{1}{N} \sum_{n=1}^N x_n = 0$.

Тоді вибіркова матриця коваріації $S = \frac{1}{N} X^T X$; . Розглянемо власні вектора і власні значення матриці S :

$$\frac{1}{N} X^T X q_i = \lambda_i q_i.$$

Домножимо обидві частини цього рівняння на X зліва:

$$\frac{1}{N} X X^T (X q_i) = \lambda_i (X q_i) \quad (2.7)$$

Позначаючи $v_i = X q_i$, отримуємо

$$\frac{1}{N} X X^T v_i = \lambda_i v_i. \quad (2.8)$$

Таким чином, матриця $\frac{1}{N} X X^T$ розміру $N \times N$ має ті ж власні значення, що і вибіркова матриця коваріації S (у якій, в свою чергу, є $D - N$ додаткових нульових власних значень).

Складність пошуку власних значень і власних векторів матриці $\frac{1}{N} X X^T$

становить $O(N^3)$, що може давати значну вигоду по порівняно з $O(D^3)$ при $D > N$. Для отримання власних векторів матриці S домножимо обидві частини останнього рівняння на X^T :

$$\frac{1}{N} X^T X (X^T v_i) = \lambda_i (X^T v_i).$$

Таким чином, $X^T v_i$ власним вектором матриці S , що відповідає власним значенням λ_i . Однак, в тому випадку, якщо вихідні вектора v_i є нормованими, тобто $\|v_i\|=1$ то вектора $X^T v_i$ нормованими вже не є. Нормовані вектора можна отримати за допомогою наступного перетворення:

$$q_i = \frac{1}{\sqrt{N\lambda_i}} X^T v_i.$$

Площа під кривою визначається значенням $\text{tr}(S)$ і відповідає величині розкиду даних.

Алгоритм на основі методу головних компонентів

Вхід: $X \in R^{N \times D}$ - вихідна вибірка даних, d - розмірність скороченої простору

Вихід: $T \in R^{N \times d}$ уявлення вибірки в редукованому просторі

$$x = \frac{1}{N} \sum_{n=1}^N x_n; \quad // \text{ Обчислюємо вибіркове середнє}$$

$$x_n \leftarrow x_b - x; \quad // \text{ Переносимо початок координат в центр вибірки}$$

якщо $N > D$ то:

$$S = \frac{1}{N} X^T X; \quad // \text{ Обчислюємо вибірккову матрицю коваріації}$$

$S = Q\Delta Q^T, \Delta = \text{diag}(\lambda_1, \dots, \lambda_D), Q^T Q = I, Q = (q_1 | \dots | q_D) //$ знаходимо власні вектора і власні значення матриці коваріації

Вибираємо d найбільших власних значень $\lambda_1 \geq \lambda_2 \geq \dots \lambda_d$ і відповідні їм власні вектора $W = (q_1 | \dots | q_d)$;

інакше:

$$S = \frac{1}{N} XX^T;$$

$S = Q\Delta Q^T, \Delta = \text{diag}(\lambda_1 \dots \lambda_D), Q^T Q = I, Q = (q_1 | \dots | q_D); //$ Знаходимо власні вектора і власні значення матриці S

$$Q \leftarrow \frac{1}{\sqrt{N}} X^T Q \text{diag}\left(\frac{1}{\sqrt{\lambda_1}}, \dots, \frac{1}{\sqrt{\lambda_D}}\right) //$$
 Переходимо до нормованих власних

векторів вибіркової матриці коваріації

Вибираємо власні вектора, відповідні d найбільшим власним значенням

$$W = (q_1 | \dots | q_d);$$

$$T = XW; //$$
 Проектуємо вибірку на обрані напрямки

Другий розділ присвячений аналізу текстурні ознаки на основі локальних бінарних шаблонів. З метою скорочення розміру текстур і підвищення точності опису вводиться модифікований, інваріантний щодо повороту, оператор. Розроблено двокроковий алгоритм класифікації на основі оператора локальних бінарних шаблонів. Розроблено алгоритм Зменшення простору ознак на основі методу головних компонент.

3 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ РОЗРОБЛЕНИХ АЛГОРИТМІВ

3.1 Інструментальні засоби

OpenCV - є найпопулярнішою бібліотекою комп'ютерного зору. Вона написана на C / C ++, її вихідний код відкритий. бібліотека включає більше 1000 функцій і алгоритмів. Вона розробляється з 1998 року, спочатку в компанії Інтел, тепер в Itseez за активної участі спільноти. Про високу популярність бібліотеки свідчить кількість завантажень, їх більш 600000 завантажень.

Бібліотека розповсюджується за ліцензією BSD, що означає, що її можна вільно і безкоштовно використовувати як у відкритих проектах з відкритим кодом, так і в закритих, комерційних проектах. Бібліотеку не обов'язково копіювати цілком в свій проект, можна використовувати шматки коду. Єдина вимога ліцензії - наявність в супроводжуючих матеріалах копії ліцензії OpenCV. Через ліберальність ліцензії бібліотека використовується багатьма компаніями, організаціями, університетами, наприклад, NVidia, Willow Garage, Intel, Google, Stanford University. Компанії NVidia і WillowGarage частково спонсорують її розробку.

Основні модулі бібліотеки можна віднести до 4 групам (розділах):

- Модулі core, highgui, що реалізують базову функціональність (базові структури, математичні функції, генератори випадкових чисел, лінійна алгебра, швидке перетворення Фур'є, введення / виведення зображень і відео, введення / виведення в форматах XML, YAML і ін.).

- Модулі imgproc, features2d для обробки зображень (фільтрація, геометричні перетворення, перетворення колірних просторів, сегментація, виявлення особливих точок і ребер, контурний аналіз і ін).

- Модулі video, objdetect, calib3d (калібрування камери, аналіз руху і відстеження об'єктів, обчислювати координати в просторі, побудова карти глибини, детектування об'єктів, оптичний потік).

- Модуль ml, який реалізує алгоритми машинного навчання (метод найближчих сусідів, наївний байєсівський класифікатор, дерева рішень,

бустінг, градієнтний бустінг дерев рішень, випадковий ліс, машина опорних векторів, нейронні мережі та ін.).

Звернемо увагу на підтримку роботи з xml-файлами. Результати проміжних обчислень можна зберігати в xml-файлах, а потім їх прочитати, наприклад, в іншій програмі, що полегшує розробку алгоритму по частинах, роботу над алгоритмом цілою командою.

Зауважимо, що бібліотека OpenCV реалізує, як правило, тільки базові операції, які використовуються в комп'ютерному зорі. Таким чином, її можна розглядати як в цілому низькорівневу бібліотеку комп'ютерного зору. Для вирішення серйозних завдань необхідно на основі наданих бібліотекою цеглинок створювати свої складні застосування.

На малюнку нижче представлена загальна схема типового застосування, призначеного для вирішення того чи іншого завдання комп'ютерного зору (звичайно, не всі програми підпадають під цю схему).

