

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ХАРКІВСЬКИЙ НАЦІОНАЛЬНИЙ
УНІВЕРСИТЕТ РАДІОЕЛЕКТРОНІКИ**

**В.О. ГОРОХОВАТСЬКИЙ
І.С. ТВОРОШЕНКО**

**АНАЛІЗ БАГАТОВИМІРНИХ ДАНИХ
ЗА ОПИСОМ
У ФОРМІ МНОЖИНИ КОМПОНЕНТ**

Монографія

**Харків
2022**

УДК 004.932.2:004.93'1

*Рекомендовано до друку Науково-технічною радою ХНУРЕ
(протокол від 18.02.2022 р. № 1/4)*

Рецензенти:

- С.Г. Удовенко*, доктор технічних наук, професор, завідувач кафедри інформатики та обчислювальної техніки Харківського національного економічного університету імені Семена Кузнеця.
- О.Г. Руденко*, доктор технічних наук, професор, завідувач кафедри комп'ютерних інтелектуальних технологій та систем Харківського національного університету радіоелектроніки.

Гороховатський В.О., Творошенко І.С.

Аналіз багатовимірних даних за описом у формі множини компонент: монографія / В.О. Гороховатський, І.С. Творошенко. – Харків: ХНУРЕ, 2022. – 124 с.

ISBN 978-966-659-379-8

У монографії розвиваються структурні технології аналізу багатовимірних даних в інтелектуальних системах. Основна увага приділяється ансамблевим моделям подання та оброблення даних у вигляді множини компонент. Запропоновано новітні методи класифікації зображень на підставі опису як множини дескрипторів ключових точок, проведено їх статистичне обґрунтування. Досліджуються нечіткі моделі подання та класифікації даних засобами інтервальної логіки. Описано результати програмного моделювання та експериментальних досліджень, що включають порівняльний аналіз результативності запропонованих підходів із традиційними структурними, нечіткими та статистичними методами. Підтверджено показники ефективності при вирішенні задач класифікації для прикладних баз даних та зображень.

Рекомендовано для науково-технічних працівників та студентів, що розробляють, впроваджують та вивчають новітні інформаційні технології чи інтелектуальні методи аналізу багатовимірних даних. Монографія може бути корисною для здобувачів вищої освіти за спеціальністю «Комп'ютерні науки» у галузі «Інформаційні технології».

УДК 004.932.2:004.93'1

ISBN 978-966-659-379-8

DOI: 10.30837/978-966-659-379-8

- © Гороховатський В.О., Творошенко І.С., 2022
© Харківський національний університет
радіоелектроніки, 2022

ЗМІСТ

ВСТУП.....	4
1 ЗАСОБИ САМОНАВЧАННЯ ТА МОДИФІКАЦІЇ ПРОСТОРУ ДАНИХ	7
1.1 Впровадження апарату мережі Кохонена	7
1.2 Експериментальне дослідження класифікаторів із самонавчанням.....	13
1.3 Класифікація зображень із впровадженням параметрів кластерного подання для структурного опису	18
1.4 Аналіз результатів комп'ютерного моделювання для класифікації за кластерним поданням.....	24
2 СТАТИСТИЧНІ МОДЕЛІ ТА ЛОГІЧНЕ ОБРОБЛЕННЯ ДАНИХ У МЕТОДАХ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ.....	29
2.1 Логічний аналіз даних при побудові мір подібності	29
2.2 Аналіз результатів моделювання класифікаторів.....	34
2.3 Статистичний аналіз складу компонентів структурного опису	38
2.4 Аналіз результатів моделювання статистичного подання.....	46
2.5 Непараметричні статистичні підходи при побудові класифікаторів.....	52
2.6 Результати моделювання непараметричних підходів для класифікації.....	56
3 НЕЧІТКІ МОДЕЛІ ПОДАННЯ ДАНИХ У СТРУКТУРНИХ МЕТОДАХ РОЗПІЗНАВАННЯ.....	59
3.1 Застосування засобів нечіткого кластерування.....	59
3.2 Експериментальне дослідження нечітких моделей	64
3.3 Грануляція даних та нечітка логіка	68
3.4 Результати моделювання методів грануляції	75
4 КЛАСИФІКАЦІЯ ТА ОБРОБЛЕННЯ ДАНИХ ЗАСОБАМИ НЕЧІТКОЇ ІНТЕРВАЛЬНОЇ ЛОГІКИ	80
4.1 Інтелектуальні засоби класифікації станів біофізичної системи	80
4.2 Прикладні технології прийняття рішень	87
4.3 Модифікація методу гілок та меж для аналізу компонент функцій належності.....	90
4.4 Результати програмної реалізації модифікованого методу.....	96
4.5 Налаштування множини компонент функцій належності.....	100
4.6 Експериментальне дослідження методу налаштування	108
ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ.....	114

ВСТУП

У сучасних системах аналізу даних, включаючи комп'ютерний зір, набули прикладного застосування методи розпізнавання об'єктів, що засновані на компонентних ознаках даних чи зображення у формі множини векторів.

До них належать методи, що базуються на визначенні множини ключових точок (КТ) зображення та їх описові у вигляді числового чи бінарного вектора – дескриптора, що відображає властивості функції яскравості зображення для локальних околів КТ [1-16]. Цей підхід дає можливість комп'ютерній програмі працювати із візуальними образами подібно людині, зір якої теж часто ґрунтується на особливих локальних прикметах зображення.

Значення дескриптора є інваріантним стосовно групи геометричних перетворень об'єктів на зображенні (зміщення, поворот, масштабування), а кількість утворених дескрипторів, що формують опис, має бути достатньою для прийняття результативного рішення відносно розрізнення розпізнаваних об'єктів. Розпізнавання (класифікація) при застосуванні структурних методів полягає в обчисленні міри релевантності між описами об'єкта та еталона, образи яких задані у вигляді множин дескрипторів, та оптимізації значень цієї міри для бази еталонів [12, 14, 15].

Відповідно до структурного підходу зображення об'єктів, які складають зміст зображення сцени, складають образи об'єктів із окремих компонент. Переміщення сформованих КТ у просторі координат адекватно відображає фізичне пересування об'єкта. Топологія множини КТ також відображає фізичну топологію пізнаваних об'єктів у побудованому просторі образів.

Перспективною ідеєю в аспекті скорочення обсягу обчислювальних витрат для процесу класифікації візуальних об'єктів є побудова деякої множини опорних точок у просторі дескрипторів КТ [12]. Комбінацією числа КТ, близьких до опорних точок у просторі їх значень (дескрипторів КТ), можна універсально отримати опис довільного образу об'єкта.

Розвиненням ідеї кластерного подання для структурних описів у межах прикладної бази зображень є безпосередня побудова правила класифікації, яке за значенням дескриптора буде відносити КТ до фіксованого еталонного класу. У результаті аналізу накопичується певна кількість голосів КТ, за якою згодом визначається номер класу для аналізованого об'єкта. Для близьких за змістом зображень таке правило із високою ефективністю важко реалізувати, тому що схожі зображення часто містять і чимало однакових дескрипторів.

Однак, наші дослідження показують, що для достатнього різноманіття баз зображень синтез індивідуального класифікаційного правила щодо окремих дескрипторів КТ все-таки може дати непогані прикладні результати [10, 12]. Науковий інтерес представляє також застосування інтелектуальних технологій організації навчання у просторі описів для досягнення значимих показників класифікації [4].

Бітова природа дескрипторів КТ у просторі бінарних векторів дає можливість впровадити подання та аналіз окремого дескриптора як ланцюжка елементів (наприклад, байтів чи набору бітів), діапазон значень яких відомий. Це дає змогу здійснювати компонентний аналіз даних з урахуванням внутрішнього змісту наявного опису об'єкту. З точки зору важливості інформації всі елементи ланцюжка рівноцінні, але місце їх розміщення у складі дескриптора фіксоване, тому є можливість аналізувати чи обробляти упорядковані послідовності елементів [3, 9, 12].

Один із можливих підходів побудови класифікатора засновано на використанні таких статистичних характеристик, як математичне очікування, дисперсія, оцінки медіани та ін. [6]. Але більш інформативним є все-таки використання безпосередньо самих значень розподілів, як це впроваджено у традиційних методах інтелектуального аналізу [17-20].

Беззаперечно, що основою сучасного апарату «data science» є статистичні методи, які теоретично та практично розвиваються вже протягом довгого часу. Їх перевагами є строге теоретичне обґрунтування та наявність розроблених програмних середовищ для практичного впровадження. Одним із найбільш застосованих у задачах комп'ютерного зору є програмні засоби бібліотеки OpenCV [21]. Бібліотека OpenCV містить понад 2500 оптимізованих класичних та сучасних алгоритмів аналізу зображень і машинного навчання. Можливості таких сучасних програмних бібліотек комп'ютерного зору, як OpenCV, забезпечують вирішення ряду нагальних практичних задач: аналіз вмісту зображень, пошук та розпізнавання заданих об'єктів, виявлення тексту, відстеження рухів об'єктів, виявлення спільних елементів на порівнюваних зображеннях, реалізація методів навчання для прикладних баз відеоданих тощо.

Важливим у напрямку аналізу багатовимірних даних є вирішення задачі підвищення достовірності прийняття класифікаційних рішень щодо стану біофізичних систем, для чого авторами пропонується застосування нечітких інтервальних уявлень про характеристики об'єктів. Розроблена модифікація методу класифікації станів генерує і критеріально оцінює набір альтернатив під час класифікації.

Ключовим у компонентному аналізі даних при впровадженні нечітких інтелектуальних систем є завдання забезпечення результативності прийняття рішень [22-25]. У монографії запропоновано модифікацію методу гілок та меж для систем обробки даних нечіткого виду, поданих природною мовою. Нова інтерпретація методу посилена підходами дихотомії та золотого перетину. Програмну реалізацію модифікованого методу в нечіткій інтелектуальній системі здійснено у середовищі об'єктно-орієнтованого програмування Python.

Запропоновано архітектуру інструментальних засобів, яка побудована на принципах удосконаленого методу налаштування параметрів функції належності, враховує невизначеність чи відсутність даних, а також особливості та обмеження предметної області застосувань [2, 26].

Матеріал монографії продовжує вивчення і розвинення структурних технологій аналізу даних в інтелектуальних системах [12-16] і ґрунтується на недавніх дослідженнях авторів [1-11, 26, 27], де детально викладене теоретичне підґрунтя та особливості прикладного застосування апарату багатокомпонентного аналізу даних. Проведені дослідження включають порівняльний аналіз результативності розроблених методів із традиційними підходами [16-20, 28], базовими структурними, нечіткими та статистичними методами в аспекті експериментально підтверджених показників ефективності та швидкодії [29-33].

Автори висловлюють щире подяку аспірантам та студентам кафедри інформатики Харківського національного університету радіоелектроніки, які є співавторами ряду публікацій і протягом тривалих років брали дієву участь у розробленні програмних продуктів, здійсненні програмного моделювання та дослідженні результативності розроблених методів інтелектуального аналізу даних із впровадженням їх у прикладних базах даних та зображень.

1 ЗАСОБИ САМОНАВЧАННЯ ТА МОДИФІКАЦІЇ ПРОСТОРУ ДАНИХ

1.1 Впровадження апарату мережі Кохонена

У комп'ютерних системах розпізнавання візуальних об'єктів визначними показниками є результативність та час оброблення.

У зв'язку з цим у прикладних задачах набули поширення методи структурної класифікації зображень, побудовані на вживанні нейронних мереж для виявленні закономірностей на множині ознак структурних описів бази зразків. Результат навчання мережі у вигляді системи «центрів даних» безпосередньо використовується для класифікації, що значно прискорює процес обчислення [12, 31, 32].

Основні переваги сучасних детекторів ORB та BRISK полягають в забезпеченні високої швидкодії при порівняльній або кращій точності, ніж у їх аналогів SIFT (Scale Invariant Feature Transform) та SURF (Speeded up Robust Features), за рахунок істотного спрощення процесу оброблення використанням дескрипторів бінарного типу [34, 35].

Важливим для науки про дані є вивчення адаптаційних властивостей і параметричних характеристик нейронних мереж стосовно навчання в задачах класифікації зображень за множиною дескрипторів КТ, де спостерігається фактично необмежене різноманіття аналізованих даних. Визначним є також дослідження ефективності схем навчання мереж, які враховують ступінь близькості елементів різних класів у побудованому просторі ознак.

Імплементация мереж Кохонена у процес класифікації дає можливість універсально і з успіхом налаштовуватися на довільні набори візуальних даних. Якість класифікації напряду залежить від результатів навчання мережі на множині дескрипторів навчальної вибірки [18].

Провідним для класифікації є вивчення можливостей і властивостей процесу навчання нейронної мережі в плані найбільш ефективного використання чи трансформацій простору даних, а також дослідження поглиблених схем навчання.

Розглянемо удосконалення методу класифікації зображень в межах бази еталонів на основі детектування дескрипторів КТ шляхом визначення специфічного простору даних для навчання мережі і застосування результатів навчання для класифікації. Результати дослідження опубліковані в [4].

Нехай $W = \{x \mid x \in R^n\}$, $W \subseteq R^n$ – простір структурних ознак (дескрипторів КТ) зображень. База описів зразків (еталонів) $Z \subset W$ задана у вигляді множини $Z = \{Z^j\}_{j=1}^J$, $s_j = \text{card } Z^j$, $s = \text{card } Z$, $s = \sum_j s_j$. При цьому кожна ознака $x_i^j \in Z^j$ асоціюється з деяким еталоном Z^j бази у плані належності до його складу.

Основною задачею навчання мережі Кохонена є налагодження класифікатора у плані формування системи центрів для еталонних даних, ефективне використання розміщеної в описах еталонної інформації з метою забезпечення високої результативності класифікації.

Завданнями роботи є застосування нейронної мережі Кохонена для навчання системи класифікації у визначеному просторі даних, аналіз варіантів навчання мережі, вивчення адаптаційних можливостей і оцінювання ефективності функціонування мережі та результативності класифікації засобами програмного моделювання.

Мережа Кохонена здатна розпізнавати кластери в даних, а також встановлювати близькість класів. Можна поліпшити розуміння структури даних, щоб потім уточнити нейромережеву модель, відкоригувавши існуючі правила класифікації об'єктів. Мережу Кохонена можна використовувати у задачах класифікації, де класи вже задані [18].

Важливим є той факт, що, якщо мережа Кохонена після розпізнавання зустрінеться із набором даних, несхожим ні на один з відомих їй зразків, то вона класифікує такий набір як новий клас [31]. Мережа Кохонена навчається методом послідовних наближень. Навчання при цьому полягає не в мінімізації помилки, а в підстроюванні внутрішніх параметрів мережі для найбільшого збігу з вхідними даними.

Авторська монографія [18] містить різноманіття підходів до побудови та навчання мереж, що дає можливість вибрати структуру мережі у відповідності до аналізованих даних. Загалом застосування мережі Кохонена у системах комп'ютерного зору націлене на виявлення найбільш значущих ознак зображення, які в подальшому застосовуються для розпізнавання.

Метою навчання мережі у даній постановці є формування системи центрів на множині дескрипторів бази еталонів. Впровадимо процедуру навчання мережі Кохонена як послідовність етапів [4].

Етап 1. Виберемо елементи навчальної множини у вигляді сукупності $Z = \{Z^j\}_{j=1}^J$ описів усіх елементів бази еталонів.

Етап 2. Ініціюємо матрицю ваг $M = \{m_j\}_{j=1}^J$, де рядками є сформовані вектори нейронів m_j центрів класів так, що $m_j = x_i^j$, $x_i^j \in Z^j$, де i – номер довільного вектора із класу зразків Z^j .

Етап 3. Виберемо поточний елемент $z \in Z$, для кожного $j \in [1, 2, \dots, J]$ обчислимо відстань $q_j = \rho(z, m_j)$ і визначимо клас d нейрона-переможця: $d = \arg \min_j q_j$.

Етап 4. Обчислимо зміни ваг для нейронів вихідного шару мережі

$$\Delta m_j = h(j, d, t) \cdot \eta \cdot (z - m_j), \quad (1.1)$$

де η – коефіцієнт швидкості навчання;

$h(j, d, t)$ – значення функції околиці для нейрона з номером j в момент часу навчання t .

Зазвичай, $h(j, d, t) = \exp[-\rho(j, d)/\sigma(t)]$ визначають у вигляді гаусової функції, а радіус $\sigma(t) = 1/\exp(t^{-2})$ околиці зменшують зі збільшенням параметра t , $t = 1, \dots, s$.

Етап 5. Коректуємо матрицю ваг $M = M + \Delta M$ на кроці t .

Етап 6. Продовжуємо навчання мережі Кохонена (етапи 3-5) до завершення списку Z .

Етап 7. Перевіряємо виконання умови припинення навчання мережі Кохонена. Традиційно критерієм є величина помилки або сумарна відстань між системами центрів на кроках t і $(t-1)$.

При невиконанні умови зупинки продовжуємо навчання відповідно до етапу 3, вибір даних із набору Z здійснюється у фіксованому або випадковому порядку.

На практиці застосуємо інший поширений критерій зупинки навчання мережі у вигляді фіксованої кількості ітерацій. Цей вибір зроблено для оцінювання та порівняння часу навчання у сформованих просторах даних.

У результаті навчання отримуємо систему центрів, яка адаптована для розпізнавання довільних структурних описів на підставі навчальної вибірки бази еталонів.

Вибір метрики на етапі 3 визначається простором дескрипторів і способом формування центрів.

Для бінарних дескрипторів ORB будемо застосовувати метрику Хемінга. Для здійснення навчання мережі Кохонена у експериментах використано

квадрат евклідової метрики, зважаючи на те, що для бінарних ознак значення метрики Хемінга та евклідової відстані ідентичні.

Якість класифікації безпосередньо залежить від результатів навчання системи і від наявного набору структурних описів навчальної вибірки.

Зосередимося на можливих прикладних варіантах модифікованого визначення простору навчальних даних у вигляді:

а) множини дескрипторів для кожного зразка;

б) множини дескрипторів зразків, для яких попередньо застосовано статистичні процедури формування центрів класів [12, 32];

в) системи центрів для кожного зразка класу. Даний варіант відрізняється від б) тим, що для класу формується система центрів на основі кожного із зразків;

г) впровадження процедури згортки для системи центрів кожного зразка.

Варіанти в) та г) здійснюють більш поглиблений аналіз, враховуючи особливості кожного із зразків як представників класу.

У процесі навчання мережі Кохонена при проведенні експериментів використано ненормалізовані дані, щоб підтримувати достатню відстань між нейронами задля забезпечення ефективного розділення класів.

Ефективність класифікації візуальних об'єктів за набором ключових точок із використанням мережі Кохонена безпосередньо залежить від таких фундаментальних взаємопов'язаних факторів: база даних як множина дескрипторів, простір даних для навчання, застосовані методи попередньої обробки (метод формування дескрипторів чи початковий вибір центрів), метрика для порівняння дескрипторів, розмір кортежу адаптованих у ході навчання нейронів.

Критерієм для оцінювання якості класифікації (значення помилки) виберемо величину, що підраховує частку елементів навчальної вибірки Z , що за результатом класифікації потрапили «не в свої» класи [4, 12]. Задамо критерій як

$$\beta = \sum_{j=1}^J (s_j - a_j) / s, \quad (1.2)$$

де a_j – число ознак із загального їх числа s_j в описі еталона Z^j , віднесених у процесі класифікації до класу j .

Значення β відображає рівень помилкових рішень при класифікації. Чим ближче β до нуля, тим вище досягнуто якість класифікації на навчальній вибірці.

Проаналізуємо три базових варіанти побудови класифікатора, що відрізняються числом нейронів, які модифікуються в процесі навчання:

- налаштовується тільки нейрон-переможець;
- модифікуються три нейрона, найближчі по відстані до нейрона-переможця;
- модифікується повна мережа нейронів відповідно до відстані до нейрона-переможця.

Оцінимо результативність розпізнавання із застосуванням цих варіантів навчання мережі Кохонена у залежності від різних за глибиною аналізу даних параметрів управління мережею.

Зазначені варіанти навчання класифікатора принципово відрізняються лише за етапом 4, де по-різному обчислюється функція $h(j, d, t)$. Для досягнення збіжності повинна бути виконана умова $h(j, d, t) \in [0, 1]$. Однак, варіант, коли налаштовується лише нейрон-переможець, реалізує грубе розпізнавання. Варіант, де модифікуються три нейрона, найближчі по відстані до нейрона-переможця, відносить кожний досліджуваний елемент до одного із трьох найближчих центрів. Варіант, де модифікується повна мережа нейронів відповідно до відстані до нейрона-переможця, здійснює найбільш повноцінне оброблення, відносячи аналізований дескриптор до усіх центрів класів одночасно, але з різними вагами, пропорційними відстані [31].

З огляду на бінарне подання дескрипторів ORB застосуємо побітове оброблення і на етапі попереднього оброблення для кожного еталонного опису Z^j визначимо вектор центру класу на основі логічного правила, яке порівнює загальну кількість одиниць для кожного з 256 бітів усієї множини дескрипторів опису з половиною від їх числа:

$$m_j(b) = \begin{cases} 1, & \sum_{d=1}^{s(j)} x_d(b) \geq s(j)/2, \\ 0, & \sum_{d=1}^{s(j)} x_d(b) < s(j)/2, \end{cases} \quad x_d \in Z^j, \quad b = 1, \dots, 256, \quad (1.3)$$

де $x_d(b)$ – біт із номером b дескриптора та номером d в описі еталону.

Відповідно до (1.3) значення кожного з бітів для центру m_j визначається значеннями бітів загальної множини дескрипторів, що належать еталону з номером j . Центр (1.3) відображає статистичні властивості еталона чи класу. Під час дослідження центри (1.3) застосуємо для визначення простору навчальних даних у варіантах класифікації б) та в).

Важливою характеристикою для варіантів а) та б) навчання мережі Кохонена є час навчання задля забезпечення ефективності класифікації.

Потенційна необхідність збільшувати кількість ключових точок, через те, що ORB та інші детектори інколи вибирають ключові точки, які не сприяють результативній класифікації зображення, вносить вимогу розглянути альтернативи за методом (1.3), що зводиться до порівняння отриманих центрів. Це дає можливість нейронній мережі значно скоротити час навчання та класифікації. Іншим варіантом є збільшення числа сформованих ключових точок та використання методів попередньої обробки для отримання опису зображення.

Основний функціонал нейромереж – це узагальнення системи ознак для зображення [18, 31]. Найбільше це стосується згорткових нейромереж, де цілеспрямованим обробленням, що властиве для методів комп'ютерного аналізу зображень, досягається суттєве скорочення загальної кількості параметрів мережевої моделі з метою мінімізувати перенавчання мережі.

Інтерпретуємо зображення, що описане бітовими образами дескрипторів еталону Z^j , у вигляді карти ймовірностей

$$p^j = \left[\sum_{d=1}^{s(j)} x_d(b) \right] / s(j), \quad (1.4)$$

що у значеннях вектору p^j інтегрує просторову інформацію опису Z^j шляхом додавання значень бітів дескрипторів для отримання скороченої моделі вхідних даних.

Вектор p^j узагальнює характеристики зображення через подання частоти появи одиниці в кожному з 256 бітів дескриптору ORB.

Подаємо нормовані вектори (1.4) на вхід мережі Кохонена і тренуємо мережу тільки на них. Класифікація за варіантом г) також ґрунтується на значеннях (1.4).

На рисунку 1.1 наведено приклад значень вектору (1.4) для тестового зображення.




Рисунок 1.1 – Приклад вектору p^j

Вектори p^j можна використовувати для довільних типів мереж, що значно знижує час навчання мережі Кохонена за рахунок обробки одного вектору там, де традиційно оброблялися сотні векторів.

1.2 Експериментальне дослідження класифікаторів із самонавчанням

Для реалізації запропонованих модифікацій класифікатора обрано середовище Visual Studio 2019 та засоби бібліотеки OpenCV [21].

Бібліотека OpenCV має більше 2500 програмних модулів, які включають набір традиційних та сучасних алгоритмів комп'ютерного зору, а також бібліотеки програм машинного навчання. Для проведення експерименту вибрано чотири категорії зображень, які показано на прикладі бази Leeds Butterfly [36, 37] (рис. 1.2).

Рисунок 1.3 містить приклад координат сформованих ключових точок, показаних у вигляді кружків. Зображення метеликів є унікальним об'єктом для наукового дослідження, оскільки візуально різні метелики мають як суттєво відмінні, так і ряд спільних властивостей.




Рисунок 1.2 – Тестові зображення



Рисунок 1.3 – Приклад зображення з координатами ключових точок

Оцінимо ефективність класифікації з опціями мережевого навчання та різною глибиною аналізу даних. Критерієм результативності вибрано (1.2). Під час експерименту протестовано два варіанти числа дескрипторів на кожному еталоні: 400 та 100 задля вивчення їх впливу на швидкодію. У комбінації з параметром числа дескрипторів на еталон протестовано два варіанти для кількості епох мережі Кохонена 100 та 200 задля пошуку та досягнення балансу швидкодії та точності.

Апробовано збільшення числа ітерацій до 300 або 400, отриманий результат показав відсутність зростання результативності класифікації, в той час як час навчання мережі Кохонена суттєво зростає.

Встановлено, що варіанти з підстроюванням виключно нейрона-переможця чи трьох нейронів, найближчих за відстанню до нейрона-переможця, дають можливість виконувати розпізнавання швидше або точніше.

Досліджено запропоновані варіанти а) – г) варіантів навчання мережі Кохонена та класифікації за 4 класами з використанням 4 категорій еталонів (рис. 1.2).

Виявлено, що час навчання досліджуваної мережі залежить від таких факторів:

- кількості епох;
- числа дескрипторів на кожний еталон;
- числа нейронів, які змінюються у процесі навчання мережі.

Проведено ряд дослідів із фіксованою кількістю ітерацій навчання мережі Кохонена. Кількість дескрипторів для кожного еталону коливалася у межах 375...400.

Результати дослідження варіанту а) за множиною дескрипторів ORB для тестового прикладу (рис. 1.2) показали, що цей підхід не дає можливості результативно класифікувати еталони, так як визначене класифікатором число ключових точок із опису класу не є максимальним.

Значення критерію $\beta = 0,65$, при цьому оціночний час роботи удосконаленого методу склав 14,94 с. Це аргументує застосування трансформації простору даних опису у вигляді підходів попереднього оброблення або побудови центрів із метою покращення ефективності.

Процедура навчання для варіанту б) проведена на двох різних зображеннях кожного із 4 еталонів (рис. 1.2). Кількість ключових точок коливалася у межах 378...400, а число ітерацій – 200. Загальний час класифікації склав 4,98 с, значення помилки $\beta = 0,31$.

Проаналізувавши дані таблиці 1.1, виявлено високу ступінь розрізнення: максимуми значень голосів знаходяться на діагоналях і значно перевищують інші елементи, тобто усі еталони класифіковані вірно. Як бачимо, використання мережі Кохонена з параметром центрів (1.3) значно знижує похибку класифікації: з 0,65 для методу а) до 0,31 для методу б).

Проаналізуємо результативність класифікації із застосуванням варіантів навчання мережі, які різняться за глибиною аналізу у залежності від числа настроюваних нейронів, протестуємо різну кількість дескрипторів для кожного еталону, а також різну кількість ітерацій навчання мережі.

Таблиця 1.1 – Результат класифікації за методом б)

Еталони	Класи			
	1	2	3	4
Z^1	279	33	27	61
Z^2	58	288	25	29
Z^3	36	91	228	23
Z^4	88	9	3	300

Для варіантів з кількістю у 400 дескрипторів на еталон помилка класифікації коливалась у межах 0,33 – 0,28. Для варіантів зі 100 дескрипторами помилка природно збільшилась і становила 0,46 – 0,29. Отже, основною

залежністю є результативність від числа ітерацій мережі. Найкращі результати отримані для 400 дескрипторів, де навіть при незначному числі ітерацій мережі Кохонена (100) вдалося досягти показника помилки 0,28.

Зміна кількості (1 чи 3) адаптованих нейронів майже не впливає на показники навчання мережі Кохонена, але вона ефективна стосовно помилки класифікації та числа помилково класифікованих даних. Модифікація одного нейрону практична тільки для 200 ітерацій та значному числі дескрипторів. Навіть при цих умовах помилка класифікації на 10% більша, ніж у відповідних варіантах із модифікацією 3-х нейронів, кількість помилок зросла від 0 до 2. Найкращий результат отримано на 200 ітераціях за 3 нейронами, при цьому коректно класифіковано всі класи еталонів з помилкою 0,23.

Оціночний час роботи для варіантів із 400 дескрипторами склав 13,7 с – 16,21 с, для варіантів зі 100 дескрипторами 6,2 с – 7,9 с. Встановлено, що метод б) показав найвищий рівень розрізнення у порівнянні з іншими, однак, при цьому він потребує значних обсягів часу навчання.

Крім того, експерименти показали, що час оброблення у методі в) вдалося значно знизити у порівнянні з іншими методами, він склав 2,27 с – 2,77 с, помилка коливалась у межах 0,20 – 0,34.

Виявлено, що основний вплив на результативність та час класифікації має кількість дескрипторів у еталоні та число ітерацій.

Найкращі результати отримані при 200 ітераціях, навіть при використанні 100 дескрипторів помилка склала лише 0,2.

Слід зазначити, що зміна кількості адаптованих нейронів практично не впливає ні на показники часу роботи мережі Кохонена, ні на результативність класифікації.

У варіанті г) застосуємо визначення (1.4) і обчислимо для дескрипторів кожного еталона вектор ймовірностей появи одиниці в кожному біті. Помилка для найкращих варіантів роботи мережі (400 дескрипторів та 200 ітерацій) суттєво знизилася до 0,06, невірно класифікований лише один еталон. Встановлено, що при зниженні кількості дескрипторів помилка зростає до 0,34, а зниження кількості ітерацій до 100 призводить до якості класифікації – 0,20.

Отже, отримані результати показали чітку залежність між показниками класифікації та кількістю дескрипторів у описі еталону. Число ітерацій також є важливим параметром, що посилює класифікаційні можливості мережі, а кількість адаптованих нейронів при даних умовах експерименту та змісту аналізованих зображень майже не впливає на результат.

Метод г) на основі (1.4) значно скорочує час роботи нейронної мережі у порівнянні з другими методами без погіршення якості. Якість класифікації для варіантів в) та г) майже співпадає.

При цьому час оброблення вдалося знизити майже у 8 раз (з 16,21 с до 2,82 с для варіантів з аналогічною якістю), що надає можливість використовувати запропонований підхід г) для великих баз зображень, у застосунках реального часу, при обробленні відеосигналів, тощо. Зазначений час потенційно дозволяє обробляти кожен десятий кадр відео з частотою оновлення – 60 кадрів в секунду.

Отримані дані про час навчання мережі та значення помилки класифікації зведено у таблиці 1.2. Бачимо, що використання засобів навчання мережі Кохонена для розрахунку центрів значно знижує похибку класифікації.

Таблиця 1.2 – Оціночний час навчання мережі Кохонена та середнє значення помилки β

	Метод			
	а)	б)	в)	г)
Час роботи, с	14,94	4,98	2,52	2,82
Середнє значення помилки β	0,65	0,31	0,27	0,06

Проведені експерименти підтвердили здатність успішно адаптувати мережу Кохонена до довільних наборів візуальних даних, особливо у разі успішного формування початкових центрів класу або виконання процесу попередньої обробки дескрипторів.

Описані результати порівняльного аналізу розроблених методів навчання та класифікації зображень на його основі для експериментальних зображень бази Leeds Butterfly при різних параметрах функціонування класифікаційної мережі Кохонена. Дослідження підтвердило здатність універсально адаптувати параметри мережі для довільних візуальних даних, особливо результативними є трансформації з використанням статистичних центрів класів та згортання даних на етапі попереднього оброблення.

Найкращу результативність показали методи із формуванням системи центрів для кожного зразка класу та використанням згортки даних, причому застосування згортки суттєво збільшує швидкість оброблення даних у порівнянні з іншими варіантами.

Новизна дослідження полягає в удосконаленні методів структурної класифікації з використанням мережі Кохонена шляхом впровадження нового

простору даних опису на базі системи центрів еталонів та згортання даних, що сприяє забезпеченню високої результативності класифікації при достатній швидкодії та дає можливість використовувати модифіковані методи у комп'ютерних застосунках реального часу.

Практичну значимість роботи складають отримані моделі програмного забезпечення для оцінювання ефективності класифікаторів у системах комп'ютерного зору, підтверджена ефективність розробок у прикладах баз даних зображень.

Подальше поліпшення продуктивності може бути досягнуто за рахунок підходів навчання з учителем, оскільки класи для дескрипторів бази даних відомі. Однак, зрозуміло, що таке врахування додаткової інформації потенційно ускладнює оброблення та впливає на швидкодію.

1.3 Класифікація зображень із впровадженням параметрів кластерного подання для структурного опису

Досягнення високих показників результативності для методів класифікації у сучасних системах комп'ютерного зору потребує вирішення ряду нагальних проблем, пов'язаних із багатовимірною природою даних.

При впровадженні структурних методів класифікації описи візуальних об'єктів подаються у вигляді множини дескрипторів ключових точок – числових векторів високої розмірності [1-12].

Описи із бінарними компонентами з використанням детекторів ORB, BRISK містять відповідно 256 бітів та 512 бітів. Число дескрипторів у складі опису досягає від 500 до 1500 елементів.

