

УДК 681.518:004.93.1'

УКПП

№ держреєстрації 0117U002248

Інв. №

Міністерство освіти та науки України

Сумський державний університет

(СумДУ)

40007, м. Суми, вул. Римського-Корсакова, 2

тел. (0542) 33-41-08      факс (0542) 33-40-49

ЗАТВЕРДЖУЮ

Проректор з наукової роботи  
д-р фіз.-мат. наук, професор

\_\_\_\_\_ А.М. Чорноус

ЗВІТ  
ПРО НАУКОВО-ДОСЛІДНУ РОБОТУ  
**ІНТЕЛЕКТУАЛЬНИЙ ПРОТЕЗ КІНЦІВКИ, ЩО САМОНАВЧАЄТЬСЯ**  
(проміжний)

Начальник НДЧ

канд. фіз.-мат. наук, снс

Д.І. Курбатов

\_\_\_\_\_ (підпись)

Науковий керівник НДР

д-р техн. наук, професор

А.С. Довбиш

\_\_\_\_\_ (підпись)

2018

Рукопис закінчено 20 грудня 2018 р.

Результати цієї роботи розглянуто науковою радою СумДУ, протокол від 27.12.2018 р. № 6

## СПИСОК АВТОРІВ

Керівник НДР, д-р техн.  
наук, професор,  
гол. наук. співроб.

(15.12.2018)

А.С. Довбиш (вступ, висновки,  
підрозділи 1.4, 3.3)

Відповідальний  
виконавець:  
Канд. техн. наук, старш.  
наук. співроб.

(15.12.2018)

I.B. Шелехов (підрозділи 2.2, 3.1)

Виконавці:  
Канд. техн. наук, старш.  
наук. співроб.

(15.12.2018)

B.B. Москаленко (підрозділи 1.1, 3.2)

Провідний інженер

(15.12.2018)

Г.В. Токаренко (підрозділ 1.3)

Канд. техн. наук,  
лаборант

(15.12.2018)

B.K. Ободяк (підрозділ 1.2)

Аспірант,  
лаборант

(15.12.2018)

B.YO. П'ятченко (підрозділи 2.1, 2.3, 3.4)

## РЕФЕРАТ

Звіт про НДР: 70 с., 11 рис., 3 табл., 23 джерела.

**СИСТЕМА КЕРУВАННЯ, МАШИННЕ НАВЧАННЯ, ОПТИМІЗАЦІЯ,  
НЕІНВАЗИВНА СИСТЕМА ЗЧИТУВАННЯ БІОСИГНАЛІВ,  
ІНФОРМАЦІЙНИЙ КРИТЕРІЙ, ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА  
ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ, РІВЕНЬ КВАНТУВАННЯ  
БІОСИГНАЛІВ, ІЄРАРХІЧНИЙ АЛГОРИТМ.**

Об'єктом дослідження є процес класифікаційного керування здатним самонавчатися протезом кінцівки руки на пасивних міографічних датчиках.

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

Предмет дослідження – категорійні моделі, методи машинного навчання та розпізнавання образів в рамках інформаційно-екстремальної інтелектуальної технології аналізу даних, метод формування вхідного математичного опису здатної навчатися системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

Досліджено питання формування вхідного математичного опису системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів. Удосконалено метод оцінки функціональної ефективності машинного навчання системи керування і запропоновано нові модифікації інформаційного критерію оптимізації параметрів машинного навчання. Розроблено категорійні моделі здатної навчатися системи керування протезом кінцівки руки і на їх базі розроблено алгоритми машинного навчання з оптимізацією контрольних допусків на ознаки розпізнавання та рівнів квантування біосигналів.

