

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ  
Факультет електроніки та інформаційних технологій

Кафедра комп'ютерних наук

Кваліфікаційна робота магістра  
**ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ КОМП'ЮТЕРНОГО  
ДІАГНОСТУВАННЯ ПАТОЛОГІЙ ОКА**

Здобувач освіти гр. ІН.м-01н

А.В. Путівець

Науковий керівник,  
кандидат технічних наук, доцент,  
доцент кафедри комп'ютерних наук

І.В. Шелехов

Завідувач кафедри  
доктор технічних наук, професор

А.С. Довбиш

Суми 2022

Затверджую:

завідувач кафедри комп'ютерних наук

«\_\_\_» \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ  
НА КВАЛІФІКАЦІЙНУ РОБОТУ ЗДОБУВАЧУ ВИЩОЇ ОСВІТИ**

Путівець Анастасії Валеріївни

1. Тема проекту (роботи) ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ КОМП'ЮТЕРНОГО ДІАГНОСТУВАННЯ ПАТОЛОГІЙ ОКА

затверджую наказом по інституту від «\_\_\_» \_\_\_\_\_ 20\_\_ р. № \_\_\_\_\_

2. Термін здачі студентом закінченого проекту (роботи) \_\_\_\_\_

3. Вхідні данні до проекту (роботи) \_\_\_\_\_

4. Зміст розрахунково-пояснювальної записки (перелік питань, що їх належить розробити)

1) Інформаційно-аналітичний огляд 2) Інформаційно-екстремальна інтелектуальна технологія

3) Інформаційне та програмне забезпечення

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень)

6. Консультанти до проекту (роботи), із значенням розділів проекту, що стосується їх

Розділ	Консультант	Підпис, дата	
		Завдання видав	Завдання прийняв

7. Дата видачі завдання \_\_\_\_\_

Керівник \_\_\_\_\_

Завдання прийняв до виконання \_\_\_\_\_

**КАЛЕНДАРНИЙ ПЛАН**

№ п/п	Назва етапів дипломного проекту (роботи)	Термін виконання проекту (роботи)	Примітка
1.	Інформаційно-аналітичний огляд		
2.	Інформаційно-екстремальна інтелектуальна технологія		
3.	Інформаційне та програмне забезпечення системи		
4.	Оформлення кваліфікаційної роботи магістра		

Здобувач вищої освіти \_\_\_\_\_

Керівник проекту \_\_\_\_\_

## РЕФЕРАТ

**Записка:** 50 стор., 31 рис., 14 табл., 1 додатка, 58 джерел.

**Об'єкт дослідження** — процес комп'ютерного діагностування патологій ока.

**Мета роботи** — розробка інформаційної інтелектуальної технології діагностування патології ока.

**Методи дослідження** — методи аналізу і інформаційного синтезу інтелектуальних систем, методи обробки зображень, методи розпізнавання образів, методи машинного навчання, методи оцінки функціональної ефективності інтелектуальних систем.

**Результати** — розроблено інформаційну технологію діагностування патології ока за зображенням. При цьому запропоновано комплекс інформаційного, алгоритмічного та програмного забезпечення основних компонентів систем комп'ютерного діагностування патології, в тому числі і інтелектуальної складової. Основну увагу дослідження приділено методам організації вирішальних правил, що формуються в процесі навчання системи, а саме порівнянню бінарної та декурсивної ієрархічної структури класифікатору. Програмна реалізація виконана з використанням середовища для наукових і інженерних розрахунків MATLAB та спеціалізованого пакету Image Processing Toolbox.

ІНТЕЛЕКТУАЛЬНА СИСТЕМА ДІАГНОСТУВАННЯ, КРИТЕРІЙ  
ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ, НАВЧАЛЬНА МАТРИЦЯ

## ЗМІСТ

ВСТУП .....	5
1 ІНФОРМАЦІЙНО-АНАЛІТИЧНИЙ ОГЛЯД.....	7
1.1 Особливості застосування методів штучного інтелекту в офтальмології	7
1.2 Постановка задачі .....	11
2 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ .....	12
2.1 Основні положення технології .....	12
2.2 Математична модель .....	13
2.3 Алгоритмічне забезпечення системи .....	14
3 ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ .....	17
3.1 Формування вхідного математичного опису .....	17
3.2 Короткий опис програмної реалізації .....	17
3.3 Аналіз результатів фізичного моделювання .....	19
ВИСНОВКИ.....	37
СПИСОК ЛІТЕРАТУРИ.....	38
ДОДАТОК.....	45

## ВСТУП

Діагностика офтальмологічного захворювання проводиться за допомогою різних видів клінічних оглядів. Обстеження можуть бути неінвазивними, наприклад, дослідження за допомогою щілинної лампи, визначення гостроти зору, зображення очного дна (ЗОД), ультразвукове дослідження, оптична когерентна томографія (ОКТ); або інвазивні дослідження, як флюоресцеїнова ангіографія [1]. Неінвазивні клінічні обстеження легше проводити, оскільки вони не мають протипоказань, не впливають на природну реакцію ока та не залежать від зовнішніх факторів в порівнянні з інвазивними дослідженнями. Таким чином, обстеження ЗОД та ОКТ є швидкими та простими методами, які можна застосовувати для широкого кола пацієнтів. Основними перевагами таких методів є те, що зображення можна легко зберігати для подальшого аналізу, прогнозування перебігу, діагностики та спостереження за захворюваннями.

Розробка технології комп'ютеризований аналіз результатів ЗОД та ОКТ, що допомагає лікарю при діагностуванні, є завданням для фахівця з комп'ютерних наук, оскільки при цьому необхідно вирішувати задачі досягнення найкращої продуктивності системи діагностування, найнижчих обчислювальних витрат та найнижчого часу роботи [2-6]. Таким чином, вибір найкращого методу аналізу та постановки діагнозу за допомогою зображень ока є складною обчислювальною проблемою [7-11]. З іншого боку, методи інтелектуального аналізу даних були з деяким успіхом застосовані при діагностуванні захворювань очей [12-14]. Деякі дослідники вивчали, як підтвердити діагноз за допомогою різних методологій. Наприклад, імовірнісні нейронні мережи застосовувалися для аналізу кровоносних судин сітківки [2], тришарова штучна нейронна мережа та метод опорних векторів – для класифікації захворювань сітківки за зображеннями очного дна [12] та для кластеризації та класифікації діабетичної ретинопатії [3].

Метою цієї роботи є адаптація інформаційно-екстремальної інтелектуальної технології з урахуванням особливостей аналізу зображень ока, що дозволить проводити діагностування атрофії зорового нерву, глаукоми, відшарування сітківки, невриту зорового нерву та пігментного ретиніту. Частина цих захворювань пов'язані з цукровим діабетом, вони є основною причиною сліпоти в усьому світі в працездатному віці (20-69 років), з основною проблемою, що 25% діабетиків у всьому світі будуть мати проблеми із зором. поряд із цукровим діабетом, і без своєчасної профілактичної діагностики та лікування ці суб'єкти будуть страждати необоротною сліпотою [15-20]. Перший розділ роботи містить огляд методів діагностування очних захворювань з використанням технологій штучного інтелекту, розпізнавання образів та машинного навчання. В другому розглядаються основні моделі інформаційно-екстремальної інтелектуальної технології та їх модифікації, критерії оцінювання якості сформованих класифікаторів та алгоритми оптимізації їх параметрів. В третьому розділі, сформовано навчальну матрицю для п'яти класів захворювань і одного класу здорового ока. Крім того цей розділ містить короткий опис програмної реалізації запропонованих алгоритмів та результати їх застосування до сформованої навчальної матриці.

# 1 ІНФОРМАЦІЙНО-АНАЛІТИЧНИЙ ОГЛЯД

## 1.1 Особливості застосування методів штучного інтелекту в офтальмології

Оскільки старіння населення стало основною демографічною тенденцією в усьому світі, очікується, що кількість пацієнтів, які страждають на захворювання очей, стрімко зросте. Раннє виявлення та відповідне лікування очних захворювань мають велике значення для запобігання втрати зору та покращення якості життя. Звичайні методи діагностики значною мірою залежать від професійного досвіду та знань лікарів, що призводить до високої частоти помилкових діагнозів та величезної втрати медичних даних. Глибока інтеграція офтальмології та штучного інтелекту (ШІ) може змінити поточну схему діагностики захворювань.

Запропонований у 1956 році Дартмутським вченим Джоном Маккарті, ШІ є загальним терміном, який «позначає апаратне чи програмне забезпечення, яке демонструє поведінку, яка виглядає розумною» [21]. Хоча це сталося шістдесят років тому, донедавна ефективність ШІ підкреслювалася завдяки розробці нових алгоритмів, спеціалізованого обладнання, хмарних сервісів і великих даних. Машинне навчання (МН), що виникло в 1980-х роках, є підрозділом ШІ, і визначається як набір методів, які автоматично виявляють закономірності в даних, а потім включають цю інформацію для прогнозування майбутніх даних за невизначених умов. Глибоке навчання (ГН), що виникло в 2000-х роках, є технологією машинного навчання, що розвивається, і здійснила революцію у світі ШІ. Ці технології керують багатьма аспектами сучасного суспільства, такими як розпізнавання об'єктів на зображеннях, переклад мов у реальному часі, керування пристроями за допомогою мовлення (наприклад, Apple Siri, Amazon Alexa і Microsoft Cortana) тощо.