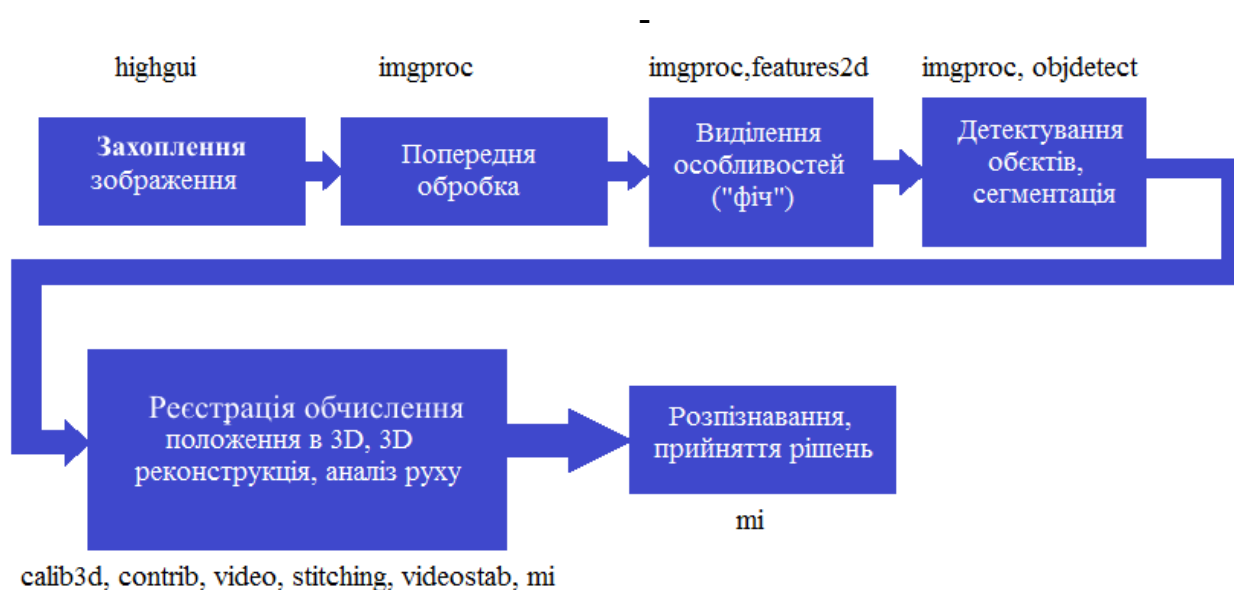


Рисунок 3.1 – Загальна схема типового додатка комп'ютерного зору

Все починається з захоплення зображень (модуль highgui). Ви читаєте зображення з файлу або читаєте відео з мережевої камери через мережевий протокол.

Далі здійснюється попередня обробка (модуль imgproc), така, як усунення шуму, вирівнювання яскравості, контрасту, виділення і видалення відблисків, тіней. Наприклад, один і той же об'єкт при різному освітленні виглядає по-

різному. У яскравому світлі червона машина, рух якої, необхідно відстежувати, буде яскраво-оранжевою. У похмуру погоду та ж машина буде виглядати червоно-рожевою. У цьому випадку на зображенні необхідно виконати вирівнювання квітів. Передобробка може бути простою, але може містити в собі цілу складну технологію.

Наступний етап - виділення особливостей (модулі `imgproc`, `features2d`). Наприклад, в завданні стеження за об'єктом це може бути пошук спеціальних точок на об'єкті, за якими легко спостерігати; для завдання детектування (т. е. виявлення на зображенні) особи - обчислення опису кожного пікселя.

Далі відбувається детектування цікавлять нас об'єктів, виділення значущих частин, сегментація зображення (модулі `imgproc`, `objdetect`). Якщо, наприклад, камера нерухома, а зображення рухоме, можна використовувати алгоритми віднімання фону.

Після цього вирішуємо основне завдання – аналіз структури (Модулі `calib3d`, `contrib`, `video`, `stitching`, `videostab`, `ml`).

В кінці відбувається розпізнавання і прийняття конкретних рішень (модуль `ml`). Наприклад, в системі відеоспостереження: з'явився небажаний об'єкт в кадрі чи ні. У задачі детектування тексту - детектувати текст, що саме за текст і т. д.

Усе більшу роль для реалізації алгоритмів та систем опрацювання зображень починають відігравати інтерпретовані мови, оскільки зростаюча міць персональних комп'ютерів починає забезпечувати достатню швидкість виконання інтерпретованих програм. А єдиною істотною перевагою компільованих мов програмування є створюваний ними високошвидкісний код. Коли швидкість виконання програми не є критичною величиною, найбільш правильним вибором буде інтерпретована мова, як більш простий і гнучкий інструмент програмування. **Для програмної реалізації розроблених алгоритмів та сценарію для тестування обрано інтерпретовану мову Python.** Розглянемо її переваги.

Якість програмного забезпечення. Для багатьох основна перевага мови Python полягає в легкочитаності, ясності й більш високій якості, що відрізняють його від інших інструментів у світі мов програмування. Програмний код мовою

Python читається легше, а виходить, багаторазове його використання й обслуговування виконується набагато простіше, чим використання програмного коду на інших мовах сценаріїв. Однаковість оформлення програмного коду мовою Python полегшує його розуміння навіть для тих, хто не брав участь у його створенні. Крім того, Python підтримує найсучасніші механізми багаторазового використання програмного коду, яким є об'єктно-орієнтоване програмування (ООП).

Висока швидкість розробки. У порівнянні з, що компілюють або строго типізованими мовами, такими як C, C++ і Java, Python у багато разів підвищує продуктивність праці розроблювача. Обсяг програмного коду мовою Python звичайно становить третину або навіть п'яту частину еквівалентного програмного коду мовою C++ або Java. Це означає менший обсяг уведення із клавіатури, меншу кількість часу на налагодження й менший обсяг працевитрат на супровід. Крім того, програми мовою Python запускаються відразу ж, минаючи тривалі етапи компіляції й зв'язування, необхідні в деяких інших мовах програмування, що ще більше збільшує продуктивність праці програміста.

Переносимість програм. Більша частина програм мовою Python виконується без змін на всіх основних платформах. Перенос програмного коду з операційної системи Linux в Windows звичайно полягає в простому копіюванні файлів програм з однієї машини на іншу. Більше того, Python надає масу можливостей по створенню стверпних графічних інтерфейсів, програм доступу до баз даних, веб-додатків і багатьох інших типів програм. Навіть інтерфейси операційних систем, включаючи спосіб запуску програм і обробку каталогів, у мові Python реалізовані стверпним способом.

Бібліотеки підтримки. У складі Python поставляється велике число зібраних і стверпних функціональних можливостей, відомих як стандартна бібліотека. Ця бібліотека надає масу можливостей, затребуваних у прикладних програмах, починаючи від пошуку тексту по шаблону й закінчуючи мережними функціями. Крім того, Python допускає розширення як за рахунок ваших власних бібліотек, так і за рахунок бібліотек, створених сторонніми розроблювачами. Із числа сторонніх розробок можна назвати інструменти

створення веб-сайтів, програмування математичних обчислень, доступ до послідовного порту, розробку ігрових програм і багато чого іншого. Наприклад, розширення NumPy позиціонується як вільний і могутніший еквівалент системи програмування математичних обчислень Matlab.

Інтеграція компонентів. Сценарії Python легко можуть взаємодіяти з іншими частинами додатка завдяки різним механізмам інтеграції. Ця інтеграція дозволяє використовувати Python для налаштування й розширення функціональних можливостей програмних продуктів. На сьогоднішній день програмний код мовою Python має можливість викликати функції з бібліотек мовою C/C++, сам викликатися із програм, написаних мовою C/C++, інтегруватися із програмними компонентами мовою Java, взаємодіяти з такими платформами, як COM і .NET, і робити обмін даними через послідовний порт або по мережі за допомогою таких протоколів, як SOAP, XML-RPC і CORBA.

Прикладне застосування Python. Python використовується не тільки окремими користувачами, він також застосовується компаніями для створення продуктів, що приносять справжній прибуток. Наприклад:

- Компанія Google широко використовує Python у своїй пошуковій системі й оплачує працю творця Python.
- Служба колективного використання відеоматеріалів Youtube у значній мірі реалізована мовою Python.
- Потужна система тривимірного моделювання й створення мультиплікації Maya підтримує інтерфейс для керування зі сценаріїв мовою Python.
- NASA, Los Alamos, Fermilab, JPL і інші використовують Python для наукових обчислень.
- ESRI використовує Python у якості інструмента налаштування своїх популярних геоінформаційних програмних продуктів під потреби кінцевого користувача.

