

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ**  
**СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ**  
**ЦЕНТР ЗАОЧНОЇ, ДИСТАНЦІЙНОЇ ТА ВЕЧІРНЬОЇ ФОРМ НАВЧАННЯ**  
**КАФЕДРА КОМП'ЮТЕРНИХ НАУК**

## **ВИПУСКНА РОБОТА**

**на тему:**

**«Інтелектуальна система розпізнавання  
стаціонарних за яскравістю зображень»**

**Завідувач кафедрою**

**Довбиш А.С.**

**Керівник роботи**

**Шелехов І.В.**

**Студент гр. Індн-61С (Суми)**

**Марков М.О.**

**СУМИ 2020**

МІНІСТЕРСТВО ОСВІТИ І НАУКИ, МОЛОДІ ТА СПОРТУ УКРАЇНИ

СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ

Центр заочної, дистанційної і вечірньої форм навчання

Кафедра комп'ютерних наук

Затверджую \_\_\_\_\_

Зав. кафедрою Довбиш А.С.

“ \_\_\_\_\_ ” \_\_\_\_\_ 2020 г.

**ЗАВДАННЯ  
до випускної роботи**

Студента п'ятого курсу, групи Індн-61С (Суми) спеціальності  
“Інформатика” дистанційної форми навчання Маркова Максима Олеговича.

**Тема: “Інтелектуальна система розпізнавання стаціонарних за  
яскравістю зображень”**

Затверджена наказом по СумДУ

№ \_\_\_\_\_ от \_\_\_\_\_ 2020 г.

**Зміст пояснювальної записки:** 1) аналітичний огляд методів розпізнавання образів; 2) постановка завдання й формування завдань дослідження; 3) опис основних положень, математичних моделей і критеріїв, що використовуються інформаційно-екстремальною інтелектуальною технологією; 5) розробка інформаційного й програмного забезпечення інтелектуальної системи; 6) аналіз результатів моделювання.

Дата видачі завдання “ \_\_\_\_\_ ” \_\_\_\_\_ 2020 г.

Керівник випускної роботи \_\_\_\_\_ Шелехов І.В.

Завдання прийняв до виконання \_\_\_\_\_ Марков М.О.

## РЕФЕРАТ

**Записка:** 54 стор., 15 рис., 4 табл., 1 додаток, 8 бібліографічних джерел.

**Об'єкт дослідження** – слабоформалізований процес розпізнавання стаціонарних за яскравістю зображень.

**Мета роботи** — розробка алгоритму розпізнавання зображень в рамках інформаційно-екстремальної інтелектуальної технології (ІЕІТ).

**Методи дослідження** — метод функціонально-статистичних випробувань, методи терії інформації і теорії розпізнавання образів.

**Результати** — розроблено інформаційне та програмне забезпечення системи розпізнавання зображень. При цьому розглянуто питання обчислення інформаційного критерію функціональної ефективності (КФЕ) таких систем в рамках інформаційно-екстремальної інтелектуальної технології. Розроблений алгоритм реалізовано у програмному забезпеченні створеному за допомогою інструментального програмного середовища Delphi 7.0.

СИСТЕМА РОЗПІЗНАВАННЯ, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ,  
НАВЧАЛЬНА МАТРИЦЯ, МЕТОД ФУНКЦІОНАЛЬНО-  
СТАТИСТИЧНИХ ВИПРОБУВАНЬ, ІНФОРМАЦІЙНО-  
ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНИЙ ТЕХНОЛОГІЯ,  
ЕКЗАМЕНАЦІЙНА МАТРИЦЯ, ІЕРАРХІЧНА КЛАСИФІКАЦІЯ

## ЗМІСТ

<b>ВСТУП.....</b>	<b>5</b>
<b>1 АНАЛІЗ ПРОБЛЕМИ ТА ПОСТАНОВКА ЗАДАЧІ .....</b>	<b>7</b>
1.1 Аналітичний огляд методів розпізнавання образів.....	7
1.2 Постановка задачі інформаційного синтезу ієрархічної системи розпізнавання стаціонарних за яскравістю зображень.....	19
<b>2 ОПИС МЕТОДУ ДОСЛІДЖЕННЯ.....</b>	<b>21</b>
2.1 Основні положення і визначення ІЕІТ .....	21
2.2 Математичні моделі систем розпізнавання.....	25
2.3 Інформаційні критерії оптимізації .....	29
<b>3 ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІЄРАРХІЧНОЇ СИСТЕМИ РОЗПІЗНАВАННЯ.....</b>	<b>33</b>
3.1 Формування вхідного математичного опису .....	33
3.2 Базовий алгоритм навчання системи розпізнавання.....	34
3.3 Алгоритм екзамєну .....	38
3.4 Алгоритм паралельної оптимізації системи контрольних допусків на ознаки розпізнавання.....	39
3.5 Алгоритм оцінки ефективності ієрархічного класифікатора.....	40
3.6 Короткий опис програмної реалізації.....	41
3.7 Результати фізичного моделювання.....	43
<b>ВИСНОВКИ .....</b>	<b>48</b>
<b>СПИСОК ЛІТЕРАТУРИ.....</b>	<b>49</b>
<b>ДОДАТОК.....</b>	<b>50</b>

## ВСТУП

Методи обробки зображень (image processing) мають надзвичайно важливе значення в сучасній науці [1], вони є одними з таких які безперервно розвиваються та вдосконалюються. При цьому під обробкою зображень розуміють не лише поліпшення зорового сприйняття зображень, але й класифікацію об'єктів, що виконується при аналізі зображень.

Області застосування методів цифрової обробки в наш час значно розширюються, витісняючи аналогові методи обробки сигналів зображень. Методи цифрової обробки широко застосовуються в промисловості, мистецтві, медицині, космосі. Вони застосовуються при керуванні процесами, автоматизації виявлення об'єктів, розпізнаванні образів і в багатьох інших. Цифрова передача зображень із космічних апаратів, цифрові канали передачі сигналів зображень вимагають забезпечення передачі все більших потоків інформації. Формування зображень, поліпшення якості та автоматизація обробки медичних зображень, включаючи зображення, що створюються електронними мікроскопами, рентгенівськими апаратами, томографами тощо, є предметом сучасних досліджень та розробок. Автоматичний аналіз у системах дистанційного спостереження широко застосовується при аналізі місцевості, у лісовому господарстві, наприклад, для автоматичного підрахунку площі вирубок, у сільському господарстві для спостереження за дозріванням урожаю, у розвідці, у системах протипожежної безпеки. Контроль якості виробленої продукції виконується завдяки автоматичним методам аналізу сцен.

Сьогодні важко представити область діяльності, у якій можна обійтися без комп'ютерної обробки зображень. При комп'ютерній обробці зображень вирішується широке коло завдань, таких як поліпшення якості зображень; вимірювання параметрів зображення; спектральний аналіз багатомірних сигналів; розпізнавання зображень; стиск зображень.

Метою даної роботи є створення системи розпізнавання зображень. Така система має бути створена на основі інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) з використанням підходу для

інформаційного синтезу системи підтримки прийняття рішень(СППР). Зважаючи на вже існуючі системи розпізнавання, потрібно визначити переваги та недоліки таких систем. Також потрібно акцентувати перевагу власної системи розпізнавання перед існуючими з метою зосередження уваги саме на параметрах, від стану та розвиненості котрих залежить якість в сенсі функціональної ефективності системи розпізнавання.

# 1 АНАЛІЗ ПРОБЛЕМИ ТА ПОСТАНОВКА ЗАДАЧІ

Інтелектуалізація систем автоматичного аналізу та класифікації являє собою досить широку галузь як з точки зору застосовності, так і з позиції методології реалізації. Метою даної роботи є висвітлення способів розпізнавання текстур. Подамо основну класифікацію та узагальнені принципи, які формулюють проблему в своєму класі задач.

## 1.1 Аналітичний огляд методів розпізнавання образів

Основними принципами теорії розпізнавання образів (ТРО) є:

- максимально-дистанційний принцип, за яким вирішальні правила будуються шляхом максимізації середньої міжкласової відстані;
- мінімально-дистанційний принцип, за яким вирішальні правила будуються за умови мінімізації середньої відстані реалізації образу до центру свого класу.

Виконання цих принципів є необхідною умовою одержання максимальної достовірності розпізнавання.

Достовірність розпізнавання визначається повною ймовірністю правильного прийняття рішень

$$P_t = p_1 D_1 = p_2 D_2,$$

де  $p_1, p_2$  - безумовні ймовірності,  $D_1, D_2$  - перша та друга достовірності відповідно. Для розв'язання задач необхідно ввести простір ознак  $\Omega^{|\Omega|}$ , де  $Card\Omega = N$ , тобто  $N$  - вимірність простору  $\Omega^{|\Omega|}$ , що визначається кількістю ознак розпізнавання.

Нехай множина  $\{X_m^0 | m = \overline{1, m}\}$  задає алфавіт класів розпізнавання.

Вектором-реалізацією образу називається структурований (впорядкований) вектор-кортеж

$$x_m^{(j)} = \langle x_{m,1}^{(j)}, \dots, x_{m,i}^{(j)}, \dots, x_{m,N}^{(j)} \rangle,$$

де  $x_{m,i}^{(j)}$  - значення  $i$ -ї ознаки розпізнавання, одержане при  $j$ -му випробуванні.

Еталонним вектором-реалізацією образу називається математичне сподівання множини реалізацій класу  $X_m^o$ :

$$x_m = \langle x_{m,1}, \dots, x_{m,i}, \dots, x_{m,N} \rangle.$$

У загальному випадку процес розпізнавання образу складається з двох етапів:

- етап навчання, на якому формуються деяким оптимальним способом вирішальні правила;
- етап екзамену (безпосереднього розпізнавання), на якому приймається рішення про належність реалізації образу, що розпізнається, одному з класів заданого або сформованого алфавіту.

Контейнером класу розпізнавання називається замкнена роздільна гіперповерхня, для якої будь-яким способом визначено геометричний центр.

Тоді детерміноване вирішальне правило  $D(X)$ , яке формується на етапі навчання, можна розглядати як

$$D(X) = \bigcup_{m=1}^M K_m^o, \quad (1.1)$$

де  $K_m^o \subset X_m^o$  – контейнер класу розпізнавання.

Розглянемо детерміновану постановку задачі розпізнавання образів. Нехай дано алфавіт класів розпізнавання  $\{X_m^o | m = \overline{1, M}\}$ . На етапі навчання необхідно побудувати деяким оптимальним способом розбиття  $\mathfrak{R}$  простору ознак  $\Omega^{|N|}$  на класи розпізнавання за умов

$$\begin{aligned} & (\forall X_m^o \in \mathfrak{R}) [X_m^o \neq \emptyset]; \\ & (\forall X_k^o \in \mathfrak{R})(\forall X_l^o \in \mathfrak{R}) [X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o = \emptyset]; \\ & \bigcup X_m^o \in \Omega; \quad k, l, m = \overline{1, M}; \end{aligned} \quad (1.2)$$



і на етапі екзамену прийняти рішення з високою повною ймовірністю  $P$ , про належність реалізації образу, що розпізнається, одному із класів заданого алфавіту.

Таким чином, в топологічному розумінні класом розпізнавання є область у просторі ознак розпізнавання – елемент розбиття

Вирішальні правила необхідні для прийняття рішень про належність образу, що розпізнається, одному з класів заданого алфавіту. Вони можуть будуватися у вигляді математичних формул, геометричних об'єктів, лінгвістичних структур та інше.