Протягом останніх років сфера охорони здоров'я була авангардом застосування ШІ. Численні дослідження показали, що алгоритми ГН працюють на високому рівні при застосуванні до гістопатологічного аналізу молочної залози [22], класифікації раку шкіри [23], прогнозу ризику серцево-

судинних захворювань [24] та виявлення раку легенів [25]. Ці вражаючі дослідження надихають численні дослідження щодо застосування ШІ в офтальмології. Розширені алгоритми ШІ разом із кількома доступними наборами даних, такими як EyePACS [26], Messidor [26] та набір даних Kaggle [27], можуть зробити прорив у різних офтальмологічних проблемах.

Стрімке зростання технологій штучного інтелекту вимагає від лікарів і комп'ютерних спеціалістів гарного взаємного розуміння не лише технології, а й медичної практики для покращення медичної допомоги в найближчому майбутньому. В існуючих аналітичних оглядах технології штучного інтелекту в офтальмології можна знайти як опис звичайних методів машинного навчання та розглянули їх застосування для діагностики та моніторингу мультимодальних очних захворювань [28], так і детально подані різні методи ГН для різних завдань і з дослідженнями кожної області застосування [29]. При цьому частина таких оглядів описує розвиток ШІ в офтальмології загалом [30], тоді як інша зосереджується на застосуванні ГН в області офтальмології [31] або аналізує ШІ та ГН одночасно в різних категоріях діагностування та профілактики захворювань очей [32].

Як ми згадували вище, МН є однією з підмножин ШІ і включає ГЛ та класичні методи машинного навчання (рис. 1.1). Визначальною характеристикою алгоритмів МН є висока функціональна ефективність, що здатна підвищуватися з часом [33]. Чим більше даних ми надаємо, тим більш точну класифікаційну модель можна побудувати.

Навчання з учителем і навчання без учителя є двома формами МН. Навчання з учителем полягає у відтворенні класифікатора на основі навчальних даних, для кожної реалізації яких апріорно відома її належності до одного з класів розпізнавання. При цьому навчання полягає в такому налаштуванні параметрів класифікатора, що дозволяє максимізувати його точність розпізнавання навчальних реалізацій. Після навчання замість навчальних реалізацій використовують екзаменаційні, для яких апріорна належність до класів розпізнавання не відома, а визначається сформованим раніше



класифікатором. Це може прискорити процес діагностування відомих захворювань за результатами клінічних аналізів.



Рисунок 1.1 – Взаємозв'язок між ШІ, МН і ГН.

Навчання без учителя полягає також у формуванні класифікатора, але належність реалізацій вхідних даних апріорно не відома. При цьому в процесі навчання не тільки оптимізуються параметри класифікатора, але і визначається потужність алфавіту класів розпізнавання. Така форма навчання дозволяє знаходити приховані взаємозв'язки між реалізаціями, які зазвичай не усвідомлюються людиною-лікарем, що може призвести до відкриття нових видів захворювань, наприклад нової енцефальної області, що пов'язана з хворобою Альцгеймера [34] або нових факторів впливу серцево-судинних захворювань до когнітивні функції людини [24]. Поки що в офтальмології більшість комп'ютеризованих систем діагностування використовують методи МН, що навчаються з учителем [35].

За допомогою класичних методів навчання можна отримати задовільний результат з невеликими наборами даних, але для цього необхідно провести якісний відбір релевантних ознак, за якими буде проводитися класифікація [36].

Класичні методи навчання, що використовуються в діагностиці, включають метод дерева рішень [37], метод випадкових лісів [38], метод опорних векторів [39], байєсівські класифікатори [40], метод k-найближчих сусідів [41], метод k-середніх [42], методи лінійного дискримінантного аналізу [43] та нейронні мережі [44]. Серед них метод випадкових лісів і метод опорних векторів найбільш часто використовується в області офтальмології [45].

ГН, як технологія МН, має можливість виявляти складні структури в наборах даних без необхідності чітко вказувати правила. Мережа ГН — це нейронна мережа з кількома прошарками між вхідним і вихідним прошарком [35]. У застосуванні до класифікації зображень ключовою відмінністю між методами ГН та класичними методами є те, як вони обробляють вхідні дані, особливо у вигляді зображення. Алгоритми ГН автоматично вивчають особливості вхідних даних без учителя, уникаючи ручного сегментування або відбору релевантних ознак [35, 46]. Однак для навчання алгоритму ГН потрібен великий набір даних. Трансферне навчання – це перенавчання класифікатору, який вже був попередньо навчений на мільйонах загальних зображень, на певному наборі даних. Цей метод дозволяє доформувати високоточний класифікатор з відносно невеликим набором навчальних даних [47].

Методи ГН відомі як «чорні ящики». Мережі створюють всеосяжні та дискримінаційні ознаки, які є занадто великими, щоб бути доступними для людської інтерпретації. Мало відомо про те, як вони аналізують вхідні дані і приймають рішення на рівні зображення [27]. Існуючі методи ГН включають довгострокову та короткочасну пам'ять [35], глибокі машини Больцмана [48], машини глибокого ядра [49], глибокі рекурентні нейронні мережі [50] та згорткові нейронні мережі (ЗНМ) [35]. Серед них найбільш використовуваним методом ГН в області розпізнавання медичних зображень є ЗНМ. ЗНМ складається з кількох згорткових прошарків, які перетворюють вхідні зображення в ієрархічні карти об'єктів: від простих об'єктів, таких як лінії, до

складних об'єктів, таких як форми та кольори. ЗНМ також включає прошарки, які можуть об'єднувати семантично подібні ознаки в одну. На виході ЗНМ формує вектор ймовірностей належності вхідної реалізації до кожного з класів розпізнавання. Існуючі архітектури ЗНМ, що використовуються в області розпізнавання медичних зображень, включають AlexNet [51], VGG [52], ResNet [53] та GoogleNet [54–57].

## **1.2 Постановка задачі**

Результати проведеного аналітичного огляду доводять актуальність практичної задачі розробки інформаційної інтелектуальної технології діагностування патології ока. При цьому перспективним вважається об'єднання декількох підходів до аналізу і синтезу класифікаторів, що формуються в процесі навчання. Для досягнення поставленої мети в роботі запропоновано використання інформаційно-екстремальної інтелектуальної технології машинного навчання та розпізнавання образів.

При цьому основні завдання роботи включають:

- 1) Формування вхідного математичного опису інтелектуальної системи діагностування патологій ока (ІСДПА)
- 2) Розробка математичної моделі навчання ІСДПА.
- 3) Вибір критерію функціональної ефективності параметрів ІСДПА.
- 4) Розробка та програмна реалізація алгоритмів навчання ІСДПА.
- 5) Перевірка працездатності ІСДПА на задачі розпізнавання шести функціональних станів ока.

## 2 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ

### 2.1 Основні положення технології

Інформаційно-екстремальна інтелектуальна технологія (ІЕІТ) використовує непараметричні методи проектування інформаційно-аналітичних систем, що здатні навчатися. В процесі навчання за ІЕІТ виконується безпосередня оцінка інформаційної здатності системи формувати класифікатор за умов значного перетину класів в просторі ознак розпізнавання та обмежених за обсягом навчальних вибірок.

З базовими визначеннями, до яких відносяться

- клас розпізнавання  $X_m^o$ ,
- алфавіт класів розпізнавання  $\{X_m^o \mid m = \overline{1, M}\}$ ,
- простір ознак розпізнавання  $\Omega$ ,
- простір бінеаризованих ознак розпізнавання  $\Omega_b$ ,
- система нормованих допусків  $\{\delta_{h,i} \mid i = \overline{1, N}\}$  на ознаки розпізнавання,
- система контрольних допусків (СКД)  $\{\delta_{k,i} \mid i = \overline{1, N}\}$  на ознаки розпізнавання,
- реалізація образу  $x_m^{(j)} \in X_m^o$   $m$ -ного класу розпізнавання,
- навчальна матриця  $\|y_{m,i}^{(j)} \mid i = \overline{1, N}, j = \overline{1, n}\|$ ,
- гіперсферичний контейнер класу розпізнавання, що визначається:
  - еталонний вектор (ЕВ)  $x_m$   $m$ -ного класу розпізнавання, який визначає центр контейнера класу розпізнавання  $X_m^o$ ,
  - радіус  $d_m$  контейнера класу розпізнавання  $X_m^o$ ,

можна ознайомитися в моїй кваліфікаційній роботі бакалавра [58].

Проте в цій роботі буде використано модифікований вектор параметрів функціонування

$$g_{h,s} = \langle x_{h,s,m_s}, d_{h,s,m_s}, \delta_{h,s} \rangle, \quad (2.1)$$

де  $x_{h,s,m_s}$  – еталонний вектор класу розпізнавання  $X_{h,s,m_s}^o$  ;

$\delta_{h,s}$  – параметр поля контрольних допусків на ознаки розпізнавання;

$d_{h,s,m_s}$  – радіус контейнера класу розпізнавання  $X_{h,s,m_s}^o$  ;

$h, s$  – індекси, що дозволяють оперувати функціональними параметрами при використанні ієрархічних структур контейнерів, а саме рівнем ієрархії і стратою;

При цьому мета навчання залишається не змінною – «оптимізувати (тут і далі в інформаційному розумінні) значення координат вектора (2.1) параметрів функціонування, які забезпечують максимальне усереднене за алфавітом  $\{X_m^o\}$  значення інформаційного КФЕ, обчислене в робочій (допустимій) області визначення функції критерію оптимізації» [58]:

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{\langle \{k\} \rangle} E_m, \quad (2.2)$$

де  $E_m$  – інформаційний КФЕ, що оцінює здатність розпізнавати реалізації класу  $X_m^o$  ;

$\langle \{k\} \rangle$  – впорядкована множина кроків навчання.

