

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ

**А. С. Довбиш, А. В. Васильєв, В. О. Любчак**

**ІНТЕЛЕКТУАЛЬНІ ІНФОРМАЦІЙНІ  
ТЕХНОЛОГІЇ В ЕЛЕКТРОННОМУ  
НАВЧАННІ**

**Монографія**

Суми  
Сумський державний університет  
2013

**УДК 37.018.43:004**

**ББК 74.584(4Укр–4Сум)7**

**Д 58**

Рекомендовано до друку вченою радою Сумського державного університету (протокол № 01 від 12 вересня 2013 р.).

Рецензенти:

**М. Д. Кошовий** – доктор технічних наук, професор Національного аерокосмічного університету ім. М.Є. Жуковського «Харківський авіаційний інститут», м. Харків;

**А. Ф. Монако** – доктор технічних наук, професор Міжнародного науково-навчального центру інформаційних технологій і систем, м. Київ.

**А. С. Довбиш, А. В. Васильєв, В. О. Любчак**

Д 58 Інтелектуальні інформаційні технології в електронному навчанні / А. В. Васильєв, А. С. Довбиш, В. О. Любчак. – Суми: Сумський державний університет, 2013. – 177 с.

**ISBN 978-966-657-495-7**

У монографії розглядається досвід створення електронних засобів навчання з використанням інтелектуальних інформаційних технологій, накопичений у Сумському державному університеті. При цьому основна увага приділяється викладанню основних положень інформаційно-екстремальної інтелектуальної технології та застосуванню її ідей і методів для інформаційного аналізу і синтезу комп'ютеризованих систем в освіті.

Книга розрахована на широке коло науковців і спеціалістів, пов'язаних з розробкою інформаційних систем, викладачів і студентів вищих навчальних закладів, що спеціалізуються в галузі комп'ютерних наук.

**УДК 37.018.43:004**

**ББК 74.584(4Укр – 4Сум)7**

© Довбиш А. С., Васильєв А. В.,  
Любчак В. О., 2013

© Сумський державний університет,  
2013

**ISBN 978-966-657-495-7**

## ЗМІСТ

<b>Список скорочень.....</b>	<b>5</b>
<b>Передмова .....</b>	<b>6</b>
<b>Вступ. ....</b>	<b>7</b>
<b>Глава 1. Особливості проектування інтелектуальних систем в електронному навчанні.....</b>	<b>11</b>
1.1. Сучасний стан та тенденції розвитку комп'ютеризованих систем в освіті.....	11
1.2. Аналітичний огляд методів аналізу та синтезу системи комп'ютеризації освіти .....	24
1.3. Критерії схожості.....	32
1.4. Визначення та класифікація інтелектуальних систем.....	36
1.5. Основні принципи проектування інтелектуальних систем .....	43
1.6. Властивості інтелектуальних систем .....	45
1.7. Етапи проектування інтелектуальних систем .....	48
1.8. Види забезпечення інтелектуальних систем .....	51
<b>Глава 2. Інтелектуальні системи, що навчаються .....</b>	<b>54</b>
2.1. Формалізована постановка задачі інформаційного синтезу СППР, що навчається .....	54
2.2. Структура і функції адаптивної системи керування навчальним процесом.....	56
2.3. Основні положення інформаційно-екстремальної інтелектуальної технології.....	62
2.4. Вхідний математичний опис.....	67
2.5 Критерії функціональної ефективності .....	69
2.6. Базовий інформаційно-екстремальний алгоритм навчання СППР .....	79
2.7. Оптимізація контрольних допусків на ознаки розпізнавання .....	83

2.8. Оптимізація рівнів селекції координат двійкових еталонних векторів класів розпізнавання.....	88
2.9. Оптимізація словника ознак розпізнавання .....	94
2.10. Функціонування системи підтримки прийняття рішень в режимі екзамену .....	97
<b>Глава 3. Застосування інтелектуальних інформаційних техно- логій в навчальному процесі.....</b>	<b>100</b>
3.1. Формування вхідного математичного опису інтелектуальної системи контролю знань .....	100
3.2. Оптимізація вагових коефіцієнтів тестів.....	102
3.3. Формування класів еквівалентних ознак розпізнавання .....	109
3.4. Оптимізації вкладених контейнерів класів розпізнавання .....	121
3.5. Функціонування системи контролю знань в режимі кластер-аналізу результатів тестування.....	133
3.6. Побудова гіпереліпсоїдного класифікатора.....	151
3.7. Архітектура та функції адаптивної системи керування навчальним процесом.....	159
<b>Список літератури.....</b>	<b>169</b>

## СПИСОК СКОРОЧЕНЬ

- АСК – автоматизована система керування;  
АСКНП – автоматизована система керування навчальним процесом;  
БД – база даних;  
БОЗ – блок оцінки знань;  
БПОІ – блок первинної обробки інформації;  
БКОІ – блок кінцевої обробки інформації;  
БП – блок прогнозування;  
БФВР – блок формування векторів розпізнавання;  
ІОД – інтерфейс організації діалогу;  
КТЗ – комплекс технічних засобів;  
КФЕ – критерій функціональної ефективності;  
ОПР – особа, що приймає рішення;  
СКД – система контрольних допусків;  
СКЗ – система контролю знань;  
СППР – система підтримки прийняття рішень;  
ТІОС – телекомунікаційно-інформаційне освітнє середовище.

## ПЕРЕДМОВА

У монографії узагальнено накопичений в Сумському державному університеті досвід створення електронних засобів навчання з використанням інтелектуальних інформаційних технологій. Оскільки автори не ставили задачу висвітлення всіх напрямів і підходів до проектування інтелектуальних інформаційних систем, то основне місце у виданні, що пропонується, займають питання інформаційного аналізу і синтезу систем комп'ютеризованої освіти в рамках розробленої колективом проблемної лабораторії інтелектуальних систем Сумського державного університету інформаційно-екстремальної інтелектуальної технології. Перевага цієї технології перед відомими методами інтелектуального аналізу даних (Data Mining) полягає в тому, що вона ґрунтується на максимізації інформаційної спроможності системи в процесі її машинного навчання. Оскільки загальний критерій функціональної ефективності інтелектуальної системи керування має інформаційну природу, то саме максимізація її інформаційної спроможності дозволяє формувати високодостовірні рішення. Крім того, використання ідей і методів машинного навчання та розпізнавання образів для аналізу і синтезу автоматизованої системи керування навчальним процесом надає їй властивість адаптивності до довільних початкових умов і впливу некерованих факторів, що обумовлюють апріорну невизначеність, і дозволяє здійснювати дефазифікацію апріорно нечітких даних.

Автори сподіваються, що викладений в монографії матеріал буде корисним при створенні сучасних інтелектуальних систем різного призначення, в тому числі, і в освітній галузі, що дозволить вітчизняним вищим навчальним закладам підвищити рівень підготовки фахівців до вимог існуючих європейських освітніх стандартів.

## ВСТУП

Сучасний період розвитку інформаційного суспільства характеризується переходом до більш високої фази його розвитку, яка умовно одержала назву знання-орієнтоване суспільство. Якщо загальною характеристикою інформаційного суспільства є застосування інформаційних технологій у створенні більш ніж половини світового валового продукту, то в знання-орієнтованому суспільстві більше половини світового валового продукту буде вироблятися за допомогою інтелектуальних інформаційних технологій. Тому розробка і впровадження у всі без винятку галузі соціально-економічної сфери українського суспільства ефективних інтелектуальних інформаційних технологій є актуальною задачею, оскільки від успішності її розв'язання залежить конкурентоспроможність економіки країни. Це ставить перед вищою школою України дуже важливе і складне завдання підготовки висококваліфікованих фахівців у галузі комп'ютерних наук, здатних розробляти і застосовувати на практиці інтелектуальні інформаційні технології. Саме розвиток цього освітнього напрямку є ключовим в подальшому науково-технічному і соціально-економічному прогресі українського суспільства.

Розробка інтелектуальних інформаційних технологій в Україні почалася одночасно з розвитком комп'ютерної ери в середині ХХ-го століття і пов'язана з такими іменами засновників наукових шкіл, як О. Г. Івахненко, В. М. Глушков, А. А. Ковалевський, М. І. Шлезінгер, В. І. Васильєв, Шабанов-Кушнарєнко, І. Б. Сіроджа, Є. П. Путятін та інші. При цьому теоретична база створення інтелектуальних інформаційних технологій була закладена в першій половині ХХ-го століття. Так, російський вчений А. А. Богданов запропонував біхевіристичну модель прийняття рішень, ідея якої полягає в оцінці функціонального стану досліджуваної системи шляхом аналізу її реакції на типові входні дії. Осно-

вою такого аналізу стали результати теорії багатовимірного статистичного аналізу та теорії інформації, становлення якої було закладено в працях Клода Шеннона, А. А. Харкевича, С. Кульбака, І. В. Кузьміна та інших вчених. Саме поєднання біхевіристичного і теоретико-інформаційного підходів призвело до створення сучасної кібернетики, яка в логіко-гносеологічному аспекті розглядається як перетин категорій керування й інформації. Центральним питанням кібернетики як науки про керування складними процесами, що не формалізуються традиційними математичними методами, є моделювання когнітивних процесів, притаманних людині при прийнятті рішень. Таке моделювання здійснюється засобами інтелектуальних інформаційних технологій виявлення закономірностей при аналізі даних.

Створені в другій половині ХХ-го століття інтелектуальні інформаційні технології в основному характеризувалися модельністю, оскільки базувалися на традиційних методах математичного моделювання. Ці технології сприяли вивченню механізму прийняття рішень людиною, але не знайшли широкого застосування на практиці через обмеження методологічного характеру. Тому на рубежі ХХІ-го століття панівною стала думка, що безальтернативною тенденцією подальшого розвитку інтелектуальних інформаційних технологій є надання їм властивості адаптивності на основі машинного навчання (самонавчання) та розпізнавання образів. Теоретичне обґрунтування й експериментальне підтвердження цього напрямку досліджень знайшло в працях відомого вченого-фізіолога Анохіна П. К.

Таким чином, подальше підвищення функціональної ефективності сучасних інтелектуальних систем полягає з одного боку в наближенні механізму прийняття рішень до його біологічного носія – людини, а з іншого – у використанні основної переваги комп'ютеризованої системи – це практично необмеженої пам'яті.



В сучасних умовах основним інноваційним напрямом динамічного розвитку і реформування вищої школи в Україні в плані її євроінтеграційних зусиль є застосування інтелектуальних інформаційних технологій в електронному навчанні (e-Learning). Нажаль, як це стверджується в праці [1], створення більшості відомих систем комп'ютеризації освіти зводиться в основному до розробки апаратно-програмного інструментарію передачі студенту навчального контенту при відсутності інтелектуальної складової. Незважаючи на великий обсяг публікацій, присвячених проблемам e-Learning, все ще спостерігається гострий дефіцит публікацій, пов'язаних з дослідженнями таких важливих питань, як автоматизація проектування навчальних дисциплін, машинна оцінка рівня знань, формування оптимальних (тут і далі в інформаційному розумінні) індивідуальних навчальних траєкторій досягнення студентом необхідного рівня знань, адаптація навчального процесу до сучасних вимог ринку праці тощо.

Складність розробки та застосування інтелектуальних інформаційних технологій в e-Learning пов'язано з необхідністю моделювання творчої діяльності людини-викладача при довільних початкових умовах навчального процесу і впливу на нього неконтрольованих факторів, що обумовлює апріорну невизначеність.

Одним із перспективних шляхів побудови адаптивних автоматизованих систем керування навчальним процесом (АСКНП) є використання ідей і методів розробленої в Сумському державному університеті інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу і синтезу здатних навчатися (самонавчатися) систем підтримки прийняття рішень (СППР), ознайомленню з основними положеннями якої присвячено це видання. При цьому основним елементом структури адаптивної АСКНП в монографії розглядається здатна навчатися СППР, орієнтована як на викладача, який розробляє та супроводжує навчально-методичне забезпечення навчальної дисципліни, так і на об'єкт навчання – сту-

дента. Для усунення неоднозначності при вживанні терміну “навчання” щодо СППР доцільним є використання терміну “машинне навчання”.

Монографія складається із трьох розділів. В першому розділі розглянуто системологічні питання проектування інтелектуальних інформаційних систем. В другому розділі викладено основні положення ІЕІ-технології аналізу і синтезу здатної навчатися СППР. Третій розділ присвячено застосуванню ідей і методів ІЕІ-технології при створенні адаптивної системи керування навчальним процесом на прикладі системи контролю знань. При цьому значну увагу приділено автоматизації формування вхідного математичного опису адаптивної АСКНП та підвищенню достовірності машинної оцінки рівня знань студентів.

Автори висловлюють щирю подяку викладачам і аспірантам кафедри комп’ютерних наук Сумського державного університету к.т.н. Шелехову І. В., к.т.н. Петрову С. О., Москаленку В. В., Бересту О. Б., Кузікову Б. О. і Стадник Г. А. за їх участь у розробленні та програмній реалізації окремих алгоритмів.

# **ГЛАВА 1. ОСОБЛИВОСТІ ПРОЕКТУВАННЯ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ В ЕЛЕКТРОННОМУ НАВЧАННІ**

## **1.1. Сучасний стан та тенденції розвитку комп'ютеризованих систем в освіті**

Технічною основою сучасних АСКНП є Інтернет, а звичайною практикою є надання слухачам доступу до мережних підручників і посібників. Істотною роль у дистанційних курсах відіграє мультимедіа: ілюстративний матеріал, мультфільми, аудіо- і відеозаписи, вбудовані в HTML-сторінки [1]. Співробітництво й академічна підтримка також забезпечуються засобами Інтернет – внутрігруповою і звичайною електронною поштою, чатом, дискусійними клубами як за участю викладача-модератора, так і без нього, дошка оголошень і служба новин, і, нарешті, аудіо- і відеоконференції. Останнім часом популярність набули «віртуальні класи», у яких слухачі програмно синхронізуються для відтворення психологічних ефектів змагання і конкуренції. Важливу роль у АСКНП відіграє персоніфікація, виконувана шляхом регулярного тестування оцінки рівня підготовки, ступеня і швидкості освоєння матеріалу.

Динаміка, з якою з'являються новинки, наприклад, на ринку систем електронного навчання, свідчить про його швидкий розвиток. Кожна така система в собі містить деякі спеціальні інструментальні засоби, які призначені для розробки навчальних дисциплін. Узагальнено вони мають такі переваги:

- істотно знижується час на розробку курсів;
- знижуються загальні витрати організації на розробку і супроводження дистанційних курсів;
- забезпечується сучасний рівень функціональних і комунікаційних можливостей графічного інтерфейсу дистанційних курсів;

- виключаються системні помилки починаючих розроблювачів дистанційних курсів.

Застосування спеціалізованих засобів розроблення дистанційних курсів дозволяє істотно розширити аудиторію потенційних їх розроблювачів курсів, у тому числі, і викладачів, що не володіють глибокими знаннями в області інформаційних технологій. Наведемо характеристику найбільш популярних систем дистанційного навчання.

Однією з найбільш популярних систем дистанційного навчання (особливо в російських освітніх структурах) є "Прометей" [2]. Вона являє собою програмну оболонку, що забезпечує дистанційне навчання й тестування слухачів і дозволяє керувати діяльністю віртуального навчального закладу. Розроблювачі системи відзначають такі особливості як: наявність інтерфейсу на чотирьох крім російської мовах (українська, казахська, англійська й іспанська), простоту в освоєнні, формат HTML, можливість вбудовування готових електронних курсів, гнучку систему тестування, невисокі вимоги до комп'ютерів, наявність централізованої бази даних і безліч інших можливостей.

Компанія BlackBoard пропонує рішення Blackboard 5, для навчальних закладів [3]. Рішення Blackboard 5 складається із трьох головних додатків: Blackboard Learning System - система керування курсами; Blackboard Community Portal System - об'єднуючий портал, що надає доступ до ресурсів, адмініструванню курсів, засобам спілкування, розкладу й т.д. для відповідних категорій користувачів; Blackboard Transaction System - інтернет-система, що забезпечує ідентифікацію студентів, надання доступу й керування платежами за навчання та інше. Blackboard Learning System складається з додатків:

- 1) Course management - безпосередньо система керування курсами, що забезпечують керування контентом, засобу спілкування

(форуми, чати й т.п.), проведення тестів, опитувань, іспитів; а також надання різного додаткового засобу керування для викладачів;

2) Blackboard Building Blocks architecture for interoperability and customization компонент, що забезпечує інтеграцію різних видів контенту й комерційних додатків із платформою Blackboard, а також утримуючі різні утиліти й додатки для студентів і викладачів;

3) Advanced integration and system management – система, що забезпечує інтеграцію рішення Blackboard з різними інформаційними системами.

Програмне навчальне середовище Learning Space 5.0 (Lotus/IBM) дає можливість навчатися й викладати в асинхронному режимі (звертаючись до матеріалів курсів у зручний час) і брати участь в on-line заняттях у режимі реального часу. Користувач може створювати зміст курсу в будь-яких додатках і потім розміщати створений матеріал в Learning Space 5.0. Програма має гнучку систему редагування й адміністрування курсу, дозволяє вибирати різні режими викладання й стежити за поточними результатами роботи учнів.

Дистанційні курси організовано у вигляді послідовності занять, які можуть бути самостійними, інтерактивними або колективними. Самостійні заняття звичайно містять матеріал для прочитання й тести, які необхідно виконати після вивчення матеріалу. Інтерактивні заняття містять у собі відвідування лекцій у віртуальному класі, участь в онлайнній дискусії або chat, роботу з віртуальною дошкою (Whiteboard) і системою спільного перегляду Web-сайтів (Follow me). Колективні заняття містять у собі заняття в офлайнній й онлайнній дискусіях, chat. Всі записи, залишені в дискусії курсу, доступні протягом усього часу вивчення курсу. Інтерактивні заняття плануються на певну дату й час, і проводяться викладачем у віртуальному класі в режимі реального часу. Поточні результати учнів (ступінь проходження курсу, оцінки за нього, витрачене час, кількість звертань і т.д.) зберігаються в базі даних. Ця

інформація доступна викладачеві в будь-який час у вигляді звітів різної форми.

Система Learning Space 5.0 складається із двох основних компонентів: "Базового модуля" (Core) і модуля "Спільна робота" (Collaboration). Базовий модуль складається із сервера Core (на якому встановлене й працює ПО Learning Space 5.0), сервера бази даних й авторського Web-сервера. Сервер Learning Space 5.0 містить основне програмне забезпечення продукту і є ядром системи дистанційного навчання. Він забезпечує створення інтерфейсу, призначеного для уведення й одержання інформації про користувачів і курси, збереження й одержання інформації про результати учнів. Він також підтримує інтерфейс студента, призначений для участі в заняттях і перегляду персональних дані реєстрації й результатів навчання. У базі даних зберігаються дані про користувачів, курс і оцінки слухачів, які видаються автоматично або за запитом користувача. Крім цих запитів до бази даних, Learning Space 5.0 містить кілька визначених форматів для створення звітів. У базі даних перебуває інформація про структуру курсу, а зміст курсу перебуває на авторському Web-сервері.

Інтегральне середовище розробки й використання мережних курсів WebCT є одним із самих потужних й популярних у світі засобів розробки й застосування мережних курсів [4-5]. Ця технологія мережного навчання підтримує стандарти IMS ([www.imsglobal.org](http://www.imsglobal.org)). Центральним інструментом даної групи є Модуль змісту, що представляє із себе гіпертекстовий підручник у форматі HTML. Безпосереднє відношення до Модуля змісту мають Пошук за матеріалами курсу і Предметний покажчик.

Електронні розподілені семінари проводяться в режимі форумів у розподіленому часі відповідно до графіка. Сценарій проведення електронного семінару та проводиться в "епістолярному" жанрі, тобто комунікація проводиться за допомогою електронних повідомлень, а не вербально як при традиційному семінарі. Протя-

гом проведення семінару студенти зобов'язані дати відповіді в письмовій формі на кожне питання семінару (ці відповіді доступні для огляду на екранах комп'ютерів всім студентам групи). Викладач коментує відповідь студента в письмовій формі, крім того, заохочуються висловлення студентів, одержувані як реакція на повідомлення своїх однокурсників (активна дискусія). Апаратно-програмні засоби дозволяють викладачеві персонально звертатися в письмовій формі до кожного студента (для цього можна так само використати внутрішню електронну пошту). Наприкінці семінару викладач підводить підсумки семінару й виставляє оцінки. Результати дискусій під час проведення семінару залишаються в базі даних.

Лідером серед західних систем електронного супроводу навчального процесу є модульне об'єктно-орієнтоване динамічне середовище Moodle [6]. Популярність системи була викликана її безкоштовним розповсюдженням під ліцензією GNU GPL у вихідному коді. Завдяки модульній структурі та можливістю доопрацювання системи власними силами, на даний час кількість модулів, які входять в базову поставку системи, значно збільшилась. Розширено модулі адміністрування, збільшено перелік типів завдань, збільшені можливості з адміністрування курсу, удосконалено механізм роботи з базою даних, розроблено зручний інтерфейс обробки оцінок. Один із суттєвих недоліків, пов'язаних із закладеною на початковому етапі проектування Moodle його архітектури, полягає в значних ускладненнях при імплементації в середовище здобутків сучасної науки в галузі побудови адаптивних систем зокрема щодо їх інтелектуальної складової, яка реалізується на основі машинного навчання та розпізнавання образів.

Із наведених прикладів можна вивести такі вимоги до загальної структури адаптивної АСКНП:

- система повинна розроблятися як мультиагентна, багатомодульна система, розроблена на об'єктному рівні;

- архітектура системи повинна підтримувати як взаємодію через Інтернет, локальну мережу, та через тверді носії інформації (CD,DVD,Blu-Ray, та інше);

- модель системи повинна бути масштабована, та легко адаптуєма до ресурсних обмежень;

- в АСКНП потрібно інтегрувати сучасні мультимедійні та Інтернет-технології, які вже використовуються в дистанційній освіті;

- модель АСКНП повинна бути гнучкою, щоб введення в неї сучасної мультимедійної або Інтернет-технології не призводило до перебудови системи;

- інтерфейс системи повинен бути таким, що не потребує від користувача спеціальних (додаткових) знань;

- бажано, щоб АСКНП була незалежна від платформи, на якій встановлена (кросплатформенність).

Нажаль, можна констатувати, що немає жодної системи, яка враховує ці вимоги. При цьому майже не дослідженими є такі питання:

- не розроблена математична модель взаємодії агентів АСКНП;

- відсутній критерій для оцінки функціональної ефективності АСКНП;

- відсутність необхідного математичного апарату для процесу виведення знань;

- відсутня математична модель ефективного машинного оцінювання знань;

- відсутні підходи до оптимізації параметрів функціонування АСКНП.

Подальша інформатизація телекомунікаційного інформаційного освітнього середовища (ТІОС) ґрунтується на комп'ютеризованих засобах праці та інтелектуальних інформаційних технологіях і потребує принципово нового інформаційного середовища – сукупності ЕОМ, систем комп'ютерних комунікацій, баз даних і



баз знань, а також програмних комплексів. У теперішній час значного поширення набули системи контролю знань, побудовані на базі здатних навчатися (самонавчатися) систем підтримки прийняття рішень (СППР) [7-9]. Такі СППР є подальшим розвитком експертних систем [10]. Вони забезпечують одержання кількісної оцінки показників роботи системи на підставі обраних критеріїв та моделей альтернативних варіантів ситуацій. Як показано в працях [8,9,11] сучасна класифікація інтелектуальних СППР є багатокритеріальною. Так, СППР, що використовуються в СКО, повинні бути:

- детерміновано-статистичними за типом вирішальних правил;
- слабо формалізованими за моделлю керування;
- стабілізуючими за законом керування;
- класифікаційними за типом керування;
- технологічно гнучкими, що легко переналагоджуються;
- адаптивними, що досягається шляхом оптимізації просторово-часових параметрів функціонування в процесі машинного навчання (самонавчання).

Інтелектуальна СППР, інтегрована в СКЗ, орієнтована на користувачів, у ролі яких виступають інформаційні агенти ВИКЛАДАЧ або СЛУХАЧ. Основними функціями інтелектуальної СППР, інтегрованої в СКЗ, можуть бути: аналіз поточного функціонального стану навчального процесу, формування та корекція навчального контенту дистанційного курсу, генерування тестів, формування еквівалентних наборів тестів для оцінки знань слухачів, контроль й оцінюванні варіантів рішень, формуванні для слухача індивідуальної навчальної траєкторії засвоювання знань необхідного рівня та інше, що забезпечує досягнення поставленої мети. Прийняття рішень в класифікаційних СППР здійснюється шляхом машинної оцінки функціонального стану слабо формалізованого процесу та реалізації користувачем рекомендованих системою керуючих команд. Структура класифікаційної СППР представлена на рис. 1.1.

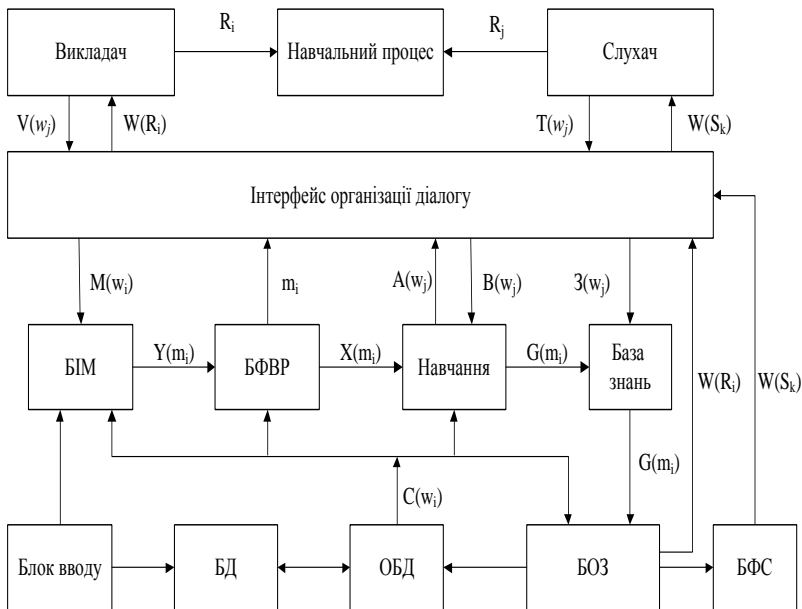


Рисунок 1.1. Структура класифікаційної СППР для супроводження навчального процесу

Користувачі – викладач і слухач працюють з СППР через інтерфейс організації діалогу (ІОД) за допомогою запитів  $V(w_j)$  і  $T(w_j)$  і відповідей  $W(r_i)$  і  $W(s_j)$  відповідно. Викладачу надається право остаточного вибору й прийняття рішення  $R_i$  із множини  $R(w_i)$ , а слухачу – вибору у разі необхідності стратегії  $S_k$ , що визначає індивідуальну навчальну траєкторію оволодіння необхідним рівнем знань. Вся множина завдань  $\{W_j\}$ , що розв'язуються СППР, розбивається на три групи: завдання аналізу, синтезу й прийняття рішень. За бажанням викладач вибирає одну з груп і вказує необхідний критерій функціональної ефективності (КФЕ).

Відповідно до обраного завдання  $w_j$  ІОД вибирає необхідні моделі  $M_i$  у блоці імітаційних моделей (БІМ). Якщо обрано режим синтезу навчальної дисципліни, то здійснюється режим навчання СППР, в процесі якого оптимізуються її просторово-часові параметри. При цьому в БІМ вводяться результати тестування слухачів і на виході він формує вхідну навчальну матрицю  $Y(m_i)$  для заданого алфавіту  $\{m_i\}$  класів розпізнавання, потужність якого визначається відповідною системою оцінки рівня знань слухачів. На початку роботи СППР створюється оперативна база даних (ОБД), що є копією бази даних (БД) і за запитом користувача видає необхідні дані  $C(w_j)$  для функціонування зазначених на рис. 1.1 функціональних блоків згідно з обраним завданням  $w_j$ . Блок формування векторів розпізнавання (БФВР) формує бінарну навчальну матрицю  $X(m_i)$  як вхідну для блоку навчання. Блок навчання буде вирішувати правила шляхом оптимізації параметрів функціонування СППР за заданим КФЕ. При цьому просторово-часові параметри функціонування СППР оптимізуються у процесі навчання шляхом реалізації багатоциклічної ітераційної процедури пошуку глобального максимуму усередненого за алфавітом класів розпізнавання значення КФЕ системи. Одержані в процесі навчання оптимальні параметри функціонування  $G(m_i)$  поступають у базу знань, звідки при виборі викладачем режиму прийняття рішень передаються в блок оцінки знань (БОЗ), в який із ОБД поступають результати поточного тестування знань слухачів. При цьому викладач має можливість через ІОД проглядати і редагувати ОБД. Результат роботи БОЗ в режимі аналізу виводиться ІОД на екран дисплея у вигляді значень, таблиць, графіків залежностей

показників функціонування від факторів, що впливають на навчальний процес, а за запитом слухача – у блок формування стратегій (БФС), який видає послідовність стратегій  $W(S_k)$ , які формують для нього індивідуальну навчальну траєкторію для оволодіння необхідним рівнем знань.

До основних загальносистемних принципів проектування СППР, що навчається, із урахуванням принципів, наведених у працях [12,13], відносяться:

- комплексність – реалізується побудовою системи, що охоплює всі галузі діяльності СППР, що навчається, функції керування, рівні організаційної структури, фази життєвого циклу, етапи оберту виробничих ресурсів та періоди планування;
- декомпозиція системи на елементи: підсистеми (цільові, функціональні, лінійного керування, забезпечення керування), спеціальні функції керування, задачі керування, модулі забезпечення окремих операцій технологічної структури;
- ієрархічність – здійснюється формуванням багаторівневої функціонально-лінійної структури СППР, що навчається, відповідно до потужності алфавіту класів розпізнавання;
- цілеспрямованість – здійснюється формуванням цільових підсистем СППР, що навчається, відповідно до основних галузей і цілей діяльності;
- замкненість циклу керування – здійснюється як у системі в цілому, так і в окремих її елементах повного циклу керування (прогнозування, планування, організація, координація, регулювання, активізація, стимулювання, урахування, контроль, аналіз);
- принцип несумісності для складних систем, який утверджує, що складність системи і точність, із якою можна її проаналізувати математичними методами, у першому наближенні обернено пропорційні;

- принцип апріорної недостатності обґрунтування гіпотез (принцип Бернуллі-Лапласа), за яким виправдано прийняття рівноймовірних гіпотез, тобто прийняття рішень в СППР, що навчається, здійснюється за найгіршими у статистичному розумінні умовами її функціонування;

- рандомізація (приведення до випадковості) вхідних даних, що дозволяє разом з детермінованими характеристиками функціонального стану СППР, що навчається вводити у розгляд випадкові реалізації образів розпізнавання для обчислення інформаційної спроможності системи;

- принцип неперервного розвитку – полягає у тому, що система повинна будуватися так, щоб поява нових засобів і сам розвиток системи не призводили до повної її перебудови.

Крім того використовуються відомі принципи системного підходу, які дозволяють здійснити аналіз і синтез адаптивної АСКНП за заданим критерієм досягнення мети.

У загальному випадку структура СППР є трьохкомпонентною і містить, крім компоненти користувача, компоненти керування і діалогу [8]. Доступність довідкових, нормативних та інших даних із БД про середовище, у якому приймається рішення, забезпечується компонентною керування даними і впливає на всі етапи ухвалення рішення.

Для керування, збереження даних, формування запитів необхідні СУБД і засоби запитів. Введення і виведення інформації, для чого служить діалоговий компонент, забезпечуються ІОД, який містить і перетворювач запитів. Компонент керування моделями – характерна риса СППР, де викликаються, випробовуються в дії, змінюються і комбінуються моделі, має базу моделей із системою керування для пошуку, генерації, перетворення параметрів і реструктуризації моделей, ведення довідника моделей; блок виконання моделей для керування прогонкою моделі і реалізації зв'язку між моделями; процесор команд моделювання для інтерпретації ін-

струкцій, одержуваних у діалозі, і направлення вироблених команд у систему керування блоком моделей або блок виконання моделей; інтерфейс з базою моделей і БД для пошуку елементів у базі моделей, прогонки моделей і збереження вихідної інформації моделі.

Для СППР, що навчаються, характерні такі особливості:

- розподілена системна архітектура;
- велика розмірність і складність функціональних зв'язків між окремими підсистемами СППР;
- використання великих і надвеликих обсягів інформації;
- наявність у їхньому складі різних (найчастіше різнорідних) архітектурних рішень і прикладних програмних продуктів;
- безперервний робочий цикл типу «24x365»;
- одночасна робота різних груп користувачів, що входять у технічний персонал таких СППР, а також наявність зовнішніх користувачів: технічних експертів та інше;
- значна ймовірність виникнення в роботі СППР критичних ситуацій, над вирішенням яких оперативно повинні працювати різні групи фахівців.

Враховуючи особливості таких систем та перспективу їхньої модернізації надалі можна зробити висновок про необхідність їх побудови на Internet-орієнтованій технологічній платформі. З огляду на названі особливості функціонування АСКНП і можливості сучасних web-технологій, можна сформулювати такі положення:

- використання протоколів TCP/IP і HTTP дозволяє успішно вирішувати завдання створення розподілених програмних продуктів і організувати їхню стійку взаємодію, навіть коли при високій пропускну здатності каналів зв'язку (менше 9600 б/с) не працюють механізми RPC (Remote Procedure Call), що лежать в основі технології MS COM/DCOM;

- при наявності таких web-стандартів і технологій, як XML (eXtended Markup Language), DOM (Document Object Model), RDF

(Resource Description Framework) і програмна реалізація їхньої підтримки на боці браузера клієнта (browser client) дозволяє успішно вирішувати завдання моделювання й інтеграції різнорідних ресурсів даних у таких системах;

- web-серверні засоби для підтримки компонентних рішень такі, як ActiveX і ASP (Active Server Pages) компанії Microsoft, а також технології EJB (Enterprise JavaBeans) і JSP (Java Server Pages), розроблені консорціумом OMG (Object Management Group) і корпорацією Sun Microsystems, є ідеальною платформою для інтеграції існуючих (успадкованих) програмних рішень;

- середовище Internet цілком відповідає парадигмі функціонування СППР у режимі «24x365», а такі її сервіси, як E-mail і Chat можуть бути використані для ефективної організації колективної роботи різних груп користувачів;

- концепції і технології web-базованого тренінгу (Web based training – WBT) можуть бути успішно застосовані для створення систем безупинного корпоративного навчання і підвищення кваліфікації персоналу розподілених СКДН;

- з огляду на функціональні особливості СКО і можливості Web-технологій архітектура Internet-базованої системи повинна базуватися на відомій трьохрівневій парадигмі побудови розподілених компонентних додатків, що мають:

- сервіси представлення даних (data presentation services);
- сервіси бізнес-логіки (business logic services);
- сервіси доступу і збереження даних (persistent data access services).