## ЗМІСТ

|  |           |
|--|-----------|
| РЕФЕРАТ .....  | 3         |
| ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ .....  | 5         |
| ВСТУП .....  | 6         |
| <b>1 ФОРМУВАННЯ ВХІДНОГО ОПИСУ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ<br/>КЕРУВАННЯ ПРОТЕЗОМ КІНЦІВКИ РУКИ .....</b>  | <b>8</b>  |
| 1.1 Формування вхідного математичного опису .....  | 8         |
| 1.2 Визначення мінімального обсягу репрезентативної навчальної вибірки   | 10        |
| 1.3 Визначення нормованих допусків на ознаки розпізнавання .....   | 19        |
| 1.4 Оцінка статистичної стійкості та однорідності навчальної вибірки .....   | 25        |
| <b>2 ОЦІНКА ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ СИСТЕМИ<br/>КЕРУВАННЯ, ЩО НАВЧАЄТЬСЯ .....</b>   | <b>27</b> |
| 2.1 Оцінка функціональної ефективності здатної навчатися системи<br>керування при двохальтернативних рішеннях .....                                | 27        |
| 2.2 Оцінка функціональної ефективності системи керування при<br>трьохальтернативних рішеннях.....  | 35        |
| 2.3 Оцінка функціональної ефективності системи керування при<br>трьохальтернативних рішеннях при застосуванні методу К-найближчих<br>сусідів ..... | 37        |
| <b>3 ІНФОРМАЦІЙНИЙ СИНТЕЗ СИСТЕМИ КЕРУВАННЯ ПРОТЕЗОМ<br/>РУКИ .....</b>  | <b>45</b> |
| 3.1 Категорійна модель машинного навчання системи керування протезом<br>кінцівки руки з неінвазивною системою зчитування біосигналів.....          | 45        |
| 3.2 Алгоритм машинного навчання системи керування протезом руки з<br>неінвазивною системою зчитування біосигналів .....                            | 47        |
| 3.3 Формалізована постановка задачі інформаційного синтезу системи<br>керування протезом, що навчається за ієрархічним алгоритмом .....            | 53        |
| 3.4 Алгоритм інформаційно-екстремального ієрархічного машинного<br>навчання.....   | 56        |
| <b>ВИСНОВКИ.....</b>   | <b>65</b> |
| <b>ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ .....</b>  | <b>67</b> |

## **ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ**

ІЕІ-технологія – інформаційно-екстремальна інтелектуальна технологія;  
КФЕ – критерій функціональної ефективності;  
НТР – науково-технічна розробка;  
ОПР – особа, що приймає рішення;  
СКД – система контрольних допусків;  
СППР – система підтримки прийняття рішень.

## ВСТУП

Створення інтелектуальних протезів руки на основі машинного навчання та розпізнавання образів дозволяє суттєво розширити їх функціональні можливості, забезпечити реабілітацію людини з інвалідністю та її адаптацію до повноцінного життя, що має важливе соціально-економічне значення. У порівнянні з протезами руки з інвазивною системою зчитування біосигналів протези з неінвазивною системою зчитування є суттєво дешевшими та зручнішими при їх використанні. Але через високу зашумленість біосигналів, багатовимірність простору ознак розпізнавання і суттєвий перетин в просторі ознак розпізнавання класів розпізнавання, які характеризують основні рухи протезу, розробка інтелектуальних протезів вимагає подолання ускладнень науково-методологічного характеру. Саме через ці причини алгоритми машинного навчання системи керування протезом руки з використанням відомих методів технології Data Mining, включаючи нейронні та імунні мережі, не забезпечують високу точність виконання команд.

Тому НДР, яка виконується на кафедрі комп’ютерних наук Сумського державного університету, спрямована на розв’язання важливої науково-практичної задачі підвищення функціональної ефективності протезів руки з неінвазивною системою зчитування біосигналів і наближення їх до функціональних можливостей інвазивних при збереженні відносно невисокої собівартості є актуальною.

НДР виконується в рамках створеної в Сумському державному університеті так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи керування в процесі машинного навчання.

Проміжний звіт НДР складається із вступу, трьох розділів, висновків і переліку посилань.

Перший розділ присвячено питанням формування вхідного математичного опису системи керування протезом руки з неінвазивною системою зчитування біосигналів.