У такій ситуації трансформація простору ознак шляхом подання у вигляді кластерної системи сприяє значному спрощенню їх прикладного впровадження.

Основним інструментом при цьому є апарат кластерного аналізу даних, який базується на встановленні метричних відношень на множині дескрипторів опису і визначенні близьких за значенням груп із опису об'єкта та еталонів [19, 20, 28, 34, 35, 36].

Не менш важливою проблемою є вибір моделей для встановлення відповідності між параметрами кластерного подання різних описів.

До таких параметрів відносять центр кластеру, який може визначатися на підставі ряду підходів, основними серед яких є медоїд множини та модифікації середнього значення [12]. Ці дослідження пов'язані з напрямом Content Based Image Retrieval (CBIR) [38, 39] у розвитку систем комп'ютерного зору.

Зазначений підхід націлено на впровадження інтелектуальних технологій розпізнавання на основі вмісту зображення із ієрархією представлення наявної інформації. Формування опису даних у вигляді множини дескрипторів КТ, а також кластерне подання опису виступають засобами узагальнення задля синтезу продуктивних рішень високого рівня.

Обчислювальна перевага класифікації за множиною центрів кластерів опису у порівнянні з традиційним підходом класифікації безпосередньо за дескрипторами опису обґрунтовується тим, що замість обрахунку релевантності множин визначається релевантність на основі їх обмеженого числа характеристик.

Якщо потужність опису із дескрипторів КТ сягає від 200 до 300 (а іноді і до 1000) елементів, то кількість центрів може бути зменшена до 2-10 елементів такої ж розмірності.

Релевантність обчислюється шляхом аналізу об'ємної множини еталонів, що у прикладних задачах досягає значень від 100 до 1500, тому виконана трансформація суттєво (у тисячі разів) скорочує обсяг необхідних обчислень. Таке прискорення спричиняє необхідність здійснювати кластеризацію даних розпізнаваного об'єкта та деяке зниження ступеня розрізненості. Це відбувається за рахунок формування та застосування узагальнених характеристик – набору центрів опису. Кластеризація еталонних даних бази при цьому виконується на підготовчому етапі і на швидкодію класифікації безпосередньо не впливає.

Грунтовний аналіз інформації про описи еталонних даних можна реалізувати процесом оброблення, де для кожного опису необхідно сформувати незалежну систему кластерів [29]. У результаті незалежного оброблення можна синтезувати індивідуальні центри кластерів для кожного еталону. Такий підхід сприятиме більш глибокому виявленню відмінностей та підвищенню ефективності класифікації.

У роботах [1-12] вивчаються міри подібності між прецедентом та ситуацією, що задані множиною факторів, а у [9, 29] розглядаються моделі та процес встановлення релевантності для просторових структур ознак, синтезованих на множині КТ.

Посилення впливу індивідуальних факторів як параметрів системи незалежних кластерів дає можливість створити інформаційну систему. Структура системи передбачає, що класифікаційне рішення незалежно (і можливо паралельно) для кожного еталону приймається комітетом. Кожний елемент адаптований виключно до свого еталонного образу [28]. Системи розпізнавання з архітектурою, що включає вибір оптимального представника

комітету, за рахунок незалежного і узгодженого оцінювання, як правило, мають прикладну ефективність.

Метою є вивчення ефективності різновидів структурного методу класифікації зображень на підставі формування кластерних систем ознак шляхом впровадження моделей для визначення релевантності трансформованих описів із використанням апарату голосування та оптимального зіставлення.

Задачами дослідження є опрацювання моделей даних задля обчислення релевантності описів за показниками кластерного подання, ефективного за швидкодією оброблення даних, а також вивчення результативності впровадження цих моделей за наслідками експериментального оцінювання запропонованих підходів для прикладної бази зображень [9, 33].

Розглянемо базу E описів зображень еталонів розмірністю $N: E = \{E_1, E_2, \dots, E_N\}$. Кожен еталонний опис E_i представляє у задачі розпізнавання окремий клас та має вид скінченної множини дескрипторів КТ зображення: $E_i = \{e_v(i)\}_{v=1}^s$, де s – число дескрипторів КТ у описі.

Кожний дескриптор $e_v(i)$ характеризує деякий окіл КТ зображення та є елементом векторного простору R^n скінченної розмірності $n: e_v(i) \in R^n$ з дійсними, цілими або бінарними компонентами. Потужності описів еталонів вважаємо рівноцінними для спрощення аналізу:

$$\text{card}(E_1) = \text{card}(E_2) = \dots = \text{card}(E_N) = s.$$

Виконання цієї умови завжди можна практично досягти відбором елементів із множини більшого розміру.

Застосуємо відображення $E \rightarrow T$ із простору образів (множини дескрипторів) у множину T непересічних кластерів, сформованих за деяким принципом. Кластер – це підмножина опису. Кожний образ E_i еталону тепер трансформується до M його непересічних підмножин $T_k(E_i)$:

$$E_i = T(E_i) = \bigcup_{k=1}^M T_k(E_i), \quad k = \overline{1, M}, \quad T_k(E_i) \cap T_j(E_i) = \emptyset. \quad (1.5)$$

За множиною $T_k(E_i)$ елементів кожного кластеру визначимо його параметр центру $b_{k,i}$, $k = \overline{1, M}$, який є ключовою характеристикою побудованої кластерної системи для аналізованих даних. Зауважимо, що кластеризація та центри $b_{k,i}$ можуть бути визначені на підставі достатньо широкого різноманіття процедур [18, 31, 36, 40].

У результаті кластерного подання образ E_i еталону сформовано у вигляді M непересічних підмножин-кластерів $T_k(E_i)$ з центрами $b_{k,i}$, $M * N$ – загальне число створених кластерів та центрів для бази еталонів.

Розпізнаваний візуальний об'єкт аналогічно опишемо скінченною множиною $Z = \{z_v\}_{v=1}^s$, де $z_v \in Z$ – дескриптори КТ, $s = \text{card } Z$.

Подібно обробленню еталонів застосуємо кластерне розбиття множини Z через відображення $Z \rightarrow T$, у результаті опис зображення об'єкту буде представлено M кластерами:

$$Z = T(Z) = \{T_k(Z)\}_{k=1}^M, T_k(Z) \cap T_j(Z) = \emptyset. \quad (1.6)$$

Для кожного кластеру $T_k(Z)$ визначимо параметри центрів $b_k(Z)$, які застосуємо у процесі класифікації. Для спрощення вважаємо число M кластерів тотожним для вхідного зображення та еталонів.

Розглянемо класифікацію виду «об'єкт – еталон» на підставі обчислення значення релевантності їх структурних описів. Замість комплектної множини елементів описів застосуємо прискорену схему класифікації на підставі використання центрів b_k системи кластерів об'єкту і еталону.

Визначення релевантності еталон-об'єкт реалізуємо як зіставлення множин центрів об'єкта та еталонів з подальшим визначенням найбільш релевантного представника серед еталонів бази.

Введемо у векторному просторі R^n деяку відстань ρ . Прикладом може бути евклідова або манхеттенська відстані, а у бінарному просторі векторів – більш ефективна за обсягом обчислень метрика Хемінга [12].

Підрахуємо $M \times M$ усіх відстаней $\rho(T_{k_1}(Z), T_{k_2}(E_i))$, $k_1, k_2 \in [1, 2, \dots, M]$ між кластерними системами еталонів та розпізнаваного об'єкта шляхом обчислення відстаней $q = \rho(b_{k_1}(Z), b_{k_2}(E_i))$ між елементами множин центрів об'єкта та i -го еталону і означимо їх як $\{q_a\}$, $a = 1, 2, \dots, M^2$. На основі значень множини $\{q_a\}$ можна із застосуванням традиційних підходів обчислити відстані між множинами: середнього зв'язку, ближнього сусіда, далекого сусіда, Хаусдорфа та інші, або їх численних модифікацій, пов'язаних із логічним аналізом чи обробленням значень q_a [15, 29]. Відстань середнього зв'язку тут має вид

$$\rho_{av}(T_k(Z), T_k(E_i)) = \frac{1}{M^2} \sum_{a=1}^{M^2} q_a. \quad (1.7)$$

Одна із модифікацій для визначення відстані обчислюється шляхом додавання трьох найменших елементів попередньо ранжованої вибірки $q^* = q_1 \leq q_2 \leq \dots \leq q_{M^2}$ для набору відстаней:

$$\rho_{3m}(T_k(Z), T_k(E_i)) = \sum_{a=1}^3 q_a^*. \quad (1.8)$$

Відстань (1.8) одночасно має властивості як диференційних, так і інтегральних метрик. Вона отримана у результаті додавання трьох незалежних мінімумів.

Як альтернативу (1.8) розглянемо додавання відстаней найближчого сусіда окремо для кожного з центрів об'єкту

$$\rho_{NN}(T_k(Z), T_k(E_i)) = \sum_{a=1}^M \min_{j=1, \dots, M} \rho(b_a(Z), b_j(E_i)). \quad (1.9)$$

Моделі відстаней (1.8), (1.9) не гарантують, що окремому центру об'єкту відповідатиме єдиний центр еталону. Визначення центру з такими властивостями спирається на застосування угорського методу для оптимального призначення кожному центру об'єкту найбільш прийнятному центру еталону [15].

Застосуємо угорський метод для оптимального встановлення відповідності між двома наборами кластерних центрів b_1, b_2 . Вони отримані для описів Z_1, Z_2 з урахуванням можливого впливу завад, що призводять до відхилень від їх ідеальних значень. Результатом впровадження угорського методу є формування максимального паросполучення для елементів двох множин з мінімізацією загальної вартості. Її можна оцінити у вигляді суми відстаней між парами окремих компонентів у b_1, b_2 . Процес зіставлення формально зводиться до оптимізаційної задачі

$$R(x) = \sum_{i=1}^M \sum_{j=1}^M \rho(b_{1i}, b_{2j}) x_{ij} \rightarrow \min, \quad (1.10)$$

де $b_{1i} \in b_1, b_{2j} \in b_2, x_{ij}$ – бінарна ознака, $x_{ij} \in \{0,1\}$, що дорівнює 1 у випадку відповідності i -го та j -го елементів.

Рішення задачі (1.10) при обмеженні на однозначність відповідності ознак із порівнюваних наборів

$$\begin{cases} \sum_{j=1}^M x_{ij} = 1 \forall i = \overline{1, M}, \\ \sum_{i=1}^M x_{ij} = 1 \forall j = \overline{1, M} \end{cases} \quad (1.11)$$

мінімізує загальну відстань (1.10) між наборами центрів b_1, b_2 .

Загальна кількість кластерних центрів у нашій задачі невелика (3...5), оптимальні методи можна вдало застосувати із незначними вимогами щодо швидкодії оброблення.

Зазначені загальноприйняті відстані та вирази (1.8), (1.9) для множин векторів можна було б застосувати і безпосередньо до описів E_i та Z , але із суттєво значнішим обсягом обчислень.

Класифікацію об'єкту за описом Z на підставі обчислених відстаней (1.7) – (1.9) між центрами аналізованих даних здійснюємо традиційно шляхом визначення найменшого серед значень для різноманіття еталонів

$$Z \rightarrow E_a : a = \arg \min_{i=1, \dots, N} \rho(T_k(Z), T_k(E_i)). \quad (1.12)$$

Незалежне кластерне подання для описів у базі еталонів сприяє також і спрощенню реалізації процедур класифікації виду «deskriptor об'єкту – еталон» стосовно окремих елементів опису розпізнаваного об'єкту.

Цей підхід є більш універсальним щодо забезпечення врахування можливої дії завад на зображенні та фільтрації у процесі класифікації появи хибних КТ, викликаних впливом завад. При цьому кластеризацію опису об'єкта, як правило, не застосовуємо (це також скорочує обчислювальні витрати). Кожний deskriptor опису об'єкта знаходить «свій еталонний клас» шляхом конкурентного зіставлення зі сформованою множиною $\{b_j(E_i)\}$ еталонних центрів.

Для кожного deskriptora $z_v \in Z$ об'єкту визначаємо найближчий серед усіх еталонних центрів $\{b_j(E_i)\}$ за процедурою ближнього сусіда

$$d = \arg \min_{i, j} \rho(z_v, b_j(E_i)), \quad d \in \{1, 2, \dots, N\}, \quad (1.13)$$

де ρ – відстань між deskriptором об'єкту та центром $b_j(E_i)$, $i \in \{1, 2, \dots, N\}$, $j \in \{1, 2, \dots, M \times N\}$.

Фактично (1.13) реалізує багатозначну характеристичну функцію $d : R^n \rightarrow \{1, 2, \dots, N\}$, що визначає еталонний клас щодо окремого deskriptora із опису об'єкта.

За результатом (1.13) $\forall z_v \in Z$ підраховуються кількості r_1, r_2, \dots, r_N голосів елементів $z_v \in Z$, віднесених до одного із центрів $\{b_j(E_i)\}$ опису E_i :

$$r_i = \sum_{v=1}^S f[z_v \rightarrow \{b_j(E_i)\}], \quad (1.14)$$

де f – логічна функція, що визначає віднесення елемента z_v до центру з номером j кластера еталону E_i .

Процедура реалізації функції f задля забезпечення фільтрації завад повинна спиратися на значення порогу δ_f для величини мінімуму серед відстаней, обчислених до кожного з наявних центрів $\{b_j(E_i)\}$ кластерів для усіх еталонів [12, 29].

Образ об'єкту класифікується за отриманими значеннями r_1, r_2, \dots, r_N голосів як

$$Z \rightarrow E_j : j = \arg \max_i r_i. \quad (1.15)$$

Вхідне зображення за класифікацією (1.13) – (1.15) буде віднесено до еталону, який набере найбільше число голосів дескрипторів його КТ.

1.4 Аналіз результатів комп'ютерного моделювання для класифікації за кластерним поданням

Розроблені моделі класифікаторів застосовано на прикладі бази зображень покемонів [41].

Застосоване програмне середовище – IntelliJ IDEA 2020 та IDLE із використанням засобів бібліотеки OpenCV та мови програмування Java. Ілюстрація зображень показана на рисунку 1.4. Для моделювання застосовано дескриптори ORB розмірністю $n = 256$.

На рисунку 1.5 наведено приклад результатів кластерування зображення на 3 кластери методом k -середніх, де кольорами відмічено координати дескрипторів із різних кластерів. Можна помітити, що елементи всередині сформованих кластерів мають спільні властивості. Наприклад, практично усі контурні точки віднесено до одного кластеру (синій колір).

Суть програмного моделювання зводилася до прикладної реалізації двох видів класифікаторів:

- з використанням голосування дескрипторів (1.13) – (1.15);
- на підставі встановлення оптимального співвідношення між центрами кластерів (1.10) – (1.12).

Перший метод реалізує принцип класифікації «дескриптор об'єкта – еталон», а другий – «об'єкт – еталон». Обидва підходи спираються на незалежну систему кластерів, сформовану для кожного із еталонів.

Класифікація здійснювалася за схемою, коли множина дескрипторів (перший метод) чи набір центрів кластерного подання одного із еталонів (другий метод) зіставлялися із множиною центрів кластерів для 10 еталонів із бази.



Рисунок 1.4 – Приклади аналізованих зображень




Рисунок 1.5 – Результат кластерування для 3-х кластерів

Розглядалися варіанти описів із дескрипторів ORB кількістю в 300 КТ, 500 КТ, 1000 КТ та 1500 КТ.

Результати обчислень нормованої кількості голосів (у відсотках) для вхідних зображень рисунку 1.4 (еталони № 3, № 5, № 6) на множині 10 еталонів при $s = 500$ наведено у таблиці 1.3.

Отримані максимуми виділено маркером у таблиці 1.3.

Таблиця 1.3 – Результати класифікації першим методом

Вхідні зображення	Еталони									
	1	2	3	4	5	6	7	8	9	10
3	7,4	8,8	23,8	9,6	12,6	7	6,8	9,4	6,6	8
5	11	9,8	10,2	7,2	29,8	9,2	3,8	5,8	3,2	10
6	9,6	9,8	8,2	12	9,4	26	6,6	4,8	5,6	8

Перший метод успішно класифікує вхідні зображення, причому перевага максимуму над найближчим значенням у рядку (інші зображення бази) достатньо впевнена для усіх вхідних зображень.

Експерименти показали, що для вибраної бази еталонів число використаних дескрипторів КТ практично не впливає на результат. Для усіх розглянутих кількостей (300, 500, 1000, 1500) КТ отримано схожі показники.

Це можна пояснити інтегрованим поданням описів бази еталонів у вигляді фіксованих наборів центрів кластерів.

Результати класифікації у вигляді значення найкоротшої відстані із застосуванням другого підходу на базі угорського методу для визначення оптимального паросполучення між центрами кластерів вхідного зображення рисунку 1.4 (еталони № 3, № 5, № 6) та еталону (еталони № 1 – № 10) для 500 КТ наведені у таблиці 1.4.

Для опису вхідного зображення кластеризація здійснювалась повторно, інакше результат був би прогнозований із-за повного співпадання центрів. Отримані мінімуми виділено маркером у таблиці 1.4.

За результатом моделювання бачимо впевнену класифікацію для розглянутих еталонів. Значення обчисленої за угорським методом найкоротшої відстані суттєво менше у порівнянні з рештою еталонів. Найкраще при цьому класифікується еталон № 6 (третій рядок таблиці 1.4).

Таблиця 1.4 – Результати класифікації другим методом

Вхідні зобра- ження	Еталони									
	1	2	3	4	5	6	7	8	9	10
3	212	230	133	242	201	197	224	193	179	198
5	248	182	227	276	133	221	238	193	199	214
6	232	196	227	248	211	49	212	213	183	106

Аналіз експериментальних даних (таблиця 1.3 та 1.4) для розглянутої бази еталонів показує більш впевнену класифікацію першим методом у порівнянні з другим методом. Це можна пояснити більш детальним аналізом компонентів даних у першому методі. Другий метод базується виключно на інтегральних характеристиках описів за результатом кластеризації.

Експерименти підтвердили можливість результативного прикладного застосування оптимальних математичних підходів (угорський метод) для задач, де дані представлено у концентрованому кластерному виді. Безпосереднє застосування цих методів до вхідних даних у вигляді кількох сотень векторів дескрипторів неможливо із-за обмежень у часі реалізації.

За результатами програмного моделювання був оцінений обсяг часу для реалізації розглянутих методів. Основну частину роботи програми займає пошук та опис КТ за допомогою детектору ORB бібліотеки OpenCV. Параметр числа КТ суттєво не впливає на швидкодію другого методу (це його перевага), вона визначається виключно числом кластерів. Із зростанням числа КТ не критично збільшується час реалізації першого методу.

Час реалізації одного акту класифікації для обох методів коливався в межах 1,1 с – 1,5 с для досліджуваних даних зображень, числа КТ, методу кластеризації і використаного апаратного забезпечення.

Впровадження кластерного подання на множині дескрипторів опису сприяє покращенню часових характеристик класифікації за рахунок застосування центрів кластерів із забезпеченням необхідного рівня результативності.

Аналіз та оброблення згрупованих даних дає можливість сформувати ієрархічну структуру зі змінюваним параметром деталізації та виявленням значимих для класифікації властивостей опису зображення.

Новизна проведеного дослідження полягає в розвиненні методу структурної класифікації зображень за описом у вигляді множини дескрипторів ключових точок на основі впровадження незалежних кластерних структур даних для еталонів та використання їх параметрів для класифікації.

Практичні рекомендації із дослідження полягають у результативному застосуванні інтегрованих ознак для груп дескрипторів опису зображень, включаючи оптимальне прийняття класифікаційного рішення.

Практична значущість роботи:

– підвищення швидкодії при обчисленні релевантності образів та класифікації;

– підтвердження результативності запропонованих моделей ознак на прикладах зображень;

– розроблення прикладних програмних моделей для дослідження та впровадження методів класифікації у системах комп'ютерного зору.

Перспективи дослідження можуть бути пов'язані із більш глибоким вивченням сфери та умов застосування типів класифікації «дескриптор об'єкта – еталон» та «об'єкт – еталон».

2 СТАТИСТИЧНІ МОДЕЛІ ТА ЛОГІЧНЕ ОБРОБЛЕННЯ ДАНИХ У МЕТОДАХ КЛАСИФІКАЦІЇ ЗОБРАЖЕНЬ

2.1 Логічний аналіз даних при побудові мір подібності

Проблема забезпечення результативної класифікації зображень у межах фіксованої бази еталонів є надзвичайно важливою при впровадженні прикладних систем комп'ютерного зору [1-12]. У роботі [12] детально викладена постановка задачі класифікації для зображень, описи яких подано множиною дескрипторів ключових точок.

Перспективною ідеєю у плані підвищення швидкодії реалізації методів класифікації є використання поняття «центру опису» для зображень із бази еталонів, який обчислюється шляхом статистичного узагальнення значень дескрипторів, представлених у вигляді рядку бітів [33, 42]. Саме бітова структура дескрипторів опису, отриманих детекторами ORB або BRISK, дає можливість подальшого зменшення обсягів обчислень і спрощення апаратної реалізації автоматизованих систем класифікації зображень.

Одним із способів збереження достатньої результативності класифікації при узагальненні образу візуального об'єкта шляхом обчислення значень центрів описів є допоміжне застосування числового вектору вагових коефіцієнтів для структури бітів, що складають центр еталонного опису.

Метою даного дослідження є підвищення результативності класифікації за рахунок впровадження ефективних способів побудови та логічного оброблення вектору вагових коефіцієнтів для центрів описів зображення.

Завданнями роботи є побудова математичних моделей для визначення вагових коефіцієнтів, виведення їх логічного оброблення, програмне моделювання алгоритмів запропонованого оброблення, оцінювання ефективності класифікації із використанням запропонованих модифікацій.

Матеріали дослідження опубліковані в статті [5].

Нехай $Z = \{Z^j\}_{j=1}^J$ – множина дескрипторів бази зображень, яку складають описи Z^j еталонів, де J – число класів. Причому $Z \subseteq B^n$, де B^n – простір бінарних векторів (ланцюжків чи рядків) розмірності n . Позначимо $s(j) = \text{card } Z^j$ – кількість елементів у описі еталону Z^j . Число класів, що підлягають розпізнаванню, визначається кількістю J еталонів.

У межах апарату бінарних даних для визначення центру опису – бінарного вектору, що буде враховувати для класифікації еталонну множину Z^j як клас, застосуємо трансформацію множини дескрипторів. Двійкове подання дескрипторів надає можливість застосувати апарат логічного оброблення цифрових даних. Беручи до уваги, що ORB- та BRISK-дескриптори мають бінарний вигляд, для кожного із еталонів Z^j визначимо бінарний вектор m_j його центру опису на підставі логічного правила

$$m_j(a) = \begin{cases} 1, & f(Z^j, a) \geq s(j)/2, \\ 0, & f(Z^j, a) < s(j)/2, \end{cases} \quad (2.1)$$

де $m_j(a)$ – значення біту на позиції з номером a для центру m_j , причому $a = 1, \dots, 256$ – при застосуванні ORB-дескриптора, $a = 1, \dots, 512$ – при застосуванні BRISK-дескриптора;

$f(Z^j, a)$ – функція, що підраховує кількість одиничних бітів на позиції з номером a у множині дескрипторів еталону Z^j .

Функція $f(Z^j, a)$ може бути обчисленою безпосередньо додаванням бітів

$$f(Z^j, a) = \sum_{d=1}^{s(j)} x_d(a), \quad x_d \in Z^j, \quad (2.2)$$

де $x_d(a)$ – біт з номером a для дескриптора з номером d в описі еталона.

Відповідно до виразу (2.1) значення кожного з бітів центру m_j для j -го класу визначається переважною більшістю значень відповідних розрядів усіх дескрипторів ключових точок, що належать еталону Z^j . Підрахунок числа одиничних бітів (2.2) можна здійснити за допомогою відповідних бінарних функцій, використавши технології оброблення множин двійкових даних.

Розглянемо правило класифікації $L: B^n \rightarrow [1, \dots, J]$ у вигляді такої функції, що $\forall z \in Z$ виконується $L(z) \in [1, \dots, J]$ так, що кожний елемент буде зараховано до одного із еталонів Z^j . При цьому конструктивно та параметрично функція L опирається на апріорні дані конкретної бази зображень.

Важливо, що належність кожного із елементів $z \in Z$ до відповідного еталону всередині бази є заданою до початку класифікації. Таке подання у вигляді центру опису ключових точок зображення можна вважати результатом навчання з учителем [5, 12].

Для розроблення ефективного методу класифікації застосуємо дискретну модель простору B^n ознак, у якому для бази еталонів $\{Z^j\}$ попередньо сформуємо центр класу $m_j \in B^n$, $j = 1, \dots, J$.

У процесі вирішення задачі класифікації довільний вектор $b \in B^n$ будемо відносити до класу v з центром m_j у відповідності до значення найменшої відстані серед усіх центрів

$$v = \arg \min_{j=1, \dots, J} \rho(b, m_j), \quad (2.3)$$

де $\rho(b, m_j)$ – метрика у просторі B^n ознак.

Враховуючи обсяг необхідних обчислень для бітових даних, у виразі (2.3) найбільш ефективно застосувати метрику Хемінга, суть якої полягає у визначенні міри відмінності між двійковими векторами у векторному просторі кодових послідовностей. У цьому випадку відстанню Хемінга $\rho(b, m_j)$ між двійковими векторами b та m_j є число бітів, за якими вони різняться.

Отже, для підсилення класифікації двійкових векторів на універсумі B^n , де дескриптори об'єкта розпізнавання та зафіксованих еталонів не обов'язково повністю побітово співпадають, правило (2.3) необхідно параметрично доповнити предикатом Q логічного аналізу із застосуванням порогу: віднесення дескриптора ключової точки до класу v здійснюється тільки у тому випадку, коли для вектора b буде додатково виконано умову

$$Q[\rho(b, m_j) \leq \delta] = 1, \quad (2.4)$$

де δ – заданий поріг еквівалентності елементів у векторному просторі.

Важливо, що, якщо таке граничне обмеження не застосувати, то до визначеного класу, ймовірно, буде віднесено зовсім не схожий елемент, хоча мінімум в (2.3) буде у будь-якому випадку досягнуто.

Враховуючи особливості запропонованої процедури класифікації, скінченна множина дескрипторів $O = \{o_1, \dots, o_v\}$, $o_v \in B^n$, що описує довільний візуальний об'єкт, буде поданою у вигляді цілочисельного вектора голосів $h[O] = \{h_1, \dots, h_J\}$, де $h_j = \text{card} \{o_i \in O \mid o_i \rightarrow Z^j\}$ – кількість елементів, віднесених за правилом (2.3) до класу з номером j .

Одним із способів для визначення класу об'єкта є парадигма

$$d = \arg \max_{j=1, \dots, J} h_j. \quad (2.5)$$

Правило (2.5) безпосередньо можна застосувати тільки у ситуації, де для подання $h[Z^j]$ кожного із еталонів значення максимуму відповідає істинному номеру j еталона, що поступає на вхід системи класифікації. Якщо дана апріорна умова для даних бази еталонів не виконується, то необхідно застосовувати інші підходи [42]. Слід зазначити, що саме правила класифікації, побудовані на підставі (2.5), дають ефективну можливість суттєво спростити процес прийняття рішення, за рахунок того, що кожний із структурних елементів може бути природно класифікований без додаткового аналізу їх сукупних властивостей.

Запропонований підхід до визначення центрів еталонних класів забезпечує значне збільшення швидкодії класифікації (у деяких випадках у сотні разів) за рахунок переходу від обчислення міри релевантності множин до порівняння векторів дескрипторів та окремих їх елементів [3], що дозволяє врахувати суттєві ознаки під час оброблення зображень.

Модернізуємо механізм застосування центру опису для задачі класифікації шляхом введення вагових коефіцієнтів w_i для кожного із його бітів, попередньо визначивши нормований вектор $\lambda = \{\lambda_i\}_{i=1}^n$:

$$\lambda_i(Z^j) = \frac{1}{s(j)} \sum_{d=1}^{s(j)} x_d(i), \quad \lambda_i \in [0, 1], \quad (2.6)$$

де i – номер біту кожного із дескрипторів у описі Z^j .

Враховуючи те, що інформаційна значимість 0 та 1 у бінарному векторі даних природно однакова, пов'яжемо значення w_i із величиною біта, отриманого для центру опису за виразом (2.1):

$$w_i(Z^j) = \begin{cases} \lambda_i, & m_j(i) = 1, \\ 1 - \lambda_i, & m_j(i) = 0. \end{cases} \quad (2.7)$$

Таким чином, у кожного i -го біту $m_j(i)$ центру опису додатково встановлюється власний ваговий коефіцієнт w_i , який надає можливість при класифікації врахувати значимість окремо взятого біта, а саме належність його значення до 0 або 1 на множині дескрипторів усього опису. За допомогою запропонованого механізму більш значущими стають біти, які зустрічаються у дескрипторах опису ключових точок часто, та менш значущими – якщо зустрічаються інколи.

Відповідно до виразу (2.7) для кожного i -го біту дескриптора $m_j(i)$ центру опису отримуємо значення коефіцієнту $0 \leq w_i \leq 1$ незалежно від

значення біту самого дескриптора. У даному випадку важливим є лише факт збігу бітів, а ваговий коефіцієнт відображає ймовірність появи біту.

Під час вирішення задачі класифікації на етапі аналізу елементи $b \in B^n$ загального вмісту структурних описів бази еталонів (навчальна вибірка) віднесемо до відповідного центру класу з використанням (2.3), у якій замість відстані Хемінга для дійсних значень центру застосуємо зважену оцінку

$$\rho(b, m_j, w) = \sum_{i=1}^n \begin{cases} w_i, & b(i) = m_j(i), \\ 0, & b(i) \neq m_j(i). \end{cases} \quad (2.8)$$

Такий підхід є ефективним, якщо при обробленні даних для усіх описів із бази еталонів маємо $\forall j: j = \arg \max_d h[Z^d]$, тобто у поданні $h[Z^j]$ максимум у векторі h відповідає істинному номеру j .

Розглянемо ще одну модифікацію оброблення для кожного біту множини дескрипторів опису, де вагові коефіцієнти w_i будуть приймати дискретні значення 0 або 1 у залежності від величини їх відхилення від статистично обґрунтованого значення 0,5. Встановимо деякий поріг допустимого відхилення $r > 0$. Умовно назвемо цей підхід «блокуванням невеликих відхилень» з порогом r , що визначає межу дискретизації у моделі логічного аналізу. Трансформуємо вагові коефіцієнти w_i , обчисливши їх за такою моделлю:

$$w_i(Z^j) = \begin{cases} 1, & \lambda_i > 0,5 + r, \\ 1, & \lambda_i > 0,5 - r, \\ 0, & 0,5 \leq \lambda_i < 0,5 + r, \\ 0, & 0,5 - r \leq \lambda_i < 0,5. \end{cases} \quad (2.9)$$

Для експериментів вибрано значення $r = 0,05$.

Розглянемо спосіб обчислення відстані між дескриптором та центром, коли у моделях (2.6), (2.7) та (2.9) додатково аналізується два випадки:

- біт центру дорівнює відповідному бітові аналізованого дескриптора;
- біт центру не дорівнює бітові дескриптора.

У даному способі оброблення додавання вагових коефіцієнтів w_i , аналогічно до підрахунку відстані Хемінга, будемо виконувати тільки у тому випадку, коли біти різняться. Зважену міру подібності між дескриптором і центром визначимо як

$$\rho(b, m_j, w) = \sum_{i=1}^n \begin{cases} 0, & b(i) = m_j(i), \\ w_i, & b(i) \neq m_j(i). \end{cases} \quad (2.10)$$

Логічне оброблення даних із використанням порогу для обчислення подібності є основою прийняття рішень у задачах класифікації [12].

Зосередимо увагу на дослідженні наступних модифікацій визначення центрів та застосування відповідних мір подібності для класифікації дескрипторів за моделлю (2.3):

1. Застосування бінарних центрів (2.1) із відстанню Хемінга.

2. Використання вагових коефіцієнтів (2.6) – (2.8) із манхеттенською відстанню.

3. Блокування (2.9) невеликих відхилень від 0,5 із бінарними ваговими коефіцієнтами.

4. Використання вагових коефіцієнтів (2.6) – (2.8) із відстанню (2.10).

5. Блокування (2.9) невеликих відхилень від 0,5 із відстанню (2.10).

Принциповою відмінністю між підходами 3 та 5 є те, що у першому випадку для обчислення міри подібності між дескриптором та центром беруться до уваги усі значення вагових коефіцієнтів із врахуванням порогу невеликих відхилень, у другому випадку – тільки ті значення, при яких біти центру та аналізованого дескриптора різняться.

2.2 Аналіз результатів моделювання класифікаторів

Для експерименту із мережі Інтернет завантажено тестову вибірку чотирьох облич людей: двох жінок та двох чоловіків (рис. 2.1). Кожне із облич має по 2 варіанти (4 пари: 1, 5; 2, 6; 3, 7; 4, 8). Еталонами виберемо перші чотири зображення (1 – 4), а для класифікації візьмемо усі 8 зображень.

Як можна помітити, зображення рисунку 2.1 візуально дуже схожі між собою, що значно ускладнює їх класифікацію навіть людським зором.

Під час експерименту застосовано детектор BRISK, що передбачає обробку 512 бітів дескриптора, за допомогою якого визначено 41 ключову точку для кожного тестового зображення, отримані координати ключових точок зображені на рисунку 2.1.

