

**МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
СУМСЬКИЙ ДЕРЖАВНИЙ УНІВЕРСИТЕТ  
КАФЕДРА КОМП'ЮТЕРНИХ НАУК**

# **КВАЛІФІКАЦІЙНА МАГІСТЕРСЬКА РОБОТА**

**на тему:  
«Інтелектуальний протез кінцівки руки, що  
навчається. Технологічне, інформаційне та  
програмне забезпечення системи керування  
протезом кінцівки руки»**

**Завідувач  
Випускаючої кафедри**

**Довбиш А.С.**

**Керівник роботи**

**Довбиш А.С.**

**Студент гр. ІН – 61маг**

**Приходченко Р.С.**

**Нормоконтроль**

**Проценко О.Б.**

**СУМИ 2018**

Сумський державний університет

(назва вузу)

Факультет \_\_\_\_\_ Еліт \_\_\_\_\_ Кафедра \_\_\_\_\_ Комп'ютерних наук \_\_\_\_\_  
Спеціальність \_\_\_\_\_ «Інформатика» \_\_\_\_\_

Затверджую:

зав.кафедрою \_\_\_\_\_

“ \_\_\_\_\_ ” \_\_\_\_\_ 20\_\_ р.

**ЗАВДАННЯ  
НА ДИПЛОМНИЙ ПРОЕКТ (РОБОТУ) СТУДЕНТОВІ**

Приходченку Роману Сергійовичу

(прізвище, ім'я, по батькові)

1. Тема проекту (роботи) Інтелектуальний протез кінцівки руки, що навчається. Технологічне, інформаційне та програмне забезпечення системи керування протезом кінцівки руки

затверджую наказом по інституту від “ \_\_\_\_\_ ” \_\_\_\_\_ 20\_\_ р. № \_\_\_\_\_

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

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

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

1) інформаційний огляд; 2) постановка задачі 3) вибір методів рішення; 4) програмна реалізація; 5) висновки.

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

# РЕФЕРАТ

**Записка:** 61 стор., 14 рис., 1 додаток, 10 джерел інформації.

**Мета роботи** — підвищення функціональної ефективності системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

**Об'єкт дослідження** — слабоформалізований процес керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

**Методи дослідження** — інформаційно-екстремальна інтелектуальна технологія аналізу даних..

**Результати** — розроблено інформаційне, алгоритмічне та програмне забезпечення системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів. При цьому інформаційний синтез системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів здійснено в рамках інформаційно-екстремальної інтелектуальної технології аналізу даних. Розроблено та програмно реалізовано алгоритм функціонування системи керування протезом руки в режимі екзамену.

ПРОТЕЗ КІНЦІВКИ РУКИ, БІОСИГНАЛ,  
МІОГРАФІЧНИЙ ДАТЧИК, НАВЧАЛЬНА МАТРИЦЯ,  
ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНА  
ТЕХНОЛОГІЯ, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ, ФУНКЦІОНАЛЬНА  
ЕФЕКТИВНІСТЬ

## ЗМІСТ

ВСТУП .....	5
1 АНАЛІЗ ПРОБЛЕМИ .....	6
1.1. Аналіз патентних і літературних джерел існуючих протезів кінцівки руки ..	6
1.2. Аналітичний огляд методів розпізнавання образів і машинного навчання систем керування.....	11
1.3. Критерії схожості об'єктів, що розпізнаються .....	23
1.4. Формалізована постановка задачі дослідження.....	27
2 ОПИС МЕТОДУ ДОСЛІДЖЕННЯ.....	30
2.1 Основні положення інформаційно-екстремальної інтелектуальної технології .....	30
2.2 Оцінка функціональної ефективності системи керування, що навчається...	35
3 ІНФОРМАЦІЙНЕ, АПАРАТНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНОГО ПРОТЕЗУ КІНЦІВКИ РУКИ.....	40
3.1 Функціональна схема протеза руки з неінвазивною системою зчитування біосигналів .....	40
3.2 Формування вхідної навчальної матриці.....	43
3.3 Алгоритм машинного навчання з паралельною оптимізацією контрольних допусків на ознаки розпізнавання .....	45
3.4 Короткий опис програмного забезпечення .....	52
3.5 Результати фізичного моделювання.....	54
ВИСНОВКИ.....	61
СПИСОК ЛІТЕРАТУРИ.....	62
ДОДАТОК А.....	68

## ВСТУП

Створення інтелектуальних протезів на основі машинного навчання та розпізнавання образів розвиває прогресивний напрямок, який дозволяє суттєво розширити їх функціональні можливості, забезпечити повну реабілітацію інвалідів та їх адаптацію до повноцінного життя в українському суспільстві, що має важливе соціально-економічне значення. Тому тема конкурсної науково-дослідної роботи є актуальною, оскільки присвячена підвищенню функціональної ефективності системи керування протезом кінцівки руки. При цьому варто відмітити, що промислове виготовлення інтелектуальних протезів кінцівок в Україні до теперішнього часу відсутнє, а їх розробкою займаються окремі групи дослідників-ентузіастів.

Найбільш досконалими є інтелектуальні протези кінцівок з інвазивною системою зчитування біосигналів. Але їх основним недоліком є дуже висока вартість на світовому ринку. Тому конкурсна робота спрямована на розв'язання важливої науково-практичної задачі підвищення функціональної ефективності протезів з неінвазивною системою зчитування біосигналів і наближення їх до функціональних можливостей інвазивних при збереженні відносно невисокої собівартості.

Зміст роботи полягає у розробленні нової інтелектуальної технології керування протезом кінцівки руки на основі пасивних міографічних датчиків, фільтрації, оброблення та класифікаційного аналізу вхідних сигналів, побудові в процесі машинного навчання безпомилкових за навчальною матрицею вирішальних правил, які на етапі екзамену, тобто безпосереднього розпізнавання біонічних сигналів кінцівки руки дозволяють виконувати відповідні рухи з високою точністю і оперативністю.

## 1 АНАЛІЗ ПРОБЛЕМИ

### 1.1. Аналіз патентних і літературних джерел існуючих протезів кінцівки руки

На нинішньому етапі розвитку технічного прогресу і наукових досягнень люди з фізичними недоліками мають великий вибір різних можливостей і асортимент продукції протезної індустрії, а також повний асортимент адаптивного обладнання. Зараз в сфері протезування, завдяки інформаційним технологіям і синергії різних індустрій, можемо спостерігати створення нових розробок і наукових досягнень. Головна ціль, яку намагаються досягти інженери всього світу – втілити в штучному виробі всі функції живої руки чи ноги.

На кінець 20-го століття всі винаходи в сфері протезування були механічного характеру, наприклад, згинання регулювалось вручну. Основними проблемами протезів тих часів були відсутність будь-якого зв'язку безпосередньо з організмом та недовговічність. Протези які заміняли руку чи ногу не могли функціонувати, як повноцінний прототип, вони заміняли активні частини тіла, але нездатні наблизитися по можливостям до природнього аналогу, це і є головний мінус протезів – низька функціональність.

Іншими видом високофункціональних протезів є пристрої, що здатні розпізнавати та відчувати поверхню, тобто зміст даної корисної моделі покликаний виконувати тактильну функцію (рис.1.1) [1].

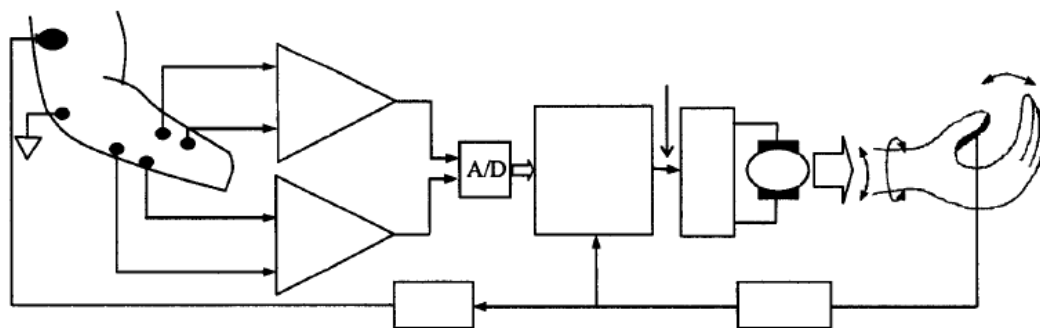


Рисунок 1.1 – Схема пристрою біоелектричного протезу руки з тактильною функцією

На рис. 1.1 зображена схема протезу, конструкція якого передбачає два електроміографічні датчики, аналого-цифровий перетворювач, підсилювачі сигналу та мікропроцесор, що обробляє інформацію отриману від електроміографічних датчиків і формує режим руху, який необхідно виконати. Але те, що відрізняє даний пристрій від більшості собі подібних знаходиться у конструкції біоелектричного пальця. Вважається, що можливість відчувати та розпізнавати поверхню дозволить протезу самостійно регулювати силу стискання предметів.

Палець протезу виконаний з полімеру полівінілденфториду товщиною 50мкм, який є п'єзоелектричним, що і робить його чутливим. Взагалі матеріал є достатньо чистим полімером, в ньому відсутні пластифікатори і антипірени, має гарні зносостійкі характеристики, добре ковзає, а також є фізіологічно інертним, що дозволяє контактувати йому з харчовими продуктами, має низьку займистість і характерний високою жорсткістю. В свою чергу датчики виготовлені з надтонких мідних пластин, що поєднані з полівінілденфторидом у єдину деталь у формі циліндру, що формує єдину сигнальну лінію, як зображено на рис. 1.2 [2].




Рисунок 1.2 – Схема будови пальця з тактильною функцією

Методи аналізу електроміограм зазвичай використовують статистичні методи, методи параметричного моделювання, методи аналізу з частотно-часовою основою. Але найбільш обширною моделлю аналізу електроміограм є метод заснований на штучних нейронних мережах та різних їх комбінаціях.[2] Нейронна мережа має розподілені, паралельні та нелінійні характеристики. Розподілені нейронні мережі мають властивість зберігати дані таким чином, щоб вони підтримували і доповнювали один одного в інформаційній мережі, це дає можливість характеризувати систему, як відказостійкою і здатною мислити тим самим не отримувати кожен раз вхідний сигнал, що є зашумленим, тобто сигнал електроміограми є уразливим для цілого ряду чинників, що можуть заважати обробці сигналу в нейронній мережі для забезпечення надійності результатів. Паралельність нейронних мереж дозволяє підвищити швидкість обробки інформації, а нелінійність надає можливість зробити будь-який процес нелінійним, особливо, якщо необхідно обробляти інформацію про фізичний процес, який за своєю природою є нелінійним.



Від отримання сигналу електроміограми до розпізнавання руху кінцівки є два етапи. Перший пов'язаний з зібраними даними з часових рядів міографічних датчиків, методом екстракції сигналу з використанням функції параметричної моделі. Другий характеризується передачею даних на вхід класифікатора нейронної мережі для отримання моделі руху кінцівки, це є загальною моделлю процесу.

Для трирівневої структури нейронної мережі Feedforward та мережевого класифікатора методу навчання з використанням мережі віртуальної реальності застосовується алгоритм градієнтного спуску. Мережа складається з трьох шарів, а саме вхідного шару, прихованого та вихідного, що не є з'єднані між собою. Мережеві класифікатори вхідного каналу електроміограми всіх часових рядів з відповідними коефіцієнтами утворюють авторегресійну модель, що ідентифікується фізичним станом рухів руки. Тому корисна модель протезу, яка має біонічний характер та міоелектричний контроль штучно-тактильної функції має більш розширений функціонал та має ознаки інтелектуальності системи.