## 2.2 Математична модель

Модифікуємо базову категорійну модель інформаційно-екстремального навчання за ІЕІТ [58] (рис. 2.1) шляхом додавання елементів діаграми відображення множин, що дозволять в процесі машинного навчання формувати ієрархічні структури контейнерів класів та оптимізувати їх параметри.




Рисунок 2.1 – Категорійна модель інформаційно-екстремального навчання

Згідно (рис. 2.1) до базової категорійної моделі [58] додається множина  $H$ , яка відповідає за відтворення класифікатору у ієрархічній формі. При цьому інші елементи моделі, за виключенням навчальної матриці  $Y$  та її бінеаризованої форми  $X$  залишаються без змін. Модифіковані  $Y^{|S|}$  та  $X^{|S|}$  формуються операторами  $g$  та  $f_1$  в залежності від індексу страти  $s$ , параметри якої оптимізуються в поточний момент навчання.

На відміну від [53] в цій роботі як КФЕ буде використано інформаційну міру Кульбака.

$$E^{(k)} = \log_2 \left( \frac{2 - (\alpha^{(k)} + \beta^{(k)}) + 10^{-r}}{\alpha^{(k)} + \beta^{(k)} + 10^{-r}} \right) * [2 - (\alpha^{(k)} + \beta^{(k)})]. \quad (2.3)$$

де  $\alpha^{(k)}$ ,  $\beta^{(k)}$  - помилки першого та другого роду,  $D_1^{(k)}$ ,  $D_2^{(k)}$  перша та друга достовірності,  $k$  – крок навчання,  $r$  – константа, яка дорівнює 0,01.

### 2.3 Алгоритмічне забезпечення системи

Базові алгоритми інформаційно-екстремального навчання за ІЕІТ, що включають алгоритми оптимізації геометричних параметрів контейнерів класів розпізнавання (LEARNING) та системи контрольних допусків (паралельний (LEARNING 2), послідовний (LEARNING 1) та паралельно-

послідовний варіант (LEARNING 2-1)), наведено в праці [58]. Розглянемо основні алгоритми формування ієрархічних класифікаторів за ІЕІТ (рис. 2.2).

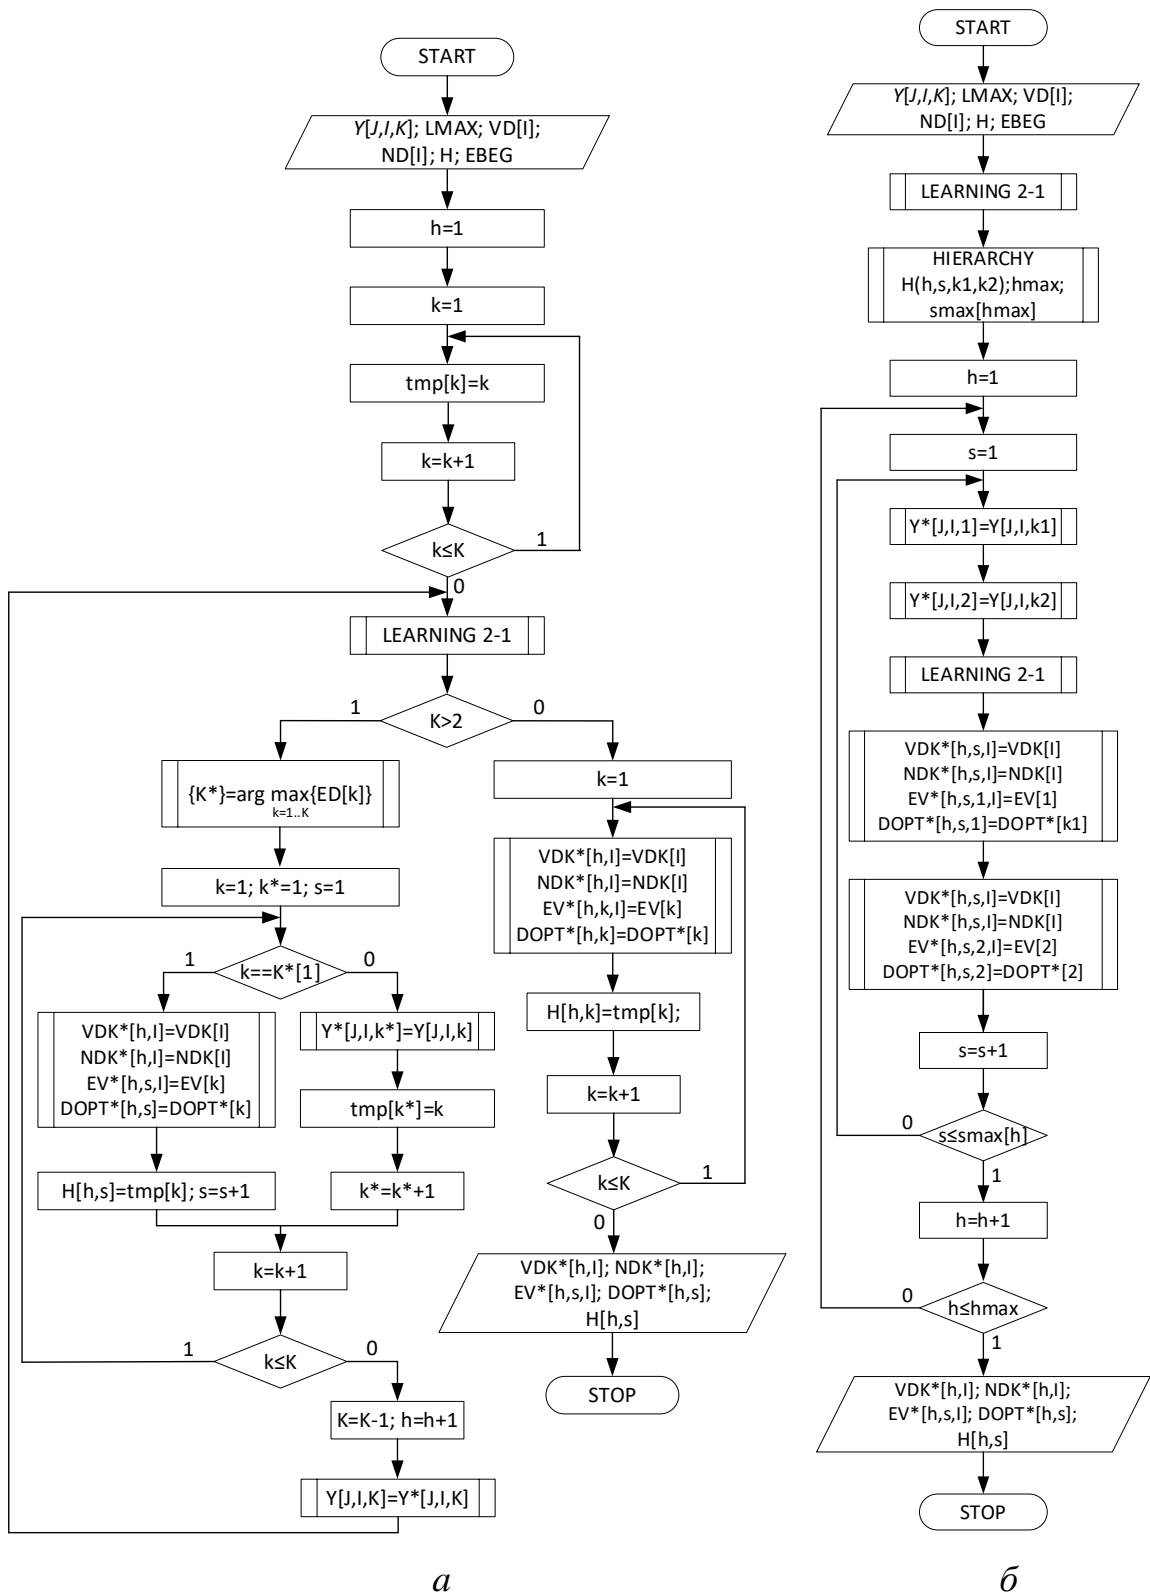


Рисунок 2.2 – Блок-схеми формування ієрархічних класифікаторів: а) бінарна та б) декурсивна структура

Алгоритм формування бінарної ієрархічної структури класифікатору (рис. 2.2 а) покроково зменшує потужність алфавіту класів, формуючи на кожному рівні ієрархії по одному вирішальному правилу. Навчальна матриця класу, для якого було сформовано вирішальне правило на рівні  $h$ , не приймає участь у навчанні на рівнях  $h+1$ ,  $h+2$ , ... В результаті роботи алгоритму формується набір оптимальних функціональних параметрів для кожного рівня ієрархії, що включає оптимальні геометричні параметри контейнерів класів та оптимальну СКД. На останньому рівні відтворюються контейнери двох класів.

Модифікація запропонованого алгоритму полягає в тому, що на кожному рівні можна формувати вирішальні правила не одного а декількох класів за умови їх безпомилковості за навчальною матрицею. Така модифікація дозволяє підвищити оперативність формування ієрархії і її використання на етапі екзамену.