Варіант 1 оброблення із застосуванням бінарних центрів (2.1) та відстанню Хемінга впевнено класифікував усі тестові зображення.

Таблиця 2.1 містить кількість голосів дескрипторів, що отримали кожне із чотирьох еталонів (№1 – №4). Як бачимо, діагональні елементи для тестових зображень №1 – №4 та №5 – №8 у стовпцях таблиці 2.1 значно перевищують решту, що свідчить про правильну класифікацію та ефективне застосування запропонованої моделі.




Рисунок 2.1 – Тестові зображення із координатами ключових точок

Таблиця 2.1 – Кількість голосів дескрипторів при застосуванні бінарних центрів

Еталон	Тестові зображення							
	1	2	3	4	5	6	7	8
1	31	7	1	1	22	10	8	0
2	0	24	2	8	2	19	5	9
3	3	5	34	1	2	10	28	6
4	7	5	0	31	15	2	0	26

Удосконалення моделі 2 із використанням вагових коефіцієнтів (2.6) – (2.8) та манхеттенською відстанню неправильно класифікувало лише зображення №6.

Аналогічно таблиці 2.1 отримано експериментальні дані для усіх розглянутих варіантів оброблення даних з точки зору результативності класифікації для запропонованої бази зображень. Варіанти оброблення 3 – 5 при цьому продемонстрували безпомилкову класифікацію. Експериментальна таблиця 2.2 містить значення частоти правильної класифікації для варіанту 5.

За даними таблиці 2.2 бачимо дещо незвичайний результат: зображення 7, що є візуально близьким до зображення еталону 3, класифіковано пропонованими варіантами оброблення 4 та 5 навіть впевненіше, ніж безпосередньо еталон 3!

Таблиця 2.2 – Частота правильної класифікації при варіанті 5 логічного оброблення

Еталон	Тестові зображення							
	1	2	3	4	5	6	7	8
1	0,76	0,22	0,1	0,1	0,59	0,36	0,01	0,07
2	0	0,61	0	0,22	0,1	0,61	0	0,3
3	0	0	0,88	0	0,07	0	0,99	0
4	0,24	0,17	0,02	0,68	0,24	0,03	0	0,63

Даний факт пояснюється тим, що зважену міру подібності між дескрипторами і центром визначено за моделлю (2.10), яка передбачає додавання вагових коефіцієнтів w_i тільки у тому випадку, коли біти різняться, це дозволило сконцентрувати класифікацію на найбільш суттєвих ознаках.

Таблиця 2.3 містить порівняльні показники досліджених модифікацій.

Таблиця 2.3 – Показники для моделей логічного оброблення

Показник	Варіанти оброблення				
	1	2	3	4	5
Швидкодія, с	6,0	8,2	9,6	8,4	10
Максимальна частота правильної класифікації	0,83	0,94	0,96	0,97	0,99

Як видно, за результатами якості класифікації та швидкодії оброблення даних не можна визначити однозначного лідера серед розроблених методів у порівнянні із традиційним варіантом 1, однак, враховуючи суттєві відмінності між максимальними частотами правильної класифікації за різними підходами (у діапазоні 0,83...0,99), найкращим виглядає варіант 5 удосконалень.

Найбільша помилка класифікації, що визначається значенням максимального із недіагональних елементів для розглянутого різноманіття моделей майже однакова і знаходиться у діапазоні 0,35...0,37.

Проаналізувавши таблицю 2.3, зроблено висновок, що у порівнянні із варіантом 1 за рахунок деякого ускладнення логічного оброблення вагових коефіцієнтів бітів швидкодія удосконалених методів дещо знижується, але ефективність правильної класифікації при цьому зростає.

Наприклад, для варіанту оброблення 5 швидкодія зменшилася на 4 с, а результативність класифікації покращилася на 0,16 у порівнянні із загальноприйнятим варіантом оброблення 1.

Враховуючи те, що запропоновані модифікації реалізують відмінні процеси оброблення даних, спираючись на відстань між дескрипторами та на вектор вагових коефіцієнтів, об'єктивним критерієм для оцінювання їх результативності може бути число правильно класифікованих дескрипторів або описів. За цим показником у проведених експериментах перевагу необхідно надати варіанту 5, що дещо перевершило підхід 4, а найгірші показники показав варіант 2.

Під час тестування запропонованих модифікацій виконано додаткові експерименти з метою вивчити ефективність класифікації за умови зміни параметрів детектора BRISK при визначенні множини та кількості ключових точок. Встановлено, що зі збільшенням числа дескрипторів для описів у межах від 30 до 60 для усіх варіантів оброблення, крім 2, спостерігається зменшення кількості неправильних класифікаційних рішень: з 8 для 30 ключових точок до 2 при 60 ключових точках. Для методу 2 цей показник практично не змінюється.

Детектор BRISK дає важливу для практики можливість керувати числом виділених ключових точок та добитися їх необмеженої кількості, однак, до них потрапляє цифровий шум, що спричиняє збільшення часових витрат.

При застосуванні модифікованих варіантів оброблення у методі класифікації є можливість керувати такими характеристиками, як параметри бінаризації, параметри детектору BRISK (засоби фільтрації, показник кутів та інші). Зазначені критерії можливо автоматично регулювати за допомогою вбудованої бібліотеки OpenCV для написання програмних скриптів. Дані фактори безпосередньо впливають на результат класифікації і адаптують класифікацію до змісту довільної бази зображень.

За результатами експериментів встановлено, що найбільш дієвими виявилися варіанти оброблення, що використовують вагові коефіцієнти із блокуванням відхилень та відстанню.

Даний результат обумовлено тим, що у їхніх розширених моделях спостерігається більший вплив тих бітів, які при побудові центра мали суттєву перевагу над протилежним бітом. Нестійкі значення, які знаходяться в околі порогу 0,5, менше впливають на результат класифікації.

Головною практичною перевагою розглянутих модифікацій є швидкодія, яка ґрунтується на зведенні зображення до бінарного масиву із 512 елементів, що пришвидшує класифікацію пропорційно числу ключових точок. Зіставлення центру опису еталону та центру опису об'єкта ще у десятки разів пришвидшує оброблення без погіршення результативності класифікації.

Новизна дослідження полягає у синтезі продуктивних модифікацій методу класифікації зображень із використанням апарату бітового аналізу даних та логічних моделей обчислення вагових коефіцієнтів для бітів опису у просторі дескрипторів ключових точок.

Практична значущість – отримання прикладних програмних моделей для оцінювання ефективності модифікацій методів класифікації з бінарним поданням даних і підтвердження їх результативності в прикладних базах зображень.

2.3 Статистичний аналіз складу компонентів структурного опису

Впровадження статистичних методів як апарату інтелектуального аналізу даних задля побудови класифікаторів для образів візуальних об'єктів у системах комп'ютерного зору націлене на забезпечення результативності вирішення прикладних задач.

Така реалізація виконується на підставі вивчення змісту, структури та властивостей еталонних даних, а також втілення цих знань у процес класифікації [12].

Останнього часу статистичні розподіли стали першорядним засобом аналізу даних у системах розпізнавання образів [19, 20, 33, 42].

Якщо опис розпізнаваного візуального об'єкту подано об'ємною множиною багатовимірних векторів, то статистичний апарат стає ключовим працездатним способом прийняття рішення про клас об'єкту.

Імовірнісні розподіли компонентів структурних описів у складі системи блоків для дескрипторів ключових точок показали свою високу результативність у аспекті якості класифікації та швидкодії оброблення.

У роботах [8, 12] детально розглянуто процедуру обчислення дескрипторів, побудову ймовірнісних розподілів на їх множині та деякі методи класифікації на основі розподілів. Виникає нагальна необхідність впровадження апарату розподілів у загальному виді для множини багатовимірних дескрипторів опису за встановленими класами даних, що визначаються заданою базою еталонів.

Навчання класифікатора у межах фіксованої бази зображень еталонів виступає у процесі класифікації як спосіб передачі інформації від нижніх (описи еталонів як множина дескрипторів ключових точок) до верхніх рівнів ієрархії даних (класифікація), що здатні узагальнювати знання нижніх рівнів. Даний принцип роботи підкреслює ефективність ієрархічного способу оброблення даних у запропонованих методах.

Метою є розроблення та вивчення властивостей класифікатора зображень на підґрунті побудови ансамблю розподілів для складу компонентів структурного

опису. Запропоновано використання інтегральних та незалежних моделей прийняття класифікаційних рішень. Такий підхід забезпечує результативну класифікацію у просторі образів як множини дескрипторів ключових точок.

У цьому підрозділі подано метод побудови моделей класифікації у синтезованому просторі даних, які підтвердили якість виявлених модифікацій аналізу даних на прикладах зображень [8].

Формальна постановка задачі класифікації із використанням опису зображення як множини дескрипторів ключових точок сформульована у [12, 14, 16]. У цих наукових працях також вивчаються особливості моделі подання образу як множини багатовимірних векторів та переваги застосування трансформацій структурного опису до простору ознак у вигляді статистичних розподілів.

Одним із ефективних статистичних засобів є кластерне подання та грануляція із використанням апарату нечітких множин [1-3]. Однак, результативність цих методів суттєво залежить від складу даних, крім того, вони вимагають додаткових обчислювальних затрат на етапі класифікації.

Застосування більш універсальних методів статистичної класифікації із базуванням на еталонній інформації сприяє не тільки узагальненню подання образів, а також і більш детальному виявленню ступеня узгодженості аналізованих та еталонних образів.

Статистичні підходи дають можливість вирішити одну із ключових проблем при впровадженні структурних методів – скоротити достатньо великий обсяг обчислювальних витрат при обробленні об'ємних векторних масивів.

Потужним засобом зниження розмірності стосовно задачі класифікації є застосування методів агрегації даних на підставі визначення центрів описів, як правило, у вигляді середнього чи медіани [12]. Незважаючи на деяку умовність цих характеристик, особливо у багатовимірному просторі, застосування центрів даних значно скорочує час оброблення, що підтверджують експериментальні результати [42, 43].

Зважаючи на структуру аналізованих даних у вигляді множини векторів, природно перспективним виглядає використання ансамблевих засобів оброблення [42]. У даному випадку результуюче класифікаційне рішення приймається на підставі множини локальних рішень для окремих дескрипторів. Ряд досліджень містить моделі для побудови ансамблевих рішень та оцінювання ефективності систем класифікації на підставі простих класифікаторів для окремих компонентів. При цьому обговорюються такі важливі переваги ансамблевих рішень, як стійкість до викривлень окремих складників та забезпечення вищої точності аналізу даних чи навчання.

Матеріал дослідження напряму не пов'язаний із підходами, що оцінюють текстурні ознаки (узори та ін.) [44-46], хоча і використовує апарат дескрипторів ключових точок, що відображають локальні особливості зображень. Наші розробки більше пов'язані із оцінюванням значущості окремих комбінацій для наборів дескрипторів, що призначено для універсального аналізу даних і націлено на виділення реальних об'єктів.

Розглянемо багатовимірний простір B^n усяких бінарних векторів розмірністю n , де будемо конструювати образи об'єкту і еталонів. Представимо мультимножину векторів $Z \subset B^n$, $Z = \{z_v\}_{v=1}^s$ як опис зображення візуального об'єкту у просторі множин дескрипторів ключових точок.

Розглянемо базу еталонів $E = \{E_1, E_2, \dots, E_N\}$ розмірністю N , $E_i = \{e_v(i)\}_{v=1}^s$, $s = \text{card } E_i$ – число дескрипторів у множині E_i , i – номер еталона у базі E . Ознаками об'єкту та еталонів є вектори $z_k \in B^n$, скінченна множина яких створює опис.

Задамо $\forall (z_k, z_\tau)$, $z_k \in B^n$, $z_\tau \in B^n$ відстань $\rho: B^n \times B^n \rightarrow [0, \infty]$ у векторному просторі B^n . Прикладом є Хемінгова метрика. Для бінарних даних заданої розмірності діапазон значень цієї метрики фіксований – $[0, n]$. Відстань є фундаментальним критерієм еквівалентності на множині дескрипторів. Вона віддзеркалює візуальну схожість піксельних околів ключових точок для функції яскравості зображення, яку відображає дескриптор [46]. Еквівалентність $z_k \equiv z_\tau$ для двох дескрипторів визначаємо на підставі деякого порогу δ_ρ для значення метрики:

$$z_k \equiv z_\tau : \rho(z_k, z_\tau) \leq \delta_\rho. \quad (2.11)$$

У базі еталонів $E = \{E_1, E_2, \dots, E_N\}$ кожен фіксований еталонний опис E_i репрезентує для класифікатора окремий клас та має вид скінченної множини дескрипторів ключових точок із B^n .

Задачею дослідження є побудова класифікатора $K: B^n \rightarrow [1, 2, \dots, N]$ на основі конструювання системи статистичних ознак за результатом навчання на матеріалі множини еталонів $E = \{E_1, E_2, \dots, E_N\}$.

Ідея побудови класифікатора така:

– для кожного дескриптора розпізнаваного об'єкту чи еталонів встановлюємо ступінь належності до наявних класів у вигляді статистичного розподілу;

– на підставі сформованої системи компонентних розподілів створюємо інтегровану ансамблеву міру релевантності опису аналізованого об’єкту та кожного із еталонів;

– застосовуємо створену міру у класифікаторі шляхом оптимізації значення релевантності у системі класів.

На підставі наявної бази описів еталонів шляхом навчання створюється новий простір образів компонентних даних у складі значень їх імовірнісної міри належності до класів.

Впровадження такого підходу на підґрунті використання рішення ансамблю компонентів забезпечує універсальність і вагому результативність класифікації.

Обчислимо на основі опису еталону $E_i = \{e_v(i)\}_{v=1}^s$ із бази E у n -мірному векторному просторі деякий «центр опису» $\alpha(i) = F(E_i)$ – агрегований вектор, що відображає властивості множини E_i

$$\alpha(i) = (\alpha_1(i), \alpha_2(i), \dots, \alpha_n(i)). \quad (2.12)$$

Центр опису α можна визначити, наприклад, шляхом обчислення середнього значення чи медіани для фіксованої множини векторів. Вектори $\alpha(i)$ виступають у даному випадку як статистичні характеристики для кожного із еталонів, покладемо їх в підґрунтя класифікації.

Окремий вектор $z_v \in Z$, $v = \overline{1, s}$, еталону і об’єкту можна формально розглядати як елемент ансамблю n -компонентних векторів

$$z_v = (z_{v,1}, z_{v,2}, \dots, z_{v,n}). \quad (2.13)$$

Для еталону E_i кожна компонента в (2.13) пов’язана з номером i .

Розглянемо спектр аналізованих даних у аспекті віднесення складового елемента опису до системи еталонних класів на підставі визначення деякої функції належності зі значеннями із діапазону $0 \dots 1$:

$$\mu: B^n \rightarrow [0,1], \mu(z_v, i) \in [0,1], \quad (2.14)$$

аргументами функції μ є дескриптор опису і номер класу.

Функцію належності μ визначимо на підставі основоположної характеристики в Data Science – співвідношення значень мір, що виражають число сприятливих випадків (подібність $\eta(z_v, i)$ до конкретного класу) та загального числа N випадків (сума подібностей до усіх наявних класів)

$$\mu(z_v, i) = \frac{\eta(z_v, i)}{\sum_{i=1}^N \eta(z_v, i)}. \quad (2.15)$$

Загальне число випадків задається кількістю N класів. Міра подібності $\eta(z_v, i)$ елемента до класу може бути задана через відстань ρ у векторному просторі до центра класу, наприклад, через манхеттенську метрику

$$\rho(z_v, i) = \sum_{k=1}^n |z_{v,k} - \alpha_k(i)|. \quad (2.16)$$

Для випадку, якщо $\alpha(i) \in B^n$, $z_v \in B^n$ замість (2.16) можна застосувати відстань Хемінга $\chi(z_v, i)$ (число не співпадаючих бітів) у просторі B^n , тоді подібність $\eta(z_v, i)$ буде визначена як

$$\eta(z_v, i) = n - \chi(z_v, i). \quad (2.17)$$

Для кожного елемента z_v за виразом (2.15) обчислимо значення вектора d його статистичного розподілу за множиною N класів

$$d = (d(1), d(2), \dots, d(N)), d(i) = \mu(z_v, i), \sum_{i=1}^N d(i) = 1. \quad (2.18)$$

Зі статистичної точки зору вектор d , що визначений для довільного дескриптору еталону чи об'єкту, виражає ступінь близькості значення дескриптора до кожного із класів.

Будемо розглядати матрицю $D = \{\{d_k(i)\}_{k=1}^s\}_{i=1}^N$, що аналогічно нечіткому поданню задає значення міри належності (2.15) для всіх компонентів аналізованого опису [1, 17, 47]. Значення s означає число дескрипторів у еталонній множині, причому величина s однакова для усіх еталонів і вхідного зображення. Рядок матриці D є розподілами за еталонними класами для окремого дескриптора вхідного зображення. Сума значень в окремому рядку дорівнює 1. Ми вважаємо, що таке обчислення розподілів близьке за сенсом до значень функції належності на множині еталонів у просторі образів.

Фактично матриця D визначає розподіл сукупностей даних за визначеними апріорі класами. Значення матриці D допускають випадок запровадити логічне оброблення вхідних даних на предмет видалення можливих завад (тобто хибних дескрипторів) шляхом аналізу значень відстаней (2.16) чи значень (2.18) з використанням порогу. У той же час цей аналіз може бути безпосередньо впроваджено у процесі класифікації.

На основі матриці D побудуємо класифікатор K , який для структурного опису довільного об'єкта реалізує відображення

$$K : D \rightarrow [1, 2, \dots, N] \quad (2.19)$$

із множини розподілів ансамблю компонентів даних у множину класів.

На початковому етапі збудуємо та застосуємо для перевірки працездатності розподіли (2.18) за класами даних безпосередньо для множини E_i еталонів

бази. Зрозуміло, що для кожного представника $E_i \in E$ класифікатор K повинен отримати як рішення номер відповідного еталону, опис якого поступає на вхід класифікатора. Це є першочерговим принципом адекватності функціонування класифікатора, який повинен впевнено розрізняти описи із множини еталонів (навчальна вибірка).

Наприклад, у розподілі даних для 1-го еталону (1-й стовпець матриці D) перша компонента повинна домінувати над іншими. Аналогічно для 2-го еталону домінуючим елементом розподілу повинен бути 2-й і т.д.

Розглянемо способи побудови класифікатора (рис. 2.2).

1. Визначення класу об'єкта за інтегральним розподілом компонентів. Визначимо стовпець матриці D з максимальною сумою елементів

$$K : j = \arg \max_i \sum_{v=1}^S d_v(i), \quad (2.20)$$

що інтегральним способом встановлює клас j об'єкту через агрегацію розподілів кожного із класів (окремий стовпець матриці D) за всією множиною складових опису. Класифікація (2.20) відповідає найбільш правдоподібному рішення, так як побудована на додаванні значень однотипних розподілів [42]. Загалом класифікатор (2.20) реалізує принцип аналізу «об'єкт – еталон» на підставі агрегації даних усього складу опису.

2. Визначення класу об'єкта за числом голосів компонентів.

Обчислимо максимальне значення для кожного рядка матриці D

$$c_v = \arg \max_{i=1, \dots, N} \{d_v(i)\}, \quad (2.21)$$

тобто визначимо окремо для кожного дескриптора опису найбільш вагомий класу за вектором розподілів, що відповідає параметру моди [12].

Для кожного дескриптора z_v опису Z за виразом (2.21) за значенням c_v інкрементуємо число h_i голосів елементів, віднесених до i -го класу

$$h_i = \begin{cases} h_i + 1, & c_v = i, \\ h_i, & c_v \neq i. \end{cases} \quad (2.22)$$

За результатом визначення (2.22) для всієї множини дескрипторів опису Z отримуємо вектор голосів

$$h = (h_1, h_2, \dots, h_N), \quad (2.23)$$

на підставі якого визначимо номер класу

$$j = \arg \max_b h_b, \quad (2.24)$$

що набрав максимальне значення серед усієї множини голосів дескрипторів об'єкту. Це метод голосування на множині дескрипторів, де клас визначається на підґрунті моди розподілу [7, 14-16].




Рисунок 2.2 – Схема класифікації за двома способами

У класифікаторі (2.21) – (2.24) реалізовано принцип аналізу «дескриптор об'єкта – еталон», де клас попередньо визначається для кожного компонента опису.

Розглянуті варіанти (2.20), (2.21) – (2.24) побудови класифікатора природно можна трактувати в рамках теорії ансамблевих моделей [28, 30, 39].

За рахунок створення та агрегування відгуків компонентних класифікаторів (локальних рішень) синтезується «сильний» класифікатор із гарантовано вищою результативністю прийняття рішень. Найбільше розглянуті підходи відповідають моделі бустінгу [28, 42].

За результатами досліджень ансамбль класифікаторів у більшості випадків забезпечує кращу точність аналізу даних чи навчання. Однак, він потребує вирішення ряду проблем, таких як збільшення часових та обчислювальних витрат, складність інтерпретації результатів, обґрунтування та вибір способів комбінування локальних рішень.

У нашому випадку набір локальних класифікаторів складається із базових моделей одного типу, тобто є однорідним.

Ансамблеве класифікаційне рішення Θ можна подати у вигляді комбінування скінченної множини локальних рішень θ_v

$$K : j = \arg \underset{i}{opt} \Theta[\{\theta_v(d_v(i))\}_{v=1}^s]. \quad (2.25)$$

Зазначимо, що у ансамблевих моделях аналізу зображень з метою врахування тільки значимих локальних рішень часто застосовують систему параметрів порогів [12]. Вона забезпечує відділення завад і загалом спрямована на підвищення надійності функціонування.

Наприклад, у модифікації класифікатора (2.21) – (2.24) клас $d_m = \max_{i=1, \dots, N} \{d_v(i)\}$ для локального рішення визначається тільки у випадку, якщо виконується умова, що порівнює значення оптимуму d_m з порогом δ_d або з найближчим до нього локальним оптимумом d_{m-1} :

$$d_m > \delta_d \text{ або } d_m > \lambda d_{m-1}, \quad (2.26)$$

де λ – числовий коефіцієнт.

У запропонованому підході ймовірності щодо належності до усіх наявних класів вираховуються у явному вигляді, це дає можливість додатково логічно обробити їх значення задля виявлення та врахування значущих відмінностей між класами.

Зауважимо, що поріг δ_d можна встановити за результатами навчання із вчителем на множині дескрипторів для еталонів. Отримане значення моди має бути не меншим від його значення для «свого» еталону.

Цей аналіз на етапі навчання класифікатора необхідно проробити для усіх еталонів і у якості порогу δ_d обрати серед усіх отриманих мод найбільше. Один із засобів підвищення результативності ансамблевих методів класифікації шляхом адаптації до наявних даних полягає в тому, щоб на підставі введення логічних процедур відібрати деяку концентровану (або найбільш інформативну) підмножину елементів, які стануть підґрунтям для класифікаційного рішення. Стосовно опису як множини дескрипторів КТ така процедура може полягати у відборі підмножини елементів, що знаходяться в межах заданої відстані від центру, або формування фіксованого числа елементів, найближчих до центру опису.

Нехай $Z \subset B^n$ – опис, $s = \text{card } Z$ – його потужність, тоді введемо процедуру L стиснення

$$L(Z) \rightarrow Z^*, \quad Z^* \subset B^n, \quad \text{card } Z^* = s^*, \quad s^* \ll s. \quad (2.27)$$

Застосування способу фільтрації (2.27) поряд із суттєвим скороченням часу обчислень часто сприяє покращенню показників класифікації. Стиснення L має бути безпосередньо націлене на відбір інформативної частини опису. Воно реалізується на етапі попереднього оброблення, тому на час здійснення класифікації не впливає.

За результатами попереднього оброблення повної бази E еталонних даних (множина усіх дескрипторів еталонів) на підставі матриці розподілів можна оцінити результативність застосування запропонованих методів класифікації на множині еталонних описів.

Наприклад, точність $Prec$ класифікації можна оцінити відношенням загального числа TP дескрипторів бази еталонів, для яких правильно визначено клас, до загального їх числа у відповідності до моделі [17]

$$Prec = \frac{TP}{TP + FP}. \quad (2.28)$$

Показник повноти $Comp1$ (частота істинно позитивних результатів) оцінимо як долю дескрипторів, правильно віднесених до класу (еталону)

$$Comp1 = \frac{TP}{TP + FN}. \quad (2.29)$$

Показники (2.28), (2.29) часто застосовують у системах машинного навчання.

2.4 Аналіз результатів моделювання статистичного подання

Моделювання виконано у середовищі PyCharm 2020 із використанням засобів бібліотеки OpenCV та мови програмування Python 3.6. Для визначення дескрипторів ключових точок застосовано детектор ключових точок ORB розмірністю $n = 256$.

Розроблені моделі класифікатора реалізовано на прикладі зображень метеликів із бази даних Leeds Butterfly [36, 37]. Розмір зображень склав 600×600 пікселів. Проілюстровано класи еталонних зображень (рис. 2.3) та координати сформованих ключових точок (рис. 2.4). Кількість обчислених дескрипторів у описі кожного із еталонів складає $s = 500$.

Підрахунком числа одиничних бітів у кожному розряді опису кожного із еталонів отримано вектори $\alpha(i), i = 1, 2, 3$, які логічним обробленням приведено до бінарного виду задля подальшого впровадження метрики Хемінга.

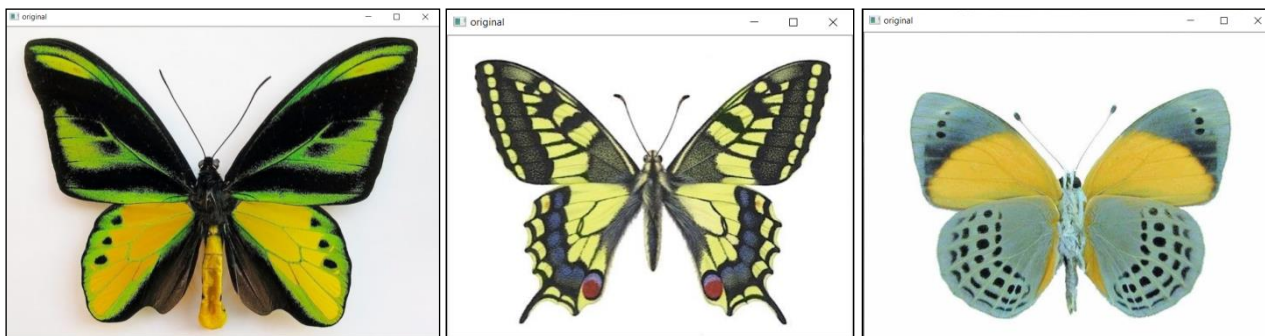


Рисунок 2.3 – Еталонні зображення метеликів Химера, Махаон, Давісій

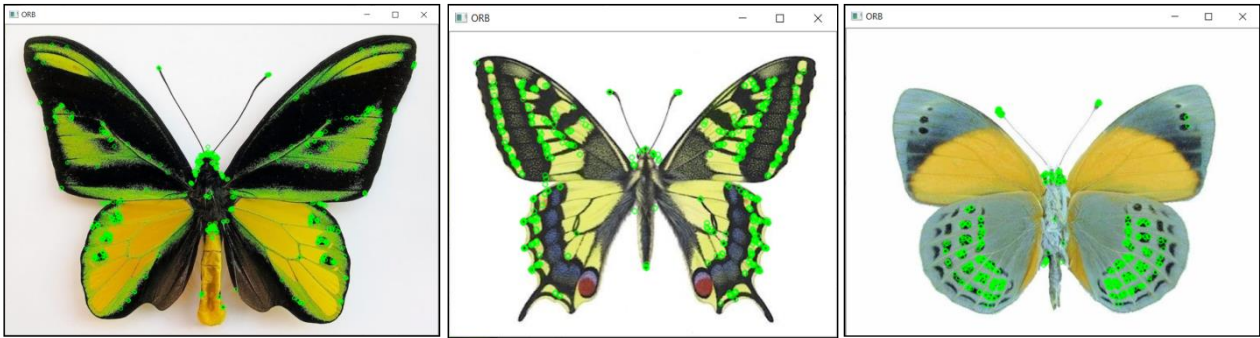


Рисунок 2.4 – Приклади виділених координат ключових точок дескриптором ORB (Химера, Махаон, Давісій)

Центри $\alpha(i)$ фактично визначались усередненням значень дескрипторів опису. Обчислені значення відстаней між центрами еталонів склали 56, 72, 72. Такий результат говорить про суттєву їх близькість у даному аспекті (28% від максимальної відстані). Адже значення відстані Хемінга між двома векторами аналізованих даних знаходяться у діапазоні $0, \dots, 256$.

У відповідності до моделі класифікації (2.20) отримано значення векторів сум у виразі (2.20), які склали відповідно:

- для 1-го еталону (Химера) – (173,01; 165,44; 161,51);
- для 2-го еталону (Махаон) – (165,45; 170,94; 163,65);
- для 3-го еталону (Давісій) – (164,97; 163,69; 171,18).

Усі еталони за методом (2.20) класифікуються вірно (максимум спостерігається у відповідній компоненті), але різниця між максимумом інтегрованого розподілу і найближчим до нього значенням досить незначна (у межах 3,5% – 4,5%). Це вказує на суттєву схожість образів у сформованому просторі ознак із використанням моделі (2.20).

За моделлю класифікатора (2.21) – (2.24) отримано трійки накопичених максимумів голосів (h_1, h_2, h_3) дескрипторів для кожного із еталонів: (281, 111, 108), (144, 249, 107), (140, 86, 274).

Із отриманих числових значень бачимо, що цей класифікатор більш впевнено здійснює розпізнавання зображень. Різниця між максимумом голосів та його найближчим конкурентом перевищує 42%, а для окремих еталонів (Химера, Махаон) досягає 60%. Це вказує на більш вагому перспективу застосування моделей класифікації «дескриптор об'єкту – еталон» у порівнянні з моделлю інтегрального аналізу (2.20).

Наші експерименти підтвердили, що запропонована процедура аналізу даних у значній мірі залежить від способу формування центрів $\alpha(i)$. Окреме дослідження проведено для визначення центрів за значенням медіани для

множини детекторів опису [43]. Відстань між медіанами різних еталонів коливається в ширшому діапазоні, ніж відстань між центрами-середніми значеннями. У нашому експерименті спостерігалось відхилення від максимальної відстані для медіан еталонів у межах 16%...46%. Таким чином, виявився факт, що медіана для множини дескрипторів (інша назва – медоїд) більш чутлива до змісту опису у порівнянні із середнім значенням.

У процесі досліджень для методу інтегрального аналізу (2.20) проведені експерименти з метою відбору інформативної підмножини (фіксованого числа) дескрипторів опису, найближчих за відстанню Хемінга до сформованого центру у вигляді медіани із використанням моделі логічного оброблення (2.27). Цю дію необхідно здійснити як для описів еталонів, так і для розпізнаваного зображення [43]. При такій трансформації значення медіани та розподілів для компонентів не змінюються, а значить, додаткові обчислення полягають тільки у формуванні стисненого інформативного опису (2.27).

Обговорюване стиснення суттєво скорочує час оброблення пропорційно зменшенню числа дескрипторів. Експериментально отримані модифіковані таким способом описи еталонів шляхом відбору 50, 100 та 200 дескрипторів із загальної кількості 500.

Дослідження показало, що з використанням запропонованої модифікації стиснення усі еталонні описи класифікуються вірно, а обчислені вагові показники $\{d(i)\}_{i=1}^N$ класів для зображень еталонів певною мірою покращуються зі зменшенням числа компонентів.

Зі зменшенням числа дескрипторів в описі спостерігається відповідна концентрація значень розподілів навколо центрів, що сприяє збільшенню показників, які відповідають «правильному» класу. А це, в свою чергу, покращує результативність класифікації, так як клас об'єкта визначається більш впевнено.

Різниця між максимальним значенням розподілу та найближчим до нього за величиною збільшилась для різних еталонів від 3% для повного опису (500 дескрипторів) до 15% (200 дескрипторів), 21% (100 дескрипторів) та 25% (50 дескрипторів) для модифікованого опису.

Подальше стиснення аналізованих описів за моделлю (2.27) призводить до втрати інформативності складу даних.

Зауважимо при цьому, що із загальних міркувань ефективність прийняття класифікаційного рішення повністю залежить від наявної бази еталонів та множини вхідних зображень, тобто від змісту прикладної задачі. Не виключено, що для окремих застосувань, де спостерігаються суттєві відмінності між образами

еталонів, найбільш ефективним може виявитися інтегральний метод (2.20), що базується виключно на значеннях медіан.

З метою порівняльного аналізу проведено експерименти, де стиснена підмножина опису у 200 – 300 дескрипторів вибиралась випадковим відбором та з використанням спеціалізованих процедур аналізу множини векторів.

Установлено, що такі способи фільтрації даних не мають перспективи застосування у досліджуваних підходах, так як результативність методу (2.20) при цьому суттєво погіршується, показник правильної класифікації навіть для вхідних еталонних зображень знижується.

Оцінимо тепер результативність класифікатора «дескриптор об'єкта – еталон» (2.21) – (2.24) за показниками точності та повноти (2.28), (2.29). Таблиця 2.4 містить кількісні характеристики числа дескрипторів окремо для кожного із трьох еталонів, віднесених розробленим класифікатором до відповідного класу. При цьому всі три еталони (число дескрипторів дорівнює 500 у кожному еталонному образі) класифіковані правильно.