Алгоритм побудови вирішальних правил [2]:

- вимірювання ознак розпізнавання;
- нормалізація значень ознак розпізнавання, яка полягає у приведенні значень до вигляду, зручного для оброблення на ЕОМ;
- формування векторів-реалізацій образу на кожному випробуванні;
- формування навчальної матриці;
- допустимі перетворення навчальної матриці в субпарацептуальному просторі;
- розбиття деяким оптимальним способом простору ознак на класи розпізнавання;

Побудоване оптимальне розбиття  $\mathfrak{R}^*$  у рамках геометричного підходу розглядається як вирішальне правило (або класифікатор).

Загальним критерієм оптимізації в ТРО є інформаційний критерій функціональної ефективності, який можна подати як функціонал від точнісних характеристик, які є функціями від дистанційного критерію:

$$E = f[D_1(d), \alpha(d), \beta(d), D_2(d)],$$

де  $d$  - дистанційний критерій.

Підхід до розв'язання задач розпізнавання образів визначається галуззю знань і науковим напрямком вирішення проблем. У теперішній час основними підходами до вирішення проблем ТРО є:

1. Алгебраїчний.

Основна перевага: прості вирішальні правила.

Основний недолік: низька достовірність розпізнавання, оскільки не враховуються додаткові неконтрольовані фактори, які впливають на процес розпізнавання.

2. Геометричний. Він є універсальним підходом до вирішення проблем розпізнавання образів.

3. Статистичний, в рамках якого використовуються статистичні вирішальні правила (наприклад, Байєсівський класифікатор та його модифікації).

4. Біологічний (штучні нейронні мережі). Алгоритми реалізуються за аналогіями процесів, що відбуваються у нервових клітинах мозку людини.

Основний недолік: висока чутливість до багатовимірності простору ознак розпізнавання.

5. Мережний (семантичні мережі, фрейми, мережі Петрі, дерево рішень та інше).

Переваги: простота моделі, можливість її розширення та ускладнення.

Основний недолік: складність побудови вирішальних правил.

6. Нечіткий. Цей підхід створений на базі алгебраїчного і є конкурентом статистичного підходу. Дозволяє моделювати складні слабоформалізовані процеси, де апріорне розбиття класів є нечітким. Але він не пристосований до оптимізації параметрів функціонування системи розпізнавання.

7. Теоретико-ігровий підхід, вирішальні правила у рамках якого характеризуються високою складністю та невисокою достовірністю розпізнавання.

Незважаючи на те, що наведені підходи відрізняються один від одного рівнем і видом математичної формалізації слабо формалізованих процесів прийняття рішень, між ними не існує чіткої межі, а самі підходи часто доповнюють один одного. Оскільки всі основні підходи, окрім алгебраїчного, перетинаються з геометричним, то саме в рамках геометричного підходу формування загальної теорії прийняття рішень є найбільш виправданим.

Основним критерієм визначення детермінованості методу розпізнавання образів є наявність детермінованих вирішальних правил.

У топологічному аспекті (у рамках геометричного підходу) такі вирішальні правила задаються геометричними параметрами контейнерів класів розпізнавання. Тобто, в режимі екзамену за детермінованими вирішальними правилами визначається належність вектора-реалізації образу що розпізнається одному із контейнерів класів розпізнавання із заданого алфавіту.

Розглянемо основні детерміновані методи розпізнавання образів [1-3].

Метод еталонів. Суть метода: для кожного класу розпізнавання за навчальною матрицею будується еталонний вектор-реалізація, координатами якого є значення ознак розпізнавання. Для алфавіта класів  $\{X_m^0 \mid m = \overline{1, M}\}$  еталонний вектор-реалізація має вигляд

$$x_m = \langle x_{m,1}, \dots, x_{m,i}, \dots, x_{m,N} \rangle,$$

де

$$x_{m,i} = \frac{1}{n} \sum_{i=1}^n x_{m,i}^{(j)}.$$

Таким чином, еталонний вектор  $x_m$  є математичним сподіванням векторів-реалізацій класу  $X_m^0$ . Він є абстрактним (фіктивним) вектором-реалізацією, який може не збігатися з будь-якою реалізацією образу.

Алгоритм розпізнавання подамо у вигляді предикатного виразу

$$(\forall x^{(j)} \in \mathfrak{R}^{|M|}) [IF d(x^{(j)} \oplus x_1) < d(x^{(j)} \oplus x_2)] THEN x^{(j)} \in X_1^0],$$

де  $M=2$ ;  $d(x^{(j)} \oplus x_1)$ ,  $d(x^{(j)} \oplus x_2)$  - кодові відстані реалізацій, що вимірюються від еталонного вектора першого класу  $x_1 \in X_1^0$  та другого класу  $x_2 \in X_2^0$  відповідно.

Таким чином, прийняття рішень про належність реалізації відповідному класу здійснюються за дистанційним критерієм відстані реалізації від еталонних векторів відповідних класів.

Перевага: простота вирішального правила.

Основний недолік: метод носить модельний характер, оскільки виключає перетин класів розпізнавання.

Метод еталонів, що дробляться. Цей метод спрямований на усунення модельності метода еталонів шляхом наближення до практичних задач, для яких є характерним перетин класів.

На рисунку 1.1. зображено класи, які перетинаються. Тут  $\perp$ ,  $\circ$  – графічне зображення реалізацій класів  $X_1^o$  і  $X_2^o$  відповідно.




Рисунок 1.1 – Графічне відображення вирішальних правил

Якщо гіперсфери перетинаються і в області перетину знаходяться реалізації більше ніж одного класу, то для них будуються контейнери другого рівня, потім третього, і т. д. До тих пір, поки контейнери не будуть перетинатися або в області перетину залишаться реалізації одного класу.

Переваги :

- метод враховує реальні апріорні розбиття класів розпізнавання, тобто що вони перетинаються;
- метод є відносно простий.

Недоліки :

- контейнери різних рівнів не є оптимальними в інформаційному розумінні;
- оскільки реалізації на практиці є випадковими, то фактична достовірність розпізнавання на екзамені може суттєво відрізнятись від асимптотичної достовірності, одержаної на етапі навчання, тобто цей метод не характеризується високою достовірністю розпізнавання.

За методом лінійних вирішальних правил роздільна гіперповерхня задається у вигляді лінійної функції

$$D(X) = \sum_{i=1}^N a_i x_i + a_0,$$

де  $x_i$  –  $i$ -та ознака розпізнавання.

Лінійні вирішальні правила застосовуються у випадку лінійно поділених векторів реалізацій образу. Нехай, для випадку двох класів ( $M = 2$ ) розподіл їх векторів-реалізацій показано на рис. 1.2.




Рисунок 1.2 - Графічне відображення лінійних вирішальних правил

У цьому випадку, алгоритм розпізнавання буде дуже простим:

IF  $D(X) > 0$  THEN  $X^{(j)} \in X_1^0$  ELSE  $X^{(j)} \in X_2^0$

Якщо  $M > 2$ , то функція роздільної гіперповерхні буде у вигляді не однієї лінійної функції, а у вигляді кусочно-лінійної функції.

Одним із прикладів реалізації лінійних вирішальних правил є перцептрон Розенблата (рис.1.3).

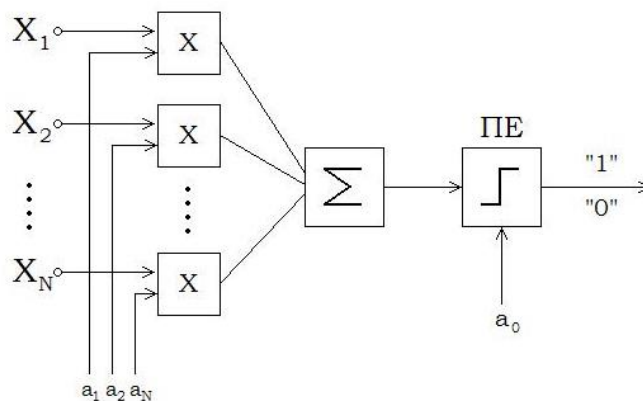


Рисунок 1.3 - Перцептрон Розенблата

На рис. 1.3  $X$  – блоки множення, ПЕ – пороговий елемент.

Задача навчання штучної нейромережі зводиться до цілеспрямованого підбору вагових коефіцієнтів з тим, щоб на виході перцептрона отримати мінімальну помилку

$$\varepsilon = |y - d| \rightarrow 0,$$

де  $y$  – вихід штучної нейромережі;  $d$  – директивний сигнал (вказівка “учителя”).

Сигнал  $a_0$  безпосередньо впливає на поріг спрацьовування порогового елемента (рис.1.4).




Рисунок 1.4 - Пороговий елемент перцептрона

Лінійні вирішальні правила можуть застосовуватися для нормальних образів, тобто для класів розпізнавання, що не перетинаються. Якщо класи перетинаються, для них навчальна вибірка не є нормально розподіленою, а вектори-реалізації образів не є лінійно поділеними.

За методом найближчих сусідів на етапі навчання побудова роздільних гіперповерхонь в просторі ознак розпізнавання здійснюється шляхом запам'ятовування всіх реалізацій образів і віднесення невідомої реалізації до того класу, “представник” якого знаходиться найближче до цієї реалізації. Відносно методу інформаційно-екстремальної інтелектуальної технології (ІЕІТ), де цей принцип використовується на етапі навчання, таким представником виступає ядро класу розпізнавання, тобто для контейнерів класів розпізнавання, які побудовані в реальному базисі бінарного простору ознак, це є вершини відповідних двійкових еталонних векторів-реалізацій.

Основний недолік методу найближчих сусідів – метод не працює у загальному випадку, коли класи перетинаються.

За методом  $K$  найближчих сусідів будується гіперсфера обсяг  $V$ , з центром у вершині вектора-реалізації  $x_m^{(j)}$ . На екзамені розпізнавання здійснюється за більшістю представників деякого класу, які знаходяться в середині гіперсфери.

При цьому основна проблема полягає у побудові гіперсфери  $V$ , яка повинна бути достатньо великою щоб в неї ввійшла більшість представників різних класів, і достатньо малою, щоб не погіршити достовірність розпізнавання.

Цей основний недолік відсутній в методах ІЕІТ, оскільки вона дозволяє в процесі навчання побудувати оптимальні, в інформаційному розумінні, контейнери класів розпізнавання. Безпосередньо, принцип  $K$  найближчих сусідів в ІЕІТ реалізується на етапі екзамену.

Метод потенційних функцій. Нехай  $M=2$ , тобто маємо алфавіт із двох класів:  $\{X_1^0, X_2^0\}$ . Відома координата вершини вектора-реалізації  $x^{(j)}$  в просторі ознак. Надамо точці, що знаходиться в цій координаті потенціал  $+q^{(j)}$ , якщо  $x^{(j)} \in X_1^0$ , і потенціал  $-q^{(j)}$ , якщо  $x^{(j)} \in X_2^0$ . Тоді може мати місце таке вирішальне правило, що створюється  $n$  потенціалами:

$$g(x) = \sum_{j=1}^n q^{(j)} k(x, x^{(j)}), \quad (1.3)$$

де  $k(x, x^{(j)})$  – потенційна функція.

За визначенням потенційна функція є спадковою по мірі збільшення відстані поточної координати  $x$  від вершини  $x^{(j)}$ , і монотонно спадаюча до 0 при  $|x - x^{(j)}| \rightarrow \infty$ .

Вибір потенційної функції не є простою задачею, яку доводиться розв'язувати розробнику інформаційного забезпечення систем розпізнавання. Від вибору потенційної функції залежить як збіжність алгоритму, так і його точність.

На рис. 1.5 наведено приклад побудови вирішального правила за методом потенційних функцій.