Алгоритм формування декурсивної ієрархічної структури класифікатору (рис. 2.2 б) базується на аналізі еталонних векторів класів, що були упорядковані за збільшенням кодової відстані від нульового двійкового вектору та поділу класів на дві приблизно рівні групи, що визначають дві гілки декурсивної структури. Для першого (верхнього за дендрографічною класифікацією) рівня структури вирішальні правила формуються за навчальними матрицями класів розпізнавання різних груп, еталонні вектори яких знаходяться на найближчій відстані. На нижньому рівні структури вирішальні правила формуються для класу з верхнього ярусу і іншого класу тієї ж групи, еталонні вектори яких знаходяться на найближчій відстані. Таким чином, кожний клас двічі приймає участь в навчанні. Основною відмінністю даного алгоритму від попереднього є те, що декурсивна ієрархічна структура створюється на початку роботи алгоритму в блоці HIERARCHY, а не формується поступово в ході навчання.



## 3 ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ

### 3.1 Формування вхідного математичного опису

Навчальна вибірка кожного класу подана у вигляді матриці розмірністю 200 ознак розпізнавання на 200 реалізацій. Значення кожної ознаки відповідало яскравості пікселів зображення і змінювалося в межах від 0 до 255.




Рисунок 3.1 – Графічне відображення навчальних матриць: а) «нормальний стан ока», б) «атрофія зорового нерву», в) «відшарування сітківки», г) «глаукома», д) «неврит зорового нерву», е) «пігментний ретиніт»

Таким чином, навчальна матриця мала такі параметри: кількість класів  $m=6$ , кількість ознак  $N = 200$ , кількість реалізацій  $n = 200$ . При цьому верхній нормований допуск для всіх ознак дорівнював 255, а нижній – 0.

### 3.2 Короткий опис програмної реалізації

Для програмної реалізації застосовувалося програмне середовище MATLAB. MATLAB - це обчислювальне середовище з багато парадигмою. Власна мова програмування, розроблена MathWorks, MATLAB дозволяє використовувати матричні маніпуляції, побудову графіків функцій та даних,

реалізацію алгоритмів, створення інтерфейсів користувача та взаємодію з програмами, написаними іншими мовами, включаючи C, C ++, C #, Java, FORTRAN та Python.

Система MATLAB складається з п'яти основних частин:

**Мова MATLAB.** Це мова матриць і масивів високого рівня з керуванням потоками, функціями, структурами даних, введенням-виведенням і особливостями об'єктно-орієнтованого програмування. Це дозволяє як програмувати в "невеликому масштабі" для швидкого створення чорнових програм, так і в "великому" для створення великих і складних додатків.

**Середовище MATLAB.** Це набір інструментів і пристосувань, з якими працює користувач або програміст MATLAB. Вона включає в себе кошти для управління змінними в робочому просторі MATLAB, введенням і виведенням даних, а також створення, контролю і налагодження М-файлів і додатком MATLAB.

**Керована графіка.** Це графічна система MATLAB, яка включає в себе команди високого рівня для візуалізації дво- і тривимірних даних, обробки зображень, анімації та ілюстрованої графіки. Вона також включає в себе команди низького рівня, що дозволяють повністю редагувати зовнішній вигляд графіки, також як при створенні Графічного призначеного для користувача інтерфейсу (GUI) для MATLAB додатків.

**Бібліотека математичних функцій.** Це велика колекція обчислювальних алгоритмів від елементарних функцій, таких як сума, синус, косинус, комплексна арифметика, до більш складних, таких як звернення матриць, знаходження власних значень, функції Бесселя, швидке перетворення Фур'є.

**Програмний інтерфейс.** Це бібліотека, яка дозволяє писати програми на C і Фортране, які взаємодіють з MATLAB. Вона включає засоби для виклику програм з MATLAB (динамічна зв'язок), викликаючи MATLAB як обчислювальний інструмент і для читання-запису MAT-файлів.

В ході роботи були використані наступні константи та змінні:

Таблиця 3.1 – Змінні та константи

<code>kvo_klassov = 3</code>	Кількість класів розпізнавання
<code>n = 100</code>	Кількість ознак розпізнавання
<code>N = 100</code>	Кількість реалізацій
<code>n_dopusk</code>	Нижній допуск
<code>v_dopusk</code>	Верхній допуск
<code>Y, SZ</code>	Масив навчальних матриць та бінарних навчальних матриць
<code>EV</code>	Масив еталонних векторів
<code>sk1, sk2</code>	Масив кодових відстаней від еталонного вектору до реалізацій
<code>D1, D2, alfa, betta</code>	Значення точносних характеристик та КФЕ при оптимальних параметрах навчання
<code>D</code>	Оптимальні радіуси контейнерів класів навчання
<code>E</code>	Критерій за Кульбаком
<code>VD, ND: array [1..n] of integer;</code>	Система допусків на значення ознак розпізнавання
<code>i, k, k1</code>	Лічильники
<code>rab_oblast</code>	Робоча область

Програмний код наведено в Додатку

### 3.3 Аналіз результатів фізичного моделювання

Для початкового алфавіту класів розпізнавання було сформовано лінійний класифікатор. При цьому застосовувалися алгоритми паралельної оптимізації СКД (рис. 3.2) і оптимізації геометричних параметрів вирішальних правил (рис. 3.3).





Рисунок 3.2 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.2 показує, що максимальне значення усередненого КФЕ було досягнуто на 116 кроці і склало 1,47144. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.3.






Рисунок 3.3 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_1^0$ ; б)  $X_2^0$ ; в)  $X_3^0$ ; г)  $X_4^0$ ; д)  $X_5^0$ ; е)  $X_6^0$ .

Результати аналізу рис. 3.3 наведено в табл. 3.2.

Таблиця 3.2 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_1^0$	0,98129	17	0,59	0,01
$X_2^0$	2,51895	3	0,88	0,03
$X_3^0$	0,59129	30	0,52	0,06
$X_4^0$	0,90729	32	0,57	0,01
$X_5^0$	1,62710	8	0,72	0
$X_6^0$	2,20275	16	0,81	0

Для підвищення ефективності системи було застосовувано алгоритми послідовної оптимізації СКД (рис. 3.4) і оптимізації геометричних параметрів вирішальних правил (рис. 3.5).




Рисунок 3.4 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.4 показує, що максимальне значення усередненого КФЕ було досягнуто на 600 кроці і склало 2,60858. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.5.