Тож, беручи до уваги глобальні недоліки сучасних систем протезування є неможливість їх використання у рідкому середовищі, через незахищеність електронних складових будови пристрою, відносно висока ціна та необхідність звернення до спеціалістів у разі необхідності апаратного чи програмного обслуговування.

Аналіз результатів, отриманих вітчизняними та закордонними вченими показує, що найбільшою функціональною ефективністю характеризуються протези кінцівок, які використовують інвазивні (з активними міографічними датчиками) та неінвазивні (з пасивними міографічними датчиками) системи зчитування біосигналів. В праці [3] показано, що біонічні протези, основані на інвазивних підходах, характеризується відносно високою точністю виконання когнітивних команд, але при цьому суттєво більшою вартістю, нижчою

гнучкість та зручністю у використанні, більш дорогим та частим обслуговуванням. Однак біонічні протези, керовані сигналами від пасивних міографічних сенсорів, як правило мають обмежений набір команд, а відновлені рухи мають не достатньо високу точність. Для підвищення достовірності розпізнавання та спектру команд, що виконуються протезом, такі протези інколи комплектують системами оптичного трекінгу руху очей чи частин тіла, що дозволяє розширити їх функціональні можливості та точність виконання команд, але підвищує їх собівартість до рівня інвазивних. Запропоновані у працях [4, 5] алгоритми машинного навчання для встановлення відповідності між сигналами та командами відповідно на основі нейронних мереж та методу опорних векторів дозволяють досягти 90% точності у розпізнаванні основних рухів кисті руки, проте точність розпізнавання руху окремих пальців навіть при непошкодженій м'язовій тканині не перевищує 60%.

Застосування традиційних методів інтелектуального аналізу даних Data Mining, включаючи штучні нейронні мережі [6], для створення здатних навчатися систем керування протезом кінцівки руки ускладнено через ряд не вирішених науково-методологічні проблеми, Основними з таких проблем є довільні початкові умови формування векторів-реалізацій образів і суттєвий перетин класів розпізнавання через мале відношення біосигнал/завада.

Таким чином, основними тенденціями удосконалення інтелектуальних систем керування протезами кінцівок згідно з працею [7] є наближення біонічних протезів до можливостей біологічного прототипу за спектром команд, точністю та оперативністю відтворення рухів та швидкістю навчання шляхом розробки алгоритмів машинного навчання з пошуком інформативного словника ознак, інваріантного до модифікацій міографічних сенсорів та зміщень.

Одним з перспективних напрямків створення системи керування протезом кінцівки із неінвазивним способом зчитування біосигналів є застосування

розробленої в Сумському державному університеті так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи в процесі її навчання [6, 7]. Основна перевага методів інформаційно-екстремального машинного навчання полягає в можливості адаптації вхідного математичного опису системи до максимальної достовірності розпізнавання образів. При цьому на відміну від нейронних мереж в ІЕІ-технології вирішальні правила будуються в рамках геометричного підходу, що суттєво зменшує вплив проблеми багатовимірності словника ознак і алфавіту класів розпізнавання на функціональну ефективність системи керування

1.2. Аналітичний огляд методів розпізнавання образів і машинного навчання систем керування

Запропоновані у працях [11 – 13] алгоритми машинного навчання для встановлення відповідності між сигналами та командами відповідно на основі нейронних мереж та методу опорних векторів дозволяють досягти 90% точності у розпізнаванні основних рухів кисті руки, проте точність розпізнавання руху окремих пальців навіть при непошкодженій м'язовій тканині не перевищує 60%.

Застосування традиційних методів інтелектуального аналізу даних Data Mining, включаючи штучні нейронні мережі [11], для створення здатних навчатися систем керування протезом кінцівки руки ускладнено через ряд не вирішених науково-методологічні проблеми, Основними з таких проблем є довільні початкові умови формування векторів-реалізацій образів і суттєвий перетин класів розпізнавання через мале відношення біосигнал/завада.

Таким чином, основними тенденціями удосконалення інтелектуальних систем керування протезами кінцівок є наближення біонічних протезів до можливостей біологічного прототипу за спектром команд, точністю та оперативністю відтворення рухів та швидкістю навчання шляхом розробки алгоритмів машинного навчання з пошуком інформативного словника ознак, інваріантного до модифікацій міографічних сенсорів та зміщень.

Розвиток теорії машинного навчання, основи якої закладено в працях [14], відбувався в рамках статистичного підходу до розпізнавання образів, що є його головною заслугою. Зміст усіх статистичних методів навчання полягає у відновленні роздільної функції шляхом мінімізації середнього ризику помилкового розпізнавання [15]. У рамках найбільш універсального підходу до аналізу і синтезу здатних навчатися СППР, яким є геометричний підхід, саме статистичні методи дозволяють будувати вирішальні правила у випадках перетину класів розпізнавання, що має місце в практичних задачах контролю та керування слабо формалізованими процесами. Крім того, використання статистичних методів навчання дозволяє здійснювати прогностичне керування та оптимізацію параметрів функціонування, які безпосередньо впливають на функціональну ефективність СППР. Однак основними недоліками статистичних методів, які обмежують їх використання на практиці, є:

- необхідність великих обсягів статистики для апроксимації функції щільності розподілу імовірностей;
- виконання жорстких умов для забезпечення статистичних стійкості та однорідності;
- висока чутливість до репрезентативності навчальних вибірок;
- невисока оперативність, через складність алгоритмів функціонування СППР, що особливо критично в режимі екзамену, тобто безпосередньо при прийнятті керуючих рішень.

Детерміновані методи розпізнавання, які розвивалися паралельно із статистичними, відрізняються простими вирішальними правилами та високою оперативністю класифікації [16]. Ці методи адекватні задачам, де класи не перетинаються, і припускається, що чіткі вирішальні правила забезпечують нульову помилку при розпізнаванні екзаменаційної вибірки будь-якого розміру. При цьому побудова вирішального правила здійснюють на базі такого математичного апарату, як математична логіка, теорія графів, топологія, математична лінгвістика, математичне програмування та інше [17]. Але ігнорування будь-якої інформації про статистичний розподіл реалізацій образу зменшує достовірність вирішальних правил при прийнятті рішень в режимі екзамену. Крім того, детерміновані методи мають низьку завадозахищеність та відсутність узагальнення даних.

Об'єднати переваги як детермінованого, так і статистичного підходів до прийняття рішень та обійти їх недоліки – така задача розв'язується у рамках детерміновано-статистичного підходу [18]. Наприклад, у праці [19] на першому етапі будуються найбільш прості детерміновані вирішальні правила, які на другому етапі статистично корегуються шляхом мінімізації кількості викидів реалізацій за “свою” еталонну оболонку та проникнення у глибину еталонних оболонок реалізацій “чужих” образів.

Подальшим розвитком методу еталонів [19] став метод еталонного опису [20], в якому з метою зменшення складності вирішальних правил акцент зроблено на відбір інформативних ознак розпізнавання шляхом оцінки їх корисності. Як методу еталонів, так і методу еталонного опису притаманна модельність через ігнорування загального випадку перетину класів розпізнавання. Це дало поштовх для розвитку нового напрямку – нормалізація образів, пов'язаної з перетворенням апріорно деформованих образів і адаптацією вхідного математичного опису СППР з метою підвищення

максимальної повної достовірності рішень, що приймаються в режимі екзамену [21]. Проведення нормалізації деформованих образів дозволяє застосовувати алгоритми навчання, які відрізняються відносно простими вирішальними правилами. Однак, при цьому основне ускладнення полягає в тому, що основний акцент машинного навчання робиться безпосередньо на оброблення образів і оптимізацію параметрів оброблення, що потребує застосування зовнішніх критеріїв валідності, які характеризують безпосередньо функціональну ефективність навчання. Серед методів нормалізації, що знайшли практичне застосування, слід виділити праці українських вчених Івахненка О.Г., Ковалевського, Путятіна Є.П. та інших, які розробили кореляційно-екстремальні методи, побудовані на пошуку максимальної кореляції між реалізаціями одного класу [22] і один із найбільш ефективних методів нормалізації образів – метод групового врахування аргументів [23].

Паралельно на вирішення проблеми підвищення функціональної ефективності машинного навчання за умов розбиття простору ознак на класи розпізнавання, що апріорно перетинаються, в кінці 20-го і на початку 21-го століть почали інтенсивно розроблятися методи нечіткої класифікації [24], основані на теорії нечітких множин Л. Заде [25].

Методи розпізнавання, що базуються на нечіткому логічному виводі, потребують лінгвістичного опису вхідних і вихідних змінних, а також формування людиною-експертом набору нечітких правил, що може виявитись неповним, або суперечливим [26]. Внаслідок необхідності розбиття універсальних множин на окремі області існує суттєве обмеження на кількість ознак розпізнавання. Тому застосування нечітких множин виправдане у випадку доступності лише якісних шкал виміру ознак розпізнавання. Що стосується застосування нечітких методів подання і виведення знань для кількісних шкал виміру ознак розпізнавання, то варто відмітити, що, як встановлено в останні

роки, наприклад, в праці [27], функція належності, яка відповідає умовам Заде, є аналогом функції щільності розподілу ймовірностей. Таким чином, у цьому випадку застосування нечітких методів аналізу і синтезу немає ніяких переваг перед статистичними методами і мають спільні недоліки. При цьому статистичний підхід до аналізу і синтезу здатних навчатися СППР має більш розвинений у порівнянні з нечітким підходом апарат багатовимірного статистичного аналізу і, крім того, критерії функціональної ефективності таких систем мають імовірнісну природу, що дозволяє оптимізувати параметри навчання.

Аналіз сучасних тенденцій розвитку методів проектування інтелектуальних СППР свідчить про інтенсивну розробку та впровадження методів на базі штучних нейронних мереж [28]. Штучні нейронні мережі володіють високим рівнем узагальнення даних, високою завадозахищеністю, а в апаратному виконанні й надійністю. Однак нейронним мережам властиві такі основні проблеми [29]:

- проблема інтерпритованості вагових коефіцієнтів, пов'язана зі складністю інтерпретації змісту інтенсивності вхідних сигналів і вагових коефіцієнтів;
- проблема інтерпретованості передатної функції (складність інтерпретації і обґрунтування адитивності аргументу і вигляду активаційної функції нейрона);
- проблема розмірності, що призводить до “комбінаторного вибуху”, який виникає при визначенні структури зв'язків нейронів, підборі вагових коефіцієнтів і передатної функції;
- проблема лінійної розділимості, оскільки збудження нейронів приймає виключно булеві значення (0 або 1).

Проблема інтерпретованості призводить до невизначеності у виборі початкової конфігурації мережі, і як наслідок до зниження якості результатів. Проблема розмірності призводить до значних обмежень на місткість та складність структури зв'язків між нейронами в мережі. Проблема лінійної розділимості призводить до необхідності застосування складних багатошарових мереж навіть для нескладних задач. Внаслідок перелічених проблем нейронним мережам властива висока ітеративність та низька швидкість процесу навчання. При цьому, як правило, використовуються градієнтні методи навчання, для яких окрім невизначеності вибору початкової точки пошуку, характерна схильність до зациклювань в локальних оптимумах, а також вимога диференційованості цільового функціоналу [29].