Вказані сервіси повинні підтримуватися браузер-клієнтами системи, наприклад MS Internet Explorer чи Netscape Communicator, у взаємодії з відповідним web-сервером (серверами) СКДН. На рівні сервісів бізнес-логіки необхідні набори компонентів для:

- обміну даними з різними типами контролерів зовнішніх пристроїв, що входять у комплекс технічних засобів СКДН;

- оброблення ретроспективної інформації про хід навчального процесу;

- прогнозування і моделювання критичних ситуацій;
- підтримки процесів тренінгу персоналу.

Ці сервіси реалізуються засобами однієї з компонентних платформ: MS COM/DCOM & MTS (Microsoft Transaction Server) / MS COM+ чи EJB (Enterprise JavaBeans) і можуть розміщатися на відповідному сервері (серверах) додатків (application server). На рівні сервісів доступу і збереження даних необхідно реалізовувати:

- базу даних ретроспективної інформації для аналізу і прогнозування стану навчального процесу;
- базу даних для забезпечення процедур дистанційного тренінгу персоналу СКО;
- репозиторій метаданих, що описують інтегровану інформаційну модель усієї СКО.

При цьому сервіси звичайно реалізуються на платформі однієї із СКО, що підтримує роботу з web-базованими додатками через XML-інтерфейс, такими як MS SQL Server 7.0/2000, Oracle 8i/9i, IBM DB2 UDB 7.2. та інші.

Таким чином, аналіз показує, що організації-розроблювачі приділяють основну увагу на створення інтерфейсу користувача, впровадженні сучасних технологій представлення контенту до споживача і практично не приділяють увагу на математичні аспекти аналізу і синтезу СКО, їх вертикального й горизонтального проектування, розроблення систем ефективної оцінки знань слухача.

## **1.2. Аналітичний огляд методів аналізу та синтезу системи комп'ютеризації освіти**

Широке впровадження електронних засобів в освіті вимагає як розвитку Internet-технологій, так і математичних методів моделювання, аналізу та синтезу СКО. Значну актуальність ця задача набуває за умов впровадження Болонської системи в ТІОС України,



що робить необхідною розробку методів оптимізації та автоматизації процесу навчання. У працях [14-18] пропонується ряд підходів до моделювання СКО, які базуються на теорії кінцевих автоматів [14], марківських процесах [15], дисперсійному аналізі [16] методах фазового портрету [17] й імітаційного моделювання [18]. Нажаль, існуючі моделі та методи моделювання дистанційного навчання не дозволяють розв'язувати задачі цілеспрямованої оптимізації параметрів функціонування СКО з метою підвищення функціональної ефективності системи.

Задача оцінювання рівня знань за визначеною шкалою є по суті частинною задачею кластер-аналізу при заданій потужності алфавіту класів розпізнавання [19-21]. Відомі алгоритми кластер-аналізу за структурою даних прийнято поділяти на два основних класи:

1) однорівневі (лінійні) алгоритми, в яких об'єкт пов'язаний тільки з однією групою;

2) алгоритми ієрархічної кластеризація, яка здійснює розбиття відносно великої групи об'єктів на групи менших розмірів.

В останні роки у зв'язку з широкою комп'ютеризацією виробничих і освітніх процесів застосування як методів факторного кластер-аналізу [20], так і кластер-аналізу в класичній постановці [21] набуває важливого значення.

Сучасні прикладні алгоритми кластер-аналізу базуються на припущенні, що використання дистанційних та статистичних критеріїв, мають приводити до ситуації, коли сформований кластер буде включати геометрично близькі групи, але при цьому отримуємо незбалансовані компоненти. Альтернативний підхід пропонує цілеспрямовано формувати контейнер за рахунок оперативного виявлення прихованих функціональних закономірностей, які об'єктивно існують [20]. Даний підхід є перспективним, але має істотні недоліки, такі як: висока обчислювальна складність, обмеження на вигляд функції регресії (лінійна), і, нарешті, він не враховує, що апріорне розбиття простору ознак на класи є нечітким,

тобто має місце перетин класів розпізнавання. У результаті побудова в процесі кластеризації чіткого розбиття класів розпізнавання, що є її кінцевою задачею, виявляється нетиповою для практичних задач.

Класичним алгоритмом неієрархічної кластеризації є сімейство алгоритмів *K-means* [21]. Відповідно до ідеї алгоритму кластер будується у вигляді центроїду, який є центром мас векторів, що визначають кластер. Але для запуску алгоритму необхідними входними даними є апріорно зазначеною кількість класів  $k$ , та визначений вигляд оціночної функції  $c: \{X : X \leq S\} \rightarrow R^+$  – вага кластера. Тоді оптимізаційна задача вибору такої множини векторів формується як мінімізація ваги кластеру

$$\sum_i c(S_i) \rightarrow \min, \quad i = \overline{1, k} \quad (1.2.1)$$

Основоположні принципи ієрархічного кластер-аналізу реалізовано в алгоритмах *Single Link*, *Complete Link*, *Group Average* [22]. Особливість цих методів полягає у розбитті векторів на класи шляхом послідовного групування векторів найближчих, в метричному сенсі, формуючи ієрархічну систему. Об'єднання відбувається до досягнення певного критичного значення. Узагальнення такого підходу отримав назву агломеративна ієрархічна кластеризація.

Об'єднати переваги як детермінованого, так і статистичного підходів до вирішення проблеми автоматичної класифікації та обійти їх недоліки – така задача розв'язується у рамках детерміновано-статистичного підходу. Наприклад, у праці [23] запропоновано будувати класифікатор у два етапи. На першому етапі будуватиметься найбільш просте детерміноване вирішальне правило, яке забезпечує безпомилкове розпізнавання реалізацій навчальної матриці. Для мінімізації кількості помилок і прогнозу їх величин при розпізнаванні на другому етапі здійснюється непараметрична ста-

тистична корекція вирішального правила. Для такої корекції використовують два одновимірних параметри, оцінку яких можна отримати за класифікованою навчальною матрицею. Це максимально-можливий викид реалізацій за “свою” еталонну оболонку та максимально-можливе проникнення у глибину еталонних оболонок реалізацій “чужих” образів. Подальшим розвитком методу еталонів [23] став метод еталонного опису [24], в якому з метою зменшення кількості еталонів, а отже і спрощення мінімізації покриття класу, акцент зроблено на відбір ефективних ознак розпізнавання шляхом оцінки їх корисності. Модельність як методу еталонів, так і методу еталонного опису полягає в ігноруванні загального випадку перетину класів і у відсутності оптимізації процесу навчання за прямим критерієм функціональної ефективності (КФЕ), що знижує їх практичну цінність.

Розглянемо математичну модель задачі автоматичної класифікації на рівні системного аналізу [25]. Така модель повинна включати як обов'язкову складову частину вхідний математичний опис, який подаємо у вигляді теоретико-множинної структури:

$$\Delta_B = \langle G, T, \Omega, Z, V, Y; \Pi, \Phi \rangle, \quad (1.2.2)$$

де  $G$  – простір вхідних сигналів (факторів), які діють на АСКНП;  $T$  – множина моментів часу зняття інформації;  $\Omega$  – простір ознак розпізнавання;  $Z$  – простір можливих станів АСКНП;  $V$  – множина вирішальних правил;  $Y$  – вибіркова множина результатів тестування знань студентів;  $\Pi: G \times T \times \Omega \rightarrow Z$  – оператор переходів, що відбиває механізм зміни станів АСКНП під дією внутрішніх і зовнішніх збурень;  $\Phi: G \times T \times \Omega \times Z \rightarrow Y$  – оператор формування вибіркової множини  $Y$  на вході АСКНП.

Нехай для чіткого (детермінованого) розбиття  $\mathfrak{R}^{|M|}$  потужності  $M$ , оператор його побудови задає бієктивне відображення  $\Theta: Y \rightarrow \mathfrak{R}^{|M|}$ . Тоді для загального випадку категорійну модель



В основу переважної більшості алгоритмів класифікації покладено гіпотезу компактності реалізацій образу, яка поділяється на гіпотези “унімодальної”, “полімодальної” і “локальної” компактності, а відносно проєкцій реалізацій образу на координатні вісі вона поділяється на відповідні проєктивні компактності. Гіпотезу унімодальної чіткої компактності покладено в основу чисельних алгоритмів автоматичної класифікації, які використовують поняття “ядро класу” і відновлюють роздільні гіперповерхні в радіальному базисі простору ознак [28]. Значне місце серед них належить таксономічним алгоритмам типу ФОРЕЛЬ [29], за допомогою яких у радіальному базисі будуються таксони. При цьому ядра таких таксонів збігаються з їх геометричним центром. В алгоритмах типу ФОРЕЛЬ єдиним керуючим параметром є поріг – радіус куль, якими покривається вибірка реалізацій  $X$ .

Таким чином, для широкого класу алгоритмів автоматичної класифікації, які реалізують задачу відокремлювання в багатовимірному просторі ознак компактних груп точок і в основу яких покладено гіпотезу чіткої компактності, загальними властивостями є використання дистанційних критеріїв типу “найближчого” або “найдалшого” сусіди та, взагалі, відсутність етапу навчання.

Ігнорування традиційними методами автоматичної класифікації гіпотези апіорної нечіткої компактності реалізацій образу дало поштовх для розвитку методів нормалізації образів [30] і методів нечіткої класифікації [31]. Основний недолік відомих методів нормалізації деформованих образів полягає у їх приведенні до “добре організованих” на етапі оброблення образів, тобто поза процедурою навчання. Це виключає можливість здійснення цілеспрямованої адаптації вхідного математичного опису інтелектуальної АСКНП в процесі побудови безпомилкових за навчальною багатовимірною матрицею вирішальних правил. Що стосується застосування методів нечіткої класифікації, то для кількісних шкал виміру ознак розпізнавання ці методи розглядаються як альтернативні статистичним методам, оскільки доведено, що у цьому випадку

функція належності, що відповідає вимогам Л. Заде, є аналогом функції щільності випадкової величини. Крім того, згідно з гіпотезою про апіорно нечітке розбиття простору ознак на класи розпізнавання реалізація процедури фазифікації вхідних даних є недоцільною, оскільки сама “природа” вже потурбувалася про їх фазифікацію. При цьому варто підкреслити, що застосування нечітких множин та апарату нечіткої логіки є виправданим при визначенні ознак розпізнавання за якісною шкалою вимірювань.

Одним із сучасних напрямків впровадження інноваційних технологій в навальний процес є застосування штучних нейронних мереж [32-34]. При цьому щодо недоліків цього напрямку необхідно вказати на те, що проблема інтерпретованості даних призводить до зниження якості одержаних результатів, проблема багатовимірності – до значних обмежень на місткість і складність структури мереж, а проблема лінійної розділимості – до необхідності застосування складних багат шарових мереж навіть для нескладних задач.

Основною сучасною тенденцією підвищення функціональної ефективності АСКНП є надання системі інтелектуальної складової на основі ідей і методів машинного навчання та розпізнавання образів. При цьому важливого значення набуває при розробленні інтелектуального інформаційного забезпечення адаптивних АСКНП створення високоефективних алгоритмів машинного навчання, які дозволяють будувати безпомилкові за багатовимірною навчальною матрицею вирішальні правила. Вирішення цієї проблеми у рамках детермінованого або статистичного підходів ускладнено через такі основні причини:

- модельний характер переважної більшості відомих методів автоматичної класифікації, що становить певну теоретико-методологічну цінність, але є непридатним для практичного застосування;

- нелінійність, нестационарність і багатofакторність навчального процесу, який відбувається за умов апіорної невизначеності.

Детерміновано-статистичний підхід до аналізу і синтезу здатних навчатися СППР дозволяє поєднати переваги детермінованих і статистичних методів і обійти їх недоліки. Тенденція до підвищення функціональної ефективності здатних навчатися (самонавчатися) СППР шляхом максимізації в процесі навчання інформаційної спроможності системи проявляє себе в останніх перспективних розробках ІТ-індустрії, однією з яких є інформаційно-екстремальна інтелектуальна технологія (ІЕІ-технологія) [9,25,36]. Основна ідея методів аналізу і синтезу здатних навчатися (самонавчатися) СППР у рамках ІЕІ-технології полягає в трансформації в процесі навчання системи апіорного у загальному випадку нечіткого розбиття простору ознак у чітке розбиття класів еквівалентності шляхом ітераційної оптимізації параметрів функціонування. При цьому здійснюється цілеспрямовано пошук глобального максимуму багатоекстремальної функції інформаційного КФЕ навчання в робочій (допустимій) області її визначення і одночасного відновлення оптимальних роздільних гіперповерхонь, що будуються в радіальному базисі бінарного простору ознак розпізнавання. Відмінністю методів ІЕІ-технології є те, що трансформація вхідного нечіткого розподілу реалізацій образів в чітке здійснюється в процесі оптимізації системи контрольних допусків, що приводить до цілеспрямованої зміни значень ознак розпізнавання і дозволяє побудувати безпомилкові за багатовимірною навчальною матрицею вирішальні правила. При цьому у рамках ІЕІ-технології вдалося поєднати нормалізацію образів, яка полягає у виправленні їх апіорної деформації стосовно еталонного образу, і безпосередньо етап навчання, на якому будуються безпомилкові за навчальною матрицею вирішальні правила.

Перспективним слід вважати застосування для пошуку глобального максимуму багато екстремальних функцій інформаційних

КФЕ навчання СКЗ генетичних алгоритмів [38], що дозволяє на відміну від методів прямого пошуку підвищити оперативність навчання системи, але втратити точність обчислення функції його якості.

Таким чином, можна зробити висновок, що не зважаючи на суттєві досягнення в галузі автоматичної класифікації і великий обсяг публікацій, значних зрушень у підвищенні функціональної ефективності СКЗ все ще не відбувається. Детальний аналіз даної тенденції, згідно з працею [1], вказує на те, що практично всі відомі інформаційні технології призначено для транспортування контенту знань до слухача, але при цьому відсутня інтелектуальна складова, яка забезпечує адаптивність системи. Тобто основним стримуючим фактором підвищення функціональної ефективності СКЗ є не сучасний стан комплексу технічних засобів ТІОС, а невирішені проблеми методологічного плану при створенні інтелектуального інформаційного забезпечення. При цьому центральним питанням підвищення функціональної ефективності СКЗ є надання СППР, що входить в її склад, властивості адаптивності шляхом використання ідей і методів машинного навчання та розпізнавання образів.

### **1.3. Критерії схожості**

Якість класифікації результатів машинного оцінювання знань суттєво залежить від вибору міри схожості (близькості). За міру схожості приймається величина, яка має границю і збільшується із зменшенням відстані між об'єктами. Традиційні міри близькості та відстаней нараховують до 50 мір схожості [39,40]. Розглянемо основні способи визначення близькості між об'єктами для кількісних шкал виміру.

Найбільш поширеною в кластер-аналізі є Евклидова відстань



$$d_E(x_m, x_l) = \sqrt{\sum_{i=1}^N (x_m^i - x_l^i)^2}, \quad (1.3.1)$$

де  $x_m$  – реалізація  $m$ -го кластера;

$x_l$  – реалізація  $l$ -го кластера;

$x_m^i$  –  $i$ -а ознака розпізнавання  $m$ -го кластера;

$x_l^i$  –  $i$ -а ознака розпізнавання  $l$ -го кластера;

$N$  – кількість ознак розпізнавання.

Міра (1.3.1) широко використовується при побудові кластерів з використанням методів еталонів,  $K$  - найближчих сусідів [41],  $K$ -середніх [21] та інших методів, що ґрунтуються на детермінованих дистанційних критеріях близькості.

Для придання більшої ваги віддалених один від одного об'єктів застосовується квадрат Евклидової відстані

$$d_E^2(x_m, x_l) = \sum_{i=1}^N (x_m^i - x_l^i)^2.$$

В практичних задачах машинного оцінювання знань має місце гіпотеза нечіткої компактності, оскільки класи, що характеризують відповідні рівні знань студентів, перетинаються і мають нечіткі (розмиті) межі. У цьому випадку доцільно застосовувати міру Махаланобіса [42]

$$d_M(x_m, x_l) = (x_m - x_l)^T W^{-1} (x_m - x_l), \quad (1.3.2)$$

де  $T$  – символ транспонування вектора-стовбчика;

$W^{-1}$  – матриця зворотня коваріаційна.

При дисперсії  $\sigma^2 = 1$  міра (1.3.2) переходить в детерміновану дистанційну міру.

Загальним недоліком дистанційних мір близькості є їх слабка валідність при класифікації через перетин класів, що має місце в практичних задачах оцінювання рівня знань. Як загальну міру валідності класифікації даних здатних навчатися СКЗ доцільно застосовувати інформаційну міру, наприклад, у вигляді

$$C_l = 1 - E, \quad (1.3.3)$$

де  $E$  – нормована інформаційна міра, яка є мірою різноманітності двох класів розпізнавання.

Найбільше розповсюдження для оцінки функціональної ефективності інтелектуальних систем знайшли ентропійна (Шеннонівська) міра [43-44] та інформаційна міра Кульбака [45]. Нормований ентропійний критерій має вигляд [44]

$$E = \frac{H_0 - H(\gamma)}{H_0} \quad (1.3.4)$$

де  $H_0$  – апіорна (безумовна) ентропія:

$$H_0 = - \sum_{l=1}^M p(\gamma_l) \log_2 p(\gamma_l); \quad (1.3.5)$$

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

$$H(\gamma) = - \sum_{l=1}^M p(\gamma_l) \sum_{m=1}^M p(\mu_m / \gamma_l) \log_2 p(\mu_m / \gamma_l). \quad (1.3.6)$$

У виразах (1.3.5) і (1.3.6) прийнято такі позначення:

$p(\gamma_l)$  – апіорна ймовірність прийняття гіпотези  $\gamma_l$ ;  
 $p(\mu_m / \gamma_l)$  – апостеріорна ймовірність прийняття гіпотези  $\mu_m$  за умови, що була прийнята гіпотеза  $\gamma_l$ ;

$M$  – кількість альтернативних гіпотез.

На практиці часто приймаються такі допущення:

- рішення є двохальтернативними ( $M=2$ );
- оскільки СППР функціонує за умов апріорної невизначеності, то згідно з принципом Бернуллі-Лапласа виправданим є прийняття рівномірних гіпотез

$$p(\gamma_1) = \dots = p(\gamma_m) = \dots = \frac{1}{M}.$$

Тоді критерій (1.3.4) із врахуванням виразів (1.3.5) і (1.3.6) приймає вигляд [25]

$$E = 1 + \frac{1}{2} \sum_{l=1}^2 \sum_{m=1}^2 p(\mu_m / \gamma_l) \log_2 p(\mu_m / \gamma_l). \quad (1.3.7)$$

Вираз (1.3.7) при прийнятих допущеннях співпадає з формулою для обчислення кількості середньої умовної інформації [43].

Ключовою проблемою методів автоматичної класифікації є питання визначення функціональної ефективності розбиття та вибір оптимального в інформаційному сенсі числа  $M$  – кількість класів розпізнавання. Тому експертний аналіз сформованих класів доповнюють використанням характеристик багатовимірною статистичного аналізу:

- загальне розсіювання

$$S = \sum_{k=1}^n (\mathbf{X}^{(k)} - \bar{\mathbf{X}})^T (\mathbf{X}^{(k)} - \bar{\mathbf{X}}),$$

де  $\bar{\mathbf{X}}$  – вибіркове середнє векторів реалізацій  $k$ -го кластеру;

$T$  – символ операції транспонування;

- внутрікласове розсіювання

$$B = \sum_{k=1}^K n_k (\bar{\mathbf{X}}_k - \bar{\mathbf{X}})^T (\bar{\mathbf{X}}_k - \bar{\mathbf{X}}),$$

де  $n_k$  – число елементів в  $m$ -му кластері;

$\bar{\mathbf{X}}_m$  – центр ваги  $m$ -го кластеру

$$\bar{\mathbf{x}}_k = \frac{1}{n_k} \sum_{j=1}^{n_k} \mathbf{x}_j^{(k)};$$

- міжкласове розсіювання

$$W = \sum_{k=1}^K W_k,$$

де

$$W_k = \sum_{j=1}^{n_k} (\mathbf{x}^{(j)} - \bar{\mathbf{x}}_k)^T (\mathbf{x}^{(j)} - \bar{\mathbf{x}}_k).$$

З іншого боку ефективність класифікації згідно з максимально-мінімальним дистанційним принципом теорії розпізнавання образів можна оцінити використавши другий функціонал Рубенса  $F_2 \in [0,1]$ ,

$$F_2 = \frac{1}{2} \left( \frac{1}{M} \sum_{m=1}^M \max_j d_{m,j} + \min_{\{k\}} d_{m,j} \right),$$

де  $d_{m,j}$  – евклідова відстань між вершинами векторів-реалізацій образів в просторі ознак розпізнавання.

Зазначені характеристики дозволяють провести оцінювання результатів класифікації. При цьому в основу цих характеристик покладено припущення про їх статистичну стійкість та однорідність.

#### 1.4. Визначення та класифікація інтелектуальних систем

Інтелектуальні системи (ІС) – це новий клас автоматизованих систем оброблення інформації на основі ЕОМ, які моделюють розумові процеси, притаманні людині при прийнятті рішень у різних галузях соціально-економічної сфери суспільства.

Відомо, що у рамках системологічного аналізу система повністю визначається шляхом однозначного задання таких її категорій, як елемент, відношення та властивість.

**Визначення 1.4.1.** Метою проектування системи є конкретизація та визначення таких значень і співвідношень її категорій, які дозволяють системі функціонувати із визначеною ефективністю.

**Визначення 1.4.2.** За існуючими стандартами [46] під функціонуванням системи розуміється процес виконання системою заданого робочого алгоритму при використанні системи за призначенням, тобто за критерієм мети створення системи.

Оскільки поняття “ефективність” все ще залишається неформалізованим, пропонується таке її визначення.

**Визначення 1.4.3.** Загальна ефективність системи визначає ступінь відповідності її складових виконанню системою свого призначення згідно із критерієм мети.

Важливою складовою загальної ефективності є функціональна ефективність.

**Визначення 1.4.4.** Під функціональною ефективністю системи розуміється складова загальної ефективності, яка визначає ступінь відповідності функціонування системи за її робочим алгоритмом виконанню поставленої перед нею задачі згідно з критерієм мети.

Формування критерію мети спрямовано на зняття невизначеності в описі системи. Оскільки мірою невизначеності є кількість інформації, то критерій мети має інформаційну природу, а інформаційний КФЕ є його важливою складовою, яка визначає асимптотичні точнісні характеристики класифікатора. Залежно від вхідних даних і уявлень про побудову та функціонування системи задачі синтезу поділяють на три класи [26]:

- інформаційний синтез, який передбачає оптимізацію (тут і далі в інформаційному розумінні) функціональної ефективності системи;
- структурний синтез, який спрямований на оптимізацію складу, конфігурації, внутрішніх і зовнішніх зв’язків системи при заданих алгоритмах її функціонування;

- комбінований синтез структури та алгоритмів функціонування, пов'язаний з розподілом функцій за елементами системи та визначенням їх оптимального складу.

Необхідною умовою синтезу системи є наявність вхідного математичного опису.

**Визначення 1.4.5.** Вхідний математичний опис є адекватною моделлю вхідних даних, що відбивають основні характеристики та властивості функціонального стану системи.

**Визначення 1.4.6.** Під функціональним станом розуміються основні характеристики системи у визначений момент або інтервал часу її функціонування у заданому режимі, які залежать як від технічного стану системи, так і від середовища, що впливає на неї через контрольовані і неконтрольовані фактори.

**Визначення 1.4.7.** Під проектуванням ІС розуміється процес створення технічного, інформаційного, програмного та організаційного забезпечення ІС для досягнення поставленої мети її функціонування. При цьому головна задача проектування полягає у формуванні переліку вимог, яким повинна задовольняти ІС, та їх реалізації на етапах проектування.

Етап апріорного проектування здійснюється за умов відсутності експериментальних даних функціонування ІС, що проектується, тобто це початковий етап проектування ІС з властивостями, які відсутні в природі або невідомі наперед розробнику. Етап апостеріорного проектування здійснюється за умов наявності експериментальних даних, одержаних як у результаті випробувань ІС, так і в процесі її експлуатації. При реалізації головної задачі проектування необхідно враховувати такі фактори:

- складність проектування, яка визначається повнотою апріорної інформації про ІС, що проектується;
- необхідність прийняття компромісних рішень;
- розбіжність з вимогами практики;
- можливі ризики.

Конструктивно ІС складається з програмно-апаратної частини і об'єкта, процесу або явища, що досліджуються (далі замість цих понять будемо використовувати переважно узагальнюючий термін “процес”).

ІС можуть функціонувати у двох режимах: автоматичному, тобто без участі в контурі функціонування системи людини – особи, що приймає рішення, (ОПР), або автоматизованому. На рис 1.3 наведено функціональну схему ІС, що функціонує в автоматизованому режимі.

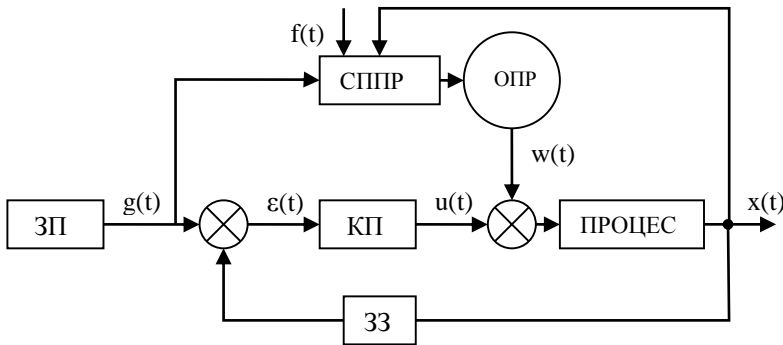


Рисунок 1.3 – Функціональна схема ІС, що функціонує в автоматизованому режимі

На рис. 1.3 прийнято такі позначення: ЗП – пристрій, що задає вхідний сигнал;  $\otimes$  – компаратор (суматор, пристрій порівняння); КП – керуючий пристрій; ЗЗ – зворотний зв’язок;  $f(t)$  – випадкові неконтрольовані збуджуючі фактори. Як видно з рис.1.2, в автоматизованій ІС функції регулятора виконують СППР і ОПР.

Використання ІС, що функціонують в автоматичному режимі, є виправданим для розв’язання задач контролю та керування формалізованими процесами, моделювання яких можливе за традиційними математичними методами [45]. У той самий час областю застосування автоматизованих ІС є слабо формалізовані процеси

(автоматична класифікація, ідентифікація, розпізнавання образів, керування, діагностування та інше), які відбуваються за умов апріорної невизначеності. Введення у розгляд гіпотези нечіткої компактності реалізацій образу потребує розширення та конкретизації поняття “слабо формалізований процес”. Для застосування цього поняття в методах машинного навчання СППР розглянемо таке його визначення.

**Визначення 1.4.8.** Слабо формалізованим називається динамічний процес, що має такі характеристики:

- унікальність процесу, пов’язана з моделюванням розумових процесів, властивих людині при прийнятті рішень;
- ознаки розпізнавання визначаються за кількісною шкалою вимірювань;
- імплікативний характер взаємозв’язку характеристик системи;
- багаторівнева ієрархічна організація бази даних і взаємозв’язку підпроцесів;
- різноманіття можливих форм взаємодії підпроцесів між собою, яке породжує неоднорідність інформації, що циркулює в системі;
- багатофакторність і наявність часткових суперечливих критеріїв;
- нечітка, у загальному випадку, компактність реалізацій образу, обумовлена довільними початковими умовами динамічного процесу керування у моменти зняття інформації;
- апріорна невизначеність.

Основною функцією СППР як складової АСКНП є формування шляхом аналізу поточного функціонального стану навчального процесу рекомендацій ОПР для вироблення оперативних і високодостовірних рішень. Далі під СППР будемо розуміти інтелектуальну СППР.

Сучасна класифікація СППР повинна враховувати всі попередні класифікації, що стосуються автоматизованих систем різного



призначення. За типом вирішальних правил СППР поділяють на детерміновані, статистичні і детерміновано-статистичні.

До детермінованих відносять СППР, що приймають рішення за чіткими вирішальними правилами. Цей клас СППР характеризується високою оперативністю, простими вирішальними правилами, але низькою достовірністю рішень, що приймаються, через вплив на ІС випадкових факторів.

Статистичні СППР ставлять за мету максимізацію (мінімізацію) статистичних критеріїв якості функціонування системи при заданих обмеженнях на саму систему або на сигнали та процеси, які впливають на неї.

У детерміновано-статистичних інтелектуальних СППР поєднано переваги як детермінованого, так і статистичного підходів до розв'язання задач аналізу та синтезу систем. У рамках цього підходу будуються прості детерміновані вирішальні правила, які на етапі навчання системи оптимізуються (тут і далі в інформаційному розумінні) шляхом статистичної корекції.

За критерієм ступеня інтелектуалізації, який у першому наближенні може характеризуватися обсягом інформації, що обробляється, ІС можна поділити так:

- системи перебору варіантів рішень згідно з встановленою пріоритетністю для наперед змодельованих ситуацій;
- ІС, які приймають рішення за детермінованими вирішальними правилами без навчання;
- ІС, що реалізують алгоритми компараторного розпізнавання за еталонами;
- експертні системи, що з метою прийняття ефективних рішень маніпулюють спеціальними знаннями, накопиченими фахівцями-експертами у конкретно-предметній сфері знань;
- СППР, які на відміну від експертних систем здатні самостійно створювати базу знань;
- ІС, що навчаються

- знання-орієнтовані (knowledge-based) ІС, що здатні утворювати базу знань за якісною шкалою виміру ознак розпізнавання.

Здатні навчатися ІС можна поділити на такі основні класи:

- ІС, що розв'язують задачу розпізнавання образів за апріорно класифікованою навчальною матрицею (навчання з “учителем”);

- ІС, що реалізують алгоритми факторного кластер - аналізу;

- ІС, що реалізують алгоритми кластер-аналізу при незмінному словнику ознак і за апріорно некласифікованими навчальними матрицями, тобто за умови неповної апріорної інформації про функціональний стан системи (навчання без “учителя”);

- ІС, що самонавчаються, які реалізують так само алгоритми автоматичної класифікації за апріорно некласифікованими навчальними матрицями, але, крім того, здатні оптимізувати параметри словника ознак розпізнавання;

- відмовостійкі ІС, що здатні самостійно діагностувати свій функціональний стан і відновлювати свою функціональну спроможність при виникненні відмов;

- адаптивні ІС, що здійснюють класифікаційне самонастроювання та самоорганізацію системи;

- томографічні ІС, що відновлюють щільність перерізу об'єкта за його проєкціями;

- ІС, що вирішують проблему шкалювання, яка полягає в побудові для шкал з різними мірами виміру зведеної шкали, координати якої можуть бути обернено відображені на відповідні вихідні шкали;

- сенсорні ІС, що моделюють чуттєві функції людини і КТЗ яких базується на “образному” комп'ютері, наділеному властивостями “технічного зору”, усномовного розпізнавання, розпізнавання пахощів, та інше;

- гібридні ІС, які поєднують різні алгоритми та методи автоматичної класифікації.

До знання-орієнтованих ІС відносять:

- системи, що ґрунтуються на інструктивних знаннях (rulebased reasoning);
- системи, що ґрунтуються на автоматичному доведенні теорем (automatic theorem-proving techniques);
- системи, що ґрунтуються на автоматичному породженні гіпотез (automatic hypothesizing);
- системи, що ґрунтуються на доведенні за аналогією (analogical reasoning);
- об'єктно-орієнтовані інтелектуальні системи (object-oriented intelligent systems);
- об'єктно-логічні інтелектуальні системи, що поєднують окремі переваги об'єктно-орієнтованих систем з системами автоматичного доведення теорем і використовують об'єктно-логічні мови, фреймові логіки (F-logics), логіки транзакції (transaction logics) та інше.

Зрозуміло, що наведена класифікація не є досить повною, оскільки відбувається неперервне розширення номенклатури ІС як за призначенням, так і за принципами функціонування.

## **1.5. Основні принципи проектування інтелектуальних систем**

Функціонування будь-якої ІС розглядається як сукупність трьох аспектів: цільового, функціонального і директивного.

Цільове функціонування – це організація і координування функціонування ІС для досягнення головної мети.

За функціональним аспектом регламентується участь людини у процесах функціонування з урахуванням її потенційних інформаційних і інтелектуальних можливостей.

Директивне функціонування встановлює ієрархічну систему підпорядкування, в якій кожна ланка реалізує координацію безпосередньо підлеглих ланок.

До основних загальносистемних принципів проектування ІС відносять:

- комплексність – побудову ІС, що охоплює всі галузі, періоди та режими її діяльності;
- декомпозиція системи на елементи та функції;
- ієрархічність;
- замкненість циклу застосування ІС. Оскільки система має декілька підзадач (організація, контроль, стимулювання та інше), то необхідно забезпечувати виконання цих підзадач у повному циклі функціонування;
- редукція простору ознак розпізнавання, яка полягає у зменшенні вимірності простору ознак шляхом усунення неінформативних або дезінформативних ознак;
- принцип максимізації інформації, який обґрунтовується екстремальністю сенсорного сприйняття образу, що експериментально доведено вченим-фізіологом П.К. Анохіним [49]. Цей принцип реалізується шляхом введення додаткових інформаційних обмежень, що збільшує різноманітність об'єктів;
- принцип дуальності ІС, який полягає в побудові найпростіших вирішальних правил за умови їх цілеспрямованого уточнення в міру накопичення апостеріорної інформації з метою наближення до безпомилкових за навчальною вибіркою;
- принцип несумісності Л. Заде, який стверджує, що складність системи і точність у першому наближенні обернено пропорційні;
- принцип апіорної недостатності обґрунтування гіпотез (принцип Бернуллі-Лапласа), який стверджує, що за умов апіорної невизначеності доцільно розглядати апіорні гіпотези рівноймовірними, тобто прийняття рішень здійснюється за найгірших у статистичному розумінні умов;
- принцип рандомізації вхідних даних, який дозволяє досліджувати статистичні характеристики процесу;

- принцип зовнішнього доповнення, який обґрунтовує необхідність використання навчальної або контрольної (екзаменаційної) вибірки для підвищення достовірності рішень, що приймаються, та перевірки відповідності технічних характеристик системи заданим;
- принцип обмеженої багатоваріантності рішень;
- принцип неперервного розвитку, за яким система буде так, щоб поява нових апаратно-програмних засобів не приводила до її перебудови;
- принцип модульності, за яким система повинна проектуватися з окремих автономних модулів, модифікація яких не повинна приводити до зниження функціональної ефективності системи.

Зрозуміло, що при проектуванні ІС необхідно дотримуватися відомих принципів системного підходу, об'єктно-орієнтованого проектування та інших загальних принципів системного аналізу.