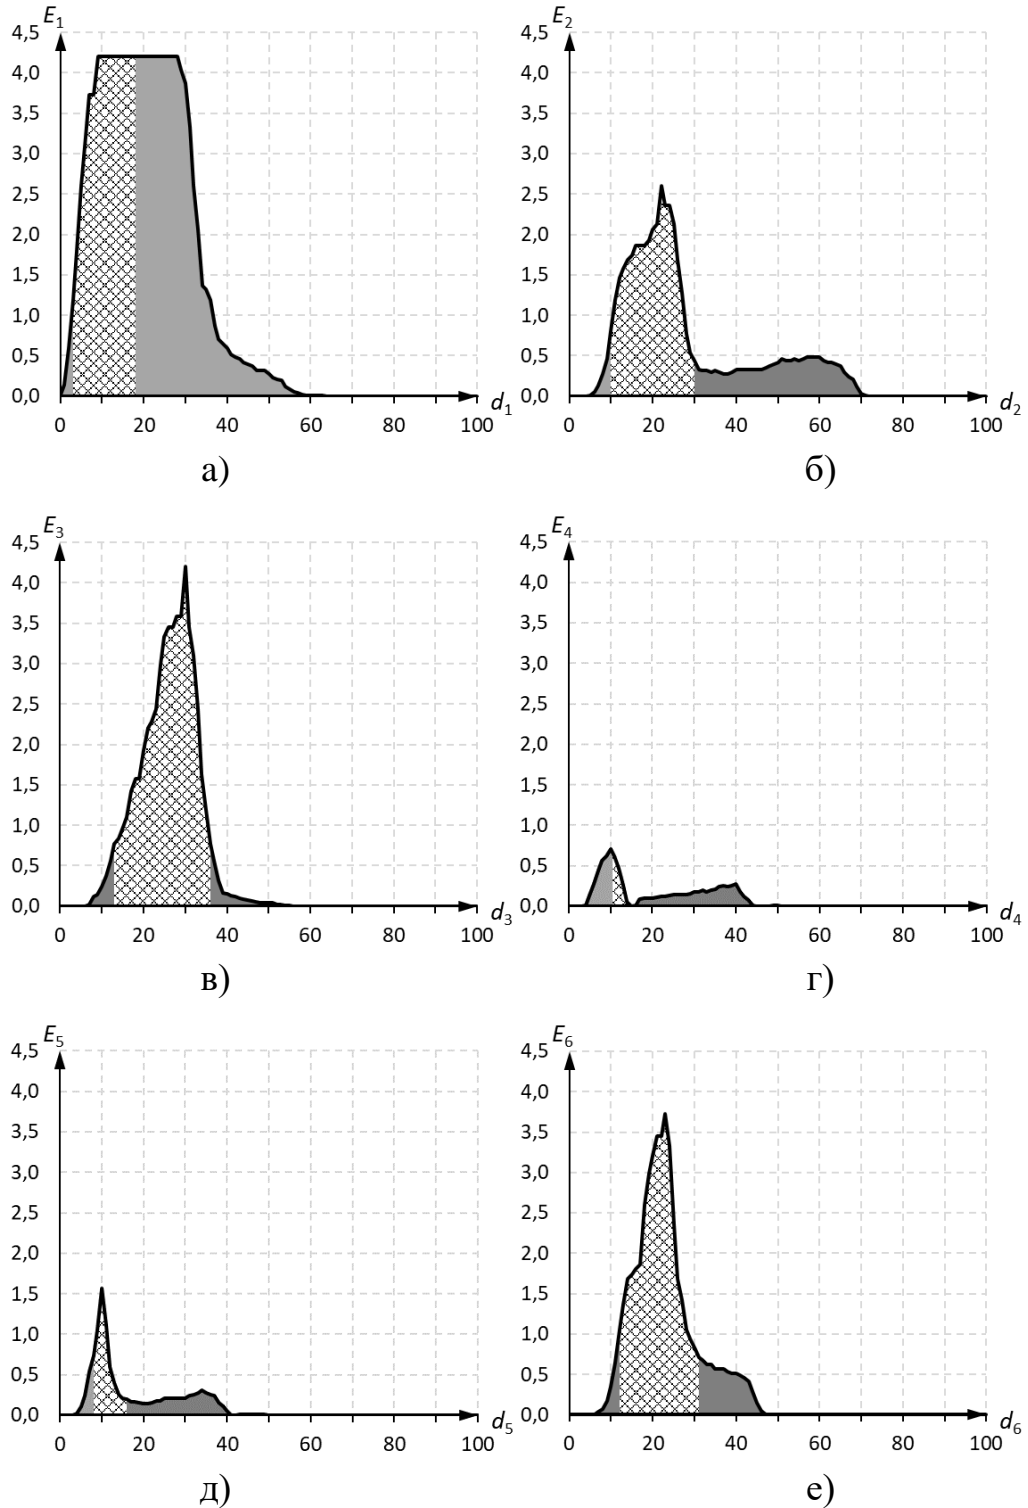


Рисунок 3.5 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_1^0$ ; б)  $X_2^0$ ; в)  $X_3^0$ ; г)  $X_4^0$ ; д)  $X_5^0$ ; е)  $X_6^0$ .

Результати аналізу рис. 3.5 наведено в табл. 3.3.

Таблиця 3.3 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_1^0$	4.39232	28	1	0
$X_2^0$	2.60558	22	0,86	0
$X_3^0$	4.39232	30	1	0
$X_4^0$	0.70752	10	0,51	0,01
$X_5^0$	1.57226	10	0,72	0,01
$X_6^0$	3.72398	23	0,96	0

Для підвищення ефективності системи було застосовано ієрархічну структуру вирішальних правил та перенавчено систему. На першому рівні ієрархії залишимо класи  $X_1^0$  та  $X_3^0$ , для яких було сформовано безпомилкові за навчальною матрицею вирішальні правила. Всі інші класи перенесено на другий рівень ієрархії. Для оптимізації на цьому рівні застосовувалися алгоритми послідовної оптимізації СКД (рис. 3.6) і оптимізації геометричних параметрів вирішальних правил (рис. 3.7).




Рисунок 3.6 – Графік залежності усередненого КФЕ від ширини поля допусків другого рівня ієрархії

Аналіз рис. 3.6 показує, що для другого рівня ієрархії максимальне значення усередненого КФЕ було досягнуто на 800 кроці і склало 3.79821. Результати оптимізації геометричних параметрів подано на рис. 3.7.

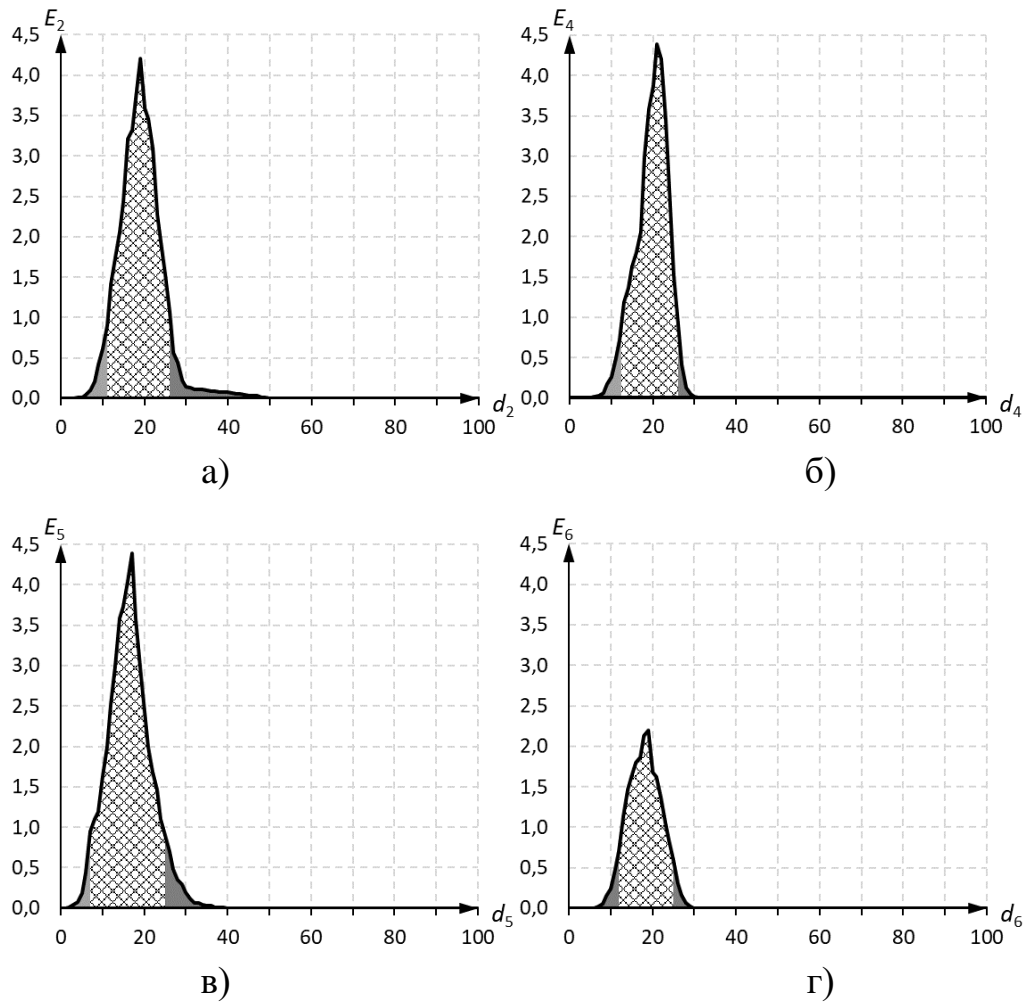


Рисунок 3.7 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_2^0$ ; б)  $X_4^0$ ; в)  $X_5^0$ ; г)  $X_6^0$ .

Результати аналізу рис. 3.7 наведено в табл. 3.4.

Таблиця 3.4 – Результати навчання

Клас	Рівень ієрархії	КФЕ	Радіус	$D_1$	$\beta$
$X_1^0$	I	4.39232	28	1	0
$X_3^0$		4.39232	30	1	0
$X_2^0$	II	4.20545	19	0,99	0
$X_4^0$		4.39232	21	1	0
$X_5^0$		4.39232	17	1	0
$X_6^0$		2.20275	19	0,81	0



Для підвищення ефективності системи на другому рівні ієрархії залишимо класи  $X_4^0$  та  $X_5^0$ , для яких було сформовано безпомилкові за навчальною матрицею вирішальні правила. Всі інші класи перенесено на третій рівень ієрархії. Для оптимізації на цьому рівні застосовувалися алгоритми послідовної оптимізації СКД (рис. 3.8) і оптимізації геометричних параметрів вирішальних правил (рис. 3.9).




Рисунок 3.8 – Графік залежності усередненого КФЕ від ширини поля допусків третього рівня ієрархії

Аналіз рис. 3.8 показує, що для третього рівня ієрархії максимальне значення усередненого КФЕ було досягнуто на 269 кроці і склало 4,39232. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.9.




Рисунок 3.9 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_2^0$ ; б)  $X_6^0$ .

Результати аналізу рис. 3.9 наведено в табл. 3.5.

Таблиця 3.5 – Результати навчання

Клас	Рівень ієрархії	КФЕ	Радіус	$D_1$	$\beta$
$X_1^o$	I	4.39232	28	1	0
$X_3^o$		4.39232	30	1	0
$X_4^o$	II	4.39232	21	1	0
$X_5^o$		4.39232	17	1	0
$X_2^o$	III	4.39232	3	1	0
$X_6^o$		4.39232	10	1	0

Таким чином, сформовані класифікатори, у вигляді трирівневої ієрархії (рис. 3.10) є безпомилковими за навчальною матрицею.




Рисунок 3.10 – Трирівнева ієрархія

Для підвищення ефективності системи було застосовано ієрархічну структуру декурсивного типу та перенавчено систему. Для чого було проаналізовано результати застосування алгоритму послідовної оптимізації СКД (рис. 3.4) і оптимізації геометричних параметрів вирішальних правил (рис. 3.5).

Таблиця 3.6 – Результати навчання

Клас	Відстань від нульового вектору	Клас - сусід	Відстань до класу сусіда
$X_1^o$	15	$X_3^o$	40
$X_2^o$	79	$X_4^o$	30
$X_3^o$	37	$X_5^o$	31
$X_4^o$	59	$X_5^o$	11
$X_5^o$	54	$X_4^o$	11
$X_6^o$	62	$X_4^o$	27




Рисунок 3.11 – Графічне відображення табл. 3.6




Рисунок 3.12 – Трирівнева ієрархічну структуру декурсивного типу

Для початкового алфавіту класів розпізнавання було сформовано

класифікатор для класів першого рівня ієрархії  $X_4^0$  та  $X_5^0$ . При цьому застосовувалися алгоритми паралельної оптимізації СКД (рис. 3.13) і оптимізації геометричних параметрів вирішальних правил (рис. 3.14).