Проблема вибору початкової точки пошуку в задачах самонавчання нейронних мереж відсутня в методі розширюваного нейронного газу, оскільки в його основі лежить ймовірнісний метод [30]. Кількість нейронів і їх розташування обчислюються в процесі самонавчання. В проблемних областях класифікації здійснюється ушільнення топології. Цей метод був першою спробою адаптації алгоритму машинного навчання під особливості вхідних даних. Однак методу розширюваного нейронного газу так само властиві низька інтерпретабельність, низька швидкодія і, крім цього, відсутність можливості динамічного керування параметрами, що впливають на швидкість збіжності алгоритму. Помилка класифікації нейронної мережі, в тому числі побудованої за методом розширюваного нейронного газу, збільшується у випадку перетину класів розпізнавання [31]. При цьому навчена нейронна мережа являє собою “чорну шухляду”, що не дозволяє прогнозувати величину помилки класифікації в режимі екзамену.

Серед нейронних мереж, що не самоорганізуються (наприклад, сігмоїдальні [32], радіальні [33], нейромережі Хопфільда [34] та інші),



заслужують на увагу мережі Хеммінга [35], які відрізняються відносно високими достовірністю розпізнавання деформованих образів та оперативністю навчання. Перевага мереж Хеммінга обумовлена використанням у них бінарного простору ознак розпізнавання як субпарацептуального, що знімає проблему нормалізації вхідних даних і підвищує завадозахищеність алгоритму навчання. Основна ідея функціонування такої мережі полягає в мінімізації відстані Хеммінга між тестовим вектором-реалізацією (еталоном), що подається на вхід мережі, і двійковими векторами-реалізаціями навчальної матриці, що кодуються в структурі мережі. У праці [35] показано, що алгоритм навчання мережі Хеммінга збігається за імовірністю. Основна проблема, пов'язана з мережею Хеммінга, проявляється у випадку, коли зашумлені зразки знаходяться на однаковій (у розумінні Хеммінга) відстані від двох чи більше еталонів. У цьому випадку вибір мережею Хеммінга одного з еталонів стає випадковим [36]. Це свідчить про відсутність у методі, що розглядається, ефективного механізму статистичної корекції параметрів розбиття простору ознак на класи розпізнавання.

Подолати вище згадані недоліки нейронних мереж намагаються в нейро-нечітких системах, де передбачається прискорити процес навчання за рахунок внесення додаткової апріорної інформації (знання експерта), підвищити інтерпретабельність моделі мережі за рахунок використання лінгвістичних змінних, врахувати перетин класів розпізнавання настройкою параметрів нечітких термів [37]. При цьому часто використовують методи стохастичного пошуку, які дозволяють розв'язувати задачі дискретної і неперервної багатовимірної нелінійної оптимізації, є методами глобального пошуку, не висувають вимог до виду цільової функції і дозволяють уникнути зациклювання в її локальних оптимумах[37]. Однак відомі методи синтезу нейро-нечітких СППР характеризуються низькою швидкістю навчання та надлишковістю

структури і числа параметрів настройки синтезованої СППР, що призводить до низького рівня узагальнення, недостатнього рівня автоматизації процесу навчання в результаті необхідності залучення користувача для задавання набору інформативних ознак, числа нечітких термів, виду і початкових значень параметрів функцій належності, а також експертних правил прийняття рішень [38]. Крім цього у нечітких штучних нейронних мережах існує суттєве обмеження на кількість вхідних змінних внаслідок необхідності розбиття універсальних множин на окремі області [38].

Відносно новим класом методів синтезу інтелектуальних СППР є штучні імунні мережі, що засновані на принципах імунології [39]. Штучні імунні мережі володіють такими інтелектуальними властивостями, як пам'ять, здатність навчатися за прикладами, вміння розпізнавати образи і приймати рішення. Одним із найбільш важливих достоїнств штучних імунних мереж для рішення задач навчання СППР є їх здатність, будучи навченими на наборі об'єктів тільки одного класу, розпізнавати відмінні від них об'єкти іншого класу. Однак відомим методам побудови СППР на базі штучних імунних мереж характерні такі недоліки, як низька швидкість функціонування (в режимі навчання та екзамену), надлишковість структури, значні витрати пам'яті на заберегання моделі штучної імунної мережі, низький рівень узагальнення навчальної інформації та низька інтерпретабельність [40].

Значним досягненням за останні роки у розвитку теорії автоматичної класифікації стало обґрунтування В.І. Васильєвим принципу редукції простору ознак розпізнавання, що обумовлює доцільність зменшення простору ознак розпізнавання, а тому і можливість побудови відносно простих вирішальних правил [41]. У працях [42] запропонована ітераційна процедура навчання розпізнаванню образів, побудована на основі теорії редукції [41] з використанням принципу дуальності оптимального керування [43]. В основі

ітераційної процедури лежить альфа-процедура, яка дозволяє послідовно корегувати простір ознак розпізнавання в процесі його розширення і будувати безпомилкове за навчальною вибіркою лінійне вирішальне правило. Аналіз наведеної процедури показує, що суттєвим її недоліком є використання дистанційного критерію. Здійснення за таким критерієм редукції простору ознак призводить до втрати інформативних ознак, що обумовлює зменшення повної достовірності розпізнавання на екзаміні.

Незважаючи на великий обсяг публікацій у галузі автоматичної класифікації, значних зрушень у підвищенні ефективності навчання СППР для АСК слабо формалізованими процесами все ще не відбувається. Основними причинами такого стану є [43]:

- модельний характер переважної більшості відомих методів автоматичної класифікації, що становить певну теоретико-методологічну цінність, але є непридатним для практичного застосування;
- незавершеність теорії ефективного машинного навчання інтелектуальних систем, проблемою все ще залишається конструювання критеріїв функціональної ефективності з метою оптимізації просторово-часових параметрів функціонування СППР, що навчаються;
- нелінійність, нестационарність і багатфакторність виробничих технологічних процесів, які відбуваються за умов апріорної невизначеності, що й обумовлює їх слабку формалізованість.

Таким чином, аналіз сучасних методів і підходів до автоматичної класифікації дозволяє зробити висновок про те, що теорія ефективного машинного навчання інтелектуальних СППР знаходиться у стані становлення і все ще залишається нерозв'язаною центральною задачею інформаційного синтезу цього класу систем – адаптація вхідного математичного опису з метою побудови безпомилкового за навчальною матрицею класифікатора, що на

практиці функціонує за умов нечіткої компактності реалізацій образів та обмеження обсягу навчальної вибірки [43]. Крім цього загальним недоліком відомих методів розпізнавання, який знижує їх практичну цінність, є відсутність алгоритмів оптимізації процесу навчання за прямим критерієм функціональної ефективності (КФЕ).

На усунення недоліків відомих методів автоматичної класифікації спрямовано інформаційно-екстремальну інтелектуальну технологію (ІЕІ-технологію) аналізу та синтезу здатних навчатися СППР [43], що розроблена в Сумському державному університеті колективом науково-дослідної проблемної лабораторії інтелектуальних систем під науковим керівництвом професора Довбиша А.С., яка ґрунтується на максимізації інформаційної спроможності СППР шляхом введення на етапі навчання додаткових інформаційних обмежень.

Основні концептуальні положення ІЕІ-технології такі:

- ІЕІ-технологія ґрунтується на прямій оцінці інформаційної спроможності АСК, що навчається;
- ІЕІ-технологія дозволяє оптимізувати просторово-часові параметри функціонування СППР, що навчається;
- прийняття рішень у рамках ІЕІ-технології здійснюється в рамках детерміновано-статистичного підходу шляхом побудови відносно простого детермінованого класифікатора, статистична корекція якого здійснюється в процесі навчання з метою побудови безпомилкових, за навчальними матрицями, вирішальних правил;
- методи ІЕІ-технології ґрунтуються на застосуванні гіпотез як чіткої, так і нечіткої компактності реалізацій образу, тобто є працездатним за умови перетину класів розпізнавання; що має місце в практичних задачах контролю та керування;

- методи ІЕІ-технології є об'єктно-структурованими, що дозволяє їх розвивати для вирішення проблеми інформаційного синтезу здатної навчатися СППР з успадкуванням властивостей структурованих об'єктів вищого ієрархічного рівня і до визначенням їх методів;
- методи ІЕІ-технології базуються на вибірковому підході математичної статистики і орієнтовані на застосування прийнятних з практичних міркувань обсягів репрезентативних навчальних вибірок;
- методи ІЕІ-технології є універсальними для проектування здатної навчатися АСКТП будь-якої природи і дозволяє вирішувати як загальну, так і частинні задачі її інформаційного синтезу.

Побудова “точного” контейнера класу розпізнавання складної геометричної форми у багатовимірному просторі ознак навіть для сучасних комп'ютерних комплексів має суттєві ускладнення. Тому при обґрунтованості гіпотези нечіткої компактності в працях [43] згідно з принципом редукції [41] у рамках детерміновано-статистичного підходу пропонується відновлювати контейнери спрощеної форми, наближеної до “точної” деяким оптимальним способом, і які формують вирішальні правила, що забезпечують в режимі екзамену достовірність прийняття рішень, близьку до максимальної асимптотичної.

У загальному випадку математичну (категорійну) модель будь-якої інтелектуальної СППР подамо, аналогічно праці [134], у вигляді діаграми відображень множин, що застосовуються в процесі класифікаційного аналізу (рис. 1.3).




Рис. 1.3. Узагальнена категорійна модель інтелектуальної СППР

На рис. 1.3 прийнято такі позначення:

$T$  – множина моментів часу зняття інформації;

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

$\Omega$  – простір ознак розпізнавання;

$Z$  – простір можливих функціональних станів СППР;

$V$  – множина типів вирішальних правил;

$Y$  – вибіркова множина (вхідна навчальна матриця);

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

$\theta$  – оператор відображення вибіркової множини  $Y$  на нечітке у загальному випадку розбиття  $\tilde{\mathfrak{R}}^{|\mathcal{M}|}$  ( $\tilde{\mathfrak{R}}^{|\mathcal{M}|} \subset \Omega$ ) простору ознак на класи розпізнавання;

$\psi$  – оператор класифікації;

$I^{|\mathcal{M}+1|}$  – множина допустимих гіпотез (рішень), де  $\gamma_{\mathcal{M}+1}$  – гіпотеза про відмову класифікації;

$\xi$  – оператор зворотного зв'язку;

$U: I^{|\mathcal{M}+1|} \rightarrow T \times G \times \Omega \times Z \times V$  – оператор регламентації функціонування СППР.

На рис. 1.3 оператор зворотного зв'язку  $\xi$  корегує геометричні параметри розбиття  $\tilde{\mathfrak{R}}^{|\mathcal{M}|}$  з метою покращення точнісних характеристик СППР і саме спосіб реалізації цього оператора задається різними методами та підходами до навчання інтелектуальних СППР.

Одним з перспективних напрямків створення системи керування протезом кінцівки із неінвазивним способом зчитування біосигналів є застосування так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології)

аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи в процесі її навчання [45]. Основна перевага методів інформаційно-екстремального машинного навчання полягає в можливості адаптації вхідного математичного опису системи до максимальної достовірності розпізнавання образів. При цьому на відміну від нейронних мереж в ІЕІ-технології вирішальні правила будуються в рамках геометричного підходу, що суттєво зменшує вплив проблеми багатовимірності словника ознак і алфавіту класів розпізнавання на функціональну ефективність системи керування.