У другому розділі розглянуто інформаційні критерії оптимізації параметрів інформаційно-екстремального машинного навчання при двох альтернативних і трьохальтернативних системах оцінки класифікаційних рішень.

Третій розділ присвячено інформаційному синтезу здатної навчатися системи керування протезом руки з неінвазивною системою зчитування біосигналів.

Результати наукових досліджень, одержаних виконавцями проекту, опубліковано в працях [1 – 16].

# 1 ФОРМУВАННЯ ВХІДНОГО ОПИСУ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ КЕРУВАННЯ ПРОТЕЗОМ КІНЦІВКИ РУКИ

## 1.1 Формування вхідного математичного опису

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

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

Таким чином, формування вхідного математичного опису інтелектуальної системи керування потребує детального вивчення та аналізу особливостей функціонування джерела інформації, яким у біонічного протезу є біографічний датчик біосигналів.

Вхідний математичний опис подамо у вигляді теоретико-множинної структури [17]

$$\Delta_B = \langle G, T, \Omega, Z, Y; \Pi, \Phi \rangle, \quad (1.1)$$

де  $G$  – простір вхідних сигналів (факторів), які діють на інтелектуальну систему керування;

$T$  – множина моментів часу зняття інформації;

$\Omega$  – простір ознак розпізнавання;

$Z$  – простір можливих функціональних станів інтелектуальної системи керування;

$Y$  – множина сигналів, які знімаються з виходу блоку первинної обробки інформації;

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

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

Як універсум випробувань  $W$  розглядається декартовий добуток наведених в (2.1) множин:

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

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

Формування алфавіту класів розпізнавання  $\{X_m^o\}$  може здійснюватися як розробником інформаційного забезпечення, так і безпосередньо ІС, що здатна функціонувати в режимі кластер-аналізу. При цьому варто враховувати, що збільшення потужності алфавіту при незмінному словнику ознак розпізнавання суттєво впливає на асимптотичні точнісні характеристики, що характеризують функціональну ефективність навчання системи, через збільшення ступеня перетину класів розпізнавання. Це

питання для IEI-технології докладно досліджено в праці [17]. Один із найпростіших імовірнісних критеріїв перетину класів для заданого алфавіту може бути подано як відношення помилки другого роду до першої достовірності, яке обчислюється на  $k$ -му кроці ітераційного навчання:

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

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

## **1.2 Визначення мінімального обсягу репрезентативної навчальної вибірки**

Функціональна ефективність машинного навчання системи керування протезом руки з неінвазивною системою зчитування біосигналів суттєво залежить від якості формування вхідного математичного опису системи. Одними із основних показників функціональної ефективності здатної навчатися системи є повна ймовірність правильного прийняття класифікаційних рішень та оперативність машинного навчання. Із математичної статистики відомо чим більше обсяг випадкової навчальної вибірки, тим менше статистична похибка є між ймовірністю  $p_i$  та емпіричною частотою  $\tilde{p}_i$  знаходження значення  $i$ -ої ознаки розпізнавання в своїх контрольних допусках

$$\tilde{p}_i = \frac{n_i}{n},$$

де  $n_i$  – кількість подій знаходження  $i$ -ої ознаки розпізнавання в своєму полі  $\delta_{K,i}$  контрольних допусків.

Згідно з теоремою Муавра-Лапласа [19] верхня оцінка статистичної похибки  $\varepsilon_{\max}$  є функцією від кількості випробувань  $n$ . Але на практиці виконання цієї умови пов'язано з суттєвими матеріальними та часовими витратами. Тому при формуванні вхідної навчальної матриці визначення мінімального обсягу  $n_{\min}$  репрезентативної навчальної вибірки доцільно здійснювати за умови отримання прийнятної з практичних міркувань статистичної помилки та оперативності алгоритму машинного навчання системи керування. Ця умова є протиречивою та потребує компромисного у розумінні Парето розв'язання задачі. У праці [19] запропоновано визначати мінімальний обсяг репрезентативної навчальної вибірки шляхом побудови на кожному випробуванні довірчого інтервалу оцінки ймовірності  $p_i$  знаходження  $i$ -ї ознаки в полі своїх контрольних допусків з ймовірністю довіри  $1-Q$ :

$$P_{\text{дов}} \left\{ \frac{n_i}{n} - \varepsilon_{Q \max}(n) \leq p_i \leq \frac{n_i}{n} + \varepsilon_{Q \max}(n) \right\} = 1 - Q, \quad (1.2)$$