Таблиця 2.4 – Результати класифікації

		Число дескрипторів	Число дескрипторів для решти еталонів	Усього
Еталон 1 (Химера)	Віднесених до 1	281	144 + 140 = 284	565
	Віднесених до 2 та 3	219	356 + 360 = 716	935
	Усього	500	1000	1500
Еталон 2 (Махаон)	Віднесених до 2	249	111 + 86 = 197	446
	Віднесених до 1 та 3	251	389 + 414 = 803	1054
	Усього	500	1000	1500
Еталон 3 (Давісій)	Віднесених до 3	274	107 + 108 = 215	489
	Віднесених до 1 та 2	226	393 + 392 = 785	1011
	Усього	500	1000	1500

Таблиця 2.5 містить обчислені значення показників Prec та Compl за даними з таблиці 2.4.

Таблиці 2.4 та 2.5 обчислені безпосередньо для методу 2 (класифікація за числом голосів компонентів) як більш перспективного при практичному застосуванні. На вхід класифікатора подавалися по черзі еталонні зображення (набір для тестування взято із бази даних Leeds Butterfly).

Таблиця 2.5 – Значення показників Prec та Compl для істинно позитивних результатів

	Еталон 1 (Химера)	Еталон 2 (Махаон)	Еталон 3 (Давісій)	Мінімум
Prec	0,497	0,55	0,56	0,497
Compl	0,562	0,498	0,548	0,498

Таблиця 2.4 містить кількості правильно і неправильно класифікованих дескрипторів за результатом тестування програмної моделі.

У таблиці 2.5 обчислено традиційні показники точності (2.28) та повноти (2.29) стосовно множини дескрипторів. За результатами навчання обчислено центри (медіани) еталонних зображень. Тестовим набором виступила множина дескрипторів еталонних зображень.

Середнє значення обох показників серед трьох аналізованих еталонів бази склало приблизно 0,536. Як бачимо із таблиці 2.5, для розглянутих зображень значення показників результативності не є достатньо високими, так як вони не є близькими до 1, як було отримано у нашому дослідженні на розрахунковому прикладі. Це можна пояснити значною подібністю досліджуваних об'єктів як візуально (рис. 2.3), так і у побудованому просторі ознак. Крім того, зрозуміло, що зі збільшенням числа класів показник точності буде природно зменшуватися.

За результатом розрахунку за даними таблиці 2.4 для істинно негативних результатів, що відповідають факту правильного розпізнавання дескрипторів інших класів, показники Prec та Compl є значно вагомими: їх середнє значення дорівнює 0,768, а мінімальне – 0,716. Це свідчить на користь достатньо високої результативності розробленого підходу. Дійсно, навіть за наявності високого рівня подібності досліджуваних об'єктів, кількість виявлених відмінних дескрипторів для різних описів є все ж таки реально значно більшою, що і було підтверджено експериментальними розрахунками.

Враховуючи безсумнівний вплив фактору багатовимірності використаних даних (розмір дескриптора 256 компонентів, число дескрипторів опису – 500), можна вважати необхідним для забезпечення впевненого розпізнавання у базах схожих за змістом зображень застосувати зменшення розмірності (стиснення чи концентрацію) описів шляхом впровадження процедур кластеризації або хешування, що може сприяти отриманню більш вагомих показників результативності класифікації.

Суть проведеного дослідження полягає в розробленні методів структурної класифікації на основі описів із множини дескрипторів ключових

точок. Зрозуміло, що результативність будь-якого методу класифікації напряму залежить від бази еталонних зображень.

Ключова ідея роботи полягає у вивченні і перевірці працездатності класифікації із використанням апарату розподілів опису за заданими еталонними класами.

Показники таблиці 2.5 не є вражаючими, але вони показують тільки результати оцінювання для окремих дескрипторів опису.

У той же час у експерименті всі еталонні зображення обома пропонованими методами класифіковані вірно, тобто фактичні показники точності і повноти класифікації в аспекті опису вхідного зображення дорівнюють 1.

Ключовий результат аналізу полягає в тому, що у даному випадку, незважаючи на невисокі показники кожного із компонентів опису, їх спільне класифікаційне рішення забезпечує гарантовано високий показник результуючого класифікатора (2.24), (2.25).

Тестування показало, що на множині еталонів пропонований метод спрацював без помилок. Швидкодія класифікації у порівнянні із традиційним підходом голосування дескрипторів, де застосовано лінійний пошук, покращується пропорційно збільшенню числа еталонів. Для тестового прикладу час опрацювання склав приблизно 5 с (розроблений метод) та 34 с (традиційний), що відповідає виграшу приблизно у 7 разів. Основна причина виграшу полягає в тому, що у розробленому методі вхідні дескриптори порівнюються метрикою Хемінга тільки із центрами еталонних описів.

Розроблений метод класифікації на основі статистичних розподілів компонентів описів побудовано на принципі розділення складників даних за класами. Цей метод за результатами експериментів підтверджує свою працездатність та ефективність при класифікації зображень. Його результативність для об'ємних баз зображень може бути посилена адаптованим вибором метрик чи мір подібності, вибором способу формування центрів для еталонних описів, введенням логічного оброблення чи стиснення структурного опису. Більш впевнені експериментальні результати класифікації показала модель, що має оптимум у векторі розподілів для окремих дескрипторів (мода розподілу). Використання концентрованої частки даних опису дає можливість покращити його розрізнення з іншими описами.

Для випадку багатокласової класифікації зі збільшенням числа класів невпинно зростає невизначеність у прийнятті рішення. Як наслідок – знижується показник точності, так як важко забезпечити, щоб у нових еталонах

не виникала подібність з уже існуючими. Виходом є прийняття рішення відносно кожного класу окремо, або ранжирування за показником впевненості.

Новизною дослідження є розроблення ефективного методу класифікації зображень на основі впровадження апарату статистичних розподілів для компонентів опису. Він реалізує поглиблений аналіз у просторі даних та забезпечує результативність класифікації навіть для схожих зображень. Класифікатор реалізовано у варіантах інтегрування компонентних розподілів за класами і на підставі аналізу моди для розподілів окремих компонент. Застосування медіани як центру опису має перевагу над середнім значенням.

2.5 Непараметричні статистичні підходи при побудові класифікаторів

Впровадження статистичних методів як апарату інтелектуального аналізу даних для побудови класифікаторів образів візуальних об'єктів у системах комп'ютерного зору націлене на покращення показників їх функціонування за рахунок поглибленого врахування властивостей, змісту та структури даних [6].

Простір образів у виді векторних даних з дійсними чи бінарними компонентами при застосуванні структурних методів складає множина дескрипторів ключових точок зображення.

Якщо є підстави вважати дійсною гіпотезу про те, що структурні елементи опису (дескриптори ключових точок фіксованого зображення) можуть у межах генеральної сукупності даних створювати просторові конгломерати (наприклад, кластери), що відображають властивості конкретного візуального образу, то допустимо застосувати непараметричні методи статистики для оцінювання характеристик таких конгломератів задля здійснення результативної класифікації.

Окрім узагальнення інформації, важливою перевагою непараметричних методів є незалежність процедур оцінювання та базованих на них методах класифікації від законів розподілу даних, що робить універсальним впровадження таких класифікаторів.

Незважаючи на те, що більш реальною у прикладних ситуаціях вважається гіпотеза, що для конкретного образу більш прийнятна модель у сенсі декількох груп однотипних даних [12], вивчення застосувань непараметричних методів для усього опису цілком показало їх прикладну привабливість з точки зору теоретичного підґрунтя і спрощення процесу оброблення.

Зокрема, замість традиційного обчислення релевантності описів як відстані між множинами дескрипторів ключових точок обсягом у 1–2 тисячі векторів, після впровадження статистичних оцінок даних визначення

релевантності зводиться до зіставлення векторних значень характеристик даних у моделі статистичного критерію.

Метою дослідження є створення класифікатора візуальних образів на підставі впровадження механізму вибіркового статистичного оцінювання для образів у вигляді множини дескрипторів ключових точок зображення [6].

Завдання – побудова моделей класифікації образів у новоствореному просторі значень статистичних параметрів, аналіз їх обчислювальної ефективності, оцінювання якості класифікації шляхом програмного моделювання.

Нехай задано деяку базу E описів зображень еталонів обсягом $N : E = \{E_1, E_2, \dots, E_N\}$. Кожен еталонний опис E_i представляє у задачі класифікації окремий клас та має вид скінченної множини дескрипторів ключових точок зображення: $E_i = \{e_v(i)\}_{v=1}^s$, де $s = \text{card } E_i$ – фіксована кількість дескрипторів ключових точок у описі еталону E_i .

Зважимо, що окремий дескриптор $e_v(i)$ характеризує деякий окіл ключових точок зображення та є елементом векторного простору R^n скінченної розмірності $n : e_v(i) \in R^n$ з дійсними або цілими компонентами. Останнього часу із-за обчислювальної ефективності набули популярності двійкові дескриптори $e_v(i) \in B^n$ із простору B^n бінарних векторів. Часто для спрощення вважають значення параметру s однаковим для кожного опису із E :

$$\text{card}(E_1) = \text{card}(E_2) = \dots = \text{card}(E_N) = s.$$

Виконання цієї умови для статистичних підходів не обов'язкове, так як статистичне оброблення, як правило, не залежить від порядку розміщення даних, хоча у задачах розпізнавання зображень статистичне підґрунтя (вибірка даних) для описів окремих еталонів (класів) повинне бути приблизно рівноцінним.

Зосередимося на бінарних образах, опис Z класифікованого візуального об'єкту визначимо у вигляді скінченної множини $Z = \{z_v\}_{v=1}^s, z_v \in B^n, Z \subset B^n$ із s дескрипторів ключових точок (наприклад, сформованих детекторами ORB, BRISK, AKAZE) з бінарними компонентами.

Бітова природа дескрипторів ключових точок у просторі B^n (n – ступінь двійки) дає можливість запровадити оброблення дескриптора як кортежу послідовних елементів (наприклад, бітів чи байтів), діапазон значень яких відомий. Для прикладу дескриптора ORB він складає 256 бітів. Це дає змогу здійснювати статистичний аналіз структурного опису (множина бінарних векторів) з урахуванням характеристик його внутрішнього складу.

Для фіксованого числа n бітів подаємо опис об'єкту бінарною матрицею $Q = \{\{q_{i,j}\}_{i=1}^s\}_{j=1}^n$ даних, у довільному порядку сформовану послідовністю s дескрипторів КТ для об'єкту.

Кожний із рядків матриці Q , що є дескриптором ключових точок, подаємо у виді d непересічних фрагментів (блоків), що послідовно поєднуються один за одним у ланцюжок. Отримаємо модерний простір даних, перевагою якого є можливість аналізувати внутрішню структуру та статистичні властивості фрагментів опису, на основі чого опис можна буде класифікувати до одного із еталонних класів. Застосуємо мережу блоків як основу для прийняття рішення про клас об'єкту. Блоки дескриптора відіграють роль системи ознак.

Такий спосіб формування ознак надає додаткову гнучкість побудови класифікаторів при практичній реалізації.

Нехай маємо вибірку значень X_1, X_2, \dots, X_s для випадкової величини X . Такі значення даних у нашій моделі представлення розміщені у стовпцях матриці Q . Вибіркові оцінки середнього M та дисперсії σ^2 для X традиційно обчислюються як

$$M(X) = \frac{1}{s} \sum_{i=1}^s X_i, \quad \sigma^2(X) = \frac{1}{s-1} \sum_{i=1}^s (X_i - \bar{X})^2. \quad (2.30)$$

Будемо розглядати стовпці матриці Q як вибіркові значення випадкової величини, а кортеж стовпців – як вибірку для системи d випадкових величин. Для кожного із складових цієї системи обчислимо вибіркові значення (2.30), отримаємо вектори вибіркових середніх та дисперсій розмірністю d :

$$M_1, M_2, \dots, M_d, \quad \sigma_1^2, \sigma_2^2, \dots, \sigma_d^2, \quad (2.31)$$

які далі покладемо в основу класифікації.

Зазначимо, що для бінарних даних значення параметрів (2.30) можна обчислити безпосередньо, спираючись на оцінку p_1 частоти появи значення одиниці серед s вимірювань: $M(X) = p_1$, а $\sigma^2(X) = p_1(1 - p_1)$ [48].

Для обчислення релевантності описів на підставі обчислених характеристик (2.31) використаємо критерій відстані Ейлера [40]

$$\rho(A, B) = \sqrt{(m_A - m_B)^2 + (\sigma_A - \sigma_B)^2}, \quad (2.32)$$

де A, B – пара порівнюваних випадкових величин;

m_A, m_B – математичні очікування;

σ_A, σ_B – середньоквадратичні відхилення.

Значення (2.32) дорівнює нулю при повному збігові параметрів.

Для порівняльного аналізу і вивчення властивостей класифікаторів застосуємо також правосторонню статистику [12]

$$\beta(A, B) = \frac{[(\sigma_A^2 + \sigma_B^2)/2 + ((m_A - m_B)/2)^2]^2}{\sigma_A^2 \sigma_B^2}, \quad (2.33)$$

що приймає значення у діапазоні $[1 \dots \infty]$ і має сенс відмінності для значень фрагментів зображень або їх описів.

Значення (2.33) дорівнює мінімуму – 1 при однакових величинах параметрів. Обидва критерії симетричні відносно порівнюваних значень.

На підставі усієї множини із d стовпців визначимо інтегровані характеристики

$$\rho_\Sigma = \sum_{i=1}^d \rho_i, \quad \beta_\Sigma = \sum_{i=1}^d \beta_i, \quad (2.34)$$

що відображають узагальнену близькість для порівнюваних описів на підставі системи стовпців.

Класифікацію будемо здійснювати конкурентним шляхом вибору класу v з оптимальною оцінкою на підставі значень $\{\theta_k\}_{k=1}^N$ отриманої системи оцінок для множини еталонів $E = \{E_1, E_2, \dots, E_k, \dots, E_N\}$:

$$v = \arg \underset{k=1,2,\dots,N}{opt} \{\theta_k\}, \quad (2.35)$$

де θ_k – оцінка для k -го класу, отримана відповідно до виразів (2.34) на основі обчислень з використанням вибіркових значень (2.31) для описів аналізованого об'єкту і еталону E_k . При цьому у моделі (2.35) як для відстані ρ_Σ , так і для подібності β_Σ визначається мінімум.

Класифікація за моделлю (2.35) для кількох класів у загальному випадку може бути неоптимальною, тому замість неї рекомендують провести навчання на даних. На практиці добре працює евристичний підхід [19], коли класи на підставі навчання по черзі оптимально відділяють від всієї сукупності [16].

Загалом розглянуту модель класифікації (2.30) – (2.35) можна віднести до метричних, так як вона ґрунтується на вимірюванні значень близькості даних. Тим більше, що суму дисперсій $\sum_{i=1}^d \sigma_i^2(X)$ можна інтерпретувати як середньоквадратичну евклідову відстань до вектора середніх значень.

Наряду із виразами (2.34) у схемі (2.35) можуть бути застосовані також інші критерії, наприклад, усереднення та медіанного оброблення даних.

Відмітимо також, що із використанням вибіркових параметрів (2.30) можна побудувати різноманіття схем класифікації структурних описів об'єктів, наприклад, на підставі статистичних процедур віднесення окремо кожного

дескриптору $z_v \in Z$ об'єкта до відповідного еталонного класу із застосуванням аналогу схеми (2.35). У даному випадку оцінка θ_k буде мати сенс числа голосів дескрипторів, віднесених до k -го класу, а рішення (2.35) про клас об'єкту здійснюється за максимальною оцінкою.

Зазначимо також, що на підґрунті значень векторів (2.31) поряд із інтегральними критеріями (2.34) можна побудувати інші варіанти прийняття класифікаційних рішень, наприклад, заснованих на підмножинах компонентів системи (2.31). У цих схемах може бути побудована модель голосування стовпців даних, коли окремі стовпці матриці Q класифікуються до різних еталонів. При цьому кінцеве рішення здійснюється на підставі максимуму або статистично значущого порогу для числа голосів стовпців [42].

2.6 Результати моделювання непараметричних підходів для класифікації

Зображеннями експериментальної бази еталонів вибрано портрети вчених (рис. 2.5) із сформованим числом дескрипторів опису $s = 500$ для кожного еталону (візуалізація координат ключових точок на рисунку 2.6).

Для визначення дескрипторів ключових точок використано детектор ключових точок ORB з параметром $n = 256$ та програмне середовище Python PyCharm з бібліотекою комп'ютерного зору OpenCV.

Дескриптори ORB обробляються як бінарні вектори. Дані зберігаються у матриці, де кількість рядків дорівнює числу виявлених дескрипторів (500), а число стовпців дорівнює 32 (256 бітів дескриптора трансформуються в 32 байти).

Програмно реалізовані моделі оброблення (2.30) – (2.34) з класифікацією (2.35) для бітового та байтового подань даних опису.



Рисунок 2.5 – Експериментальні зображення



Рисунок 2.6 – Зображення з координатами ключових точок

Обчислені значення критеріїв (2.31) для усіх пар порівнюваних зображень наведені у таблицях 2.6 та 2.7.

Таблиця 2.6 – Значення критеріїв (2.34) для бітового подання

Пари зображень	ρ_{Σ}	β_{Σ}
(1,2)	8,49	256,91
(1,3)	36,41	277,60
(2,3)	34,61	276,43

Таблиця 2.7 – Значення критеріїв (2.34) для байтового подання

Пари зображень	ρ_{Σ}	β_{Σ}
(1,2)	204,74	32,20
(1,3)	715,71	34,66
(2,3)	738,21	34,67

Як бачимо із таблиці 2.6, критерій ρ_{Σ} за рахунок кращої чутливості до варіацій даних (значніший розкид значень) забезпечує дещо вищий рівень розрізнення аналізованих показників описів зображень, ніж β_{Σ} .

За обома критеріями найбільш схожою визначена пара зображень (1,2). Третє зображення за критерієм β_{Σ} практично у однаковій мірі схоже як на перше, так і на друге.

Зважаючи на те, що мінімальне значення критерію ρ_{Σ} дорівнює нулю, а для критерію β_{Σ} воно рівне 256 для бітів та 32 для байтів, за результатом

експериментів можна віддати перевагу критерію ρ_{Σ} у плані забезпечення кращої розрізненості, а значить, і кращої результативності класифікатора. У той же час обидва критерії гарантовано вірно здійснюють класифікацію (2.35) під час геометричних перетворень зміщення, повороту, масштабу розглянутих вхідних зображень.

При цьому для байтового подання показник розрізнення за критерієм ρ_{Σ} дещо ліпший, так як має більше відхилення від нуля.

Для запропонованої моделі статистичного аналізу даних виграш у обсязі обчислювальних витрат на класифікацію у порівнянні із традиційними підходами, заснованими на зіставленні множин дескрипторів, зростає пропорційно збільшенню числа ключових точок у описах і збільшенню числа еталонів. Побудована система ознак на основі оцінок непараметричної статистики не залежить від типу розподілу даних (дескрипторів ключових точок) і від порядку їх визначення на зображенні, що сприяє прикладному впровадженню таких методів. Застосовані ознаки узагальнюють еталонну інформацію в межах векторів середнього та дисперсії і можуть бути впроваджені також і у моделях кластерного подання, в тому числі і для системи незалежних кластерів для кожного еталону.

Зважаючи на те, що класифікація за значенням релевантності обчислюється шляхом аналізу всієї множини еталонів, кожний із яких містить сотні ключових точок, статистичний аналіз суттєво (у тисячі разів) понижує обсяг необхідних обчислень. Відплатою за таке прискорення є деяке зниження ступеня розрізненості за рахунок узагальнених властивостей статистичних характеристик.

Новизну дослідження складає удосконалення методу класифікації зображень на основі впровадження критеріїв, заснованих на непараметричних оцінках даних опису, що дає можливість спростити класифікатор та прискорити прийняття результативного рішення.

Практична значущість роботи полягає у експериментальному підтвердженні працездатності запропонованих моделей статистичного аналізу описів зображень задля класифікації, розробленні програмних моделей для впровадження описаних методів у системах комп'ютерного зору.

Перспективи дослідження пов'язані із розширенням різноманіття схем класифікації шляхом аналізу індивідуальних рішень для фрагментів опису та окремих елементів із множини дескрипторів аналізованого об'єкту. Важливою представляється також задача поглибленого дослідження завадостійкості розроблених підходів.

3 НЕЧІТКІ МОДЕЛІ ПОДАННЯ ДАНИХ У СТРУКТУРНИХ МЕТОДАХ РОЗПІЗНАВАННЯ

3.1 Застосування засобів нечіткого кластерування

Сучасні дослідження націлені на підвищення ефективності структурних методів шляхом подання множини дескрипторів у кластерному виді, формуванням «узагальненого дескриптора», що відображає властивості множини усіх дескрипторів зображення та інші [5, 12].

Задача кластерування об'ємних масивів багатовимірних спостережень (векторів-образів) виникає у прикладних задачах комп'ютерного зору і вирішується рядом технологій [30, 31, 40]. Наприклад, коли класи перетинаються, використовують методи нечіткого кластерного аналізу, одним з найпоширеніших методів є Fuzzy C-Means clustering (FCM) [49].

Завданням нечіткого кластерування є знаходження нечіткого розподілу або нечіткого покриття множини дескрипторів зображення, що зводиться до визначення ступенів належності елементів системі кластерів [50]. Нечітка кластеризація у порівнянні із традиційною дає можливість глибше виявити розрізнявальні властивості описів, що важливо для класифікації [51, 52].

Завданням є створення технології та вивчення її властивостей при застосуванні нечіткого кластерування даних у структурних методах класифікації зображень. Матеріал викладено у роботі [5].

Під дескриптором КТ формально розуміємо бінарний вектор $b = (b_1, b_2, \dots, b_n)$, $b_i \in \{0, 1\}$, $b \in B^n$, де B^n – множина всіх бінарних векторів розмірності n . Для детектора BRISK значення $n = 512$.

Структурний опис зображення візуального об'єкта – це скінченна множина $O = \{x_i \mid x_i \in B^n\}$. У складі опису O допускається співпадання або близькість значень окремих елементів, тобто на практиці O є мультимножиною.

Традиційний метод для обчислення релевантності описів B_1 та B_2 зводиться до підрахунку числа r «еквівалентних» елементів одного з описів, що вважається еталоном, у складі іншого опису [6]

$$r = \text{card}\{x_1 \in B_1 \mid x_1 \equiv x_2, x_2 \in B_2\}. \quad (3.1)$$

Еквівалентність $x_1 \equiv x_2$ в (3.1) трактується як

$$x_1 \equiv x_2 : \rho(x_1, x_2) \leq \delta, \quad (3.2)$$

де ρ – метрика у просторі B^n ;

δ – поріг для значення метрики, для якого елементи x_1, x_2 вважаються еквівалентними.

Як правило, прийняття рішення ґрунтується на нормованому значенні r , де параметром нормування є чисельність $m_1 = \text{card}\{B_1\}$ елементів еталонної множини B_1 . Для дескрипторів ключових точок із простору B^n у виразі (3.2) можна використати манхеттенську відстань

$$d(p, q) = \sum_{i=1}^N |p_i - q_i|, \quad (3.3)$$

де $p = (p_1, p_2, \dots, p_n)$ та $q = (q_1, q_2, \dots, q_n)$ – вектори-дескриптори.

Застосування традиційного методу проблематично за обсягом обчислень, так як пов'язане з визначенням мір подібності чи відстані у просторі описів як множин дескрипторів [46].

Перспективною ідеєю задля суттєвого скорочення об'єму обчислень є кластерне подання [5], у результаті чого структурний опис має вигляд

$$h[O] = (h_1, h_2, \dots, h_k), \quad (3.4)$$

де k – число сформованих кластерів;

h_i – число елементів опису, що віднесені у процесі кластеризації до кластеру з номером k .

Як правило, квантування даних здійснюють в межах розпізнаваної бази зображень, тобто на фіксованій множині еталонних описів.

На основі процедури угруповання формуємо для бази еталонних описів k кластерів елементів, тобто переходимо від описів еталонів у вигляді множин до векторного подання:

$$R : B^n \rightarrow h, \quad (3.5)$$

де $h = (h_1, \dots, h_k)$, $h_i \in C_+$ – цілочисельний вектор розмірності k .

У результаті трансформації (3.5) опис представляється вектором, а при визначенні релевантності описів обчислюється подібність чи близькість векторів h (а не множин векторів). Як показують експерименти, час розпізнавання зображення навіть при мінімальному числі еталонів (5...10) скорочується в десятки разів зі збереженням високої якості [5]. Параметрами такого удосконалення є вибраний метод кластеризації, кількість кластерів, значення порогу для встановлення еквівалентності дескрипторів у виразі (3.2) та інше.

Застосуємо для множини бінарних дескрипторів кластеризацію за методом *c*-середніх (Fuzzy C-Means, FCM), який базується на інструментарії нечіткої логіки [53, 54].

Метод нечіткої кластеризації FCM дозволяє розбити наявну множину елементів потужністю N на задане число k нечітких множин [55].

Для кожного елемента множини розраховується значення його функції належності до будь-кого з кластерів. Такий підхід має суттєві переваги під час оброблення граничних точок кластерів, що можуть належати різним кластерам.

Метод FCM мінімізує цільову функцію:

$$J_m = \sum_{i=1}^l \sum_{j=1}^k \mu_{ij}^m \|x_i - c_j\|^2, \quad m \geq 1, \quad (3.6)$$

де μ_{ij}^m – функція належності об'єкта x_i кластеру j , $\mu_{ij}^m \in [0, 1]$;

c_j – центроїд кластера j ;

$\| \cdot \|$ – метрика, що характеризує ступінь близькості елементів множини;

k – кількість кластерів;

l – кількість елементів у описі зображення.

Значення матричної функції належності та центроїдів оновлюються ітераційно:

$$\mu_{ij}^m = 1 / \left(\sum_{j=1}^k \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{2/(m-1)} \right), \quad (3.7)$$

$$c_j = \frac{\sum_{i=1}^l \mu_{ij}^m x_i}{\sum_{i=1}^l \mu_{ij}^m}. \quad (3.8)$$

Ітерації методу FCM виконуються, поки максимальна відмінність за всіма кластерам між поточною і попередньою ітерацією не буде задовольняти умові:

$$\max |\mu_{ij}^{(s+1)} - \mu_{ij}^{(s)}| < \varepsilon, \quad (3.9)$$

де ε – похибка;

s – номер ітерації.

У результаті процесу (3.7) – (3.9) обчислюються вектори центроїдів c_j та значення матричної функції належності μ_{ij} . Аналіз цієї матриці дає можливість встановити ступінь належності до кожного із кластерів щодо усіх аналізованих елементів даних. Після проведення нечіткої кластеризації аналогічно традиційному кластеруванню обчислюється вектор $h[B]$, що представляє опис у створеній кластерній системі [5]. Далі на підставі подань $h[B]$ для еталону та об'єкту за метрикою (3.3) можна обчислити релевантність інтегрованих образів зображень.

Іншим способом є вирахування релевантності на підставі аналізу близькості кожного із елементів об'єкта до центроїдів кластерів.

Застосування апарату нечіткої логіки до кластерування множини дескрипторів зображень надає можливість якісніше врахувати властивості кластерної системи у середовищі аналізованих даних, а саме перейти від «поверхневого» результату аналізу («належить», «не належить») до «більш глибокого» з обчисленням значень ступеня належності до кластеру.

За рахунок нечіткої кластеризації можна не тільки розподілити дескриптори за кластерами, але і розрахувати суму значень функції належності для елементів окремих еталонів, що сприяє формуванню інтегрованих еталонних образів аналогічно узагальненому дескриптору [12].

Важливою властивістю застосування апарату кластерування (звичайного і нечіткого) є незалежність сформованих просторів даних від порядку слідування дескрипторів у описі, так як це гарантує інваріантність значень трансформованих подань відносно групи геометричних перетворень [56].

Представляється доцільним розвинути методів структурного розпізнавання на основі використання значень функції належності, отриманої за результатом нечіткої кластеризації, яка чисельно вираховує індивідуальні особливості ознак опису.

Розглянемо такі варіанти оброблення:

1. Шляхом аналізу значень функції належності μ_{ij} можна за принципом «чемпіонського списку» відібрати фіксоване число d найбільш значущих дескрипторів із опису кожного еталону. Для цього треба здійснити ранжирування дескрипторів за обчисленим значенням μ_{ij} у межах опису кожного із еталонів. У результаті отримуємо стиснене подання $x^* = x_1^*, \dots, x_d^*$ із d найбільш впливових дескрипторів для кожного еталону. x^* – це компактний опис, що забезпечує відповідне зменшення часу оброблення чи класифікації прямо пропорційно значенню d . Аналіз результативності застосування стиснених описів наведено у [43].

2. Другим способом є логічне оброблення списку дескрипторів як відбір на підставі значення деякого порогу φ у вигляді виконання умови

$$\mu_{ij} > \varphi, \quad (3.10)$$

де φ – фіксований поріг для значення функції належності.

Для впровадження подальшої класифікації з використанням (3.10) необхідно вирівняти отримане число відібраних дескрипторів для кожного із еталонів.

3. На підставі нечіткого кластерного аналізу можна скористатися значенням μ_{ij} для реалізації процедури аналізу окремо кожного із дескрипторів об'єкту. Для цього спочатку конкурентним шляхом визначимо дескриптор з номером i всередині еталону, який у просторі ознак знаходиться найближче до отриманого центру кластеру. Будемо вважати вагові коефіцієнти $\{\mu_{ij}\}$ кластерної системи характеристиками узагальненого дескриптора для цього еталону. Класифікацію здійснюємо на підставі додавання вагових коефіцієнтів для дескрипторів аналізованого опису.

4. Для формування системи центрів кластерів на множині дескрипторів бази еталонів можна застосувати апарат нейронних мереж Кохонена у визначеному просторі даних.

Враховуючи використання у роботі детектора BRISK, рекомендовано обчислювати відстані дескрипторів до центрів кластерів за допомогою метрики Хемінга, евклідової метрики або манхеттенської відстані (3.3).

У результаті навчання отримуємо систему центрів, яка адаптована для розпізнавання довільних структурних описів на підставі навчальної вибірки бази еталонів. Якість класифікації безпосередньо буде залежати від результатів навчання системи і від наявного набору структурних описів навчальної вибірки.

При побудові класифікатора, якщо модифікується повна мережа нейронів відповідно до відстані нейрона-переможця, то виконується найбільш повноцінне оброблення даних, відносячи аналізований дескриптор до усіх центрів класів одночасно, але з різними ваговими коефіцієнтами $\{\mu_{ij}\}$, пропорційними відстані [57].

Використання засобів навчання мережі Кохонена у розрахунку центрів значно знижує похибку класифікації [4].

Конструкція перетворення бази дескрипторів для набору еталонів подана на рисунку 3.1.




Рисунок 3.1 – Схема перетворення описів

Класифікація на основі нечіткого кластерування поступається перед традиційним кластерування збільшеним часом оброблення даних (певний час

витрачається на розрахунок вагових коефіцієнтів $\{\mu_{ij}\}$ належності до того чи іншого кластеру кожного із дескрипторів), але виграє за рахунок можливості фіксування лише найбільш впливових дескрипторів для кожного еталону, що забезпечує досягнення високої якості розпізнавання при класифікації.

3.2 Експериментальне дослідження нечітких моделей

Впровадження моделі кластерного подання структурних описів для розпізнавання зображень представлено у вигляді інструментального засобу.

Проведено програмне моделювання досліджуваних методів мовою Python 3.6 у середовищі Visual Studio 2019 з використанням засобів бібліотеки OpenCV. Програмна платформа може працювати на Windows, Android, iOS, Windows Phone, Mac OS X та Linux.

Оцінювання результативності щодо застосування кластерного апарату відбувалось на прикладі задачі ідентифікації людських облич. Метою було виявити ступінь схожості фотографій близнюків та близьких родичів (наприклад, матері та доньки). На рисунку 3.2 та 3.3 наведено приклади досліджуваних об'єктів за зображеннями розміром 250×260 .

Приклад координат виділених детектором BRISK ключових точок показано на рисунку 3.4, гістограми повторень значень характерних ознак для цих зображень подано на рисунку 3.5.

Експерименти проводилися з числом кластерів $k = 2, 3, 5$.



Рисунок 3.2 – Зображення близнюків



Рисунок 3.3 – Зображення матері та доньки



Рисунок 3.4 – Зображення рисунку 3.2 з координатами ключових точок




Рисунок 3.5 – Гістограми повторень значень дескрипторів для зображень на рисунку 3.4

Кількість встановлених точок для зображень на рисунку 3.2 дорівнює 185, для зображень на рисунку 3.3 – 138.

Кластеризація в межах бази із двох зображень виконана методом FCM. Роль нечітких множин на даному етапі полягає у визначенні значення функції належності, побудованої на основі множини дескрипторів ключових точок для бази зображень, з врахуванням наперед заданого порогу еквівалентності елементів. Такий підхід дає можливість забезпечити ефективне розпізнавання.

Особливістю результатів нечіткої кластеризації для обох типів зображень є зосередження їх кластерних подань фактично у 2 кластерах.

Для зображень рисунку 3.2 пропорції числа ключових точок у кластерах склали приблизно 95/65, а для зображень рисунку 3.3 – 90/28, при цьому зі збільшенням числа кластерів ці пропорції практично зберігаються. Загалом така практична ситуація сприяє кращому розпізнаванню об'єктів.