## 1.6. Властивості інтелектуальних систем

Умовою розв'язання головної задачі проектування є визначення властивостей, які повинні мати ІС, що проектується. Основними властивостями ІС є:

- **стійкість** – це властивість ІС повертатися в попередній функціональний стан після припинення дії збурюючих факторів;
- **керованість** – це існування необмеженого керування, яке може перевести систему із довільного початкового стану в будь-який інший заданий стан за кінцевий інтервал часу;
- **спостережуваність** – це можливість визначення поточного функціонального стану системи шляхом аналізу вихідних змінних при заданому керуючому сигналі за кінцевий період часу.

З точки зору теоретико-інформаційного підходу умовою спостережуваності є виконання нерівності

$$I = H - H(\gamma) > 0,$$

де  $H$  – апіорна (безумовна) ентропія;

$H(\gamma)$  – апостеріорна ентропія, що характеризує залишкову невизначеність після прийняття рішення.

Наприклад, в ІС спостережуваність може бути втрачена за умови невиправданого збільшення або зменшення поля контрольних допусків на ознаки розпізнавання, що має наслідком збіг векторів-реалізацій різних образів. Тобто спостережуваність – це властивість ІС розрізняти вектори-реалізації образів.

**Точність ІС**, яка визначається через точнісні характеристики відповідної системи оцінок рішень. Для двохальтернативної системи оцінок достовірність рішень характеризується повною ймовірністю правильного прийняття рішень:

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

де  $p_1, p_2$  – безумовні ймовірності прийняття основної гіпотези  $\gamma_1$  і альтернативної гіпотези  $\gamma_2$  відповідно;

$D_1, D_2$  – точнісні характеристики: перша та друга достовірності відповідно;

і повною ймовірністю неправильного прийняття рішень:

$$P_f = p_1 \alpha + p_2 \beta,$$

де  $\alpha, \beta$  – точнісні характеристики: помилки першого та другого роду відповідно.

Оскільки гіпотези  $\gamma_1$  і  $\gamma_2$  складають повну групу подій, то має місце  $P_t + P_f = 1$ .

**Надійність ІС.** Це властивість ІС забезпечувати виконання заданих функцій, зберігаючи в часі функціональну ефективність системи в заданих межах, технічного обслуговування, ремонту, супроводження інформаційного та програмного забезпечення, зберігання і транспортування.

**Масогабаритні характеристики** визначаються геометричними та ваговими показниками ІС.

**Стабільність ІС.** Це властивість ІС зберігати незмінними свої характеристики у процесі експлуатації.

**Енерговитрати,** пов'язані з обсягом електроенергії, що споживається ІС при її функціонуванні.

**Вартість** як сукупні витрати на всіх етапах життєвого циклу системи.

Основні етапи життєвого циклу ІС показано на рис.1.4.



Рисунок 1.4 – Схема етапів життєвого циклу системи

На рис.1.5 показано типовий якісний графік зміни показника надійності  $\lambda$  функціонування будь-якої системи в процесі її експлуатації за умови відсутності відновлення системи.




Рисунок 1.5– Графік залежності параметра  $\lambda$  у процесі експлуатації системи

На рис 1.5 показано три часові відрізки функціонування ІС: I – введення системи в експлуатацію; II – період стабільної експлуатації; III – період ”старіння” системи, обумовлений її фізичним зносом. Специфіка ІС полягає в тому, що на першому відрізку невисока функціональна ефективність обумовлена не стільки КТЗ системи, який в основному є відповідною конфігурацією стандартних уніфікованих засобів електронно-обчислювальної і телекомунікаційної техніки, а необхідністю верифікації спеціального програмного забезпечення шляхом його адаптації до реального слабо формалізованого керованого процесу. Для здатних навчатися СППР їх невисока функціональна ефективність на цьому часовому інтервалі пов’язана з необхідністю донавчання системи шляхом розширення потужності алфавіту класів розпізнавання. На третьому часовому відрізку зниження функціональної ефективності ІС в основному пов’язано з дрейфом в просторі та часі багатовимірних реалізацій класів розпізнавання, що обумовлено як зміною умов функціонування системи, так і впливом на керований процес систематичних збурюючих факторів.

## **1.7. Етапи проектування інтелектуальних систем**

Проектування ІС – складний і тривалий процес, який регламентується існуючими в Україні стандартами на створення всіх видів її забезпечення. Послідовність узагальнених етапів проектування ІС показано на рис. 1.6.





Рисунок 1.6 – Схема етапів проектування

Функціональна ефективність ІС, що проектується, значною мірою визначається якістю розроблення **технічного завдання (ТЗ)**, яке здійснюється за результатами маркетингу і включає формування мети, вимог, оцінку можливості технічної реалізації та процедуру узгодження між замовником і виконавцем щодо вимог та характеристик проекту.

Етап **технічної пропозиції** здійснюється з метою визначення принципів реалізації системи, структури, програмного забезпечення та КТЗ, що задовольняють вимогам технічного завдання. На цьому етапі проводиться патентний та інформаційний пошук прототипів та аналогів системи, що проектується.

Етапи **ескізного та технічного** проектування належать до стадії дослідно-конструкторського розроблення ІС.

На етапі **ескізного** проектування розв'язуються задачі аналізу та синтезу, здійснюється детальне опрацювання технічного та інформаційного забезпечення відповідно до ТЗ. Особливістю проектування ІС є необхідність проведення на цьому етапі програмної реалізації розроблених алгоритмів з метою фізичного моделювання системи, що характерно для евристичних методів аналізу і синтезу, тестування та верифікації програмного продукту.

На етапі **технічного (робочого)** проектування на основі ТЗ та результатів ескізного проектування розробляється повний **комплект технічної документації**, який включає:

- 1) електричні схеми;
- 2) графічну документацію у вигляді необхідних креслень та специфікацій до них;
- 3) програмне забезпечення: текст програми, опис програми, специфікація, формуляр, опис застосування, інструкції для оператора, системного програміста та інше;
- 4) текстова документація: загальні технічні умови на систему, частинні технічні умови на комплектуючі, технічний опис, технічні формуляри, паспорти, інструкції на налаштування системи та вузлів, інструкції з експлуатації та інше.

На етапі технічного проектування випускається технічна документація, необхідна для виготовлення дослідної партії системи у заводських умовах, яка включає:

- технологічні інструкції;
- технологічні (маршрутні) карти;
- креслення на технологічне оснащення та необхідне технологічне обладнання.

Невід'ємною частиною проектування ІС на всіх етапах є проведення випробувань системи, які мають таку класифікацію:

- прийомоздавальні випробування, які полягають у встановленні відповідності системи та її складових ТЗ;

- лабораторні випробування, які відбуваються на етапах ескізного та технічного проектування і полягають в оцінці правильності функціонування, точнісних оцінок, стійкості, стабільності, надійності роботи з метою забезпечення технічних умов;
- сумісні випробування, які проводяться проектувальниками та замовниками за програмою лабораторних випробувань, але, як правило, за більш жорстких умов;
- натурні випробування, які проводяться у присутності замовника як завершальний етап перед здачею системи за умов, максимально наближених до заводських.

Таким чином, схему проектування ІС можна представити у вигляді рекурсивної ієрархічної структури, в якій результати одержані при виконанні послідовних етапів повертаються для доопрацювання та уточнення на попередні етапи.

## **1.8. Види забезпечення інтелектуальних систем**

Згідно з існуючим стандартом [46] для здатних навчатися ІС доцільним є виділення таких основних видів її забезпечення, як технічне, інформаційне, програмне та організаційне, структуру яких показано на рис. 1.7.

На ефективність функціонування ІС вирішальний вплив має інформаційне забезпечення, яке характеризується значним обсягом інформаційних операцій, пов'язаних на етапі навчання із структуруванням і нормалізацією даних, керуванням масивами даних, оцінкою ефективності процесу навчання, формуванням інформаційного фонду, прийняттям рішень та інше. Тому у рамках алгоритмічного (евристичного) підходу до моделювання ІС математичне забезпечення, яке включає методи реалізації інформаційних і обчислювальних процедур, спрямованих на формування та перетворення інформаційних структур даних, належить до інформацій-

ного забезпечення. При цьому математичне забезпечення ІС розглядається як технологія оброблення інформації з метою прийняття достовірних рішень.

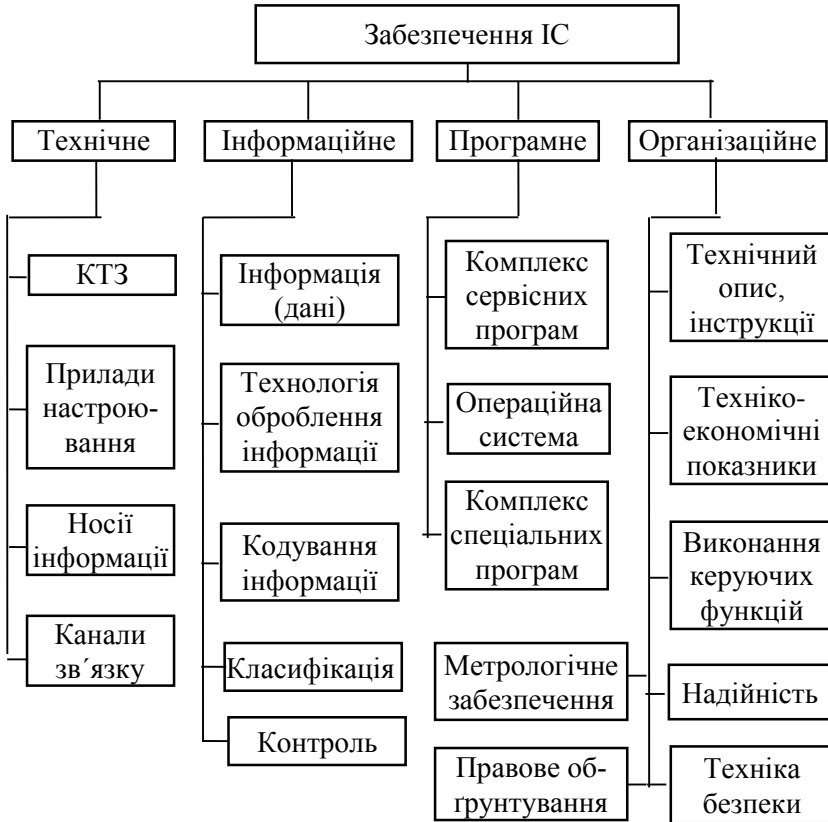


Рисунок 1.7 – Види забезпечення ІС

Розглянемо структуру інформаційного забезпечення ІС, що навчається, основними елементами якого є:

- інформація як атрибут прийняття рішень;
- технологія оброблення інформації як формалізована система обчислювальних і логічних операцій;

- кодування як спосіб інформаційного узгодження елементів КТЗ, стиснення інформації, підвищення її заводо захищеності та безпеки;
- класифікація як процес прийняття рішень;
- контроль як процес встановлення відповідності між функціональним і технічним станами ІС.

Однією із важливих функцій інформаційного забезпечення є класифікаційний аналіз даних. Тому класифікацію доцільно розглядати, як і контроль, окремим елементом інформаційного забезпечення.

Розроблення інформаційного забезпечення ІС складається з послідовного розв'язання таких основних задач:

- організація збору інформації про можливі функціональні стани та режими функціонування ІС;
- формування словника ознак розпізнавання;
- розроблення математичної (інформаційної) моделі ІС для режимів її функціонування;
- конструювання КФЕ навчання ІС і розроблення процедури його обчислення;
- розроблення засобів інформаційних технологій прийняття достовірних рішень за умови апріорної невизначеності;
- дефазифікація нечітких множин на екзамені;
- розроблення методів та алгоритмів перспективного та нормативного прогнозування функціональної ефективності та надійності ІС.

Розв'язок наведених вище задач інформаційного забезпечення дозволяє отримати відповіді на такі важливі питання, як інформаційне відображення функціональних станів ІС і оптимізація просторово-часових параметрів функціонування за КФЕ навчання системи з метою забезпечення на екзамені достовірної класифікації поточного або спрогнозованого її функціонального стану.

## ГЛАВА 2. ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ, ЩО НАВЧАЮТЬСЯ

### 2.1. Формалізована постановка задачі інформаційного синтезу СППР, що навчається

З метою звуження проблеми будемо розглядати тільки найважливішу складову загальної ефективності – функціональну ефективність машинного навчання системи, яка характеризується інформаційною спроможністю системи. Тоді має місце така формалізована постановка задачі інформаційного синтезу ІС, що навчається.

Нехай відомі алфавіт класів розпізнавання  $\{X_m^o \mid m = \overline{1, M}\}$  і багатовимірна навчальна матриця типу «об’єкт-властивість», яка характеризує  $m$ -й функціональний стан СППР – клас розпізнавання  $X_m^o$ :

$$\|y_{m,i}^{(j)}\| = \begin{vmatrix} y_{m,1}^{(1)} & y_{m,2}^{(1)} & \dots & y_{m,1}^{(1)} & \dots & y_{m,N}^{(1)} \\ y_{m,1}^{(2)} & y_{m,2}^{(2)} & \dots & y_{m,1}^{(2)} & \dots & y_{m,N}^{(2)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y_{m,1}^{(j)} & y_{m,2}^{(j)} & \dots & y_{m,1}^{(j)} & \dots & y_{m,N}^{(j)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y_{m,1}^{(n)} & y_{m,2}^{(n)} & \dots & y_{m,1}^{(n)} & \dots & y_{m,N}^{(n)} \end{vmatrix}. \quad (2.1.1)$$

У матриці (2.1.1) рядок є реалізацією образу  $\{y_{m,i}^{(j)} \mid i = \overline{1, N}\}$ , де  $N$  – кількість ознак розпізнавання, а стовпчик матриці – випадкова навчальна вибірка  $\{y_{m,i}^{(j)} \mid j = \overline{1, n}\}$ , де  $n$  – обсяг вибірки. Дано структурований вектор просторово-часових параметрів

функціонування  $g = \langle g_1, \dots, g_\xi, \dots, g_\Xi \rangle$ , які впливають на функціональну ефективність здатної навчатися СППР, з відповідними на них обмеженнями  $R_\xi(g_1, \dots, g_\Xi) \leq 0$ .

В процесі навчання необхідно визначити оптимальні значення параметрів функціонування вектору  $\{g_\xi^*\}$ , які забезпечують максимум інформаційного КФЕ в області визначення його функції:

$$E_m^* = \max_G E_m,$$

де  $E_m$  – КФЕ процесу машинного навчання розпізнавати реалізації класу  $X_m^o$ ;

$G$  – область допустимих значень параметрів функціонування ІС.

При цьому розв'язкою задачі частинного інформаційного синтезу системи може бути визначення оптимального значення, наприклад, параметра  $g_\xi^*$  як

$$g_\xi^* = \arg_{G_\xi} E_m^*,$$

де  $G_\xi$  – область допустимих значень параметра  $g_\xi$ .

Метод інформаційного синтезу СППР, що навчається, повинен відповідати таким основним вимогам:

- прямо та об'єктивно характеризувати функціональну ефективність системи;
- бути в рамках методології аналізу даних об'єктно-орієнтованим методом проектування;
- у рамках детерміновано-статистичного підходу корегувати математичний опис на вході нечіткого регулятора з метою побу-

дови класифікатора, який забезпечує на екзамені повну достовірність рішень, наближену до максимальної асимптотичної, що визначається ефективністю навчання СППР;

- забезпечувати високу функціональну ефективність навчання СППР при прийнятті гіпотез як чіткої, так і нечіткої компактності реалізацій образу, яка допускає перетин класів розпізнавання, що має місце на практиці;

- оптимізувати просторово-часові параметри функціонування СППР, що навчається, за інформаційним КФЕ;

- розв'язувати задачі прогнозування зміни функціональної ефективності та надійності СППР;

- бути універсальним для здатних навчатися СППР різної природи та призначення.

Таким чином, задача інформаційного синтезу СППР, що навчається, полягає в оптимізації за інформаційним КФЕ параметрів функціонування системи, які впливають на її ефективність. Такі параметри можуть задаватися як тактико-технічним завданням на проектування системи (наприклад, показники якості та технологічні параметри навчального процесу, які задають організаційно-методологічні обмеження, інші директивні параметри), так і визначатися безпосередньо розробником СППР при пошуку інформаційно-технічних рішень забезпечення виконання системою поставленої задачі.

## **2.2. Структура і функції адаптивної системи керування навчальним процесом**

Основна особливість інтелектуальних інформаційних технологій для аналізу і синтезу адаптивних СКО у порівнянні з методами їх моделювання на основі традиційних математичних методів полягає у застосуванні ідей і методів інтелектуального аналізу даних (Data Mining) в рамках алгоритмічного (евристичного або кібернетичного) підходу [50]. Згідно з теорією класифікаційного



керування структуру адаптивної системи керування процесом подання та засвоєння знань з окремої навчальної дисципліни можна розглядати як сукупність таких взаємопов'язаних узагальнених компонентів:

об'єкт керування – керований навчальний процес, спрямований на динамічне формування керуючих факторів підвищення рівня знань слухачів;

викладач як керуючий орган навчального процесу;

СППР, побудована на основі машинного навчання та розпізнавання образів, основним призначенням якої є оцінка поточного функціонального стану навчального процесу та формування рекомендацій викладачу для підвищення рівня знань слухачів;

блок первинного оброблення інформації (БПОІ), призначенням якого є формування вхідних даних для оцінки рівня знань слухачів;

блок кінцевого оброблення інформації (БКОІ), основними функціями якого є реалізація технології подання та виведення нових знань, формування та корекція навчального контенту з дисципліни, що викладається, та реалізація індивідуальної навчальної траєкторії підвищення рівня знань слухача.

На рис. 2.1 наведено узагальнену функціональну схему адаптивної АСКНП, до складу якої входить здатна навчатися СППР. В цій схемі для наочності показано основні інформаційні потоки, агреговані функціональні вузли та відповідні робочі змінні системи. Показана на рис. 2.1 структура дозволяє функціонувати системі у режимах машинного навчання СППР та її екзамену, тобто безпосереднього прийняття рішень в робочому режимі.

Робота системи регламентується особою, що приймає рішення (ОПР), функції якої виконує викладач. Викладач згідно з рекомендаціями СППР формує керуючі команди  $\{U\{\gamma_m\} | m = \overline{1, M}\}$ , видає їх в БКОІ для реалізації і через «Модуль формування та реалізації запитів» отримує інформацію про функціональний стан СППР.



тися просто як реалізація) образу, кожна координата якого є одномісним предикатом, що приймає значення «1», якщо значення ознаки знаходиться в полі контрольних допусків, і «0», якщо – не знаходиться.

Розглянемо функціонування СППР у режимі навчання за апріорно класифікованою навчальною матрицею (навчання з “учителем”). При дії на керований навчальний процес випадкових факторів  $f(t)$  і довільних початкових умов формування реалізацій  $\{z^{(j)}, j = \overline{1, n}\}$  успішності суб’єкта навчального процесу – слухача в БПОІ здійснюється згідно з вибраною оціночною функцією формування шкали оцінювання і відображення на неї поточної реалізації  $z^{(j)}$  з метою формування реалізації  $y_m^{(j)}$ , координати якої є нормованими результатами контролю знань, наприклад, оцінки відповідей слухачів на тестові запитання. Крім того, БПОІ здійснює перевірку статистичної стійкості й однорідності навчальних вибірок за відповідними статистичними критеріями [51] та визначення мінімального обсягу  $n_{\min}$  репрезентативної навчальної вибірки, наприклад, за методом, запропонованим в праці [25], тобто виконує функції розвідувального аналізу. На виході БПОІ залежно від заданої потужності  $m$  алфавіту класів розпізнавання формується класифікована нечітка навчальна матриця  $\{y_m^{(j)}\}$  або при  $m = 1$  – некласифікована матриця  $\{y^{(j)}\}$ , які поступають в блок формування векторів розпізнавання (БФВР). У БФВР як результат оцінки допускового контролю формується бінарна навчальна матриця  $\{x_m^{(j)} | j = \overline{1, M}\}$ , яка складається із структурованих випадкових векторів-реалізацій образу  $x_m^{(j)} = \langle x_{m,1}^{(j)}, \dots, x_{m,i}^{(j)}, \dots, x_{m,N}^{(j)} \rangle$ , де  $N$  – кількість ознак розпізнавання. При цьому система контрольних допусків (СКД)  $\{\delta_{n,i} | i = \overline{1, N}\}$  та рівні селекції  $\{\rho_m\}$  координат двійкових еталонних векторів класів розпізнавання поступають в

БФВР із бази даних. На виході БФВР з деяким наперед заданим рівнем довіри в режимі навчання СППР формується багатовимірна бінарна навчальна матриця  $\{x_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n_{\text{min}}}\}$ , яка поступає на вхід блоку «Машинне навчання СППР». З виходу блоку «Машинне навчання СППР» у базу знань надходить вектор  $\{g_\xi^*\}^\Lambda \mid \xi = \overline{1, \Lambda}; \Lambda = \overline{1, \Xi}$  оптимальних параметрів функціонування СППР, які забезпечують максимальне значення інформаційного КФЕ в робочій (допустимій) області визначення його функції. У прогностичному режимі навчання, крім цих параметрів, обчислюються значення одновимірних екстремальних порядкових статистик  $\{S_m^*\}$ , інваріантних до параметрів розподілу ймовірностей реалізацій образу. Випробування, під час якого КФЕ набуває свого максимального значення  $E_m^*$ , є моментом зупинення навчання розпізнавання реалізацій класу  $X_m^o$ . При цьому поточне значення статистики  $S_m$ , яка є членом варіаційного ряду, приймається за екстремальне  $S_m^*$ .

При функціонуванні СППР в режимі екзамену, тобто безпосереднього прийняття рішень, із БФВР в блок «Екзамен СППР» поступає екзаменаційна матриця  $\{x^{(j)}\}^\Lambda$ , де  $\Lambda$  – символ відкритості множини, тобто кількість реалізацій образу може змінюватися від однієї до  $n_{\text{min}}$ , а із бази знань надходять значення оптимальних геометричних параметрів контейнерів класів розпізнавання  $\{g_\xi^*\}$ , які формують вирішальні правила. При цьому в БФВР із бази знань поступають оптимальні значення СКД  $\{\delta_{k,i}^*\}$  і рівнів селекції  $\{\rho_m^{(j)}\}$  координат двійкових еталонних векторів класів розпізнавання, які забезпечують однакові умови формування навчальної та екзаменаційної матриць. З першого виходу блоку «Екзамен

СППР» викладач через «Модуль формування та реалізації запитів» отримує гіпотезу  $\gamma_m$  про належність функціонального стану СППР до класу  $X_m^o$  із сформованого на етапі навчання СППР алфавіту.

При функціонуванні СППР в режимі кластер-аналізу з метою автоматизації формування вхідної класифікованої навчальної матриці із БФВР на перший вхід блоку «Кластер-аналіз» поступає не-класифікована навчальна матриця  $\{x^{(j)}\}$ , яка складається з реалізацій всіх класів розпізнавання із заданого алфавіту. Сформовані на кожному кроці кластеризації вхідних даних класифіковані навчальні матриці  $\{x_m^o\}$  поступають на другий вхід блоку «Машинне навчання СППР», який оцінює за інформаційним КФЕ якість кластеризації та видає на другий вхід блоку «Кластер-аналіз» значення параметрів кластеризації  $\{g_\xi\}$ , що оптимізуються. Таким чином, алгоритм кластер-аналізу вхідних даних розглядається як вкладений в алгоритм навчання СППР.

Для прогнозування зміни функціональної ефективності СППР та визначення моменту її перенавчання на перший вхід блоку прогнозування (БП) надходить поточне значення статистики  $S_{m,n}$ , яка обчислюється блоком «Екзамен СППР» і характеризує статистичні властивості бінарної екзаменаційної матриці класу  $X_m^o$  визначеного за сформованими на етапі машинного навчання СППР вирішальними правилами. На інший вхід БП надходить із бази знань масив статистик  $\{< S_m^* >\}$ , які є інваріантними до законів розподілу ймовірностей і характеризують статистичні властивості класів розпізнавання в моменту першого навчання  $\tau_1$ . Оцінку точності прогнозу природно пов'язувати з достовірністю розпізнавання або із значенням отриманого в процесі навчання СППР в момент

прогнозування  $\tau_r$  критерію  $E_m^*(\tau_r)$ . Результатом БП є параметричний клас розпізнавання  $\{X_m^o(\tau_r)\}$ , який характеризує функціональний стан АСКНП в момент прогнозування  $\tau_r$ , і у випадку виходу статистики  $S_{m,n}$  за межі варіаційного блоку статистики  $S_m^*$  – інформація  $\tau_{nep}$  про необхідність перенавчання СППР.

Таким чином, розглянута структура СППР, що навчається, характеризується широкими функціональними можливостями і дозволяє розв'язувати задачі як її машинного навчання, так і прогностичної класифікації.

### **2.3. Основні положення інформаційно-екстремальної інтелектуальної технології**

Основна ідея машинного навчання у рамках ІЕІ-технології полягає в трансформації апріорного у загальному випадку нечіткого розбиття простору ознак у чітке розбиття класів еквівалентності шляхом ітераційної оптимізації параметрів функціонування ІС. При цьому здійснюється цілеспрямовано пошук глобального максимуму багатоекстремальної функції статистичного інформаційного критерію в робочій (допустимій) області її визначення і одночасного відновлення оптимальних роздільних гіперповерхонь, що будуються в радіальному базисі бінарного простору ознак розпізнавання. Відмінністю методів ІЕІ-технології є те, що трансформація вхідного нечіткого розподілу реалізацій образів в чітке здійснюється в процесі оптимізації системи контрольних допусків, що приводить до цілеспрямованої зміни значень ознак розпізнавання і дозволяє побудувати безпомилкові за багатовимірною навчальною матрицею вирішальні правила. Таким чином, у рамках ІЕІ-технології вдалося поєднати нормалізацію образів, яка полягає у виправленні їх апріорної деформації стосовно еталонного образу,

і безпосередньо етап навчання, на якому будуються вирішальні правила.

З точки зору обчислювальної трудомісткості відновлення у радіальному базисі бінарного просторі  $\Omega$  ознак розпізнавання оптимального формою контейнера класу розпізнавання є одиничний гіперпаралелепіпед. З метою узагальнення та зручності побудови такого контейнера припустимо існування “псевдогіперсфери”, яка описує цей гіперпаралелепіпед, тобто містить усі його вершини. Це дозволяє далі розглядати такі параметри оптимізації контейнера в радіальному базисі простору ознак  $\Omega$ , як еталонний вектор, наприклад,  $x_m \in X_m^o$ , вершина якого визначає геометричний центр контейнера  $K_m^o$ , і радіус псевдосферичного контейнера, який визначається у просторі Хеммінга за формулою

$$d_m = \sum_{i=1}^N (x_{m,i} \oplus \lambda_i), \quad (2.3.1)$$

де  $x_{m,i}$  –  $i$ -та координата еталонного вектору  $x_m$ ;

$\lambda_i$  –  $i$ -та координата деякого вектору  $\lambda$ , вершина якого належить контейнеру  $K_m^o \in X_m^o$ .

Надалі, з метою спрощення, кодова відстань (2.3.1), наприклад, між векторами  $x_m$  і  $\lambda$  буде позначатися у вигляді  $d_m = d(x_m \oplus \lambda)$ .

За ПЕІ-технологією відновлення в радіальному базисі оптимального контейнера, наприклад, для класу  $X_m^o$  здійснюється шляхом його цілеспрямованої послідовної трансформації в гіперсферичний габарит, радіус  $d_m$  якого збільшується на кожному кроці навчання за рекурентною процедурою:

$$d_m(k) = [d_m(k-1) + h | d_m(k) \in G_m^d], \quad (2.3.2)$$

де  $k$  – змінна числа збільшень радіуса контейнера  $K_m^o$ ;

$h$  – крок збільшення радіуса;

$G_m^d$  – область допустимих значень радіуса  $d_m$ .

У загальному випадку при прийнятті гіпотези нечіткої компактності реалізацій образу розбиття простору ознак на класи розпізнавання є нечітким розбиттям  $\tilde{\mathfrak{R}}^{|M|}$ , а елементи цього розбиття є нечіткими класами розпізнавання.

Побудова в процесі оптимізації параметрів навчання безпомилкових за навчальною матрицею вирішальних правил в рамках ІЕІ-технології здійснюється згідно з принципом відкладених рішень Івахненка О. Г. [52] за багатоциклічною ітераційною процедурою пошуку максимального граничного значення КФЕ навчання КДС у вигляді

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_1 \cap G_E} \frac{1}{M} \sum_{m=1}^M E_m \} \dots \} \}, \quad (2.3.3)$$

де  $E_m$  – інформаційний КФЕ навчання СППР розпізнавати реалізації класу  $X_m^o$ ;

$G_{\xi}$  – допустима область значень  $\xi$ -ї ознаки розпізнавання;

$G_E$  – допустима область визначення функції інформаційного КФЕ навчання.

При цьому на алгоритм навчання (2.3.3) згідно з ІЕІ-технологією накладаються такі обмеження:

$$(\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}) [X_m^o \neq \emptyset]; \quad (2.3.4)$$

$$(\exists X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\exists X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset]; \quad (2.3.5)$$



$$\left(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}\right)\left(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}\right)\left[X_k^o \neq X_l^o \rightarrow \text{Ker}X_k^o \cap \text{Ker}X_l^o = \emptyset\right], \quad (2.3.6)$$

де  $\text{Ker} X_k^o, \text{Ker} X_l^o$  ядра класів  $X_k^o$  і  $X_l^o$  відповідно;

$$\bigcup_{X_m^o \in \tilde{\mathfrak{R}}} X_m^o \subseteq \Omega_B; k \neq l; k, l, m = \overline{1, M}. \quad (2.3.7)$$

Нехай класи  $X_k^o$  і  $X_l^o$  є “найближчими сусідами”, тобто мають серед усіх класів найменшу міжцентрову відстань  $d(x_k \oplus x_l)$ , де  $x_k, x_l$  – еталонні вектори відповідних класів. Тоді за ІЕІ-технологією з метою запобігання “поглинання” одним класом ядра іншого класу умови доповнюються предикатним виразом

$$\left(\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}\right)\left(\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}\right)\left[X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& \right. \\ \left. \& (d_l^* < d(x_k \oplus x_l))\right], \quad (2.3.8)$$

де  $d_k^*, d_l^*$  – оптимальні радіуси контейнерів  $K_k^o$  і  $K_l^o$  відповідно.

Глибина циклів оптимізації визначається розмірністю вектора параметрів навчання  $g = \langle g_1, \dots, g_\xi, \dots, g_\Xi \rangle$ . При цьому внутрішні цикли оптимізують фенотипні параметри навчання, які безпосередньо впливають на геометричну форму контейнерів класів розпізнавання. Такими параметрами, наприклад, для гіперсферичних контейнерів класів є їх радіуси. До генотипних відносять параметри навчання, які прямо впливають на розподіл реалізацій класу (наприклад, контрольні допуски на ознаки розпізнавання, рівні селекції координат еталонних двійкових векторів, параметри оптимізації словника ознак, плану навчання, параметри впливу середовища та інше). Послідовна оптимізація кожного із цих параметрів дозволяє збільшувати значення максимуму КФЕ навчання, що

підвищує повну ймовірність правильного прийняття рішень на екзамені. Обов'язковою процедурою алгоритму навчання за ІЕІ-технологією є оптимізація контрольних допусків, величина яких безпосередньо впливає на значення відповідних ознак розпізнавання, а так само і на параметри розподілу реалізацій образу.

Цілеспрямованість оптимізації просторово-часових параметрів функціонування ІС за ІЕІ-технологією здійснюється шляхом визначення тенденції зміни асимптотичних точнісних характеристик процесу навчання.

Таким чином, за умови обґрунтування гіпотези компактності (чіткої або нечіткої) основна ідея навчання за ІЕІ-технологією полягає в послідовній нормалізації вхідного математичного опису СППР шляхом цілеспрямованої трансформації апріорних габаритів розкиду реалізацій образів з метою максимального їх захоплення контейнерами відповідних класів, що відбудовуються в радіальному базисі у процесі навчання. Оптимальні контейнери за ІЕІ-технологією забезпечують максимальну різноманітність між сусідніми класами, міра якої дорівнює максимуму інформаційного КФЕ навчання в робочій області визначення його функції. Оптимальні геометричні параметри контейнерів, одержані в процесі навчання за ІЕІ-технологією, дозволяють на екзамені приймати рішення за відносно простим детермінованим вирішальним правилом, що важливо при реалізації алгоритмів прийняття рішень в реальному темпі часу. При цьому повна достовірність класифікатора наближається до максимальної асимптотичної, яка визначається ефективністю процесу навчання. Досягнення на екзамені асимптотичної достовірності розпізнавання можливо за умови забезпечення однакових характеристик статистичної стійкості та статистичної однорідності навчальної та екзаменаційної матриць.

## 2.4. Вхідний математичний опис

Основною задачею формування вхідного математичного опису ІС є створення багатовимірної навчальної матриці  $\|y_{m,i}^{(j)}\|$ ,  $m = \overline{1, M}; i = \overline{1, N}, j = \overline{1, n}$ . При цьому необхідно розв'язувати такі задачі:

- формування словника ознак та алфавіту класів розпізнавання;
- визначення мінімального обсягу репрезентативної навчальної матриці;
- визначення нормованих допусків на ознаки розпізнавання.

Таким чином, формування вхідного математичного опису АСКНП потребує детального вивчення та аналізу особливостей функціонування джерела інформації, яким, наприклад, у задачах керування може бути розподілений у просторі і часі технологічний процес, космічний корабель та інше.

Вхідний математичний опис подаємо у вигляді теоретико-множинної структури

$$\Delta_B = \langle G, T, \Omega, Z, Y; \Pi, \Phi \rangle, \quad (2.4.1)$$

де

$G$  – простір вхідних сигналів (факторів), які діють на ІС;

$T$  – множина моментів часу зняття інформації;

$\Omega$  – простір ознак розпізнавання;

$Z$  – простір можливих станів ІС;

$Y$  – множина сигналів, які знімаються з виходу БПОІ;

$\Pi: G \times T \times \Omega \rightarrow Z$  – оператор переходів, що відбиває механізм зміни станів ІС під впливом внутрішніх і зовнішніх факторів;

$\Phi: G \times T \times \Omega \times Z \rightarrow Y$  – оператор формування вибіркової множини  $Y$  на вході ІС.