Рисунок 1.5 - Вирішальне правило за методом потенційних функцій

Таким чином, процес навчання за методом потенційних функцій полягає в побудові вирішального правила (1.5). Тоді процес розпізнавання за цим методом може здійснюватись за таким алгоритмом: якщо в точці  $x$ , де знаходиться реалізація, що розпізнається, обчислюємо  $g(x)$  і отримуємо правило

$$\text{IF } g(x) > 0 \text{ THEN } X^{(j)} \in X_1^0 \text{ ELSE } X^{(j)} \in X_2^0.$$

Зауваження: при великих обсягах навчальної вибірки доцільно обчислювати не вирішальне правило, а оцінювати розподільну межу для класів розпізнавання (рис. 1.5). У цьому випадку для підвищення оперативності розпізнавання достатньо лише визначити де знаходиться реалізація – справа чи зліва від межі.

Подальше узагальнення метода потенційних функцій полягає в його рандомізації шляхом побудови роздільної межі за навчальною вибіркою з використанням процедур стохастичної апроксимації.

Переваги:

- простота реалізації, яка ґрунтується на фізичних законах електростатики (чим далі від заряду, тим менше його вплив).


Недоліки:

- необхідність обґрунтування вибору потенційної функції, яка впливає безпосередньо на збіжність алгоритму навчання та на достовірність розпізнавання в режимі екзамену.



– метод носить модельний характер, оскільки орієнтований на класи що не перетинаються у просторі ознак розпізнавання.

При структурних методах, реалізації образу характеризують не множиною їх значень (наприклад, навчальна матриця типу об'єкт-властивість) або їх відношень (наприклад, навчальна матриця типу відношень-схожості), а їх структурою. Наприклад, на рис. 1.6 а). наведено зображення, яке можна описати його ієрархічною структурою (рис. 1.6 б):



а)



б)

Рисунок 1.6 – Зображення (а) та відповідна ієрархічна структура (б)

Структурний підхід ґрунтується на аналогії між структурою реалізації образу та синтаксисом мов, тому він часто називається лінгвістичним.

Етап розпізнавання за структурними методами полягає в розпізнаванні не похідних елементів реалізацій образу і синтаксичному аналізі (граматичний розбір) “речення”, що описує образ.

Структурні методи знайшли широке використання при сегментації (при визначенні меж) різних образів, при усномовному розпізнаванні за послідовністю фонем та інше.

Основна перевага – це можливість подати велику кількість реалізацій у вигляді малопотужної множини непохідних елементів і граматичних правил.

Недоліки:

- відсутність прямих вирішальних правил.
- обмеженість використання через те, що аналізується не весь образ, а тільки його фрагмент, що ускладнює процес прийняття рішень.

Об'єднати переваги як детермінованого, так і статистичного підходів до розпізнання образів та обійти їх недоліки – така задача розв'язується у рамках детерміновано-статистичного підходу, наприклад, в методі еталонів Турбовича, де запропоновано будувати класифікатор у два етапи. На першому етапі будується найбільш просте детерміноване вирішальне правило, яке забезпечує безпомилкове розпізнавання реалізацій навчальної матриці. Для мінімізації кількості помилок і прогнозу їх величин при розпізнаванні на другому етапі здійснюється непараметрична статистична корекція вирішального правила. Для такої корекції використовують два одномірних параметри, оцінку яких можна отримати за класифікованою навчальною матрицею. Це максимально-можливий викид реалізацій за “свою” еталонну оболонку та максимально-можливе проникнення у глибину еталонних оболонок реалізацій “чужих” образів.

Подальшим розвитком методу еталонів став метод еталонного опису, в якому з метою зменшення кількості еталонів, а отже і спрощення мінімізації покриття класу, акцент зроблено на відбір ефективних ознак розпізнавання шляхом оцінки їх корисності.

Модельність як методу еталонів, так і методу еталонного опису полягає в ігноруванні загального випадку перетину класів і у відсутності оптимізації процесу навчання за прямим критерієм, що знижує їх практичну цінність.

## 1.2 Постановка задачі інформаційного синтезу ієрархічної системи розпізнавання стаціонарних за яскравістю зображень

Проаналізувавши існуючі методи побудови систем розпізнавання образів, увагу було зупинено на методах ієрархічної кластеризації та методу функціонально-статистичних випробувань, котрі найточніше відображають інформаційні процеси розпізнавання в біологічних системах[3].

Тому, в рамках [2] постановка задачі має наступний зміст:

Нехай відомий алфавіт класів розпізнавання  $\{X_m^0\}$ ,  $m = \overline{1, M}$ , ( $M = 3$ ). Дано навчальну матрицю (1.4) типу об'єкт-властивість

$$\|y_{m,i}^{(j)}\|, \quad i = \overline{1, N}, \quad j = \overline{1, n}, \quad (1.4)$$

де  $N, n$  - кількість ознак розпізнавання і реалізацій образу одного класу.

Визначено структурований вектор параметрів функціонування системи  $g = \langle g_1, \dots, g_\xi, \dots, g_\Xi \rangle$  з відповідними обмеженнями на ці параметри  $R_\xi(g_1, \dots, g_z) \leq 0$ .

Треба на етапі навчання побудувати деяким оптимальним способом (тут і надалі в інформаційному розумінні) розбиття простору ознак на класи еквівалентності за умови, що критерій функціональної ефективності (КФЕ) навчання системи досягає глобального максимуму функції (1.5).

$$E^* = \max_{G_E} E_m, \quad (1.5)$$

де  $E_m$  - критерій функціональної ефективності системи розпізнавати реалізації класу  $X_m^0$ . Оптимальне значення параметру при цьому визначається як  $g_\xi^* = \arg \max_{G_E} E_m$ , де  $G_E$  - область значень критерію.

У роботі необхідно розробити модифікацію методу синтезу системи автоматичної класифікації, що навчається в рамках ІЕІТ, котра дозволить підвищити ефективність навчання системи.

Таким чином, метою роботи є:

- 1) формування множини класів розпізнавання;
- 2) оптимізація в інформаційному сенсі параметрів функціонування системи автоматичної класифікації з урахуванням особливостей вхідного математичного опису;
- 3) оптимізація параметрів навчання з метою підвищення достовірності правильного прийняття рішень.

## 2 ОПИС МЕТОДУ ДОСЛІДЖЕННЯ

### 2.1 Основні положення і визначення ІЕІТ

ІЕІТ – інформаційно-екстремальний метод аналізу та синтезу здатної навчатися (самонавчатися) системи прийняття рішень (СПР), що ґрунтується на прямій оцінці інформаційної спроможності системи і гіпотезі нечіткої компактності реалізацій образу, яка допускає в загальному випадку перетин класів розпізнавання [4-7]. ІЕІТ є модифікацією методу функціонально-статистичних випробувань (МФСВ), доповнюючи його оптимізаційними процедурами різних рівнів, поєднуючи таким чином, методи багатокритеріальної ентропійної оптимізації з оптимізацією геометричних параметрів класів розпізнавання в єдину методологію. Метод орієнтовано на використання сучасних обчислювальних комплексів і призначено для розв'язання практичних задач контролю та керування слабо формалізованими процесами шляхом автоматичної класифікації їх функціональних станів за умови апріорної невизначеності.

Основна ідея МФСВ полягає в оптимізації структурованих просторово-часових параметрів функціонування СПР шляхом трансформації в процесі навчання відношення схожості на нечіткому розбитті простору ознак розпізнавання на класи у відношення еквівалентності.

Класом розпізнавання (образом)  $X_m^o$  називається множина відбитих властивостей  $m$ -го функціонального стану СПР і відношень між її елементами. Клас розпізнавання – топологічна категорія, яка задається в просторі ознак розпізнавання областю  $X_m^o \subset \Omega_B$  ( $\Omega_B$  – простір ознак розпізнавання).

Детерміновано-статистичний підхід до моделювання систем вимагає завдання систем нормованих (експлуатаційних) і контрольних допусків на ознаки розпізнавання. Нехай  $X_1^o$  – базовий клас, який характеризує максимальну

функціональну ефективність системи керування, тобто є найбільш бажаним для особи, що приймає рішення.

Нормованим називається поле допусків  $\{\delta_{H,i} \mid i = \overline{1, N}\}$ , в якому значення  $i$ -ої ознаки знаходиться з імовірністю  $p_i = 1$  або  $p_i = 0$ , за умови, що функціональний стан СПР відноситься до базового класу  $X_1^0$ .

Контрольним називається поле допусків,  $\{\delta_{H,i} \mid i = \overline{1, N}\}$  в якому значення  $i$ -ї ознаки знаходиться з імовірністю  $0 < p_i < 1$  за умови, що функціональний стан СПР відноситься до базового класу  $X_1^0$ .

У МФСВ контрольні допуски на ознаки розпізнавання вводяться з метою рандомізації процесу прийняття рішень, оскільки для повного дослідження процесу керування необхідно використовувати як детерміновані, так і статистичні характеристики. Зрозуміло, що  $|\delta_{K,i}| \leq |\delta_{H,i}|$  і базова система контрольних допусків є сталою для всього алфавіту класів розпізнавання.

Реалізацією образу  $x_m^{(j)} \in X_m^0$  називається випадковий структурований двійковий вектор

$$x_m^{(j)} = \langle x_{m,1}^{(j)}, \dots, x_{m,i}^{(j)}, \dots, x_{m,N}^{(j)} \rangle, \quad j = \overline{1, n_{\min}},$$

де  $x_{m,i}^{(j)}$  –  $i$ -та координата вектора, яка приймає одиничне значення, якщо значення  $i$ -ої ознаки знаходиться в полі допусків  $\delta_{K,i}$ , і нульове значення, якщо не знаходиться;  $n_{\min}$  – мінімальна кількість випробувань, яка забезпечує репрезентативність навчальної вибірки.

При обґрунтуванні гіпотези компактності (чіткої, або нечіткої) за геометричний центр класу  $X_m^0$  приймається вершина двійкового еталонного вектора  $x_m$ .

Еталонний вектор-реалізація  $x_m$  – це математичне сподівання реалізацій класу  $X_m^0$ . Подамо детермінований вектор  $x_m$  у вигляді структурованого двійкового (бінарного) вектора:

$$x_m = \langle x_{m,1}, \dots, x_{m,i}, \dots, x_{m,N} \rangle, \quad m = \overline{1, M},$$

де  $x_{m,i}$  –  $i$ -та координата вектора, яка приймає одиничне значення, якщо значення  $i$ -ої ознаки знаходиться в нормованому полі допусків  $\delta_{n,i}$ , і – нульове значення, якщо не знаходиться.

Ефективність функціонування СПР залежить від її параметрів функціонування.

Параметром функціонування називається характеристика інформаційного забезпечення, яка прямо або непрямо впливає на функціональну ефективність системи і регулюється. Параметри функціонування, які оптимізуються в процесі навчання, будемо називати параметрами навчання.

Як критерій оптимізації процесу навчання в рамках МФСВ застосовується будь-який статистичний логарифмічний інформаційний КФЕ, який є природною мірою різноманітності класів розпізнавання і одночасно функціоналом точнісних характеристик нечіткого СПР.

Достовірність класифікатора залежить від геометричних параметрів роздільних гіперповерхонь класів розпізнавання.

Для загального випадку, коли класи розпізнавання перетинаються розглянемо відносний коефіцієнт нечіткої компактності реалізацій класу  $X_m^o$ .

$$l_{m,d} = \frac{d_m^*}{d(x_m \oplus x_c)} \quad (2.1)$$

Процес навчання полягає в мінімізації виразу (2.1).

В МФСВ, який ґрунтується на допущенні гіпотези компактності (чіткої або нечіткої) реалізацій образу, як наближення "точної" роздільної гіперповерхні для класу  $X_m^o$  розглядається гіперсфера, центром якої є еталонний  $x_m \in X_m^o$ , а радіусом  $d_m$  – кодова відстань, яка у просторі Хеммінга визначається за формулою:

$$d_m = \sum_{i=1}^N (x_{m,i} \oplus \lambda_{m,i}), \quad (2.2)$$

де  $x_{m,i}$  –  $i$ -та координата вектора  $x_m \in X_m^o$ ;  $\lambda_{m,i}$  –  $i$ -та координата деякого вектора-реалізації  $\lambda_m$ , вершина якого знаходиться на роздільній гіперповерхні класу  $X_m^o$ ;  $\oplus$  – операція складання за модулем два.