Значення манхеттенської відстані, за якою визначено релевантність для кластерних подань зображень (рис. 3.2, рис. 3.3) представлено у таблиці 3.1. Максимальне значення відстані складає 175, а мінімальне – 0.

Таблиця 3.1 – Релевантність для векторних подань зображень

Рисунок, №	Число кластерів, k		
	2	3	5
2	8	7	16
3	12	14	19

Проаналізувавши таблицю 3.1, можна відмітити достатню адекватність використання кластерної моделі в задачі зіставлення описів таких об'єктів.

Відстань для близнюків у інших експериментах була меншою за відстань для матері та доньки (рис. 3.3) приблизно на 50% для всіх значень k . Обчислення показали, що відстань у кластерному поданні між представниками зображень рисунку 3.2 та рисунку 3.3 перевищує значення 125. Даний факт виявляє чутливість методу до незначних особливостей зображення і його можливість застосування у прикладних системах.

Аналіз обчислювальних витрат часу на розрахунок значення релевантності за нечітким кластерним поданням у порівнянні з традиційним методом голосування шляхом підрахунку числа еквівалентних дескрипторів для зображень рисунку 3.2 та рисунку 3.3 показав вигреш у 2,5 рази. Вигреш пропорційно зростає зі збільшенням кількості точок та числа еталонів.

Міра подібності за голосуванням для двох різних зображень склала 0,15 (максимальне значення – 1,0), нормована до числа точок еталону відстань Хемінга для їх узагальнених дескрипторів склала 0,072 (мінімум 0). Для скороченого випадковим чином опису із 65 контрольних точок ця відстань зросла до 0,36. Цей факт можна пояснити зростанням ступеня різноманіття даних всередині опису, що для вибраного виду оброблення призводить до деякого «розмазування» образу у просторі, зменшення рівня індивідуальності його подання та до збільшення рівня перетину образів різних зображень.

Для досягнення достатнього ступеня розрізненості образів можна рекомендувати попереднє оброблення опису для включення в його склад тільки найбільш значущих для даного зображення дескрипторів, в тому числі і з використанням функції належності.

Для конкретних зображень в експерименті при вказаному способі логічного оброблення достатньо використовувати 45 – 65 точок.

Під час експерименту детально вивчено ітераційний розподіл елементів заданої множини на 2 кластери із врахуванням зазначеного порогу точності під час їх зіставлення та близькості елемента об'єкта до центру класу. Класифікація відбувається із застосуванням чисел із плаваючою точкою (вагові коефіцієнти $\{\mu_{ij}\}$). Для повного розподілу на 2 класи 160 ключових точок зображень рисунку 3.2 витрачено 48 ітерацій та 4,2 хвилини, при цьому забезпечено якісне розпізнавання.

Порівняльний аналіз результатів проведених експериментів із застосуванням нечіткого кластерування та традиційних підходів кластеризації показав наступні переваги залучення інструментарію нечітких множин для вирішення задачі класифікації:

1. Логічний аналіз виду (3.10) не тільки забезпечує якість кластерування, але й суттєво скорочує час для розподілу множини дескрипторів на кластери за рахунок мінімізації числа альтернатив попадання до кластеру до однієї можливої.

2. Метод нечіткого кластерування дає можливість досягти більш точного значення c_j для центру кластеру, яке на пряму впливає на результати класифікації.

3. За рахунок впровадження узагальненого дескриптору шляхом додавання коефіцієнтів μ_{ij} можна додатково скоротити час класифікації за рахунок порівняння векторних подань для зображення і еталонів.

Традиційне кластерування позбавлене цих можливостей і виконує розбиття дескрипторів на кластери «жорстким» способом на відміну від «м'якого» нечіткого кластерування.

Методи класифікації зображень із використанням кластерного нечіткого подання мають переваги, пов'язані із можливістю використання значень функції належності, що загалом сприяє підвищенню результативності.

Нечітке кластерне подання описів потребує дещо більшого часу оброблення у порівнянні з традиційною кластеризацією, але демонструє більшу гнучкість і ефективність розрізнення даних у задачах комп'ютерного зору.

Впровадження логічного аналізу значення функції належності, а також побудова узагальненого подання опису у вигляді спільного дескриптора у десятки разів скорочує час розпізнавання, але потребує додаткового попереднього оброблення опису.

Новизна дослідження полягає в розробленні методу класифікації на підставі технології нечіткого кластерування опису як множини дескрипторів ключових точок, що сприяє підсиленню ефективності в аспекті покращення розрізнення даних і скорочення обсягів обчислень за рахунок логічного оброблення та побудови узагальнених представлень.

Практична значущість роботи – підвищення глибини аналізу візуальних даних та швидкодії класифікації, підтвердження результативності запропонованих методів на прикладах зображень, створення прикладних програмних засобів для вивчення та впровадження методів класифікації у системах комп'ютерного зору.

3.3 Грануляція даних та нечітка логіка

Перспективною є розробка ефективних методів структурного розпізнавання зображень з використанням принципів гранулювання даних та апарату нечіткої логіки [53–55]. Дана методика дозволить за допомогою механізмів обчислювального інтелекту організувати високоякісний та швидкодіючий інструментарій розпізнавання візуальних об'єктів. Результати дослідження викладено у роботах [7, 42].

Запропоновано вирішити задачу за допомогою гранулювання значень ознак. Для визначення ступеня належності досліджуваного об'єкта до еталонного класу рекомендовано використовувати апарат нечіткої логіки.

Показник швидкодії розпізнавання за рахунок трансформації системи ознак може бути покращений у десятки разів.

Наприклад, гранулювання елементів опису [12] може забезпечити необхідне стиснення обсягу ознак; ефективну трансформацію простору; формування підмножин найбільш інформативних ознак з метою ефективного зниження обчислювальних витрат [43].

У структурних методах розпізнавання зображень окремі ключові точки елементів опису представлені векторами із простору B^n з дійсними компонентами. Структурний опис об'єкта – це кінцева мультимножина $O \subset B^n$.

Існує ряд методів виявлення та зіставлення ключових точок на зображенні. Наприклад, BRIEF, ORB, BRISK, FREAK, AKAZE, LATCH, SIFT, SURF, які використовують бінарне подання ознак зображення [34, 35, 46].

Для проведення досліджень обраний як один з ефективних та швидких методів структурного аналізу – Speeded Up Robust Features (SURF) [12, 46].

SURF використовується для пошуку об'єктів на зображенні, але він працює не з об'єктами (не виділяє об'єкт з фону). Метод розглядає зображення як єдине ціле та шукає особливості цього зображення. При цьому особливості можуть бути всередині об'єкту, на фоні, на точках межі об'єкту та фону. Цей метод як і інші не зовсім ефективно працює для об'єктів простої форми та без яскраво вираженої текстури. SURF не знайде ключових точок усередині таких об'єктів. КТ будуть знайдені на межі об'єкту з фоном або лише на фоні. Досліджуваний об'єкт не може бути розпізнаний на іншому зображенні або іншому фоні з цієї причини.

Метод SURF формує $O \subset B_1^n$ (кінцеву мультимножину) із підмножини $B_1^n \subset B^n$ векторів $o = (o_1, \dots, o_n)$, $o \in O$, $n = 64 \vee 128$.

Підмножина B_1^n визначена як множина n -мірних дійсних векторів, евклідова норма яких дорівнює одиниці: $\|o\| = \sqrt{\sum_{i=1}^n o_i^2} = 1$. На практиці ця умова реалізується у наближеному вигляді $B_1^n = \{o \mid o \in B^n, \|o\| \approx 1\}$.

Опис SURF може містити сотні векторів, що суттєво уповільнює обробку. Завдання скорочення числа векторів передбачає побудову стисненого опису O^* з урахуванням відображення $\Omega: O \rightarrow O^*$.

Варіантом опису є формування підмножини $O^* \subset O$ значно меншої потужності шляхом застосування процедури відбору (редукції) ознак O . «Редукція множини ознак» є способом компресії даних з метою зниження витрат на розпізнавання. У теорії розпізнавання цей процес називають формуванням підмножини «значимих», «унікальних» чи «інформативних» ознак [14, 43].

Основним критерієм оцінювання подібності елементів B_1^n є метрика ρ . Найчастіше як ρ використовують евклідову метрику з B_1^n .

Критерієм еквівалентності ключових точок o_i, o_j є значення $\rho(o_i, o_j)$, яке не перевищує апріорної величини порогу δ_o .

Дві ключові точки еквівалентні, якщо умова $\rho(o_i, o_j) \leq \delta_o$. Подібність значень характерних ознак усередині опису та між описами оцінюється евклідовою відстанню $\rho(o_i, o_j) = \sqrt{\sum_v [o_i(v) - o_j(v)]^2}$ між векторами o_i, o_j .

Ступінь близькості ознак між собою в рамках опису та бази описів можна оцінити на основі побудови відношень на множинах характерних ознак [14]. Використання апарату відношень близькості забезпечує нові можливості у вдосконаленні розпізнавання за рахунок урахування індивідуальних властивостей ознак опису. Поріг δ_o визначають як відсоток (точність) від максимально можливого значення.

Вибір δ_o залежить також від процедури обробки. Величини порогу δ_o можуть відрізнятись. Наприклад, у процедурах навчання, під час встановлення еквівалентності ключових точок, при класифікації. Встановлене відношення еквівалентності елементів O при фіксованому значенні δ_o визначає розбиття O .

Здатність гранулювання інформації є важливою властивістю інтелектуальних систем. Дані структури використовують семантику для формалізації розв'язання задач. При гранулюванні розділяють чіткий та нечіткий підходи.

Інформаційною гранулою називають підмножина універсуму, на якому визначено відношення подібності (нерозрізненості, еквівалентності). Гранула є об'єднання атомарних елементів.

У результаті такий універсум або опис можна зобразити як множину гранул. Основи теорії міри та відношень розроблені на сукупності гранул. Міра гранули обчислюється як сума (інтеграл) значень функції належності елементів.

Міра $d(A)$ дискретної гранули A визначена як

$$d(A) = \sum_{a \in A} \mu_A(a), \quad (3.11)$$

де $\mu_A(a)$ – значення функції належності гранулі A , $\mu_A(a) \in [0, 1]$ [58].

Для чіткого подання $\mu_A(a)$ набуває бінарних значень 0 або 1. Операції над гранулами здійснюються за законами теорії множин [50, 59]. Гранули можуть містити одна одну, утворювати ієрархії. Гранулювання даних реалізується певним методом та залежить від низки параметрів. Можлива постановка питання про оптимальне гранулювання на основі апарату нечіткої логіки.

Функція належності $\mu_A(a)$ застосовується до кожного еталону $O(q)$ із множини Q . Відстань між векторним описом (дескриптором) точки інтересу та іншими векторами характерних ознак підраховується для кожної ключової точки.

Дві характерні ознаки вважаються однаковими, якщо відстань між векторами їх дескрипторів менша за припустиму помилку ε . Значення для припустимої помилки ε підбирається шляхом експериментів і залежить від бази еталонів Q .

Використання функції належності $\mu_A(a)$ передбачає, що всі еталони одного класу залежні один від одного [57]. Характерна ознака може бути унікальною у межах одного класу еталонів, а повторюватися у межах інших класів. Додавання нового еталону до класу передбачає перерахунок належності дескрипторів всіх еталонів у межах цього класу. Аналіз за допомогою функції належності здійснюється повторно.

Коефіцієнт «унікальності» τ кожної характерної ознаки може визначатися:

$$\tau = e / \text{total},$$

де e – кількість однакових унікальних ознак у межах одного еталону $O(q)$;

total – загальна кількість еквівалентних унікальних ознак бази еталонів Q .

Дескриптор видаляється з розгляду, якщо значення менше заздалегідь прийнятого порогу δ_o . Якщо ця ключова точка повторювалася в інших еталонах бази еталонів Q – усунення примітиву спрацює автоматично. Виняток із досліджуваної множини «неунікальної» ключової точки дозволить зменшити обсяг бази даних та підвищити швидкодію розпізнавання зображення.

Якість та швидкодія розпізнавання покращується при $\tau \rightarrow 1$, а обсяг бази даних зменшується.

Для елемента o_i опису $O = \{o_i\}_{i=1}^I$ визначимо число h_i повторень:

$$h_i = \sum_{j=1, I} 1(\rho(o_i, o_j) \leq \delta_o), \quad (3.12)$$

$$\text{де } 1(\rho(o_i, o_j) \leq \delta_o) = \begin{cases} 1, & \rho(o_i, o_j) \leq \delta_o, \\ 0, & \text{otherwise.} \end{cases}$$

$h_i \in C_+$ – це число елементів O , еквівалентних елементу $o_i \in O$ з точністю до δ_o відповідно істинності предикату $1(\rho(o_i, o_j) \leq \delta_o)$, C_+ – множина цілих невід’ємних чисел.

Розглянемо скінченну множину $O = \{O^i\}_{i=1}^Q$ описів, що відповідають базі зображень з Q еталонів. Для кожної ключової точки $o_{ij} \in O^i$ еталону з номером i обчислимо індекси унікальності: α_{ij}, β_{ij} :

$$\alpha_{ij} = c_{ij} / s_i, \quad \beta_{ij} = c_{ij}^s / (s - s_i), \quad \alpha_{ij} \in [0, 1], \quad \beta_{ij} \in [0, 1], \quad (3.13)$$

де c_{ij} – число (3.12) подібних елементів для o_{ij} в i -му еталоні;

s_i – число характерних ознак i -го еталону;

c_{ij}^s – значення (3.12) для o_{ij} в базі еталонів, крім еталону з номером i ;

$s = \sum_i s_i$ – загальна кількість елементів описів бази O .

Для елементів кожного еталону обчислимо значення індексів (3.13) та інтегральні показники $\sum_j \alpha_{ij}$, $\sum_j \beta_{ij}$. У випадку $s_i \neq s_q$ при $i \neq q$.

Індекс α_{ij} показує ступінь повторюваності j -го елементу всередині i -го еталону. Індекс β_{ij} показує рівень повторюваності j -го елементу в описах інших об'єктів бази, крім i -го. Найбільш значущим для розпізнавання можна вважати β_{ij} . Чим ближче β_{ij} до нуля, тим більш унікальний елемент серед інших елементів бази. Сума $\alpha_{ij} + \beta_{ij}$ показує ступінь унікальності елемента по всій базі. Інтегральні показники $\sum_j \alpha_{ij}$, $\sum_j \beta_{ij}$ характеризують загальну унікальність елементів еталону в межах бази.

Дослідження значень $\{o_{ij}, \alpha_{ij}, \beta_{ij}\}$ та інтегральних показників дає можливість практично оцінити ступінь розрізнення об'єктів бази при застосуванні структурної класифікації. Аналіз індексів унікальності α_{ij}, β_{ij} дозволяє побудувати та застосувати процедури редукції ознак як усередині еталона, так і у межах бази

Фільтрування здійснюється шляхом побудови предикату «важливості» елемента у новому описі. На основі обчислених характеристик можна виділити групи (гранули) рідко або часто повторюваних ключових точок.

Запропоновано способи редукції ознак:

1. Еталони обробляються незалежно. Визначається кортеж із g ознак з найменшими значеннями α_{ij} .

2. Для кожного еталону формується кортеж із g унікальних ознак серед інших еталонів, тобто з найменшими значеннями β_{ij} .

Збільшення швидкодії розпізнавання зображень для цих способів становить s_i / g . Трансформація ознакового простору здійснюється на попередньому етапі та не впливає на час розпізнавання.

Другий спосіб перспективніший і впливає на ефективність. Критерій β_{ij} показує рівень відмінності еталонів. Ознаки з високим значенням α_{ij} інтенсивно повторюються всередині опису. Ключові точки з максимальним значенням α_{ij} містять інформаційну складову та відображаються на результатах розпізнавання.

Визначення поняття «гранула» та запропоновані способи обчислення індексів унікальності дають можливість сформувати елементи бази описів у системі класів. Такий підхід гранулює елементи в групі і значно скорочує час оброблення [12].

Класи можуть бути визначені на основі характеристик α_{ij}, β_{ij} .

Класифікуючи різні елементи в базі $U = \{u_1, u_2, \dots, u_i, \dots, u_l\}$, отримаємо подання еталону в вигляді мультимножини [60]. Належність точки o мультимножині A встановлюється шляхом обчислення характеристичної функції

$$\chi_A(Z) = \begin{cases} 1, & o \in A, \\ 0, & o \notin A. \end{cases}$$

Перевірка $o \in A$ виконується порівнянням o з елементами U на основі $\rho(o, u_i)$ (або іншої міри).

Клас u_* елементу o визначимо шляхом дискретної оптимізації

$$u_* = \arg \min_{u_i \in U} \rho(o, u_i), \quad \rho(o, u_*) \leq \delta_o, \quad (3.14)$$

на множині U . Класифікація (3.14) включає перевірку умови $\rho(o, u_*) \leq \delta_o$.

Запропонований підхід дозволяє видалити з розгляду окремі елементи зображення.

На основі (3.14) при k базових класах для еталону $O(q)$ отримаємо векторне подання

$$\varphi(j) = \{\varphi_1, \varphi_2, \dots, \varphi_i, \dots, \varphi_k\}, \quad \varphi_i \in C_+, \quad (3.15)$$

де φ_i – кратність входження i -го базового елемента.

На основі запропонованої класифікації (3.14) та векторного опису (3.15) виконана трансформація $O \rightarrow \varphi$. Дане перетворення здійснено з множинного подання у векторному описі φ кінцевої розмірності k з компонентами із C_+ .

«Представники» кластерів задаються апріорно множиною U . Спосіб класифікації на основі U аналогічний розкладанню по системі ортогональних функцій. Основна відмінність полягає в тому, що для елементів U ортогональність не потрібна. В отриманій системі ознак не потрібно відновлювати елементи.

Розпізнавання об'єкта при мультимножинному поданні здійснюється шляхом обчислення та мінімізації відстані

$$\rho(A, B) = \frac{\sum_i w_i |\varphi_A(u_i) - \varphi_B(u_i)|}{\sum_i w_i \max[\varphi_A(u_i), \varphi_B(u_i)]}, \quad (3.16)$$

де w_i – вагові коефіцієнти (у даному дослідженні прийнято $\sum_i w_i = 1$);

$\varphi_A(u_i), \varphi_B(u_i)$ – кратності при поданні множин A та B у проєкції базового елемента $u_i \in U$.

Дворівневу систему класифікації отримано при реалізації гранулювання даних за допомогою (3.14) або (3.15) для елементів O . У цій системі клас об'єкта визначається як

$$j = \text{Class}_2[\text{Class}_1[O, U]], \quad (3.17)$$

де Class_1 – класифікація на рівні елементів опису в базі U ;

Class_2 – класифікація трансформованого опису в базі O .

Створення вдалої базової множини $U = \{u_i\}_{i=1}^k$ забезпечить результативну класифікацію за запропонованою методикою. Множина U – це тезаурус, ознаки опису якого знаходять своє місце у поданні $\varphi(q)$. Тезаурус – це сукупність термінів, що описують предметну область із зазначенням семантичних відношень між ними.

Елементи, які віднесені до множини u_i , є об'єктами-синонімами. Під час розпізнавання такі об'єкти формально не розрізняються.

Нехай s є вхідним числом ознак. Обчислення індексів унікальності та класів ґрунтується на аналізі симетричної матриці відстаней $M = \|m_{i,j}\|_{s \times s}$, де $m_{i,j} = \rho(o_i, o_j)$. Відстані відображають зв'язок між елементами у вигляді ступеня еквівалентності [60]. Для кожного o_i можна визначити характеристики сумарної та середньої зв'язності

$$d_i(o_i) = \sum_{j=1}^s m_{i,j}, \quad \bar{d}_i = \frac{1}{s-1} \sum_{j=1, j \neq i}^s m_{i,j}, \quad (3.18)$$

де використовуються елементи i -го рядка або стовпця матриці M . Чим менше значення (3.18), тим сильніше i -й елемент пов'язаний з іншими з опису.

У порядку зниження рівня зв'язності здійснимо впорядкування елементів, наприклад, як $d_{\min} = d_1 \leq d_2 \leq \dots \leq d_s = d_{\max}$. Створюється рейтинговий список, по якому вибираються найбільш інформативні елементи ($\max d_i$).

Другим способом аналізу є підрахунок кількості елементів, з якими пов'язаний аналізований елемент відповідно до (3.13). У результаті отримаємо необхідний порядок елементів.

Обидва способи передбачають перевірку умови $r_{i,j} \leq \delta_r$. Аналізуються лише «значущі» зв'язки. Запропоновані моделі обробки даних (3.13), (3.18) є основою побудови множини U та встановлення числа k . Від кількості базових класів k обернено пропорційно залежить збільшення швидкодії.

Методами формування базової множини U є редукція ознак за значеннями характеристик (3.13), (3.18) та кластеризація на множині елементів досліджуваної бази. Елементи U вибираються як представники кластерів. Схема перетворення опису при формуванні інформативних ознак чи векторного подання запропоновано на рисунку 3.6.

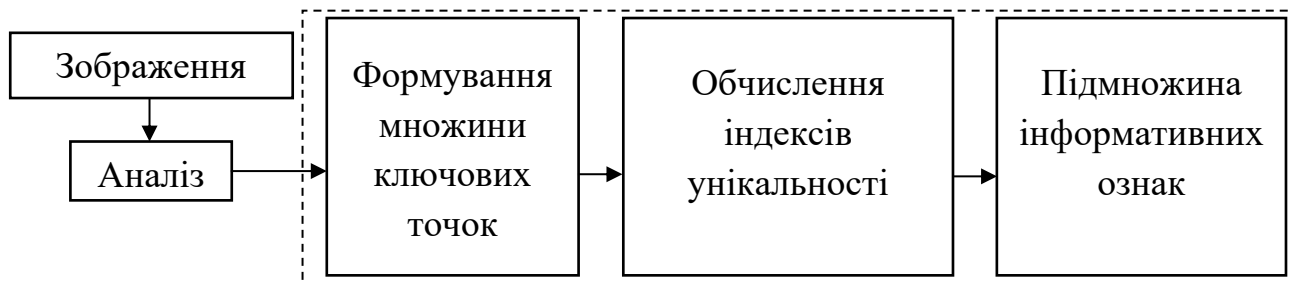


Рисунок 3.6 – Схема перетворення опису зображення

3.4 Результати моделювання методів грануляції

Проведено програмне моделювання розроблених методів мовою Python 3.6 у середовищі Visual Studio 2019 із використанням засобів бібліотеки OpenCV. Програмна платформа може працювати на Windows, Android, iOS, Windows Phone, Mac OS X та Linux.

Результати експериментів показали, що для різних баз зображень при порозі $\delta_o < 0,45$ для багатьох ключових точок (більше 84%) не визначається жодної подібної ознаки. При порозі $\delta_o > 1,77$ всі ознаки стають еквівалентними між собою. У цих ситуаціях неможливо сформувати підмножину унікальних ознак [60]. Для отримання множини унікальних ключових точок найбільш прийнятні значення порогів $\delta_o = 0,59$ та $\delta_o = 0,78$.

Для проведення дослідження відібрано 12 зображень розміром 300×300 пікселів (рис. 3.7).

Знімки завантажені із бази портретів відомих кіноактрис [61]. Число характерних ознак SURF в їх описах склало: 91, 87, 97, 85, 99, 92, 89, 90, 92, 86, 95, 98. Таблиця 3.2 містить значення індексів унікальності (3.13) для 10-ти перших ключових точок і індекс для опису зображення № 1 рисунку 3.7.

Подані ключові точки (табл. 3.2) мають досить близькі значення (3.13). Результуючий діапазон значень опису зображення № 1 рисунку 3.7 становить від 0,25 до 0,75.

Рисунок 3.8 містить гістограму повторювань ознак в описі зображення № 1 рисунку 3.7. Результати досліджень показали, що існує група унікальних ознак (рис. 3.8), яку можна взяти за основу для формування компактного опису.



Рисунок 3.7 – Приклади зображень із бази портретів відомих кіноактрис

Таблиця 3.2 – Значення індексів унікальності для зображення № 1 рисунку 3.7

№ ключової точки	1	2	3	4	5	6	7	8	9	10	Сума
α_{ij}	0,32	0,55	0,38	0,31	0,28	0,45	0,53	0,37	0,44	0,69	38,16
β_{ij}	0,27	0,49	0,26	0,39	0,34	0,47	0,46	0,48	0,43	0,67	33,89




Рисунок 3.8 – Гістограма повторення значень ознак в описі зображення № 1 із зображеннями № 2 – № 12 рисунку 3.7

Таблиця 3.3 містить номери та значення індексів для 10-ти найбільш унікальних ключових точок.

Таблиця 3.3 – Значення індексів унікальності для відібраних ключових точок

№ ключової точки	67	29	88	83	82	21	50	14	70	44
α_{ij}	0,10	0,12	0,12	0,15	0,18	0,21	0,22	0,24	0,25	0,26
№ ключової точки	67	29	88	52	83	25	82	65	42	26
β_{ij}	0,07	0,10	0,11	0,17	0,17	0,19	0,20	0,21	0,23	0,24

На рисунку 3.9 показано множину сформованих ключових точок та підмножини з 10 унікальних ключових точок.

Критерій унікальності є основним для отримання стисненого опису. Кількість ключових точок може бути зменшено одразу в 9 разів. Імовірність правильного розпізнавання на основі стисненого опису з 10 унікальних ключових точок за відсутності завад при цьому не знижується.

Час розпізнавання у проведеному експерименті знизився у 3,4 рази. Скорочення обчислювальних витрат залежить від розміру бази зображень.

Позитивний ефект перевищує 120 разів при кількості зображень – 45. Експеримент із виділенням унікальних ознак на зображенні продемонстрував, що позитивний ефект для 12 еталонів становить приблизно 75 разів.

Дослідження підтвердило, що кількість помилкових збігів для системи унікальних ключових точок зображень істотно менша, ніж для повних описів.

При порозі $\delta_o = 0,59$ кількість помилкових збігів знижується з 92% – 94% до 12% – 30%, а при порозі $\delta_o = 0,45$ – з 52% до 8%.




Рисунок 3.9 – Результат експерименту із зображенням № 1 рисунку 3.7: множина із 91 ключової точки (а), 10 унікальних ключових точок (б), 10 унікальних ключових точок у базі 12 зображень рисунку 3.7 (в)

Представлені гістограми на рисунку 3.10 показують число подібних ключових точок зображення № 1 на рисунку 3.7: власні 10 унікальних ознак (а), 10 унікальних ознак у межах всієї бази (б) без застосування порога δ_o .




Рисунок 3.10 – Гістограми подібних ключових точок зображення № 1 рисунку 3.7

Дані гістограми підтверджують можливість розпізнавання з урахуванням класифікації ключових точок. Базовою множиною виступає 10 унікальних характерних ознак.

У цьому дослідженні значення допустимої помилки ε встановлено в інтервалі $[0,1; 0,4]$, порогу δ_o – $[0,5; 0,8]$. Проведені експерименти підтвердили ефективність застосування функції належності.

Додатково проведена класифікація при спотворенні зображень адитивним шумом з розподілом Гауса. При завадах кількість ключових точок завжди зростає. Експеримент показав збільшення числа ознак у 4 рази.

При проведенні розпізнавання на основі множин унікальних ключових точок еталонів кількість помилкових відповідностей при порозі $\delta_o = 0,45$ скоротилася з 46% до 1,8%. Імовірність розпізнавання не знижується. Число збігів з досліджуваним об'єктом становить 92%. Результати отримані для бази із 75 зображень золотих сережок [62] (рис. 3.11).



Рисунок 3.11 – Приклади з бази зображень сережок

Можна переконатися у складності експериментальних зразків.

Результатом застосування розробленої методики є компактна підмножина або векторний опис унікальних та інформативних ключових точок. Зменшення кількості ознак дає змогу знизити ймовірність помилкової ідентифікації об'єктів на зображенні [63]. Апарат нечіткої логіки використовується для визначення ступеня належності досліджуваного об'єкта до еталонного класу.

Прикладні експерименти підтвердили ефективність стиснення вхідних даних. Важливим етапом знаходження значимих ключових точок є формування базової множини для класифікації елементів.

Прикладна значущість роботи обґрунтована за критерієм часу оброблення без зниження характеристик достовірності та завадостійкості.

Результати тестування розроблених підходів показали збільшення швидкодії структурного розпізнавання зображень у декілька разів.

4 КЛАСИФІКАЦІЯ ТА ОБРОБЛЕННЯ ДАНИХ ЗАСОБАМИ НЕЧІТКОЇ ІНТЕРВАЛЬНОЇ ЛОГІКИ

4.1 Інтелектуальні засоби класифікації станів біофізичної системи

У сучасних системах управління та оброблення багатовимірних даних, пов'язаних із задачами прикладної біофізики, часто необхідно приймати рішення в умовах суттєвої невизначеності, коли варто враховувати неточність, нечіткість чи недостовірність даних або знань, та класифікувати чи діагностувати стани системи, що не підлягає формалізації [64].

У такій ситуації більш результативними можуть бути підходи нечіткої інтервальної логіки, що дають можливість використовувати в явному вигляді не тільки значення функції належності, але і її аналітичну форму, забезпечуючи цим самим достатньо високий ступінь достовірності рішень.

На практиці вибір нечітких правил, змінних і їх значень безпосередньо пов'язаний із предметною областю та із особливостями управління її процесами [65].

Геоінформаційний інструментарій дозволяє користувачеві здійснити пошук, аналіз та редагування цифрової карти, надає можливість управляти територіями та отримувати інформацію про об'єкти управління з урахуванням просторових координат X, Y, Z .

Прикладом сучасної ГІС є програмна платформа ArcGIS 10.3.

Метою нашого дослідження [26] є підвищення достовірності прийняття рішень щодо станів біофізичної системи за рахунок застосування нечітких інтервальних уявлень про класифіковані стани об'єктів.

Під нечітким динамічним об'єктом (НДО) будемо розуміти взаємодіючі предмети і процеси нечітких мережевих моделей, які створюються у процесі моделювання, мають нечіткі атрибути та властивості, зміст яких змінюється в часі згідно динаміки розвитку модельованих процесів.

Прикладом НДО є людина – складна біофізична система, яка може набувати множину певних станів у встановленому просторі ознак.

НДО описується такими елементами:

$$\text{НДО} = \left\{ \tilde{P}_i(\text{in}), \tilde{t}_i, \tilde{P}_i(\text{out}), \mu, \Delta\mu_{i\tilde{A}}, X, Y, Z, \tilde{M}_{p_j}(\text{in}), \tilde{L}\{x_u\}, \tilde{M}_{\tilde{p}_j} \right\} \quad (4.1)$$

де $\tilde{P}_i(\text{in})$ – значення параметрів вхідного об'єкта;

\tilde{t}_i – визначення дії (переходу);

$\tilde{P}_i(out)$ – стан вихідного об’єкта;

μ – функція належності вхідного об’єкта;

$\Delta\mu_{i\tilde{A}}$ – значення функції належності, подане через аналітичну форму деякого інтервального значення ($\Delta\mu_{i\tilde{A}}(x)$), що є принциповим. Функція належності вказує ступінь приналежності елемента x до нечіткої множини \tilde{A} . У роботі використано такі види функцій належності: показникова, трикутна, трапецієвидна, Гауса;

X, Y, Z – координати просторового об’єкта в ГІС;

$\tilde{M}_{p_j}(in)$ – маркірування вихідної позиції $\tilde{p}_j \in \{\tilde{P}_i(out)\}$ переходу \tilde{t}_i мережі;

$\tilde{L}\{x_u\}$ – предикат на моделі $\tilde{S}(f) = \langle \tilde{P}, \tilde{T}, \tilde{F}(f), \tilde{M}(f)_0, \tilde{D}, \tilde{B}, \tilde{C}, \tilde{\Lambda}, \tilde{L} \rangle$:

$$\tilde{L}\{x_u\} = \begin{cases} 1, & \text{if } \tilde{L}\{x_u\} = \text{true}, \\ 0, & \text{if } \tilde{L}\{x_u\} = \text{false}; \end{cases}$$

$\tilde{M}_{\tilde{p}_j}$ – вектор поточного маркірування.

Якщо, наприклад, трикутна функція $\Delta\mu_{1\tilde{A}}(x)$ на нечіткій множині \tilde{A} визначається значеннями сторін трикутника (a, b, c) та описується залежністю

$$\mu(x) = \begin{cases} 0, & x \leq a, \\ \frac{x-a}{b-a}, & a < x \leq b, \\ \frac{c-x}{c-b}, & b < x \leq c, \\ 0, & c < x, \end{cases} \quad (4.2)$$

а показникова функція $\Delta\mu_{2\tilde{A}}(x)$ на нечіткій множині \tilde{A} описується як

$$y_2(x) = 1 - e^{-k(x-f)^2}, \quad (4.3)$$

то результуюче значення $\Delta\mu_{1\tilde{B}}(x)$ на нечіткій множині \tilde{B} буде знаходитись у межах «більше, ніж $\Delta\mu_{1\tilde{A}}(x)$ і менше, ніж $\Delta\mu_{2\tilde{A}}(x)$ », тобто $\overline{\Delta\mu_{1\tilde{A}}(x)} \leq \Delta\mu_{1\tilde{B}}(x) \leq \Delta\mu_{2\tilde{A}}(x)$.