Таким чином, як універсум випробувань  $W$  розглядається декартовий добуток наведених в (2.4.1) множин:

$$W = G \times T \times \Omega \times Z.$$

Словник ознак розпізнавання  $\Sigma^{[N]}$ , де  $N = \text{Card } \Sigma^{[N]}$ , складається з первинних ознак, які є безпосередньо характеристиками процесу, що досліджується, і з вторинних ознак, які є похідними від первинних. Обов'язковою вимогою до словника ознак є його структурованість. На практиці первинними ознаками можуть бути значення параметрів, що зчитуються з датчиків інформації, або експериментальні дані, одержані безпосередньо при дослідженні процесу, включаючи умови його реалізації. Найбільш поширеними вторинними ознаками є різні статистичні характеристики векторів-реалізацій класів  $\{x_{m,i}^{(j)} \mid i = \overline{1, N}\}$ , навчальних вибірок  $\{x_{m,i}^{(j)} \mid j = \overline{1, n}\}$  або всієї навчальної матриці.

Формування алфавіту класів розпізнавання  $\{X_m^o\}$  може здійснюватися як розробником інформаційного забезпечення, так і безпосередньо СППР, що здатна функціонувати в режимі кластер-аналізу вхідних даних. При цьому варто враховувати, що збільшення потужності алфавіту при незмінному словнику ознак розпізнавання суттєво впливає на асимптотичні точнісні характеристики, що характеризують функціональну ефективність навчання системи, через збільшення ступеня перетину класів розпізнавання. Один із найпростіших імовірнісних критеріїв перетину класів для заданого алфавіту може бути подано як відношення помилки другого роду до першої достовірності, яке обчислюється на  $k$ -му кроці ітераційного навчання:

$$\eta = \frac{\beta^{(k)}}{D_1^{(k)}}. \quad (2.4.2)$$

Одним з ефективних шляхів корекції точнісних характеристик при збільшенні потужності алфавіту класів є формування ієрархічних алгоритмів навчання ІС, що дозволяє алфавіт класів розбити на групи меншої потужності і здійснювати навчання для кожної із них, та створення штучної надлишковості словника ознак, наприклад, із застосуванням методів завадозахищеного кодування.

## 2.5. Критерії функціональної ефективності

Центральним питанням інформаційного синтезу ІС є оцінка функціональної ефективності процесу навчання, яка визначає максимальну достовірність рішень, що приймаються на екзамені. Як КФЕ в ІЕІ-технології можуть використовуватися різні критерії, які задовольняють таким властивостям інформаційних мір:

- інформаційна міра є величина дійсна і знакододатна як функція від імовірності;

- кількість інформації для детермінованих змінних ( $p_i = 1$  або  $p_i = 0$ ) дорівнює нулю;

- інформаційна міра має екстремум при ймовірності  $p_i = \frac{1}{m}$ ,

де  $m$  – кількість якісних ознак розпізнавання.

Серед інформаційних мір для оцінки функціональної ефективності СППР, що навчається, перевагу слід віддавати статистичним логарифмічним критеріям, які дозволяють працювати з навчальними вибірками відносно малих обсягів. Серед таких критеріїв найбільшого використання знайшли ентропійні міри [44] та інформаційна міра Кульбака [45].

Подаємо нормований ентропійний КФЕ навчання ІС розпізнавати реалізації класу  $X_m^o$  у вигляді:

$$E_m^{(k)} = \frac{I_m^{(k)}}{I_{\max}^{(k)}} = \frac{H_m^{(k)} - H_m^{(k)}(\gamma)}{H_m^{(k)}}, \quad (2.5.1)$$

де  $I_m^{(k)}$  – кількість умовної інформації, що обробляється на  $k$ -му кроці навчання ІС розпізнавати реалізації класу  $X_m^o$ ;  $I_{\max}^{(k)}$  – максимальна можлива кількість умовної інформації, одержаної на  $k$ -му кроці навчання;  $H_m^{(k)}$  – апіорна (безумовна) ентропія (1.3.5), що існує на  $k$ -му кроці навчання системи розпізнавати реалізації класу  $X_m^o$ ;  $H_m^{(k)}(\gamma)$  – апостеріорна (умовна) ентропія, що характеризує залишкову невизначеність після  $k$ -го кроку навчання системи розпізнавати реалізації класу  $X_m^o$ .

Для двоальтернативної системи оцінок ( $M = 2$ ) і рівномірних гіпотез, що характеризує найбільш важкий у статистичному сенсі випадок прийняття рішень, після відповідної підстановки ентропій (1.3.5) і (1.3.6) у вираз (2.5.1) та заміни відповідних апостеріорних ймовірностей на апіорні за формулою Байєса [43] ентропійний критерій набирає вигляду

$$\begin{aligned} E_m^{(k)} = 1 + \frac{1}{2} & \left( \frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} + \right. \\ & + \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \\ & \left. + \frac{D_{1,m}^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{D_{1,m}^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \right) \end{aligned}$$

$$+ \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)}, \quad (2.5.2)$$

де  $\alpha_m^{(k)}(d)$  – помилка першого роду прийняття рішення на  $k$ -му кроці навчання;

$\beta_m^{(k)}(d)$  – помилка другого роду;

$D_{1,m}^{(k)}(d)$  – перша достовірність;

$D_{2,m}^{(k)}(d)$  – друга достовірність;

$d$  – дистанційна міра, яка визначає радіуси гіперсферичних контейнерів, побудованих в радіальному базисі простору Хеммінга.

Оскільки точнісні характеристики є функціями відстані реалізації образу від вершин еталонних векторів, то критерій (2.5.2) в ІЕІ-технології слід розглядати як нелінійний і взаємно-неоднозначний функціонал від точнісних характеристик, що потребує знаходження в процесі навчання робочої (допустимої) області для його визначення.

Розглянемо модифікацію диференціальної інформаційної міри Кульбака, яка подається як добуток відношення правдоподібності  $\Lambda$  на міру відхилень відповідних розподілів ймовірностей.

У праці [25] розглядається логарифмічне відношення повної ймовірності  $P_{t,m}^{(k)}$  правильного прийняття рішень про належність реалізацій класів  $X_m^o$  і  $X_c^o$  контейнеру  $K_{m,k}^o \in X_m^o$  до повної ймовірності помилкового прийняття рішень  $P_{f,m}^{(k)}$ , яке для двохальтернативної системи оцінок рішень має вигляд

$$\Lambda = \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} = \log_2 \frac{p(\mu_m)p(\gamma_{1,k}/\mu_m) + p(\mu_c)p(\gamma_{2,k}/\mu_c)}{p(\mu_m)p(\gamma_{2,k}/\mu_m) + p(\mu_c)p(\gamma_{1,k}/\mu_c)}, \quad (2.5.3)$$

де  $p(\mu_m)$  – безумовна ймовірність появи реалізації класу  $X_m^o$ ;

$p(\mu_c)$  – безумовна ймовірність появи реалізації найближчого (сусіднього) класу  $X_c^o$ ;

$\gamma_{1,k}$  – гіпотеза про належність контейнеру  $K_{m,k}^o \in X_m^o$  реалізації класу  $X_m^o$ ;

$\gamma_{2,k}$  – альтернативна гіпотеза.

Із урахуванням (2.5.3) при допущенні згідно із принципом Лапласа-Бернуллі, що  $p(\mu_m) = p(\mu_c) = 0,5$ , і після переозначення апіорних умовних ймовірностей відповідними точнісними характеристиками загальна міра Кульбака остаточно набирає вигляду

$$\begin{aligned}
 E_{Km}^{(k)} &= \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} * [P_{t,m}^{(k)} - P_{f,m}^{(k)}] = \\
 &= \left| \begin{array}{l} P_{t,m}^{(k)} = 0,5D_{1,m}^{(k)}(d) + 0,5D_{2,m}^{(k)}(d) \\ P_{f,m}^{(k)} = 0,5\alpha_m^{(k)}(d) + 0,5\beta_m^{(k)}(d) \end{array} \right| = 0,5 \log_2 \left( \frac{D_{1,m}^{(k)}(d) + D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) * \\
 &\quad * [(D_{1,m}^{(k)}(d) + D_{2,m}^{(k)}(d)) - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))] = \\
 &= \log_2 \left( \frac{2 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) * [1 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))]. \quad (2.5.4)
 \end{aligned}$$

Нормовану модифікацію критерію (2.5.4) можна подати у вигляді

$$E_{K,m}^{(k)} = \frac{E_{Km}^{(k)}}{E_{K \max}^{(k)}}, \quad (2.5.5)$$



де

$E_{K_{\max}}^{(k)}$  – значення інформаційного критерію при підстановці  
 $D_{1,m}^{(k)}(d) = D_{2,m}^{(k)}(d) = 1$  і  $\alpha_m^{(k)}(d) = \beta_m^{(k)}(d) = 0$  в формулу (2.5.4).

Нормування критеріїв оптимізації є доцільним при порівняльному аналізі результатів досліджень і при оцінці ступеня близькості реальної СППР, що навчається, до потенційної. Але при оптимізації в процесі машинного навчання параметрів функціонування СППР можна використовувати ненормовані КФЕ як більш простіші. Розглянемо процедуру обчислення модифікації ентропійного КФЕ (3.5.2) для двохальтернативного рішення при рівноймовірних гіпотезах. Оскільки інформаційний критерій є функціоналом від точнісних характеристик, то при репрезентативному обсязі навчальної вибірки необхідно користуватися їх оцінками

$$D_{1,m}^{(k)}(d) = \frac{K_{1,m}^{(k)}}{n_{\min}} ; \quad \alpha_m^{(k)}(d) = \frac{K_{2,m}^{(k)}}{n_{\min}} ; \quad \beta_m^{(k)}(d) = \frac{K_{3,m}^{(k)}}{n_{\min}} ;$$

$$D_{2,m}^{(k)}(d) = \frac{K_{4,m}^{(k)}}{n_{\min}} , \quad (2.5.6)$$

де  $K_{1,m}^{(k)}$  – кількість подій, які означають належність реалізацій образу контейнеру  $K_{1,m}^o$ , якщо дійсно  $\{x_1^{(j)}\} \in X_1^o$  ;

$K_{2,m}^{(k)}$  – кількість подій, які означають неналежність реалізацій контейнеру  $K_{1,m}^o$ , якщо дійсно  $\{x_1^{(j)}\} \in X_1^o$  ;

$K_{3,m}^{(k)}$  – кількість подій, які означають належність реалізацій контейнеру  $K_{1,m}^o$ , якщо вони насправді належать класу  $X_2^o$  ;

$K_{4,m}^{(k)}$  – кількість подій, які означають неналежність реалізацій контейнеру  $K_{1,m}^o$ , якщо вони насправді належать класу  $X_2^o$  ;

$n_{\min}$  – мінімальний обсяг репрезентативної навчальної вибірки.

Після підстановки відповідних оцінок точнісних характеристик (2.5.6) у вираз (2.5.2) одержимо робочу формулу для обчислення в рамках ІЕІ-технології ентропійного інформаційного КФЕ навчання СППР розпізнаванню реалізацій класу  $X_1^o$

$$E_{1,m}^{(k)} = 1 + \frac{1}{2} \left( \frac{K_{1,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} \log_2 \frac{K_{1,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} + \frac{K_{2,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} \log_2 \frac{K_{2,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} + \frac{K_{3,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} \log_2 \frac{K_{3,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} + \frac{K_{4,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} \log_2 \frac{K_{4,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} \right). \quad (2.5.7)$$

Робоча модифікація критерію Кульбака після відповідної підстановки оцінок (2.5.6) у вираз (2.5.4) приймає вигляд

$$E = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_2^{(k)} + K_3^{(k)}]}{[K_2^{(k)} + K_3^{(k)}] + 10^{-r}} \right\} [n - (K_2^{(k)} + K_3^{(k)})], \quad (2.5.8)$$

де  $r$  – число цифр у мантисі значення критерію  $E_m^{(k)}$ .

Розглянемо схему обчислення коефіцієнтів  $K_2^{(k)}$  і  $K_3^{(k)}$  у формулі (2.5.8). На рис. 2.2 показано структуру навчальної матриці, яка послідовно складається з векторів реалізацій  $\{x_1^{(j)}\} \in X_1^o$  і  $\{x_2^{(j)}\} \in X_2^o$  відповідно.




Рисунок 2.2 – Структура навчальної матриці

Алгоритм обчислення коефіцієнтів  $K_2^{(k)}$  і  $K_3^{(k)}$  у формулі (2.5.7) має такий предикатний вигляд:

$$\begin{aligned}
 & (\forall X_1^o \in \mathfrak{R}^{|\Lambda|})(\forall X_2^o \in \mathfrak{R}^{|\Lambda|})[\text{if } x_1^{(j)} \in X_1 \text{ then} \\
 & \quad K_1(j) := K_1(j-1) + 1 \text{ else } K_2(j-1) + 1]; \\
 & (\forall X_1^o \in \mathfrak{R}^{|\Lambda|})(\forall X_2^o \in \mathfrak{R}^{|\Lambda|})[\text{if } x_2^{(j)} \in X_1 \text{ then} \\
 & \quad K_3(j) := K_3(j-1) + 1 \text{ else } K_4(j) := K_4(j-1) + 1].
 \end{aligned}$$

В працях [25,53] запропоновано модифікацію КФЕ за Кульбаком для трьохальтернативної системи оцінок рішень і проаналізовано доцільність його використання у порівнянні з двоохальтернативним.

Для визначення залежності міри Кульбака від точнісних характеристик при трьохальтернативних рішеннях введемо основну гіпотезу  $\gamma_1$  про належність діагностичної ознаки показнику «НОРМА», гіпотезу  $\gamma_2$  про належність діагностичної ознаки показнику «МЕНЬШЕ НОРМЫ» та гіпотезу  $\gamma_3$  про належність діагностичної ознаки показнику «БОЛЬШЕ НОРМЫ». Відповідно позначимо їх апостеріорні гіпотези:  $\mu_1$  – значення ознаки дійсно знаходиться у полі допусків  $\delta$ ,  $\mu_2$  – лівіше поля допусків  $\delta$  та  $\mu_3$  – правіше поле допусків  $\delta$ . На рис. 2.3. показано можливі варіанти прийняття рішень при трьох альтернативній системі оцінок рішень, що приймаються. Тут прийнято такі позначення:  $x$  – апріорне значення ознаки, що вимірюється;  $z$  – апостеріорне (дійсне) значення ознаки;  $\delta$  – поле допусків. При цьому приймаються три апріорні гіпотези: гіпотеза  $\gamma_1$  – значення  $x$  ознаки знаходиться в полі допусків  $\delta$ ; гіпотеза  $\gamma_2$  – значення  $x$  ознаки знаходиться

зліва від поля допусків  $\delta$  і гіпотеза  $\gamma_3$  – значення  $x$  ознаки знаходиться справа від поля допусків  $\delta$ .

Згідно з рис. 2.3 трьохальтернативні рішення оцінюються дев'ятьма точнісними характеристиками:

- перша достовірність  $D_{1,m}^{(k)} = p(\gamma_1 / \mu_1)$  (рис. 2.3а);
- перша помилка першого роду  $\alpha_{1,m}^{(k)} = p(\gamma_2 / \mu_1)$  (рис. 2.3б);
- друга помилка першого роду  $\alpha_{2,m}^{(k)} = p(\gamma_3 / \mu_1)$  (рис. 2.3в);
- друга достовірність  $D_{2,m}^{(k)} = p(\gamma_2 / \mu_2)$  (рис. 2.3г);
- перша помилка другого роду  $\beta_{1,m}^{(k)} = p(\gamma_1 / \mu_2)$  (рис. 2.3д);
- друга помилка другого роду  $\beta_{2,m}^{(k)} = p(\gamma_3 / \mu_2)$  (рис. 2.3е);
- третя достовірність  $D_{3,m}^{(k)} = p(\gamma_3 / \mu_3)$  (рис. 2.3є);
- перша помилка третього роду  $\sigma_{1,m}^{(k)} = p(\gamma_1 / \mu_3)$  (рис. 2.3ж);
- друга помилка третього роду  $\sigma_{2,m}^{(k)} = p(\gamma_2 / \mu_3)$  (рис. 2.3з).

Введемо такі припущення:

- система контрольних допусків на діагностичні ознаки є симетричною;
- точнісні характеристики  $\beta_{2,m}^{(k)}$  та  $\sigma_{2,m}^{(k)}$  є малоймовірними, тому ними можна знехтувати.

З метою спрощення наступних перетворень прийнемо для симетричного двобічного поля допусків такі співвідношення

$$\alpha_m^{(k)} = \alpha_{1,m}^{(k)} = \alpha_{2,m}^{(k)}; \beta_m^{(k)} = \beta_{1,m}^{(k)}; \sigma_m^{(k)} = \sigma_{1,m}^{(k)}. \quad (2.5.9)$$

З урахуванням припущень (2.5.11) при трьохальтернативних рішеннях повні ймовірності  $P_{t,m}^{(k)}$  і  $P_{f,m}^{(k)}$  відповідно дорівнюють

$$\begin{aligned} P_{t,m}^{(k)} &= p(\mu_1)D_{1,m}^{(k)} + p(\mu_2)D_{2,m}^{(k)} + p(\mu_3)D_{3,m}^{(k)}; \\ P_{f,m}^{(k)} &= p(\mu_1)\alpha_m^{(k)} + p(\mu_2)\beta_m^{(k)} + p(\mu_3)\sigma_m^{(k)}. \end{aligned} \quad (2.5.10)$$




Рисунок 2.3 – Варіанти оцінки трьохальтернативних рішень

Згідно з принципом Бернуллі-Лапласа прийнемо гіпотези рівномірними

$$p(\mu_1) = p(\mu_2) = p(\mu_3) = \frac{1}{3}; \quad (2.5.11)$$

Після підстановки співвідношень (2.5.10) та умови (2.5.11) в формулу (2.5.8) отримаємо

$$E_m^{(k)} = \frac{1}{3} \{ [D_{1,m}^{(k)} + D_{2,m}^{(k)} + D_{3,m}^{(k)}] - [\alpha_m^{(k)} + \beta_m^{(k)} + \sigma_m^{(k)}] \} * \log_2 \frac{D_{1,m}^{(k)} + D_{2,m}^{(k)} + D_{3,m}^{(k)}}{D_{1,m}^{(k)} + D_{2,m}^{(k)} + D_{3,m}^{(k)}}. \quad (2.5.12)$$

Враховуючи прийняті вище припущення мають місце наступні співвідношення між точнісними характеристиками для кожної із трьох груп подій

$$D_{1,m}^{(k)} + 2\alpha_m^{(k)} = 1; \quad D_{2,m}^{(k)} + \beta_m^{(k)} + \sigma_m^{(k)}; \quad D_{3,m}^{(k)} + \beta_m^{(k)} + \sigma_m^{(k)}. \quad (2.5.13)$$

З урахуванням співвідношень (2.5.13) представимо формулу (2.5.11) у вигляді

$$E_m^{(k)} = \frac{1}{3} \{ D_{1,m}^{(k)} + 1 - 2[\beta_m^{(k)} + \sigma_m^{(k)}] \} * \log_2 \frac{2D_{1,m}^{(k)} + 4 - 4[\beta_m^{(k)} + \sigma_m^{(k)}]}{1 - D_{1,m}^{(k)} + 2[\beta_m^{(k)} + \sigma_m^{(k)}]}. \quad (2.5.14)$$

Таким чином, одержані модифікації інформаційних критеріїв оптимізації параметрів навчання для двохальтернативних і трьохальтернативних рішень є функціоналами як від точнісних характеристик рішень, що приймаються, так і від дистанційних критеріїв, тобто їх можна розглядати як узагальнення відомих статистичних і детермінованих (дистанційних) критеріїв оптимізації параметрів функціонування СППР.

## 2.6. Базовий інформаційно-екстремальний алгоритм навчання СППР

Базовий інформаційно-екстремальний алгоритм оптимізації просторово-часових параметрів функціонування СППР реалізується у внутрішньому циклі структурованої ітераційної процедури навчання, що й обумовило його назву. Призначенням базового алгоритму навчання є:

- обчислення інформаційного КФЕ навчання ІС;
- пошук глобального максимуму КФЕ у робочій (допустимій) області визначення його функції;
- оптимізація геометричних параметрів контейнерів класів розпізнавання.

Розглянемо категорійну модель навчання СППР за базовим алгоритмом у вигляді діаграми відображення множин. При обґрунтуванні гіпотези нечіткої компактності має місце нечітке розбиття  $\tilde{\mathfrak{R}}^{|M|} \subset \Omega$ , яке в рамках ІЕІ-технології відповідає умовам (2.3.4) – (2.3.8). Введемо оператор  $\theta$  нечіткої факторизації простору ознак:  $\theta: Y \rightarrow \tilde{\mathfrak{R}}^{|M|}$  і оператор класифікації  $\psi: \tilde{\mathfrak{R}}^{|M|} \rightarrow I^{|l|}$ , який перевіряє основну статистичну гіпотезу про належність реалізацій  $\{x_m^{(j)} | j = \overline{1, n}\}$  нечіткому класу  $X_m^o$ . Тут  $l$  – кількість статистичних гіпотез. Оператор  $\gamma: I^{|l|} \rightarrow \mathfrak{F}^{|q|}$  шляхом оцінки статистичних гіпотез формує множину точнісних характеристик  $\mathfrak{F}^{|q|}$ , де  $q=l^2$  – кількість точнісних характеристик. Оператор  $\varphi: \mathfrak{F}^{|q|} \rightarrow E$  обчислює множину значень інформаційного КФЕ, який є функціоналом точнісних характеристик. Контур оптимізації геометричних параметрів нечіткого розбиття  $\tilde{\mathfrak{R}}^{|M|}$  шляхом пошуку максимуму КФЕ навчання розпізнаванню реалізацій класу  $X_m^o$  замикається оператором  $r: E \rightarrow \tilde{\mathfrak{R}}^{|M|}$ .

Категорійну модель функціонування СППР в режимі її навчання за базовим алгоритмом показано на рис. 2.4 у вигляді структурної діаграми відображень множин




Рисунок 2.4 – Категорійна модель навчання СППР за базовим алгоритмом

На рис. 2.4 показано контур операторів, які оптимізують геометричні параметри контейнерів класів розпізнавання розбиття  $\tilde{\mathcal{R}}^{/M/}$ , що відновлюються в радіальному базисі простору ознак розпізнавання.




Рисунок 2.5 – Контур операторів оптимізації контейнерів класів розпізнавання

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

Вхідною інформацією для навчання за базовим алгоритмом є дійсний в загальному випадку масив реалізацій образу  $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$ ; система полів контрольних допусків  $\{\delta_{K,i}\}$  на ознаки розпізнавання і рівні селекції  $\{\rho_m\}$  координат еталонних векторів-реалізацій, які за замовчуванням дорівнюють



0,5 для всіх класів розпізнавання. Розглянемо етапи реалізації алгоритму:

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

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_{K,i}; \\ 0, & \text{if } y_{m,i}^{(j)} \notin \delta_{K,i}; \end{cases} \quad (2.6.1)$$

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

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m; \\ 0, & \text{if } \textit{else}, \end{cases} \quad (2.6.2)$$

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

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

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

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

в) для кожного еталонного вектора в його рядку матриці кодів відстаней знаходиться мінімальний елемент, індекс якого визначає найближчий йому вектор;

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

4. Оптимізація кодової відстані  $d_m$  відбувається за рекурентною процедурою (2.3.3). При цьому  $E_m(0) = 0$ .

5. Процедура закінчується при знаходженні максимуму КФЕ в робочій області його визначення:  $E_m^* = \max_{\{d\}} E_m$ , де  $\{d\} = \{d_1, \dots, d_k, \dots, d_{\max}\} \in [0; d(x_m \oplus x_l) - 1]$  – множина радіусів концентрованих гіперсфер, центр яких визначається вершиною еталонного вектора  $x_m \in X_m^o$ . При цьому множина  $\{d\}$  є так само множиною кроків навчання ІС.

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

$$d_m^* = \arg \max_{\{G_E \cap G_d\}} E_m^*, \quad (2.6.3)$$

де  $G_E$  – робоча (допустима) область визначення інформаційного критерію  $E_m$ ;

$G_d$  – допустима область значень радіусів контейнерів класів розпізнавання, які відновлюються в процесі навчання в радіальному базисі простору ознак.

Параметри навчання СППР за базовим алгоритмом – оптимальні кодові відстані  $\{d_m^*\}$  і оптимальні еталонні вектори-реалізації  $\{x_m^*\}$  для заданого алфавіту  $\{X_m^o\}$  є обов’язковими вхідними даними для функціонування СППР в режимі екзамену, тобто безпосереднього прийняття рішень.

Таким чином, основною функцією базового алгоритму навчання СППР у рамках ІЕІ-технології є обчислення на кожному кроці навчання інформаційного КФЕ і організація пошуку його глобального максимуму в робочій області визначення функції критерію з метою визначення оптимальних геометричних параметрів розбиття простору ознак на класи розпізнавання.

## 2.7. Оптимізація контрольних допусків на ознаки розпізнавання

Система контрольних допусків (СКД) на значення ознак розпізнавання прямо впливає на геометричні параметри контейнерів класів розпізнавання, а таким чином і на асимптотичні точнісні характеристики навчання СППР. Тому питання оптимізації контрольних допусків на ознаки розпізнавання в методах ІЕІ-технології набуває важливого значення при інформаційному синтезі СППР, що навчається. Розглянемо підхід до оптимізації СКД на ознаки розпізнавання в рамках ІЕІ-технології [9,25].

На рис. 2.6 показано симетричне (двобічне) поле допусків на значення  $i$ -ї ознаки  $y_{m,i}^{(j)}$ ,  $i = \overline{1, N}$ .




Рисунок 2.6 – Симетричне поле допусків

На рис. 2.6 прийнято такі позначення:  $A_0$  – математичне сподівання ознаки  $y_i$ ;  $A_{H,i}$ ,  $A_{B,i}$  – нижній і верхній нормовані допуски відповідно;  $A_{HK,i}$ ,  $A_{BK,i}$  – нижній і верхній контрольні допуски відповідно;  $\delta_{H,i}$  – нормоване поле допусків;  $\delta_{K,i}$  – контрольне поле допусків;  $\delta$  – параметр поля контрольних допусків, що оптимізується.

Діаграму відображень множин у процесі навчання СППР з оптимізацією СКД на ознаки розпізнавання з урахуванням діаграми (рис. 2.4) показано на рис. 2.7.




Рисунок 2.7 – Категорійна модель навчання СППР з оптимізацією контрольних допусків

У діаграмі (рис. 2.7) терм-множина  $D$  складається із допустимих значень СКД, а контур операторів, показаний на рис. 2.8, оптимізує контрольні допуски на ознаки розпізнавання.



Рисунок 2.8 – Контур операторів оптимізації контрольних допусків на ознаки розпізнавання

Задача оптимізації контрольних допусків на ознаки розпізнавання є частинною задачею загального алгоритму навчання СППР

(2.3.2), яка розв'язується за структурованою двохциклічною процедурою пошуку глобального максимуму інформаційного КФЕ в робочій області визначення його функції

$$\delta_K^* = \arg < \max_{G_\delta} \{ \max_{G_E \cap G_d} \frac{1}{M} \sum_{m=1}^M E_m \} >, \quad (2.7.2)$$

де  $G_\delta$  – область допустимих значень контрольних допусків на ознаки розпізнавання..

В рамках ІЕІ-технології застосовуються в основному два типи інформаційно-екстремальних алгоритмів оптимізації контрольних допусків:

- паралельний алгоритм, при якому контрольні допуски оптимізуються для всіх ознак одночасно;
- послідовний алгоритм, при якому контрольні допуски оптимізуються послідовно для кожної ознаки розпізнавання при фіксованих (стартових) значеннях інших ознак;

Перевагою паралельного алгоритму оптимізації СКД є висока оперативність реалізації алгоритму, але він не дозволяє одержати точне значення глобального максимуму КФЕ в робочій області визначення його функції. Тому екстремальні значення параметрів функціонування ІС, одержані в процесі їх оптимізації за паралельним алгоритмом, є квазіоптимальними. Алгоритми послідовної оптимізації СКД дозволяють обчислювати точні значення глобального максимуму КФЕ в робочій області, але характеризуються не високою оперативністю. З метою поєднання переваг цих алгоритмів оптимізацію СКД на ознаки розпізнавання доцільно здійснювати на практиці за паралельно-послідовним алгоритмом. При цьому реалізація паралельного алгоритму дозволяє визначити стартові контрольні допуски, які є вхідними для алгоритму послідовної оптимізації. Це дозволяє підвищити оперативність послідовного алгоритму, оскільки стартові квазіоптимальні контрольні допуски вже знаходяться в робочій області визначення функції КФЕ.

Алгоритм ітераційної послідовності оптимізації контрольних допусків, збіжність якого доведено в праці [25], полягає у наближенні глобального максимуму інформаційного критерію оптимізації до граничного його значення в допустимій області значень функції критерію і має таку структуру [54]:

$$\{\delta_i^*\} = \arg \langle \otimes_{l=1}^L \{ \max_{G_\delta} \frac{1}{M} \sum_{m=1}^M \{ \max_{G_E \cap G_d} E_m \} \} \rangle, \quad i = \overline{1, N}, \quad (2.7.3)$$

де  $\otimes$  – символ операції повторення ітераційних циклів пошуку глобального максимуму інформаційного КФЕ в робочій області визначення його значення функції;

$G_{\delta_i}$  – область допустимих значень параметра поля контрольних допусків для  $i$ -ї ознаки;

$L$  – кількість прогонів ітераційної процедури послідовної оптимізації контрольних допусків;

Розглянемо кроки реалізації алгоритму паралельної оптимізації, що оптимізує параметр  $\delta$  поля контрольних допусків для всіх ознак розпізнавання одночасно. Вхідні дані: масив реалізацій образів – навчальна матриця  $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n_m}\}$ ; нижні  $\{A_{H,i} \mid i = \overline{1, N}\}$  та верхні  $\{A_{B,i} \mid i = \overline{1, N}\}$  нормовані допуски на ознаки розпізнавання, які визначають область значень їх контрольних допусків.

1. Ініціалізація лічильника кроків зміни параметра поля контрольних допусків на ознаки розпізнавання  $\delta := 0$ .

2. Інкремент лічильника:  $\delta := \delta + 1$ .

3. Обчислення нижніх та верхніх контрольних допусків для всіх ознак розпізнавання при  $\delta_i := \delta, i = \overline{1, N}$ :

$$A_{HK,i} = \begin{cases} y_{1,i} \left( 1 - \frac{\delta_i}{\delta_{\max}} \right), & \text{if } y_{1,i} \left( 1 - \frac{\delta_i}{\delta_{\max}} \right) \leq A_{H,i}; \\ A_{H,i}, & \text{if else;} \end{cases} \quad (2.7.4)$$

$$A_{BK,i} = \begin{cases} y_{1,i} \left( 1 + \frac{\delta_i}{\delta_{\max}} \right), & \text{if } y_{1,i} \left( 1 + \frac{\delta_i}{\delta_{\max}} \right) \geq A_{B,i}; \\ A_{B,i}, & \text{if else.} \end{cases} \quad (2.7.5)$$

4. Реалізується базовий алгоритм навчання (2.6.3).

5. Порівняння: якщо  $\overline{E}[\delta] \geq \overline{E}[\delta - 1]$ , то запам'ятовується екстремальне значення  $\delta_i^* := \delta$ ,  $i = \overline{1, N}$  і глобальний максимум КФЕ  $\overline{E}^* := \overline{E}[\delta]$ .

6. Порівняння: якщо  $\delta < \delta_{\max}$ , то перехід на крок 3, інакше – крок 7.

7. ЗУПИН.

Визначені на етапі паралельної оптимізації квазіоптимальні контрольні допуски на ознаки розпізнавання приймаються як стартові для алгоритму їх послідовної оптимізації за процедурою (2.1.3). При цьому схема алгоритму послідовної оптимізації контрольних допусків така:

1. Ініціалізація лічильника прогонів процедури оптимізації параметрів навчання:  $l := 0$ .

2. Для стартової системи допусків обчислюється за базовим алгоритмом навчання (2.6.3) значення усередненого КФЕ  $\overline{E}^{(l)}$ .

3. Інкремент лічильника прогонів:  $l = l + 1$ .

4. Ініціалізація лічильника ознак розпізнавання:  $i := 0$ .

5. Інкремент лічильника ознак розпізнавання:  $i = i + 1$ .

6. Визначення екстремального значення параметра поля контрольних допусків  $\widehat{\delta}_i^{(l)} := \arg \max_{G_{\delta_i}} \delta_i^{(l)}$ .

7. Порівняння: якщо  $i < N$ , то виконується крок 5, інакше – крок 9.

8. Порівняння: якщо  $\left| \overline{E}^{(l-1)} - \overline{E}^{(l)} \right| \leq \varepsilon$ , де  $\varepsilon$  – будь-яке мале позитивне число, то виконується крок 9, інакше – крок 3.

9. Визначення оптимальної системи контрольних допусків на ознаки розпізнавання  $\{\delta_i^*\} := \{\widehat{\delta}_i^{(l)}\}$ .

10. ЗУПИН.

Таким чином, оскільки використання базового алгоритму навчання через використання неоптимальних контрольних допусків, як правило, не забезпечує побудови безпомилкових за навчальною матрицею вирішальних правил, то обов'язковою процедурою інформаційно-екстремального алгоритму навчання СППР є оптимізація СКД на ознаки розпізнавання. У випадку, якщо оптимізація контрольних допусків не розв'язує основну задачу навчання, тоді згідно з принципом відкладених рішень Івахненка О. Г. необхідно здійснювати оптимізацію інших параметрів функціонування СППР, які впливають на її ефективність.

## **2.8. Оптимізація рівнів селекції координат двійкових еталонних векторів класів розпізнавання**

У загальному випадку адаптація вхідного математичного опису здатної навчатися СППР з метою побудови безпомилкових за навчальною матрицею вирішальних правил полягає в реалізації багатоциклічної ітераційної процедури (2.3.3) оптимізації за інформаційним КФЕ просторово-часових параметрів функціонування, які впливають на функціональну ефективність СППР, що навча-



ється. Серед таких параметрів важливу роль відіграє рівень селекції (квантування за рівнем) координат двійкових еталонних векторів-реалізацій, образів, які визначають геометричні центри контейнерів класів розпізнавання.

Рівнем селекції координат еталонного двійкового вектору називається рівень квантування дискрет полігона емпіричних частот потрапляння значень ознак розпізнавання у свої поля контрольних допусків.

Полігон будується для кожного класу так: по осі абсцис відкладаються номери ознак розпізнавання в еталонному векторі  $x_m$ , а по осі ординат – відносні частоти  $\omega_{m,i} = n_i/n$ , де  $n_i$  – кількість випробувань, при яких значення  $i$ -ї ознаки знаходиться в своєму полі контрольних допусків.

Оптимізація рівнів селекції у рамках ІЕІ-технології дозволяє розв'язувати такі важливі для підвищення асимптотичної достовірності класифікатора задачі:

- центрування контейнерів класів розпізнавання, тобто наближення геометричних центрів контейнерів класів розпізнавання до їх емпіричних центрів розсіювання реалізацій образу;
- максимізація середньої міжкласової кодової відстані для заданого алфавіту у відповідності до максимально-дистанційного принципу теорії розпізнавання образів.