де  $Q$  – рівень значущості (будь-яке мале додатне число, наближене до нуля;

$\varepsilon_{Q \max}(n)$  – максимальна статистична похибка, обчислена при заданому рівні значущості  $Q$ .

На практиці при оцінюванні статистичних рішень використовуються стандартні значення рівній значущості: 0,05; 0,01 і 0,001 [19–21].

Величину максимальної статистичної похибки  $\varepsilon_{\max}(Q)$  при заданому рівні значущості  $Q$  будемо обчислювати згідно з наслідком теореми Муавра-Лапласа як

$$\varepsilon_{Q \max}(n) = \frac{\arg \left[ \Phi(x) = 1 - \frac{Q}{2} \right]}{2\sqrt{n}}, \quad (1.3)$$

де  $\Phi(x)$  – функція Лапласа, таблиці обчислення якої розміщено, наприклад, в працях [19, 20].

Для прикладу обчислення максимальної статистичної похибки  $\varepsilon_{Q \max}(n)$  оберемо рівень значущості  $Q = 0,05$ , який відповідає значенню функції Лапласа

$$\Phi(x) = 1 - \frac{Q}{2} = 0,975..$$

Із таблиці обчислення функцій Лапласа [20], знаходимо для функції  $\Phi(x)=0,975$  значення її аргументу, яке дорівнює  $x = 1,98$ .

Аналогічно обчислюється статистична похибка  $\varepsilon_{Q \max}(n)$  для інших рівній значущості.

На рис. 1.1 показано графіки залежності максимальної статистичної похибки  $\varepsilon_{Q \max}(n)$  при різних значеннях рівня значущості  $Q$ , де умовно показано три області: I – заборонена область, в якій похибка  $\varepsilon_{Q \max}(n)$  перевершує допустиму; II – компромісна область в інтервалі  $30 < n < 80$  і область III, яка характеризується суттєвими ресурсними та часовими витратами при відносно малій швидкості зменшення статистичної похибки.

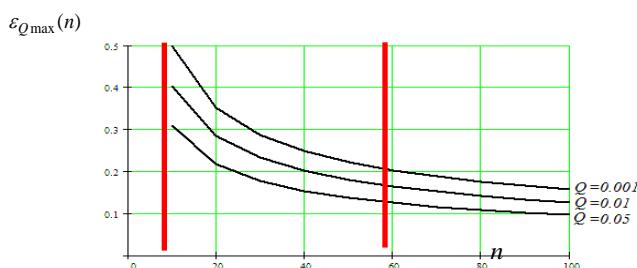
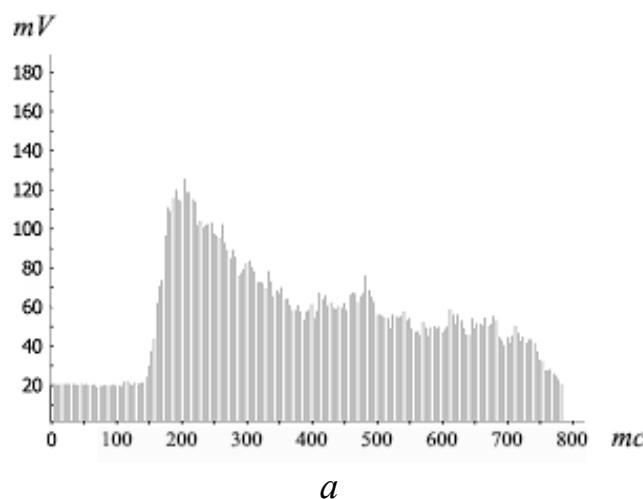
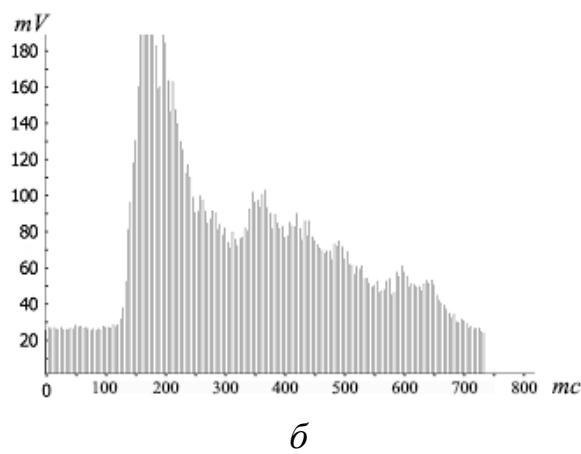