Рисунок 3.13 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.13 показує, що максимальне значення усередненого КФЕ було досягнуто на 10 кроці і склало 2,73952. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.14.




Рисунок 3.14 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_4^0$ ; б)  $X_5^0$

Результати аналізу рис. 3.14 наведено в табл. 3.7.

Таблиця 3.7 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_4^0$	4.39232	28	1	0
$X_5^0$	1.27358	27	0,97	0.32

Для підвищення ефективності системи було застосовувано алгоритми послідовної оптимізації СКД (рис. 3.15) і оптимізації геометричних параметрів вирішальних правил (рис. 3.16).




Рисунок 3.15 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.15 показує, що максимальне значення усередненого КФЕ було досягнуто на 400 кроці і склало 3,06619. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.16.




Рисунок 3.16 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_4^0$ ; б)  $X_5^0$ .

Результати аналізу рис. 3.16 наведено в табл. 3.8.

Таблиця 3.8 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_4^0$	4.39232	24	1	0
$X_5^0$	1.92693	21	0,99	0,22

Для початкового алфавіту класів розпізнавання було сформовано класифікатор для класів другого рівня ієрархії  $X_3^0$  та  $X_5^0$ . При цьому застосовувалися алгоритми паралельної оптимізації СКД (рис. 3.17) і оптимізації геометричних параметрів вирішальних правил (рис. 3.18).





Рисунок 3.17 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.17 показує, що максимальне значення усередненого КФЕ було досягнуто на 92 кроці і склало 3,36220. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.18.

Рисунок 3.18 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_3^0$ ; б)  $X_5^0$

Результати аналізу рис. 3.18 наведено в табл. 3.9.

Таблиця 3.9 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_3^0$	4.39232	63	1	0
$X_5^0$	2.51895	44	0,86	0.01

Для підвищення ефективності системи було застосовувано алгоритми послідовної оптимізації СКД (рис. 3.19) і оптимізації геометричних параметрів вирішальних правил (рис. 3.20).




Рисунок 3.19 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.19 показує, що максимальне значення усередненого КФЕ було досягнуто на 800 кроці і склало 4,20545. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.20.




Рисунок 3.20 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_3^0$ ; б)  $X_5^0$ .

Результати аналізу рис. 3.20 наведено в табл. 3.10.

Таблиця 3.10 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_3^0$	4.39232	38	1	0
$X_5^0$	4.39232	34	1	0

Для початкового алфавіту класів розпізнавання було сформовано класифікатор для класів другого рівня ієрархії  $X_4^0$  та  $X_6^0$ . При цьому застосовувалися алгоритми паралельної оптимізації СКД (рис. 3.21) і оптимізації геометричних параметрів вирішальних правил (рис. 3.22).




Рисунок 3.21 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.21 показує, що максимальне значення усередненого КФЕ було досягнуто на 47 кроці і склало 3,13290. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.22




Рисунок 3.22 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_4^0$ ; б)  $X_6^0$



Результати аналізу рис. 3.22 наведено в табл. 3.11.

Таблиця 3.11 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_4^0$	4.39232	45	1	0
$X_6^0$	2.06036	10	0,79	0

Для підвищення ефективності системи було застосовувано алгоритми послідовної оптимізації СКД (рис. 3.23) і оптимізації геометричних параметрів вирішальних правил (рис. 3.24).




Рисунок 3.23 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.23 показує, що максимальне значення усередненого КФЕ було досягнуто на 400 кроці і склало 3,13290. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.24.




Рисунок 3.24 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_4^0$ ; б)  $X_6^0$ .

Результати аналізу рис. 3.24 наведено в табл. 3.12.

Таблиця 3.12 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_4^0$	4.39232	12	1	0
$X_6^0$	2.06036	13	0.79	0

Для початкового алфавіту класів розпізнавання було сформовано класифікатор для класів третього рівня ієрархії  $X_1^0$  та  $X_3^0$ . При цьому застосовувалися алгоритми паралельної оптимізації СКД (рис. 3.25) і оптимізації геометричних параметрів вирішальних правил (рис. 3.26).



Рисунок 3.25 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.25 показує, що максимальне значення усередненого КФЕ було досягнуто на 11 кроці і склало 4,20545. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.26.




Рисунок 3.26 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_1^0$ ; б)  $X_3^0$

Результати аналізу рис. 3.26 наведено в табл. 3.13.

Таблиця 3.13 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_1^0$	4.39232	75	1	0
$X_3^0$	4.39232	42	1	0

Для початкового алфавіту класів розпізнавання було сформовано класифікатор для класів третього рівня ієрархії  $X_2^0$  та  $X_6^0$ . При цьому застосовувалися алгоритми паралельної оптимізації СКД (рис. 3.27) і оптимізації геометричних параметрів вирішальних правил (рис. 3.28).




Рисунок 3.27 – Графік залежності усередненого КФЕ від ширини поля допусків

Аналіз рис. 3.28 показує, що максимальне значення усередненого КФЕ було досягнуто на 2 кроці і склало 3,79862. Результати оптимізації геометричних параметрів за такої СКД подано на рис. 3.29.




Рисунок 3.29 – Графік залежності КФЕ від радіусів роздільних вирішальних правил класів: а)  $X_2^0$ ; б)  $X_6^0$

Результати аналізу рис. 3.29 наведено в табл. 3.14.

Таблиця 3.14 – Результати навчання

Клас	КФЕ	Радіус	$D_1$	$\beta$
$X_2^0$	4.39232	3	1	0
$X_6^0$	4.39232	10	1	0

Порівняльний аналіз результатів навчання інтелектуальної системи діагностування, що використовує бінарну та декурсивну ієрархічну структуру вирішальних правил доводить їх ефективність в задачі класифікації шести функціональних станів ока за зображенням. Кожна з цих структур дозволяє сформувати безпомилковий за навчальною матрицею класифікатор.

## ВИСНОВКИ

В кваліфікаційній магістерській роботі було розв'язано практичну задачу розробки інформаційної інтелектуальної технології діагностування патології ока. Для досягнення поставленої мети були використані та адаптовані до задачі діагностування методи інформаційно-екстремальної інтелектуальної технології машинного навчання та розпізнавання образів,.

При цьому було виконано такі основні завдання:

- 1) Сформовано вхідний математичний опис інтелектуальної системи діагностування патологій ока (ІСДПА)
- 2) Розроблено математичні моделі навчання ІСДПА, що включали додаткові контури оптимізації ієрархічної структури вирішальних правил.
- 3) Як критерію функціональної ефективності параметрів ІСДПА обрано інформаційну міру Кульбака.
- 4) Розроблено алгоритми оптимізації геометричних параметрів вирішальних правил, системи контрольних допусків на ознаки розпізнавання, ієрархічної структури вирішальних правил
- 5) Програмна реалізація алгоритмів навчання ІСДПА виконана в середовищі для наукових і інженерних розрахунків MATLAB.
- 6) В ході перевірки працездатності на задачі розпізнавання шести функціональних станів ока ІСДПА вдалося побудувати два варіанта ієрархічної структури вирішальних правил, що відтворюють безпомилковий за навчальною матрицею класифікатор.

## СПИСОК ЛІТЕРАТУРИ

1. Stitt W. Advances in Our Understanding of Diabetic Retinopathy / W. Stitt, N. Lois, R. J. Medina, P. Adamson, and T. M. Curtis // *Clinical Science*, 2013. – №. 1(125). – pp. 1-17.
2. Gurudath N. Machine Learning Identification of Diabetic Retinopathy from Fundus Images / N. Gurudath, M. Celenk, H. B. Riley // *IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*, 2014. – pp. 1-7.
3. Priyadarshini R. A Novel Approach to Predict Diabetes Mellitus Using Modified Extreme Learning Machine / R. Priyadarshini, N. Dash, R. Mishra // *International Conference on Electronics and Communication Systems (ICECS)*, 2014. – pp. 1-5.
4. Quellec G. Automated Assessment of Diabetic Retinopathy Severity Using Content-Based Image Retrieval in Multimodal Fundus Photographs / G. Quellec et al. // *Investigative Ophthalmology & Visual Science*, 2011. – № 11(52). – pp. 8342-8348.
5. Welikalaa R.A. Automated Detection of Proliferative Diabetic Retinopathy Using a Modified Line Operator and Dual Classification / R.A. Welikalaa et al. // *Computer Methods and Programs in Biomedicine*. 2014. – № 3(114). – pp. 247-261.
6. Roychowdhury S. DREAM: Diabetic Retinopathy Analysis Using Machine Learning / S. Roychowdhury, D. D. Koozekanani, K. K. Parhi // *IEEE Journal of Biomedical and Health Informatics*, 2013. – № 5(18). – pp. 1717-1728.
7. Usher D. Automated Detection of Diabetic Retinopathy in Digital Retinal Images: A Tool for Diabetic Retinopathy Screening / D. Usher, M. Dumskyj, M. Himaga, T.H. Williamson, S Nussey, and J. Boyce // *Diabetic Medicine*, 2004. – № 1(21). – pp. 84-90.
8. Philip S. The Efficacy of Automated "Disease/ No Disease" Grading for Diabetic Retinopathy in a Systematic Screening Programme / S. Philip // *British Journal of Ophthalmology*, 2007. – №91(11).– pp. 1512-1517.