### 1.3. Критерії схожості об'єктів, що розпізнаються

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 [46]. 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 [46],  $K$ - середніх [47] 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 [48]

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

де  $T$  – символ транспонування вектора-стовбчика;

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

При дисперсії  $1/2 \sigma^2$  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

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

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



Найбільше розповсюдження для оцінки функціональної ефективності інтелектуальних систем знайшли ентропійна (Шеннонівська) міра [49] та інформаційна міра Кульбака [50]. Нормований ентропійний критерій має вигляд [49]

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

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 апіорної невизначеності, то згідно з принципом Бернуллі-Лапласа виправданим є прийняття рівноймовірних 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 [51]

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

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  $X$  – 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;  $X_m$  – 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.Формалізована постановка задачі дослідження

Розв'язання в рамках ІЕІ-технології задачі інформаційного синтезу здатної навчатися системи керування протезом кінцівки зводиться до максимізації найважливішої складової її функціональної ефективності, яка характеризується інформаційною спроможністю системи і визначає достовірність класифікаційних рішень. Тоді має місце така формалізована постановка задачі інформаційного синтезу ІС, що навчається [52].

Нехай відомі алфавіт класів розпізнавання  $\{X_m^o | m = \overline{1, M}\}$  і багатовимірну навчальну матрицю типу «об'єкт-властивість», яка характеризує  $m$ -й функціональний стан системи керування – клас розпізнавання  $X_m^o$ :

$$\| y_{m,i}^{(j)} \| = \begin{vmatrix} y_{m,1}^{(1)} & y_{m,2}^{(1)} & \dots & y_{m,1}^{(1)} & \dots & y_{m,N}^{(1)} \\ y_{m,1}^{(2)} & y_{m,2}^{(2)} & \dots & y_{m,1}^{(2)} & \dots & y_{m,N}^{(2)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y_{m,1}^{(j)} & y_{m,2}^{(j)} & \dots & y_{m,1}^{(j)} & \dots & y_{m,N}^{(j)} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ y_{m,1}^{(n)} & y_{m,2}^{(n)} & \dots & y_{m,1}^{(n)} & \dots & y_{m,N}^{(n)} \end{vmatrix}. \quad (1.4.1)$$

У матриці (1.4.1) рядок є реалізацією образу  $\{y_{m,i}^{(j)} | i = \overline{1, N}\}$ , де  $N$  – кількість ознак розпізнавання, а стовпчик матриці – випадкова навчальна вибірка  $\{y_{m,i}^{(j)} | j = \overline{1, n}\}$ , 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  $E_m$  – інформаційний КФЕ машинного навчання системи керування розпізнавати реалізації класу  $X_m^o$ ;  $G$  – область допустимих значень параметрів функціонування.

На етапі екзамену, тобто безпосереднього функціонування системи керування протезом кінцівки в робочому режимі, необхідно з високою достовірністю класифікувати біосигнал і сформувати керуючу команду на виконавчий пристрій для його реалізації.

## 2 ОПИС МЕТОДУ ДОСЛІДЖЕННЯ

### 2.1 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

$$d_m = \sum_{i=1}^N (x_{m,i} \oplus \lambda_i), \quad (2.1.1)$$

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 ІЕІ-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:

$$d_m(k) = [d_m(k-1) + h \mid d_m(k) \in G_m^d], \quad (2.1.2)$$

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. [53] за багатоциклічною ітераційною процедурою пошуку максимального граничного значення КФЕ навчання КДС у вигляді

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_1 \cap G_E} \frac{1}{M} \sum_{m=1}^M E_m \} \dots \} \}, \quad (2.1.3)$$

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 (2.1.3) згідно з ІЕІ- технологією накладаються такі обмеження:

$$\left( \forall X_m^o \in \tilde{\mathfrak{R}}^{|M|} \right) \left[ X_m^o \neq \emptyset \right]; \quad (2.1.4)$$

$$\left( \exists X_k^o \in \tilde{\mathfrak{R}}^{|M|} \right) \left( \exists X_l^o \in \tilde{\mathfrak{R}}^{|M|} \right) \left[ X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset \right]; \quad (2.1.5)$$

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

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



$$\bigcup_{X_m^o \in \tilde{\mathfrak{R}}} X_m^o \subseteq \Omega_A; k \neq l; k, l, m = \overline{1, M}. \quad (2.1.7)$$

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

$$\left( \forall X_k^o \in \tilde{\mathfrak{R}}^{[M]} \right) \left( \forall X_l^o \in \tilde{\mathfrak{R}}^{[M]} \right) [X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& \& (d_l^* < d(x_k \oplus x_l))], \quad (2.1.8)$$

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.

2.2 Оцінка функціональної ефективності системи керування, що навчається

Центральним питанням інформаційного синтезу системи керування рухомим об'єктом 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 властивостям інформаційних мір [6]/

Серед інформаційних мір найбільшого використання знайшли ентропійна міра [8] та інформаційна міра Кульбака [9].

Подемо нормований ентропійний КФЕ навчання системи керування розпізнавати реалізації класу  $X_m^o$  у вигляді:

$$E_m^{(k)} = \frac{I_m^{(k)}}{I_{\max}^{(k)}} = \frac{H_m^{(k)} - H_m^{(k)}(\gamma)}{H_m^{(k)}}, \quad (2.2.1)$$

де  $I_m^{(k)}$  – кількість умовної інформації, що обробляється на  $k$ -му кроці навчання системи 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, що існує на  $k$ -му кроці навчання системи;  $H_m^{(k)}(\gamma)$  – апостеріорна (умовна) ентропія, що характеризує залишкову невизначеність після  $k$ -го кроку навчання системикерування.

Для двохальтернативної системи оцінок ( $M = 2$ ) і рівноймовірних гіпотез, що характеризує найбільш важкий у статистичному сенсі випадок прийняття рішень, після заміни у виразі (2.2.1) відповідних апостеріорних ймовірностей на апіорні за формулою Байєса [6] ентропійний критерій набирає вигляду

$$\begin{aligned}
E_m^{(k)} = 1 + \frac{1}{2} & \left( \frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{\alpha_m^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} + \right. \\
& + \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{\beta_m^{(k)}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \\
& + \frac{D_{1,m}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} \log_2 \frac{D_{1,m}(d)}{D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)} + \\
& \left. + \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \log_2 \frac{D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + D_{2,m}^{(k)}(d)} \right), \tag{2.2.2}
\end{aligned}$$

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.

Критерій (2.2.2) є нелінійний і взаємно-неоднозначний функціонал від точнісних характеристик, що потребує знаходження в процесі навчання робочої (допустимої) області для його визначення.

Запропонована в праці [6] модифікована інформаційна міра Кульбака розглядається як добуток логарифмічного відношення правдоподібності обчисленої на  $k$ -му кроці машинного навчання повної ймовірності правильного прийняття рішень  $P_{t,m}^{(k)}$  до повної ймовірності помилкового прийняття рішень  $P_{f,m}^{(k)}$  на їх різницю. Для двохальтернативних гіпотез модифікований критерій Кульбака має вигляд [6]

$$\begin{aligned}
E_{K m}^{(k)} &= \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} * [P_{t,m}^{(k)} - P_{f,m}^{(k)}] = \\
&= \left| \begin{array}{l} P_{t,m}^{(k)} = 0,5D_{1,m}^{(k)}(d) + 0,5D_{2,m}^{(k)}(d) \\ P_{f,m}^{(k)} = 0,5\alpha_m^{(k)}(d) + 0,5\beta_m^{(k)}(d) \end{array} \right| = 0,5 \log_2 \left( \frac{D_{1,m}^{(k)}(d) + D_{2,m}^{(k)}(d)}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) * \\
&\quad * [(D_{1,m}^{(k)}(d) + D_{2,m}^{(k)}(d)) - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))] = \\
&= \log_2 \left( \frac{2 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) * [1 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))]. \quad (2.2.3)
\end{aligned}$$

Нормована модифікація критерію (2.2.3) подається у вигляді [6]

$$E_{K,m}^{(k)} = \frac{E_{K m}^{(k)}}{E_{K \max}^{(k)}}, \quad (2.2.4)$$

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 (2.2.4).

Розглянемо процедуру обчислення модифікації ентропійного КФЕ (2.2.2) для двоальтернативного рішення при рівномірних гіпотезах. Оскільки інформаційний критерій є функціоналом від точнісних характеристик, то при репрезентативному обсязі навчальної вибірки необхідно користуватися їх оцінками

$$D_{1,m}^{(k)}(d) = \frac{K_{1,m}^{(k)}}{n_{\min}}; \quad \alpha_m^{(k)}(d) = \frac{K_{2,m}^{(k)}}{n_{\min}}; \quad \beta_m^{(k)}(d) = \frac{K_{3,m}^{(k)}}{n_{\min}}; \quad D_{2,m}^{(k)}(d) = \frac{K_{4,m}^{(k)}}{n_{\min}}, \quad (2.2.5)$$

де  $K_{1,m}^{(k)}$  – кількість подій, які означають належність реалізацій своєму класу  $X_m^o$ ;  $K_{2,m}^{(k)}$  – кількість подій, які означають неналежність реалізацій своєму класу  $X_m^o$ ;  $K_{3,m}^{(k)}$  – кількість подій, які означають належність чужих реалізацій класу  $X_m^o$ ;  $K_{4,m}^{(k)}$  – кількість подій, які означають неналежність чужих реалізацій класу  $X_m^o$ ;  $n_{\min}$  – мінімальний обсяг репрезентативної навчальної вибірки.

Після підстановки відповідних оцінок точнісних характеристик (2.2.6) у вираз (2.2.2) одержимо робочу формулу для обчислення в рамках ІЕІ-технології ентропійного інформаційного КФЕ навчання СППР розпізнаванню реалізацій класу  $X_1^o$

$$E_m^{(k)} = 1 + \frac{1}{2} \left( \frac{K_{1,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} \log_2 \frac{K_{1,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} + \frac{K_{2,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} \log_2 \frac{K_{2,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} + \frac{K_{3,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} \log_2 \frac{K_{3,m}^{(k)}}{K_{1,m}^{(k)} + K_{3,m}^{(k)}} + \frac{K_{4,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} \log_2 \frac{K_{4,m}^{(k)}}{K_{2,m}^{(k)} + K_{4,m}^{(k)}} \right). \quad (2.2.6)$$

Робоча модифікація критерію Кульбака після відповідної підстановки оцінок (2.2.6) у вираз (2.2.4) приймає вигляд

$$E_m^{(k)} = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_2^{(k)} + K_3^{(k)}]}{[K_2^{(k)} + K_3^{(k)}] + 10^{-r}} \right\} [n - (K_2^{(k)} + K_3^{(k)})], \quad (2.2.7)$$

де  $10^{-r}$  – достатньо мале число, що вводиться для уникнення поділу на нуль ( $r$  – число цифр у мантисі значення критерію  $E_m^{(k)}$ ).

Розглянемо схему обчислення коефіцієнтів  $K_2^{(k)}$  і  $K_3^{(k)}$  у формулі (2.2.8).