Як показано на прикладі (рис. 4.1), перетин двох функцій належності (4.2) та (4.3), представлених через інтервальні значення (аналітичні форми), утворює область перерізу, площа якої описується фігурою *deb* на деякій нечіткій множині \tilde{B} .




Рисунок 4.1 – Перетин функцій належності
(значення $\Delta\mu_{1\tilde{B}}(x)$ визначає штрихова поверхня *deb*)

Для визначення $\Delta\mu_{1\tilde{B}}(x)$ застосуємо дефаззіфікацію на основі принципу «центра мас»

$$\Delta\mu_{1\tilde{B}}(x) = \frac{\sum_{i=0}^I \Delta\mu_{i\tilde{A}}(x) S_{i\tilde{A}}}{\sum_{i=0}^I S_{i\tilde{A}}}, \quad (4.4)$$

де $\Delta\mu_{1\tilde{B}}(x)$ – результуюча функція належності;

$\Delta\mu_{i\tilde{A}}(x)$ – аналітичне значення функції належності інтервальної форми;

$S_{i\tilde{A}}$ – площа області перетину.

При цьому реалізація інтелектуальних обчислювальних механізмів, процедур прямого *modus ponens* (GMP) та зворотного *modus tollens* (GMT) нечіткого логічного виведення [57] (нечітка логіка на інтервалі) $0 \leq \overline{\Delta\mu_{1\tilde{A}}(x)} \leq \Delta\mu_{1\tilde{B}}(x) \leq \Delta\mu_{2\tilde{A}}(x)$ може бути виконана з урахуванням координат X, Y, Z .

Під час дослідження використано процедури GMP та GMT *if/then* умови з відомим відношенням $\tilde{R}(x, y)$ та нечіткими значеннями антецедента \tilde{A}' або наслідку \tilde{B}' , які дозволили визначити наслідок \tilde{B}' або значення антецедента \tilde{A}' з наступною дефаззіфікацією [57].

Ключовим моментом цього дослідження є те, що реалізовано нечітке логічне виведення та виконано об'єднання скінченного числа нечітких правил з використанням законів силогізму, які дозволили кожному умову правил із бази знань аналітично описати нечіткими відношеннями.

Процедури нечіткого логічного виведення на взаємодіючих процесах дослідимо на моделях, побудованих композицією фрагментів (рис. 4.2).

Для фрагмента моделі:

$$\exists \tilde{t}_i \in \tilde{T} / (\|\tilde{p}_i(in)\| = 1) \text{ and } (\|\tilde{p}_i(out)\| = 1) \quad (4.5)$$

запишемо таку конструкцію вирішення процедури прямого нечіткого логічного виведення:

$$\begin{aligned} & \text{if } \tilde{p}_j \in \{\tilde{p}_i(in)\} \text{ is } \mu_{\tilde{p}_j}(k) \text{ then } \tilde{t}_i \text{ is } \mu_{\tilde{t}_i} \\ & \text{if } \tilde{t}_i \text{ is } \mu_{\tilde{t}_i}(k) \text{ then } \tilde{p}_j \in \{\tilde{p}_i(out)\} \text{ is } \mu_{\tilde{p}_j} \\ & \tilde{p}_j \in \{\tilde{p}_i(in)\} \text{ is } z_{\tilde{p}_j}(k) \end{aligned}, \quad (4.6)$$

$$\tilde{p}_j \in \{\tilde{p}_i(out)\} \text{ is } z_{\tilde{p}_j}(k)$$

де $z_{\tilde{p}_j}(k)$ у загальному випадку визначене згідно $\mu_{\tilde{p}_j}(k)$,

або

$$\begin{aligned} & \text{if } \tilde{p}_j \in \{\tilde{p}_i(in)\} \text{ is } \mu_{\tilde{p}_j}(k) \text{ then } \tilde{p}_j \in \{\tilde{p}_i(out)\} \text{ is } \mu_{\tilde{p}_j}(k) \\ & \tilde{p}_j \in \{\tilde{p}_i(in)\} \text{ is } z_{\tilde{p}_j}(k) \end{aligned}, \quad (4.7)$$

$$\tilde{p}_j \in \{\tilde{p}_i(out)\} \text{ is } z_{\tilde{p}_j}(k)$$

тоді відношення може бути представлено:

$$R(\tilde{p}_j \in \{\tilde{p}_i(in)\}, \tilde{p}_j \in \{\tilde{p}_i(out)\}) = \tilde{R}_1(\tilde{p}_j \in \{\tilde{p}_i(in), \tilde{t}_i\}) \circ \tilde{R}_2(\tilde{t}_i, \tilde{p}_j \in \{\tilde{p}_i(out)\}). \quad (4.8)$$

З урахуванням цього отримаємо розв'язок у просторі функцій належності:

$$z_{\tilde{p}_j \in \{\tilde{p}_i(out)\}}(k) = z_{\tilde{p}_j \in \{\tilde{p}_i(in)\}}(k) \wedge \mu_R(\tilde{p}_j \in \{\tilde{p}_i(in)\}, \tilde{p}_j \in \{\tilde{p}_i(out)\}). \quad (4.9)$$

У (4.6) – (4.9) функції належності і їх значення визначені як $0 \leq \mu_1(k) \leq z_{\tilde{p}_j=a}(k) \leq \mu_2(k)$. Аналогічно (4.6) – (4.9) можуть бути отримані розв'язки і для фрагментів моделі з іншими поєднаннями вхідних і вихідних вершин моделі.

Запропонована формалізована модель інтелектуальних засобів класифікації надає можливість спроектувати нечітку модель діагностики стану людини та забезпечує механізм розрахунку коефіцієнту впевненості у кожному стані із визначеної множини простору станів біофізичної системи.

Реалізація поставленої задачі полягає у визначенні деякої підмножини станів на основі їх формальної класифікації з використанням ідей обчислювального інтелекту [50, 66-69].

У спроектованій системі використано розроблені [23-25] та існуючі підходи [55], проведено інтелектуальну обробку даних, надано користувачу повну інформацію для прийняття рішення.

Нехай ϵ множина діагностичних ознак $\tilde{P}_j, j \in J$ для множини станів $\{D_j\}, j \in J$. Вся множина ознак $\tilde{P}_j, j \in J$ розбивається на 4 групи за родинною властивістю \tilde{S}_j (симптоми, як правило візуального характеру), \tilde{F}_j (фактори, що негативно впливають на людину), \tilde{L}_j (результати технічних обстежень), $\tilde{D}\tilde{S}_j$ (додаткові симптоми, які виявляють за допомогою додаткового опитування), які відповідають чотирьохетапному діагностуванню станів [58].

Для кожного значення із множини ознак $\tilde{P}_j, j \in J$ задається його функція належності μ_j до кожного стану $\{D_j\}, j \in J$, тобто отримуємо деяку множину $\{\mu_j(x)\}, j \in J$.

Задамо коефіцієнти впевненості KU_j ознак у певних класифікаціях станів (діагнозах) $\{D_j\}, j \in J$, тобто отримуємо деяку множину $\{KU_j(k)\}, j \in J$.

Виходячи із

$$|\{\mu_j(x)\}| = |\{KU_j(k)\}|, \quad (4.10)$$

можемо стверджувати, що існує еквівалентність значень коефіцієнтів впевненості і функцій належності, яка використовується у даному дослідженні під час розв'язання задачі класифікації станів людини:

$$\forall \mu_j(x), \forall KU_j(k), \mu_j(x) \in \{\mu_j(x)\}, KU_j(k) \in \{KU_j(k)\} \mid \mu_j(x_0) = KU_j(k_0), \quad (4.11)$$

$$\begin{aligned} \forall \Delta \mu_j(x), \forall \Delta KU_j(k), \Delta \mu_j(x) \in \{\Delta \mu_j(x)\}, \\ \Delta KU_j(k) \in \{\Delta KU_j(k)\} \mid \Delta \mu_j(x_0) = \Delta KU_j(k_0) \end{aligned} \quad (4.12)$$

причому, необхідно враховувати, що $\mu_j(x_0)$ є верхньою границею оцінки $KU_j(k_0)$

$$\mu_j(x_0) \geq KU_j(k_0), \quad (4.13)$$

а $\Delta \mu_j(x_0)$ є відповідно верхньою границею оцінки $\Delta KU_j(k_0)$

$$\Delta \mu_j(x_0) \geq \Delta KU_j(k_0). \quad (4.14)$$

Таким чином, кожній ознаці у групі ставиться у відповідність коефіцієнт впевненості $\{KU_j(k_0)\}$, який співпадає з функцією належності $\{\mu_j(x_0)\}$ значень ознаки \tilde{P}_j , $j \in J$ до класифікації станів $\{D_j\}$, $j \in J$, тобто

$$\mu_j(x_0) \approx KU_j(k_0), \quad (4.15)$$

$$\Delta\mu_j(x_0) \approx \Delta KU_j(k_0). \quad (4.16)$$

Тоді, якщо існує деяка сукупність функцій належності $\{\mu_j(x_0)\}$, а також сукупність аналітичних залежностей, які визначають коефіцієнти впевненості $\{KU_j(k_0)\}$, то з деяким наближенням буде виконуватися (4.15).

Так, наприклад, якщо у деяких випадках отримуємо значення функції $\mu_j(x_0) = 0,66$, то значення коефіцієнта впевненості може бути визначене як (4.13) і з урахуванням (4.15) коефіцієнт впевненості $KU_j(k_0) \approx 0,66$, тобто він не перевищує значення функції належності $\mu_j(x_0)$.

Визначення коефіцієнта впевненості $KU_j(k)$ у станах (діагнозах) $\{D_j\}$, $j \in J$ за всіма ознаками \tilde{P}_j , $j \in J$, що входять у конкретну вибрану групу \tilde{S}_j , \tilde{F}_j , \tilde{L}_j , $\tilde{D}\tilde{S}_j$, упорядковано за зменшенням значимості, здійснюється згідно підходу [58]: для групи \tilde{S}_j визначаємо значимі (не нульові) значення функцій належності $\mu_b(\tilde{S}_b)$:

$$\tilde{S}_j = \bigcup_{b=1}^B Pr_{\tilde{s}} \tilde{S}_b \rightarrow \mu_b(\tilde{S}_b), \quad (4.17)$$

де $Pr_{\tilde{s}}$ – параметри, що відповідають вибраній групі \tilde{S}_j ;

\tilde{S}_b – значення вибраного параметра $Pr_{\tilde{s}}$ із групи \tilde{S}_j ;

Для груп \tilde{F}_j , \tilde{L}_j , $\tilde{D}\tilde{S}_j$ визначаємо значимі (не нульові) значення функцій належності аналогічно (4.17).

Визначення коефіцієнта впевненості $KU_j(k)$ з урахуванням (4.15) і (4.17) має вигляд:

$$KU_j(k) = \frac{\sum_{b=0}^B \mu_b(\tilde{S}_b)}{|\tilde{S}_b|} \vee \frac{\sum_{d=0}^D \mu_d(\tilde{F}_d)}{|\tilde{F}_d|} \vee \frac{\sum_{q=0}^Q \mu_q(\tilde{L}_q)}{|\tilde{L}_q|} \vee \frac{\sum_{h=0}^H \mu_h(\tilde{D}\tilde{S}_h)}{|\tilde{D}\tilde{S}_h|}, \quad (4.18)$$

де $\mu_b(\tilde{S}_b)$, $\mu_d(\tilde{F}_d)$, $\mu_q(\tilde{L}_q)$, $\mu_h(\tilde{D}\tilde{S}_h)$ – функції належності за кожною ознакою, що відповідають групам \tilde{S}_j , \tilde{F}_j , \tilde{L}_j і $\tilde{D}\tilde{S}_j$, упорядковано за зменшенням значимості;

$|\tilde{S}_b|$, $|\tilde{F}_d|$, $|\tilde{L}_q|$, $|\tilde{D}\tilde{S}_h|$ – потужності множин значимих ознак, для яких $\mu_b(\tilde{S}_b) \geq \varepsilon^*$, $\mu_d(\tilde{F}_d) \geq \varepsilon^*$, $\mu_q(\tilde{L}_q) \geq \varepsilon^*$, $\mu_h(\tilde{D}\tilde{S}_h) \geq \varepsilon^*$, ε^* – деякий мінімальний поріг, причому

$$|\tilde{S}_b| \subset \tilde{S}_j, |\tilde{F}_d| \subset \tilde{F}_j, |\tilde{L}_q| \subset \tilde{L}_j, |\tilde{D}\tilde{S}_h| \subset \tilde{D}\tilde{S}_j.$$

Визначимо коефіцієнт впевненості на інтервалі $\Delta KU_j(k)$ з урахуванням (4.16):

$$\Delta KU_j(k) = \frac{\sum_{j=0}^n \Delta \mu_j(\tilde{S}_j) Pl_i}{\sum Pl_i} \vee \frac{\sum_{j=0}^n \Delta \mu_j(\tilde{F}_j) Pl_i}{\sum Pl_i} \vee \frac{\sum_{j=0}^n \Delta \mu_j(\tilde{L}_j) Pl_i}{\sum Pl_i} \vee \frac{\sum_{j=0}^n \Delta \mu_j(\tilde{D}\tilde{S}_j) Pl_i}{\sum Pl_i}, \quad (4.19)$$

де $\Delta \mu_j(\tilde{S}_j)$, $\Delta \mu_j(\tilde{F}_j)$, $\Delta \mu_j(\tilde{L}_j)$, $\Delta \mu_j(\tilde{D}\tilde{S}_j)$ – функції належності, подані через інтервал за кожною ознакою і відповідають групам \tilde{S}_j , \tilde{F}_j , \tilde{L}_j і $\tilde{D}\tilde{S}_j$;

Pl_i – елементарна площа, що відповідає області перетину всіх функцій належності, поданих через інтервали за кожною із ознак, та групами \tilde{S}_j , \tilde{F}_j , \tilde{L}_j і $\tilde{D}\tilde{S}_j$.

Тоді

$$KU_{j(zakl)} = \max KU_j(k), \quad (4.20)$$

$$\Delta KU_{j(zakl)} = \max \Delta KU_j(k). \quad (4.21)$$

Таким чином, коефіцієнт впевненості $KU_{j(zakl)}$ або $\Delta KU_{j(zakl)}$ у стані $\{D_j\}$, $j \in J$ на основі коефіцієнтів $KU_j(k)$ або $\Delta KU_j(k)$, обчислених за кожною групою споріднених ознак, визначено відповідно до (4.20), (4.21).

Отже, запропоновані підходи для проектування нечіткої моделі класифікації стану людини забезпечують формування заключної множини станів з коефіцієнтами впевненості на основі обробки множини ознак \tilde{P}_j , $j \in J$ для простору станів $\{D_j\}$, $j \in J$, причому ознаки мають значення функцій належності, що подані через аналітичні форми інтервальних значень $(\Delta \mu_{i\tilde{A}}(x))$.

Спроектована архітектура інтелектуальних засобів передбачає сортування значень станів за коефіцієнтом впевненості, присвоюючи результату стан з максимальним коефіцієнтом впевненості.

4.2 Прикладні технології прийняття рішень

Нами розроблено структуру і функції системи [47, 63] з використанням об'єктно-орієнтованого програмування Python, яка забезпечує: обробку ознак; класифікацію станів; визначення ступеню впевненості; мінімальні вимоги до рівня кваліфікації професіонала, що отримує заключне рішення щодо стану.

Основною функцією створеного інтерфейсу є формалізована система опитування, структура якої дозволяє вести діалог з оператором, що приймає рішення в оптимальному режимі, а також формує список необхідних додаткових даних, які слід надати у залежності від попередніх етапів.

У даній системі передбачено отримання додаткових ознак і інших показників, використовуючи сучасні засоби телекомунікацій та Internet-технологій [55].

Пояснення заключного вирішення щодо станів подано незалежно від правил і формується на природній мові. У раніше розроблених системах пояснення складалося із тексту відповідного правила, що викликало у користувачів труднощі.

Для аналізу результатів дослідження виконано тестування розробленої інтелектуальної системи та оцінено складність моделювання процесів, що дає можливість аналізувати практичну результативність спроектованої системи.

Усі початкові дані подані у вигляді множини позицій: \tilde{P}_j , $j \in J$, $|\tilde{P}_j| \cong 950$.

Множина основних симптомів \tilde{S}_j , факторів \tilde{F}_j , результатів технічних обстежень \tilde{L}_j і додаткових симптомів $\tilde{D}\tilde{S}_j$ визначають значення, які відображають ознаки можливих станів.

До основних симптомів \tilde{S}_j можна віднести, наприклад, такі: «Поведінка роздратована», «Турбує запаморочення постійно», «Серцеві болі дуже сильні». Фактори \tilde{F}_j описуються, наприклад, такими значеннями критеріїв: «Вікова категорія від 50 до 60 років», «Наявність серцево-судинного захворювання – гіпертонія», «Підвищена яскравість світла на робочому місці». Результати лабораторних обстежень \tilde{L}_j представлені у вигляді таких значень: «Інтервал верхнього значення артеріального тиску від 110 до 130», «Інтервал венозного тиску від 50 до 100», «Виявлено зміну очного дна у вигляді звуження артерій сітчатки». Додаткові симптоми $\tilde{D}\tilde{S}_j$ подані за допомогою таких значень критеріїв: «Шкіряний покрив має жовту пігментацію», «Виявлено набряклість на фалангах пальців».

Вибір рішення проводиться в умовах невизначеності інформації про ознаки, що фактично передбачає розгляд більш широкого переліку потенційно можливих станів.

Виникає задача обмеження початкової множини потенційних рішень на кожному етапі класифікації станів:

$$\{|D_{ij}^{(1)}|, |D_{ff}^{(2)}|, |D_{lj}^{(3)}|, |D_{sj}^{(4)}|\} = D$$

підмножиною:

$$\{\{D_{ij}^{(1)}\}, \{D_{ff}^{(2)}\}, \{D_{lj}^{(3)}\}, \{D_{sj}^{(4)}\}\} = D^*$$

при $\{KU_{ij} \geq 0,5\}$, $\{KU_{ff} \geq 0,5\}$, $\{KU_{lj} \geq 0,5\}$, $\{KU_{sj} \geq 0,5\}$ відповідно.

Після визначення підмножини рішень на 2 – 4 етапах класифікації станів людини проводиться їх уточнення, яке призводить до утворення нової підмножини [58]:

$$\{\{D_{ij}^{(1)}\}, \{D'_{ff}^{(2)}\}, \{D'_{lj}^{(3)}\}, \{D'_{sj}^{(4)}\}\} = D'$$

Вирішення цієї задачі полягає у визначенні необхідної підмножини [58]:

$$\{D'_{sj}^{(4)}\} \subset D' \text{ при } \{KU_{sj} \rightarrow \max\}$$

на основі аналізу і обробки кожного рішення по сукупності ознак.

Для визначення складності моделювання процесів, зокрема, часу оброблення даних до видачі результату, вибрано декілька тестових прикладів роботи системи з різною кількістю початкової інформації.

Для кожного із тестових прикладів визначено час виконання процесів моделювання.

Тестовий приклад № 1 першого етапу класифікації. Нехай, як вхідні дані будуть значення 10 основних симптомів \tilde{S}_j виду: «Запаморочення спостерігається дуже часто», «Іноді буває потемніння перед очима». Система видає перелік можливих серцево-судинних діагнозів (класифікацій станів) з певними коефіцієнтами впевненості через 2,95 секунди: {«Стенокардія 0,65», «Гіпертонія 0,87»}.

Тестовий приклад № 2 другого етапу класифікації. Нехай, як вхідні дані будуть значення 8 супутніх факторів \tilde{F}_j виду: «Вікова категорія від 30 до 40 років», «Професія пов'язана з нервовими збудженнями і перенапрутою психікою». Система видає перелік можливих серцево-судинних станів з певними коефіцієнтами впевненості через 2,89 секунди: {«Гіпертонія 0,73», «Стенокардія 0,56»}.

За допомогою розроблених інтелектуальних процедур прийняття рішень, що ґрунтуються на знання орієнтованих технологіях, вдалося отримати не тільки початкову множину відсортованих станів за коефіцієнтом впевненості в них, а й оптимізувати її за рахунок відсікання малозначимих станів, що мають коефіцієнт впевненості менший за 0,5.

Отже, тестування № 1 показало: основний діагноз «Гіпертонія» з коефіцієнтом впевненості 0,87, а на його фоні є ще діагноз «Стенокардія» з коефіцієнтом впевненості 0,65. Для аналізу складності моделювання процесів розробленої системи результати тестування занесемо у таблицю 4.1.

Таблиця 4.1 – Результати тестування системи

№ об'єкту / № етапу класифікації	1/1	1/2	2/1	2/2	2/3	2/4	3/3	3/4	4/3	5/1	5/2	5/4
Кількість введених параметрів, x	10	8	14	6	16	23	10	16	6	18	15	20
Час обробки даних, τ (с)	2,95	2,89	3,11	2,81	3,25	3,74	3,01	3,23	2,94	3,36	3,24	3,54

Залежність складності τ програмного продукту від кількості значень вхідних даних x можна представити у вигляді:

$$\tau(x) = ax^2 + bx + c, \quad (4.22)$$

де a – визначається форматом і розміром динамічних об'єктів;

b – визначається швидкодією комп'ютерних засобів;

c – визначається архітектурою і використаною програмною платформою технічних засобів.

Важливим аспектом під час вирішення задач даного класу в системах значного розміру даних є оцінка їх складності за критеріями витрат часових і обчислювальних ресурсів. Під час розв'язання практичних задач підтверджено, що верхня оцінка складності не перевищує (4.22).

Новизну дослідження складає удосконалення та поглиблене вивчення властивостей методу багатоетапного оперативного оцінювання станів об'єктів, який базується на впровадженні нечітких інтервальних уявлень та інтелектуальних засобів класифікації станів біофізичної системи.

Практична значимість роботи полягає у забезпеченні достовірності класифікації станів біофізичних систем та створенні програмного застосунку, що універсально може бути використаний для довільного набору даних.

Перспективою може бути врахування у створеній системі геоінформаційної складової, що буде сприяти оптимізації її логістичних показників та можливості оцінювання ефективності чи розрахунку вартості функціонування у процесі впровадження.

4.3 Модифікація методу гілок та меж для аналізу компонент функцій належності

Надзвичайно важливим компонентом інтелектуальних систем з нечіткими даними є необхідність досить швидко і точно визначати екстремуми функції належності [50, 70].

Наприклад, у медичних системах підтримки рішень здійснюється визначення екстремумів кожної функції належності для кожного симптому, потім множина екстремумів піддається узагальненню шляхом обчислення центру мас, таким чином розраховується коефіцієнт впевненості у вирішенні конкретного захворювання.

Чим точніше і швидше визначаються екстремуми, тим точніший заключний коефіцієнт упевненості, тобто підвищується достовірність прийнятого рішення про захворювання [58].

Основна проблема застосування градієнтного методу для пошуку оптимуму функції полягає у виборі величини дискретного кроку. Якщо функція має локальні екстремуми, то визначення оптимальних значень утруднено через можливість пропуску глобального екстремуму. Недоліком градієнтного методу є його обчислювальна ресурсоємність при пошуку глобального екстремуму [1].

Генетичні алгоритми припускають послідовний підбір, комбінування та варіацію необхідних значень. Вони проводять пошук у великих і складних просторах станів, дозволяють з досить високою точністю апроксимувати функцію, хоча мають ряд недоліків, таких як обчислювальна складність реалізації і нестійкість рішень [54].

Дихотомічний поділ завжди пропорційний, члени поділу вичерпують один одного, так як кожен об'єкт діленої множини потрапляє тільки в одну з підобластей допустимих рішень M_i або \bar{M}_i , поділ проводиться однотипно – наявність або відсутність деякої ознаки.

До недоліків методу слід віднести невисоку швидкість збіжності та необхідність попереднього визначення інтервалу, на якому функція змінює знак. Таким чином, метод дихотомії застосовують тоді, коли потрібна висока надійність, а швидкість збіжності є несуттєвою.

Оптимізація методом «золотого перерізу» виконується за допомогою послідовних етапів, на яких відбувається зменшення ширини зони пошуку. Зона пошуку при цьому ділиться у пропорції «золотого перерізу».

Фібоначчі доведено, що такий спосіб розподілу діапазону пошуку забезпечує найшвидший вихід до оптимуму. Недолік методу – відсутність гарантії виходу на абсолютний оптимум при складному характері цільової функції, а також більш складніше оброблення у порівнянні із дихотомією.

У цілому, аналіз методів оптимізації, в основі яких лежить покрокове скорочення зони пошуку оптимуму, дозволяє зробити висновок: властива їм висока швидкість наближення до оптимуму робить їх застосування особливо ефективним у тих застосунках, де важливо зведення до мінімуму числа кроків. До їх застосування має передувати попередній аналіз характеру цільової функції для зведення до мінімуму ризику пропуску істинного оптимуму.

Постановка завдання дослідження включає такі складові: дано множину функцій належності, експерт задає їхній вигляд $\mu_i(x)$ із деякими значеннями параметру k_i для кожного $\mu_i(x)$.

Нехай у процесі нечіткого логічного висновку, наприклад, Заде-Мамдані, визначено, що вихідна функція належності має похибку ε , яка перевищує деяку допустиму похибку ε^* . Тоді під час побудови функцій належності $\mu_i(x)$ виникає необхідність приведення значень параметру k_i відповідно до існуючих експертних оцінок. Для визначення підсумкового значення коефіцієнта впевненості за допомогою методу центру мас [54] запропоновано для кожної функції належності $\mu_i(x)$ обчислити екстремум.

Необхідно:

- на множині функцій належності $\mu_i(x)$ запропонувати спосіб настроювання k_i , який мінімізує ε з урахуванням допустимої похибки $\varepsilon \leq \varepsilon^*$, ε^* – граничне значення помилки;
- оцінити обчислювальну складність рішення за часовим критерієм τ .

Метою дослідження є підвищення достовірності прийняття рішень за рахунок оптимізації підобласті допустимих рішень щодо екстремумів функцій належності в нечітких інтелектуальних системах.

Завдання дослідження – модифікувати метод гілок та меж за допомогою посилення його можливостей методами дихотомії та золотого перетину.

У статті [1] запропоновано розвиток методу гілок та меж на основі функціональних можливостей дихотомії та золотого перерізу для вирішення задачі оптимізації функції належності та оцінювання його обчислювальної складності.

Враховуючи нечіткий опис прикладних предметних областей, подання даних проводилося на природній мові термами нечіткої логіки [57]. Наприклад, для лінгвістичної змінної «температура» термами є «знижена», «висока» та «нормальна», аналітичні форми яких можна надати [58]:

$$\mu(x) = e^{-k_1 x^2}, \quad k_1 \geq 0, \quad (4.23)$$

$$\mu(x) = 1 - e^{-k_2(x-a)^2}, \quad k_2 \geq 0, \quad x \geq a, \quad (4.24)$$

$$\mu(x) = e^{-k_3(x-a)^2}, \quad k_3 \geq 0, \quad x \geq a. \quad (4.25)$$

Реалізація лінгвістичних змінних передбачає фізичні описи їх термів, визначення яких можливе при спільній роботі з експертами. Для подання фізичної величини зазвичай достатньо від 3 до 7 термів на кожну змінну. Належність кожного значення терму визначається функцією належності.

У процесі роботи з нечіткими функціями належності, що є результатом фаззифікації лінгвістичних змінних та їх значень деякими правилами продукції *if / then* [24], виникає потреба у їх диференціюванні для знаходження екстремумів значень функцій належності [22].

Проблему дозволяє вирішити використання Гаусіану як функції належності, а також підходи на основі нечіткої логіки [1]. При вирішенні специфічних завдань можна вибрати більш відповідні види функцій і досягти кращих результатів роботи інтелектуальної системи, ніж використання функцій стандартного вигляду.

Загальні положення запропонованої модифікації опишемо на прикладі пошуку мінімуму чи максимуму функції $\mu_i(x)$ на області допустимих значень x . Функція $\mu_i(x)$ та значення x можуть бути довільної природи. Для методу гілок та меж необхідно враховувати дві процедури: розгалуження та визначення оцінок (меж). Процедура розгалуження полягає у розбитті області допустимих рішень M на підобласті M_i менших розмірів:

$$\bigcup_i M_i = M, \quad M_i \cap M_j = 0, \quad i \neq j. \quad (4.26)$$

Принцип поділу далі застосовується до нових отриманих областей. Процедура рекурсивно використовується до усіх отриманих на кожному кроці

підобластей. Сформовані підобласті утворюють дерево пошуку, вузлами якого є збудовані підобласті [54]. Після деякого кроку розбиття кожна підобласть M_i містить по одному оптимальному варіанті x_{opt_i} . Процедура розгалуження закінчується створенням вибірки V з оптимальних варіантів x_{opt_i} для підобластей M_i , яка є вектором можливих допустимих рішень для області M .

Процедура полягає у пошуку верхніх або нижніх меж для оптимального значення на підобластях допустимих рішень:

$$M = V(x_{opt_i} \in M_i), i \in N. \quad (4.27)$$

Визначення екстремуму функції належності зводиться до знаходження оптимального значення функції $\mu_i(x)$ серед значень вибірки V .

Для посилення швидкості збіжності функцій тепер додатково використовуємо метод дихотомії для підбору значень функцій належності $\mu_i(x)$ шляхом послідовного поділу на дві частини досліджуваної множини, що не пов'язані між собою. Дихотомія має властивість збіжності для безперервних функцій, зокрема і недиференційованих [54].

Нехай задана функція належності вигляду

$$\mu_i(x): [a, b] \rightarrow R, \quad \mu_i(x) \in C([a, b]), \quad (4.28)$$

де a, b – межі інтервалу, що підлягає дослідженню;

R – клас невизначених функцій на заданому інтервалі;

C – клас безперервних у кожній точці інтервалу функцій.

Розіб'ємо відрізок навпіл і візьмемо дві симетричні щодо центру точки x_1 та x_2 :

$$x_1 = \frac{a+b}{2} - \delta; \quad x_2 = \frac{a+b}{2} + \delta, \quad (4.29)$$

де δ – деяке число в інтервалі $\left(0, \frac{b-a}{2}\right)$.

Відкинемо той із кінців початкового інтервалу, до якого ближче виявилася одна з двох знову поставлених точок з максимальним значенням (пошук мінімуму).

Якщо $\mu_i(x_1) > \mu_i(x_2)$, то береться відрізок $[x_1, b]$, а відрізок $[a, x_1]$ відкидається. Інакше береться дзеркальний щодо середини відрізок $[a, x_2]$, а відкидається $[x_2, b]$.

Процедура відкидання кінців, обчислювальні процедури дихотомії та процедури нечіткого логічного виведення на деяких з функцій (4.28)

виконуються доти, доки не буде досягнуто заданої точності ε на множині значень $\{k_i\}$, $i \in I$:

$$|y_{\text{actual}} - y_{\text{expected}}| \leq \varepsilon, \quad (4.30)$$

де ε – гранично допустиме відхилення фактичного значення від очікуваного.

Так як на кожній ітерації доводиться обчислювати нові точки, вдосконалимо метод, вираховуватимемо лише одну нову точку на черговій ітерації, що спростить процедуру знаходження екстремумів.

Такий підхід досягається шляхом дзеркального поділу відрізка у золотому перерізі, використовуючи параметр

$$\delta = (b - a) \left(\frac{1}{2} - \frac{1}{\phi} \right), \quad (4.31)$$

де ϕ – пропорція золотого перетину.

Метод золотого перерізу посилює метод гілок і меж, наприклад, для завдання мінімізації за таким принципом: якщо нижня межа для підобласті M_i дерева пошуку більша, ніж верхня межа раніше переглянutoї підобласті M_{i-1} , то M_i може бути виключена з подальшого розгляду.

Мінімальні з отриманих верхніх значень заносяться у глобальну змінну V , а будь-який вузол дерева пошуку, нижня межа якого більша за значення V , виключається з розгляду.

Якщо нижня межа вузла дерева збігається з верхньою, то це значення – мінімум функції і досягається на відповідній підобласті.

Подальше розгалуження у цій вершині не відбувається. Від дерева повного перебору відсікаються вершини і ребра, що йдуть за ними.

Метод золотого перерізу виключає підобласть допустимих рішень M_i із розгляду за допомогою оціночних функцій. Оціночна функція $t(M_i) = t_i$, що задана на вершинах дерева повного перебору і рівна в його кінцевих вершинах відповідним значенням функції приналежності $\mu_i(x)$ для варіантів, що входять в область допустимих рішень M .

Оціночна функція $t(M_i) = t_i$, що дає нижню межу, у процесі розбиття підобласті M_i на частини не зменшується, що визначає верхню межу – не зростає. Чим ближча оцінка до точної межі, тим ефективніше застосування методу. Це пояснюється тим, що число вершин дерева повного перебору, що відсікаються, залежить також і від сили оцінки.

Із загальних міркувань зрозуміло, чим точніша оцінка, тим більших за обсягом обчислень вимагає її відшукання.