Параметр  $\rho_m$  пов'язаний з інформативністю ознак розпізнавання. Наприклад, якщо у процесі навчання знайдено оптимальне значення  $\rho_m^* < 0,5$ , то це свідчить про виявлення принаймні однієї інформативної ознаки, латентність якої полягала саме в її малій частоті появи. Якщо знайдено  $\rho_m^* > 0,5$ , то це свідчить про негативний вплив на прийняття рішень принаймні однієї “заважаючої” ознаки. За замовчуванням рівень селекції дорівнює  $\rho = 0,5$ .

Оптимізацію рівнів селекції координат двійкових еталонних векторів доцільно здійснювати за паралельно-послідовним алгоритмом, що дозволяє за алгоритмом паралельної оптимізації визначити стартову квазіоптимальну систему рівнів селекції, а за послідовним – оптимальні рівні селекції для всіх координат еталонних векторів-реалізацій образу. При цьому за умови обґрунтування у загальному випадку нечіткої гіпотези компактності реалізацій образу оптимізацію рівнів селекції  $\rho_m$  будемо здійснювати на базі інформаційно-екстремального алгоритму навчання.

Спочатку розглянемо алгоритм оптимізації рівнів селекції координат двійкової реалізації найбільш бажаного для ОПП першого класу  $X_1^o$ , оскільки для інших класів система контрольних допусків на ознаки розпізнавання залишається незмінною.

Нехай дано алфавіт класів розпізнавання  $\{X_m^o \mid m = \overline{1, M}\}$  і навчальну матрицю  $\|y_{m,i}^{(j)}\|$ ,  $i = \overline{1, N}$ ,  $j = \overline{1, n}$ . Задано структурований вектор параметрів функціонування системи, що навчається розпізнавати реалізації класу  $X_1^o$ :  $g = \langle x_1, d_1, \delta, \rho_1 \rangle$ , який складається з еталонної реалізації  $x_1$  класу  $X_1^o$ , геометричного параметра  $d_1$  – кодової відстані гіперповерхні контейнера  $K_1^o$  класу  $X_1^o$  від вершини еталонної реалізації  $x_1 \in X_1^o$ . Задано допустимі області значень відповідних параметрів:  $x_1 \in \Omega_B^{|N|}$ , де  $\Omega_B^{|N|}$  – бінарний простір ознак потужності  $N$ ;  $d_1 \in [0; d(x_1 \oplus x_c) - 1]$ , де  $x_c$  – еталонна реалізація сусіднього (найближчого до  $X_1^o$ ) класу  $X_c^o$ , параметра контрольного поля допусків  $\delta \in [0; \delta_H / 2]$ , де  $\delta_H$  – нормоване (експлуатаційне) поле допусків на ознаки розпізнавання і рівень селекції  $\rho_1$  координат еталонної реалізації  $x_1$ ,  $\rho_1 \in [0; 1]$ .

Необхідно на етапі навчання за апріорно класифікованими реалізаціями нечітких образів побудувати оптимальне в інформаційному розумінні чітке розбиття  $\mathfrak{R}^{|M|}$  дискретного простору ознак  $\Omega_B$  на  $M$  класів розпізнавання шляхом ітераційної оптимізації координат вектора параметрів функціонування  $g$  за умови, що значення усередненого за алфавітом  $\{X_m^o\}$  інформаційного КФЕ навчання СППР набуває глобального максимуму в робочій (допустимій) області визначення його функції.

Діаграму відображень множин, що застосовуються при оптимізації рівнів селекції координат еталонних векторів у процесі навчання СППР, показано на рис. 2.9.




Рисунок 2.9 – Категорійна модель навчання СППР з оптимізацією рівнів селекції

На рис. 2.10 показано оператори контура оптимізації рівня селекції координат двійкових еталонних векторів-реалізацій образів.




Рисунок 2.10 – Оператори контура оптимізації рівня селекції координат двійкових еталонних векторів

Оптимальний рівень селекції  $\rho_1$  координат еталонного вектора  $x_1 \in X_1^o$  визначається у результаті реалізації багатocyклічної ітераційної процедури

$$\rho_1^* = \arg \max_{G_\rho} \{ \max_{G_\delta} \{ \max_{G_E \cup G_d} \bar{E}^* \} \} , \quad (2.8.1)$$

де  $G_\rho$  – область допустимих значень параметра  $\rho_1$ .

Оптимальні рівні селекції координат еталонних векторів інших класів визначаються за процедурою максимізації інформаційного КФЕ навчання СППР розпізнавати реалізації класу  $X_m^o$ ,  $m = \overline{2, \Lambda}$ :

$$\rho_m^* = \arg \max_{G_\rho} \{ \max_{G_\Omega \cup G_d} E_m \} . \quad (2.8.2)$$

Таким чином, процедура (2.8.2) на відміну від процедури (2.8.1) не оптимізує контрольні допуски на ознаки розпізнавання, оскільки вони визначаються тільки для пріоритетного для ОПР класу  $X_1^o$ . При цьому внутрішні цикли алгоритмів (2.8.1) і (2.8.2) реалізуються послідовно операторами, які утворюють базовий контур (рис. 2.5). Для алгоритму (2.8.1) наступний цикл реалізується послідовністю операторів контуру (рис. 2.8) і зовнішній цикл – послідовністю операторів контуру оптимізації рівнів селекції (рис. 2.10).

Розглянемо детальніше схему алгоритму послідовної оптимізації рівнів селекції:

1. Обнуляється лічильник ознак розпізнавання:  $i:=0$ .
2.  $i:=i+1$ .

3. Встановлюються значення для верхнього  $\rho v$  та нижнього  $\rho n$  рівнів селекції відповідно.
4. Встановлюється крок зміни рівня селекції  $\rho c$ .
5. Обнуляється лічильник кроків оптимізації рівня селекції:  
 $z := 0$ .
6.  $z := z + 1$ .
7. Задається значення поточного рівня селекції:  $\rho z := \rho n + \rho c$ .
8. Визначається, наприклад, за ентропійною мірою Шеннона (2.5.4) або критерієм Кульбака (2.5.6), глобальний максимум КФЕ  $E_\rho^*$ . Якщо маємо декілька однакових значень  $E_z^*$ , то вибираємо значення з найменшим усередненим коефіцієнтом нечіткої компактності реалізацій образу:

$$L_\rho = \frac{1}{M} \sum_{m=1}^M \frac{d_m^*}{d(x_m \oplus x_{c,m})}, \quad (2.8.3)$$

де  $x_{c,m}$  – найближчий еталонний вектор до класу  $X_m^o$ .

Параметри функціонування, які відповідають глобальному максимуму критерію  $E_\rho^*$  при мінімальному  $L_\rho$ , вважаються оптимальними.

9. Якщо  $\rho z < \rho v$ , то виконується крок 6, інакше – 10.

10. Якщо  $i \leq N$ , де  $N$  – кількості ознак розпізнавання, то виконується крок 2, інакше – «ЗУПИН».

Таким чином, алгоритм оптимізації рівнів селекції координат двійкових еталонних векторів-реалізацій образу, як і інших параметрів навчання СППР, у рамках ІЕІ-технології полягає у наближенні глобального максимуму інформаційного критерію оптимізації, обчисленого в робочій області визначення його функції, до найбільшого граничного значення.

## 2.9. Оптимізація словника ознак розпізнавання

Одним із ефективних шляхів редукції простору ознак розпізнавання є оптимізація словника ознак [55,56], яка спрямована на зменшення його інформаційної надлишковості. У загальному випадку проблема формування оптимального в інформаційному розумінні словника ознак розпізнавання може розглядатися у трьох аспектах:

- 1) попередній відбір ознак для формування початкового словника ознак розпізнавання;
- 2) пошук у надлишковому словнику інформативних ознак, виявлення латентних і виключення неінформативних і “заважаючих” ознак розпізнавання;
- 3) доповнення словника інформативними первинними та вторинними ознаками розпізнавання.

Початковий відбір ознак все ще залишається в основному функцією людини – розробника інформаційного забезпечення СППР. Доступність ознак розпізнавання для вимірювання, наявність необхідних датчиків інформації (сенсорів) і приладів вимірювання значною мірою впливають на формування словника ознак. Тому важливого значення набуває необхідність найкращого використання наявних ознак розпізнавання. Саме на це спрямовано другий аспект вирішення проблеми шляхом оптимізації вхідного математичного опису в процесі навчання СППР. Третій аспект проблеми формування інформативного словника так само доцільно вирішувати у рамках оптимізації параметрів процесу навчання СППР в рамках ІЕІ-технології.

Згідно із принципом відкладених рішень введемо, наприклад, у діаграму оптимізації СКД (2.8.1) додатковий контур, який замикається операторами  $\pi: E \rightarrow \Sigma$ , де множина  $\Sigma$  – словник ознак розпізнавання, що містить первинні та вторинні у загальному випадку надлишкові в інформаційному розумінні ознаки, і  $\omega: \Sigma^\Lambda \rightarrow \Omega$ , який безпосередньо змінює розмірність простору

ознак. Крім того, розширення словника може здійснюватися, наприклад, за рахунок вимірювання параметрів впливу зовнішнього середовища та інших параметрів функціонування ІС, які впливають на потужність простору станів  $Z$ , за допомогою оператора  $h: \Sigma \rightarrow Z$ .

Діаграму відображення множин у процесі навчання СППР за ІЕІ-технологією із оптимізацією словника ознак розпізнавання показано на рис. 2.11.




Рисунок 2.11 – Категорійна модель навчання СППР з оптимізацією словника ознак розпізнавання

У діаграмі (рис. 2.11) оператор  $\tau$  змінює крок дискретизації реалізації образ, що призводить до зміни потужності словника.

Після формування у загальному випадку апріорно надлишкового варіанта словника  $\Sigma$  його оптимізація здійснюється у процесі навчання СППР шляхом реалізації ітераційної процедури пошуку максимуму цільової функції

$$\Sigma^* = \operatorname{arg\,max}_{\Sigma \in \Omega} EK(\Omega), \quad (2.9.1)$$

де  $EK(\Omega)$  – деяка узагальнена цільова функція, що включає як інформаційний КФЕ, так і додаткові умови, які є характерними для

відповідного алгоритму селекції ознак розпізнавання. З урахування вище наведеного на рис. 2.12 показано діаграму відображень множин, що застосовуються у процесі навчання СППР при оптимізації словника ознак [55].




Рисунок 2.12 – Категорійна модель оптимізації словника ознак розпізнавання за критерієм (2.9.1)

У діаграмі (рис. 2.12) штрих пунктирними стрілками позначені можливі додаткові оператори оптимізації словника, що використовують особливості оптимізації інших параметрів функціонування СППР, що навчається. Так, оператор  $h_D$  виділяє групу ознак розпізнавання, що не змінюють КФЕ у процесі оптимізації СКД за умови, що така оптимізація проводилася для кожної ознаки розпізнавання послідовно. Оператор  $h_{\tilde{R}^{|M|}}$  здатний перевірити, які з ознак було задіяне при реалізації максимально-дистанційного або мінімально-дистанційного принципів оптимізації геометричних параметрів розбиття простору ознак розпізнавання. Слід зазначити, що ці контури впливають лише на стратегію оптимізації словника, оскільки здатні об'єднувати окремі ознаки розпізнавання в групи відповідно до їх впливу на функціональну ефективність системи, що навчається.



## 2.10. Функціонування системи підтримки прийняття рішень в режимі екзамену

Діаграма відображень множин на екзамені має такі відмінності від діаграм оптимізаційного навчання у рамках ІЕІ-технології:

- зворотний зв'язок у діаграмі не містить контурів оптимізації параметрів функціонування ІС, а призначенням оператора  $U_E$  є регламентація екзамену;
- замість оператора  $\theta$  вводиться оператор  $P$  відображення бінарної вибіркової множини  $X \subset \Omega_E$ , що розпізнається, на побудоване на етапі навчання чітке розбиття  $\mathfrak{R}^{|M|}$ ;
- оператор класифікації  $\Psi$  утворює композицію двох операторів: оператор обчислення функції належності  $\Psi_1: \tilde{\mathfrak{R}}^{|M|} \rightarrow F$ , де  $F$  – множина функцій належності, і оператор дефазифікації  $\Psi_2: F \rightarrow I^{|M+1|}$ , який вибирає відповідну гіпотезу за максимальним значенням функції належності.

З урахуванням наведених відмінностей діаграму відображень множин, що застосовуються при функціонуванні СППР в режимі екзамену, показано на рис. 2.13 [9].




Рисунок 2.13 – Категорійна модель функціонування СППР в режимі екзамену

У діаграмі (рис. 2.13) оператор  $\Phi_1$  відображає універсум випробувань на вибірку множини  $X$ , яка утворює екзаменаційну

матрицю  $\| x_i^{(j)} \mid i = \overline{1, N}, j = \overline{1, n} \|$ , аналогічну навчальній матриці за структурою, параметрами та процедурою формування.

За наявності оптимальних параметрів навчання СППР алгоритм екзамену має такі вхідні дані:

- $\{x_m^* \mid m = \overline{1, M}\}$  – масив еталонних двійкових векторів-реалізацій образу, які визначають геометричні центри відповідних оптимальних контейнерів класів розпізнавання, побудованих на етапі навчання;
- $\{d_m^*\}$  – масив оптимальних радіусів, побудованих на етапі навчання відповідних контейнерів;
- $\{x^{(j)} \mid j = \overline{1, n}\}^\Lambda$  – відкритий масив двійкових векторів-реалізацій образу, що розпізнається;
- $\{\delta_{k,i}^* \mid i = \overline{1, N}\}$  – оптимальна СКД на ознаки розпізнавання, визначена на етапі навчання.

За замовчуванням, тобто при відсутності оптимізації на етапі навчання рівня селекції координат еталонних векторів класів розпізнавання, при формуванні бінарної екзаменаційної матриці на практиці він дорівнює  $\rho_m = 0,5$ , тобто у цьому випадку координата еталонного вектору приймає значення ознаки, яке з найбільшою частотою присутнє у відповідній навчальній вибірці.

Алгоритм екзамену у рамках ІЕІ-технології ґрунтується на аналізі значень функції належності, яка обчислюється для кожної реалізації, що розпізнається, і для гіперсферичного контейнера класу розпізнавання  $X_m^o$  має вигляд

$$\mu_m = 1 - \frac{d(x_m^* \oplus x^{(j)})}{d_m^*}. \quad (2.10.1)$$

Розглянемо схему реалізації алгоритму екзамену:

- 1) формування лічильника класів розпізнавання:  $m := m + 1$ ;
- 2) формування лічильника числа реалізацій, що розпізнаються:  $j := j + 1$ ;
- 3) обчислення кодової відстані  $d(x_m^* \oplus x^{(j)})$ ;
- 4) обчислення функції належності;
- 5) порівняння: якщо  $j \leq n$ , то виконується крок 2, інакше – крок 6;
- 6) порівняння: якщо  $m \leq M$ , то виконується крок 1, інакше – крок 7;
- 7) визначення класу  $X_m^o$ , до якого належить реалізація образу, наприклад, за умови  $\bar{\mu}_m^* = \max_{\{m\}} \bar{\mu}_m$ , де  $\bar{\mu}_m = \frac{1}{n} \sum_{j=1}^n \mu_{m,j}$  – усереднене значення функцій належності для реалізацій класу  $X_m^o$ , або видача повідомлення: «Клас не визначено», якщо  $\bar{\mu}_m^* \leq c$ . Тут  $c$  – порогове значення.

Таким чином, вирішальні правила, що використовуються у рамках ІЕІ-технології в режимі екзамену СППР є детермінованими і відрізняються незначною обчислювальною трудомісткістю, що дозволяє їх реалізовувати у реальному темпі часу.

## ГЛАВА 3. ЗАСТОСУВАННЯ ІНТЕЛЕКТУАЛЬНИХ ІНФОРМАЦІЙНИХ ТЕХНОЛОГІЙ В НАВЧАЛЬНОМУ ПРОЦЕСІ

### 3.1. Формування вхідного математичного опису інтелектуальної системи контролю знань

Важливою підсистемою інтелектуальної СКНП є система контролю знань (СКЗ), побудована на основі здатної навчатися СППР. Формування вхідного математичного опису адаптивної СКЗ розглянемо для чотирьох класів, тобто для оцінок рівня знань студентів: «відмінно» – клас  $X_5^o$ , «добре» – клас  $X_4^o$ , «задовільно» – клас  $X_3^o$  і «незадовільно» – клас  $X_2^o$ . Класи формувалися за експериментальними даними, отриманими в процесі перевірки знань студентів з навчальної дисципліни «Інтелектуальні системи», яка викладається в Сумському державному університеті для студентів спеціальності «Інформатика», що навчалися за дистанційною формою. Тестові запитання для семестрового контролю склалися на базі навчального контенту цієї дисципліни у кількості 130, для контролю навчального модулю «Методи подання знань» – 48 і для контролю навчального модулю «Методи виведення знань» – 28. Початковий словник ознак залежно від обсягу навчального матеріалу, що контролювався, складався відповідно із 130, 48 і 32 ознак розпізнавання, значення яких дорівнювали відповідним результатам тестування. Відповідь на кожний з тестів оцінювалася за стобальною шкалою.

За нормоване поле допусків на кожну ознаку розпізнавання було вибрано стобальну шкалу оцінювання. При цьому за  $i$ -ту ознаку розпізнавання приймався відбитий на шкалу оцінювання за обраною оціночною функцією результат відповіді студента на  $i$ -й тест із заданої множини. Контрольні допуски на ознаки вибира-

лися в процесі навчання СППР за наведеною у другому розділі методикою. Мінімальна кількість реалізацій, яка забезпечувала репрезентативність навчальної вибірки для використання ІЕІ-технології, визначалася за методикою праці [25], і для кожного з класів дорівнювала  $n = 40$ , що забезпечило максимальну статистичну похибку  $\varepsilon_{\max} = \pm 0,01$  при рівні значущості  $Q = 0,05$ .

На підготовчому етапі створювалися за наведеним у цьому підрозділі інформаційно-екстремальним алгоритмом еквівалентні набори тестів, які формувалися шляхом додавання в початкові довільно сформовані базові набори (10-15 тестів) еквівалентних тестів із залишкового словника, еквівалентність яких визначалася СППР за результатами тестування. Нееквівалентними вважалися тести (ознаки) групи, для яких значення інформаційного КФЕ машинного навчання СППР було меншим допустимого значення  $E_{\text{доп}}^*$ .

Таким чином, початковий словник ознак  $\Sigma^{|N|}$  розглядається як об'єднання декількох підмножин ознак:

$$\Sigma^{|N|} = \bigcup_{\Sigma^{|N_k|} \in \Sigma^{|N|}} \Pi(\Sigma^{|N_k|}), \quad (3.1.1)$$

де  $\Pi(\Sigma^{|N_k|})$  – підмножина еквівалентних ознак розпізнавання.

При цьому для виразу (3.1.1) має місце умова

$$\begin{aligned} [\forall \Pi(\Sigma^{|N_k|}) \in \Sigma^{|N|}] [\forall \Pi(\Sigma^{|N_l|}) \in \Sigma^{|N|}] \{ \Sigma^{|N_k|} \neq \Sigma^{|N_l|} \rightarrow \\ \rightarrow \Sigma^{|N_k|} \cap \Sigma^{|N_l|} \neq \emptyset \}, \end{aligned}$$

тобто класи еквівалентності ознак розпізнавання можуть перетинатися.

Оскільки у рамках ІЕІ-технології адаптація вхідного математичного опису СППР відбувається шляхом допустимих перетворень

в дискретному субпарцептуальному просторі ознак розпізнавання, то визначення елементів бінарної навчальної матриці  $\|x_{m,i}^{(j)}\|$ ,  $i = \overline{1, N_k}$  здійснювалося за правилом (2.6.1), а формування еталонних векторів-реалізацій класів розпізнавання за правилом (2.6.2). Як вхідний тестовий набір розглядалися запитання закритого типу з одним, або декількома правильними варіантами відповідей для оцінки рівня знань студентів за результатами їх атестації після вивчення модулів «Методи подання знань» і «Методи виведення знань» навчальної дисципліни «Інтелектуальні системи».

### 3.2. Оптимізація вагових коефіцієнтів тестів

Оптимізація вагових коефіцієнтів тестів у рамках ІЕІ-технології дозволяє підвищити достовірність оцінки рівня знань слухачів та автоматизувати процес вибору цих коефіцієнтів, який на практиці покладається на викладача – розробника тестів. Ця задача досліджувалася в праці [57].

Категорійну модель здатної навчатися СКЗ у вигляді діаграми відображення множин, що застосовуються в процесі оптимізації дидактичних параметрів, показано на рис. 3.1.




Рисунок 3.1 – Діаграма відображення множин при оптимізації тестів

Крім контура оптимізації геометричних параметрів контейнерів класів розпізнавання базового алгоритму навчання (рис. 2.6) діаграма, показана на рис. 3.1, містить контур оптимізації контрольних допусків, в якому терм-множина  $D$  – значення системи контрольних допусків на ознаки розпізнавання, і контур оптимізації дидактичних параметрів генерування тестів, в якому  $W$  і  $V$  множини значень коефіцієнтів валідності  $k_B$  і значущості  $k_3$  відповідно. Тут  $\Sigma^\Lambda$  – відкрита послідовність тестів, що генерується викладачем при створенні навчально-методичного забезпечення СКЗ.

Категорійна модель процесу навчання СППР у вигляді показаної на рис. 3.1 діаграми, в якій множини, що застосовуються при навчанні, відображаються відповідними операторами на інші множини, складається з орієнтованих контурів оптимізації параметрів функціонування системи. При цьому категорійна модель відповідає принципу повної композиції, оскільки множина  $E$  є загальною для всіх контурів оптимізації. Крім того, моделювання слабо формалізованого навчального процесу у вигляді категорійної моделі суттєво спрощує розроблення структурних схем інформаційно-екстремальних алгоритмів навчання СППР і дозволяє здійснювати розширення їх функціональних можливостей.

Оскільки оптимізація вагових коефіцієнтів оцінок відповідей при тестуванні слухачів здійснюється для кожного тесту, то як алгоритм навчання СППР розглянемо послідовну структуровану ітераційну процедуру пошуку глобального максимуму інформаційного КФЕ навчання в робочій області визначення його функції

$$K_{3,i}^* = \arg\{\max_{G_1}\{\max_{G_2}\{\max_{G_3}\left[\bigotimes_{l=1}^L \max_{G_E \cap G_d} \bar{E}\right]\}\}\}, i = \overline{1, N}, \quad (3.2.1)$$

Оптимізацію вагових коефіцієнтів тестів будемо здійснювати на прикладі оцінки знань студентів за навчальний модуль «Методи

подання знань» з навчальної дисципліни «Інтелектуальні системи», що викладається студентам спеціальності «Інформатика» в Сумському державному університеті. За результатами тестування знань студентів було сформовано вхідну апріорно класифіковану викладачем навчальну матрицю  $\|y_{m,i}^{(j)}\|$  з параметрами:  $m = \overline{1,4}; i = \overline{1,24}; j = \overline{1,40}$ .

Розглянемо схему алгоритму оптимізації вагових коефіцієнтів тестів (3.2.1), яку розроблено у відповідності до категорійної моделі, показаної на рис. 2.4.

Крок 1. Формування лічильника значень коефіцієнта значущості  $K_3 : s := 0$ .

Крок 2.  $s := s + 1$ .

Крок 3. Формування лічильника значень коефіцієнта валідності  $K_B : b := 0$ .

Крок 4.  $b := b + 1$ .

Крок 5. Обнулюється лічильник кроків зміни параметра  $\delta : l := 0$ .

Крок 6. Запускається лічильник:  $l := l + 1$  і обчислюються нижні та верхні контрольні допуски для всіх ознак:  $\{A_{HK,i}[l] := y_{m,i} - \delta[l]\}$  і  $\{A_{BK,i}[l] := y_{m,i} + \delta[l]\}$ ,  $i = \overline{1,N}$ , відповідно.

Крок 7. Реалізується базовий алгоритм навчання за схемою, наведеною в підрозділі 2.6, і обчислюється значення усередненого інформаційного КФЕ навчання СППР.

Крок 8. Якщо в робочій області визначення функції інформаційного КФЕ має місце  $E_1^*[b,l] \geq E_1^*[b,l-1]$ , то виконується крок 9, інакше – крок 10.

Крок 9. Якщо  $\delta \leq \delta_H / 2$ , то виконується крок 6, інакше – крок 10.



Крок 10. Обчислюються оптимальні контрольні допуски і максимальне значення критерію  $E_1^*[b]$  відповідно

$$\{A_{HK,i}^* := A_{HK,i}[l-1]\}; \{A_{BK,i}^* := A_{BK,i}[l-1]\}, i = \overline{1, N};$$

$$E_1^*[b] := E_1^*[b, l-1].$$

Крок 11. Якщо в робочій області визначення функції інформаційного КФЕ має місце  $E_1^*[b] \geq E_1^*[b-1]$ , то виконується крок 10, інакше – крок 4.

Крок 12. Якщо  $K_B[b] \in G_{K_B}$ , то  $K_B^* = \max_{(b)} \{K_B[b]\}$ .

Крок 13. Якщо  $K_3[s] \in G_{K_3}$ , то виконується крок 2, інакше – крок 14

Крок 14.  $K_3^* = \max_{\{s\}} \{K_3[s]\}$  і ЗУПИН.

У процесі реалізації запропонованого алгоритму, в якому оцінка функціональної ефективності навчання СППР здійснювалася за модифікованим критерієм Кульбака (25.8), було побудовано оптимальні контейнери для чотирьох класів розпізнавання:  $X_5^o$  – «відмінно»,  $X_4^o$  – «добре»,  $X_3^o$  – «задовільно і  $X_2^o$  – «незадовільно».

На рис. 3.2 показано результати оптимізації радіуса контейнера класу  $X_5^o$ , де заштрихована ділянка вказує на робочу (допустиму) область визначення функції критерію оптимізації (2.5.4).




Рисунок 3.2. Графік залежності КФЕ від величини радіуса контейнера класу  $X_5^o$

Згідно з рис. 3.2 оптимальний радіус гіперсферичного контейнера, який дорівнює  $d_5^* = 21$  у кодових одиницях Хеммінга, визначається як екстремальне значення глобального максимуму функції критерія оптимізацій ( $E_5^* = 2,45$ ) в робочій області її визначення.

На рис.3.3 показано графік залежності критерію Кульбака (2.5.4) від величини радіуса контейнера класу  $X_4^o$ , одержаний при оптимізації вагових коефіцієнтів тестів.




Рисунок 3.3 – Графік залежності критерію Кульбака від величини радіуса контейнера класу  $X_4^o$

Аналіз рис. 3.3 показує, що радіус оптимального контейнера дорівнює  $d_4^* = 17$  кодовим одиницям Хеммінга при максимальному значенні КФЕ навчання СППР  $E_4^* = 1,45$ .

На рис.3.4 показано графік залежності критерію Кульбака від величини радіуса контейнера класу  $X_3^o$ .




Рисунок 3.4 – Графік залежності КФЕ від величини радіуса контейнера класу  $X_3^o$

Аналіз рис. 3.4 показує, що радіус оптимального контейнера дорівнює  $d_3^* = 17$  кодовим одиницям Хеммінга при значенні КФЕ навчання СППР  $E_3^* = 0,95$ .

На рис. 3.5 показано графік залежності критерію Кульбака при оптимізації вагових коефіцієнтів тестів від величини радіуса контейнера класу  $X_2^o$ . Згідно з рис. 3.5 оптимальний радіус гіперсферичного контейнера, який дорівнює  $d_1^* = 17$  у кодових одиницях Хеммінга, визначається як екстремальне значення глобального максимуму критерію оптимізації ( $E_1^* = 1,02$ ), обчисленого в робочій області визначення його функції.




Рисунок 3.5 – Графік залежності критерію Кульбака від радіуса контейнера класу  $X_2^{o\wedge}$

Таким чином, експериментально підтверджено можливість відновлення в процесі навчання СППР оптимальних в інформаційному розумінні контейнерів класів розпізнавання, які у рамках геометричного підходу визначають вирішальні правила, що застосовуються в режимі екзамену СППР, тобто безпосередньої оцінки рівня знань слухачів. З іншого боку, аналіз значень глобальних максимумів КФЕ навчання (рис.3.2 - 3.5) показує, що вони в робочій області їх визначення не є граничними, тобто оптимальний класифікатор не є безпомилковим за навчальною матрицею. Це потребує оптимізації інших просторово-часових параметрів функціонування СППР, які впливають на її асимптотичні точнісні характеристики.

Подальше удосконалення запропонованого методу синтезу адаптивної мультиагентної СППР у рамках ІЕІ-технології полягає в побудові безпомилкового за навчальною матрицею класифікатора шляхом оптимізації інших дидактичних і технологічних просторово-часових параметрів функціонування, які впливають на то-

чнісні характеристики процесу навчання системи. Крім того, у загальному випадку для вирішення проблеми оптимального генерування тестів, яка є ключовою при автоматизації створення вхідного математичного опису СППР для керування і супроводження навчального процесу, важливого значення набуває вирішення проблеми конструювання універсальної оціночної функції.

### **3.3. Формування класів еквівалентних ознак розпізнавання**

Визначення класів еквівалентних ознак розпізнавання (тестів) здійснювалося з метою формування репрезентативних в інформаційному розумінні наборів тестів [58,59]. Для розв'язання цієї задачі на базі повного словника із 28 ознак розпізнавання було сформовано базовий словник  $\Sigma_{\text{баз}}$ , який складався із 14 ознак, а інші 14 ознак увійшли до залишкового словника  $\Sigma_{\text{залиш}}$ . При цьому для зручності графічного відображення результатів оптимізації масштаб оціночної шкали і відповідно параметра оптимізації  $\delta$  було збільшено у 10 разів, тобто замість стобальної оціночної шкали використовувалася тисячебальна шкала.

Згідно розробленого алгоритму на нульовій ітерації процесу формування класів еквівалентності було проведено оптимізацію параметрів навчання СППР за базовим словником ознак. На рис.3.6 показано результати оптимізації СКД на ознаки розпізнавання за критерієм (2.5.4) і за навчальною матрицею, сформованою для базового словника ознак. При цьому реалізація алгоритму машинного навчання СППР здійснювалася з паралельною оптимізацією контрольних допусків, тобто допуски на всі ознаки змінювалися одночасно.





Рисунок 3.6 – Графік залежності усередненого КФЕ від параметра поля контрольних допусків для базового словника ознак

Аналіз рис. 3.6 показує, що максимальне усереднене значення ненормованого КФЕ (2.5.6) дорівнює  $\overline{E^*} = 2,72$ , а оптимальне значенням параметра СКД на ознаки розпізнавання –  $\delta^* = \pm 80$  (у перерахунку на 100-бальну оціночну шкалу дорівнює  $\delta^* = \pm 8$ ). Процес оптимізації геометричних параметрів контейнерів класів розпізнавання при оптимальному значенні параметра  $\delta^*$  ілюструє рис. 3.7.








Рисунок 3.7 – Графіки КФЕ при оптимізації контейнерів:

$a$  – клас  $X_1^o$  – «відмінно»;  $b$  – клас  $X_2^o$  – «добре»;  
 $v$  – клас  $X_3^o$  – «задовільно»;  $z$  – клас  $X_4^o$  – «незадовільно»

Аналіз рис. 3.7 показує, що оптимальні значення радіусів контейнерів класів розпізнавання дорівнюють: для першого класу  $d_1^* = 3$ , для другого –  $d_2^* = 2$ , для третього –  $d_1^* = 3$ , для четвертого –  $d_1^* = 4$ . Відповідно мінімальна міжцентрова відстань для першого класу дорівнює –  $d(x_1 \oplus x_3) = 5$ , для другого класу –  $d(x_1 \oplus x_3) = 5$ , для третього класу –  $d(x_1 \oplus x_3) = 6$  і для четвертого класу –  $d(x_1 \oplus x_3) = 5$ . Враховуючи те, що сусідом для першого класу був четвертий клас, для другого – перший клас, для третього – другий і для четвертого – перший, то можна зробити висновок, що класи перетинаються.

Підтвердженням перетину класів є максимальні значення відповідних КФЕ та значення точнісних характеристик навчання СППР, які не дорівнюють граничним:

- для класу  $X_1^o$ :  $E_1^* = 1,24$ ;  $D_{1,1}^* = 0,68$ ;  $\beta_1^* = 0,00$ ;
- для класу  $X_2^o$ :  $E_2^* = 4,39$ ;  $D_{1,2}^* = 1,00$ ;  $\beta_2^* = 0,00$ ;
- для класу  $X_3^o$ :  $E_3^* = 4,39$ ;  $D_{1,3}^* = 1,00$ ;  $\beta_3^* = 0,00$ ;
- для класу  $X_4^o$ :  $E_4^* = 0,71$ ;  $D_{1,4}^* = 0,82$ ;  $\beta_4^* = 0,34$ .

Таким чином, класифікатор, що було побудовано на основі базового словника ознак розпізнавання не є безпомилковим. Ця проблема може бути вирішена як за допомогою додаткової оптимізації параметрів функціонування СППР або формування нового базового словника ознак шляхом додавання в початковий базовий словник нових ознак із залишкового словника.

На рис. 3.8 наведено результати оцінки еквівалентності ознак розпізнавання за алгоритмом навчання з оптимізацією СКД на ознаки розпізнавання за процедурою (2.7.2) і показана динаміка



зміни середнього значення КФЕ в процесі формування першого класу еквівалентності. На рис. 3.8 горизонтальна неперервна лінія показує усереднене значення КФЕ для базового словника, а різнокольорові прямокутники – усереднене значення КФЕ при таких варіантах базового словника, в яких перша ознака була замінена на ознаку з альтернативного словника з  $i$ -м номером. На рис. 3.8 світлим кольором помічено ті ознаки, що є еквівалентними, чорним – нееквівалентні, а сірим – альтернативні




Рисунок 3.8 – Діаграма оцінювання еквівалентності ознак розпізнавання

У процесі розбиття ознак розпізнавання на класи еквівалентності на кожному кроці формувалися варіанти словників ознак розпізнавання з потужністю, що дорівнювала потужності поточного словника ознак, для яких проводилася оптимізація параметрів навчання й обчислювалося максимальне усереднене значення КФЕ. В праці [58-60] запропоновано критерій оцінки еквівалентності ознак розпізнавання, яка дозволяє оцінити еквівалентність, використовуючи усереднене значення КФЕ, одержане в процесі машинного навчання СППР:

$$Q = \frac{\sum_{m=1}^M \overline{E}_{\text{баз}}^{(m)}}{M} - \frac{\sum_{m=1}^M \overline{E}_{\text{залиш}}^{(m)}}{M}, \quad (3.3.1)$$

де  $\overline{E}_{\text{баз}}^{(m)}$  – КФЕ  $m$ -го класу розпізнавання для базового словника;  
 $\overline{E}_{\text{залиш}}^{(m)}$  – КФЕ  $m$ -го класу розпізнавання для залишкового (альтернативного) словника.