Алгоритм навчання за МФСВ полягає в реалізації багатоциклическої ітераційної процедури оптимізації структурованих просторово-часових параметрів функціонування СПР шляхом пошуку глобального максимуму усередненого за алфавітом  $\{X_m^o\}$  значення КФЕ навчання.

Оптимальною кодовою відстанню (радіусом) між вектором  $x_m$  і контейнером  $K_m^o$  називається екстремальне значення  $d_m^*$ , яке визначає максимум інформаційного КФЕ  $E_m^* = \max_{\{d\}} E_m$ , де  $\{d\}$  – послідовність збільшень радіуса контейнера  $K_m^o$ .

Побудова оптимальної в інформаційному сенсі гіперповерхні у вигляді гіперсфери за МФСВ зводиться до оптимізації радіуса роздільної гіперсфери  $d_m$ , яка відбувається за ітераційним алгоритмом (2.3):

$$d_m(k) = d_m(k-1) + \begin{cases} h, & \text{if } E_m[d(k)] \geq E_m[d(k-1)]; \\ 0, & \text{if } \text{else} \end{cases} \quad (2.3)$$

де  $k$  – змінна числа збільшень радіуса гіперповерхні;  $d_m(0) = 0$ ;  $h$  – крок збільшення.


Процедура закінчується при знаходженні екстремального значення критерію  $E_m^* = \max_{\{d\}} E_m$ , де  $\{d\} = \{0, 1, \dots, d(x_m \oplus x_{m+1})\}$  – множина радіусів концентрованих гіперсфер, центр яких визначається вершиною еталонного вектора  $x_m \in X_m^o$ ;  $x_{m+1}$  – еталонний вектор найближчого (до  $X_m^o$ ) класу  $X_{m+1}^o$ .




## 2.2 Математичні моделі систем розпізнавання

При обґрунтуванні гіпотези нечіткої компактності [8] має місце нечітке розбиття  $\tilde{\mathfrak{R}}^{|M|} \subset \Omega$ , яке в рамках МФСВ відповідає умовам (2.3.5) і (2.3.6). Введемо оператор  $\theta$  нечіткої факторизації простору ознак:  $\theta: \mathbf{Y} \rightarrow \tilde{\mathfrak{R}}^{|M|}$  і оператор класифікації  $\psi: \tilde{\mathfrak{R}}^{|M|} \rightarrow \mathbf{I}^{|l|}$ , який перевіряє основну статистичну гіпотезу про належність реалізацій  $\{x_m^{(j)} | j = \overline{1, n}\}$  нечіткому класу  $X_m^o$ . Тут  $l$  – кількість статистичних гіпотез. Оператор  $\gamma: \mathbf{I}^{|l|} \rightarrow \mathfrak{Z}^{|q|}$  шляхом оцінки статистичних гіпотез формує множину точнісних характеристик  $\gamma: \mathfrak{Z}^{|q|}$ , де  $q = l^2$  – кількість точнісних характеристик. Оператор  $\phi: \mathfrak{Z}^{|q|} \rightarrow \mathbf{E}$  обчислює множину значень інформаційного КФЕ, який є функціоналом точнісних характеристик. Контур оптимізації геометричних параметрів розбиття  $\tilde{\mathfrak{R}}^{|M|}$  шляхом пошуку максимуму КФЕ навчання розпізнаванню реалізацій класу  $X_m^o$  замикається оператором  $r: \mathbf{E} \rightarrow \tilde{\mathfrak{R}}^{|M|}$ .

Структурна діаграма процесу навчання за МФСВ для випадку нечіткого розбиття має вигляд




Таким чином, у діаграмі (2.4) контур операторів безпосередньо оптимізує геометричні параметри розбиття  $\tilde{\mathfrak{R}}^{|M|}$ .




Оператор  $U: \mathbf{E} \rightarrow \mathbf{G} \times \mathbf{T} \times \Omega \times \mathbf{Z} \times \mathbf{V}$  регламентує процес навчання і дозволяє оптимізувати параметри його плану, які визначають, наприклад, обсяг і структуру випробовувань, черговість розгляду класів розпізнавання та інше.

За алгоритмом (2.3) кожен параметр навчання повинен мати в діаграмі відображень множин свій контур оптимізації при виконанні умови повної композиції: множина  $\mathbf{E}$  є загальною для всіх контурів оптимізації. Серед параметрів навчання, які суттєво впливають на вірогідність класифікатора, розглянемо поля контрольних допусків  $\{\delta_{K,i} \mid i = \overline{1, N}\}$  на значення ознак розпізнавання, рівні селекції  $\{\rho_m\}$  координат еталонних двійкових векторів і крок квантування в часі  $\tau$  реалізацій образу. Нехай контур оптимізації СКД, яка утворює множину  $\mathbf{D}$ , замикається послідовно оператором  $\delta_1: \mathbf{E} \mapsto \mathbf{D}$  і оператором  $\delta_2: \mathbf{D} \rightarrow \mathbf{Y}$ , який змінює реалізації образу в процесі максимізації критерію  $E_m \in \mathbf{E}$ . Нехай значення рівнів селекції утворюють множину  $\check{\mathbf{C}}$ , контур оптимізації якої замикається послідовно оператором  $\rho: \mathbf{E} \mapsto \check{\mathbf{C}}$  і оператором  $\chi: \check{\mathbf{C}} \rightarrow \mathbf{X}$ . Контур оптимізації кроку квантування в часі замикається послідовно оператором  $\tau_1: \mathbf{E} \mapsto \check{\mathbf{T}}$ , де  $\check{\mathbf{T}}$  – множина значень кроків квантування, і оператором  $\tau_2: \check{\mathbf{T}} \rightarrow \mathbf{T}$ , який змінює інтервали часу між зняттям інформації. Тоді діаграма відображень множин в процесі навчання набуває вигляду



У діаграмі (2.5) у порівнянні з діаграмою (2.4) з'явилося три нових контури оптимізації. Так, контур



оптимізує рівні селекції координат еталонних двійкових векторів, а контур

$$\begin{array}{c} \rightarrow \theta \longrightarrow \Psi \longrightarrow \gamma \longrightarrow \varphi \longrightarrow \delta_1 \longrightarrow \delta_2 \\ \longleftarrow \hspace{10em} \longleftarrow \end{array} \quad (2.7)$$

оптимізує СКД на ознаки розпізнавання. Контур оптимізує крок квантування  $\tau$  вхідного сигналу  $g_m(t)$  при забезпеченні обмеження зверху, яке визначається за теоремою Шеннона-Котельнікова.

$$\begin{array}{c} \rightarrow \Phi \longrightarrow \theta \longrightarrow \Psi \longrightarrow \gamma \longrightarrow \varphi \longrightarrow \tau_1 \longrightarrow \tau_2 \\ \longleftarrow \hspace{10em} \longleftarrow \end{array} \quad (2.8)$$

Діаграма відображень множин на екзамені має такі відмінності від діаграм оптимізаційного навчання за МФСВ:

- зворотний зв'язок у діаграмі не містить контурів оптимізації параметрів функціонування ІСУ, а призначенням оператора  $U_E$  є регламентація екзамену;
- замість оператора  $\theta$  вводиться оператор  $P$  відображення вибіркової множини  $X \subset \Omega_B$ , що розпізнається, на побудоване на етапі навчання розбиття  $\tilde{\mathfrak{R}}^{M_1}$ ;
- комутативне кільце утворюється між розбиттям  $\tilde{\mathfrak{R}}^{M_1}$ , множиною гіпотез  $\mathbf{I}^{|M+I|}$  і покриттям  $\tilde{L}^{M_1}$ ;
- оператор класифікації  $\Psi$  утворює композицію двох операторів:  $\Psi_1: \tilde{\mathfrak{R}}^{M_1} \rightarrow \mathbf{F}$ , де  $\mathbf{F}$  – множина функцій належності, і оператор дефазифікації  $\Psi_2: \mathbf{F} \rightarrow \mathbf{I}^{|M+I|}$ , який вибирає гіпотезу за максимальним значенням функції належності.

З урахуванням наведених відмінностей діаграма відображень множин на екзамені набуває вигляду

$$\begin{array}{ccccccc}
 & & & & U_E & & \\
 & & & & \Phi_1 & P & \Psi_1 \quad \Psi_2 \\
 \boxed{\longrightarrow} & T \times G \times \Omega \times Z \times V & \longrightarrow & X & \longrightarrow & \tilde{\mathfrak{R}}^{M|} & \longrightarrow & F & \longrightarrow & I^{M+1|} \\
 & & & & & \searrow \nu & & \swarrow \lambda & & \\
 & & & & & & & \tilde{L}^{M|} & & 
 \end{array}$$

(2.9)

У діаграмі (2.9) оператор  $\Phi_1$  відображає універсум випробувань на вибірккову множину  $X$ , яка утворює екзаменаційну матрицю  $\|x_i^{(j)} \mid i = \overline{1, N}, j = \overline{1, n}\|$ , аналогічну за структурою та параметрами формування навчальній матриці. Як агрегована модель процесу навчання системи розпознавання, наприклад, за діаграмою (2.5) може розглядатися структурована множина:

$$\Delta_H = \langle W, Y, X, \tilde{\mathfrak{R}}^{M|}, E; \Phi, \theta_1, \theta_2, f, r, c, \delta, \tau, U \rangle, \quad (2.10)$$

де  $f$  – композиція операторів  $\psi \circ \gamma \circ \varphi$ ;

$$c = \rho \circ \chi;$$

$$\delta = \delta_1 \circ \delta_2;$$

$$\tau = \tau_1 \circ \tau_2.$$

Аналогічно за діаграмою (2. 9), подамо агреговану модель екзамену у вигляді

$$\Delta_E = \langle W, X, \tilde{\mathfrak{R}}^{M|}, I^{M+1|}; \Phi_1, P, \Psi, U_E \rangle \quad (2.11)$$

де  $\Psi = \Psi_1 \circ \Psi_2$ .

Прийемо за базову модель навчання за МФСВ діаграму (2.4), яка відображає множини, застосовані при оптимізації тільки геометричних параметрів розбиття  $\tilde{\mathfrak{R}}^{M|}$ . Всі множини і оператори в діаграмі (2.4) прийемо так само за базові. Базова діаграма є орієнтованим графом  $G_0 = \langle |G_0|, ArG_0, \nu_0 \rangle$ , де  $|G_0|$  – множина вершин, потужність якої дорівнює кількості базових

множин;  $ArG_0$  – сукупність ребер і  $v_0: ArG_0 \rightarrow |G_0| \times |G_0|$  – оператор, який співставляє кожному ребру його початок і кінець. Крім того, має місце таке твердження.

Базовий граф  $G_0$ , який задано діаграмою (2.4), є категорією  $Cat G_0$ .

Перевагою категорійних моделей у вигляді діаграм відображень множин типу (2.4) є те, що вони дозволяють на етапі системного аналізу не тільки встановлювати відношення між елементами інформаційного забезпечення та інформаційними потоками оброблення інформації, але і полегшують розробку структур алгоритмів різних режимів функціонування системи розпізнавання.