При визначенні екстремуму функції належності $\mu_i(x)$ використані такі основні принципи відсікання гілок:

а) відсічення у порівнянні з уже знайденим значенням функції $\mu_i(x)$. Якщо необхідно знайти мінімальне значення $\mu_i(x)$ за умови, що отримані оцінки знизу $M_i(eval)_n = m_i$ для частини вершин дерева та значення функції належності $\mu_i(x) = \mu_0(x)$ для деякої підобласті допустимих рішень M_i , то у вершинах, де $(M_i(eval)_n = m_i) \geq \mu_0(x)$, розгалуження припиняється. $\mu_0(x)$ – знайдене значення певного виду функції належності. Кількість відсікань за цим способом збільшується в міру зменшення значення $\mu_0(x)$;

б) відсікання під час порівняння двох оцінок. Даний спосіб застосовується, якщо для деякої підобласті M_i будується оцінка знизу $M_i(eval)_n = m_i$ та зверху $M_i(eval)_v = m_i$, причому

$$(M_i(eval)_n = m_i) \geq (M_i(eval)_v = m_i), \quad (4.32)$$

то при відшуканні мінімального значення функції $\mu_i(x)$ розгалуження з вершини підобласті M_i припиняється;

в) розгалуження у вибраній вершині припиняється, якщо відомо, що відповідна їй підобласть M_i не містить оптимального значення функції $\mu_i(x)$, або вже відомо x_{opt_i} функції $\mu_i(x)$.

Розгалуження триває, застосовувавши елементи методу дихотомії, такими способами:

– розгалуження за мінімальною нижньою межею (при відшуканні мінімального значення функції належності $\mu_i(x)$). Процедура починається з побудови ребер. Розгалуження утворюється у вершині з мінімальною оцінкою $M_i(eval)_n = m_i$. Для вершин, у яких відбувається розгалуження, можна побудувати ребра, що виходять із них у дереві перебору;

– розвиток дерева по гілках (послідовна побудова гілок). Процедура починається з побудови одного маршруту, включаючи його кінцеву вершину. Припустимо, що M_k – перша від кінця цього маршруту вершина, така, що ще не побудовано із неї ребро (M_k, M_i) , що виходить, та при цьому $(M_i(eval) = m_i) < \mu_0(x)$, тобто підобласть допустимих рішень M_i не відсікається (відшукується мінімум). Побудувавши ребро (M_k, M_i) , добудуємо маршрут, що проходить через вершину, до кінця або до вершини, в якій відбувається відсікання. При такому способі продовження розгалуження у побудованому дереві більше вершин, ніж при розгалуженні по мінімальній

нижній межі, але доводиться запам'ятовувати менший обсяг даних про кількість побудованих вершин.

Запропонована технологія визначення екстремумів нечітких функцій належності здійснюється так:

- при дефаззифікації нечітких функцій належності виділяються деякі значення, які входять у продукцію «Якщо X , то Y »;
- аргументом вхідної функції належності подається деяка величина x_{input} .

Відповідно до методу дефаззифікації дана величина проєктується на вихідну функцію Y , на виході отримуємо значення y_{actual} ;

- суть підбору значень параметрів k полягає в тому, щоб змінити вид вихідної функції належності відповідно до отриманого від експерта очікуваного значення y_{expected} .

Оскільки функція належності визначається параметром k , то саме k підлягає підбору. Наприклад, для $\mu_i(x)$ лінгвістичної змінної «температура» для терму «висока» має місце вираз (4.24).

Значення k піддається дихотомії з використанням кроку апроксимації $\frac{\varepsilon}{2}$.

Ця величина кроку обумовлена необхідністю виконання умови (4.30). На виході технології надається екстремум функції належності (рис. 4.2).



Рисунок 4.2 – Блок-схема оптимізації функції належності

4.4 Результати програмної реалізації модифікованого методу

Дослідження обчислювальної складності посиленого методу гілок та меж для визначення екстремумів функцій належності показало, що кількість ітерацій методу з урахуванням функціональних можливостей дихотомії та золотого перерізу, а відповідно і час його роботи τ , мають експоненційну залежність від значення точності ε .

У існуючих підходах спостерігалася повільна для вирішення даної задачі лінійна, а в деяких випадках при комбінації з іншими методами степенева залежність від величини значення точності ε [1, 54].

Справді, пошук на одній ітерації містить витрати $\approx n$ операцій. Стратегія побудови гілок та знаходження меж, використовуючи принципи методу дихотомії, передбачає процедури поділу на два при реалізації деякої ітерації.

Ділення цілих ненульових n -розрядних (крім знакових розрядів) чисел A та B , представлених у прямому (для простоти) коді, призводить до отримання цілої частки C та цілого залишку 0 , якому присвоюється знак діленого, а знак частки обчислюється як сума за модулем 2 операндів A та B .

Процедура виконується у такій послідовності [1]:

а) дільник B зсувається вліво (нормалізується) так, щоб у старшому інформаційному розряді виявилася 1, далі підраховується кількість зрушень S . Частка від ділення може бути не більше $S + 1$ розрядів, не рівних нулю;

б) виконується $S + 1$ цикл ділення модулів $|A|$ на $|B'|$, де $|B'|$ – нормалізоване B . У результаті даної операції знаходиться $(S + 1)$ розряд частки, починаючи зі старшого із $(S + 1)$ молодших;

в) отриманий в останньому циклі ділення залишок R_{S+1} зсувається праворуч на S розрядів, якщо він додатній. У разі отримання від'ємного залишку $R_{S+1} < 0$ до нього для відновлення додається $|B'|$, тобто:

$$[R_{S+1}]_{\text{vost}} = R_{S+1} + |B'|. \quad (4.33)$$

Після цього виконується зсув праворуч на S розрядів. Виходить цілий залишок від ділення.

Для визначення верхньої оцінки складності запропонованого методу гілок та меж, на основі функціональних можливостей методів дихотомії та золотого перерізу, при n операціях на кожній ітерації представимо стратегію пошуку у вигляді:

$$n + n(n-1) + n(n-1)(n-2) + n(n-1)(n-2)(n-3) + n(n-1)(n-2)(n-3)(n-4) + \dots \quad (4.34)$$

Приймаємо до уваги розкладання ряду показникової функції [54] як

$$e^x \approx 1 + \frac{x}{1!} + \frac{x^2}{2!} + \frac{x^3}{3!} + \dots \quad (4.35)$$

Для точного визначення екстремумів функцій належності у завданнях нечіткого логічного виведення [24] можна визначити верхню оцінку складності, яка не перевищує

$$O(n) \approx ke^n, \quad (4.36)$$

де $O(n)$ – складність посиленого методу;

n – кількість обчислювальних ітерацій;

k – параметр, який визначається обчислювальними ресурсами комп'ютера, у даному випадку k деяка нелінійна зростаюча функція.

Очевидно, що залежність (4.36) багато в чому корелюється параметром k і потребує відповідного вибору конфігурації апаратних засобів комп'ютера.

Тоді розв'язання задачі може бути подане у вигляді:

$$\begin{aligned} \varepsilon &\rightarrow \min; \\ W &\geq W^*; \\ \varepsilon &\leq \varepsilon^*, \end{aligned} \tag{4.37}$$

де W^* – деяке наперед задане граничне значення швидкості процесора.

Розв'язання задачі (4.37) нетривіальне, тому що залежності ε та W – нелінійні. Враховуючи, що у (4.36) $n \approx \frac{1}{\varepsilon}$, то рішення (4.37) одночасно знижує складність (4.36), що важливо у застосунках.

Для оцінки обчислювальної складності проведено нормування значень точності та кількості операцій до одиничної норми. Якщо точність – ε' , то вона приймає значення $\varepsilon' = 1 - \varepsilon$. Кількість операцій обчислюється множенням реальної кількості операторів, що виконуються, на коефіцієнт пропорційності a , де $a = \frac{1}{N}$, N – кількість операцій при $\varepsilon' \geq 1$.

Нами здійснено практичну реалізацію запропонованої інформаційної технології в медичній предметній галузі, а саме – кардіології [63]. Розроблений метод оброблення нечіткої інформації дозволяє працівникам кардіології з високою достовірністю поставити діагноз, заздалегідь попередити пацієнта про небезпеку та визначити фактори, що сприяють усуненню хворобливого процесу.

Виконано вимір часу роботи програмного застосунку для нечіткої кардіологічної симптоматики на апаратній платформі комп'ютера з процесором AMD E2-1800 APU with Radeon(tm) HD Graphics 1.70 GHz, обсягом ОЗУ 4 Гб та операційною системою Windows 7:

- при значенні точності $\varepsilon = 0,01$ час роботи застосунку: $\tau = 6$ мс;
- при значенні точності $\varepsilon = 0,001$ час обчислень: $\tau = 534$ мс.

Застосунок призначено для реалізації автоматичного визначення значення k функції належності.

Користувач має можливість визначати:

- типи вхідної та вихідної фаззи-величин («знижена», «нормальна», «висока»);
- значення аргументу для вхідної величини x_{input} (точка відліку дефазифікації);

– очікуване значення аргументу вихідної величини y_{expected} на основі експертних оцінок;

– необхідну точність обчислень ε .

Суть обчислень полягає у підборі значення коефіцієнта k , що визначає вигляд функції вихідний нечіткої величини заданого типу з метою знаходження наближення значення y_{actual} до значення y_{expected} з дотриманням точності.

Застосунок реалізує визначення значень при дефаззифікації нечітких величин:

– визначення типів вхідної та вихідної нечітких величин;

– вказівка точки відліку у вигляді аргументу функції вхідної нечіткої величини x_{input} ;

– визначення екстремуму функції вхідної нечіткої величини, що відповідає заданій точці відліку та зіставлення значення вихідної нечіткої величини;

– формування складової підінтегральної фігури, обмеженої функцією вихідної нечіткої величини та лінією проєктування значення функції вхідної нечіткої величини на графік функції вихідної нечіткої величини;

– визначення абсциси центру тяжкості отриманої фігури, яка визначає y_{actual} .

Механізм підбору значення коефіцієнта k зводиться до мінімізації (з точністю ε) абсолютної різниці очікуваного та фактичного значення аргументу: $\Delta x = |y_{\text{expected}} - y_{\text{actual}}|$.

Програмну реалізація модифікованого методу здійснено у середовищі програмування Python 3.6 [1]. Інструментальна платформа передбачає ряд апроксимуючих припущень, що дозволяють застосувати чисельні методи [55] за допомогою розбиття підінтегральної функції, що аналізується, на ряд простих складових для знаходження центру тяжкості. Кількість фігур визначається заданою точністю обчислень. Підбір коефіцієнта здійснюється шляхом дихотомії.

Новизну дослідження становить модифікація методу гілок та меж, який посиленій функціональними можливостями дихотомії та золотого перерізу, та застосування її в нечітких інтелектуальних системах.

Завдяки застосуванню модифікованого методу точніше і швидше визначаються екстремуми функцій належності, зростає коефіцієнт впевненості у медичному діагнозі і, як наслідок, покращується достовірність прийнятого рішення про захворювання. Створений програмний застосунок надає можливість задавати потрібну точність значень функції належності, швидше видає діагноз і точніше значення коефіцієнта впевненості.

Визначено обчислювальну складність модифікованого методу за критерієм часових витрат. Вона близька до експоненціальної від обраної точності, що говорить про обчислювальну ефективність запропонованого

методу. Обґрунтовано верхню межу обчислювальної складності, яка близька до квадратичного значення.

4.5 Налаштування множини компонент функцій належності

Важливим аспектом реалізації технологій прийняття рішень на множині альтернатив $\{A_i\}, i \in I$ мережевої моделі, яка відображає процеси предметної області $\{P_k\}, k \in K$, є застосування знання орієнтованих технологій [25], що відображають моделі правил для баз знань:

$$\{if\ x\ is\ \mu_i(x)\ then\ y\ is\ \mu_j(y)\}, \quad (4.38)$$

де x, y – вхідні та вихідні змінні;

$\mu_i(x), \mu_j(y)$ – функції належності для вхідної та вихідної змінних.

У зв'язку з цим задля уточнення достовірності рішень є актуальним підвищення адекватності використаних функцій належності нечітких процесів під час нечіткого логічного виведення на базах знань. Під достовірністю рішення слід розуміти властивість системи відображати реально існуючі об'єкти дослідження та логічні виведення щодо їх станів із необхідною точністю.

У роботах [23-25, 54] досліджено деякі аспекти налаштування параметрів функцій належності

$$\mu(x) = f(k, a, b), \quad (4.39)$$

де k – параметр, що підлягає налаштуванню;

a, b – межі інтервалу, що може бути поданим через аналітичну форму значення функції належності за допомогою нечітких інтервальних уявлень.

Однак, для прийняття адекватного рішення в умовах суттєвої невизначеності, коли наявні неточність, нечіткість чи недостовірність інформації, важливим моментом є необхідність, наприклад, врахування параметру точності апроксимації [54].

Вирішення задач нечіткого логічного виведення реалізовано на основі підходів Заде-Мамдані з подальшою дефазифікацією [24]

$$y'_0 = \vee x'_0 \wedge \mu(x, y), \quad (4.40)$$

де y'_0 – результуючий вектор;

x'_0 – чіткий вхідний вектор;

$\mu(x, y)$ – функція належності нечіткого відношення Заде-Мамдані для правил (4.38);

\vee, \wedge – оператори знаходження значень максимуму та мінімуму.

Суть виразу (4.40) – отримати результуюче кількісне значення (crisp value) для кожної із лінгвістичних змінних, щоб у подальшому, використавши, наприклад, метод центру тяжіння, знайти значення коефіцієнту впевненості на основі визначеної множини типів функцій належності [57].

У роботі [57] запропоновано підхід для налаштування параметрів функцій належності. Доведено, що метод дихотомії дає можливість для множини функцій $\{\mu(x)\}$ ефективно здійснювати налаштування коефіцієнта k у залежності від очікуваної величини дефаззифікованого значення функції належності y^{expected} відповідно до (4.40) для (4.39).

Встановлено [57], що така реалізація має обчислювальну складність $O(n)$, яка не перевищує:

$$O(n) \approx e^{\frac{1}{\varepsilon}}, \quad (4.41)$$

де n – кількість обчислювальних ітерацій при реалізації процедури налаштування параметрів функцій належності;

ε – параметр точності апроксимації.

Існуючі підходи до налаштування параметрів [54, 55] ґрунтуються на застосуванні методів дихотомії, гілок та меж, багатозначної логіки. Аналіз показав, що отримані рішення мають обчислювальну складність, що наближається до експонентної, а рішення характеризуються істотною нестабільністю.

Поряд із великою кількістю формальних систем багатозначних логік, постає проблема інтуїтивної інтерпретації отриманих за їх допомогою результатів та адекватних методів їх дослідження. Без змістовної інтерпретації істинних значень будь-яке n -значне числення залишається абстрактною структурою [63].

Метою дослідження є удосконалення методу налаштування параметрів функцій належності шляхом впровадження моделей, побудованих на основі принципів багатозначної логіки задля підвищення точності прийняття рішень та зниження обчислювальної складності інструментальних засобів [2].

Розглянемо можливість визначення екстремумів функцій належності на основі багатозначної інтервальної логіки.

Під багатозначною інтервальною логікою [50] розуміють апарат, який передбачає більше, ніж два можливих значення – істина або хибність, додатковими результатами істинності висловлювань можуть бути: «невизначене (нейтральне)», «невідоме», «можливо істинне», «можливо хибне», «безглузде (абсурдне)» та інші. Крім того, системи багатозначної логіки групують за класами, наприклад, часткова логіка або нечітка логіка [57].

Моделі, побудовані на основі принципів багатозначної логіки, відображають дві основні риси: множинність значень істинності висловлювань та можливість побудови більш складних висловлювань за допомогою логічних операцій, які дозволяють за значеннями істинності вихідних висловлювань встановлювати істинність складного висловлювання.

Індивідуальні висловлювання багатозначної інтервальної логіки, розбиті на класи із одним і тим же значенням істинності [71-74], відносять до поняття множини E -констант моделі, які фактично ототожнюють усі індивідуальні висловлювання, замінюючи їх відповідними значеннями істинності.

Змінні висловлювання виражають через величини x_1, x_2, \dots, x_n , що, як значення, приймають елементи із множини E . Логічної зв'язки реалізують відповідно до множини M елементарних функцій (операцій), що приймають значення із E .

Особливу увагу заслуговує встановлення значень складних висловлювань, що побудовані із індивідуальних та змінних висловлювань, а також логічних зв'язків. Результати істинності таких висловлювань, як «невизначене», «невідоме», «можливо істинне», «можливо хибне», «безглузде», необхідно подавати із певним ступенем істинності для кожного із простору значень станів об'єкта.

Це дозволить на основі принципів багатозначної інтервальної логіки більш точно класифікувати висловлювання стосовно параметрів об'єкта та подати їх у вигляді функцій належності [54].

Відомо, що множина функцій належності є скінченною множиною у рамках класу задач $\{\mu_i\} = const$ [55].

Для налаштування параметра k заздалегідь чітко визначено функцію належності, яка може бути поданою у вигляді (4.39).

За методом дихотомії реалізовано та обґрунтовано ітеративний процес налаштування параметра k [57]

$$k_i = k_{i-1} \pm \frac{\varepsilon}{2}, \quad (4.42)$$

де значення k_i отримано на i -му кроці.

Процес налаштування триває доки не досягнуто критерію точності апроксимації Δy :

$$\Delta y = |y^{\text{actual}} - y^{\text{expected}}| \leq \varepsilon, \quad (4.43)$$

де y^{actual} – фактичне значення дефазифікованої величини.

Для удосконалення існуючого методу налаштування параметрів функцій належності пропонуємо використовувати поточне значення дільника як

мінімальне та ввести ряд додаткових значень дільника під час ітеративного підбору k (4.42) за умови заданої точності апроксимації ε (4.43)

$$d \in \{d_1, d_2, \dots, d_{n-1}, 2, \dots, l\}, \quad (4.44)$$

де d_1, d_2, \dots, d_{n-1} – поточні значення дільника d_i ;

$2, \dots, l$ – натуральні значення дільника d_i , крім 1, де $l > 2, l \in L$.

Такий підхід до вибору дільника d_i дозволить прискорити досягнення точності ε за рахунок зменшення кроку апроксимації у $2, \dots, l$ разів, причому $d_i > 2, d_i \in L$.

Для кожного типу функції належності та кожного d_i необхідно виміряти час роботи запропонованого алгоритму τ_i , де τ_i – модельний (системний) час, який визначають шляхом імітаційного моделювання, вимірюючи час виконання процесів у експериментальній моделі.

Для цього створюють програмний застосунок, що імітує процеси налагодження параметрів. Далі треба проаналізувати, при яких типах функції $\mu(x)$ та дільника d_i модельний час τ_i прямує до нуля.

Критерієм пошуку екстремумів функцій належності на основі багатозначної логіки приймемо $\{\tau_k\}, i \in K$, врахувавши його таким чином

$$\forall \tau_k, \tau_k \in \{\tau_k\} \xrightarrow{F^*} extr, \quad (4.45)$$

де F^* – обмеження предметної області.

На множині функцій належності $\{\mu_i\}, i \in I$ здійснимо ранжирування τ_k за критерієм мінімізації модельного часу. Для значень з $\{\tau_{k_{\min}}\}$ визначається їх дільник d_{\min_i} для μ_i

$$k_i = k_{i-1} \pm \frac{\varepsilon}{d_{\min}}. \quad (4.46)$$

Для знаходження (4.46) виділимо ключові етапи запропонованого методу.

Етап 1. Фаззифікація правила продукції, вибір типів функції належності.

Етап 2. Задання параметрів функцій належності з використанням експертних оцінок [55].

Етап 3. Вирішення задачі нечіткого логічного виведення Заде-Мамдані.

Етап 4. Дефаззифікація результатів виведення.

Етап 5. Визначення оцінки очікуваного дефаззифікованого значення y^{expected} .

Етап 6. Задання дільника дихотомії d_i та точності ε .

Етап 7. Запуск процесу ітеративної апроксимації.

Етап 8. Зупинка при досягненні необхідної точності ε .

Етап 9. Оновлення параметрів налаштованої функції належності.

Етапи 6 – 9 є принципово новими у процесі визначення екстремуму функції належності на основі багатозначної інтервальної логіки та становлять суть підбору параметрів.

У запропонованому методі дільником d_i виступає значення апріорно заданої точності вирахувань ε (4.43) [57], що дозволяє виконати умову для модельного часу τ_k :

$$\tau_{\Delta y, A} < \tau_{\varepsilon, d},$$

де $\tau_{\Delta y, A}$ – модельний час при використанні чисельника кроку Δy і знаменника A ;

$\tau_{\varepsilon, d}$ – модельний час при використанні чисельника кроку ε і знаменника d .

У даному дослідженні передбачено, що оцінка часу τ_k проведення операції налаштування k визначається у мс (10^{-3} с), знаменник кроку операції визначається на інтервалі $[0, 1]$.

Отже, вирішення задачі пошуку екстремумів функцій належності на підставі багатозначної логіки дозволяє досягти мінімального значення модельного часу τ при заданій точності апроксимації ε та введення додаткових значень дільника d_i під час ітеративного процесу підбору k .

Таким чином, для удосконалення методу налаштування параметрів на основі багатозначної логіки запропоновано для складних висловлювань ввести степені для усіх значень істинності, що на виході надасть більш точний тип функції належності $\mu(x)$.

Введена багатозначність дозволить за рахунок наперед визначених дискретних значень d_i швидко досягти задану експертну точність ε , і, цим самим, знайти екстремум функції $\mu(x)$ з мінімальним часом τ_i на основі обчислень для різних типів функцій належності. Такий комплексний підхід до налаштування параметрів функцій належності показав ефективність у порівнянні із дослідженнями, що передбачали лише бінарні результати істинності [3].

Стан біофізичного об'єкту – людини може характеризуватися показниками частоти пульсу (високий, нормальний, низький, 90 серцевих скорочень у хвилину), температури (висока, нормальна, низька, 37.7°C), верхньої межі артеріального тиску (висока, нормальна, низька, 120 мм рт. ст.), віку (молодий, зрілий, людина похилого віку, 20 років) та інше [58].

За простір станів людини прийнято множину можливих діагнозів (захворювань) \tilde{D}_{final} .

Невизначеність може бути внесено неточними або ненадійними даними з технічних приладів, отриманими в умовах обмеження на матеріальні або часові ресурси [55, 75-82].

Запропонована модель інструментальних засобів для прийняття рішень про наявність або відсутність у біофізичного об'єкта (людини) певного стану із класу задач (серцево-судинні захворювання) містить механізм запропонованого методу налаштування параметрів функцій належності на принципах багатозначної інтервальної логіки.

Архітектура моделі суттєво відрізняється від аналогічних, бо включає додатково розроблені елементи:

– підсистему набуття знань про предметну область, яка визначає стратегії створення інтерфейсу для інженера зі знань;

– підсистему обробки та формалізації вихідних даних і знань, що передбачає наявність логічних висловлювань (індивідуальних та складних) на основі багатозначної логіки, використовує функції належності та їх значення;

– підсистему формування рішень та рекомендацій, що виводить на друк вирішення зі списком вказівок та рекомендацій, здійснює коригування та доповнення до блоку довідкової інформації і накопичених знань експертів;

– підсистему реєстрації і обробки даних, що забезпечує взаємодію користувача з об'єктом дослідження за допомогою доступного інтерфейсу;

– блок моделювання та налаштування $\mu_i(x)$, що застосовує удосконалений механізм налаштування параметрів, який передбачає послідовне виконання ланцюжка методів (гілок та меж, удосконаленого дихотомії, золотого перетину) та отримання коефіцієнтів впевненості;

– підсистему нечіткого логічного виведення, що проводить чотирьохетапну обробку просторів станів об'єктів. Модель обробки просторів станів за допомогою машини логічного виведення та матриці вагових коефіцієнтів передбачає чотири етапи (рис. 4.3, блоки 1 – 11 у підсистемі нечіткого логічного виведення).

Блок 1. На основі суб'єктивних даних можна визначити множину рішень $D_{ij}^{(1)}$ з коефіцієнтами впевненості KU_{ij} і наступним уточненням простору станів на множині $D_{ff}^{(2)}$, $D_{lj}^{(3)}$, $D_{sj}^{(4)}$ або надати висновок про відсутність рішення із класу \tilde{D}_{final} .

Блок 2. На основі відомих факторів можна визначити множину вирішень $D_{ff}^{(2)}$ з певними коефіцієнтами впевненості KU_{ff} , уточнити результат

$D_{ij}^{(1)}$, провести уточнення станів на множині вирішень $D_{lj}^{(3)}$, $D_{sj}^{(4)}$ або надати висновок про відсутність вирішення із класу \tilde{D}_{final} .

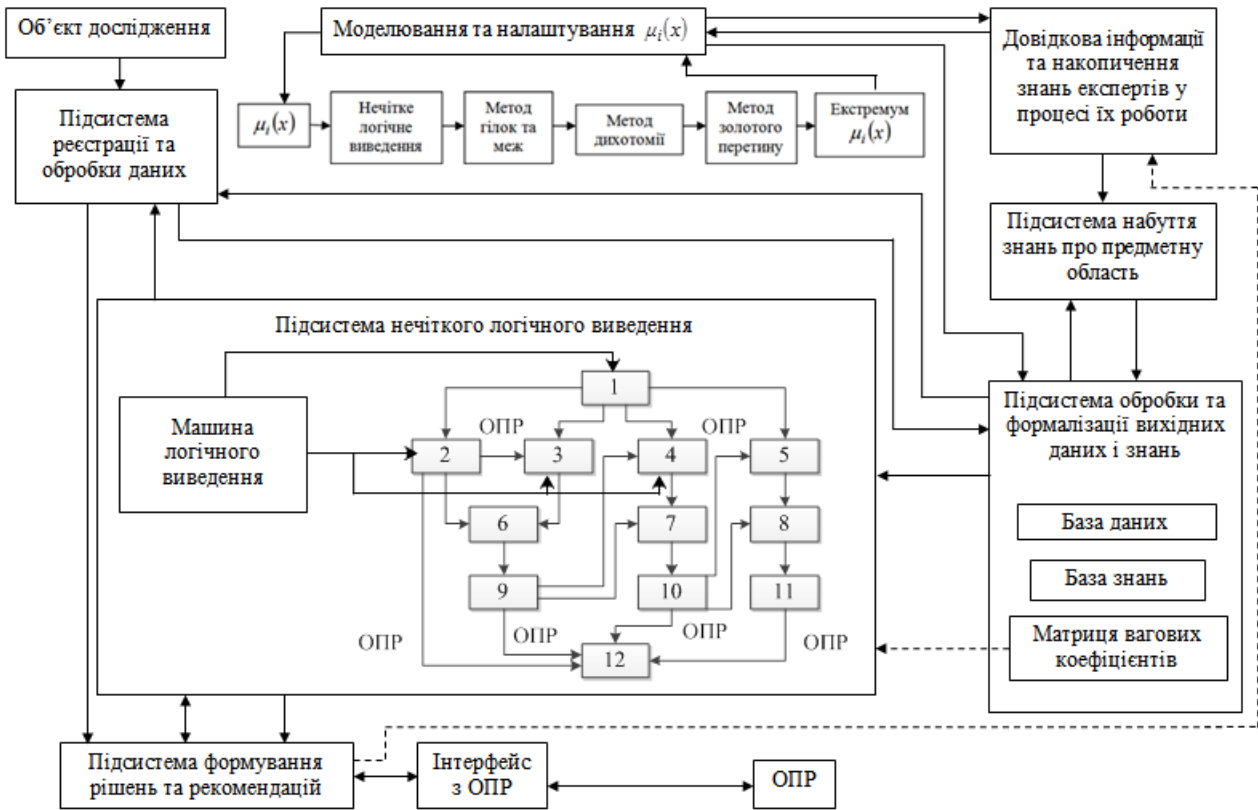


Рисунок 4.3 – Модифікована модель інструментальних засобів

Блок 3. На основі результатів лабораторних обстежень можна визначити множину вирішень $D_{lj}^{(3)}$ з коефіцієнтами впевненості KU_{lj} , уточнити результати $D_{ij}^{(1)}$ та $D_{ff}^{(2)}$, провести уточнення станів на множині вирішень $D_{sj}^{(4)}$ або надати висновок про відсутність рішення із класу \tilde{D}_{final} .

Блок 4. На основі додаткових даних можна визначити множину $D_{sj}^{(4)}$ з коефіцієнтами впевненості KU_{sj} , уточнити результати $D_{ij}^{(1)}$, $D_{ff}^{(2)}$ та $D_{lj}^{(3)}$, надати заключне вирішення $D_{final}^{(4)}$ з $KU_{sj} \rightarrow max$ або висновок про відсутність вирішення із класу задач \tilde{D}_{final} .

Блок 5. Обробка і аналіз $D_{ij}^{(1)}$ та $D_{ff}^{(2)}$, відбір найбільш значимих результатів за умови $\{KU_{ij} \geq 0,5\}$ та $\{KU_{ff} \geq 0,5\}$.

Блок 6. Обробка і аналіз $D_{lj}^{(3)}$ та $D_{sj}^{(4)}$ з урахуванням результатів $D_{ij}^{(1)}$ та $D_{ff}^{(2)}$, відбір найбільш значимих результатів за умови $\{KU_{lj} \geq 0,5\}$ та $\{KU_{sj} \geq 0,5\}$.

Блок 7. Обробка і аналіз $D_{sj}^{(4)}$ з урахуванням результатів $D_{ij}^{(1)}$, $D_{ff}^{(2)}$, $D_{lj}^{(3)}$, відбір результату за умови $\{KU_{sj} \rightarrow max\}$.

Блок 8. Врахувавши результат вирішень $D_{ij}^{(1)}$ та $D_{ff}^{(2)}$ з певними KU_{ij} та KU_{ff} , можна надати рекомендації, що відповідають даним рішенням, або рекомендації щодо збору необхідної додаткової інформації для підвищення достовірності вирішення задачі.

Блок 9. Врахувавши результат $D_{lj}^{(3)}$ з певними KU_{lj} , можна надати рекомендації, що відповідають даним рішенням, або рекомендації щодо збору необхідної додаткової інформації для підвищення достовірності.

Блок 10. Врахувавши результат $D_{sj}^{(4)}$, система визначає одне вирішення з $\{KU_{sj} \rightarrow max\}$.

Блок 11. Визначається \tilde{D}_{final} з $\{KU_{sj} \rightarrow max\}$.

Структурну схему побудови і взаємодії основних модулів модифікованої моделі, яка враховує удосконалену методику налаштування параметрів, подано на рисунку 4.3.

Налаштування параметрів функцій належності здійснюється за етапами розвинутого метода у процесі тестування роботи системи розробниками програмного засобу та експертами предметної області шляхом визначення відповідності вихідних даних отриманому результату (4.41).

Наприклад, якщо отриманий результат на думку експертів не відповідає результату обробки даних:

$$D'_{d8}^{(4)} \neq (\{\tilde{S}_{18}^{(1)}, \tilde{S}_{32}^{(1)}, \tilde{S}_{57}^{(1)}\}, \{\tilde{F}_{68}^{(2)}, \tilde{F}_{88}^{(2)}, \tilde{F}_{145}^{(2)}\}, \{\tilde{L}_{171}^{(3)}, \tilde{L}_{275}^{(3)}\}, \{\tilde{D}\tilde{S}_{327}^{(4)}, \tilde{D}\tilde{S}_{385}^{(4)}\}),$$

то така система потребує перегляду і налаштування вихідної інформації до тих пір, поки результати роботи системи на певній кількості тестів і різним складом експертів не покажуть найбільш точне значення, що мінімізує похибку ε .

Основне призначення запропонованої моделі (рис. 4.3) полягає у наданні спроектованої розширеної архітектури інструментальних засобів для прийняття рішень, що не поступаються за якістю експерту у даній предметній області.

Ключову роль відіграє блок моделювання та налаштування $\mu_i(x)$. Через блок довідкової інформації та накопичення знань експертів до системи надходять дані стосовно типів функцій належності для наявних у базі даних значень лінгвістичних змінних.

Налаштування параметрів відбувається під час послідовного виконання ланцюжка методів (гілок та меж, дихотомії, золотого перетину).

На етапі спрацювання методу дихотомії рішення задачі підсилюється введенням значення d_i під час ітеративного процесу підбору k (4.42) та мінімізації модельного часу $\{\tau_k\}, i \in K$ (4.45).

У раніше запропонованих моделях для підвищення точності рішень не вистачало врахування саме значень лінгвістичних змінних для кожного типу функцій належності, а також введення дискретних значень дільника (4.44) задля зниження часу (4.45) для визначення екстремумів функцій належності.

4.6 Експериментальне дослідження методу налаштування

Програмна реалізація налаштування параметрів функцій належності виконана у об'єктно-орієнтованому середовищі та реалізована у блоці моделювання та налаштування $\mu_i(x)$ на етапі методу дихотомії (рис. 4.3).

У інструментальному застосунку використано різні типи функцій належності (показникова, трикутна, трапецієвидна, Гауса) для наявних значень лінгвістичних змінних.

Наприклад, множина Гаусіанів для лінгвістичних значень функцій належності має вигляд:

$$- \text{«Великий» } \mu_1 = 1 - e^{-k_1(a-b)^2}, k_1 > 0, a \geq 0, b \geq 0;$$

$$- \text{«Малий» } \mu_2 = e^{-k_2 a^2}, k_2 > 0, a \geq 0;$$

$$- \text{«Середній» } \mu_3 = e^{-k_3(a-b)^2}, k_3 > 0, a \geq 0, b \geq 0.$$

Підбір дільника дихотомії d_{\min} (4.46) здійснюється для кожного із типів функцій належності індивідуально на відміну до раніше запропонованих методів, де усі механізми зорієнтовані на тип функції належності в цілому. Такий підхід забезпечує кращу якість результатів.