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  $K_1^{(k)}$ ,  $K_2^{(k)}$ ,  $K_3^{(k)}$  і  $K_4^{(k)}$  має такий предикатний вигляд:

$$(\forall X_1^o \in \mathfrak{R}^{|\Lambda|})(\forall X_2^o \in \mathfrak{R}^{|\Lambda|})[\text{if } x_1^{(j)} \in X_1 \text{ then } K_1^{(k)} := K_1^{(k-1)} + 1 \text{ else } K_2^{(k)} := K_2^{(k-1)} + 1];$$

$$(\forall X_1^o \in \mathfrak{R}^{|\Lambda|})(\forall X_2^o \in \mathfrak{R}^{|\Lambda|})[\text{if } x_2^{(j)} \in X_1 \text{ then } K_3^{(k)} := K_3^{(k)} + 1 \text{ else } K_4^{(k)} := K_4^{(k-1)} + 1].$$

Таким чином, вище наведені інформаційні критерії оптимізації параметрів навчання системи керування в рамках ІЕІ-технології можна розглядати як узагальнені критерії близькості об'єктів, що розпізнаються.

### 3 ІНФОРМАЦІЙНЕ, АПАРАТНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНОГО ПРОТЕЗУ КІНЦІВКИ РУКИ

#### 3.1 Функціональна схема протеза руки з неінвазивною системою зчитування біосигналів

Основна ідея інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки полягає в адаптації вхідного математичного опису до максимальної достовірності класифікації біосигналів з метою формування відповідних керуючих команд для виконуючих пристроїв. При цьому трансформація вхідного апріорно нечіткого розподілу реалізацій образів в чітке здійснюється в процесі оптимізації за інформаційним критерієм функціональної ефективності (КФЕ) параметрів навчання, які впливають на точнісні характеристики класифікаційних рішень. Оптимальні геометричні параметри контейнерів, одержані в процесі машинного навчання дозволяють на екзамені приймати рішення за відносно простими детермінованими вирішальними правилом, що важливо при реалізації алгоритмів прийняття рішень в реальному темпі часу.

На рис. 3.1 наведено схему здатної навчатися системи керування протезом руки, в якій для наочності показано лише інформаційні потоки, основні агрегатовані функціональні вузли та відповідні робочі змінні системи. Прказана на рис.2.1 структура дозволяє функціонувати системі як у режимі навчання, так і в режимі екзамену. Робота системи регламентується користувачем– особою, що приймає рішення (ОПР), який формує біосигнали на виконання конкретних команд  $\{U_m(t) \mid m = \overline{1, M}\}$ , де  $m$  –кількість функціональних станів протезу, які характеризують відповідні його рухи. Біосигнали зчитуються з міографічних



датчиків і подаються послідовно на блоки фільтрації та нормалізації. З виходу блоку нормалізації біосигнал поступає в блок первинної обробки інформації (БПОІ), який перетворює біосигнал шляхом його квантування на заданому часовому інтервалі до вигляду, зручного для подальшого оброблення. З виходу БПОІ квантований за часом біосигнал поступає в блок розвідувального аналізу (БРА) для оцінки статистичної стійкості та однорідності навчальної вибірки за відповідними статистичними критеріями. Якщо виконуються умови статистичної стійкості та однорідності, то біосигнал поступає на вхід блоку формування векторів розпізнавання (БФВР). У БФВР як результат оцінки допускового контролю нормалізованих біосигналів формується бінарна навчальна матриця  $\{x_m^{(j)} \mid j = \overline{1, M}\}$ , 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)  $\{\delta_{n,i} \mid i = \overline{1, N}\}$  поступає в БФВР із бази даних.

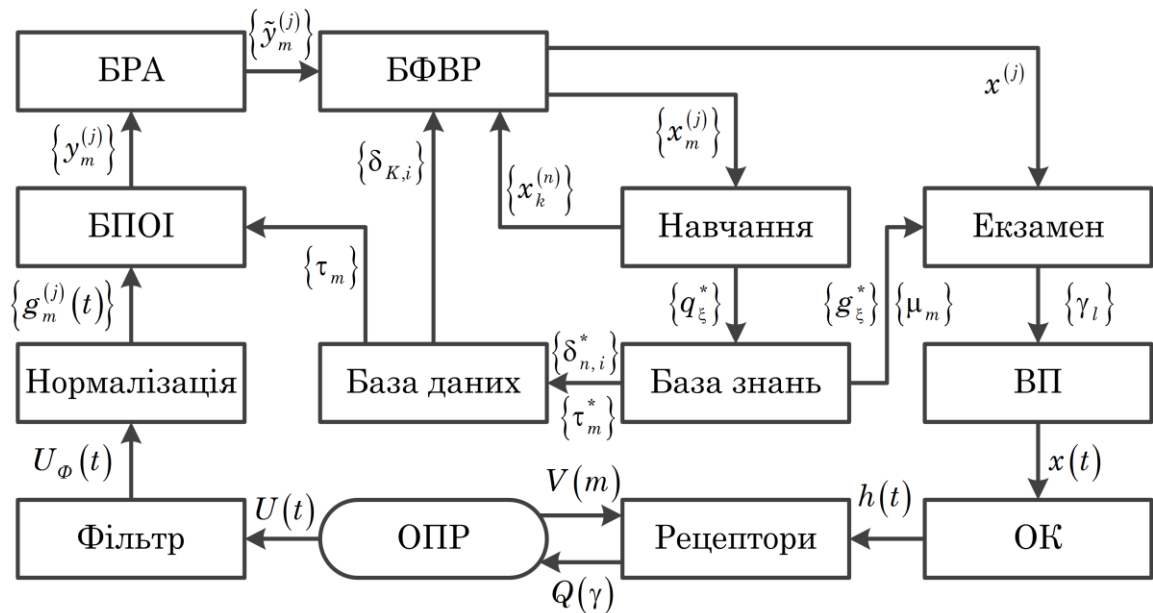


Рисунок 3.1 – Функціональна схема інтелектуальної системи керування протезом руки

На виході БФВР формується структурований випадковий бінарний вектор-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. З виходу БФВР вектори-реалізації біосигналів  $\{x_m^{(j)}\}$  подаються на вхід блоку «Навчання», який згідно з алгоритмами інформаційно-екстремального навчання здійснює оптимізацію параметрів навчання  $\{g_\xi\}$  за інформаційним критерієм. Оптиміальні параметри навчання  $\{g_\xi^*\}$  поступають в базу знань.

При функціонуванні системи керування в режимі екзамену, тобто безпосередньо в робочому режимі, із бази знань визначенні на етапі машинного навчання оптиміальні параметри навчання  $\{g_\xi^*\}$  і вирішальні правила поступають в блок «Екзамен», на інший вхід якого із БФВР поступає вектор-реалізація  $x^{(j)}$  образу, що розпізнається. При цьому із бази знань в базу даних поступають оптиміальні контрольні допуски на ознаки розпізнавання, звідки вони передаються в БФВР для формування екзаменаційного вектора реалізації  $x^{(j)}$ .


Після класифікації біосигналу блок «Екзамен» формує команду  $\gamma_m$ , яка подається на виконавчий пристрій (ВП), який безпосередньо впливає на об'єкт керування (ОК). Зворотний зв'язок в системі здійснюється через рецепторну систему ОПР, який за допомогою запита  $V(m)$  і відгуку  $Q(\gamma)$  формує наступну команду.

Таким чином, розглянута структура системи керування, що навчається, характеризується широкими функціональними можливостями і дозволяє розв'язувати задачі навчання і екзамену. Крім того, така система здатна самонавчатися, використовуючи методи кластер-аналізу для автоматичного


формування вхідної навчальної матриці і методи факторного кластер-аналізу для розширення алфавіту класів розпізнавання [15].

### 3.2 Формування вхідної навчальної матриці


Основними задачами формування вхідного математичного опису здатної навчатися системи керування протезом кінцівки руки є формування словника ознак розпізнавання, алфавіту  $\{X_m^o\}$ ,  $m = \overline{1, M}$  класів розпізнавання, які характеризують можливі функціональні стани керованого протезу, і багатовимірної вхідної навчальної матриці  $\|y_{m,i}^{(j)}\|$ ,  $m = \overline{1, M}; i = \overline{1, N}, j = \overline{1, n}$ , реалізації якої складаються із впорядкованої за часом послідовності значень біосигналу, що зчитується з міографічного датчика при виконанні користувачем протезу певного руху. При цьому необхідно здійснити нормалізацію біосигналу шляхом його квантування із заданим періодом на заданому часовому інтервалі. На рис. 3.1 показано вхідні біосигнали, які зчитувалися із чотирьох міографічних датчиків, розташованих на кінцівці руки при виконанні трьох рухів: поворот кісті протезу лівої руки вправо на  $90^\circ$  – клас розпізнавання  $X_1^o$ ; згинання чотирьох пальців (крім великого) для взяття флешки, що знаходилася на столі) – клас розпізнавання  $X_2^o$  і стиснення кулака з метою захоплення флешки – клас розпізнавання  $X_3^o$ .



*a*



*б*



*в*

Рисунок 3.1 – Приклади біосигналів міографічних датчиків: *a* – клас  $X_1^o$  ;

*б* – клас  $X_2^o$  ; *в* – клас  $X_3^o$

При формуванні навчальної матриці крок квантування біосигналів, показаних на рис.3.1, складав 15 мілісекунд, а інтервал квантування – 2 с.

Таким чином, структурований вектор-реалізація одного класу розпізнавання складався із 480 ознак розпізнавання, які дорівнювали дискретним значенням біосигналів, що зчитувалися послідовно із чотирьох міографічних датчиків.

### 3.3 Алгоритм машинного навчання з паралельною оптимізацією контрольних допусків на ознаки розпізнавання

Обов'язковою процедурою інформаційно-екстремального машинного навчання систем керування є оптимізація контрольних допусків на ознаки розпізнавання. На рис. 3.2. показано категорійну модель інформаційно-екстремального машинного навчання із оптимізацією контрольних допусків на ознаки розпізнавання




Рисунок 3.2 – Категорійна модель машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання

В категорійній моделі (рис. 3.2) показано такі оператори формування вхідного математичного опису системи керування:  $\Phi_1$  – оператор побудови простору ознак розпізнавання;  $\Phi_2$  – оператор формування вхідної навчальної

матриці  $Y$  і  $\Phi_3$  – оператор формування бінарної навчальної матриці  $X$ . Крім того, категорійна модель має додатковий контур оптимізації контрольних допусків на ознаки розпізнавання, який замикається через множину  $D$  – систему контрольних допусків на ознаки розпізнавання.

Згідно з категорійною моделлю (рис. 3.2) інформаційно-екстремальний алгоритм машинного навчання з оптимізацією системи контрольних допусків на ознаки розпізнавання подається у вигляді ітераційної процедури пошуку глобального максимуму усередненого за алфавітом класів розпізнавання, наприклад, інформаційного критерію (2.2.6) в робочій (допустимій) області визначення його функції

$$\delta_K^* = \arg \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \}, \quad (3.3.1)$$

де  $G_\delta$  – допустима область значень параметра  $\delta$  поля контрольних допусків, яєй дорівнює половині двобічного, симетричного поля контрольних допусків.

Вхідною інформацією для алгоритму навчання є масив  $\{y_{m,i}^{(j)}\}$  і система полів нормованих допусків  $\{\delta_{H,i}\}$  на ознаки розпізнавання, яка задає область значень відповідних контрольних допусків.