### 2.3 Інформаційні критерії оптимізації

Для оцінки функціональної ефективності СПР широко використовуються ентропійні інформаційні критерії. Наприклад, за Шенноном такий нормований критерій має вигляд

$$E = \frac{H_0 - H(\gamma)}{H_0}, \quad (2.12)$$

де  $H_0$  – апіорна (безумовна) ентропія:

$$H_0 = -\sum_{l=1}^M p(\gamma_l) \log_2 p(\gamma_l); \quad (2.13)$$

$H(\gamma)$  – апостеріорна умовна ентропія, яка характеризує залишкову невизначеність після прийняття рішень:

$$H(\gamma) = -\sum_{l=1}^M p(\gamma_l) \sum_{m=1}^M p(\mu_m / \gamma_l) \log_2 p(\mu_m / \gamma_l), \quad (2.14)$$

де  $p(\gamma_l)$  – апіорна ймовірність прийняття гіпотези  $\gamma_l$ ;  $p(\mu_m/\gamma_l)$  – апостеріорна ймовірність появи події  $\mu_m$  за умови прийняття гіпотези  $\gamma_l$ ;  $M$  – число альтернативних гіпотез.

На практиці при оцінюванні функціональної ефективності СК, що навчається, можуть мати місце такі допущення:

- рішення є двоальтернативним ( $M=2$ );
- оскільки здатна навчатися СК слабо формалізованим процесом функціонує за умови невизначеності, то за принципом Бернуллі-Лапласа виправдано прийняття рівноймовірних гіпотез  $p(\gamma_1) = p(\gamma_2) = 0,5$ .

Тоді критерій з урахуванням виразів (2.12) і (2.13) набирає такий частинний вигляд:

$$E = 1 + \frac{1}{2} \sum_{l=1}^2 \sum_{m=1}^2 p(\mu_m/\gamma_l) \log_2 p(\mu_m/\gamma_l). \quad (2.14)$$

При двоальтернативному рішенні ( $M=2$ ) за основну беремо гіпотезу  $\gamma_1$  про знаходження значення ознаки розпізнавання, що контролюється, в полі допусків  $\delta$  і як альтернативну їй – гіпотезу  $\gamma_2$ . При цьому мають місце чотири можливих результати оцінки виміру ознаки (рис. 2.1), які характеризуються наступними ймовірностями – точнісними характеристиками: помилка першого роду  $-\alpha = \rho(x \notin \delta / z \in \delta)$  (рис. 2.1а); помилка другого роду  $-\beta = \rho(x \in \delta / z \notin \delta)$  (рис. 2.1б); перша достовірність  $-D_1 = \rho(x \in \delta / z \in \delta)$  (рис. 2.1в) і друга достовірність  $-D_2 = \rho(x \notin \delta / z \notin \delta)$  (рис. 2.1г), де  $x, z$  – виміряне та дійсне значення ознаки розпізнавання відповідно.




Рисунок 2.1 – Можливі результати оцінки виміру ознак розпізнавання при  $M=2$

Розіб'ємо множину значень ознак на області  $\mu_1$  та  $\mu_2$ . Область  $\mu_1$  включає значення, що знаходяться в допуску  $\delta$ , а  $\mu_2$  – не в допуску. Тоді можна записати  $\alpha = p(\gamma_2 / \mu_1)$ ;  $\beta = p(\gamma_1 / \mu_2)$ ;  $D_1 = p(\gamma_1 / \mu_1)$ ;  $D_2 = p(\gamma_2 / \mu_2)$ .

Виразимо апостеріорні ймовірності  $p(\mu_m / \gamma_l)$  через апіорні за формулою Байєса:

$$p(\mu_m / \gamma_l) = \frac{p(\mu_m) p(\gamma_l / \mu_m)}{p(\mu_1) p(\gamma_l / \mu_1) + p(\mu_2) p(\gamma_l / \mu_2)}$$

та, прийнявши  $p(\mu_1) = p(\mu_2) = 0,5$ , отримаємо:

$$p(\mu_1 / \gamma_1) = \frac{D_1}{D_1 + \beta}; \quad p(\mu_2 / \gamma_1) = \frac{\beta}{D_1 + \beta};$$

$$p(\mu_1 / \gamma_2) = \frac{\alpha}{\alpha + D_2}; \quad p(\mu_2 / \gamma_2) = \frac{p_2 D_2}{p_1 \alpha + p_2 D_2}. \quad (2.15)$$

Після підстановки (2.15) в (2.14) отримаємо формулу для обчислення КФЕ за Шенноном:

$$E = 1 + \frac{1}{2} \left( \frac{\alpha}{\alpha + D_2} \log_2 \frac{\alpha}{\alpha + D_2} + \frac{D_1}{D_1 + \beta} \log_2 \frac{D_1}{D_1 + \beta} + \right.$$

$$\left. + \frac{\beta}{D_1 + \beta} \log_2 \frac{\beta}{D_1 + \beta} + \frac{D_2}{\alpha + D_2} \log_2 \frac{D_2}{\alpha + D_2} \right). \quad (2.16)$$

Логарифмічна статистична інформаційна міра Кульбака [7] дозволяє оцінювати диференційну інформативність ознак розпізнавання. Збудемо робочу формулу для обчислення міри Кульбака та встановимо її зв'язок з точнісними характеристиками процесу навчання за МФСВ. Введемо логарифмічне відношення повної ймовірності  $P_t^{(k)}$  правильного прийняття рішень про належність реалізацій класів  $X_m^o$  і  $X_{m+1}^o$   $k$ -му контейнеру  $K_{m,k}^o \in X_m^o$ , побудованому на  $k$ -му кроці навчання СПР розпізнавати реалізації класу  $X_m^o$ , до повної ймовірності помилкового прийняття рішень  $P_f^{(k)}$ , яке для двоальтернативної системи оцінок рішення має такий вигляд:

$$\Lambda = \log_2 \frac{P_t^{(k)}}{P_f^{(k)}} = \log_2 \frac{p(\mu_m)p(\gamma_{1,k}/\mu_m) + p(\mu_{m+1})p(\gamma_{2,k}/\mu_{m+1})}{p(\mu_m)p(\gamma_{2,k}/\mu_m) + p(\mu_{m+1})p(\gamma_{1,k}/\mu_{m+1})},$$

де  $\gamma_{1,k}$ ,  $\gamma_{2,k}$  – гіпотези про належність контейнеру  $K_{m,k}^o$  реалізацій відповідно до класів  $X_m^o$  і  $X_{m+1}^o$

При допущенні, що  $p(\mu_m) = p(\mu_{m+1}) = 0,5$ , загальна міра Кульбака остаточно набуває вигляду

$$\begin{aligned} J_m^{(k)} &= 0,5 \log_2 \left( \frac{D_1^{(k)} + D_2^{(k)}}{\alpha^{(k)} + \beta^{(k)}} \right) \left[ (D_1^{(k)} + D_2^{(k)}) - (\alpha^{(k)} + \beta^{(k)}) \right] = \\ &= \log_2 \left( \frac{2 - (\alpha^{(k)} + \beta^{(k)})}{\alpha^{(k)} + \beta^{(k)}} \right) \left[ 1 - (\alpha^{(k)} + \beta^{(k)}) \right] \end{aligned} \quad (2.17)$$

Нормовану модифікацію критерію Кульбака можна подати у вигляді

$$J_{m,k} = \frac{J_m^{(k)}}{J_{\max}^{(k)}}, \quad (2.18)$$

де  $J_{\max}^{(k)}$  – значення критерію при  $D_1^{(k)} = D_2^{(k)} = 1$  і  $\alpha^{(k)} = \beta^{(k)} = 0$  для формули (2.17).

Нормування критеріїв оптимізації є доцільним при порівняльному аналізі результатів досліджень і при оцінці ступеня близькості реальної СПР до потенційної.



## 3 ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІЄРАРХІЧНОЇ СИСТЕМИ РОЗПІЗНАВАННЯ

### 3.1 Формування вхідного математичного опису

Найважливішим елементом у дизайні є текстури. Це, як правило, растрові зображення з роздільною здатністю 128x128, 256x256 пікселів використовуються для заливки областей шляхом розміщення копій пліч-о-пліч, без видимих швів на стиках.

Наклавши текстуру, на якій або об'єкт можна додати йому реалістичний вигляд. Для покриття 3d об'єктів кращого результату можна добитися, використовуючи текстури більш високого дозволу. Існують так само текстури 32768x32768 пікселів і вище (Мегатекстури). Які застосовують для покриття ландшафтів ігрових рівнів (замість безлічі дрібних текстур), при створенні комп'ютерних ігор.

Хоч самі по собі текстури є растровими зображеннями з їх допомогою можна передати ілюзію рельєфу. Поняття текстура фактично відповідає за властивості поверхні об'єкта, такі як шорсткість, гладкість тощо. На рис. 3.1 подано графічне відображення текстур, що використовувалися в роботі.



Рисунок 3.1 – Графічне відображення навчальних матриць

Навчальні матриці формуються безпосередньо з зображення, при цьому зчитується яскравість кожного пікселя, що змінюється від 0 - чорний колір до 255 - білий колір, проміжні значення є градаціями сірого. Враховуючи стаціонарність зображень, (тобто те, що невеличкий елемент зображення містить достатньо інформації для відновлення зображення в цілому) будемо вважати кожний рядок пікселів зображення реалізацією класу, при цьому кількість ознак буде співпадати з кількістю елементів такого рядка. Таким

чином, навчальна матриця для кожного класу складається з  $n=100$  реалізацій, а словник ознак з  $N=100$  ознак.

### 3.2 Базовий алгоритм навчання системи розпізнавання

Призначенням базового алгоритму навчання LEARNING [2] є оптимізація геометричних параметрів контейнерів класів розпізнавання, які відновлюються на кожному кроці навчання в радіальному базисі. Вхідною інформацією для навчання за базовим алгоритмом у загальному випадку є дійсний масив реалізацій образу  $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$ ; система полів контрольних допусків  $\{\delta_{k,i}\}$  і рівні селекції  $\{\rho_m\}$  координат двійкових еталонних векторів-реалізацій образу, які за замовчанням дорівнюють 0,5 для всіх класів розпізнавання.

Розглянемо етапи реалізації алгоритму LEARNING:

1 Формування бінарної навчальної матриці  $\|x_{m,i}^{(j)}\|$ , елементи якої дорівнюють

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_{k,i}, \\ 0, & \text{if } y_{m,i}^{(j)} \notin \delta_{k,i}. \end{cases} \quad (3.1)$$

2 Формування масиву еталонних двійкових векторів  $\{x_{m,i} \mid m = \overline{1, M}, i = \overline{1, N}\}$ , елементи якого визначаються за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m, \\ 0, & \text{if } \textit{else}, \end{cases} \quad (3.2)$$

де  $\rho_m$  – рівень селекції координат вектора  $x_m \in X_m^o$ .

3 Розбиття множини еталонних векторів на пари найближчих "сусідів":  $\mathfrak{R}_m^{[2]} = \langle x_m, x_l \rangle$ , де  $x_l$  – еталонний вектор сусіднього класу  $X_l^o$ , здійснюється за таким алгоритмом:

а) структурується множина еталонних векторів, починаючи з вектора  $x_1$  базового класу  $X_1^o$ , який характеризує найбільшу функціональну ефективність СПР;

б) будується матриця кодкових відстаней між еталонними векторами розмірності  $M \times M$ ;

в) для кожного рядка матриці кодкових відстаней знаходиться мінімальний елемент, який належить стовпчику вектора, найближчого до вектора, що визначає строку. За наявності декількох однакових мінімальних елементів вибирається з них будь-який, оскільки вони є рівноправними;

г) формується структурована множина елементів попарного розбиття  $\{\mathcal{R}_m^{[2]} \mid m = \overline{1, M}\}$ , яка задає план навчання.

4 Оптимізація кодової відстані  $d_m$  відбувається за рекурентною процедурою (2.3). При цьому береться  $E_m(0) = 0$ .

5 Процедура закінчується при знаходженні максимуму КФЕ в робочій області його визначення:  $E_m^* = \max_{\{d\}} E_m$ , де  $\{d\} = \{0, 1, \dots, d < d(x_m \oplus x_l)\}$  – множина радіусів концентрованих гіперсфер, центр яких визначається вершиною  $x_m \in X_m^o$ .