9. Cheng S. C. A Novel Approach to Diagnose Diabetes Based on the Fractal Characteristics of Retinal Images / S. C. Cheng and Y. M. Huang // IEEE Transactions on Information Technology in Biomedicine, 2003. – № 3(7). – pp. 163-170.
10. García M. Neural Network Based Detection of Hard Exudates in Retinal Images / M. García, C.I. Sánchez, M.I. López, D. Abásolo, and R. Hornero // Computer Methods and Programs in Biomedicine, 2009. – № 1(93). – pp. 9-19.
11. Lu W. Applications of Artificial Intelligence in Ophthalmology: General Overview / W. Lu, Y. Tong, Y. Yu, Y. Xing, C. Chen, and Y. Shen // Journal of Ophthalmology, 2018.
12. Vandarkuzhali D. C. S. Elm Based Detection of Abnormality in Retinal Image of Eye Due to Diabetic Retinopathy / D. C. S. Vandarkuzhali, and T. Ravichandran // Journal of Theoretical and Applied Information Technology, 2005. – № 6. – pp. 423-428.
13. Antal B. An Ensemble-Based System for Automatic Screening of Diabetic Retinopathy / B. Antal and A. Hajdu // Knowledge-Based Systems, 2013. – № 60. – pp. 20-27.
14. Yoo T. K. Diabetic Retinopathy Risk Prediction for Fundus Examination Using Sparse Learning: A Cross-Sectional Study / T. K. Yoo and E. C. Park // BMC Medical Informatics and Decision Making, 2013. – № 1(13). – pp. 106.
15. Cho N. H. IDF Diabetes Atlas: Global Estimates of Diabetes Prevalence for 2017 and Projections for 2045 / N. H. Cho et al. // Diabetes Research and Clinical Practice, 2018. – № 138. – pp. 271-281.
16. International Diabetes Federation (IDF), IDF Diabetes Atlas, 8th ed., [online], 2017. – <https://idf.org/e-library/epidemiology-research/diabetes-atlas.html>
17. American Diabetes Association, 2. Classification and Diagnosis of Diabetes: Standards of Medical Care in Diabetes-2019. – Diabetes Care, 2019. – № 42. – pp. S13-S28.

18. Baker C. W. Recent Advancements in Diabetic Retinopathy Treatment from the Diabetic Retinopathy Clinical Research Network / C. W. Baker, Y. Jiang, and T. Stone // *Current Opinion in Ophthalmology*, 2016. – № 3(27). – pp. 210.
19. Yau J. W. Y. Global Prevalence and Major Risk Factors of Diabetic Retinopathy / J. W. Y. Yau et al. // *Diabetes Care*, 2012. – № 3(35). – pp. 556-564.
20. Guariguata L. An Updated Systematic Review and Meta-Analysis on the Social Determinants of Diabetes and Related Risk Factors in the Caribbean / L. Guariguata, C. Brown, N. Sobers, I. Hambleton, T.A. Samuels, and N. Unwin // *Revista Panamericana de Salud Pública*, 2018. – № 42.
21. Graham N. Artificial Intelligence / N. Graham // *Blue Ridge Summit: Tab Books*, Philadelphia, PA, USA, 1979.
22. Bejnordi B. E. Context-aware stacked convolutional neural networks for classification of breast carcinomas in whole-slide histopathology images / B. E. Bejnordi, G. Zuidhof, M. Balkenhol et al. // *Journal of Medical Imaging*, 2017. – № 4(4). – Article ID 44504.
23. Esteva A. Dermatologist-level classification of skin cancer with deep neural networks / A. Esteva, B. Kuprel, R. A. Novoa et al. // *Nature*, 2017. – № 542 (7639). – pp. 115–118.
24. Weng S. F. Can machine-learning improve cardiovascular risk prediction using routine clinical data? / S. F. Weng, J. Reips, J. Kai, J. M. Garibaldi, and N. Qureshi // *PLoS One*, 2017. – № 4(12). – Article ID e174944.
25. van Ginneken B. Fifty years of computer analysis in chest imaging: rule-based, machine learning, deep learning / B. van Ginneken // *Radiological Physics and Technology*, 2017. – № 1(10). – pp. 23–32.
26. Gulshan V. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs / V. Gulshan, L. Peng, M. Coram et al. // *JAMA*, 2016. – № 22(316). – p. 2402.



27. G. Quellec, K. Charrière, Y. Boudi, B. Cochener, and M. Lamard, “Deep image mining for diabetic retinopathy screening,” *Medical Image Analysis*, vol. 39, pp. 178–193, 2017.
28. M. Caixinha and S. Nunes, “Machine learning techniques in clinical vision sciences,” *Current Eye Research*, vol. 42, no. 1, pp. 1–15, 2017.
29. G. Litjens, T. Kooi, B. E. Bejnordi et al., “A survey on deep learning in medical image analysis,” *Medical Image Analysis*, vol. 42, pp. 60–88, 2017.
30. A. Lee, P. Taylor, J. Kalpathy-Cramer, and A. Tufail, “Machine learning has arrived!,” *Ophthalmology*, vol. 124, no. 12, pp. 1726–1728, 2017.
31. E. Rahimy, “Deep learning applications in ophthalmology,” *Current Opinion in Ophthalmology*, vol. 29, no. 3, pp. 254–260, 2018.
32. L. J. Catania and E. Nicolitz, “Artificial intelligence and its applications in vision and eye care,” *Advances in Ophthalmology and Optometry*, vol. 3, no. 1, pp. 21–38, 2018.
33. Z. Ghahramani, “Probabilistic machine learning and artificial intelligence,” *Nature*, vol. 521, no. 7553, pp. 452–459, 2015.
34. A. K. Ambastha and T. Y. Leong, “A deep learning approach to neuroanatomical characterisation of Alzheimer’s disease,” *Studies in Health Technology and Informatics*, vol. 245, p. 1249, 2017.
35. Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
36. D. E. Freund, N. Bressler, and P. Burlina, “Automated detection of drusen in the macula,” in *Proceedings of the IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, pp. 61–64, Boston, MA, USA, June 2009.
37. L. Rokach and O. Maimon, “Top-down induction of decision trees classifiers - a survey,” *IEEE Transactions on Systems Man and Cybernetics Part C*, vol. 35, no. 4, pp. 476–487, 2005.
38. L. Breiman, “Random forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.

39. C. C. Chang and C. J. Lin, "LIBSVM: a library for support vector machines," *ACM Transactions on Intelligent Systems and Technology*, vol. 2, no. 3, pp. 1–27, 2011.
40. P. Langley and K. Thompson, "An analysis of Bayesian classifiers," in *Proceedings of AAAI*, pp. 223–228, San Jose, CA, USA, March 1992.
41. J. M. Keller, M. R. Gray, and J. A. Givens, "A fuzzy K-nearest neighbor algorithm," *IEEE Transactions on Systems Man and Cybernetics*, vol. 15, no. 4, pp. 580–585, 2012.
42. T. Kanungo, D. M. Mount, N. S. Netanyahu, C. D. Piatko, R. Silverman, and A. Y. Wu, "An efficient k-means clustering algorithm: analysis and implementation," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, no. 7, pp. 881–892, 2002.
43. J. Ye, "Two-dimensional linear discriminant analysis," *Advances in Neural Information Processing Systems*, vol. 17, no. 6, pp. 1431–1441, 2005.
44. M. T. Hagan, H. B. Demuth, and M. Beale, *Neural Network Design*, PWS Publishing Co., Boston, MA, USA, 1997.
45. A. Statnikov, L. Wang, and C. F. Aliferis, "A comprehensive comparison of random forests and support vector machines for microarray-based cancer classification," *BMC BIOINFORMATICS*, vol. 9, no. 1, pp. 1–10, 2008.
46. P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus, and Y. Lecun, "OverFeat: integrated recognition, localization and detection using convolutional networks," *Arxiv*, 2013.
47. D. S. Kermany, M. Goldbaum, W. Cai et al., "Identifying medical diagnoses and treatable diseases by image-based deep learning," *Cell*, vol. 172, no. 5, pp. 1122–1131, 2018.
48. R. Salakhutdinov and G. Hinton, "An efficient learning procedure for deep Boltzmann machines," *Neural Computation*, vol. 24, no. 8, pp. 1967–2006, 2012.
49. Y. Cho and L. K. Saul, "Kernel methods for deep learning," in *Advances in Neural Information Processing Systems 22: Conference on Neural*

- Information Processing Systems, pp. 342–350, Vancouver, British Columbia, Canada, 2009.
50. N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, “SMOTE: synthetic minority over-sampling technique,” *Journal of Artificial Intelligence Research*, vol. 16, no. 1, pp. 321–357, 2002.
  51. A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” in *Proceedings of International Conference on Neural Information Processing Systems*, pp. 1097–1105, Lake Tahoe, Nevada, December 2012.
  52. K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *Computer Science*, <http://arxiv.org/abs/arXiv:1409.1556>, 2014.
  53. K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770–778, Las Vegas, NV, June 2016.
  54. C. Szegedy, W. Liu, Y. Jia et al., “Going deeper with convolutions,” <http://arxiv.org/abs/arXiv:1409.4842>, 2014.
  55. S. Ioffe and C. Szegedy, “Batch normalization: accelerating deep network training by reducing internal covariate shift,” <http://arxiv.org/abs/arXiv:1502.03167>, 2015.
  56. C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the inception architecture for computer vision,” in *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2818–2826, Las Vegas, NV, June 2016.
  57. C. Szegedy, S. Ioffe, V. Vanhoucke, and A. Alemi, “Inception-v4, inception-ResNet and the impact of residual connections on learning,” <http://arxiv.org/abs/arXiv:1602.07261>, 2016.
  58. Путівець, А.В. Інтелектуальна система виявлення уражень сітківки ока: робота на здобуття кваліфікаційного ступеня бакалавра; спец.: 122 -

комп'ютерні науки (інформатика) / А.В. Путівець; наук. керівник І.В. Шелехов. - Суми: СумДУ, 2020. - 72 с.