Розглянемо основні етапи реалізації алгоритму навчання системи розпізнавання з паралельною оптимізацією контрольних допусків на ознаки розпізнавання, за якою на кожному кроці навчання змінюються контрольні допуски для всіх ознак розпізнавання одночасно:

- 1) ініціалізація лічильника кроків зміни параметра  $\delta$  поля контрольних допусків на ознаки розпізнавання:  $\delta := 0$ ;
- 2)  $\delta := \delta + 1$ ;

3) обчислюються для всіх ознак розпізнавання нижні  $A_{НК,i}$  і верхні  $A_{БК,i}$  контрольні допуски на ознаки розпізнавання:

$$A_{НК,i} = \bar{y}_i - \delta; \quad A_{БК,i} = \bar{y}_i + \delta.$$

4) реалізується базовий алгоритм, за наведеною в підрозділі 2.2 схемою;

5) якщо  $\delta < \delta_H / 2$ , то виконується пункт 2, інакше – пункт 6;

6) обчислюється усереднене за алфавітом класів розпізнавання максимальне значення критерію  $\bar{E}^*$ ;

7) визначається оптимальний параметр поля контрольних допусків, який забезпечує максимальне значення усередненого критерію  $\bar{E}^*$ :

$$\delta^* = \arg \bar{E}^* ;$$

8) обчислюється оптимальна система контрольних допусків на ознаки розпізнавання:

$$A_{НК,i}^* = \bar{y}_i - \delta^*; \quad A_{БК,i}^* = \bar{y}_i + \delta^* ;$$

9) ЗУПИН.

Таким чином, параметрами інформаційно-екстремального навчання системи розпізнавання є оптимальні радіуси  $\{d_m^*\}$  гіперсферичних контейнерів класів розпізнавання, оптимальні еталонні вектори-реалізації  $\{x_m^*\}$  класів розпізнавання і оптимальний параметр  $\delta^*$  поля контрольних допусків, які дозволяють побудувати в просторі ознак розпізнавання вирішальні правила (2.2.1) для прийняття рішень при функціонуванні геоінформаційної системи безпосередньо в режимі пошуку зон інтересу на місцевості.

Алгоритми екзамену в рамках ІЕІ-технології можуть мати різну структуру залежно від розподілу реалізацій образу, що розпізнаються. Обов'язковою умовою їх реалізації є забезпечення однакових структурованості і параметрів формування як для навчальної, так і для екзаменаційної матриць.

За наявності чіткого розбиття, яке було утворено на етапі навчання, алгоритм екзамену за МФСВ має такі вхідні дані:

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

За умовчанням приймається рівень селекції  $\rho_m = 0,5$ .

Розглянемо кроки реалізації алгоритма екзамену при застосуванні гіпотези чіткої компактності реалізацій образу:

1. Формування лічильника  $m := m + 1$  класів розпізнавання, які СПР навчена розпізнавати.
2. Формування лічильника  $j := j + 1$  числа реалізацій, що розпізнаються.
3. Порівняння: якщо  $x^{(j)} \in X_m^o$ , то виконується крок 4, інакше – крок 5.
4. Формування лічильника  $k := k + 1$  позитивних результатів порівняння.
5. Порівняння: якщо  $j \leq n$ , то виконується крок 2, інакше – крок 6.
6. Порівняння: якщо  $k > j/2$ , то виконується крок 8, інакше – крок 7.



7. Порівняння: якщо  $t \leq M$ , то виконується крок 1, інакше – крок 8.

8. Визначення класу  $X_m^o$ , до якого належить екзаменаційна матриця. Якщо в процесі екзамену порівняння на кроці 6 не дало позитивного результату, то може бути запущено алгоритм ФКА, з метою донавчання СПР, або алгоритм прогностичної класифікації, з метою підтвердження необхідності перенавчання СПР.

Для нечіткого розбиття алгоритм екзамену за МФСВ ґрунтується на аналізі значень функції належності, яка має вигляд (2.3.8) і обчислюється для кожної реалізації, що розпізнається. Розглянемо кроки реалізації алгоритму екзамену при нечіткому розбитті:

1. Формування лічильника  $m := m + 1$  класів розпізнавання.
2. Формування лічильника  $j := j + 1$  числа реалізацій, що розпізнаються.
3. Обчислення кодової відстані  $d(x_m^* \oplus x^{(j)})$ .
4. Обчислення функції належності (2.3.8):

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

5. Порівняння: якщо  $j \leq n$ , то виконується крок 2, інакше – крок 6.

6. Порівняння: якщо  $t \leq M$ , то виконується крок 1, інакше – крок 7.

7. Визначення класу  $X_m^o$ , до якого належить екзаменаційна реалізація, наприклад, за умови

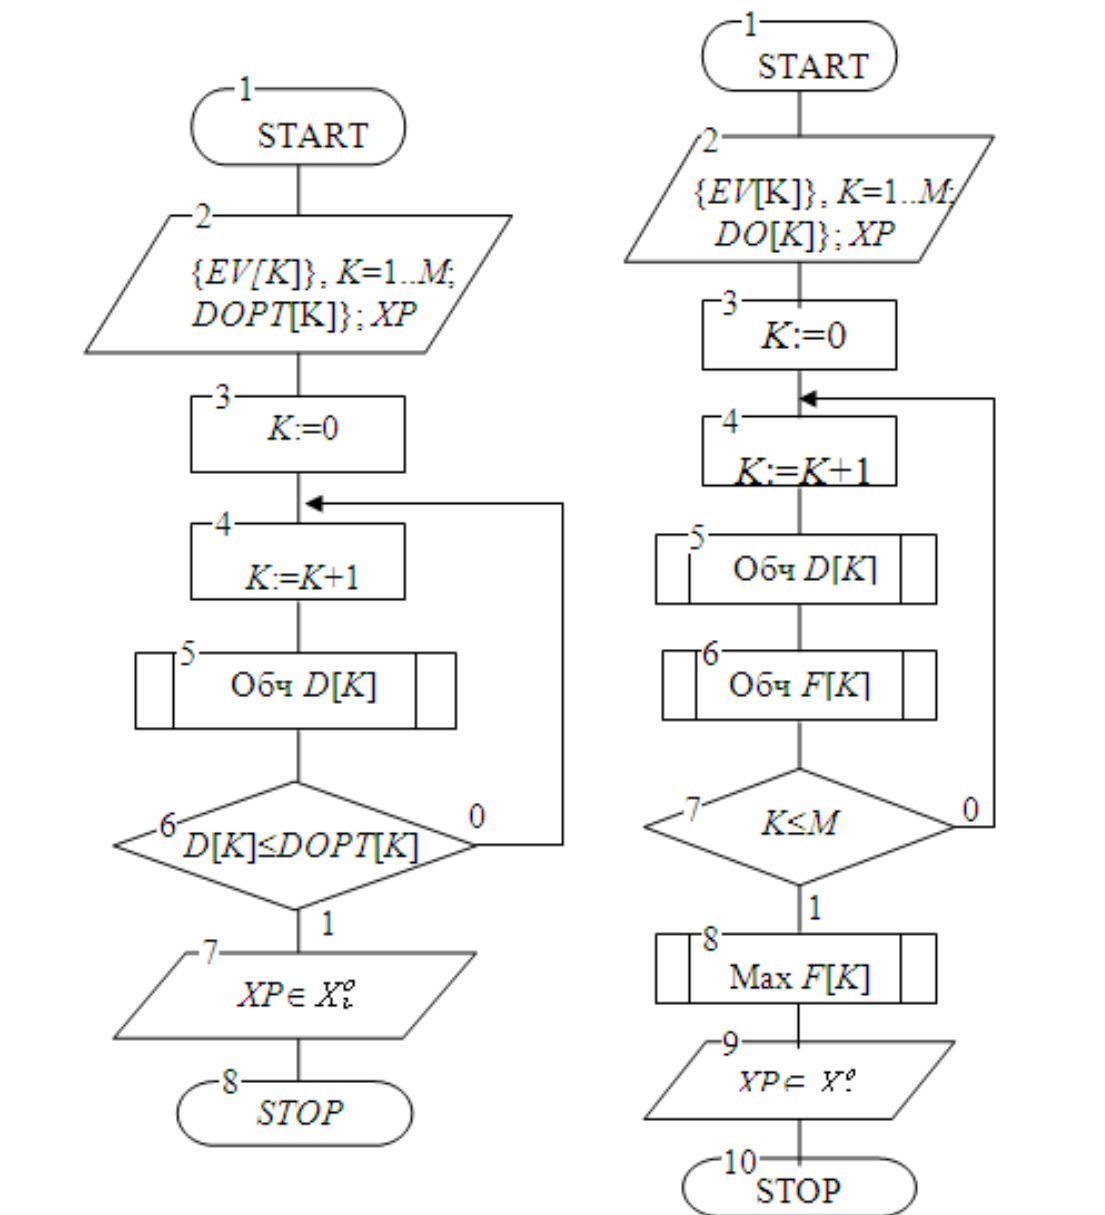
$$\mu_m^* = \max_{\{m\}} \mu_m,$$

де

$$\mu_m = \frac{1}{n} \sum_{j=1}^n \mu_{mj}$$

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.

На рис. 3.5а наведено структурну схему алгоритму екзамену для чіткого розбиття, а на рис. 4.5б – для нечіткого розбиття. Алгоритм має такі вхідні дані:  $\{EV[K]\}$  – масив еталонних двійкових векторів,  $K = \overline{1, M}$  – змінна числа класів розпізнавання;  $\{DOPT[K]\}$  – цілий масив оптимальних радіусів контейнерів класів розпізнавання у кодовій відстані Хеммінга;  $XP$  – двійкова реалізація образу, що розпізнається. Виходом алгоритму є повідомлення про належність реалізації, що розпізнається, деякому класу  $X_k^o$  із сформованого на етапі навчання алфавіту класів  $\{X_m^o\}, k, m = \overline{1, M}$ . На рис. 4.5а блок 5 обчислює, починаючи з базового класу, кодову відстань  $d\{EV[K] \oplus XP\}$  між поточним еталонним вектором і реалізацією  $XP$ . Блок 6 здійснює порівняння кодової відстані реалізації  $XP$  від центру контейнера поточного класу з його оптимальним радіусом, значення якого було винайдено на етапі навчання. За умови позитивної відповіді блоку 6 приймається рішення про належність реалізації  $XP$  одному із класів розпізнавання. Таким чином, при обґрунтуванні гіпотези чіткої компактності реалізацій образу,



а)

б)

Рисунок 3.5 – Структурні схеми алгоритмів екзамену:

а) чітке розбиття; б) нечітке розбиття

СПР приймає на екзамені рішення за простим детермінованим правилом. Не на багато складніше алгоритм екзамену для нечіткого розбиття (рис. 4.5б). Тут вхідні дані такі самі, як і в попередньому випадку. Блок 6 для кожного

класу обчислює значення функції належності  $F[K]$ , яка в позначеннях алгоритму за формулою (2.3.8) має вигляд:

$$F[K] = 1 - \frac{D[K]}{DOPT[K]}.$$

Після виходу із циклу блок 8 визначає клас до якого належить реалізація  $XP$  за максимальним значенням функції належності. У загальному випадку критеріями дефазифікації екзаменаційної матриці можуть бути сумарні значення функцій належності за умови, що вони перебільшують відповідні допустимі порогові значення.

### 3.4 Короткий опис програмного забезпечення

Для створення програмного забезпечення режиму екзамену було обрано мову програмування Arduino, яка дозволяє програмувати мікропроцесори сімейства AVR. Синтаксис мови Arduino схожий на синтаксис мови C/C++ але спрощений за рахунок спеціалізованих функцій та бібліотек.