Універсальна природа мови забезпечує можливість його застосування в самих різних областях. Фактично з певною часткою впевненості можна затверджувати, що Python так чи інакше використовується практично кожною досить великою організацією, що займається розробкою програмного

забезпечення, – як для розв'язку короткострокових тактичних завдань, так і для розробки довгострокових стратегічних проектів.

З погляду функціональних можливостей Python можна назвати гібридом. Його інструментальні засоби укладаються в діапазон між традиційними мовами сценаріїв (такими як Tcl, Scheme і Perl) і мовами розробки програмних систем (такими як C, C++ і Java). Python забезпечує простоту й невимушеність мови сценаріїв і міць, яку звичайно можна знайти в мовах, що компілюють. Перевищуючи можливості інших мов сценаріїв, така комбінація робить Python зручним засобом розробки великомасштабних проектів. Нижче приводиться список основних можливостей, які є в арсеналі Python:

Динамічна типізація. Python сам стежить за типами об'єктів, використовуваних у програмі, завдяки чому не потрібно писати довгі й складні оголошення в програмному коді. У дійсності, у мові Python взагалі відсутні поняття типу й необхідність оголошення змінних. Тому що програмний код мовою Python не стиснутий рамками типів даних, він автоматично може обробляти цілий діапазон об'єктів.

Автоматичне керування пам'яттю. Python автоматично розподіляє пам'ять під об'єкти й звільняє її ("складання сміття"), коли об'єкти стають непотрібними. Більшість об'єктів можуть збільшувати й зменшувати займаний обсяг пам'яті в міру необхідності.

Модульне програмування. Для створення великих систем Python надає такі можливості, як модулі, класи й виключення. Вони дозволяють розбити систему на складові, застосовувати ООП для створення програмного коду багаторазового користування й елегантно обробляти виникаючі події й помилки.

Вбудовані типи об'єктів. Python надає найбільш типові структури даних, такі як списки, словники й стрічки, у вигляді особливостей, властивих самій мові програмування. Ці типи відрізняються високою гнучкістю й зручністю. Наприклад, вбудовані об'єкти можуть розширюватися й стискуватися в міру необхідності, можуть комбінуватися один з одним для вистави даних зі складною структурою.

Вбудовані інструменти. Для роботи з усіма цими типами об'єктів у складі Python є потужні й стандартні засоби, включаючи такі операції, як конкатенація (об'єднання колекцій), одержання зрізів (добування частини колекції), сортування, відображення й багато чого іншого.

Бібліотеки утиліт. Для виконання більш вузьких завдань до складу Python також входить велика колекція бібліотечних інструментів, які підтримують практично все, що тільки може знадобитися, – від пошуку з використанням регулярних виражень до роботи в мережі. Бібліотечні інструменти мови Python – це те місце, де виконується більша частина операцій.

Утиліти сторонніх розроблювачів. Python – це відкритий програмний продукт і тому розроблювачі можуть створювати свої попередньо скомпільовані інструменти підтримки завдань, розв'язати які внутрішніми засобами неможливо.

Перевага Python перед іншими мовами високого рівня

- Має більш широкі можливості, чому Tcl. Мова Python підтримує "програмування в цілому", що робить його застосовним для розробки великих систем.

- Має більш чіткий синтаксис і більш просту архітектуру, ніж Perl, що робить програмний код більш читаним, простим у супроводі й знижує ймовірність появи помилок.

- Простіше й зручніше, чим Java. Python – це мова сценаріїв, а Java успадкувала складний синтаксис від таких мов програмування, як C++.

- Простіше й зручніше, чим C++, але нерідко він не може конкурувати з C++, оскільки, будучи мовою сценаріїв, Python призначений для розв'язку іншого кола задач.

- Більш прозорий і більш універсальний, ніж PHP. Іноді Python використовується для створення веб-сайтів, але він здатний вирішувати набагато більш широке коло завдань, від керування роботами до створення анімаційних фільмів.

- Більш зрілий і має більш ясний синтаксис, ніж Ruby. На відміну від Ruby і Java, об'єктно-орієнтований стиль програмування є обов'язковим в Python – він не змушує використовувати ООП у проектах, де цей стиль не застосуємо.

– Має динамічні особливості таких мов, як Smalltalk і Lisp, але має більш простий і традиційний синтаксис, доступний як для розроблювачів, так і для кінцевих користувачів, що настроюються систем.

Узагальнена структура програмного засобу відображає інструментальні бібліотеки котрі використовуються при реалізації програмного забезпечення (рисунок 3.2). Модуль SciPy містить модулі для оптимізації, інтегрування, спеціальних функцій, обробки сигналів, обробки зображень, генетичних алгоритмів, розв'язування звичайних диференціальних рівнянь та інших задач, які розв'язуються в науці і при інженерній розробці. Модуль NumPy надає підтримку великих багатовимірних масивів і матриць, бібліотеку високорівневих математичних функцій для операцій з цими масивами. Модуль CV дозволяє підключати в сценарій бібліотеку опрацювання зображень OpenCV. Модуль scikit-image це бібліотека обробки зображень, яка реалізує алгоритми і утиліти для використання в науково-дослідному, освітньому і промисловому ПЗ. Модуль scikit-learn реалізує основні методи машинного навчання: алгоритми навчання з учителем (Supervised Learning), алгоритми навчання без вчителя (Unsupervised Learning). Модуль matplotlib використовується для візуалізації наукових даних у вигляді графіків.

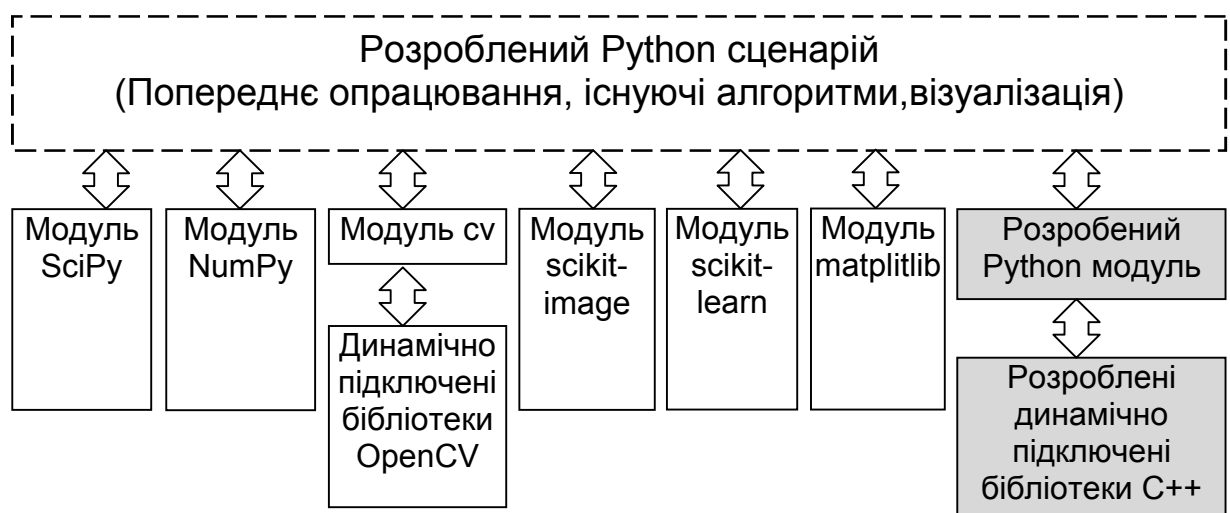


Рисунок 3.2 – Структура програмного засобу

Для програмної реалізації використано структурний та об'єктно-орієнтований підходи. Окремі сутності предметної області представляють у вигляді класів, взаємодія між ними проходить чітко визначеним способом через

інтерфейс класу і технологію наслідування.