Для налаштування параметрів функції належності Гауса вигляду «Великий» час роботи інструментального засобу при не налаштованій функції склав $\tau_1 = 37,7$ мс, а $\tau_2 = 6$ мс. Інтерфейс користувача програмного застосунку при виконанні налаштування параметрів функції належності Гауса вигляду «Малий» подано на рисунку 4.4.

Час роботи інструментального засобу при не налаштованій функції $\tau_1 = 130,0$ мс, а $\tau_2 = 2,5$ мс. Для налаштування параметрів функції належності Гауса вигляду «Середній» час роботи інструментального засобу при не налаштованій функції склав $\tau_1 = 110,5$ мс, а $\tau_2 = 10,6$ мс.

На рисунку 4.4 подано процес налаштування параметру k функції належності Гауса вигляду «Малий» при значенні $d_i = 4$, як видно, у результаті

відповідних обчислень $\Delta y = 0$, тобто $y^{\text{actual}} = y^{\text{expected}}$ при заданій точності апроксимації $\varepsilon = 0,001$ – параметр k налаштовано, $k = 0,384$.

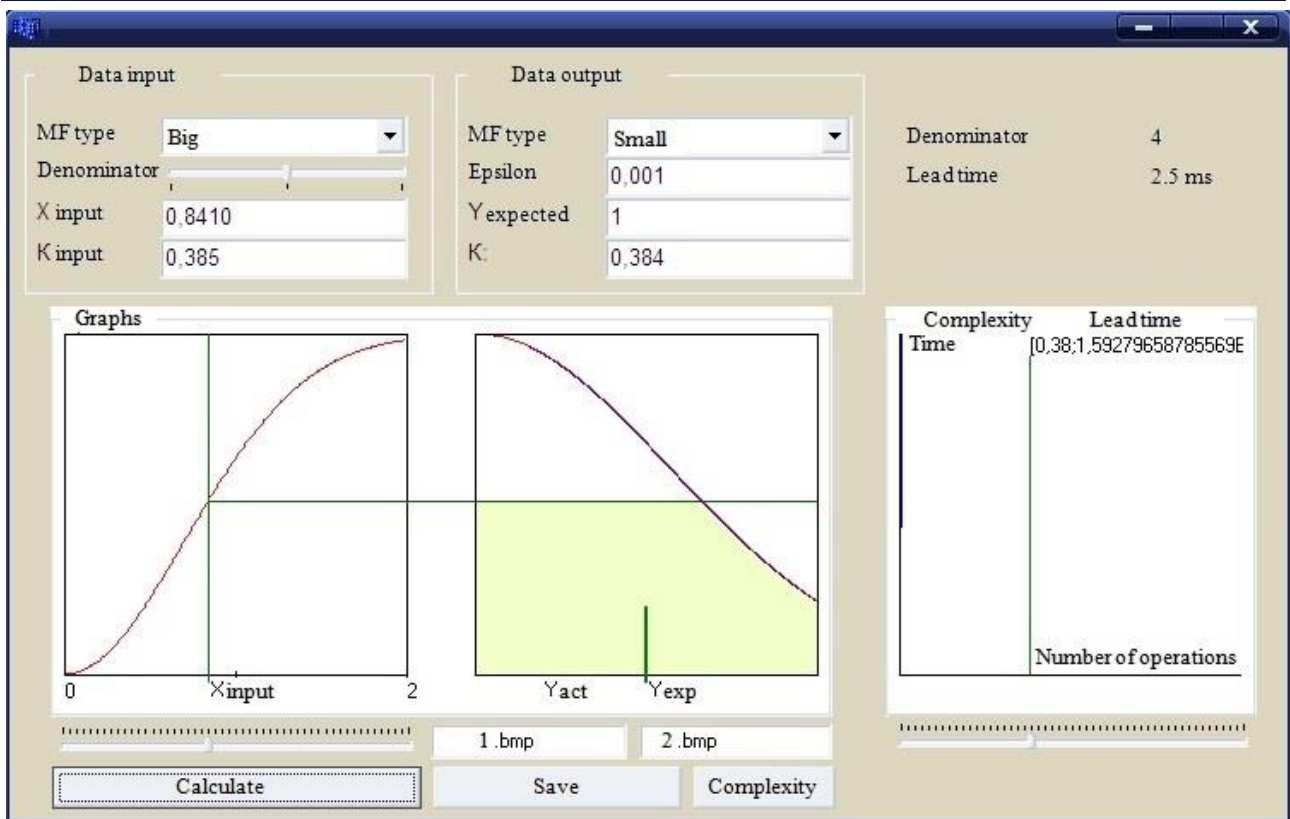



Рисунок 4.4 – Інтерфейс програмного застосунку при налаштуванні функції належності «Малий»

Проведені експерименти продемонстрували ефективність введення значень дільника d_i під час ітеративного процесу підбору k та суттєве зменшення модельного часу $\{\tau_k\}, i \in K$ (4.45), так, під час налаштування функції належності «Великий» модельний час зменшено у 6 разів, «Малий» – у 52 рази, «Середній» – у 10 разів при заданій точності апроксимації $\varepsilon = 0,001$.

Аналогічним чином, налаштування параметрів функцій належності виконано для усіх наявних у базі даних значень лінгвістичних змінних для решти типів функцій належності (показникової, трикутної, трапецієвидної), що використовуються під час даного дослідження.

У процесі роботи програмного застосунку отримано фактичні значення системного часу τ для функцій належності Гауса та множини дільників дихотомії, наприклад, $d = \{2, 4, 8\}$ (табл. 4.2).

Таблиця 4.2 – Час роботи програмного застосунку, мс

Значення функції належності	Дільник d_i		
	2	4	8
«Великий»	42	71	67
«Малий»	100	76	94
«Середній»	118	67	110

Проаналізувавши дані таблиці 4.2, можна зробити висновок, що для наявних у базі даних значень лінгвістичних змінних «Великий», «Малий», «Середній» для функції належності Гауса при заданій точності апроксимації $\varepsilon = 0,001$, щоб отримати мінімальний модельний час роботи застосунку, слід використовувати такі допоміжні значення дільника d_i :

- для значення «Великий» $d_i = 2$ ($\tau_k = 42$ мс);
- «Малий» $d_i = 4$ ($\tau_k = 76$ мс);
- «Середній» $d_i = 4$ ($\tau_k = 67$ мс).

Аналогічним чином визначено допоміжні значення дільника d_i для усіх наявних у базі даних значень лінгвістичних змінних для решти типів функцій належності (показникової, трикутної, трапецієвидної).

Отримані експериментальні дані довели ефективність запропонованого способу налаштування параметрів функцій належності.

Значення модельного часу обробки даних τ залежить від апаратного забезпечення комп'ютерних засобів.

Залежність часу τ від точності ε і дільника d_i отримано на ноутбучі з процесором AMD E2-1800 APU with Radeon(tm) HD Graphics 1.70 GHz та 4 GB RAM (табл. 4.3).

Таблиця 4.3 – Залежність модельного часу τ від точності обчислень ε і дільника d_i

μ	d_i	ε									
		0,1	0,08	0,06	0,04	0,02	0,01	0,006	0,004	0,002	0,001
«Великий»	2	1	2	3	4	4	5	13	21	31	40
	4	2	3	3	5	5	6	20	29	52	71
	8	2	3	3	5	6	6	17	23	43	62
«Малий»	2	2	3	4	7	8	7	31	53	81	100
	4	2	2	4	5	8	8	27	58	70	80
	8	3	3	4	6	9	9	22	52	84	95
«Середній»	2	2	2	3	5	10	11	29	65	92	118
	4	2	3	3	6	10	6	17	41	53	67
	8	3	4	4	6	11	10	26	60	81	110

Таблиця 4.3 надає можливість підібрати значення дільника d_i у залежності від точності апроксимації ε та наявних у базі даних значень лінгвістичних змінних «Великий», «Малий», «Середній» для функції належності Гауса з допустимим модельним часом τ .

Залежність обчислювальної складності програмного застосунку τ від значень дільника d_i подано на рисунку 4.5.

Зауважимо, що для підвищення точності результату необхідно застосовувати мінімальну точність апроксимації $\varepsilon = 0,001$, однак, це призведе до збільшення модельного часу τ . Зрозуміло, що значення таблиці 4.3 відображають і інші залежності, відмінні від поданої на рисунку 4.5.

Необхідно підходити індивідуально до кожного значення лінгвістичних змінних усіх типів функцій належності [2, 26, 83-93]. З метою підвищити достовірність рішень у ряді прикладних задач у процесі подальшого проектування на основі обґрунтованих підходів до налаштування параметрів функцій належності та архітектури модифікованої моделі розроблено також інструментальні засоби для оброблення простору станів людей із серцево-судинними захворюваннями. Програмна реалізація системи здійснена у середовищі об'єктно-орієнтованого програмування [26, 54] та інтегрується із розробленим програмним застосунком налаштування функцій належності.




Рисунок 4.5 – Залежність складності обчислень τ від значень дільника d_i

Запропонована модель враховує невизначені інтервальні уявлення про простір станів об'єктів за рахунок налаштування параметрів функцій належності, що дає можливість опрацювати індивідуальні та складні логічні висловлювання багатозначної інтервальної логіки.

Удосконалений метод налаштування параметрів функцій належності, на відміну від існуючих, заснований на попередньому заданні точності обчислень ϵ , що дозволяє виконати умову достатності для значення модельного часу τ та суттєво зменшити обчислювальну складність реалізації.

Розроблені інструментальні засоби мають ряд суттєвих практичних переваг у порівнянні з людиною-експертом і діючими програмними аналогами, можуть бути використані у клінічній практиці спеціалістами-початківцями, так і у закладах підвищення кваліфікації.

Проведено експериментальні дослідження функціонування розробленої системи на тестових прикладах. Програмний застосунок надає можливість задавати необхідну точність щодо параметра функції належності, у реальному часі видає діагноз із значенням коефіцієнта впевненості $\{KU_{sj} \rightarrow max\}$.

Критеріями ефективності прийнято достовірність і час прийняття правильних адекватних рішень [94-105]. Завдяки застосуванню запропонованої

моделі інструментальних засобів у інтелектуальній медичній системі за даними експертних оцінок достовірність підвищена до 20%.

Новизну дослідження становить удосконалення методу налаштування параметрів функцій належності, яке передбачає застосування принципів багатозначної інтервальної логіки за умови заданої точності апроксимації, що дозволить підвищити достовірність інтелектуальних рішень за допустимий час обробки нечітких даних.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Tvoroshenko I.S., and Gorokhovatsky V.O. (2019) Modification of the branch and bound method to determine the extremes of membership functions in fuzzy intelligent systems. *Telecommunications and Radio Engineering*, 78 (20), pp. 1857-1868.
2. Tvoroshenko I.S., and Gorokhovatskyi V.O. (2020) Effective tuning of membership function parameters in fuzzy systems based on multi-valued interval logic. *Telecommunications and Radio Engineering*, 79 (2), pp. 149-163.
3. Gorokhovatskyi V.O., Tvoroshenko I.S., and Peredrii O.O. (2020) Image classification method modification based on model of logic processing of bit description weights vector. *Telecommunications and Radio Engineering*, 79 (1), pp. 59-69.
4. Gorokhovatskyi V., and Tvoroshenko I. (2020) Image Classification Based on the Kohonen Network and the Data Space Modification. In *CEUR Workshop Proceedings: Computer Modeling and Intelligent Systems (CMIS-2020)*. 2608. pp. 1013-1026.
5. Gorokhovatskyi V.O., Tvoroshenko I.S., and Vlasenko N.V. (2020) Using Fuzzy Clustering in Structural Methods of Image Classification. *Telecommunications and Radio Engineering*, 79 (9), pp. 781-791.
6. Kobylin O., Gorokhovatskyi V., Tvoroshenko I., and Peredrii O. (2020) The Application of Non-Parametric Statistics Methods in Image Classifiers Based on Structural Description Components. *Telecommunications and Radio Engineering*, 79 (10), pp. 855-863.
7. Daradkeh Y.I., Tvoroshenko I., Gorokhovatskyi V., Latiff L.A., and Ahmad N. (2021) Development of Effective Methods for Structural Image Recognition Using the Principles of Data Granulation and Apparatus of Fuzzy Logic. *IEEE Access*, 9, pp. 13417-13428.
8. Daradkeh Y.I., Gorokhovatskyi V., Tvoroshenko I., Gadetska S., and Al-Dhaifallah M. (2021) Methods of Classification of Images on the Basis of the Values of Statistical Distributions for the Composition of Structural Description Components. *IEEE Access*, 9, pp. 92964-92973.
9. Ahmad M.A., Gorokhovatskyi V., Tvoroshenko I., Vlasenko N., and Mustafa S.K. (2021) The Research of Image Classification Methods Based on the Introducing Cluster Representation Parameters for the Structural Description. *International Journal of Engineering Trends and Technology*, 69 (10), pp. 186-192.

10. Гороховатський В., Творошенко І., Сидоренко Д. (2021) Класифікація зображень із використанням кластерного подання. *Міжнародний науковий симпозиум «Інтелектуальні рішення-С». Обчислювальний інтелект (результати, проблеми, перспективи). Теорія прийняття рішень: праці міжнародного наукового симпозиуму (Вересень 29, 2021)*. Київ – Ужгород, С. 44-45.
11. Гороховатський В.О., Творошенко І.С. (2021) Методи інтелектуального аналізу та оброблення даних: навч. посібник. Харків: ХНУРЕ, 92 с.
12. Гороховатський В.О., Гадецька С.В. (2020) Статистичне оброблення та аналіз даних у структурних методах класифікації зображень: монографія. Харків: ФОП Панов А.Н., 128 с.
13. Гороховатский В.А. (2003) Распознавание изображений в условиях неполной информации. Харьков: ХНУРЭ, 112 с.
14. Гороховатский В.А. (2014) Структурный анализ и интеллектуальная обработка данных в компьютерном зрении: монография. Харьков: СМИТ, 316 с.
15. Гороховатский В.А., Полякова Т.В. (2018) Применение пространственных структур признаков для классификации изображений в компьютерном зрении. Харьков: ФОП Панов А.Н., 120 с.
16. Путятин Е.П., Аверин С.И. (1990) Обработка изображений в робототехнике. Москва: Машиностроение, 320 с.
17. Флах П. (2015) Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных. Москва: ДМК Пресс, 400 с.
18. Кохонен Т. (2013) Самоорганизующиеся карты. Москва: БИНОМ. Лаборатория знаний, 655 с.
19. Duda R.O., Hart P.E., and Stork D.G. (2000) Pattern classification. Hoboken, New Jersey, USA: John Wiley & Sons, 738 p.
20. Shapiro L., and Stockman G. (2001) Computer vision. Upper Saddle River, New Jersey, USA: Prentice Hall, pp. 107-136.
21. OpenCV Open Source Computer Vision, Accessed: Dec. 24, 2021. [Online]. Available: <https://docs.opencv.org/master/index.html>.
22. Lyashenko V., Mustafa S.K., Tvoroshenko I., and Ahmad M.A. (2020) Methods of Using Fuzzy Interval Logic During Processing of Space States of Complex Biophysical Objects. *International Journal of Emerging Trends in Engineering Research*, 8 (2), pp. 372-377.
23. Кучеренко Е.И., Филатов В.А., Творошенко И.С., Байдан Р.Н. (2005) Интеллектуальные технологии в задачах принятия решений технологических комплексов на основе нечеткой интервальной логики. *Восточно-Европейский журнал передовых технологий*, № 2, С. 92-96.

24. Кучеренко Е.И., Творошенко И.С. (2003) Процессы принятия решений в сложных системах на основе нечетких интервальных представлений. *Вісник Національного технічного університету «ХПІ». Тематичний випуск: Системний аналіз, управління та інформаційні технології. Х.: НТУ «ХПІ», 1 (7), С. 79-86.*
25. Бодянский Е.В., Кучеренко Е.И., Творошенко И.С. (2004) О синтезе нечетких алгоритмов на основе композиции фрагментов правил и моделей. *АСУ и приборы автоматки, № 128, С. 19-28.*
26. Tvoroshenko I.S., and Gorokhovatsky V.O. (2019) Intelligent classification of biophysical system states using fuzzy interval logic. *Telecommunications and Radio Engineering, 78 (14), pp. 1303-1315.*
27. Gorokhovatskyi V., Rusakova N., and Tvoroshenko I. (2020) The application of image analysis methods and predicate logic in applied problems of magnetic monitoring. *Telecommunications and Radio Engineering, 79 (20), pp. 1801-1811.*
28. Szeliski R. (2010) *Computer Vision: Algorithms and Applications.* London, Great Britain: Springer-Verlag, 979 p.
29. Гороховатський В.О., Пономаренко Р.П. (2020) Класифікація зображень на підставі формування незалежної системи кластерів у складі структурних описів бази еталонів. *Сучасні інформаційні системи, 4 (2), С. 17-23.*
30. Oliinyk A., and Subbotin S.A. (2016) A stochastic approach for association rule extraction. *Pattern Recognition and Image Analysis, 26 (2), pp. 419-426.*
31. Осовский С. (2002) *Нейронные сети для обработки информации.* Москва: Финансы и статистика, 344 с.
32. Гороховатський В.О., Пупченко Д.В., Солодченко К.Г. (2018) Аналіз властивостей, характеристик та результатів застосування новітніх детекторів для визначення особливих точок зображення. *Системи управління, навігації та зв'язку, 1 (47), С. 93-98.*
33. Гороховатський В.О., Запорожченко А.П., Сірик Т.О., Тарасенко О.П. (2020) Дослідження результативності застосування ознак розподілів даних для обчислення релевантності описів зображень. *Системи управління, навігації та зв'язку, 1 (59), С. 68-73.*
34. Rublee E., Rabaud V., Konolige K., and Bradski G. (2011) ORB: an efficient alternative to SIFT or SURF. *In Proceedings IEEE International Conference on Computer Vision (ICCV), pp. 2564-2571.*
35. Leutenegger S., Chli M., and Siegwart R. (2011) BRISK: Binary Robust Invariant Scalable Keypoints. *In Proceedings IEEE International Conference on Computer Vision (ICCV), pp. 2548-2555.*

36. Gorokhovatskyi O., Gorokhovatskyi V., and Peredrii O. (2018) Analysis of Application of Cluster Descriptions in Space of Characteristic Image Features. *Data*, 3 (4), p. 52.
37. Learning Models for Object Recognition from Natural Language Descriptions, Accessed: Jan. 10, 2022. [Online]. Available: <http://www.josiahwang.com/projects/leedsbutterfly>.
38. Celik C., and Bilge H.S. (2017) Content based image retrieval with sparse representations and local feature descriptors: A comparative study. *Pattern Recognition*, 68, pp. 1-13.
39. Sonka M., Hlavac V., and Boyle R. (2014) Image Processing, Analysis, and Machine Vision. Atlanta, Georgia, USA: Thomson-Engineering, pp. 385-452.
40. Nong Ye. (2013) Data Mining: Theories, Algorithms, and Examples. Florida, USA: CRC Press, 349 p.
41. Pokemon image library, Accessed: Dec. 12, 2021. [Online]. Available: <https://www.pokemon.com/ru/pokedex/>.
42. Гороховатський В.О., Гадецька С.В., Стяглик Н.І., Власенко Н.В. (2020) Класифікація зображень на підставі ансамблю статистичних розподілів за класами еталонів для компонентів структурного опису. *Радіоелектроніка, інформатика, управління*, № 4, С. 85-94.
43. Gorokhovatskiy V.A. (2011) Compression of Descriptions in the Structural Image Recognition. *Telecommunications and Radio Engineering*, 70 (15), pp. 1363-1371.
44. Bezsonov O., Rudenko O., Udovenko S., and Dudinova O. (2017) Processing of noisy digital images with use of evolving autoencoders. *Eastern-European Journal of Enterprise Technologies*, 6/9 (90), pp. 63-69.
45. Manning C.D., Raghavan P., and Schütze H. (2009) An Introduction to Information Retrieval. Cambridge, England: Cambridge University Press, pp. 289-315.
46. Yakovleva O., and Nikolaieva K. (2020) Research of descriptor based image normalization and comparative analysis of SURF, SIFT, BRISK, ORB, KAZE, AKAZE descriptors. *Advanced Information Systems*, 4 (4), pp. 89-101.
47. Творошенко И.С. (2004) Структура и функции интеллектуальных средств принятия решений в сложных системах. *Искусственный интеллект*, № 4, С. 462-470.
48. Феллер В. (1984) Введение в теорию вероятностей и ее приложения. Москва: Мир, 528 с.
49. Hashemzadeh M., Oskouei A.G., and Farajzadeh N. (2019) New fuzzy C-means clustering method based on feature-weight and cluster-weight learning. *Applied Soft Computing*, 78, pp. 324-345.

50. Кучеренко Є.І., Творошенко І.С. (2011) Оперативне оцінювання простору станів складних розподілених об'єктів з використанням нечіткої інтервальної логіки. *Искусственный интеллект*, № 3, С. 382-387.

51. Gorokhovatsky V.A., and Putyatin Ye.P. (2009) Image Likelihood Measures of the Basis of the Set of Conformities. *Telecommunications and Radio Engineering*, 68 (9), pp. 763-778.

52. Kasprzyk J., and Pedrycz W. (2015) Springer Handbook of Computational Intelligence. Berlin Heidelberg, Germany: Springer-Verlag, pp. 1173-1180.

53. Daradkeh Y.I., and Tvoroshenko I. (2020) Technologies for Making Reliable Decisions on a Variety of Effective Factors using Fuzzy Logic. *International Journal of Advanced Computer Science and Applications*, 11 (5), pp. 43-50.

54. Кучеренко Е.И., Корниловский А.В., Творошенко И.С. (2010) О методах настройки функций принадлежности в нечетких системах. *Системы управления, навигации и связи*, № 1, С. 13.

55. Filatov V., and Kovalenko A. (2019) Fuzzy Systems in Data Mining Tasks. *Studies in Computational Intelligence*, pp. 243-274.

56. Karami E., Prasad S., and Shehata M. (2017) Image matching using SIFT, SURF, BRIEF and ORB: performance comparison for distorted images. arXiv: 1710.02726. [Online]. Available: <https://arxiv.org/abs/1710.02726>.

57. Ahmad M.A., Tvoroshenko I., Baker J.H., and Lyashenko V. (2019) Computational Complexity of the Accessory Function Setting Mechanism in Fuzzy Intellectual Systems. *International Journal of Advanced Trends in Computer Science and Engineering*, 8(5), pp. 2370-2377.

58. Babker A.M., Altoum A.E.A., Tvoroshenko I., and Lyashenko V. (2019) Information Technologies of the Processing of the Spaces of the States of a Complex Biophysical Object in the Intellectual Medical System HEALTH. *International Journal of Advanced Trends in Computer Science and Engineering*, 8 (6), pp. 3221-3227.

59. Daradkeh Y.I., and Tvoroshenko I. (2020) Application of an Improved Formal Model of the Hybrid Development of Ontologies in Complex Information Systems. *Applied Sciences*, 10 (19). p. 6777.

60. Гороховатский В.А., Куликов Ю.А. (2012) Формализм мультимножеств в задачах структурного распознавания и поиска в базах видеоданных. *Искусственный интеллект*, № 1, С. 76-85.

61. Самые красивые советские актрисы. URL: https://www.pinterest.ie/pin/439312138654120787/?nic_v2=1a6L1tctW (дата обращения 24.12.2021).

62. Gold earrings, Accessed: Dec. 25, 2021. [Online]. Available: https://www.google.com/search?q=gold+earrings&sxsrf=ALeKk03Zn_bfnSmZGksIVTeZVBEuhsauVg:1603190034550&source=lnms&tbn=isch&sa=X&ved=2ahUKEwjB1Jck_MLsAhVEqaQKHbHsBU8Q_AUoAXoECAUQAaw&biw=1517&bih=741

63. Rudenko O., Bezsonov O., and Yakovliev D. (2021) Face Recognition in the Presence of Non-Gaussian Noise. *In CEUR Workshop Proceedings: Computer Modeling and Intelligent Systems (CMIS-2021)*. 2864. Available online: <http://ceur-ws.org/Vol-2864/paper15.pdf>.

64. Творошенко И.С. (2010) Анализ процессов принятия решений в интеллектуальных системах. *Системы обработки информации*, № 2, С. 248-253.

65. Voskoglou M.G. (2019) Multi-Valued Logics: A Review. *International Journal of Applications of Fuzzy Sets and Artificial Intelligence*, 9, pp. 5-12.

66. Ересько Ю.Н. (2002) Локализация изображений в автоматических визирах. Москва: Компания Спутник+, 357 с.

67. Путятін Є.П., Гороховатський В.О., Матат О.О. (2006) Методи та алгоритми комп'ютерного зору: навч. посібник. Харків: ТОВ «Компанія СМІТ», 236 с.

68. Гороховатский В.А., Передрий Е.О. (2009) Корреляционные методы распознавания изображений путем голосования систем фрагментов. *Радіоелектроніка, інформатика, управління*, 1 (20), С. 74-81.

69. Гороховатський В.О., Гадецька С.В., Стяглик Н.І. (2019) Вивчення статистичних властивостей моделі блочного подання для множини дескрипторів ключових точок зображень. *Радіоелектроніка, інформатика, управління*, № 2, С. 100-107.

70. Yang B., and Li H. (2018) A novel dynamic timed fuzzy Petri nets modeling method with applications to industrial processes. *Expert System Applications*, 97, pp. 276-289.

71. Білоцерковський В.В., Удовенко С.Г., Чала Л.Е. (2020) Метод нейромережевого розпізнавання фальсифікованих зображень. *Біоніка інтелекту*, 2 (95), С. 32-42.

72. Gorokhovatsky V.O., and Gadetska S.V. (2019) Determination of Relevance of Visual Object Images by Application of Statistical Analysis of Regarding Fragment Representation of their Descriptions. *Telecommunications and Radio Engineering*, 78 (3), pp. 211-220.

73. Gorokhovatskyi V., Putyatin Ye., Gorokhovatskyi O., and Peredrii O. (2018) Quantization of the Space of Structural Image Features as a Way to Increase Recognition Performance. *In Proceedings IEEE Second International Conference on Data Stream Mining & Processing (DSMP)*, pp. 464-467.

74. Gadetska S.V., and Gorokhovatsky V.A. (2018) Statistical Measures for Computation of the Image Relevance of Visual Objects in the Structural Image

Classification Methods, *Telecommunications and Radio Engineering*, 77 (12), pp. 1041-1053.

75. Zhang J.H., Xia J.J., Garibaldi J.M., Groumpos P.P., and Wang R.B., (2017) Modeling and control of operator functional state in a unified framework of fuzzy inference Petri nets. *Computer Methods and Programs in Biomedicine*, 144, pp. 147-163.

76. Srinath K.R. (2017) Python – The Fastest Growing Programming Language. *International Research Journal of Engineering and Technology*, 4, pp. 354-357.

77. Rashid B., and Rehmani M.H. (2016) Applications of Wireless Sensor Networks for Urban Areas: A Survey. *Journal of Network and Computer Applications*, 60, pp. 192-219.

78. Liu H.C., Luan X., Li Z., and Wu J. (2018) Linguistic Petri Nets Based on Cloud Model Theory for Knowledge Representation and Reasoning. *IEEE Transactions on Knowledge and Data Engineering*, 30, pp. 717-728.

79. Mukhamedieva D.T., and Begimov O.M. (2018) Methods and Algorithms of Fuzzy Models Construction Assessing the State of the Low-Formalized Processes. *International Journal of Applied Engineering Research*, 13 (6), pp. 4364-4372.

80. Akyüz M.H., Öncan T., and Altinel İ.K. (2019) Branch and bound algorithms for solving the multi-commodity capacitated multi-facility Weber problem. *Annals of Operations Research*, 279 (1-2), pp. 1-42.

81. Pickup L., Lang A., Atkinson S., and Sharples S. (2018) The dichotomy of the application of a systems approach in UK healthcare the challenges and priorities for implementation. *Ergonomics*, 61 (1), pp. 15-25.

82. Oliinyk A., Skrupsky S., and Subbotin S. (2018) Experimental Research and Analysis of Complexity of Parallel Method for Production Rules Extraction. *Automatic Control and Computer Sciences*, 52 (2), pp. 89-99.

83. García-Martínez X., and Van der Linden T. (2019) A characterization of Lie algebras via algebraic exponentiation. *Advances in Mathematics*, 341, pp. 92-117.

84. Kwak S., Ryu U., Kim G., and Jo M. (2019) A fuzzy reasoning method based on compensating operation and its application to fuzzy systems. *Iranian Journal of Fuzzy Systems*, 16 (3), pp. 17-34.

85. Aghaeipoor F., and Javidi M.M. (2019) On the influence of using fuzzy extensions in linguistic fuzzy rule-based regression systems. *Applied Soft Computing*, 79, pp. 283-299.

86. Nair A., and Dreyfus D. (2018) Technology alignment in the presence of regulatory changes: The case of meaningful use of information technology in healthcare. *International journal of medical informatics*, 110, pp. 42-51.

87. Pourjavad E., and Mayorga R.V. (2019) A comparative study and measuring performance of manufacturing systems with Mamdani fuzzy inference system. *Journal of Intelligent Manufacturing*, 30 (3), pp. 1085-1097.

88. Matarneh R., Tvoroshenko I., and Lyashenko V. (2019) Improving Fuzzy Network Models For the Analysis of Dynamic Interacting Processes in the State Space. *International Journal of Recent Technology and Engineering*, 8 (4), pp. 1687-1693.

89. Maciel L., and Ballini R. (2019) A fuzzy inference system modeling approach for interval-valued symbolic data forecasting. *Knowledge-Based Systems*, 164, pp. 139-149.

90. Lam H.K. (2018) A review on stability analysis of continuous-time fuzzy-model-based control systems: From membership-function-independent to membership-function-dependent analysis. *Engineering Applications of Artificial Intelligence*, 67, pp. 390-408.

91. Olivas F., Valdez F., Melin P., Sombra A., and Castillo O. (2019) Interval type-2 fuzzy logic for dynamic parameter adaptation in a modified gravitational search algorithm. *Information Sciences*, 476, pp. 159-175.

92. Wu D., and Mendel J.M. (2019) Recommendations on designing practical interval type-2 fuzzy systems. *Engineering Applications of Artificial Intelligence*, 85, pp. 182-193.

93. Johnson K.W., Soto J.T., Glicksberg B.S., Shameer K., Miotto R., Ali M., Ashley E., and Dudley J.T. (2018) Artificial intelligence in cardiology. *Journal of the American College of Cardiology*, 71 (23), pp. 2668-2679.

94. Tvoroshenko I., and Gorokhovatskyi V. (2022) The Application of Hybrid Intelligence Systems for Dynamic Data Analysis. *International Journal of Engineering and Information Systems*, 6 (2), pp. 40-48.

95. Tvoroshenko I., Ahmad M.A., Mustafa S.K., Lyashenko V., and Alharbi A.R. (2020) Modification of Models Intensive Development Ontologies by Fuzzy Logic. *International Journal of Emerging Trends in Engineering Research*, 8 (3), pp. 939-944.

96. Ahmad M.A, Tvoroshenko I., Baker J.H., Kochura L., Lyashenko V. (2020) Interactive Geoinformation Three-Dimensional Model of a Landscape Park Using Geoinformatics Tools. *International Journal on Advanced Science, Engineering and Information Technology*, 10 (5), pp. 2005-2013.

97. Daradkeh Y.I., Gorokhovatskyi V., Tvoroshenko I., and Al-Dhaifallah M., (2022) Classification of Images Based on a System of Hierarchical Features. *Computers, Materials & Continua*, 72 (1), pp. 1785-1797.

98. Гороховатский В.А., Путятин Е.П., Столяров В.С. (2017) Исследование результативности структурных методов классификации изображений с

применением кластерной модели данных. *Радиоэлектроника, информатика, управление*, № 3 (42). С. 78-85.

99. Gorokhovatskyi V.A. (2018) Image Classification Methods in the Space of Descriptions in the Form of a Set of the Key Point Descriptors. *Telecommunications and Radio Engineering*, 77 (9), pp. 787-797.

100. Gorokhovatskyi V.A., and Zamula A.A. (2016) Employment of Intelligent Technologies in Multiparametric Control Systems. *Telecommunications and Radio Engineering*, 75 (19), p. 1775-1785.

101. Gadetska S., Gorokhovatskyi V., Stiahlyk N., and Vlasenko N. (2022) Aggregate Parametric Representation of Image Structural Description in Statistical Classification Methods. *In CEUR Workshop Proceedings: Computer Modeling and Intelligent Systems (CMIS-2022)*, 3137, pp. 68-77.

102. Кобилін О.А., Творошенко І.С. (2021) Методи цифрової обробки зображень: навч. посібник. Харків: ХНУРЕ, 124 с.

103. Gadetska S.V., Gorokhovatskyi V. O., Stiahlyk N. I., and Vlasenko N.V. (2021) Statistical data analysis tools in image classification methods based on the description as a set of binary descriptors of key points. *Radio Electronics, Computer Science, Control*, № 4, pp. 58-68.

104. Tvoroshenko I. (2019) Development of models of spatial analysis of status of interactive processes of complex systems. *International Scientific Conference Scientific Development of New Eastern Europe: Conference Proceedings (Riga, April 6th, 2019)*. Latvia: Baltija Publishing, Part II. pp. 152-156.

105. Творошенко І.С. (2021) Технології прийняття рішень в інформаційних системах: навч. посібник. Харків: ХНУРЕ, 120 с.