Результати застосування міри еквівалентності (3.3.1) в процесі машинного навчання СКЗ наведено на рис. 3.9.

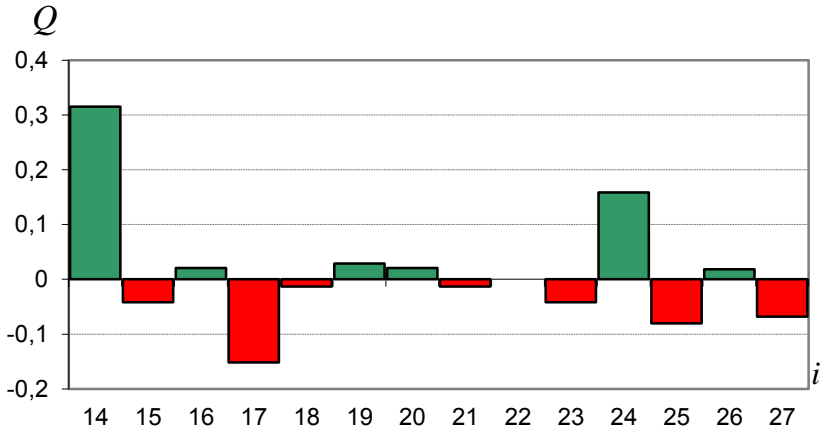


Рисунок 3.9 – Діаграма оцінювання еквівалентності ознак розпізнавання, одержана при застосуванні міри еквівалентності (3.3.1)

Одержані при аналізі результати оцінки еквівалентності за мірою (3.3.1) дозволяють розбити альтернативний словник на три групи:

- еквівалентні ознаки – {22};
- нееквівалентні ознаки – {15, 17, 18, 21, 23, 25, 27};
- альтернативні ознаки – {14, 16, 19, 20, 24, 26}.

З метою дослідження впливу на функціональну ефективність в праці [57] паралельно з оцінкою еквівалентності за мірою еквівалентності (3.3.1) застосовувалася в процесі машинного навчання СКЗ деталізована міра еквівалентності

$$Q' = \sqrt{\sum_m^M (E_{баз}^{(m)} - E_{залиши}^{(m)})^2}, \quad (3.3.2)$$

яка оцінює еквівалентність ознаки з нового словника до ознаки з базового словника з урахуванням її впливу на ефективність відновлення оптимального контейнера кожного з класів розпізнавання окремо. Ця міра дозволяє встановити належність ознаки до групи еквівалентних або нееквівалентних ознак розпізнавання.

На рис. 3.10 показано результати оцінки еквівалентності ознак за критерієм (3.3.2). Аналіз результатів оцінки еквівалентності у цьому випадку показує, що ознака під номером 22 альтернативного словника (на рис. 3.8 зображена білим кольором) є еквівалентною до нульової ознаки із базового словника, оскільки вона не змінює як ефективність функціонування СППР в цілому, так і по класифікатору кожного з класів розпізнавання.




Рисунок 3.10 – Діаграма оцінювання еквівалентності ознак розпізнавання, одержана при застосуванні міри еквівалентності (3.3.2)

Відповідно ознаки, що позначено чорним кольором, а саме 15, 17, 18, 21, 23, 25, 27 є нееквівалентними, оскільки, як показано на рис. 3.8, знижують ефективність функціонування СППР, а тому їх не бажано використовувати в варіанті завдання, оскільки це може призвести до зменшення повної ймовірності правильного оцінювання рівня знань слухача. Ознаки показані сірим кольором, а саме 14, 16, 19, 20, 24, 26, збільшують згідно з рис. 3.8 ефективність функціонування СППР, тому вони є альтернативними. У результаті виконання аналогічних дій відносно інших ознак розпізнавання базового словника було сформовано класи еквівалентності, наведені в табл. 3.1.

**Таблиця 3.1 – Результати формування класів еквівалентності ознак розпізнавання**

№	Класи еквівалентності													
	0	1	2	3	4	5	6	7	8	9	10	11	12	13
1	22	24	25	14	16	25	26	15	23	23	21	21	14	15
2	19	27	26	23	26	20	15	17	14	14	17	26	17	14
3	16	15	20	24	20	16	27	14	24	18	15	18	23	18
4	20	18	15	20	18	24	25	19	19	17	16	16	21	23
5	26	22	16	16	25	15	20		17	20	25	20	24	27
6	24	20	17	19	27	18	14		21	22	20	24	20	19
7	14	25	19		24	19	17		25	27	22	15	25	17
8		16			21	14			20	25	19	17	22	
9		21			23				16	26	26	14	16	
10		17			19				22	24			15	
11		26			14				15	21				
12		19							26	15				
13										19				
14										16				

У першому рядку табл. 3.1 показані 14 ознак із базового словника ознак розпізнавання, для яких формуються класи еквівалентності. У стовпчиках у порядку зменшення еквівалентності подано ознаки, що є еквівалентними або альтернативними. При цьому зафарбовані сірим кольором клітинки таблиці відповідають еквівалентним ознакам, усі інші ознаки є альтернативними. Таким чином у другому рядку подані ознаки, що при заміні найменше впливають на функціональну ефективність СППР. Таким чином, впорядкований перший клас еквівалентності ознак розпізнавання має такий вигляд: 22, 19, 16, 20, 26, 24, 14. Тобто заміна нульової ознаки розпізнавання в базовому словнику ознак на одну із цих ознак альтернативного словника забезпечує еквівалентність базового словника.

Підвищення функціональної ефективності СППР дозволяє підвищити достовірність розпізнавання класів, що характеризують рівні знань слухачів за відповідною системою оцінювання. Питання про заміну ознаки у базовому словнику вирішує викладач при формуванні еквівалентних наборів тестів.

Для перевірки результатів було сформовано еквівалентний словник, в якому половину ознак було замінено на еквівалентні до них або альтернативні.

На рис. 3.11 показано процес оптимізації СКД на ознаки розпізнавання для еквівалентного словника з використанням алгоритму навчання СППР з паралельною оптимізацією контрольних допусків на ознаки розпізнавання (2.7.2). Аналіз рис. 3.11 показує, що усереднене значення КФЕ дорівнює  $\overline{E^*} = 2,85$  і перевищує значення при початковому базовому словнику ознак ( $\overline{E^*} = 2,72$ ). При цьому оптимальним значенням параметра поля контрольних допусків дорівнює  $\delta^* = \pm 79$ .






Рисунок 3.11 – Процес оптимізації СКД для еквівалентного словника ознак розпізнавання


Динаміку зміни КФЕ (2.5.4) в процесі відновлення контейнерів класів розпізнавання показано на рис. 3.12. Тут і далі подвійною штриховкою позначено робочі області визначення функції інформаційного критерію. Аналіз рис. 3.12 показує, що оптимальні значення геометричних параметрів для першого класу дорівнюють  $d_1^* = 4$ , для другого класу –  $d_1^* = 2$ , для третього –  $d_1^* = 3$  і для четвертого –  $d_4^* = 3$ .




*a*



б



б



2

Рисунок 3.12 – Графіки зміни КФЕ при оптимізації радіусів контейнерів:  $a$  – клас  $X_1^o$  – «відмінно»;  $b$  – клас  $X_2^o$  – «добре»;  $v$  – клас  $X_3^o$  – «задовільно»;  $z$  – клас  $X_4^o$  – «незадовільно»

Враховуючи те, що сусідом для першого класу був четвертий клас, для другого – третій клас, для третього – другий і для четвертого – перший, то можна зробити висновок, що класи перетинаються, але мають кращі точнісні характеристики у порівнянні з мірою (3.3.1). Підтвердженням наявності перетину класів розпізнавання є значення максимумів КФЕ та точнісних характеристик машинного навчання СППР:

- для класу  $X_1^o$ :  $E_1^* = 0,71$ ;  $D_{1,1}^* = 0,75$ ;  $\beta_1^* = 0,11$ ;
- для класу  $X_2^o$ :  $E_2^* = 4,40$ ;  $D_{1,2}^* = 1,00$ ;  $\beta_2^* = 0,00$ ;
- для класу  $X_3^o$ :  $E_3^* = 4,40$ ;  $D_{1,3}^* = 1,00$ ;  $\beta_3^* = 0,00$ ;
- для класу  $X_4^o$ :  $E_4^* = 1,24$ ;  $D_{1,4}^* = 0,79$ ;  $\beta_4^* = 0,14$ .

Таким чином, результати навчання СППР для еквівалентного словника ознак розпізнавання вказують на доцільність його застосування замість базового словника.



### 3.4. Оптимізації вкладених контейнерів класів розпізнавання

Розроблення структури контейнерів класів розпізнавання для СКЗ ґрунтується на гіпотезі про наявність еталонного образу знань студента, який засвоїв матеріал навчальної дисципліни в повному обсязі та заслуговує на оцінку «відмінно». Інші образи знань, що відповідають оцінкам «добре», «задовільно» і «незадовільно», мають певний рівень відхилення від даного еталонного образу. Таким чином, специфіка машинного контролю знань полягає в тому, що алфавіт класів розпізнавання є структурованим. В цьому випадку класи знань, які задаються в просторі ознак розпізнавання відповідними областями, краще описуються не полімодальною, а одномодальною, або вкладеною структурою класів розпізнавання, яка характеризується загальним центром розсіювання реалізацій. При цьому у центрі розміщується клас знань рівня «відмінно», його обрамляє клас знань рівня «добре», який в свою чергу обрамляється класом знань рівня «задовільно». Останній клас «незадовільно» відповідає найвіддаленішим від еталонного рівням знань слухачів. Контейнери, що мають таку структуру розбиття простору ознак на класи розпізнавання будемо називати вкладеними. В працях [61] розглянуто інформаційно-екстремальні алгоритми навчання СППР з оптимізацією вкладених контейнерів класів розпізнавання. При цьому геометричний центр всіх контейнерів класів розпізнавання визначається вершиною одиничного еталонного вектора  $x_0$ , кількість координат якого дорівнює потужності словника ознак розпізнавання, а кожний гіперсферичний контейнер класу  $X_m^o$  характеризується внутрішнім  $R_1^{(m)}$  і зовнішнім  $R_2^{(m)}$  радіусами гіперсфери. При цьому оптимальними вважаються такі значення радіусів, що відповідають максимальному значенню КФЕ в робочій області визначення його функції.

Модифікацію математичної моделі базового алгоритму навчання СППР (рис. 2.4) подамо у вигляді діаграми відображень множин, показаної на рис. 3.13.




Рисунок 3.13 – Категорійна модель оптимізації вкладених контейнерів класів розпізнавання

Показані на рис. 3.13 оператори  $r_1$  і  $r_2$  оптимізують відповідно внутрішні та зовнішні радіуси вкладених контейнерів класів розпізнавання в процесі їх відновлення в радіальному базисі простору ознак розпізнавання.

Застосування вкладених контейнерів класів розпізнавання вносить певні зміни в базовий алгоритм машинного навчання СППР в рамках ІЕІ-технології. Розглянемо кроки реалізації такого алгоритму за математичною моделлю, поданою на рис. 3.14:

- 1) формування бінарної навчальної матриці  $\|x_{m,i}^{(j)}\|$ , елементи якої визначаються за правилом (2.6.1);
- 2) формування одиничного  $N$ -вимірного двійкового еталонного вектора  $x_0$ ;
- 3) ініціалізація лічильника класів  $k = 2$ ;
- 4) ініціалізація лічильника кроків оптимізації внутрішнього радіуса  $R1 = 0$ ;
- 5) ініціалізація лічильника кроків оптимізації зовнішнього радіуса  $R2 = 0$ ;

6) побудова вкладеного контейнера класу з такими параметрами: центр контейнера  $x$ , внутрішній  $R1$  та зовнішній  $R2$  радіус вкладеної гіперсфери;

7) обчислення точнісних характеристик, обчислення обраного інформаційного КФЕ та перевірка на знаходження його в робочій області;

8) якщо  $R2 < N$ , то  $R2 = R2 + 1$  та перехід на пункт 5;

9) якщо  $R1 < R2$ , то  $R1 = R1 + 1$  та перехід на пункт 6;

10) процедура закінчується при знаходженні глобального максимуму інформаційного КФЕ в робочій області його визначення. Застосування вкладених контейнерів класів розпізнавання потребує модифікувати стандартний вигляд функції належності (3.6.1), оскільки вона повинна враховувати вплив двох контейнерів класів: того, що обрамляє контейнер класу, і того, який обрамляється цим контейнером. Зважаючи на можливість перетину вкладених контейнерів, в праці [60] запропонована трапецієвидна форма функції належності:

$$\mu_k(d) = \begin{cases} 0, & \text{якщо } d < R_1^{(k)}; \\ \frac{d - R_1^{(k)}}{R_2^{(k-1)} - R_1^{(k)}}, & \text{якщо } R_1^{(k)} \leq d < R_2^{(k-1)}; \\ 1, & \text{якщо } R_2^{(k-1)} \leq d < R_1^{(k+1)}; \\ \frac{d - R_1^{(k+1)}}{R_2^{(k)} - R_1^{(k+1)}}, & \text{якщо } R_1^{(k+1)} \leq d < R_2^{(k)}; \\ 0, & \text{якщо } d \geq R_2^{(k)}; \end{cases} \quad (3.4.1)$$

де  $R_1^{(k)}$  – внутрішній (найближчий до вершини одиничного вектора) радіус контейнера класу  $X_k^o$ ;

$R_2^{(k)}$  – зовнішній радіус контейнера класу  $X_k^o$ ;

$d$  – кодова відстань між одиничним вектором  $x_0$  та реалізацією, що розпізнається в процесі екзамену.

З урахуванням функції належності (3.4.1) розбиття  $\tilde{\mathfrak{R}}^{|M|}$  має структуру, показану на рис. 3.14.




Рисунок 3.14 – Графік функції належності реалізації, що розпізнається від її відстані до еталонного вектора  $x_0$

На рис. 3.14 фігурні дужки, зображені під віссю абсцис, показують області контейнерів кожного з класів. Функція належності зображена неперервною лінією. Кожний трапецієвидний інтервал відповідає функції належності окремого класу. Класи, контейнери яких знаходяться в центрі або зовні даної структури вкладених гіперсфер, характеризуються виродженою формою функції належності.

В праці [61] досліджено процес відновлення в просторі ознак розпізнавання  $\Omega_B$  вкладених контейнерів класів розпізнавання за наведеним в цьому підрозділі базовим інформаційно-екстремальним алгоритмом навчання СППР.

Алфавіт класів розпізнавання складався із чотирьох класів,: клас  $X_5^o$  – «відмінно»; клас  $X_4^o$  – «добре»; клас  $X_3^o$  – «задовільно»; клас  $X_2^o$  – «незадовільно». Вхідну навчальну матрицю для

словника із 48 ознак розпізнавання було одержану в процесі машинного тестування рівня знань студентів з навчальної дисципліни «Інтелектуальні системи» для спеціальності «Інформатика». При цьому початкова бінарна навчальна матриця формувалася СППР для СКД з параметром поля допусків  $\delta = \pm 5$  градацій 100-бальної оціночної шкали, а всі координати двійкового еталонного вектора  $x_0$  дорівнювали одиниці. У процесі навчання СППР перевірка основної гіпотези  $\gamma_1$  про належність вектора-реалізації образу, що подається на вхід СППР, до відповідного класу здійснювалася за вирішальними правилами (3.4.1).

Аналіз результатів оптимізації вкладених контейнерів за базовим алгоритмом показав, що оптимальним параметрам контейнерів відповідають такі максимальні значення КФЕ і точнісних характеристик навчання СППР:

$$\text{для класу } X_5^o - E_{\max}^{(5)} = 0,60 \ (D_{1,5} = 0,82 ; \beta_5 = 0,03) ;$$

$$\text{для класу } X_4^o - E_{\max}^{(4)} = 0,41 \ (D_{1,4} = 0,97 ; \beta_4 = 0,47) ;$$

$$\text{для класу } X_3^o - E_{\max}^{(3)} = 0,32 \ (D_{1,3} = 0,75 ; \beta_3 = 0,13) ;$$

$$\text{для класу } X_2^o - E_{\max}^{(2)} = 0,53 \ (D_{1,2} = 0,97 ; \beta_2 = 0,25) .$$

Оскільки максимальне усереднене значення нормованих ентропійних критеріїв ( $\bar{E} = 0,48$ ) і відповідні їм точнісні характеристики навчання СППР не досягають своїх граничних значень, то можна зробити висновок, що побудовані вирішальні правила не є безпомилковими за навчальною матрицею, що потребує оптимізації СКД на ознаки розпізнавання.

На рис. 3.15 показано графік залежності модифікації нормованого критерію Кульбака (2.5.4) від параметра  $\delta$  поля контрольних допусків, одержаний при відновленні вкладених контейнерів в процесі машинного навчання СППР з паралельною оптимізацією контрольних допусків на ознаки розпізнавання.










Рисунок 3.15 – Графік залежності усередненого КФЕ від параметра поля контрольних допусків

Аналіз рис.3.15 показує, що максимальне значення КФЕ в робочій області визначення його функції (2.4.5) дорівнює  $\overline{E}_{\max} = 0,62$ , а відповідно оптимальне значення параметра поля контрольних допусків дорівнює  $\delta^* = \pm 12$ .

На рис. 3.16 показано графіки залежності ентропійного КФЕ (2.5.2) від величин радіусів вкладених контейнерів класів розпізнавання, одержані в процесі навчання СППР за інформаційно-екстремальним алгоритмом при оптимальному значенні параметра  $\delta^* = \pm 12$  поля контрольних допусків на ознаки розпізнавання.






Рис. 3.16. - Графіки залежності ентропійного КФЕ від геометричних параметрів вкладених контейнерів класів в процесі оптимізації СКД:

$a$  – зовнішній радіус  $R_1^{(5)}$  класу  $X_5^o$ ;  $b$  – внутрішній радіус  $R_2^{(5)}$  класу  $X_5^o$ ;  $c$  – зовнішній радіус  $R_1^{(4)}$  класу  $X_4^o$ ;  $d$  – внутрішній радіус  $R_2^{(4)}$  класу  $X_4^o$ ;  $e$  – зовнішній радіус  $R_1^{(3)}$  класу  $X_3^o$ ;  $f$  – внутрішній радіус  $R_2^{(3)}$  класу  $X_3^o$ ;  $g$  – зовнішній радіус  $R_1^{(2)}$  класу  $X_2^o$ ;  $h$  – внутрішній радіус  $R_2^{(2)}$  класу  $X_2^o$

Аналіз результатів оптимізації (рис. 3.16) показує, що квазіоптимальними параметрами контейнера класу  $X_5^o$  є зовнішній радіус  $R_1^{(5)}=13$  і внутрішній радіус  $R_2^{(5)}=0$ ; контейнера класу  $X_4^o$  є зовнішній радіус  $R_1^{(4)}=15$  і внутрішній радіус  $R_2^{(4)}=13$ ; контейнера класу  $X_3^o$  є зовнішній радіус  $R_1^{(3)}=17$  і внутрішній радіус  $R_2^{(3)}=15$ ; контейнера класу  $X_2^o$  є зовнішній радіус  $R_1^{(2)}=23$  і внутрішній радіус  $R_2^{(2)}=17$ .



Квазіоптимальним параметрам контейнерів відповідають такі значення КФЕ і точнісних характеристик навчання СППР:

$$\text{для класу } X_5^o - E_{\max}^{(5)} = 0,62 (D_{1,5} = 0,90; \beta_5 = 0,05);$$

$$\text{для класу } X_4^o - E_{\max}^{(4)} = 0,49 (D_{1,4} = 0,88; \beta_4 = 0,10);$$

$$\text{для класу } X_3^o - E_{\max}^{(3)} = 0,36 (D_{1,3} = 0,82; \beta_3 = 0,15);$$

$$\text{для класу } X_2^o - E_{\max}^{(2)} = 0,48 (D_{1,2} = 0,93; \beta_2 = 0,17).$$

При цьому значення нормованого ентропійного КФЕ ( $\bar{E} = 0,62$ ) перевершує його значення, одержане за базовим алгоритмом ( $\bar{E} = 0,48$ ). Таким чином, відновлені вирішальні правила так само не є безпомилковими за навчальною матрицею. Одним із ефективних шляхів підвищення точності визначення глобального максимуму багато екстремальної функції інформаційного КФЕ навчання СППР є застосування алгоритму послідовної оптимізації контрольних допусків на ознаки розпізнавання. Але у рамках ІЕІ-технології з метою підвищення оперативності навчання доцільно застосувати алгоритм паралельно-послідовної оптимізації СКД на ознаки розпізнавання. При цьому квазіоптимальні контрольні допуски на ознаки розпізнавання, одержані за алгоритмом навчання СППР з паралельною оптимізацією СКД, приймемо як стартові для алгоритму навчання з їх послідовною оптимізацією.

Алгоритм навчання з послідовною оптимізацією СКД на ознаки розпізнавання було реалізовано за ітераційною процедурою (2.7.3). На рис. 3.17 показано динаміку зміни модифікованого ентропійного критерію (2.5.2) в процесі послідовної оптимізації СКД на ознаки розпізнавання




Рисунок 3.17 – Графік зміни усередненого ентропійного КФЕ при послідовній оптимізації СКД

Аналіз рис. 3.17 показує, що на восьмому прогоні ітераційної процедури оптимізації КФЕ досягає свого граничного значення  $\bar{E}_{\max} = 1$ , що свідчить про побудову безпомилкових за навчальною матрицею вирішальних правил. Тривалість навчання СППР дорівнює  $t = 700 c$ , що не є критичним, оскільки функціонування СППР в режимах машинного навчання і екзамену, як правило, відбувається в роздільному часі. На рис. 3.18 показано графіки залежності ентропійного КФЕ (2.5.2) від геометричних параметрів гіперсферичних вкладених контейнерів відповідних класів розпізнавання, одержані в результаті паралельно-послідовної оптимізації СКД на ознаки розпізнавання.

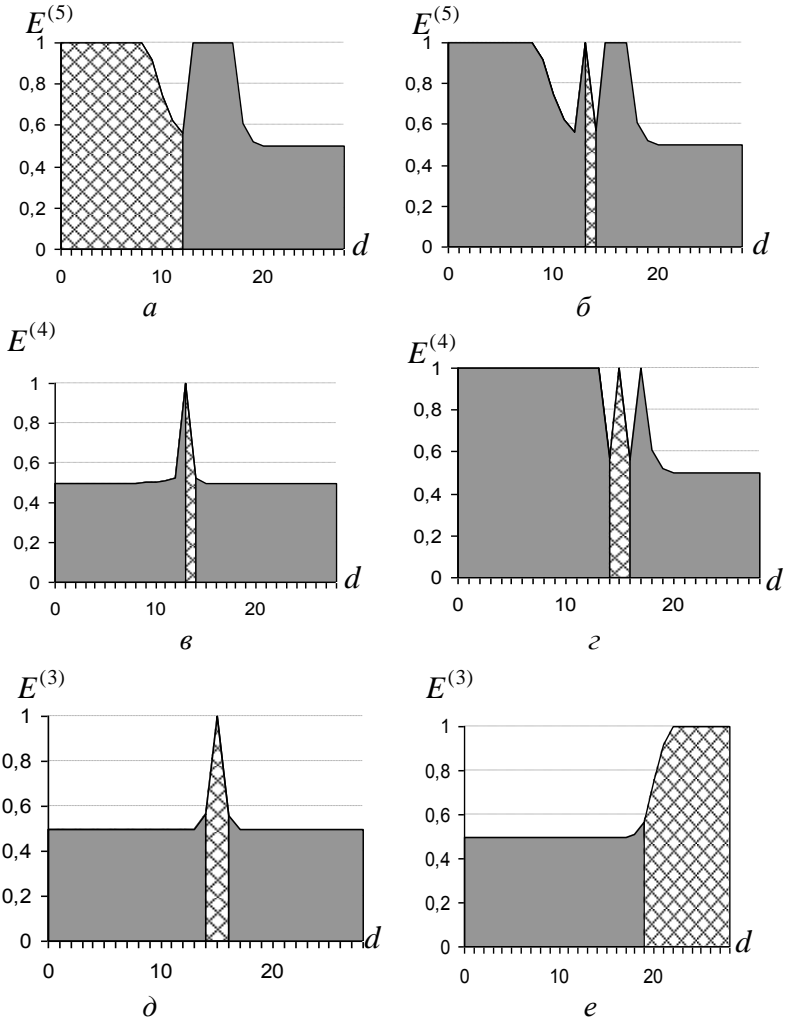


Рисунок 3.18 – Процес оптимізації радіусів вкладених контейнерів класів розпізнавання після послідовної оптимізації СКД: *a* – внутрішній радіус  $R_1^{(5)}$  класу  $X_5^o$ ; *b* – зовнішній радіус  $R_2^{(5)}$  класу  $X_5^o$ ; *c* – внутрішній радіус  $R_1^{(4)}$  класу  $X_4^o$ ; *d* – зовнішній

радіус  $R_2^{(4)}$  класу  $X_4^o$ ;  $\delta$  – внутрішній радіус  $R_1^{(3)}$  класу  $X_3^o$ ;  $\epsilon$  – зовнішній радіус  $R_2^{(2)}$  класу  $X_3^o$

Аналіз рис. 3.18 показує, що оптимальні радіуси контейнерів дорівнюють: для класу  $X_5^o$  – внутрішній радіус  $R_1^{(5)}=0$  і зовнішній радіус  $R_2^{(5)}=13$ ; для класу  $X_4^o$  – внутрішній радіус  $R_1^{(4)}=13$  і зовнішній радіус  $R_2^{(4)}=15$ ; для класу  $X_3^o$  – внутрішній радіус  $R_1^{(3)}=15$  і зовнішній радіус  $R_2^{(3)}=23$ . При цьому оптимальним параметрам контейнерів відповідають такі значення КФЕ і точнісних характеристик навчання СППР:

$$\text{- для класу } X_5^o - E_{\max}^{(5)} = 1 (D_{1,5} = 1; \beta_5 = 0);$$

$$\text{- для класу } X_4^o - E_{\max}^{(4)} = 1 (D_{1,4} = 1; \beta_4 = 0);$$

$$\text{- для класу } X_3^o - E_{\max}^{(3)} = 1 (D_{1,3} = 1; \beta_3 = 0);$$

$$\text{- для класу } X_2^o - E_{\max}^{(2)} = 1 (D_{1,2} = 1; \beta_2 = 0).$$

Таким чином, в процесі оптимізації параметрів функціонування СППР вдалося побудувати безпомилковий за навчальною матрицею класифікатор, який гарантує повну ймовірність правильного прийняття СППР рішень в режимі екзамену, наближену до достовірності висококваліфікованого викладача. При цьому необхідно мати на увазі, що хоч вкладені контейнери класів розпізнавання не перетинаються, але контейнери класів, які межують один з одним, мають однакові внутрішні та зовнішні радіуси. Тому у випадку, коли результати оцінювання знань слухачів відповідають таким граничним значенням, рішення приймається на користь студента, що відповідає сучасним дидактичним принципам.

### **3.5. Функціонування системи контролю знань в режимі кластер-аналізу результатів тестування**

При інформаційному аналізі і синтезі інтелектуальної СКЗ виникає необхідність формування апріорного розбиття простору ознак розпізнавання на класи, яке у процесі навчання корегується деяким оптимальним способом. Таку задачу розв'язує безпосередньо викладач, відносячи результати тестування до відповідної інтуїтивної оціночної шкали. Але оскільки при зростанні кількості студентів, вищий навчальний заклад при збереженні традиційної системи оцінок знань буде змушений для забезпечення навчального процесу збільшувати як матеріальні витрати, так і професорсько-викладацький склад, то задача розробки алгоритмів машинної оцінки знань студентів за методами сучасних прогресивних інтелектуальних технологій є актуальною.

Всі відомі методи кластер-аналізу характеризуються застосуванням дистанційних критеріїв схожості, які є частинними випадками узагальненої махаланобісової метрики (1.3.3). Застосування дистанційних критеріїв і статистичних показників не виключає ситуації, коли кластер можуть формувати геометрично близькі вектори-реалізації образу, але при цьому будуть суттєво відрізнятися між собою їх відповідні координати – значення ознак розпізнавання. Тому, наприклад, у працях [62,63] запропоновано підхід, що ґрунтується на виявленні у емпіричних даних об'єктивно існуючої функціональної закономірності. Такий підхід має ряд недоліків:

- висока обчислювальна трудомісткість, пов'язана із необхідністю оброблення великих масивів емпіричних даних;
- наявність апріорно чіткого розбиття, що не є характерним для більшості практичних задач контролю та керування;
- лінійний вигляд функції регресії, яка не у всіх випадках адекватно описує зв'язок.

Таким чином, аналіз існуючих сучасних методів кластер-аналізу дозволяє зробити такі два основні висновки:

а) методи кластер-аналізу, що виключають процес машинного навчання, характеризуються низькою достовірністю прийняття рішень відносно методів із навчанням;

б) відомі методи кластер-аналізу, що навчаються, не дозволяють побудувати безпомилковий за навчальною матрицею класифікатор, оскільки ігнорують перетин класів розпізнавання, тобто носять модельний характер.

Однією із перспективних технологій аналізу та синтезу адаптивних систем керування слабо формалізованими процесами є ІЕІ-технологія, що ґрунтується на реалізації принципу максимізації інформаційної спроможності системи шляхом введення в процесі оптимізації просторово-часових параметрів функціонування додаткових інформаційних обмежень з метою побудови в режимі навчання безпомилкового за навчальною матрицею класифікатора. Розглянемо формалізовану постановку задачі кластеризації даних в рамках ІЕІ-технології.

Нехай дано масив вхідних даних  $\{Y_{0,i}^{(j)} \mid i = \overline{1, N}; j = \overline{1, n}\}$ , де  $N$  – кількість ознак розпізнавання (результатів тестування в академічній групі, що атестується за поточний навчальний модуль дистанційного курсу);  $n$  – обсяг навчальної вибірки (кількість студентів, що тестуються),  $i$  відома потужність алфавіту класів розпізнавання  $\{Y_m^0 \mid m = \overline{1, M}\}$ .

Ефективність кластеризації даних будемо оцінювати інформаційним КФЕ  $E$ . Нехай за результатами тестового контролю сформовано некласифіковану навчальну матрицю типу «об'єкт-властивість»  $\|y_{0,i}^{(j)} \mid i = \overline{1, N}; j = \overline{1, n}\|$ , де (результатів тестування в академічній групі, що атестується за поточний навчальний модуль дистанційного курсу);  $N$  – обсяг навчальної вибірки (кількість студентів в групі за списком). При цьому відома потужність алфавіту

класів розпізнавання  $\{Y_m^0 | m = \overline{1, M}\}$ . Сформовано структурований вектор просторово-часових параметрів функціонування СКЗ:  $g = \langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1} \rangle$  з відповідними обмеженнями:  $R_{\xi_1}(g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}) \leq 0$ .

Треба у рамках ІЕІТ на етапі навчання СКЗ за результатами машинного тестування сформуванати апіорну нечітку класифіковану навчальну матрицю для  $M$  класів розпізнавання і побудувати оптимальні вирішальні правила шляхом цілеспрямованої трансформації апіорного нечіткого розбиття простору ознак на класи розпізнавання у чітке розбиття еквівалентності за умови, що усереднений за алфавітом класів інформаційний КФЕ машинного навчання СППР, набуває глобального максимуму в робочій області визначення його функції

$$E^* = \frac{1}{M} \sum_{m=1}^M \max_G E_m, \quad (3.5.1)$$

де

$E_m$  – КФЕ навчання системи розпізнавати реалізації класу  $X_m^o$ ;  
 $G$  – область допустимих значень параметрів функціонування СКНП.

Оскільки результат розв'язання задачі кластер-аналізу суттєво впливає на функціональну ефективність керування навчальним процесом, яка прямо залежить від достовірності оцінки рівня знань слухачів за результатами тестового контролю, то контур кластеризації даних доцільно інтегрувати в категорійну модель інформаційно-екстремального навчання СППР, як це показано на рис.3.19 [64].




Рисунок 3.19 – Діаграма відображення множин при інформаційно-екстремальному кластер-аналізі вхідних даних

Категорійна модель (рис. 3.19) містить оператор формування вибіркової неклаसифікованої навчальної матриці

$$\Phi : G \times T \times Z \times \Omega \rightarrow Y',$$

де  $G$  – простір вхідних сигналів (факторів), які діють на СКНП;

$T$  – множина моментів часу зняття інформації;

$Z$  – простір можливих станів системи контролю знань;

$\Omega$  – простір ознак розпізнавання;

$Y'$  – вибірка множини – вхідна некласифікована навчальна матриця.

Оператор  $\theta_1$  здійснює відображення некласифікованої навчальної матриці  $Y'$  в класифіковану матрицю  $Y$  шляхом визначення початкових координат центрів кластерів, використовуючи, наприклад, стратегію максимальної віддаленості центрів між собою, або їх рівномірного розподілу вздовж найбільшої вісі гіперкубу вхідних даних. Композиція операторів  $\theta_2 \circ \theta_3$  здійснює відображення навчальної матриці  $Y$  на розбиття  $\tilde{\mathfrak{R}}$  в двійковому



просторі Хеммінга шляхом агрегації двійкових векторів-реалізацій, котрі знаходяться в межах поточного радіусу гіперсферичного контейнера. Оператор  $n$  здійснює відображення поточного розбиття простору ознак контейнером кластеру  $X_m^o$  на множину  $N$ , що містить кількість агрегованих векторів-реалізацій для кожної ітерації циклу центрування контейнера кластеру  $X_m^o$ . Оператор  $d$  регламентує центрування та збільшення радіусу гіперсферичного контейнера кластеру. Центрування контейнера кластеру в бінарному просторі здійснюється за принципом “зсуву середнього” і триває до моменту стабілізації кількості векторів-реалізацій в ньому. Умовою зупинення нарощування радіусу є досягнення всередині контейнера необхідного обсягу  $n_m \geq n_{\min}$  векторів, які вилучаються з розгляду при побудові контейнера наступного кластера. Оператор  $\delta = \delta_1 \circ \delta_2$  та  $\sigma = \sigma_1 \circ \sigma_2$  цілеспрямовано змінюють систему контрольних допусків  $D$  на ознаки розпізнавання та простір ознак  $\Omega$  згідно з алгоритмом оптимізації словника ознак відповідно, оцінюючи їх вплив на КФЕ СППР. Композиція операторів  $m_1 \circ m_2$  замикає контур оптимізації кількості кластерів розбиття, та вибору базового кластера, відносно якого буде визначатися система контрольних допусків з відповідним переобчисленням бінарної матриці в процесі кожного кроку центрування. Оператор класифікації  $\Psi_H : \tilde{\mathfrak{R}}^{|M|} \rightarrow I^{|l|}$  перевіряє статистичну гіпотезу  $\gamma_1 : y_m^{(j)} \notin K_c^o$ , де  $y_m^{(j)}$  – вектор-реалізація, що належить кластеру  $X_m^o$ ,  $K_c^o$  – контейнер сусіднього кластера  $X_c^o$ ,  $I^{|l|}$  – множина  $l$  статистичних гіпотез. Оператор  $\gamma$  формує множину точнісних характеристик  $\mathfrak{S}^{|q|}$ , де  $q = l^2$ . Оператор  $\varphi$  обчислює терм-множину  $E$  значень інформаційного КФЕ, який є функціоналом точнісних характеристик. Оператор

$U_H : E \rightarrow G \times T \times \Omega \times Z$  регламентує процес самонавчання СППР.