Алгоритм було реалізовано за допомогою середовища розробки Arduino IDE 1.6.12 у вигляді програми для мікроконтролера. Результати виконання програми виводяться у монітор послідовного порту. Були використані наступні константи та змінні (Табл. 3.3.1):

Таблиця 3.4.1 – Основні константи та змінні програми

Ім'я константи або змінної	Короткий опис
#define M 3	Кількість класів розпізнавання
#define N 50	Кількість ознак розпізнавання
signal; pgZna = 400;	Змінні, за допомогою яких активізуються

	елементи програми, що виконують збір даних з датчиків
vDlt [N]; nDlt [N];	Система контрольних допусків на ознаки розпізнавання
etVktr [M] [N];	Масив еталонних векторів
d [M];	Оптимальні радіуси контейнерів класів навчання
y [N]; x [N];	Матриця реалізації та бінарна матриця реалізації

Крім того було розроблено наступні функції (Табл. 3.4.2):

Таблиця 3.4.2 – Основні процедури та функції програми

Ім'я функції	Короткий опис
fRealiz()	Формування матриці реалізації
fBinMatrix()	Формування бінарної матриці реалізації
calcDist(int vector1[], int vector2[])	Функція для розрахунку відстані між двома векторами в бінарному просторі
fEkzam()	Функція для визначення приналежності до класу

Вимірювання активності м'язів за допомогою електричного потенціалу, що називається електроміографія (ЕМГ), використовується для медичних досліджень та діагностики нервово-м'язових розладів. Однак з появою ще більш потужні мікроконтролерів та інтегральних схем, ЕМГ схеми та датчики знайшли застосування у сфері протезування, робототехніки та інших систем управління.

Характер імпульсів показує що амплітуда сигналу на пряму залежить від сили стискання м'язів. На показники датчику впливають такі фактори, як щільність прилягання контакту, спітнілість шкіри, місце розташування. Саме тому сила сигналу може бути різною. Для формування вектору реалізації використовується порогове значення, яке самостійно визначається програмою як середнє від мінімального та максимального значення. Для знаходження цих значень на початку програми відбувається калібрування відповідно до умов формування вхідних даних.

Зчитування сигналу відбувається неінвазивними методом тому у сигналі з датчику присутні шуми та перепади напруги. Для згладжування сигналу застосовується фільтр Калмана, що дозволило отримати згладжений сигнал без різкої зміни амплітуди.

Формування матриці реалізації починається в той момент коли нормалізований сигнал перетинає порогове значення. Заповнення вектору відбувається шляхом його квантування із заданим періодом на заданому часовому інтервалі.

### 3.5 Результати фізичного моделювання

Алгоритм (3.1) було реалізовано для машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів. При цьому система навчалася розпізнавати три класи, які характеризували основні рухи протезу кінцівки руки: клас  $X_1^o$  – згинання долоні; клас  $X_2^o$  – стискання долоні (утримання предмету) і клас  $X_3^o$  – розгинання долоні.

На рис. 3.3 показано графік залежності усередненого за алфавітом класів розпізнавання інформаційного критерію (3.2) від параметра  $\delta$  поля контрольних

допусків, який на кожному кроці машинного навчання змінювався для всіх ознак розпізнавання одночасно.






Рисунок 3.3 – Графік залежності інформаційного критерію від параметра поля контрольних допусків на ознаки розпізнавання

На рис. 3.3 подвійною штриховкою позначено робочі (допустимі) області визначення критерію (3.2), в яких перша і друга достовірності перевершують відповідно помилки першого і другого роду. При цьому оптимальне значення параметра  $\delta$  визначається максимальною величиною інформаційного критерію у всіх робочих областях. Аналіз графіку показує, що оптимальне значення параметру поля контрольних допусків дорівнює  $\delta^* = \pm 13 mV$  при максимальному значенні ненормованого інформаційного критерію (3.2)  $\bar{E}^* = 1,2$ .


Для побудови вирішальних правил необхідно знання оптимальних в інформаційному розумінні геометричних параметрів контейнерів класів розпізнавання. На рис. 3.4 показано графіки залежності інформаційного критерію (3.2) від радіусів контейнерів класів розпізнавання, одержані при оптимальному параметрі поля контрольних допусків на ознаки розпізнавання.



а



б



в

Рисунок 3.4 – Графіки залежності інформаційного критерію (3.2) від радіусів контейнерів класів розпізнавання: а – клас  $X_1^o$ ; б – клас  $X_2^o$ ; в – клас  $X_3^o$



Аналіз рис. 3.4 показує, що оптимальні значення радіусів контейнерів класів розпізнавання, визначені при оптимальному параметрі поля контрольних допусків дорівнюють: для класу  $X_1^o - d_1^* = 20$  (тут і далі в кодових одиницях); для класу  $X_2^o - d_2^* = 24$  і для класу  $X_3^o - d_3^* = 12$ .

Для підвищення функціональної ефективності машинного навчання системи керування протезом було реалізовано алгоритм послідовної оптимізації контрольних допусків. При цьому отримані за результатами паралельної оптимізації контрольні допуски на ознаки розпізнавання розглядалися як стартові для їх послідовної оптимізації. Такий підхід дозволив суттєво підвищити оперативність машинного навчання, оскільки послідовна оптимізація контрольних допусків відбувалася в робочій області визначення функції інформаційного критерію (3.2).

На рис. 3.5 показано динаміку зміни максимальних значень усередненого за алфавітом класів розпізнавання інформаційного критерію при реалізації процедури послідовної оптимізації контрольних допусків на ознаки розпізнавання.




Рисунок 3.5 – Графік зміни максимальних значень інформаційного критерію в процесі послідовної оптимізації контрольних допусків на ознаки розпізнавання

Оскільки кількість ітерацій послідовної оптимізації визначається кількістю ознак розпізнавання, то аналіз рис. 3.5 показує, що вже на другому прогоні процедури (3.5) було досягнуто максимальне значення інформаційного критерію оптимізації, яке дорівнює  $\bar{E}^* = 1,8$ , що суттєво перевершує його значення, отримане за результатами паралельної оптимізації контрольних допусків ознаки розпізнавання.

На рис. 3.6 показано графіки залежності інформаційного критерію (5) від радіусів контейнерів класів розпізнавання, побудовані при одержаних за результатами послідовної оптимізації оптимальних контрольних допусках на ознаки розпізнавання.

Для створення протезу, який буде виглядати як справжня рука, потрібно детально розглянути анатомічну будову кісток та м'язів звичайної руки людини, яка складається з плеча, передпліччя та кисті, котра найскладніша у своїй будові і також поділяється на зап'ястя, п'ястя та пальці.

Палець людини поділений на фаланги, що забезпечує стискання долоні у кулак. За це відповідають суглоби та сухожилля, які дуже міцні і водночас еластичні. Для руху пальців недостатньо одних суглобів та сухожиль, тому на долоні людини присутні м'язи, які разом з сухожиллям надають можливість руці міцно стискати долоню. Важливим фактором є те, що сухожилля проходять від кінцівки пальця до самого передпліччя, що також набагато збільшує силу, яку треба прикласти для того, щоб розтиснути долоню.

Сучасні механічні та автоматизовані пристрої, зокрема промислові маніпулятори найчастіше складаються з металевих деталей та мають велику вагу. Для підприємства чи цеху ці фактори не мають великої ролі, але коли мова йде про електронно-механічний пристрій, який приєднаний до людини, ці

фактори відіграють велику роль, так як перевантажують тіло людини. В такому випадку цей механізм перетворюється з допоміжного у заважаючий.

Значно краще, якщо механічна частина буде легкою і водночас функціонально-гнучкою, тому такий матеріал як пластмаса є найбільш вдалим для використання. Проте при виборі матеріалу слід врахувати той факт, що зараз існує безліч видів пластику – від гнучкого до твердого, від хімічно безпечного для людини і навпаки отруйного для неї.


Звичайний процес створення пластмасової руки дуже складний і вимагає багато ресурсів. Проте 3D-друк вдало вирішує цю проблему. Він забезпечує малі затрати виробництва і велику точність виробів із пластику та навіть з металу. Тому ця технологія якнайкраще підходить для виконання легкого та конструктивно точного механічного виробу.

Рух пальців маніпулятора здійснюється завдяки протягнутому уздовж пальця з передньої та задньої сторони тросика. Він, проходячи через спеціальні отвори у пальцях, розміщується у канавці рифленого підшипника. Далі тросик натягується серводвигуном захованим у середину корпусу руки. При обертанні двигуна тросик натягується, завдяки чому відбувається стискання пальця. На моторах встановлені редуктори, які зменшують швидкість обертів, але при цьому збільшують момент крутіння, що забезпечує міцне стискання усіх пальців руки.

На рис. 3.3.2 показано загальний вигляд та компоновка інтелектуального протезу руки



а



б

Рис. 3.3.2. – Результати фізичного моделювання: а – роздрукована на 3-D принтері пластмасова оболонка руки; б – міографічний датчик підключений до руки людини;

## ВИСНОВКИ

1. В результаті виконання роботи розроблено категорійні моделі функціонування системи керування протезом кінцівки руки на основі яких реалізовано в рамках інформаційно-екстремальної інтелектуальної технології алгоритми функціонування системи в режимі машинного навчання

2. В результаті машинного навчання системи керування протезом кінцівки руки здійснено оптимізацію системи контрольних допусків на ознаки розпізнавання, досліджено їх вплив на функціональну ефективність навчання системи і побудовано вирішальні правила.

3. За результатами фізичного моделювання доведено, що машинне навчання системи керування протезом кінцівки руки з оптимізацією системи контрольних допусків дозволило суттєво підвищити достовірність розпізнавання зображень у порівнянні з базовим алгоритмом навчання.

4. Як один із шляхів підвищення функціональної ефективності системи керування протезом кінцівки руки необхідно додатково здійснити “глибоке” навчання, яке полягає в оптимізації параметрів оброблення зображень біосигналів з метою підвищення інформативності ознак розпізнавання.

5. За одержаними в роботі результатами опубліковано тези доповіді на Міжнародній науковій конференції з автоматичного управління «Автоматика – 2016» і наукову статтю в журналі «Біоніка інтелекту».

## СПИСОК ЛІТЕРАТУРИ

1. Farrell T. R. A comparison of the effects of electrode implantation and targeting on pattern classification accuracy for prosthesis control / T. R. A Farrell, R.F. Weir // Biomedical Engineering. – IEEE Press, Vol. 55, N. 9. – 2008. – P. 2198-2211.
2. Conradt J. Artificial prosthetic limbs Problems and solutions for connecting brains and robots / J. Conradt // Neuroscientific system theory. – Munich, Germany : TUM. – 2015. – 39 p.
3. Барский А.Б. Нейронные сети: распознавание, управление, принятие решений / А.Б. Барский. – М.: Финансы и статистика. – 2004. – 176 с.
4. Chowdhury R. H. Surface Electromyography Signal Processing and Classification Techniques / R. H. Chowdhury, M. B. I. Reaz, M. A. B. M. Ali, A. A. A. Bakar, K. Chellappan, T. G. Chang // Sensors. – Basel, Switzerland : MDPI. – 2013. – P. 12431-12466.
5. Benatti S. Analysis of robust implementation of an emg pattern recognition based control / S. Benatti, E. Farella, L. Benini, E. Gruppioni // Conference: International Conference on Bio-inspired Systems and Signal. – Angers, France : BIOSIGNALS. – 2014. – P. 45-54
6. Довбиш А.С. Основи проектування інтелектуальних систем: Навчальний посібник / А.С. Довбиш.– Суми: Видавництво СумДУ, 2009.– 171 с.
7. Довбиш А.С. Інтелектуальні інформаційні технології в електронному навчанні / А.С. Довбиш, А.В. Васильєв, В.О. Любчак. – Суми: Видавництво СумДУ, 2013.– 178 с.
8. Ивахненко А. Г. О принципах построения обучающихся систем управления сложными процессами / А. Г. Ивахненко. – М.: Наука, 1970. – 252 с.
9. Карпов В.С. Адаптивные регуляторы состояния с частотным разделением каналов управления и самонастройки для объектов с

запаздыванием / В.С. Карпов, В.М. Мазуров // науч. журнал Теория и системы управления. – 1995. – №1. – С. 168–176.іvіv

10. Анохин П. К. Биология и нейрофизиология условного рефлекса / П. К. Анохин. – М.: Медицина. – 1968. – 547 с.