3.2 Об'єктна модель системи онкологічної діагностики

Розроблені алгоритми включено до модуля системи онкологічної діагностики. Розглянемо прецеденти та узагальнену об'єктну модель інформаційної системи аналізу біомедичних зображень. Складність розроблення концептуальної та об'єктної моделей автоматизованої системи онкологічної діагностики на основі зображень впливає з наступних факторів:

- наявність декількох ролей користувачів (акторів);
- наявність великої кількості прецедентів;
- комбінування методів комп'ютерного зору, методів штучного інтелекту, зокрема методів нечіткого виводу висновку;
- різноманітність даних в системі (зображення, ознаки класів мікрооб'єктів, правила виводу, функції належності та ін.);
- адаптація графічного інтерфейсу до ролі поточного користувача.

Одними із самих широкоживаних сьогодні паттернів розробки архітектури є Model-View-Controller, Model-View-Presenter, Model-View-ViewModel (MVVM), View- Interactor- Presenter- Entity- Routing (VIPER). Всі ці архітектури вимагають чіткого розділення програмної системи на шари: представлення, предметної області, даних. Шар представлення описує модель запиту до об'єктів шару предметної області і модель відповіді. Об'єкти цього шару повинні представляти вхідну на вихідну інформацію в спосіб не залежний від обраних бібліотек і фреймворків графічного інтерфейсу. Найкращим випадком є використання бібліотеки графічного інтерфейсу користувача як плагіна до розроблюваного ядра системи.

Ядро системи включає правила предметної області і сутності даних. Ці сутності розробляється окремо від модулів графічного інтерфейсу, модулів мережевої взаємодії чи модулів взаємодії з базою даних. Ядро системи можна

представити об'єктами Інтерактор та Сутність (рисунок 3.3). Об'єкт Інтерактор може відображати окремий прецедент.

Об'єктно-орієнтовані системи розглядаються як сукупність автономних і незалежних об'єктів, що взаємодіють між собою на різних рівнях. Зміна реалізації будь-якого об'єкта або додавання/корекції нових функцій не впливає на інші об'єкти системи. Чітка відповідність між реальними об'єктами (сутностями) та керуючими об'єктами програмної системи полегшує розуміння та реалізацію проекту.

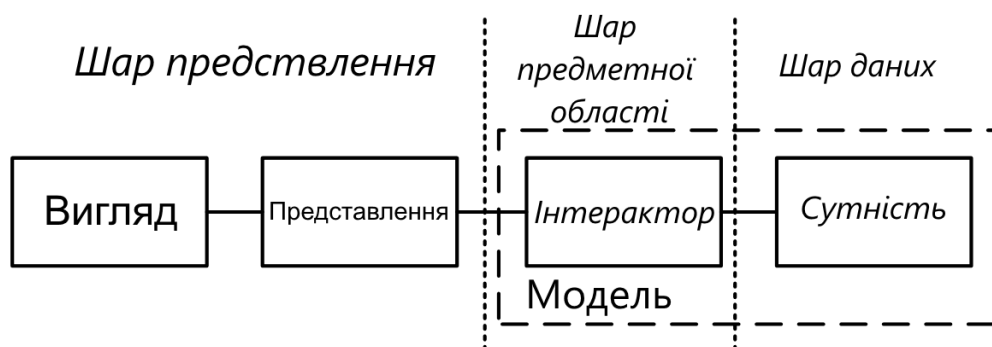


Рисунок 3.3 – Узагальнена архітектура програмного забезпечення автоматизованої системи

При використанні об'єктно-орієнтованого підходу під час проектування програмних систем використовують два основних типи моделей системної архітектури:

- статичні моделі, що описують статичну структуру системи в термінах класів об'єктів і взаємин між ними. Основними взаємовідносинами, що розглядаються на даному етапі, є відносини узагальнення, відносини виду ”використовують-використовуються” та структурні відносини.

- динамічні моделі. Дані моделі описують динамічну структуру системи та показують взаємодії між об'єктами системи (але не класами об'єктів).

Етап проектування є одним з головних під час розробки програмних систем та має на меті забезпечити виконання таких задач:

- виділення основних сутностей, що описують предметну область;
- визначення основних полів, методів класів;

- теоретична перевірка правильності функціонування програмної системи та її модулів;
- усунення надлишкових зв'язків між окремими модулями системи;
- оцінка технічних вимог та функціональних характеристик майбутньої програмної системи.

Про проектуванні системи був використаний об'єктно-орієнтований підхід. В основі даного підходу лежить об'єктна декомпозиція, що дозволяє провести попередню оцінку обраної структури. При аналізі предметної області було виділено 4 основних користувачі та 3 додаткових користувачі. Приведемо опис функції користувачів.

Адміністратор: встановлення, налаштування, модифікація наявних модулів, додавання, редагування, видалення користувачів системи, модифікації форм звітності, технічна підтримка ІС та бази даних, аналіз записів роботи системи та прогнозування можливих помилок, доступ до всіх функціональних модулів системи, наявність унікального ідентифікатора та ідентифікація в системі.

Лікар-діагност: отримання зображень, пошук інформації в БД, створення нових правил діагностування, створення нових шаблонних описів медичних об'єктів, редагування облікових карток пацієнта, постановка діагнозу, обмін повідомленнями, наявність унікального ідентифікатора та ідентифікація в системі.

Лікуючий лікар: отримання зображень, первинна обробка зображень, пошук інформації в БД, редагування облікових карток пацієнта, постановка діагнозу, обмін повідомленнями, наявність унікального ідентифікатора та ідентифікація в системі.

Лаборант: отримання зображень, пошук інформації, первинна обробка зображень, внесення інформації в БД зображень, ідентифікація в системі тільки при необхідності, доступ до модулів обробки зображень, обмін поштовими повідомленнями.

Даний набір Акторів та прецедентів дозволяє оцінити основні складові майбутньої системи, визначити майбутню структуру та множину класів для подальшої її реалізації.

Діаграма прецедентів гібридної інтелектуальної системи аналізу біомедичних зображень наведено на рисунку 3.4.