Ітераційна процедура інформаційно-екстремального кластер-аналізу полягає у наближенні глобального максимуму інформаційного критерію якості розбиття до граничного його значення в допустимій області значень функції критерію і має структуру

$$\bar{E}^* = \max_{X_B^o \in \{X_m^o\}} \{ \max_{G_\delta} \{ \max_{G_{n_{\min}}} \bar{E} \} \}, \quad (3.5.2)$$

де  $X_B^o$  – кластер, що обирається за базовий, відносно якого визначається система контрольних допусків на ознаки розпізнавання;

$G_\delta$  – допустима область значень параметра поля контрольних допусків на ознаки розпізнавання  $\{\delta_i, i = \overline{1, N}\}$ ;

$G_{n_{\min}}$  – допустима область значень мінімальної кількості векторів-реалізацій в кластері .

Внутрішній цикл ітераційної процедури (3.5.2) реалізує дистанційний алгоритм кластер-аналізу даних в двійковому просторі Хеммінга – базовий алгоритм. Вхідні дані для базового алгоритму:  $M$  – кількість кластерів (класів) розбиття;  $\{y_i^{(j)} \mid j = \overline{1, n}; i = \overline{1, N}\}$  – масив реалізацій образу;  $\{\delta_i \mid i = \overline{1, N}\}$  – параметр поля контрольних допусків на  $i$ -ту ознаку розпізнавання;  $B$  – номер базового кластера  $X_B^o$ .

Розглянемо основні кроки реалізації базового алгоритму.

Крок 1. Обчислення початкових центрів кластерів в евклідовому просторі. Якщо це перший запуск базового алгоритму, або при попередніх запусках базового алгоритму відсутня робоча область визначення інформаційного КФЕ, то розрахунок початкових центрів здійснюють за правилом рівномірного розподілу центрів в гіперкубі вхідних даних

$$y_{mi} = y_i^{(j_1)} + \frac{m-1}{M-1} (y_i^{(j_2)} - y_i^{(j_1)}), \quad m = \overline{1, M}, \quad i = \overline{1, N}, \quad (3.5.3)$$

де  $y_i^{(j_1)}$ ,  $y_i^{(j_2)}$  – два найбільш віддалені в евклідовій метриці вектори-реалізації, що належать вхідній неклассифікованій матриці  $\{y_i^{(j)}\}$ .

У протилежному випадку вже існує розбиття даних на кластери і початкові координати центру кожного кластера можна визначити як вибіркове середнє значення  $i$ -ї ознаки у векторах-реалізаціях кластера

$$y_{m,i} = \frac{1}{n_m} \sum_{j=1}^{n_m} y_{m,i}^{(j)}, \quad m = \overline{1, M}, \quad i = \overline{1, N}. \quad (3.5.4)$$

Крок 2. Зміна нумерації центрів кластерів таким чином, щоб центр базового кластера нумерувався першим, тобто  $X_1^o \leftrightarrow X_B^o$ .

Крок 3. Ініціалізація лічильника кластерів:  $m := 0$ .

Крок 4.  $m := m + 1$ .

Крок 5. Якщо  $m = 1$  (базовий кластер), то обчислюються нижній  $A_{HK,i}$  та верхній  $A_{BK,i}$  контрольні допуски для кожної ознаки розпізнавання за формулами

$$A_{HK,i} = \begin{cases} y_{1,i} \left( 1 - \frac{\delta_i}{\delta_{\max}} \right), & \text{if } y_{1,i} \left( 1 - \frac{\delta_i}{\delta_{\max}} \right) \leq A_{H,i}; \\ A_{H,i}, & \text{if else;} \end{cases} \quad (3.5.5)$$

$$A_{BK,i} = \begin{cases} y_{1,i} \left( 1 + \frac{\delta_i}{\delta_{\max}} \right), & \text{if } y_{1,i} \left( 1 + \frac{\delta_i}{\delta_{\max}} \right) \geq A_{B,i}; \\ A_{B,i}, & \text{if else.} \end{cases} \quad (3.5.6)$$

Крок 6. Формування бінарної матриці вхідних даних  $\|x_i^{(j)}\|$  здійснюється за правилом

$$x_i^{(j)} = \begin{cases} 1, & \text{if } A_{HK,i} \leq y_i^{(j)} \leq A_{BK,i}; \\ 0, & \text{if else.} \end{cases} \quad (3.5.7)$$

Крок 7. Обчислення значень координат двійкового еталонного вектора  $x_m$ . При цьому у випадку наявності розбиття даних (кластер  $X_m^o$  містить  $n_m$  агрегованих векторів-реалізацій) обчислення здійснюють за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n_m} \sum_{j=1}^{n_m} x_{m,i}^{(j)} > 0,5; \\ 0, & \text{if else.} \end{cases} \quad (3.5.8)$$

У протилежному випадку – за правилом

$$x_{m,i} = \begin{cases} 1, & \text{if } A_{HK,i} \leq y_{m,i} \leq A_{BK,i}; \\ 0, & \text{if else} \end{cases} \quad (3.5.9)$$

Крок 8. Ініціалізація лічильника кроків зміни радіуса контейнера кластеру  $X_m^o$ :  $d_m := 0$ .

Крок 9.  $d_m := d_m + 1$ .

Крок 10. Ініціалізація динамічного масиву  $A_{n,m}$ , що зберігає значення  $n_m$  для кожної ітерації центрування кластера  $X_m^o$ , і початок центрування контейнера кластера.

Крок 11. Додавання в динамічний масив  $A_{n,m}$  поточного значення  $n_m$ .

Крок 12. Очищення розмітки векторів-реалізацій кластера  $X_m^o$  для здійснення нової розмітки.

Крок 13. Об'єднання в кластер некластеризованих двійкових векторів-реалізацій, для яких виконується умова  $d(x_m \oplus x^{(j)}) \leq d_m$ , де  $d(x_m \oplus x^{(j)})$  – кодова відстань Хеммінга між двійковими векторами  $x_m$  і  $x^{(j)}$ .

Крок 14. Обчислення нового центру кластера  $X_m^o$  в евклідовому просторі за формулою (3.5.4).

Крок 15. Порівняння: якщо  $m=1$  (базовий кластер), то здійснити обчислення верхніх та нижніх контрольних допусків за формулами (3.5.5) і (3.5.6) та бінарної матриці вхідних даних за правилом (3.5.7).

Крок 16. Обчислення двійкового еталонного вектора  $x_m$  за правилом (3.5.8).

Крок 17. Порівняння: якщо в динамічному масиві  $A_{n_m}$  не зустрічається значення  $n_m$ , що відповідає новому об'єднанню векторів-реалізацій в кластер, то здійснюється перехід до пункту

11, інакше – перехід до кроку 18 для зупину центрування кластера  $X_m^o$  з метою уникнення автоколивального процесу.

Крок 18. Порівняння: якщо  $d_m < N$ , то перехід до кроку 19, інакше – до кроку 20.

Крок 19. Порівняння: якщо  $n_m \geq n_{\min}$  то перехід до кроку 20, інакше – до кроку 9.

Крок 20. Порівняння: якщо  $m < M$ , то перехід до кроку 6, інакше – до кроку 21.

Крок 21. Обчислення усередненого інформаційного КФЕ  $\bar{E}$  (3.5.1) і ЗУПИН.

Оптимізація вибору базового кластера  $X_B^o \in \{X_m^o\}$  та мінімальної кількості векторів-реалізацій в кластері  $40 < n_{\min} < [n/M]$  здійснюється шляхом пошуку глобального максимуму КФЕ в робочій області визначення його функції. При цьому, збільшуючи з певним кроком  $n_{\min}$  на етапі паралельної оптимізації параметра поля контрольних допусків  $\delta_i$  може бути відсутня робоча область КФЕ. В такому разі як квазіоптимальне значення параметра  $\delta_i$  для алгоритму послідовної оптимізації можна використати вектор  $\{\delta_i, i = \overline{1, N}\}$  з попереднього кроку за умови вибору того самого базового кластера. Вибір значення  $n_{\min}$  впливає на ступінь узагальнення вхідних даних їх мультимодальним розбиттям і на кількість некластеризованих даних. Одночасна оптимізація  $M$  та  $n_{\min}$  здійснює оптимальне розбиття на кластери з однаковим ступенем узагальнення даних.

Як КФЕ кластеризації розглянемо модифікацію інформаційної міри Кульбака у вигляді

$$E_m^{(k)} = \left[ P_{1,m}^{(k)} - P_{f,m}^{(k)} \right] \cdot \log_2 \frac{P_{1,m}^{(k)}}{P_{f,m}^{(k)}} = \left[ \begin{array}{l} P_{1,m}^{(k)} = p(\mu_1) \cdot D_{1,m}^{(k)} + p(\mu_2) \cdot D_{2,m}^{(k)} \\ P_{f,m}^{(k)} = p(\mu_1) \cdot \alpha_m^{(k)} + p(\mu_2) \cdot \beta_m^{(k)} \\ p(\mu_1) = p(\mu_2) = 0,5 \\ \alpha_m^{(k)} = 1 - D_{1,m}^{(k)} = 0; D_{2,m}^{(k)} = 1 - \beta_m^{(k)} \end{array} \right] =$$

$$= \left[ D_{1,m}^{(k)} - \beta_m^{(k)} \right] \cdot \log_2 \left( \frac{1 + (D_{1,m}^{(k)} - \beta_m^{(k)})}{1 - (D_{1,m}^{(k)} - \beta_m^{(k)})} \right), \quad (3.5.10)$$

де  $D_{1,m}^{(k)}$  – перша достовірність, обчислена для  $m$ -го кластера на  $k$ -му кроці оптимізації параметрів СППР;

$D_{2,m}^{(k)}$  – друга достовірність;

$\alpha_m^{(k)}$  – помилка першого роду;

$\beta_m^{(k)}$  – помилка другого роду.

Оскільки при кластер-аналізі завжди перша достовірність дорівнює  $D_{1,m}^{(k)} = 1,0$ , то формула КФЕ (3.5.10) набуває остаточного вигляду

$$E_m^{(k)} = \left[ 1 - \beta_m^{(k)} \right] \cdot \log_2 \left( \frac{2 - \beta_m^{(k)}}{\beta_m^{(k)}} \right). \quad (3.5.11)$$

Важливого значення при кластеризації вхідних даних набуває застосування зовнішньої валідації її результатів, що дозволяє виявити відсутність нав'язування реальним даним невласивої для них кластерної структури або відмовитися від обраного методу кластер-аналізу. Це особливо актуально для складних розподілів векторів-реалізацій, які важко аналізувати традиційними прийомами розвідувального аналізу. Тому розглянемо обчислювальний аспект критерію зовнішньої валідації – статистики Ренда. За цим

критерієм порівняння заданого розбиття вхідних даних  $P$  з незалежною від нього структурою кластерів  $C$ , отриманою в результаті кластеризації вхідних даних, здійснюється шляхом підрахунку кількості пар точок даних  $y^{(t)}$ ,  $y^{(l)}$  з множини вхідних даних  $\{y^{(j)} | j = \overline{1, n}\}$ , розглядаючи чотири різних випадки в залежності від способу розміщення  $y^{(t)}$  і  $y^{(l)}$  в множинах  $C$  і  $P$ :

1)  $y^{(t)}$  і  $y^{(l)}$  належать до одного кластеру структури  $C$  і до одного класу розбиття  $P$ ;

2)  $y^{(t)}$  і  $y^{(l)}$  належать до одного кластеру структури  $C$ , але до різних класів з розбиття  $P$ ;

3)  $y^{(t)}$  і  $y^{(l)}$  належать до різних кластерів структури  $C$ , але до одного класу з розбиття  $P$ ;

4)  $y^{(t)}$  і  $y^{(l)}$  належать до різних кластерів структури  $C$  і до різних класів з розбиття  $P$ .

Число пар точок в цих чотирьох випадках позначають як  $a$ ,  $b$ ,  $c$  та  $d$  відповідно. Тоді статистика Ренда  $R$ , яка знаходиться в діапазоні  $[0, 1]$ , обчислюється за формулою

$$R = \frac{a+d}{a+b+c+d} . \quad (3.5.12)$$

Як видно з виразу (3.5.12), чим більші значення індексу валідації, тим більш схожі між собою структура  $C$  і розбиття  $P$ .

Запропоновані алгоритми реалізовано при синтезі інтелектуальної СКЗ при оцінюванні знань студентів з навчальної дисципліни «Інтелектуальні системи», що викладається в Сумському державному університеті. Загальна кількість тестів, яка визначала потужність словника ознак розпізнавання, дорівнювала  $N = 30$ . При цьому обсяг реалізацій рівнів знань



становив 360 векторів, що дорівнювало кількості тестових запитань. Класи розпізнавання (рівні знань) на практиці перетинаються, як це показано на попарних проєкціях перших чотирьох головних компонент апіорно класифікованої викладачем матриці результатів тестування (рис. 3.20). Червоним кольором відмічено рівень знань клас  $X_1^o$  – «Незадовільно», темно-бірюзовим кольором відмічено клас  $X_2^o$  – «Задовільно», синім – клас  $X_3^o$  – «Добре», світло-бірюзовим – клас  $X_4^o$  – «Відмінно».

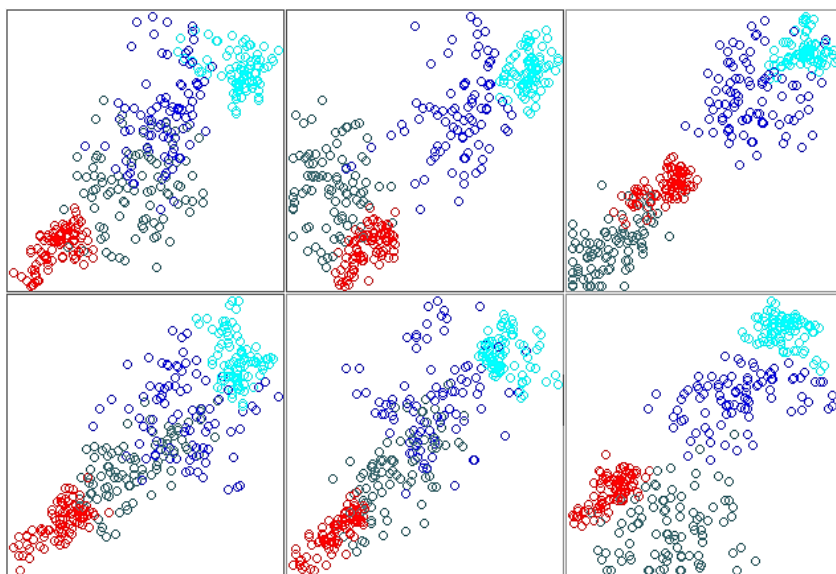


Рисунок 3.20 – Попарні проєкції перших чотирьох головних компонент на площину

Аналіз рис. 3.20 дозволяє вибрати такі вхідні параметри алгоритму кластер-аналізу:

- кількість кластерів розбиття  $M = 4$ ;
- початкова мінімальна кількість векторів-реалізацій  $n_{\min} = 80$ , яка залежить від максимально допустимого відсотку некластеризованих даних  $C = 11\%$  і може збільшуватися в процесі кластер-аналізу.

За базовий кластер спочатку було прийнято  $X_B^o \leftrightarrow X_1^o$ . На рис. 3.21 показано процес оптимізації поля контрольних допусків при заданих обмеженнях.




Рисунок 3.21 – Графіки зміни КФЕ (3.5.12) та індексу Ренда в процесі кластеризації з паралельною оптимізацією контрольних допусків на ознаки розпізнавання

Аналіз рис. 3.21 показує, що на етапі паралельної оптимізації СКД було отримано квазіоптимальне значення параметра  $\delta_i = 32$  поля контрольних допусків, при якому КФЕ приймає максимальне значення  $\bar{E}^* = 0,602$ . При цьому індекс Ренда становить  $R = 0,93$ .

На рис. 3.22 показано процес одного прогону ( $L=1$ ) при реалізації алгоритму кластеризації з послідовною оптимізацією поля контрольних допусків на ознаки розпізнавання.






Рисунок 3.22 – Графіки зміни КФЕ та індексу Ренда за один прогін процедури послідовної оптимізації поля контрольних допусків на ознаки розпізнавання

Аналіз рис. 3.22 показує, що алгоритму послідовної оптимізації поля контрольних допусків, який стартував при  $\delta_i = \pm 32$ , вже на першому прогоні на ітерації  $k = 1834$  вдалося побудувати безпомилкові вирішальні правила, оскільки нормований усереднений КФЕ приймає значення  $\bar{E}^* = 1,0$ . При цьому індекс Ренда становить  $R = 0,94$ .


Процес центрування та нарощування радіусів контейнерів при оптимальних контрольних допусках показано на рис. 3.23. При цьому верхній рядок позначень вісі абсцис показує кількість векторів–реалізацій, що входять в побудовані кластери, а нижній – радіуси контейнерів кластерів.



*a*



*b*



*c*




Рисунок 3.23 – Графіки зміни кількості векторів-реалізацій при збільшенні радіусу контейнерів та їх центруванні:  
*a* – кластер  $X_1^o$ ; *b* – кластер  $X_2^o$ ; *v* – кластер  $X_3^o$ ; *z* – кластер  $X_4^o$

Результати аналізу рис. 3.23 зведено в табл. 3.2 і табл. 3.3.

Таблиця 3.2 – Значення радіусів контейнерів кластерів і кількість охоплених ними векторів-реалізацій

$X_m^o$	$X_1^o$	$X_2^o$	$X_3^o$	$X_4^o$
$d_m$	4	8	9	7
$n_m$	85	81	80	95

Таблиця 3.3 – Кодові відстані між еталонними векторами кластерів

	$x_1$	$x_2$	$x_3$	$x_4$
$x_1$	0	15	14	28
$x_2$	15	0	15	15
$x_3$	14	15	0	14
$x_4$	28	15	14	0

Таким чином, згідно з концептуальними принципами ІЕІ-технології інформаційно-екстремальна кластеризації вхідних даних полягає в реалізації допустимих перетворень безпосередньо в субпарацептуальному бінарному просторі ознак розпізнавання. Це гарантує формування нечіткої навчальної матриці, відображення якої в бінарний простір забезпечує побудову чітких та завадозахищених вирішальних правил. Крім того, порівняно з кластеризацією даних в неперервному Евклідовому просторі зменшується обчислювальна складність при збільшенні потужності алфавіту класів та розмірності словника ознак. При цьому один з кластерів обирається за базовий, відносно центру якого визначають контрольні допуски на ознаки розпізнавання. Розбиття простору ознак на кластери здійснюється починаючи з визначення стартових центрів кластерів, які потім уточнюються за правилом “зсуву середнього” в процесі зростання радіусу контейнера. При цьому центрування зміщених кластерів полягає в стабілізації кількості векторів-реалізацій, охоплених оболонкою контейнера. Процес зростання радіусу контейнера кластеру зупиняється при досягненні заданого репрезентативного обсягу векторів-реалізацій  $n_m \geq n_{\min}$ .

В результаті кластеризації даних за інформаційно-екстремальним алгоритмом вдалося побудувати чітке розбиття простору ознак на кластери, практично ідентичне розбиттю, побудованому в бінарному просторі ознак розпізнавання за апіорно класифікованою навчальною матрицею, що містить аналогічні реалізації кластерів.

Таким чином, доведено ефективність застосування ідей і методів ІЕІ-технології для автоматизації формування вхідного математичного опису СКЗ, побудованої на основі машинного навчання та розпізнавання образів і яка є центральною підсистемою інтелектуальної АСКНП.

### 3.6. Побудова гіпереліпсоїдного класифікатора

У випадку значної витягнутості розподілу реалізацій образів ефективність розпізнавання за гіперсферичними вирішальними правилами може бути збільшена за умови переходу до побудови гіпереліпсоїдних контейнерів класів розпізнавання. При цьому з метою зменшення обчислювальної трудомісткості алгоритму навчання СППР доцільно здійснювати таку побудову шляхом деформації оптимального гіперсферичного контейнера в напрямі розподілу реалізацій образу. Відновлений в процесі навчання гіпереліпсоїд обертання будемо описувати твірним еліпсом з довжиною великої півосі, що дорівнює радіусу оптимального гіперсферичного контейнера, та деякою оптимальною віссю обертання твірного еліпса, на якій знаходяться його фокуси, рівновіддалені від центру гіперсферичного контейнера (рис. 3.24). При цьому оптимізації підлягають як орієнтація осі, на якій знаходяться фокуси, в багатовимірному двійковому просторі Хеммінга, так і ексцентриситет твірного еліпса. Такого роду оптимізацію за інформаційним КФЕ геометричних параметрів гіпереліпсоїдних контейнерів класів розпізнавання, що відновлюються в радіальному базисі субпарацептуального бінарного (за Хеммінгом) простору ознак розпізнавання, можна розглядати як узагальнення і модифікацію методу головних компонент [28] шляхом переходу від гомоморфних проєкцій реалізацій образів на координатні вісі до їх ізоморфних проєкцій на ядра класів розпізнавання.




Рисунок 3.24 – До побудови гіпереліпсоїдного контейнера

В праці [64] задача оптимізації параметрів гіпереліпсоїдного контейнера класу  $X_m^o$  зводиться до пошуку оптимальної пари фокусів  $\langle x_{m1}, x_{m2} \rangle^*$ , при яких зменшується, або повністю усувається перетин класів розпізнавання і як наслідок зростає значення КФЕ навчання СППР.

Алгоритм побудови гіпереліпсоїдного вирішального правила для класу  $X_m^o$  можна подати у вигляді ітераційної процедури оптимізації фокусної відстані  $d(x_{m1} \oplus x_{m2})$  шляхом цілеспрямованого пошуку глобального максимуму КФЕ навчання в робочій області визначення його функції:

$$d(x_{m1} \oplus x_{m2})^* = \arg \{ \max_{G_p} \{ \max_{G_\delta} \{ \max_{G_d} E_m^* \} \} \}, \quad (3.6.1)$$

де

$G_p$  – допустима область значень координат фокусів гіпереліпсоїдного контейнера класу  $X_m^o$ ;



$G_\delta$  – допустима область значень параметра поля допусків  $\delta$  для класифікатора з гіперсферичними контейнерами;

$G_d$  – допустима область значень параметра радіусу гіперсферичного контейнера класу  $X_m^o$ .

Як фокуси гіпереліпсоїдного контейнера в  $N$ -вимірному бінарному просторі можуть виступати точки  $x_m^{(v)}$ , віддалені від двійкового еталонного вектора  $x_m$  на фокальну відстань  $c_m = d(x_m \oplus x_m^{(v)})$ , утворюючи множину  $\{x_m^{(v)} \mid v = \overline{1, V}\}$ , де  $V = C_N^{c_m}$ . Розбиття множини векторів  $\{x_m^{(v)}\}$  на  $P$  пар фокусів  $\{X_{m,p}^{[2]} = \langle x_{m1}^{(p)}, x_{m2}^{(p)} \rangle \mid p = \overline{1, P}\}$  здійснюється виходячи з умови  $d(x_{m1}^{(p)} \oplus x_{m2}^{(p)}) = 2c_m$ , яка забезпечує фіксацію вектора  $x_m$  як центру гіпереліпсоїдного контейнера. Однак в цьому випадку для невеликих значень  $c_m$  і відносно великих  $N$  отримаємо надлишково велику кількість пар фокусів, що може призвести до значного зменшення оперативності алгоритму. Крім того, при  $c_m > N/2$  не можна утворити жодної пари фокусів. Тому на практиці можна формувати не повну множину точок потенційних фокусів  $\{x_m^{(v)} \mid v = \overline{1, N}\}$ , утворену шляхом послідовних  $N$  зсувів вліво на один розряд операції інверсії над послідовно розміщеними  $c_m$  розрядами в еталонному векторі  $x_m$ , враховуючи обмеження  $c_m \leq N/2$ . В результаті ітераційна процедура пошуку оптимальної пари фокусів набуває вигляду

$$d(x_{m1} \oplus x_{m2})^* = \arg \left\{ \max_{\{c\}} \left\{ \max_{\{p\}} E_m^* \{d[x_{m1}^{(p)} \oplus x_{m2}^{(p)}]\} \right\} \right\}. \quad (3.6.2)$$

Робоча область обчислення інформаційного КФЕ оптимізації гіпереліпсоїдних контейнерів класів розпізнавання обмежується як загальними для ІЕІ-технології умовами  $D_1 \geq 0,5$  і  $D_2 \geq 0,5$ , так і специфічними умовами

$$\begin{aligned} & d(x_{c1} \oplus x) + d(x_{c2} \oplus x) - 2c_c > 0, \\ & \forall x \in \{x : d(x_{m1} \oplus x) + d(x_{m2} \oplus x) \leq 2d_m\}, \\ & (\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}) (\forall X_c^o \in \tilde{\mathfrak{R}}^{|M|}) (X_m^o \neq X_c^o), \end{aligned}$$

де

$d(x_{c1} \oplus x)$ ,  $d(x_{c2} \oplus x)$  – кодові відстані Хеммінга від двійкового вектора  $x$  до першого та другого фокусів контейнера класу  $X_c^o$  відповідно;

$d(x_{m1} \oplus x)$ ,  $d(x_{m2} \oplus x)$  – кодові відстані Хеммінга від двійкового вектора  $x$  до першого та другого фокусів контейнера класу  $X_m^o$  відповідно;

$c_c$  – фокальна відстань гіпереліпсоїдного контейнера класу  $X_c^o$ ;

$d_m$  – довжина великої півосі гіпереліпсоїдного контейнера класу  $X_m^o$ .

Належність двійкового вектора-реалізації до гіпереліпсоїдного контейнера класу  $X_m^o$  визначається за умови

$$\begin{aligned} & \text{if } d(x_{m1} \oplus x^{(j)}) + d(x_{m2} \oplus x^{(j)}) \leq 2d_m \\ & \text{then } x^{(j)} \in X_m^o \text{ else } x^{(j)} \notin X_m^o, \end{aligned} \quad (3.6.3)$$

де

$d(x_{m1} \oplus x^{(j)})$ ,  $d(x_{m2} \oplus x^{(j)})$  – кодові відстані між вектором  $x^{(j)}$

і першим та другим фокусами контейнера класу  $X_m^o$  відповідно;  
 $d_m$  – значення великої півосі контейнера класу  $X_m^o$ .

Алгоритм екзамену для гіпереліпсоїдного класифікатора базується на аналізі значень функції належності реалізації образу, що розпізнається, контейнеру класу  $X_m^o$ , яка обчислюється за формулою

$$\mu_m = 1 - \frac{d(x_{m1}^* \oplus x^{(j)}) + d(x_{m2}^* \oplus x^{(j)}) - d(x_{m1}^* \oplus x_{m2}^*)}{2d_m^* - d(x_{m1}^* \oplus x_{m2}^*)}, \quad (3.6.4)$$

де

$d(x_{m1}^* \oplus x^{(j)})$ ,  $d(x_{m2}^* \oplus x^{(j)})$  – кодові відстані між реалізацією образу, що розпізнається, і оптимальними першим та другим фокусами контейнера класу  $X_m^o$  відповідно;

$d(x_{m1}^* \oplus x_{m2}^*) = 2c_m^*$  – оптимальна міжфокусна відстань контейнера класу  $X_m^o$ ;

$d_m^*$  – оптимальне значення великої півосі контейнера класу  $X_m^o$ .

Для побудови гіпереліпсоїдного класифікатора, який є узагальненням гіперсферичного, важливе значення має така теорема.

Теорема 3.1. Для того, щоб гіпереліпсоїдний контейнер з фокусами  $x_{m1}$  та  $x_{m2}$  був вписаний у свій початковий гіперсферичний контейнер з центром в точці  $x_m$  та радіусом  $d_m$  за умов

$$d(x_m \oplus x_{m1}) = d(x_m \oplus x_{m2}) = c_m;$$

$$d(x_{m1} \oplus x_{m2}) = 2c_m;$$

$$c_m < \frac{1}{2}d_m$$

необхідно та достатньо, щоб велика піввісь твірного еліпса дорівнювала  $d_m - c_m$ .

Виконання умови теореми 3.1 обумовлює використання правила для визначення належності реалізацій  $x^{(j)}$  до гіпереліпсоїдного контейнера вигляду:

$$\begin{aligned} & \text{if } d(x_{m1} \oplus x^{(j)}) + d(x_{m2} \oplus x^{(j)}) \leq 2(d_m - c_m) \\ & \text{then } x^{(j)} \in X_m^o \text{ else } x^{(j)} \notin X_m^o. \end{aligned}$$

Перехід від гіперсферичних вирішальних правил до гіпереліпсоїдних дозволяє підвищити КФЕ навчання та збільшити місткість двійкового простору ознак розпізнавання за рахунок побудови більш точних контейнерів класів розпізнавання порівняно з гіперсферичними. Однак, щоб уникнути зниження оперативності навчання внаслідок ускладнення форми контейнерів класів розпізнавання на початковому етапі навчання здійснюється оптимізація генотипних параметрів при використанні гіперсферичних контейнерів. При цьому отримані гіперсферичні контейнери розглядаються як квазіоптимальні і є стартовими габаритами, в межах яких здійснюється пошук фокусів оптимальних гіпереліпсоїдних контейнерів. Такий процес можна розглядати як корекцію геометричних параметрів початкових вирішальних правил при незмінному словнику ознак розпізнавання та незмінних контрольних допусках, що задаються для ознак розпізнавання.

В праці [64] наведено основні етапи реалізації алгоритму гіпереліпсоїдної корекції вирішальних правил, що відновлюються в бінарному просторі ознак розпізнавання:

Крок 1. Ініціалізація лічильника класів розпізнавання:  $m := 0$ .

Крок 2.  $t := t + 1$ .

Крок 3. Ініціалізація лічильника кроків зміни фокального радіусу:  $c_m := 0$ .

Крок 4.  $c_m := c_m + 1$ .

Крок 5. Формування множини потенційних фокусів  $\{x_m^{(v)} \mid v = \overline{1, V}\}$ , що задовольняють умові  $d(x_m \oplus x_m^{(v)}) = c_m$ , де  $c_m$  – фокальна відстань, а  $x_m$  – еталонний вектор класу  $X_m^o$ .

Крок 6. Розбиття множини векторів  $\{x_m^{(p)}\}$  на  $P$  пар фокусів  $\langle x_{m1}^{(p)}, x_{m2}^{(p)} \rangle \mid p = \overline{1, P}\}$ , що задовольняють умову  $d(x_{m1}^{(p)} \oplus x_{m2}^{(p)}) = 2c_m$ .

Крок 7. Ініціалізація лічильника пар фокусів:  $p := 0$ .

Крок 8.  $p := p + 1$ .

Крок 9. Ініціалізація фокусів контейнера  $\langle x_{m1}, x_{m2} \rangle := \langle x_{m1}^{(p)}, x_{m2}^{(p)} \rangle$ .

Крок 10. Обчислення точнісних характеристик  $D_{1,m}$  і  $\beta_m$ , прийнявши за сусідній клас  $X_c^o$  сукупність реалізацій  $\{x_c^{(j)} \mid j = \overline{1, n_m}\} \in \left[ \bigcup_{k=1}^M X_k^o \right] \setminus X_m^o$ , що мають мінімальне значення суми  $d(x_{m1} \oplus x^{(j)}) + d(x_{m2} \oplus x^{(j)})$ , обчислення інформаційного КФЕ навчання  $E_m$  за формулою (3.5.6).

Крок 11. Порівняння: якщо  $p < P$ , то виконується крок 8, інакше – крок 12.

Крок 12. Визначення оптимальної пари фокусів контейнера класу  $X_m^o$  :

$$\langle x_{m1}, x_{m2} \rangle^* = \arg \max_{\{p\}} E_m^* (\langle x_{m1}^{(p)}, x_{m2}^{(p)} \rangle)$$

Крок 13. Якщо  $c_m < d_m^e / 2$ , то виконується крок 4, інакше – крок 14.

Крок 14. Визначення оптимального значення фокальної відстані:

$$c_m^* = \arg \max_{\{c_m\}} E_m^* .$$

Крок 15. Якщо  $m < M$ , то виконується крок 2, інакше – крок 16.

Крок 16. ЗУПИН.

В праці [64] доведено, що застосування гіпереліпсоїдного класифікатора при деформованих нормальних розподілах, що є характерним при контролі знань, суттєво підвищує оперативність побудови безпомилкових за навчальною матрицею вирішальних правил. Так, наприклад, показано, якщо для гіперсферичного класифікатора безпомилкові вирішальні правила було побудовано після реалізації паралельно-послідовного алгоритму оптимізації контрольних допусків на ознаки розпізнавання, то при використанні гіпереліпсоїдного класифікатора – вже після реалізації алгоритму паралельної оптимізації СКД.

Таким чином, перехід від гіперсферичного класифікатора до гіпереліпсоїдного є подальшим узагальненням інформаційно-екстремального методу навчання СППР, яке дозволяє будувати безпомилкові за навчальною вибіркою вирішальні правила для апріорних розподілів реалізацій образів довільної конфігурації.

### 3.7. Архітектура та функції адаптивної системи керування навчальним процесом

В Сумському державному університеті групою співробітників розроблено в рамках ІЕІ-технології інформаційне та програмне забезпечення адаптивної АСКНП. Основою адаптивної АСКНП є здатна навчатися СППР, основними функціями якої є оцінка поточного рівня знань студентів та адаптація навчального контенту дисципліни. Для побудови адаптивної СКДН було використано такі сучасні рішення, як використання уніфікованого програмного інтерфейсу для передачі даних між функціональними блоками системи та визначення контексту документа згідно з його змістом та призначенням блоку, який його обробляє. Розширене використання паттерну Inversion of Control та Model-View-Control дозволило створити гнучку, стабільну та зручну платформу для розробки АСКНП. На рис. 3.25 показано інтерфейс СППР, здатної навчатися в машинному режимі.