Таким чином, базовий алгоритм навчання є ітераційною процедурою пошуку глобального максимуму інформаційного КФЕ в робочій області визначення його функції

$$d_m^* = \arg \max_{\{d\}} E_m^*.$$

На рис. 3.2 наведено структурну схему базового алгоритму навчання LEARNING.

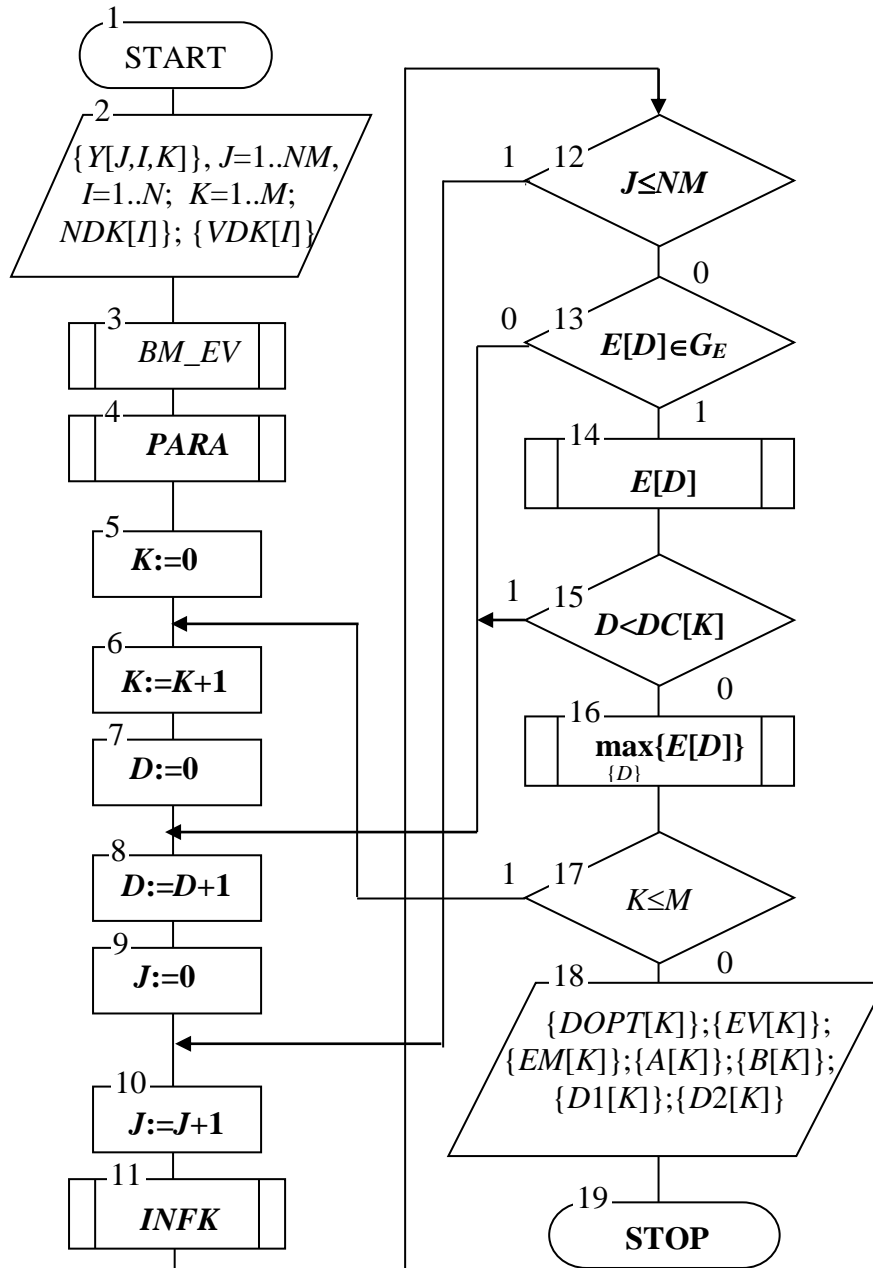


Рисунок 3.2 – Структурна схема базового алгоритму навчання

Тут показано такі вхідні дані:  $\{Y[J,I,K]\}$  – масив навчальних вибірок,  $J = \overline{1, NM}$  – змінна кількості випробувань, де  $NM$  – мінімальний обсяг репрезентативної навчальної вибірки,  $I = \overline{1, N}$  – змінна кількості ознак розпізнавання,  $K = \overline{1, M}$  – змінна кількості класів розпізнавання;  $\{NDK[I]\}$ ,  $\{VDK[I]\}$  – масиви нижніх і верхніх контрольних допусків на ознаки відповідно. Результатом реалізації алгоритму є:  $\{DOPT[K]\}$  – цілий масив оптимальних

значень радіусів контейнерів класів розпізнавання у кодовій відстані Хеммінга;  $\{EV[K]\}$  – масив еталонних двійкових векторів класів розпізнавання;  $\{EM[K]\}$  – дійсний масив максимальних значень інформаційного КФЕ процесу навчання;  $\{D1[K]\}$ ,  $\{A[K]\}$ ,  $\{B[K]\}$ ,  $\{D2[K]\}$  – дійсні масиви оцінок екстремальних значень точнісних характеристик процесу навчання для відповідних класів розпізнавання: перша достовірність, помилки першого та другого роду і друга достовірність відповідно. Змінна  $D$  є робочою змінною кроків навчання, на яких послідовно збільшується значення радіуса контейнера.

У структурній схемі алгоритму (рис. 3.2) блок 3 формує масив навчальних двійкових вибірок  $\{X[J,I,K]\}$  шляхом порівняння значень елементів масиву  $\{Y[J,I,K]\}$  з відповідними контрольними допусками за правилом (1) і формує масив еталонних двійкових векторів  $\{EV[K]\}$  шляхом статистичного усереднення стовпців масиву  $\{X[J,I,K]\}$  за правилом (2) при відповідному рівні селекції, який за замовчуванням дорівнює  $\rho_m = 0,5$ . Блок 4 здійснює розбиття множини еталонних векторів на пари “найближчих сусідів”. Блок 11 обчислює на кожному кроці навчання значення інформаційного КФЕ. При невиконанні умови блока порівняння 12 блок 13 оцінює належність поточного значення критерію  $E[D]$  робочій області  $G_E$  визначення його функції і при позитивному рішенні блока 13 це значення запам’ятовується блоком 14. При негативному рішенні блока порівняння 15, в якому величина  $DC[K]$  дорівнює кодовій відстані між парою сусідніх еталонних векторів, блок 16 здійснює у робочій області  $G_E$  пошук глобального максимуму КФЕ –  $EM[K]$  і визначає для нього екстремальне значення радіуса гіперсфери –  $DOPT[K]$ . Аналогічно будуються оптимальні контейнери для інших класів. Якщо параметри навчання  $\{DOPT[K]\}$  і  $\{EV[K]\}$  є вхідними даними для екзамену, то значення КФЕ та екстремальних оцінок точнісних характеристик використовуються для аналізу ефективності процесу навчання.

Таким чином, основною процедурою базового алгоритму навчання за МФСВ є обчислення на кожному кроці навчання інформаційного КФЕ і

організація пошуку його глобального максимуму в робочій області визначення функції критерію.

### 3.3 Алгоритм екзамену

На рис. 3.3 показано структурну схему алгоритму екзамену для нечіткого розбиття простору ознак розпізнавання, яке має місце у загальному випадку.

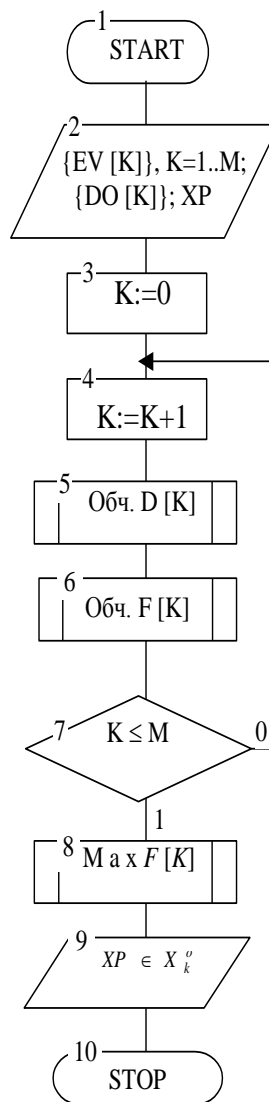


Рисунок 3.3 – Структурна схема алгоритму екзамену

Алгоритм має такі вхідні дані:  $\{EV[K]\}$  – масив еталонних двійкових векторів;  $K = \overline{1, M}$  – змінна числа класів розпізнавання;  $\{DOPT[K]\}$  – цілий масив

оптимальних радіусів контейнерів класів розпізнавання у кодовій відстані Хеммінга;  $XP$  – двійкова реалізація образу, що розпізнається.

Виходом алгоритму є повідомлення про належність реалізації, що розпізнається, деякому класу  $X_k^o$  із сформованого на етапі навчання алфавіту класів  $\{X_m^o\}, k, m = \overline{1, M}$ . На рис. 3.3 блок 5 обчислює, починаючи з базового класу, кодову відстань  $d\{EV[K] \oplus XP\}$  між поточним еталонним вектором і реалізацією  $XP$ . Блок 6 для кожного класу обчислює значення функції належності  $F[K]$ , яка для гіперсферичного класифікатора має вигляд

$$F[K] = 1 - \frac{D[K]}{DOPT[K]}. \quad (3.3)$$

Після виходу із циклу блок 8 визначає клас, до якого належить реалізація  $X_P$  за максимальним значенням функції належності (3.3).

### **3.4 Алгоритм паралельної оптимізації системи контрольних допусків на ознаки розпізнавання**

На ефективність навчання СППР значно впливає використання контуру оптимізації СКД. Алгоритм оптимізації контрольних допусків за МФСВ полягає у наближенні глобального максимуму інформаційного критерію оптимізації до найбільшого його значення в області значень функції.

Розглянемо схему алгоритму LEARNING-2, призначеного для паралельної оптимізації контрольних допусків на ознаки розпізнавання. Вхідні дані: масив реалізацій образу  $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$ ; стартова СКД  $\{\delta_{K,i}\}$  і система нормованих допусків (СНД)  $\{\delta_{H,i}\}$ , яка визначає область значень відповідних контрольних допусків. За область визначення параметра  $\delta$  приймається інтервал  $[1; \delta_H / 2]$ , де  $\delta_H$  – ширина нормованого поля допусків. Стартовий параметр  $\delta_i$  поля контрольних допусків може дорівнювати половині відповідного симетричного поля нормованих допусків для  $i$ -ї ознаки

за умови випадковості її значень. Попередньо для кожної ознаки визначається ціна градації  $\Delta_i$ , на яку змінюється  $i$ -та ознака.

Розглянемо кроки реалізації цього алгоритму:

1. Обнулюється лічильник кроків зміни параметра  $\delta: l:=0$ .
2. Запускається лічильник:  $l:=l+1$  і обчислюються нижні та верхні контрольні допуски для всіх ознак:  $\{A_{HK,i}[l] := y_{m,i} - \delta[l]\}$  і  $\{A_{BK,i}[l] := y_{m,i} + \delta[l]\}$ ,  $i = \overline{1, N}$ , відповідно.
3. Реалізується базовий алгоритм навчання.
4. Якщо  $E_1^*[l] \geq E_1^*[l-1]$ , то виконується пункт 5, інакше пункт 6.
5. Якщо  $\delta \leq \delta_H / 2$ , то виконується пункт 2, інакше пункт 6.
6.  $\{A_{HK,i}^* := A_{HK,i}[l-1]\}; \{A_{BK,i}^* := A_{BK,i}[l-1]\}$ ,  $i = \overline{1, N}; E_1^* := E_1^*[l-1]$  і “ЗУПИН”.