11. Хемминг Р.В. Численные методы для научных работников и инженеров. Пер с англ. / Р.В. Хемминг.– 1968. – 203 с. Фомин Я. А. Статистическая теория распознавания образов / Я. А. Фомин, Г. Р. Тарловский. – М.: Радио и связь. – 1986.– 264 с.

12. Duda R. O. Pattern Classification: second ed. / R. O. Duda, P. E. Hart, D. G. Stork. – New York: John Wiley & Sons. – 2001. – 738 p.

13. Костюк В.И. Промышленные роботы в сборочном производстве / В.И. Костюк, Л.С. Ямпольский, И.Б. Иваненко. – К.: Техніка. – 1983. – 184 с.

14. Волошин Г.Я. Методы распознавания образов: конспект лекций / Г.Я. Волошин. – Владивосток. – 2000. – 80 с.

15. Довбиш А.С. Основи проектування інтелектуальних систем: Навчальний посібник / А.С. Довбиш. – Суми: Видавництво СумДУ, 2009. □ 171 с.

16. Турбович И. Т. Опознавание образов. Детерминир.-статист. подход / И.Т. Турбович, В.Г. Гитис, В.К. Маслов. □ М.: Наука. □ 1971. □ 246 с.

17. Анисимов Б. Распознавание и цифровая обработка изображений / Б. В. Анисимов, В. Д. Курганов, В. К. Злобин. □ М.: Высшая школа. – 1983.–256 с.

18. Загоруйко Н.Г. Прикладные методы анализа данных и знаний / Н.Г. Загоруйко. – Новосибирск: ИМ СО РАН. – 1999. – 270 с.

19. Путятин Е.П. Обработка изображений в робототехнике / Е.П. Путятин, С.И. Аверин. – М: Машиностроение. – 1990. – 320 с.

20. Ивахненко А.Г. Самообучающиеся системы распознавания и автоматического управления. – Киев: Техніка. – 1969. – 392 с.
21. Рыжов А.П. О качестве классификации объектов на основе нечетких правил / А.П. Рыжов // Интеллектуальные системы. – Том 9, Выпуск 2. – 2005 – С. 253–264.
22. Zadeh L. A. Fuzzi sets / L. A. Zadeh // Information and Control. □ 1965. □ №8. □ P. p. 338□353.
23. Субботін С.О. Подання й обробка знань у системах штучного інтелекту та підтримки прийняття рішень / С.О. Субботін. – Запоріжжя:ЗНТУ. – 2008. – 341 с.
24. Будник М.М. Класифікація груп на основі нормованих функцій розподілу в медицині / М.М. Будник // Управляючі системи і машини. 2007. №3 – С.57-64.
25. Барский А.Б. Нейронные сети: распознавание, управление, принятие решений / А.Б. Барский. – М.:Финансы и статистика. – 2004. – 176 с.
26. Зайченко Ю.П. Основы проектирования интеллектуальных систем / Ю.П. Зайченко. – К.: Вид. Дім. “Слово”. – 2004. – 352 с.
27. Sledge I.J. Growing Neural Gas for Temporal Clustering / I.J. Sledge, J.M. Keller // 19th International Conference on Pattern Recognition (ICPR 2008), 8-11 Dec., 2008. – P. 1–4.
28. Podolak I.T. A Hierarchical Classifier with Growing Neural GAS Clustering / I.T. Podolak, K. Bartocha // Adaptive and Natural Computing Algorithm. – Springer-Verlag Berlin Heidelberg. – 2009. – Volume 5495.– P. 283–292.
29. Осовский С. Нейронные сети для обработки информации: Пер. с польського И.Д. Рудинского / С. Осовский. – М.: Финансы и статистика. – 2004. – 344 с.



30. Leonard J.A. Radial basis function networks for classifying process faults / J.A. Leonard, M.A. Kramer // IEEE Control System Magazine, 1991, April. – P. 31–38.
31. Hopfield J. Neural computations of decisions in optimization problem / J. Hopfield, D. Tank // Biological Cybernetics. – 1985.– Vol. 52.– P. 141–152.
32. Lippmann R. An introduction to computing with neural nets / R. Lippmann // IEEE ASSP Magazine, 1987. April. – P. 4–22.
33. Kovačević V.B. High-speed implementation of Hamming neural network / V.B. Kovačević, A.M. Gavrovska, M.P. Paskaš // Conference Publications: Neural Network Applications in Electrical Engineering (NEUREL), 2010 10th Symposium on 23-25 Sept. – 2010. – P. 167–170.
34. Дубровин В.И. Интеллектуальные средства диагностики и прогнозирования надежности авиадвигателей. Монография / В.И. Дубровин, С.А. Субботин, А.В. Богуслаев, В.К. Яценко. – Запорожье: ОАО «Мотор-Сич». – 2003. - 279 с.
35. Forest S. Self-nonsel discrimination in a computer / S. Forest, A.S. Perelson, L. Allen, R. Cherukuri // Research in security and privacy: 1994 IEEE Symposium, California, 1-18 May 1994: proceedings. – Los Alamitor: IEEE Press, 1994. – P.202-212.
36. Dasgupta D. Artificial immune systems in industrial applications / D. Dasgupta, S. Forest // Intelligent processing and manufacturing material: international conference IPMM'99, Honolulu, 10-14 July 1999: proceedings. – New York: Wiley Computer Publishing, 1999.– P.121-135.\
37. Ji Z. Revisiting negative selection algorithms / Z. Ji, D. Dasgupta // Evolutionary computation. – 2007. – Vol. 15. – P. 223-251.

38. Васильев В. И. Единство задач обучения распознаванию образов, восстановления зависимостей и функций принадлежности / В.И. Васильев // Управляющие системы и машины. □ №6. □ 2002. □ С. 3 □ 9.

39. Фельдбаум А.А. Основы теории оптимальных автоматических систем. Изд. 2-е, испр. и доп / А.А. Фельдбаум. – М: Наука. – 1966. – 623 с.

40. Краснополюсовський А.С. Інформаційний аналіз і синтез нечіткого регулятора системи керування, що навчається : дис. д-ра техн. наук: 05.13.03 / Національний аерокосмічний ун-т ім. М.Є.Жуковського Харківський авіаційний ін-т. – Х. – 2005.

41. Дмитриев А. К. Основы теории построения и контроля сложных систем / А. К. Дмитриев, П. А. Мальцев. □ Л.: Энергоатомиздат. Ленингр. отделение. – 1988. □ 192 с.

42. Довбыш А.С. Информационно-экстремальный алгоритм оценки состояния узлов телекоммуникационной GRID-системы / Довбыш А.С., Москаленко В.В. // 22-я Международная Крымская конференция «СВЧ – техника и телекоммуникационные технологии» 10-14 сентября 2012, Севастополь, Крым, Украина. – Том 1. –С. 415-416.

43. Суздаль В.С. Проектирование многомерной робастной системы управления процессами кристаллизации / В.С. Суздаль, А.В. Соболев, Ю.М. Епифанов // Науковий вісник КУЕІТУ “Нові технології”.– 2010. – №1(27). – С.151–153.

44. Оксанич А.П. Архитектура и функциональность двухуровневой АСУТП выращивания слитков кремния / А.П. Оксанич, В.Р. Петренко, С.Э. Притчин // науковий журнал "Складні системи і процеси ". – 2005.– №1.– С. 78–84.

45. Литюга А. М. Теоретические основы построения эффективных АСУ ТП / А. М. Литюга, Н. В. Клиначёв, В. М. Мазуров. – Тула, Челябинск. – 2002. – 627 с.

46. Мазуров В.М. Адаптивный ПИД-регулятор с частотным разделением каналов управления и самонастройки / В.М. Мазуров, В.В. Кондратьев // Приборы и системы управления, 1995, №1. - С. 33–35.

47. Карпов В.С. Адаптивные регуляторы состояния с частотным разделением каналов управления и самонастройки для объектов с запаздыванием / В.С. Карпов, В.М. Мазуров // науч. журнал Теория и системы управления. – 1995. – №1. – С. 168–176.

48. Оксанич А.П. Система контроля диаметра слитка кремния в процессе выращивания/ А.П. Оксанич, С.Э. Притчин // Передовые технологии и технические решения. – 2004. – № 1. – С. 6 –8.

49. 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.

50. Ортега Дж. Введение в численные методы решения дифференциальных уравнений. Пер.с англ. / Дж. Ортега, У. Пул. – М.: Наука. – 1986. – 288 с.

## ДОДАТОК А

## Лістинг програми функціонування в режимі екзамену

```
#define N 50
#define M 3

int vDlt[N];
int nDlt[N];
int etVktr[M][N];
int d[M];
int y[N];
int x[N];
int sygnal;
int pgZna = 400;

void fRealiz(){
    Serial.println("Realizacia:");
    if(sygnal>pgZna){
        for(int i=0; i<N; i++){
            y[i] = sygnal;
            delay(50);
            Serial.print(y[i]);
        }
        Serial.println();
    }
    delay(2000);
}

void fBinMatrix(){
    for(int i=0; i<N; i++){
        if(y[i]>nDlt[i] && y[i]<vDlt[i])
            x[i]=1;
    }
}
```

```

        else
            x[i]=0;
        Serial.print(x[i]);
    }
    Serial.println();
}

int calcDist(int vector1[], int vector2[]){
    int sum = 0;
    for (int i=0; i<N; i++){
        if(vector1[i]!=vector2[i]){
            sum++ ;
        }
    }
    return sum;
}

int fEkzam(){
    int nKlas = -1;
    int minDist = N;
    int dist;
    for (int i=0; i<M; i++){
        dist = calcDist(x,etVktr[i]);
        if(dist<minDist && dist<d[i]){
            minDist = dist;
            nKlas = i;
        }
    }
    return nKlas;
}

int fEkzam2(){
    int mu_k_max;
    int mu_max = -1;

```

```
int mu[N];
int dist;
for (int i=0; i<M; i++){
    mu[i]=0;
    dist=calcDist(x,etVktr[i]);
    mu[i]=1-dist/d[i];
    if(mu[i]>mu_max) mu_k_max=i;
}
if(mu_max<0) mu_k_max=-1;
return mu_k_max;
}
void setup() {
}
void loop() {
    sygnal = analogRead(A0);
    fRealiz();
    fBinMatrix();
    int recKlas = fEkzam2();
    if(recKlas == -1) Serial.println("Ne nalejit klasu!");
    else Serial.println(recKlas);
}
```