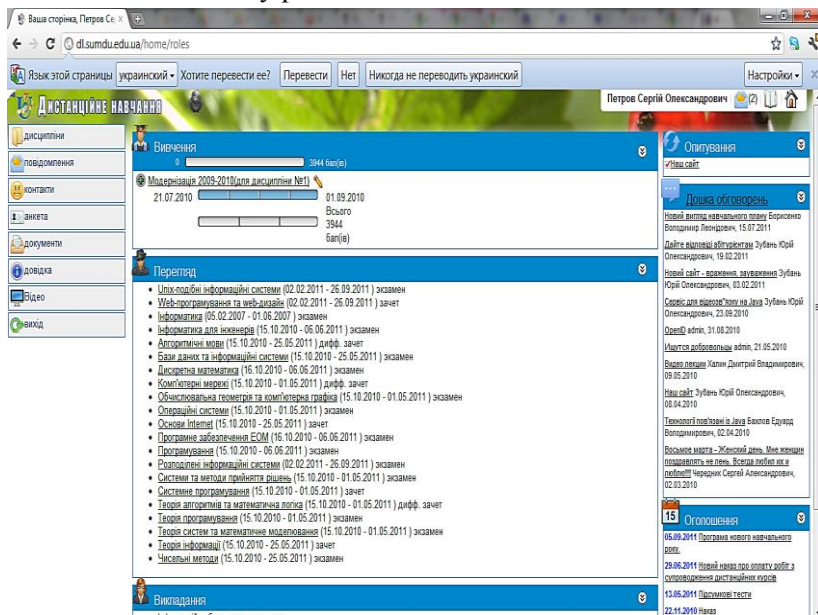


Рисунок 3.25 – Web - Інтерфейс адаптивної АСКНП

Показаний на рис. 3.25 інтерфейс містить інформацію, щодо наявних дисциплін, які закріплені за викладачем, з механізмом розподілу доступу до них. При цьому реалізовано механізм внутрішньої комунікації між користувачами системи. Інтелектуальна складова СКНП реалізується під час формування структури дистанційного курсу (рис. 3.26).

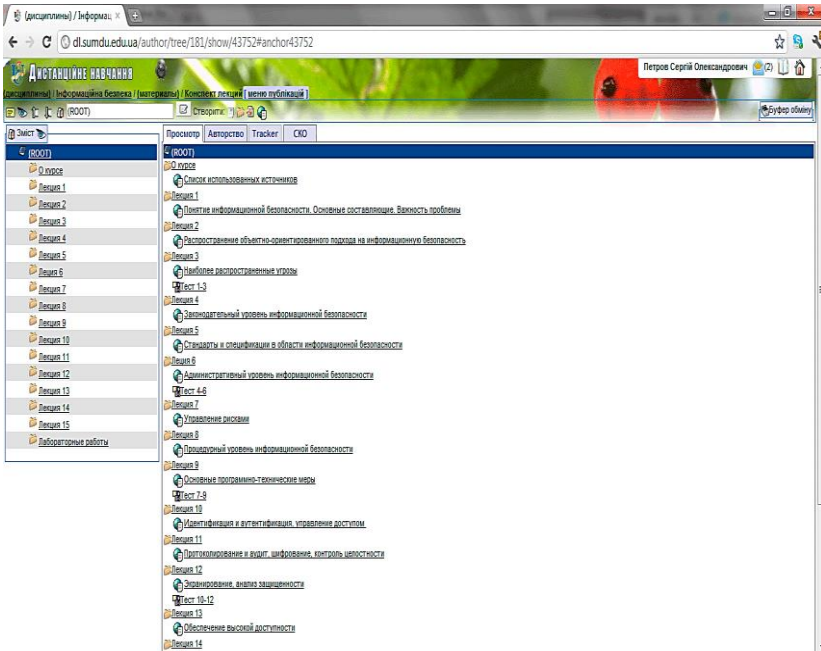


Рисунок 3.26 – Інтелектуальний інтерфейс формування структури дисципліни

З метою представлення навчального матеріалу та контролю знань з використанням сервісу Google Docs та API розробленої на факультеті електроніки та інформаційних технологій Сумського державного університету соціальної мережі створено як альтернативний інтегрований інтерфейс, показаний на рис. 3.27.



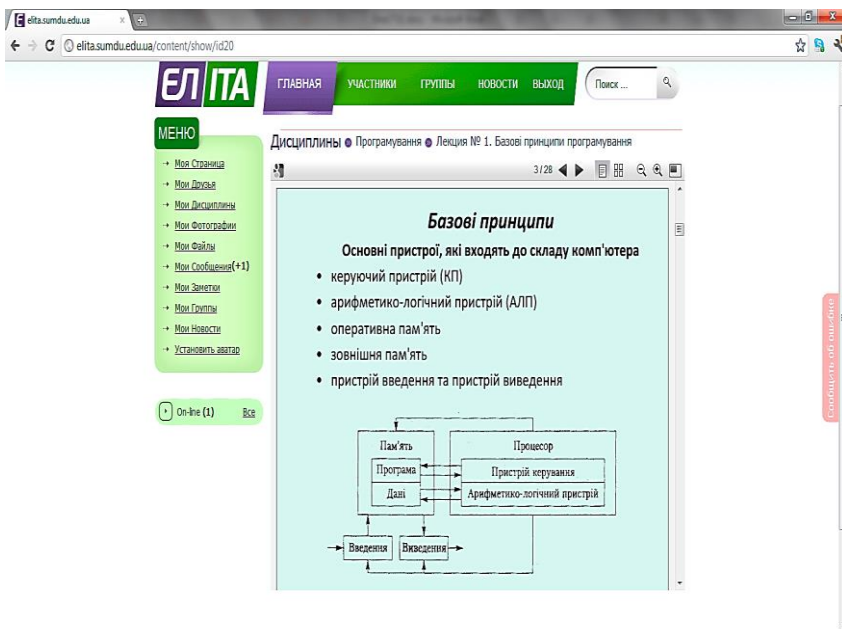


Рисунок 3.27 – Фрагмент представлення навчального контенту з використанням сервісу Google Docs

З метою забезпечення можливості гнучкого застосування функціональні блоки системи здатні функціонувати окремо один від одного. Як приклад, для реалізації етапу контролю знань в режимі відсутності доступу до мережі Інтернет, реалізовано застосування яке дозволяє проводити тестування рівня знань слухачів та керування тестовими запитаннями (рис. 3.28). Даний інтерфейс підтримує повний перелік типів запитань, та реалізує можливість отримання додаткових параметрів тестування таких як: час відповіді на поточне питання, загальний час проходження тесту, зміна вибору відповіді та інші.

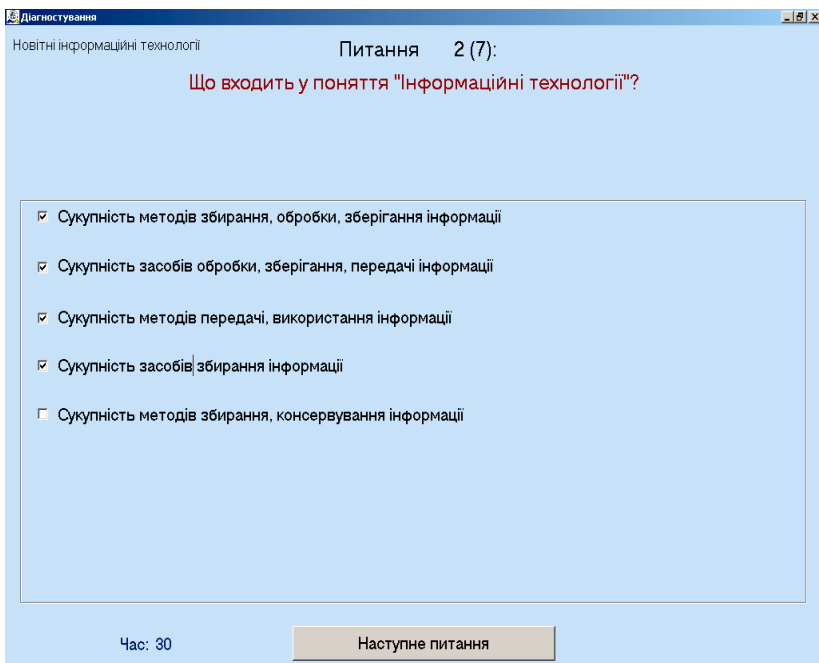


Рисунок 3.28 – Інтерфейс тестування користувачів в режимі off-line

Для зручного керування блоками тестових запитань реалізовано інтерфейсний модуль формування тестових порцій, редагування запитань, відповідей та визначення значень їх вагових характеристик. При наявності, наприклад, тимчасового підключення до мережі Інтернет, проведені налаштування доданків синхронізуються з центральним сервером, також пересилаються дані що були зібрані під час тестування.

На рис. 3.29 показано інтерфейс керування блоками запитань та формування тестових наборів.

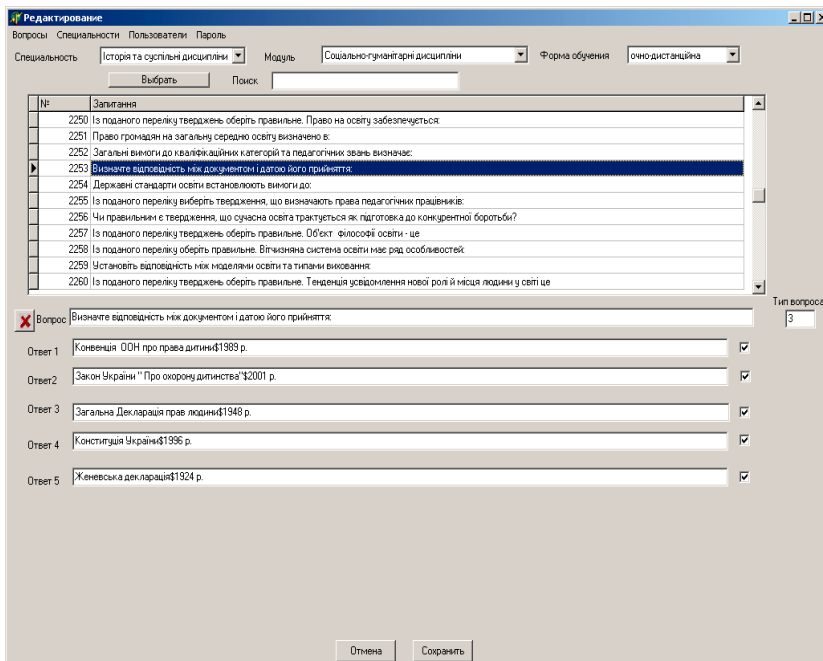


Рисунок 3.29 – Інтерфейс формування тестових наборів

Функціонально розроблена модель розширює базову концепцію ролей операційної системи. Метод аутентифікації, що використовується за замовченням – логін користувача і пароль, при цьому система підтримує і інші методи авторизації (наприклад, з використанням сертифікатів, OpenAPI). При цьому сесія підтримується за рахунок технології Cookies захищеного збереження даних користувача в клієнтській частині.

Керування користувачами, та їх зв'язком з навчальною групою здійснюється як центральною СКНП, так і в автономному режимі у вигляді локального доданку (рис. 3.30).

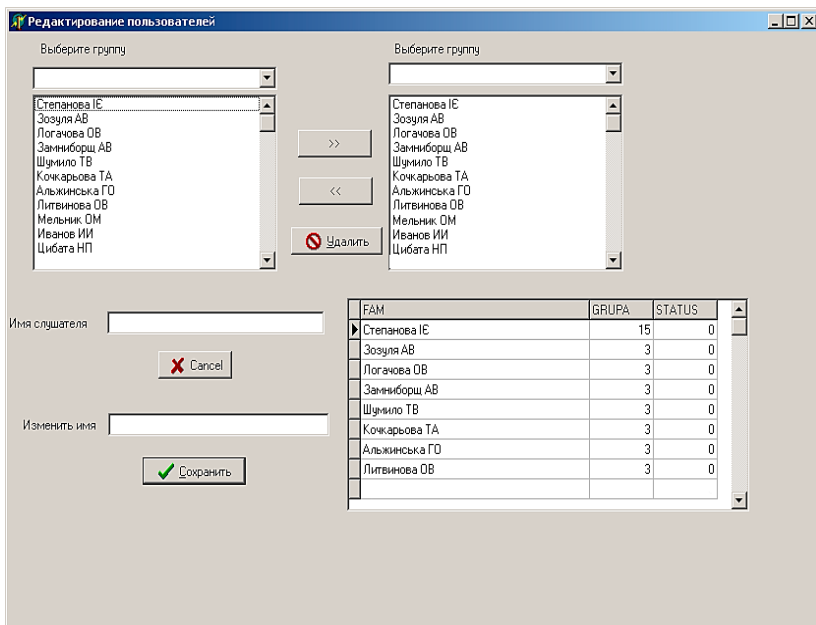


Рисунок 3.30 – Інтерфейс керування користувачами СКНП

Компонентний підхід використаний при проектуванні та розробки системи дозволяє без принципних обмежень проводити її розширення до більш високого рівня автоматизації навчального процесу навчального закладу, або іншої установи, де відбувається вирішення задач подачі інформації та контролю її засвоєння. Суттєвої переробки можуть вимагати лише інтерфейси користувача, оскільки вони можуть суттєво відрізнитися для кожного нового застосування системи, та специфічні для окремого випадку використання бізнес-об'єкти.

Структура бази даних та програмних класів повністю відповідає реальним об'єктам автоматизації та не вносить обмежень для масштабування та розширення системи. Застосування гнучкої компонентної архітектури дозволяє сформувати фрагменти системи, будуючи її розподілене застосування, що особливо важливо

при значній кількості користувачів та інформації, що зберігається та обробляється системою. Це дозволило виділити пріоритетні функціональні фрагменти системи, зменшити вплив на систему пікового навантаження та забезпечити безперервне функціонування системи. Існуючі інтерфейси та сервіси підтримують можливість взаємодії з іншими системами використовуючи технологію web-сервісів.

Використання бібліотеки каркасних класів Zend Framework та чіткої архітектури інтерфейсів дозволяє покрити практично всю функціональність unit-тестами, за допомогою PHPUnit або подібних систем. Крім того, використовуючи даний каркас, вдається досягти високого рівня можливості тестувати компоненти презентаційного рівня, що в комплексі дає можливість повністю проводити підхід паралельного тестування (test-driven approach) при розробці системи. Такий підхід не тільки забезпечує стабільність системи в цілому, а й полегшує її розвиток і підтримку у майбутньому.

Розроблена сукупність інтерфейсів забезпечує достатньо повне покриття необхідних режимів взаємодії суб'єктів АСКНП, що дозволяє максимально гнучко реалізовувати впровадження запропонованої технології.

Аналіз і синтез мультиагентної адаптивної та багатокомпонентної АСКНП для підтримки та супроводження навчального процесу проводилося з використанням сучасних парадигм проектування та розробки сервіс-орієнтованих технологій і патернів проектування. Зазначені вимоги до програмного забезпечення потребують створення комплексу програмних продуктів, орієнтованого як на вирішення технічних задач, так і для реалізації компонентної взаємодії.

Використання активної моделі в рамках MVC та системи каркасних класів дозволило об'єднати локальні або настільні доданки з сервіс-орієнтованими веб-системами. Для програмної реалізації ядра системи використано редактор Eclipse з наступними модулями: PHP Developments Tools, JsEclipse, система контролю версій

(SVN), AmaterasERD для візуального проектування баз даних, SQL-Data Tools Platform для обробки та оптимізації SQL запитів, QuickREx – підтримка швидкого опрацювання регулярних виразів, AmaterasUML – модуль формування моделі класів та UML діаграм, Мулун – підсистема керування задачами.

На рис. 3.31 показано архітектуру мультиагентної СППР для керування та супроводження навчального процесу.

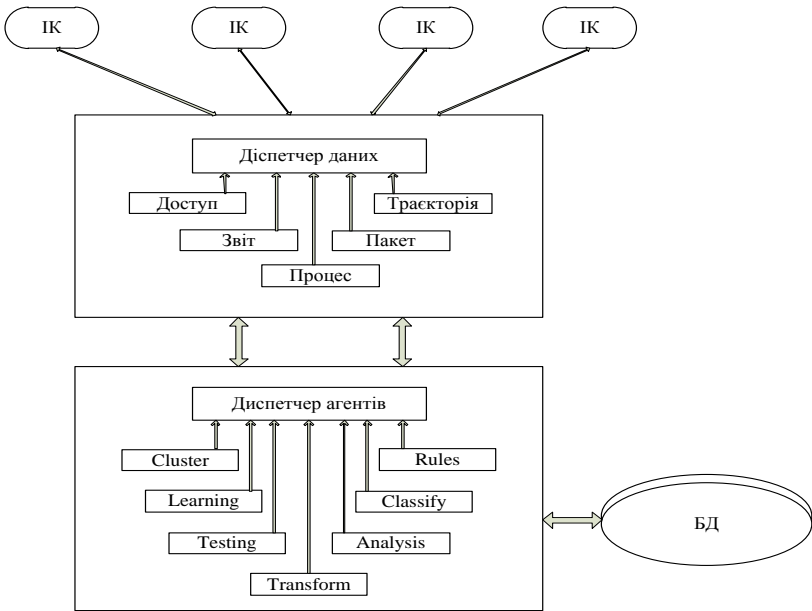


Рисунок 3.31 – Архітектура мультиагентної СКНП

Розроблена організація ядра системи дозволяє відокремити рівні зберігання, обробки та відображення даних та забезпечило можливість створення додаткового програмного інтерфейсу API додавання нових модулів.

Слід зазначити, що програмні підсистеми збору даних можуть функціонувати автономно використовуючи тимчасові сховища даних. Інтерфейс координування роботи агентів реалізовано з використанням принципів побудови паттерну SingelTone, що дозволяє виділи та окремо обробляти блок статичної інформації, щодо активних агентів системи. Компоненти програмного забезпечення СППР показано на рис. 3.32.

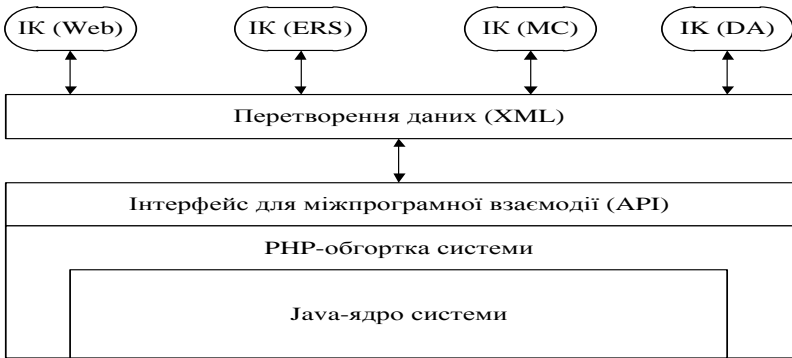


Рисунок 3.32 – Структурна схема компонентів програмного забезпечення

На основі конфігураційних даних (Config) ядро системи (Core) визначає параметри доступу (Params) до бази даних (DB), з якої обирається клас обробки даних (Class) та шаблон візуального оформлення (Template). За допомогою модуля генерування посилань (Link) та класом шаблонізатору (Taglibs) формується блок для завантаження (Loader). Loader реалізує паттерн фронт-контролер, призначення якого полягає у ініціалізації доданка, визначення маршруту вхідного та вихідного запитів і завантаження визначених дій. Під час цього процесу відбувається перевірка прав користувача на завантаження (використання) певного модуля (Auth). При цьому реалізовано принцип кешування функцій, що завантажу-

ються. Для безпосереднього відображення даних використовуються менеджер шаблонів Smarty. Додавання сторонніх модулів реалізовано за рахунок наслідування абстрактного класу AClass.

Реалізація сучасних принципів впровадження систем електронного навчання відбувається за рахунок впровадження технологій web 2.0. Таким чином, база даних системи спроектована з ознаками спеціалізованої навчальної соціальної мережі з можливістю комунікації між учасниками процесу. Інтенсифікація роботи користувачів системи з навчальним контентом дозволяє значно розширити множину ознак розпізнавання та постійно накопичення статистичні дані. Відповідність структури бази даних першій та другій нормальній формі дозволяє уникати збільшення кількості таблиць при додаванні нових функціональних модулів (плагинів).



## СПИСОК ЛІТЕРАТУРИ

1. Гриценко В. И. Дистанционное обучение: теория и практика / В. И. Гриценко, С. П. Кудрявцева, В. В. Колос, Е. В. Веренич. – К.: Наукова думка, – 2004. – 375 с.
2. Андреев А. А. Дидактические основы дистанционного обучения. Методы и средства дистанционного обучения / А. А. Андреев. – <http://www.iet.mesi.ru/br/22b.htm>.
3. Englemore R. Blackboard Systems / R.Englemore, T. Morgan. – Wokingham, England: Addison-Wesley, 1988. – 11 p.
4. Якушев П. С. Анализ технологий и систем управления электронным обучением: Отчет [Электронный ресурс] / П. С. Якушев // Реализация образовательных программ инновационного типа в области ИТ. - режим доступа: <http://inno.cs.msu.su/implementation/it-university/07/report.doc> (24.10.2009).
5. Якушин А. В. Использование LMS в учебном процессе педагогического вуза А. В. Якушин // Современные информационные технологии и ИТ-образование: Сборник докладов научно-практической конференции / под ред. В. А. Сухомлина, отв. Ред. Е. Н. Никелина. – М.: МАКС пресс, - 2006. - С. 189-193.
6. Cole J. Using Moodle: Teaching with the Popular Open Source Course Management System / J. Cole, H. Foster.– O'Reilly, 2010. – 266 p.
7. Петров Е. Г., Новожилова М. В., Гребеннік І. В. Методи і засоби прийняття рішень у соціально-економічних системах: Навч. посібн. / За ред. Е. Г. Петрова. – К.: Техніка, 2004. – 256 с.
8. Ситник В. Ф. Системи підтримки прийняття рішень: Навч. посіб. / В. Ф. Ситник – К.: КНЕУ, 2004. – 614 с.

9. Довбиш А. С. Основи проектування інтелектуальних систем: Навчальний посібник / А.С. Довбиш. – Суми: Видавництво СумДУ, 2009. – 171 с.

10. Уотермен Д. Руководство по экспертным системам: Пер. с англ. / Д. Уотермен. – М.: Мир, 1989.– 388 с.

11. Субботін С. О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень / С. О. Субботін. – Запоріжжя: ЗНТУ. – 2008. – 341 с.

12. Ивахненко А. Г. О принципах построения обучающихся систем управления сложными процессами. – М.: Наука, 1970. – 252 с.

13. Ту Дж., Гонсалес Р. Принципы распознавания образов: Пер. с англ. – М.: Мир, 1978. – 416 с.

14. Астанин С. В. Сопровождение процесса обучения на основе нечеткого моделирования / С. В. Астанин // Открытое образование. – 2000. – №5. – С 12-18.

15. Веренич Е. В. Оценивание мультимедиаьных дистанционных курсов с использованием цепей Маркова / Е. В. Веренич // Управляющие системы и машины. – 2002. – №3/4. – С. 66-71.

16. Бублик В. В. Електронне навчання в Україні і світі. Ретроспектива і перспектива [Текст] / В. В. Бублик, О. К. Закусило, В. П. Шевченко // Теорія і методика навчання інформатики та математики: Збірник наукових праць. Вип. 3. / під ред. І. П. Аносова та ін. - Мелітополь: МДПУ, 2004. - С. 10-27.

17. Колос В. В., Мониторинг телекоммуникационной информационно-образовательной среды вуза // В.В. Колос, В. А. Любчак, А. Г. Пивень // Вісник Сумського державного університету. Серія Технічні науки. – 2006. – №10(94). – С. 59-68.

18. Строгалев В. П. Имитационное моделирование / В. П. Строгалев, И. О. Толкачева. – М.: МГТУ им. Баумана, 2008. – 697 с.

19. Методы анализа данных: Подход, основанный на методе динамических сгущений: Пер. с фр. / Кол. авт. под рук. Э. Дидэ / Под ред. и с предисл. С. А. Айвазяна и В. М. Бухштабера. – М.: Финансы и статистика, 1985. – 375 с.

20. Ким Дж.-О. Факторный, дискриминантный и кластерный анализ / Дж.-О. Ким, Ч.У. Миллер, У.Р. Клекк и др. – М.: Финансы и статистика, 1989. – 215 с.

21. Jain A. K. Data Clustering: 50 Years Beyond K-Means" / A. K. Jain // Pattern Recognition Letters. – 2010. – Vol. 31, №8. – P. 651 - 666.

22. Уиллиамс У. Т. Методы иерархической классификации: Статистические методы для ЭВМ / У.Т. Уиллиамс, Д.Н. Ланс. Под ред. М.Б. Малютов. – М.: Наука.– 1986. – С. 269-301.

23. Турбович И.Т. Опознавание образов: Детерминир.-статист. подход / И. Т. Турбович, В. Г. Гитис, В. К Маслов. – М.: Наука, 1971. – 246 с.

24. Анисимов Б. В., Курганов В. Д., Злобин В. К. Распознавание и цифровая обработка изображений. – М.: Высшая школа, 1983. – 256 с.

25. Краснопоясовський А. С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань. – Суми: Видавництво СумДУ, 2004. – 261 с.

26. Дмитриев А. К., Мальцев П. А. Основы теории построения и контроля сложных систем. – Л.: Энергоатомиздат; Ленингр. отд-ние, 1988. – 192 с.

27. Васильев В. И. Теория редукции в проблемах экстраполяции / В. И. Васильев // Проблемы управления и информатики. – 1996. – №1,2. – С.239-251.

28. Прикладная статистика: Классификация и снижение размерности: Справ. изд. / С. А. Айвазян, В. М. Бухштабер, И. С. Енюков, Л. Д. Мешалкин / Под ред. С. А. Айвазяна. – М.: Финансы и статистика, 1989. – 607 с.

29. Загоруйко Н. Г. Алгоритмы обнаружения эмпирических закономерностей / Н. Г. Загоруйко, В. Н. Елкина, Г. С. Лбов. – Новосибирск: Наука, 1985. – 110 с.

30. Гиренко А. В., Ляшенко В. В., Машталир В. П. Путятин Е. П. Методы корреляционного обнаружения объектов. – Харьков: АО “БизнесИнформ”, 1996. – 112 с.

31. Соколов А. Ю. Алгебраическое моделирование лингвистических динамических систем / А.Ю. Соколов // Проблемы управления и информатики. – 2000. – С. 141–147.

32. Sotirov S. Neural network for defining intuitionistic fuzzy sets in e-learning / S. Sotirov, E. Sotirova, D. Orozova // Thirteenth Int. Conf. on IFSs, Sofia, 9 - 10 May 2009, NIFS. – 2009. – Vol. 15. – P. 33-36.

33. Baylari Ahmad. Design a personalized e-learning system based on item response theory and artificial neural network approach / Ahmad Baylari, Gh.A. Montazer // Expert Systems with Applications. – 2009. – V 36. – P. 8013–8021.

34. Bodyanskiy E.V., Vorob'ev S.A. Recurrent neural network detecting changes in the properties of nonlinear stochastic sequences / E.V. Bodyanskiy, S.A. Vorob'ev // Automation and Remote Control. – 2000. – Vol. 1.– №7. – P. 1113–1124.

35. *Advances in Learning Theory: Methods, Models and Application* / J.A.K. Suykens, G. Horvath, S. Basu, C. Micchelli, J. Vandewalle // IOS Press NATO-ASI Series in Computer and Systems Sciences, Amsterdam, The Nether-Lands, 2003. – 432 p.

36. Довбыш А. С. Информационно-экстремальный алгоритм оптимизации параметров гиперэллипсоидных контейнеров классов распознавания / А.С. Довбиш, Н. Н. Будник, В. В. Москаленко // Проблемы управления и информатики: Междунар. науч.-техн. журнал. – 2012. – № 5. – С. 111–119.

37. Huang, M. J. Constructing a personalized eLearning system based on genetic algorithm and case-based reasoning approach / M. J. Huang, H. S. Huang, M. Y Chen // *Expert Systems with Applications*. – 2007. – V. 33. – P. 551–564.

38. Дзюба О. О. Дослідження впливу параметрів гібридного алгоритму на функціональну ефективність навчання системи підтримки прийняття рішень / О. О. Дзюба, І. В. Шелехов // *Радіоелектронні і комп'ютерні системи*. – Харків. – 2009. – №3(37). – С. 88-91.

39. Зайченко Ю. П. Основы проектирования интеллектуальных систем: Навчальний посібник / Ю. П. Зайченко. – К.: Видавничий Дім «Слово». – 2004. – 352 с.

40. Фролов Ю. В. Интеллектуальные системы и управленческие решения. / Ю. В. Фролов. – М.: Московский городской педагогический университет. – 2000. – 294 с.

41. Duda R. O. *Pattern Classification* / R. O. Duda, P. E. Hart, D. G. Stork. – Second ed. John Wiley & Sons, New York. – 2001. – 738 p.

42. Батуркин С. А. Статистические алгоритмы кластеризации данных в адаптивных обучающихся системах / С. А. Батуркин, Е. Ю. Батуркина, В. А. Зименко, И. В. Сигинов // *Вестник*

Рязанского государственного радиотехнического университета. – 2010. – №1 (выпуск 31). – С. 65-68.

43. Краснопоясовський А. С. Класифікаційний аналіз даних: Навчальний посібник / А. С. Краснопоясовський. – Суми: Видавництво СумДУ. – 2002. – 159 с.

44. Кузьмин И. В. Оценка эффективности и оптимизация автоматизированных систем контроля и управления. – М.: Сов. радио, 1971. – 296 с.

45. Кульбак С. Теория информации и статистика / С. Кульбак. – М.: Наука. – 1967. – 408 с.

46. ДСТУ 2481–94. Системи оброблення інформації. Інтелектуальні інформаційні технології. Терміни та визначення // Державний стандарт України. – 1994.

47. Проектирование систем управления на ЭВМ / А. Ю. Соколов, Ю. Н. Соколов, В. М. Ильющко, М. М. Митрахович, Д. И. Гайсёнок // Под ред. Ю. Н. Соколова. – Харьков: ХАИ, 2005. – 590 с.

48. Кулик А. С. Обеспечение отказоустойчивости систем управления. – Харьков: ХАИ, 1991. – 90 с.

49. Анохін П. К. Биология и нейрофизиология условного рефлекса. – М.: Медицина, 1968. – 547 с.

50. Berry M.J.A. Data Mining Techniques. For Marketing, Sales and Customer Support / M.J.A. Berry, G. Linoff. – John Willey & Sons, Inc. – 1997. – 454 p.

51. Большев Л. Н. Таблицы математической статистики / Л. Н. Большев, Н. В. Смирнов. – М.: Наука, 1983. – 416 с.

52. Ивахненко А. Г. Самоорганизация прогнозирующих моделей / А. Г. Ивахненко, Ё. А. Мюллер. – К. : Техніка. – 1985. – 219с.

53. Довбыш А. С. Информационно-экстремальный алгоритм обучения системы диагностирования патологических процессов / А. С. Довбыш, Саад Джулгам, А. А. Стадник // «Инновации в науке»: сборник статей по материалам XXIII Международной заочной научно-практической конференции (12 августа 2013 г.). – Новосибирск: Изд. «СибАК». – 2013. – №23. – С. 45-54.

54. Москаленко В. В. Інформаційно-екстремальний унімодальний класифікатор з паралельно-послідовною оптимізацією контрольних допусків на ознаки розпізнавання / / В. В. Москаленко, І. В. Шелехов, О. В. Соколов // АСУ та прилади автоматики. – 2011. – №156. – С. 42–47.

55. Довбиш А. С. Оцінка інформативності ознак розпізнавання за методом функціонально-статистичних випробувань / А. С. Довбиш, І. В. Шелехов // Вісник Сумського державного університету. – Суми, 2006. - №10(94). – С. 51-58.

56. Кузьмін І. В. Оптимізація словника ознак розпізнавання для інформаційно-екстремального унімодального класифікатора / І. В. Кузьмін, В. В. Москаленко // Вісник Вінницького політехнічного інституту. – 2012. – №5. – С. 91-97

57. Петров С. О. Оптимізація параметрів генерування тестів за інформаційно екстремальною технологією / С. О. Петров // Збірник праць Науково-методологічного семінару “Перспективні технології навчання та освітні простори” Міжнародний науково-навчальний центр інформаційних технологій та систем НАН та МОН України (МННЦ) м. Київ. – 2008. – Вип. 2. – С.71-78.

58. Петров С. О. Оцінка інформативності тестів в системах керування дистанційним навчанням / С. О. Петров, І. В. Шелехов // Вісник Херсонського національного технічного університету.– 2007. – №4(27). – С. 586-591.

59. Довбиш А. С. Машинна оцінка знань студентів у системах керування дистанційним навчанням / А. С. Довбиш,

В. О. Любчак, С. О. Петров // Вісник Сумського державного університету. Серія «Технічні науки». – 2007. – №1. – С. 167-178.

60. Петров С. О. Алгоритм побудови класів еквівалентних наборів ознак розпізнавання в системах керування, що навчаються / С. О. Петров // Збірник праць Третьої Міжнародної конференції «Нові інформаційні технології в освіті для всіх: система електронної освіти, 1-3 жовтня 2008 р.: доповідь. – Київ. – 2008. – С. 455-461.

61. Довбиш А. С. Математичне моделювання при синтезі системи керування дистанційним навчанням / А. С. Довбиш, С. О. Петров // Математичне моделювання. Дніпродзержинський державний університет. – 2007. – №2(17). – С. 64-67.

62. Довбыш А. С. Иерархический информационно-экстремальный алгоритм кластер-анализа результатом тестирования уровня знаний учащихся / А. С. Довбыш, Саад Джулгам, С. А. Петров // Управляющие системы и машины. – 2012. – №2. – С. 62-67.

63. Москаленко В. В. Інформаційно-екстремальна кластеризація даних / В. В. Москаленко // АСУ та прилади автоматики. – 2012. – №160. – С.75-84.

64. Москаленко В.В. Інформаційно-екстремальне навчання системи підтримки прийняття рішень з адаптивною кластеризацією даних / В. В. Москаленко // Вісник СумДУ. Серія технічні науки. – 2012. – №3. – С.92-106.



Наукове видання

**Анатолій Степанович Довбиш, Анатолій Васильович Васильєв,  
Володимир Олександрович Любчак**

**ІНТЕЛЕКТУАЛЬНІ ІНФОРМАЦІЙНІ ТЕХНОЛОГІЇ  
В ЕЛЕКТРОННОМУ НАВЧАННІ**

**Монографія**

Редактор	А. С. Довбиш
Комп'ютерне верстання	А. С. Довбиша
	Л. Л. Дедкової
Художнє оформлення	С. Ю. Цегельникова

Формат 60x84/16. Умов. друк. арк. – 10,46. Обл.-вид. арк. – 9,11.  
Тираж 300 пр. Замовлення №

Видавець і виготовлювач  
Сумський державний університет,  
вул. Римського-Корсакова, 2, м. Суми, 40007  
Свідоцтво суб'єкта видавничої справи ДК № 3062 від 17.12.2007.