### 3.5 Алгоритм оцінки ефективності ієрархічного класифікатора

- 1) Формуємо множину ієрархічних класифікаторів  $Q: Q_l = (V_1^{(l)}, V_2^{(l)}, \dots, V_t^{(l)}, \dots, V_{T_l}^{(l)})$ , де  $l$  – номер ієрархічного класифікатора ( $l=1 \dots |Q|$ ),  $V_t^{(l)}$  – множина класів, вирішальні правила яких формуються на  $t$  – тому рівні ієрархічного класифікатора  $Q_l$ ;  $T_l$  – максимальна кількість рівнів ієрархій  $Q_l$  класифікатора.
- 2) Ініціюємо лічильник ієрархічних класифікаторів  $l:=1$ .
- 3) Оптимізуємо параметри  $Q_l$  – ієрархічного класифікатора з використанням паралельного алгоритму оптимізації системи контрольних допусків на ознаки розпізнавання  $\{\delta_t^{(l)}\}$  і базового алгоритму оптимізації геометричних параметрів контейнерів класів розпізнавання  $\{R_t^{|V_t^{(l)}}|\}$ . При визначенні найближчих (сусідніх) класів для класів  $V_t^{(l)}$  враховуємо лише класи тих рівнів ієрархії, що є не вищими за поточний рівень  $t$ , тобто  $\{V_t^{(l)}, V_{t+1}^{(l)}, \dots, V_{T_l}^{(l)}\}$ .



- 4) Визначаємо усереднене максимальне значення КФЕ по всіх класах ієрархії  $Q_l$

$$\bar{E}_l^* = \frac{\sum_{t=1}^{T_l} \left( \sum_{k=1}^{|V_t^{(l)}|} E_{t,k}^* \right)}{\left| \bigcup_{t=1}^{T_l} V_t^{(l)} \right|},$$

де  $E_{t,k}^*$  - максимальне значення КФЕ в робочій області його визначення, що було отримане в процесі оптимізації параметрів функціонування інтелектуальної системи для k-того класу на t-тому рівні.

- 5)  $l := l + 1$

- 6) Якщо  $l \leq |Q|$ , то переходимо до наступного варіанту ієрархічного класифікатора (перехід до етапу 3), інакше перехід до етапу 7.

- 7) Визначаємо оптимальний в інформаційному розумінні ієрархічний класифікатор  $Q_{opt}$  для якого виконується умова

$$\bar{E}_{opt}^* = \max_l \bar{E}_l^*$$

- 8) Останов.

### 3.6 Короткий опис програмної реалізації

Алгоритм було реалізовано за допомогою середовища розробки Borland Delphi 7 у вигляді консольної прикладної програми. Були використані наступні константи та змінні (Табл. 3.1):

Таблиця 3.1 – Основні константи та змінні програми

Ім'я константи або змінної	Короткий опис
$m = 3$	Кількість класів розпізнавання
$n = 100$	Кількість ознак розпізнавання
$nr = 100$ ;	Кількість реалізацій
$Y, VM: \text{array}[1..m, 1..n, 1..nr]$ of integer;	Навчальна матриця та бінарна навчальна матриця
$EV : \text{array}[1..m, 1..n]$ of integer;	Масив еталонних векторів
$SK : \text{array}[1..2, 1..nr]$ of integer;	Масив кодівих відстаней від еталонного вектора до реалізацій

Таблиця 3.1(продовження)

A,B,D1,D2,EM:array[1..m]of real;	Значення точносних характеристик та КФЕ при оптимальних параметрах навчання
D:array[1..m]of integer;	Оптимальні радіуси контейнерів класів навчання
PARA:integer;	Кодова відстань між центрами класів навчання
VD,ND:integer;	Система допусків на значення ознак розпізнавання
i,j,k:integer;	Лічильники
FT:Text;	Дескриптор файлу вхідних даних
Delta:array[1..m]of integer;	Масив параметрів СКД, що використовуються при її формуванні і оптимізації.

Крім того було розроблено наступні процедури та функції (Табл. 3.2):

Таблиця 3.2 – Основні процедури та функції програми

<b>Ім'я функції або процедури</b>	<b>Короткий опис</b>
Function INFK;	Функція для розрахунку поточного значення КФЕ
Procedure LoadClass;	Процедура для завантаження навчальної матриці
Procedure MakeBM;	Розрахунок бінарної навчальної матриці
Procedure MakeDO;	Розрахунок оптимальних значень радіусів контейнерів класів розпізнавання
Procedure MakeEV;	Розрахунок значень центрів контейнерів класів розпізнавання
Procedure MakePARA;	Розрахунок матриці кодових відстаней між центрами класів та знаходження найближчого.
Procedure MakeSK;	Розрахунок кодових відстаней між центрами класів та реалізаціями.
Procedure SaveClass;	Збереження отриманих результатів.
Procedure SKDO;	Оптимізація СКД за паралельним алгоритмом

### 3.7 Результати фізичного моделювання

В роботі проводилася оцінка ефективності чотирьох варіантів ієрархічного класифікатора. Графічне відображення цих варіантів наведено на рис. 3.4.




Рисунок 3.4 - Варіанти ієрархічних класифікаторів ефективність, яких оцінювалася: а) однорівневий класифікатор, б-г) дворівневі класифікатори

При оптимізації функціональних параметрів однорівневого класифікатора (рис. 3.4 а)) значення кроку СКД  $\delta$ , оптимізувалося автоматично. Як критерій оптимізації параметрів функціонування використовувався ентропійний критерій Шеннона.

На рисунку 3.5 показано динаміку зміни узагальненого КФЕ в процесі паралельної оптимізації СКД.




Рисунок 3.5 – Процес паралельної оптимізації кроку  $\delta$  СКД

Аналіз рисунку показує про досягнення максимуму узагальненого КФЕ при  $\delta = 28$ . На рисунку 3.6 показано оптимальний СКД.




Рисунок 3.6 –Оптимальний за узагальненим КФЕ коридор СКД.

На рисунку 3.7 ілюстровано еталонні вектори та бінарні матриці класів розпізнавання, отримані в процесі навчання СППР.




Рисунок 3.7 – Оптимальні бінарні матриці та еталонні вектори класів розпізнавання: а) клас  $X_1^0$ ; б) клас  $X_2^0$ ; в) клас  $X_3^0$ .

Аналіз рисунку свідчить про значний перетин класів розпізнавання, це дозволяє зробити припущення про значну кореляцію ознак розпізнавання.

На рисунку 3.8 показано процес оптимізації радіусів контейнерів класів розпізнавання.




Рисунок 3.8 – Оптимізація радіусів контейнерів класів розпізнавання: а) клас  $X_1^0$ ; б) клас  $X_2^0$ ; в) клас  $X_3^0$

На рисунку 3.8 темно-сірим кольором позначено робочу область визначення КФЕ, а світло-сірим кольором показано область, де значення першої та другої достовірності менше за 0,5. Аналіз рисунку 3.9 свідчить про значний перетин класів розпізнавання, так як робочі області достатньо обмежені, а значення КФЕ в них відносно невелике. Таким чином, в результаті навчання СППР отримано наступні оптимальні параметри функціонування:

Оптимальне значення узагальненого КФЕ  $E_y^* = 0.33151$

Оптимальне значення ширини СКД  $\delta^* = 28$

Таблиця 3.1 відображає оптимальні параметри класів розпізнавання, отриманих в процесі навчання СППР.

Таблиця 3.1. Оптимальні параметри класів розпізнавання

Клас розпізнавання	Оптимальне КФЕ	Оптимальний радіус	Точнісні характеристики	
			D1	D2
$X_1^0$	0.5755	46	1,00	0,62
$X_2^0$	0.0889	46	0,79	0,52
$X_3^0$	0.3302	45	0,53	0,95

Аналогічно проводилася оцінка ефективності інших дворівневих варіантів ієрархічних класифікаторів (рис. 3.5 б-г)). Результати такої оцінки наведено в таблиці 3.2.

Таблиця 3.2. –Результати оцінки ефективності ієрархічних класифікаторів

Рівень ієрархії	Клас розпізнавання	Оптимальне КФЕ	Оптимальний радіус	Точнісні характеристики		$\delta^*$
				D1	D2	
Ієрархічний класифікатор $Q_1$ (рис. 3.5 а))						
1 рівень	$X_1^0$	0.5755	46	1,00	0,62	28
	$X_2^0$	0.0889	46	0,79	0,52	
	$X_3^0$	0.3302	45	0,53	0,95	
Усереднене КФЕ $\bar{E}_1^*$		0.3315				
Ієрархічний класифікатор $Q_2$ (рис. 3.5 б))						
1 рівень	$X_1^0$	0.6732	45	0,90	0,97	24
2 рівень	$X_2^0$	0.4958	44	0,76	0,96	27
	$X_3^0$	0.2688	51	0,92	0,55	
Усереднене КФЕ $\bar{E}_2^*$		0.4793				

Таблиця 3.2.(продовження)

Ієрархічний класифікатор $Q_3$ (рис. 3.5 в)						
1 рівень	$X_2^0$	0.4958	44	0,76	0,96	22
2 рівень	$X_1^0$	0.6732	45	0,90	0,97	24
	$X_3^0$	0.7327	47	0,92	0,98	
Усереднене КФЕ $\bar{E}_3^*$		0.6339				
Ієрархічний класифікатор $Q_4$ (рис. 3.5 г)						
1 рівень	$X_3^0$	0.4803	53	0,99	0.53	24
2 рівень	$X_1^0$	0.5480	54	1.00	0.51	22
	$X_2^0$	0.5431	38	0.53	1.00	
Усереднене КФЕ $\bar{E}_4^*$		0.5238				

Аналіз табл. 3.2 вказує на те, що максимальне усереднене значення КФЕ  $\bar{E}_{opt} = \bar{E}_3^* = 0,6339$  було отримано для ієрархічного класифікатора  $Q_3$ . Таким чином, ієрархічний класифікатор  $Q_3$ , графічне відображення якого подано на рис. 3.5 в), є оптимальним в інформаційному розумінні.

## ВИСНОВКИ

1. Модифікований базовий алгоритм навчання, регламентований ІЕІТ-технологією, дозволив підвищити достовірність правильного прийняття рішення в процесі функціонування системи розпізнавання стаціонарних за яскравістю зображень. Використання контуру паралельної оптимізації системи контрольних допусків на ознаки розпізнавання дозволили максимізувати мультикритерій функціональної ефективності.

2. Низьке оптимальне значення критерію функціональної ефективності для деяких класів вказує на недостатню достовірність ефективного функціонування системи розпізнавання стаціонарних за яскравістю зображень. Це викликано значним перетином областей локалізації ознак, асоційованих з класами розпізнавання. Для підвищення достовірності функціонування системи розпізнавання стаціонарних за яскравістю зображень потрібно вводити та оптимізувати додаткові параметри функціонування системи розпізнавання, з метою максимізації різноманітності між класами, внесення інваріантності в процес обробки вхідних даних та підвищення стійкості та завадозахищеності системи розпізнавання.



## СПИСОК ЛІТЕРАТУРИ

1. Горелик А. Л., Скрипкин В. А. Методы распознавания М.: Высшая школа, 1989. – 222 с.
2. Стокман Дж., Шапиро Л. Компьютерное зрение — М. : Бином. Лаборатория знаний, 2006. — 752 с.
3. В.Н. Вапник, А.Я. Червоненкис Теория распознавания образов М.: Наука, 1974. — 416 с.
4. Довбиш А.С. Основи проектування інтелектуальних систем: Навчальний посібник.— Суми: Видавництво Сум ДУ, 2009.— 171 с.
5. Краснопоясовський А.С. Інформаційний синтез інтелектуальних систем керування: підхід, що ґрунтується на методі функціонально-статистичних випробувань.— Суми: Видавництво СумДУ, 2004.— 261 с.
6. Краснопоясовський А. С., Черниш А.В., Сластушевський О.Ю. Про вибір критерію функціональної ефективності системи розпізнавання, що навчається // Радиоэлектроника и информатика, 2001.— №4.
7. Кульбак С. Теория информации и статистика: Пер. с англ. –М.: Наука, 1967.
8. Рідкокаша А.А., Голдер К.К. Основи систем штучного інтелекту: Навчальний посібник. –Черкаси: Видавництво «Відлуння-Плюс», 2002.—240с.