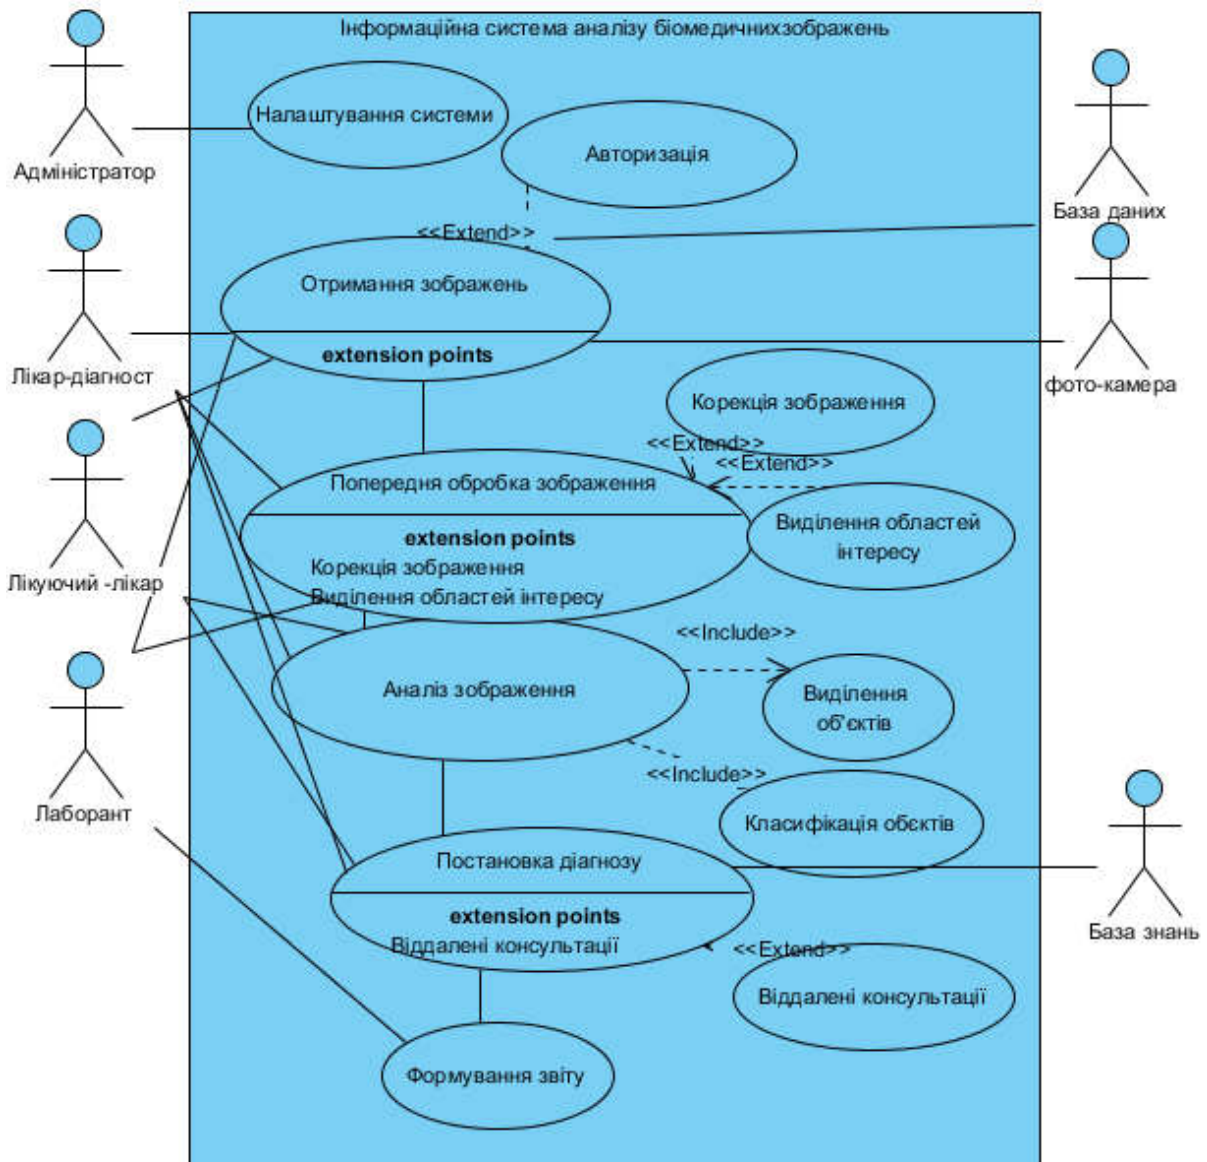


Рисунок 3.4 – Діаграма прецедентів інформаційної системи аналізу біомедичних зображень

Відповідно до об'єктної моделі стандарту DICOM інтерфейс зокрема повинен забезпечити відображення та редагування даних про пацієнта, дослідження, серію біомедичних зображень, екземпляри біомедичних зображень). Додатково для кожного зображення потрібно представити (описати), атрибути зображення, клас мікрооб'єктів вибраного дослідження та самі мікрооб'єкти вибраного класу, яким і будуть задаватися певні атрибути.

Моделювання знань на основі візуальної інтерпретації зображень і створення бази знань діагностичних ознак складний багатокроковий процес. Він має такі кроки: опис мікрооб'єктів та їх якісних ознак, визначення числових ознак мікрооб'єктів, визначення нечітких змінних та побудова функцій належності, формалізація правил діагностування злюякісних новоутворень, побудова бази нечітких правил.

Для задоволення вимог персистентності системи і збереження інформації про пацієнта, зображень, отриманих із відповідного препарату, кількісних ознак мікрооб'єктів розроблено базу даних. Головна таблиця зберігає дані про пацієнта. Вона має зв'язки із таблицями для зберігання даних про дослідження та таблицею, що пов'язує серію зображень, розміщених в певному каталозі файлової системи із ідентифікатором дослідження. Окрема таблиця пов'язує зображення та набір виділених на ньому областей і їх числових ознак.

Для опису мікрооб'єктів та їх якісних ознак потрібно формалізувати знання (досвід) експерта морфолога: логічні дерева рішень, мову опису клітин та діагнозу. Описові знання можна представити у вигляді спеціальної онтології опису клітин, яка містить всю інформацію про морфологію ракових клітин. Структурована та ієрархічна онтологія складається з усіх значних морфологічних характеристик, які розглядаються окремо. Для кожної характеристики (наприклад, розмір ядра) необхідно зафіксувати якісні значення категорій, які можна присвоїти цій ознаці (наприклад, дуже малий, малий, середній або великий). Узагальнена об'єкта модель автоматизованої системи зображена на рисунку 3.5.

Підсистема набуття знань призначена для перегляду уже зроблених досліджень, яка дозволяє переглянути зображення цих дослідів та усі виділені мікрооб'єкти на зображенні. Людина-експерт може охарактеризувати зображення та виділені мікрооб'єкти у вигляді атрибутів або якісних категорій.

Інтерфейс системи повинен відображати інформацію про: пацієнта, дослід вибраного пацієнта, зображення і клас мікрооб'єктів вибраного дослідів та самі мікрооб'єкти вибраного класу, яким і будуть задаватися певні атрибути. Вибраному зображенню теж можуть задаватися атрибути або якісні категорії.

Узагальнена об'єктна модель машини нечіткого логічного складається із об'єкта обчислення числових ознак, об'єкта - агрегатора числових ознак, об'єкта фазифікації, об'єкта - агрегатора правил діагностування, об'єкту функцій належності, об'єкта нечіткого логічного виводу, об'єкта дефазифікації та об'єкта постановки діагнозу. Нечіткий логічний вивід працює в двох режимах:

- 1) отримання знань;
- 2) постановки попереднього діагнозу (класифікації).