## ДОДАТОК

Base.m

```

clear;
Delta_Optimization;
kvo_klassov = 3;
delta = temp(1);
y1 = imread('1.bmp');
[N,n,dimension] = size(y1);
Y(:,:,1) = y1(:,:,1);
y2 = imread('2.bmp');
[N,n,dimension] = size(y2);
Y(:,:,2) = y2(:,:,1);
y3 = imread('3.bmp');
Y(:,:,3) = y3(:,:,1);
y4 = imread('4.bmp');
Y(:,:,4) = y3(:,:,1);
y5 = imread('5.bmp');
Y(:,:,5) = y3(:,:,1);
y6 = imread('6.bmp');
Y(:,:,6) = y3(:,:,1);

sr_znach_prizn_po_realiz = mean(Y(:,:,1));
n_dopusk = sr_znach_prizn_po_realiz - delta;
v_dopusk = sr_znach_prizn_po_realiz + delta;
SZ = sr_znach_prizn_po_realiz;

for k=1:kvo_klassov
for i=1:n
    SZ(i,:,k) = Y(i,:,k) >= n_dopusk & Y(i,:,k) <=
        v_dopusk;
end
end
    EV = mean(SZ) >= 0.5;
    for k1 = 1:kvo_klassov
        for k = 1:kvo_klassov
            temp(k) = sum(xor(EV(1,:,k1),EV(1,:,k)));
        end
    temp(k1) = 101;
    dc(k1) = min(temp);
    temp2 = find(dc(k1) == temp);

```

```

kc(k1) = temp2(1);

for i = 1:n
    sk1(i) = sum(xor(EV(1,:,k1),SZ(i,:,k1)));
    sk2(i) = sum(xor(EV(1,:,k1),SZ(i,:,kc(k1))));
end

d = [1:n];
for i = 1:n
    K1(i) = sum(sk1 <= d(i));
end
for i = 1:n
    K2(i) = sum(sk2 <= d(i));
end

D1 = K1 / 200;
beta = K2 / 200;
D2 = 1 - beta;
alfa = 1 - D1;

Pt = D1 + D2;
Pf = alfa + beta;
E = 0.5*log2((Pt + 0.01)./(Pf + 0.01)).*(Pt-Pf);

Table = [K1; K2; D1; D2; alfa; beta; E]';
rab_oblast = find(((D1 > 0.5)&(D2 > 0.5))&(d < dc(k1
)));

if isempty(rab_oblast)
    Emax(k1) = max(E);
    d_tmp = find(E == Emax(k1));
    D1max(k1) = D1(d_tmp(1));
    D2max(k1) = D2(d_tmp(1));
    alfa_max(k1) = alfa(d_tmp(1));
    beta_max(k1) = beta(d_tmp(1));
    dopt(k1) = -1;
else
    Emax(k1) = max(E(rab_oblast))
    temp_dopt = rab_oblast(find(E(rab_oblast) == Emax(k1
)));

```

```

dopt(k1) = temp_dopt(1);
D1max(k1) = D1(dopt(k1));
D2max(k1) = D2(dopt(k1));
alfa_max(k1) = alfa(dopt(k1));
beta_max(k1) = beta(dopt(k1));
end

end

```

Display

Delta\_Optimization.m

```

kvo_klassov = 6;
delta = 250;
y1 = imread('1.bmp');
[N,n,dimension] = size(y1);
Y(:,:,1) = y1(:,:,1);
y2 = imread('2.bmp');
[N,n,dimension] = size(y2);
Y(1:n,1:N,2) = y2;
y3 = imread('3.bmp');
Y(:,:,3) = y3(:,:,1);

sr_znach_prizn_po_realiz = mean(Y(:,:,1));
for delta = 1:250
n_dopusk = sr_znach_prizn_po_realiz - delta;
v_dopusk = sr_znach_prizn_po_realiz + delta;
SZ = sr_znach_prizn_po_realiz;
for k = 1:kvo_klassov
for i = 1:n
SZ(i,:,k) = Y(i,:,k) >= n_dopusk & Y(i,:,k) <=
v_dopusk;
end
end
EV = mean(SZ) >= 0.5;
for k1 = 1:kvo_klassov

```

```

    for k = 1:kvo_klassov
        temp(k) = sum(xor(EV(1, :, k1), EV(1, :, k)));
    end
    temp(k1) = 101;
    dc(k1) = min(temp);
    temp2 = find(dc(k1) == temp);
    kc(k1) = temp2(1);

    for i = 1:n
        sk1(i) = sum(xor(EV(1, :, k1), SZ(i, :, k1)));
        sk2(i) = sum(xor(EV(1, :, k1), SZ(i, :, kc(k1))));
    end

    d = [1:n];
    for i = 1:n
        K1(i) = sum(sk1 <= d(i));
    end
    for i = 1:n
        K2(i) = sum(sk2 <= d(i));
    end

    D1 = K1 / 100;
    betta = K2 / 100;
    D2 = 1 - betta;
    alfa = 1 - D1;

    Pt = D1 + D2;
    Pf = alfa + betta;
    E = 0.5*log2((Pt + 0.01) ./ (Pf + 0.01)) .* (Pt - Pf);

    Table = [K1; K2; D1; D2; alfa; betta; E]';
    rab_oblast = find(((D1 > 0.5) & (D2 > 0.5)) & (d < dc(k1)));

    if isempty(rab_oblast)
        Emax(k1) = max(E);
        d_tmp = find(E == Emax(k1));
        D1max(k1) = D1(d_tmp(1));
        D2max(k1) = D2(d_tmp(1));
        alfa_max(k1) = alfa(d_tmp(1));
    end

```



```

betta_max(k1) = betta(d_tmp(1));
dopt(k1) = -1;
else
Emax(k1) = max(E(rab_oblast));
temp_dopt = rab_oblast(find(E(rab_oblast) == Emax(k1)
)));
dopt(k1) = temp_dopt(1);
D1max(k1) = D1(dopt(k1));
D2max(k1) = D2(dopt(k1));
alfa_max(k1) = alfa(dopt(k1));
betta_max(k1) = betta(dopt(k1));
end
end

E_delta(delta) = mean(Emax);
rab_delta(delta) = any((D1max > 0.5) & (D2max > 0.5
));
end
ws = find(rab_delta);
Emax_delta = max(E_delta(ws));
temp = ws(find(Emax_delta == E_delta(ws)));

```

Display.M

```

subplot(3,6,1),imshow(Y(:,:,1));
xlabel(['Class 1 ',num2str(N),'x',num2str(n)]);
subplot(3,6,2),imshow(Y(:,:,2));
xlabel(['Class 2 ',num2str(N),'x',num2str(n)]);
subplot(3,6,3),imshow(Y(:,:,3));
xlabel(['Class 3 ',num2str(N),'x',num2str(n)]);
subplot(3,6,4),imshow(Y(:,:,4));
xlabel(['Class 4 ',num2str(N),'x',num2str(n)]);
subplot(3,6,5),imshow(Y(:,:,5));
xlabel(['Class 5 ',num2str(N),'x',num2str(n)]);
subplot(3,6,6),imshow(Y(:,:,6));
xlabel(['Class 6 ',num2str(N),'x',num2str(n)]);
subplot(3,6,7),imshow(SZ(:,:,1));
xlabel('Binary matrix 1');
subplot(3,6,8),imshow(SZ(:,:,2));
xlabel('Binary matrix 2');

```

```
subplot(3,6,9),imshow(SZ(:,:,3));
xlabel('Binary matrix 3');
subplot(3,6,10),imshow(SZ(:,:,4));
xlabel('Binary matrix 4');
subplot(3,6,11),imshow(SZ(:,:,5));
xlabel('Binary matrix 5');
subplot(3,6,12),imshow(SZ(:,:,6));
xlabel('Binary matrix 6');
subplot(3,6,13),imshow(EV(:,:,1));
xlabel('Etal vector 1');
subplot(3,6,14),imshow(EV(:,:,2));
xlabel('Etal vector 2');
subplot(3,6,15),imshow(EV(:,:,3));
xlabel('Etal vector 3');
subplot(3,6,16),imshow(EV(:,:,4));
xlabel('Etal vector 4');
subplot(3,6,17),imshow(EV(:,:,5));
xlabel('Etal vector 5');
subplot(3,6,18),imshow(EV(:,:,6));
xlabel('Etal vector 6');
plot(sr_znach_prizn_po_realiz);
xlabel('Kontroln dopuski');
hold on;
plot(v_dopusk);
plot(n_dopusk);
legend('VD','SZ','ND');
plot(d,E);
hold on;
area(rab_oblast,E(rab_oblast));
```