## ДОДАТОК

```

program Teach;

{$APPTYPE CONSOLE}

uses
  Windows, Messages, SysUtils, Variants, Classes, Graphics, Controls,
  Forms, Dialogs, ExtCtrls, Grids, StdCtrls, ImgList, Menus, ComCtrls,
  ExtDlgs;

const
  m=3;      // кількість класів (слої навчальної матриці)
  n=100;    // кількість ознак розпізнавання (стовпці навч. матр.)
  nr=100;   // кількість реалізацій класів (рядки навч. матр.)

var
  Y, BM: array[1..m, 1..n, 1..nr] of integer; // навчальна матриця + бінарна навч.
  матр.
  VD, ND: array[1..n] of integer; // система контрольних допусків
  EV: array[1..m, 1..n] of integer; // еталонні вектори (центри контейнерів
  класів)
  SK: array[1..2, 1..nr] of integer; // кодові відстані від еталонного вектору до
  реалізацій [1] -своїх x[2]-сусідніх
  A, B, D1, D2, EM: array[1..m] of real; //точнісні характеристики(TX)+ критерій
  функціональної ефективності(КФЕ)
  A_NWS, B_NWS, D1_NWS, D2_NWS, EM_NWS: array[1..m] of real; // TX+КФЕ, коли нема
  робочої області
  D: array[1..m] of integer; // оптимальні радіуси контейнерів класів
  D_NWS: array[1..m] of integer; //радіуси контейнерів класів, коли нема робочої
  області
  PARA, dc: array[1..m] of integer; //номер сусіднього класу та міжцентрова
  відстань
  i, j, k, kl: integer; // лічильники
  FT, FT_EXM: Text; // дескриптори файлів для звітності
  FileName: string;
  delta, tclass: array[1..n] of integer;
  tdelta: integer; //ширина коридору СКД
  ifsaveclasses: boolean; // флаг ведення звіту
  make_report: boolean; //флаг ведення звіту оптимізації СКД

Procedure LoadClass(num: integer);
var BMPClass: TBitmap;
begin
  BMPClass:=TBitmap.Create;
  Write('FileName for ', num, ' class: (ENTER=', num, '.bmp) ');
  Readln(FileName);
  if FileName='' then FileName:=concat(inttostr(num), '.bmp');
  BMPClass.LoadFromFile(FileName);
  for j:=1 to nr do
    for i:=1 to n do
      Y[num, i, j]:=getRvalue(BMPClass.Canvas.Pixels[i, j]);
  BMPClass.Destroy;
end;

Procedure MakeDelta(td: integer);
var delta_i: integer;
begin
  for delta_i:=1 to n do
    delta[delta_i]:=td;
  end;
Procedure MakeSD;
  var
    Sum: integer;
begin

```

```

for i:=1 to n do
begin
  sum:=0;
  for j:=1 to nr do
    sum:=sum+y[tclass[i],i,j];
  sum:=round(sum/nr);
  vd[i]:= sum+delta[i];
  nd[i]:= sum-delta[i];
end;
end;

```

```

Procedure MakeSD2(il:integer);
  var
    Sum:integer;
begin
  sum:=0;
  for j:=1 to nr do
    sum:=sum+y[tclass[il],il,j];
  sum:=round(sum/nr);
  vd[il]:= sum+delta[il];
  nd[il]:= sum-delta[il];
end;

```

```

Procedure MakeBM;
begin
for k:=1 to m do
  for i:=1 to n do
    for j:=1 to nr do
      if (Y[k,i,j]>=ND[i])and(Y[k,i,j]<=VD[i])then BM[k,i,j]:=1 else BM[k,i,j]:=0;
end;

```

```

Procedure MakeEV;
var sum:integer;
begin
for k:=1 to m do
  for i:=1 to n do begin
    sum:=0;
    for j:=1 to nr do
      sum:=sum+BM[k,i,j];
    if sum/nr>=0.5 then EV[k,i]:=1 else EV[k,i]:=0;
  end;
end;

```

```

Procedure MakePARA;
var sum,kc:integer;
begin
for k:=1 to m do
  begin
  para[k]:=1; dc[k]:=n;
  for kc:=1 to m do
    if (k<>kc)then begin
      sum:=0; for i:=1 to n do sum:=sum+abs(EV[k,i]-EV[kc,i]);
      {if ifsavclasses then
        Write(sum,chr(9));}
      if sum<=dc[k] then begin para[k]:=kc; dc[k]:=sum; end;
    end
    {Else if ifsavclasses then Write('X',chr(9));
    if ifsavclasses then Writeln; }
  end;
end;

```

```

Procedure MakeSK(num:integer);
begin
for j:=1 to nr do begin
SK[1,j]:=0;SK[2,j]:=0;
  for i:=1 to n do begin
    SK[1,j]:=SK[1,j]+abs(EV[num,i]-BM[num,i,j]);
    SK[2,j]:=SK[2,j]+abs(EV[num,i]-BM[PARA[num],i,j]);
  end;
end;
end;

function INFK(t_:integer;var t_D1:real; var t_beta:real):real;
var k1,k2,k3,k4:integer;
    d1_b:double;
begin
  k1:=0;k2:=0;k3:=0;k4:=0;
  for j:=1 to nr do
  begin
    if sk[1,j]<=t_ then inc(k1);
    if sk[2,j]<=t_ then inc(k3);
  end;
  k4:=nr-k3;
  k2:=nr-k1;
  t_D1:=k1/nr;
  t_Betta:=k3/nr;
  d1_b:=t_D1-t_Betta;
  INFK:=d1_b*ln((1+d1_b+0.1)/(1-d1_b+0.1))/ln(2); //Полный критерий Кульбака,
  выраженный через D1 и beta
end;

Procedure SaveClass(num:integer);
begin
Writeln(FT,'Class ',num);
Writeln(FT,'BM[' ,num,']');
for i:=1 to n do begin
for j:=1 to nr do
Write(FT,BM[num,i,j],chr(9));
Writeln(FT);
end;
Writeln(FT,'EV[' ,num,']');
for i:=1 to n do
Write(FT,EV[num,i],chr(9));
Writeln(FT);
Writeln(FT,'PARA[' ,num,']=',PARA[num]);
Writeln(FT,'dc[' ,num,']=',dc[num]);
Writeln(FT,'d',chr(9),'E',chr(9),'D1',chr(9),'Betta',chr(9),'Alfa',chr(9),'D2',c
hr(9),'K1',chr(9),'K2',chr(9),'K3',chr(9),'K4');
end;

Procedure MakeDO;
var te,tD1,tbeta:real;
    t,ti:integer;
begin
  AssignFile(FT_EXM,'REZ.TXT');
  Rewrite(FT_EXM);
  if ifsaveclasses then begin
    for ti:=1 to n do
      Write(FT_EXM,VD[ti],' ',ND[ti],chr(9));
      Writeln(FT_EXM);
    end;
  for k:=1 to m do begin
  if ifsaveclasses then begin
  AssignFile(FT,'REZ'+inttostr(k)+'.TXT');
  Rewrite(FT);
  SaveClass(k);

```

```

end;
em[k]:=0;
em_NWS[k]:=0;
d[k]:=0;
MakeSK(k);
for t:=0 to n do begin
  te:=INFK(t,td1,tbeta);
  if ifsaveclasses then
    Writeln(FT,t,chr(9),te:0:5,chr(9),td1:0:3,chr(9),tbeta:0:3,chr(9),1-
td1:0:3,chr(9),1-tbeta:0:3,chr(9),round(td1*nr),chr(9),round((1-
td1)*nr),chr(9),round((1-tbeta)*nr),chr(9),round(tbeta*nr));
  if te>EM_NWS[k] then begin
EM_NWS[k]:=te;d_NWS[k]:=t;d1_NWS[k]:=td1;b_NWS[k]:=tbeta; end;
  if (td1>=0.5)and(tbeta<0.5)and(t<dc[k])then begin
  if te>em[k] then begin em[k]:=te;d[k]:=t;d1[k]:=td1;b[k]:=tbeta; end;
  end;
  end;
  if ifsaveclasses then begin
  Writeln(FT,'Class ',k,chr(9),'Em= ',em[k]:0:5,chr(9),'do=
',d[k],chr(9),'dc=',dc[k],chr(9),'D1= ',d1[k]:0:2,chr(9),'Beta= ',b[k]:0:2);
  // Writeln('Class ',k,chr(9),'Em= ',em[k]:0:5,chr(9),'do=
',d[k],chr(9),'dc=',dc[k],chr(9),'D1= ',d1[k]:0:2,chr(9),'Beta= ',b[k]:0:2);
  Writeln(FT_EXM,k);
  for ti:=1 to n do
    Write(FT_EXM,EV[k,ti],' ');
  Writeln(FT_EXM);
  Writeln(FT_EXM,d[k]);
  closefile(FT);
  end;
end;
closefile(FT_EXM);
end;

Procedure SKDO(kl:integer;delta_max:integer);
var e0:real;
i_ds,j_ds:integer;
a:boolean;
my_i,my_j,my_ji:integer;
f1,f2,f3:textfile;
sum_real, em_avg:real;
ff_x:integer;
begin

if make_report then
begin assign(f1,concat('E_delta(параллельный)X',inttostr(kl),'.dat'));
rewrite(f1);end;{
i_ds:=0{1}{200}{};
j_ds:=0{1};
e0:=0;
for i_ds:=0 to delta_max do
begin
if (i_ds/20)=trunc(i_ds/20) then write(i_ds,'-');

Makedelta(i_ds);
//delta:=i_ds;
MakeSD;
MakeBM;
MakeEV;
MakePARA;
MakeDO;
a:=true;
for my_i:= 1 to m do
if d[my_i]=0 then a:=false;
if make_report then
begin

```

```

    write(f1, (VD[1]-ND[1])/2, ' ', a);
    for my_i:=1 to m do
        write(f1, ' ', em[my_i], ' ', d[my_i], ' ', d1[my_i], ' ', b[my_i], ' ', para[my_i],
        ' ', dc[my_i]);
        writeln(f1);
    end;
    em_avg:=0;
    for my_i:= 1 to m do
        em_avg:=em_avg+Em[my_i];
    em_avg:=em_avg/m;
    if (em_avg>e0) and (a) then begin e0:=em_avg; j_ds:=i_ds;end;
    {i_ds:=i_ds+1;}
    end;
    writeln;
    Makedelta(j_ds);
    MakeSD;
    MakeBM;
    MakeEV;
    MakePARA;
    MakeDO;
    if make_report then closefile(f1);
    end;

begin
    { TODO -oUser -cConsole Main : Insert code here }
    ifsaveclasses:=true;
    make_report:=true;
    Writeln('LOAD');
    LoadClass(1, '1.bmp');
    LoadClass(2, '2.bmp');
    LoadClass(3, '3.bmp');
    ifsaveclasses:=false;
    SKDO(1,100);
    ifsaveclasses:=true;
    MakeSD;
    MakeBM;Writeln('BM..Done');
    MakeEV;Writeln('EV..Done');
    Writeln('PARA');
    MakePARA;Writeln('PARA..Done');
    MakeDO;
    Writeln('TEACH..Done');
    Readln;
end.

```