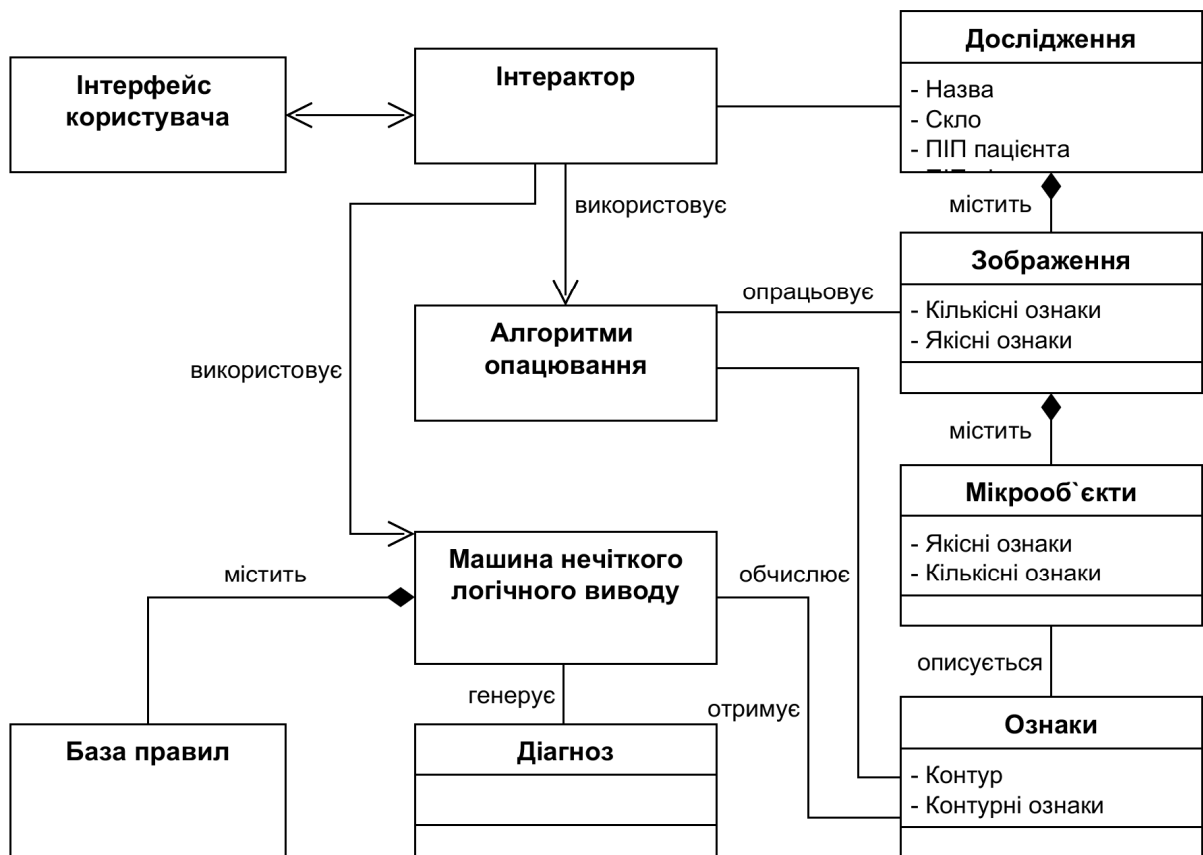


Рисунок 3.5 – Об'єктна модель програмного забезпечення системи

В режимі отримання знань агрегатор правил діагностування заносить правила діагностування в нечіткій формі, які отримані від експертів (цитолога та гістолога). Крім цього об'єкт функцій належності заповнюється конкретними параметрами функцій належності.

У режимі постановки діагнозу об'єкт обчислення числових ознак зчитує цитологічні та гістологічні зображення, в якому обчислюються відповідно цитологічні та гістологічні ознаки, що утворюють множину вхідних ознак, яка

записується в агрегаторі числових ознак. На основі числових ознак ідентифікуються функції належності. Використовуючи множину числових ознак і їх функції належності, об'єкт фазифікації утворює нечітку множину вхідних ознак. Об'єкт нечіткого логічного виводу на основі множини правил та множини ознак, виводить (inference) нечітку множину діагнозів. Об'єкт дефазифікації переводить нечітку множину діагнозів у множину діагностичних ознак із відповідними ваговими коефіцієнтами кожного правила.

Правило діагностування має наступну форму:

IF розмір_клітини=дрібний AND форма_літини=кубічна TO
діагноз=нормальна

Ознака «розмір клітини» задано терм-множиною: дрібний (small), збільшений (enlarged), гігантський (giant). На етапі набуття знань для кожного терму обчислено мінімальне і максимальне значення а також параметри нормального розподілу.

3.3 Експериментальні дослідження

Тестові зображення з бази даних Breast Cancer Cell dataset представлено на рисунку 3.6.

При постановці задачі розробки алгоритму класифікації прийняті наступні вихідні дані:

- зчисленна множина Ω об'єктів, що мають різну форму, і довільним образом розташованих і орієнтованих у площині предметів (на стрічці конвеєра) щодо пристрою реєстрації зображень;

- множина Ω розбивається на класи Ω_k , що утворюють алфавіт класів, причому $\Omega = \bigcup_{k=1}^K \Omega_k$, і задані еталонні зображення $\omega_k^e \in \Omega_k$ кожного із класів об'єктів множини (по одному або кілька об'єктів у кожному із класу), які зберігаються в базі даних.




Рисунок 3.6 – Тестові зображення

Алгоритм розпізнавання включає наступні етапи: сегментація зображення, опис зображення об'єкта в просторі обраних ознак, прийняття рішення про віднесення об'єкта, що з'являється в робочому полі пристрою реєстрації, до певного класу.


Рішення про віднесення вхідного зображення до певного класу здійснюється класифікатором на основі оцінки міри близькості у вигляді евклідової відстані відповідно до правила

$$\min_j \{\rho_E(\omega^T, \omega_j^E)\} \rightarrow \Omega_k, \quad \Omega_k \in \Omega,$$

де евклідова відстань $\rho_E(\omega^T, \omega_j^E)$ у просторі ознак між вхідним зображенням ω^T і еталонним зображенням ω_j^E .

Проведемо дослідження розроблених алгоритмів. Об'єкти на ГЗ розбиті на три класи: фон, ядро клітини, з'єднувальна тканина. На рисунку 3.7,а наведено приклад ГЗ та відповідне йому класифіковане зображення на рисунку

3.7.б. Чорним кольором позначено фон, сірим позначено з'єднувальну тканину, білим – ядра клітин.



а) Вихідне зображення

б) Розбиття на класи

Рисунок 3.7 – Приклад класифікації гістологічного зображення

Для класифікації областей використаємо текстурні ознаки на основі матриць розподілу рівнів сірого. Обчислимо такі ознаки: контраст, несхожість, однорідність, другий кутовий момент (ДКМ). В таблиці 3.1 представлено характеристики текстурних ознак для кожного класу об'єктів.

Таблиця 3.1 – Вихідні текстурні ознаки

	Фон		Тканина		Ядро	
	Середнє	СКВ	Середнє	СКВ	Середнє	СКВ
Контраст	12,32	61,04	10,32	47,94	19,999	81,35
Несхожість	0,7593	2,88	0,82196	2,5363	1,147	3,58
Однорідність	0,0246	0,093	0,0315	0,0841	0,0175	0,0515
ДКМ	0,004518	0,0253	0,00329	0,009556	0,00201	0,00575

Метод головних компонент (principal component analysis, PCA) є найпростішим методом зменшення розмірності в даних. Ідея методу полягає в пошуку в вихідному просторі гіперплощини заданої розмірності з подальшим проектуванням вибірки на дану гіперплощину. При цьому вибирається та гіперплощина, помилка проектування даних на яку є мінімальною в відносно суми квадратів відхилень (СКВ).

Нехай є деяка вибірка об'єктів $X = \{\mathbf{x}_n\}_{n=1}^N$, $\mathbf{x}_n \in R^D$. Задача зменшення розмірності полягає в отриманні представлення цієї вибірки в просторі меншої розмірності $T = \{\mathbf{t}_n\}_{n=1}^N$, $\mathbf{t}_n \in R^d$. Розмірність $d < D$, але в окремих випадках d може і збігатися з D . Зменшення розмірності в описі даних забезпечує:

- зменшення обчислювальних витрат при обробці даних;
- зменшення часу навчання оскільки чим менше кількість ознак, тим менше потрібно об'єктів для впевненого відновлення прихованих залежностей в даних і тим вище якість відновлення подібних залежностей;
- стиснення даних для більш ефективного зберігання інформації;
- візуалізація вибірки багатомірних даних у дво-, тривимірному просторі;
- витягнення нових ознак отримані в результаті перетворення, може надавати значний внесок при подальшому вирішенні задач розпізнавання.

Для експериментальних досліджень використано мову програмування Python, бібліотеки алгоритмів машинного навчання sklearn, бібліотеку роботи з матрицями numpy. Узагальнений алгоритм зменшення простору ознак:

- нормування даних, оскільки текстурні ознаки мають різні діапазони значень;
- отримання власних векторів і власних значень з коваріаційної матриці або кореляційної матриці;
- сортування власних значень в порядку зменшення і вибірка d власних векторів, які відповідають d найбільшим власним значенням;
- побудувати проєкційну матрицю W з обраних d власних векторів;
- Перетворити вихідний масив даних X з допомогою W , щоб отримати d -мірний підпростір ознак T .

Експериментальні дані містять вимірювання текстурних ознак для кожної точки тестового гістологічного зображення. Дані розбиті на три класи: фон, ядро клітини, з'єднувальна тканина. Вихідний набір даних представлено у вигляді таблиці 3.2. Кожен експеримент проводиться для ковзаючого вікна розміру 9 пікселів та вектору зсувів 4 пікселі.

Таблиця 3.2 – Фрагмент тестових даних

№	Контраст	Несхожість	Однорідність	ДКМ	Клас
1	10,12	0,533	0,022	0,0035	ядро

В таблиці 3.3 предствлено ознаки класів у двовимірному просторі ознак. На рисунку 3.8 наведено результуючий двовимірний простір ознак точок зображення.

Таблиця 3.3 – Редукований двовимірний простір текстурних ознак

	Фон		Тканина		Ядро	
	Середнє	СКВ	Середнє	СКВ	Середнє	СКВ
Ознака 1	0.0307044	1,434	0,03738	0,91787	-0,204712	0.8214
Ознака 2	0.0162723	1,071	-0,02395	0,87924	0,053651	1.3928




Рисунок 3.8 – Двовимірний простір текстурних ознак

Як видно з графіку частина пікселів всіх трьох класів накладається. Це зумовлено принципом розрахунку текстурних ознак в ковзаючому вікні, що приводить до ефекту розмиття границь окремих об'єктів на зображенні. Проте в області обмежень $[0; 20]$ по першій ознаці і $[0; -3]$ по другій ознаці вдалося досягти розбиття простору на три класи.

Результати вимірювання швидкодії класифікації набору із 100 зображень розміром 3000×2000 пікселів при використанні різних текстурних ознак і співмірній точності (precision) класифікації наведені в таблиці 3.4.

Таблиця 3.4 – Швидкодія класифікації

	Час,хв	
	Повний простір текстурних ознак	Редукований простір текстурних ознак
Локальні бінарні шаблони	15	7
Матриці розподілу рівнів сірого	21	12

У третьому розділі здійснено програмну реалізацію розроблених алгоритмів. Проведено експериментальне дослідження алгоритмів класифікації зображень та алгоритмів зменшення простору ознак при класифікації біомедичних зображень на основі методу головних компонент.

ВИСНОВКИ

В результаті виконання магістерської роботи одержані наступні результати:

1) Проведено огляд існуючих методів та алгоритмів вирішення задач текстурного аналізу. Розглянуто задачу класифікації зображень на основі текстурних ознак. Визначено проблеми побудови простору текстурних ознак та визначено вимоги до ознак. Підсумовано переваги і недоліки систем автоматизованої мікроскопії.

2) В результаті аналізу текстурних ознак на основі локальних бінарних шаблонів модифіковано LBP-оператор і забезпечено його інваріантність щодо повороту, що дозволило підвищити точність опису текстури. Розроблено двокроковий алгоритм класифікації на основі оператора локальних бінарних шаблонів.

3) Розроблено алгоритм зменшення простору ознак на основі методу головних компонент, що дозволило отримати компактну множину текстурних ознак.

4) Здійснено програмну реалізацію розроблених алгоритмів. Проведено експериментальне дослідження алгоритмів класифікації зображень та алгоритмів зменшення простору ознак при класифікації біомедичних зображень на основі методу головних компонент. Для експериментів обрано базу даних гістологічних зображень Breast Cancer Dataset. Зображення розбиті на три класи: фон, ядро клітини, з'єднувальна тканина. Вихідний простір текстурних ознак складається із ознак на основі МРРС: контраст, несхожість, однорідність, другий кутовий момент. Простір ознак зменшено до двох, що дозволили класифікувати три типи тканини на гістологічному зображенні.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Дерій М.В. Ресурс для розміщення баз біомедичних зображень. / Дерій М.В., Котюбін А.В., Скрипець В.І. // 72-ї науково-технічна конференція професорсько-викладацького складу, науковців, аспірантів та студентів Одеської національної академії зв'язку ім. О.С. Попова. Одеса, 2017. – с. 81-82.
2. Блаттер К. Вейвлет-анализ. Основы теории: Учебное пособие для вузов: пер. с нем. / К. Блаттер; пер. Т. Э. Кренкель, ред. пер. А. Г. Кюркчан. – М.: Техносфера, 2006. – 2711 с.
3. Малла С. Вейвлет-анализ в обработке сигналов: Навчальний посібник для вузів / С. Малла; пер. Я.М. Жилейкин. – М.: Мир, 2005. – 671 с.
4. Ng R. Fourier slice photography / Ren Ng // ACM Transactions on Graphics - 2005 - № 24(3). - P. 735–744.
5. Singh M. SAR Image Classification Using PCA and Texture Analysis / Mandeep Singh, Gunjit Kaur // Proceedings of the International Conference “Information Technology and Mobile Communication” (AIM). – Nagpur-Maharashtra- India, 2011. – P. 435-439
6. Мельник Г. М. Зменшення простору текстурних ознак гістологічних зображень за допомогою методу головних компонент // Моделювання та інформаційні технології. - 2016. - Вип. 77. - С. 176-180
7. Schaffalitzky F. Geometric grouping of repeated elements within images / F. Schaffalitzky, A. Zisserman // In Proc. 9th British Machine Vision Conference (BMVC), Southampton, September 1998 – Southampton, UK: Springer-Verlag, 1998. – С. 13-22.
8. Liu Y. A Computational Model for Periodic Pattern Perception Based on Frieze and Wallpaper Groups / Yanxi Liu, Robert T. Collins, Yanghai Tsin // IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI) - 2004. - Т. 1, № 26. - С. 354-371

9. Tuceryan M. Texture Segmentation Using Voronoi Polygons / M. Tuceryan, A. K. Jain // IEEE Transactions on Pattern Analysis and Machine Intelligence - 1990. - T. 2, № 12. - C. 211-216.
10. Liu Y. Near-regular Texture Analysis and Manipulation / Yanxi Liu, Wen-Chieh Lin, James H. Hays // ACM Transactions on Graphics (SIGGRAPH 2004) – 2004. – P. 368-376.
11. Wolter F. Spatio-temporal representation and reasoning based on RCC-8 / Frank Wolter, Michael Zakharyashev // In Proceedings of the seventh Conference on Principles of Knowledge Representation and Reasoning (KR2000) – Breckenridge, Colorado, USA: Morgan Kaufmann, 2000. – P. 3-14.
12. Rajkovic N. Comparison of Monofractal, Multifractal and gray level Co-occurrence matrix algorithms in analysis of Breast tumor microscopic images for prognosis of distant metastasis risk / N. Rajković, D. Kolarević, K. Kanjer, N. T. Milosević, D. Nikolić-Vukosavljević, M. Radulovic // Biomedical Microdevices. - Springer, 2016. - Vol. 5, Num. 18. - P. 83.
13. Saito A. A novel method for morphological pleomorphism and heterogeneity quantitative measurement: Named cell feature level co-occurrence matrix / A. Saito et al. // Journal of Pathology Informatics. – 2016 - Vol. 7, Num. 36.
14. Mohanty A. K. Classifying Benign and Malignant Mass using GLCM and GLRLM based Texture Features from Mammogram / A. K. Mohanty, S. Beberta, S. K. Lenka // International Journal of Engineering Research and Applications. – 2011. - Vol. 1, Issue 3. – P. 687-693.
15. Belsare A. D. Classification of breast cancer histopathology images using texture feature analysis / A. D. Belsare, M. M. Mushrif, M. A. Pangarkar, N. Meshram // 2015 IEEE Region 10 Conference – 2015. – P. 1-5.
16. Herve N. Statistical color texture descriptors for histological images analysis / N. Herve, A. Servais, E. Thervet, J. Olivo-Marin, V. Meas-Yedid // 2011 IEEE International Symposium on Biomedical Imaging: From Nano to Macro – 2015. – P. 724-727.
17. Onder D. Automated classification of cancerous textures in histology images using quasi-supervised learning algorithm / D. Onder, S. Sarioglu, B. Karacali // 2010 15th National Biomedical Engineering Meeting – 2010. – P. 1-4.

18. Riaz F. Content-Adaptive Region-Based Color Texture Descriptors for Medical Images / F. Riaz, A. Hassan, R. Nisar, M. Dinis-Ribeiro, M. Tavares Coimbra // IEEE Journal of Biomedical and Health Informatics. – 2017. – Vol. 21, No. 1. – P. 162-171.
19. Мельник Г.М. Аналітичний огляд методів аналізу та синтезу текстурних зображень / Г.М. Мельник // Вісник Хмельницького національного університету - 2007. - Т. 2, № 1. - С. 110-114
20. Burges C. J. A tutorial on support vector machines for pattern recognition // Data Mining and Knowledge Discovery. – 1998. – Vol. 2, no. 2,- P. 121-167.
21. Burt P. J. The laplasian pyramid as a compact image code // IEEE Transactions on Communications. – 1983.– Vol. COM- 31, no. 4. – P. 532-540.
22. Chang T. Texture analysis and classification with tree-structured wavelet transform / Chang T., Jay C.-C. K. // IEEE Transactions on Image Processing.- 1993. – Vol. 2, no. 4, – P. 429-441.
23. Chapelle O., Vapnik P. II. V. Svms for histogram based image classification // IEEE Transactions on Neural Net-works.– 1999.– Vol. 10,- P. 1055-1064.
24. Chen Y. One-class svm for learning in image retrieval / Chen Y., Zhou X. S., Huang T. S.// IEEE International Conference on Image Processing (ICIP 2001).- 2001.- p. 34-37.
25. Chitkara V. Color-based image retrieval using compact binary signatures: Tech. Rep. TR 01-08: University of Alberta Edmonton, 2001.
26. Chuang G. Wavelet descriptor of planar curves: theory and applications / Chuang G. C.-H.. Kuo C.-C. J. // IEEE Transactions on Image Processing – 1996. - January. - Vol. 5, no. 1. - P. 56-70.
27. Coifman R. R. Entropy-based algorithms for best basis selection // IEEE Transactions on Information Theory. – 1992. – March. - Vol. 38, no. 2. - P. 713-718.
28. Cover T. M., Hart P. E. Nearest neighbor pattern classification // IEEE Transactions on Information Theory. – 1967. -- Vol. 13, no. 1. – Pp. 21–27.
29. Cross G. R., Markov random field texture models // IEEE Transactions on Pattern Analysis and Machine Intelligence:– 1983.– Vol. PAMI-5. - Pp. 25-39.
30. Deer P., On the fusion of image features. – [Електронний ресурс]. Режим доступу <http://citeseer.ist.psu.edu/162546.html>.

31. Dennis T. J. Fractal modelling in image texture analysis // IEEE Proc. of Radar and Signal Processing. – Vol. 136. – 1989. - p. 227-235.
32. Do M. N. Texture similarity measurement using kullback- leibler distance on wavelet subbands // IEEE International Conference on Image Processing (ICIP-2000). - Vol. 3. - 2000. - P. 730-733.
33. Efficient and effective querying by image content: Tech. rep. / C. Faloutsos, W. Equitz, M. Flickner et al.: IBM Research, 1993.
34. An efficiently computable metric for comparing polygonal shapes / E. M. Arkin, L. Chew, D. Huttenlocher et al. // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1991. – Vol. 13. – P. 209-216.
35. Fan S. Shape representation and retrieval using distance histograms: Tech. Rep. 01-14: Department of Computing Science, University of Alberta, 2001.
36. Fast algorithm for the computation of moment invariants / M. F. Zakaria, L. J. Vroomen, P. J. A. Zombor-Murray, J. M. H. M. van Kessel // Pattern Recognition. – 1987. - Vol. 20, no. 6. - p. 639-C43.
37. Field D. J. Relations between the statistics of natural images and the response properties of cortical cells // Journal of the Optical Society of America. – 1987. - Vol. 4, no. 12. - P. 2370-2393.
38. Fox E. A., Combination of multiple searches // 2nd Text REtrieval Conference (TREC-2). – National Institute of Standards and Technology Special Publication 500-215, 1994. - p. 243-252.
39. Freeman H. In computer processing of line-drawing images // ACM Computing Surveys (CSUR). - 1974. - March. – Vol. 6. - p. 57-97.
40. Ghafoor A., Iqbal R. NKhan S. A. Modified chamfer matching algorithm // Lecture Notes in Computer Science. – 2003. – Vol. 2690. – p. 1102-1106.
41. Gotlieb C. CKreyszig H. E. Texture descriptors based on co-occurrence matrices // Computer Vision, Graphics and Image Processing. - 1990.– July. - Vol. 51, no. 1- p. 70-86.
42. Grosky W. An image data model / Grosky W., Stanchev P. //In Proceedings of Advances in Visual Information Systems: 4th International Conference. - 2000. - Pp. 227-243.
43. Guerin-Dugue A. Image retrieval: a first step for a human centered approach / Guerin-Dugue A., Ayache S., Berrut C. // Joint Conference of ICI, CSP and PRCM. - 2003.- p. 21-25.

44. Haddadnia J., Ahmadi M., Faez K. An efficient feature extraction method with pseudo-zernike moment in RBF neural network-based human face recognition system // EURASIP Journal on Applied Signal Processing. – 2003.- p. 890-901.
45. Hateren J. H. V., der Schaaf A. V. Independent component filters of natural images compared with simple cells in visual cortex // Transactions of Royal Society of London. – 1998. – Vol. B265. – p. 359-366.
46. Heller K. A. simple bayesian framework for content- based image retrieval / Heller K. A., Ghahramani Z. // IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2006). - 2006. - p. 2110-2117.
47. Hew P. Geometric and zernike moments. - Diary, Department of Mathematics, The University of Western Australia. - 1996. - October. [Електронний ресурс]. Режим доступу: <http://citeseer.ist.psu.edu/hew96geometric.html>.
48. Hoque S. K. A new chain-code quantization approach enabling high performance handwriting recognition based on multi- classifier schemes / Hoque S., K. Sirlantzis M. C. F. // Seventh International Conference on Document Analysis and Recognition (ICDAR'03). -Vol. 2.- 2003.- 843 p.
49. Howarth P. Evaluation of texture features for content-based image retrieval / Howarth P., Riiger S. // Proceedings of CIVR'04. - 2004. - p. 326-334.
50. Методичні рекомендації до виконання дипломної роботи з освітньо-кваліфікаційного рівня “Магістр”. Спеціальність „Комп’ютерні системи та мережі” / О.М. Березький, Л.О. Дубчак /Під ред. О.М. Березького – Тернопіль: ТНЕУ, 2013.– 47 с.