Рисунок 1.1 – Графіки залежності максимальної статистичної похибки при різних значеннях рівня значущості

Розглянемо алгоритм визначення мінимального обсягу репрезентативної навчальної вибірки ознак розпізнавання, отриманої при формуванні вхідної навчальної матриці системи керування протезом кінцівки руки за біосигналами, які знімалися з міографічного датчика біосигналів (рис. 1.2). При цьому розглядався алфавіт із трьох класів, 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.

*a**b*

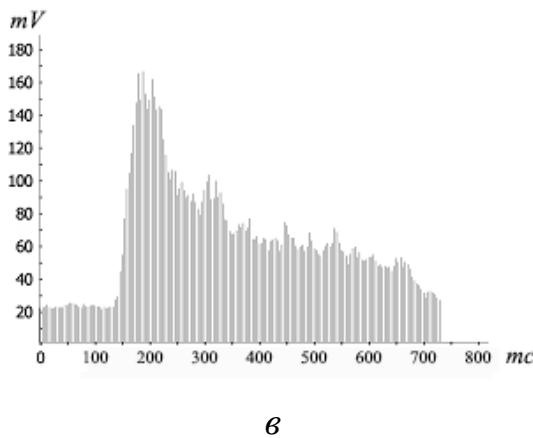


Рисунок 1.2 – Типові реалізації біосигналів для заданого алфавіту класів розпізнавання:  $a$  – клас  $X_1^o$ ;  $b$  – клас  $X_2^o$ ;  $c$  – клас  $X_3^o$

Аналіз рис. 1.2 показує, що наявність в реалізаціях класів розпізнавання однакових ознак обумовлює їх перетин в просторі ознак. Крім того, біосигнали мають відносно великий шумовий фон. Ці фактори суттєво ускладнюють задачу розпізнавання біосигналів.

Формування вектору-реалізації відповідного класу розпізнавання здійснювалося шляхом квантування за часом біосигналу із періодом  $10 \text{ ms}$  на заданому часовому інтервалі  $1 \text{ s}$ . Тобто кожна реалізація образу складалася із 100 ознак розпізнавання. При цьому з метою фільтрації шуму квантування біосигналу починалося з моменту досягнення його амплітудою порогового значення, яке дорівнювало  $30 \text{ mV}$ . У результаті для заданого алфавіту  $\{X_m^o | m = \overline{1, 3}\}$  класів розпізнавання була сформована вхідна навчальна матриця у вигляді тривимірного масиву  $\{y_{m,i}^{(j)}\}$ , в якому кількість ознак розпізнавання дорівнювала  $N = 100$ , а кількість векторів-реалізацій для кожного класу розпізнавання –  $n = 40$ . Нормоване поле допусків на ознаки розпізнавання, яке задавало область значень відповідних контрольних допусків, дорівнювало  $\delta_H = \pm 20 \text{ mV}$ .

Структурна схема алгоритму визначення мінімального обсягу навчальної вибірки показана на рис 1.3.

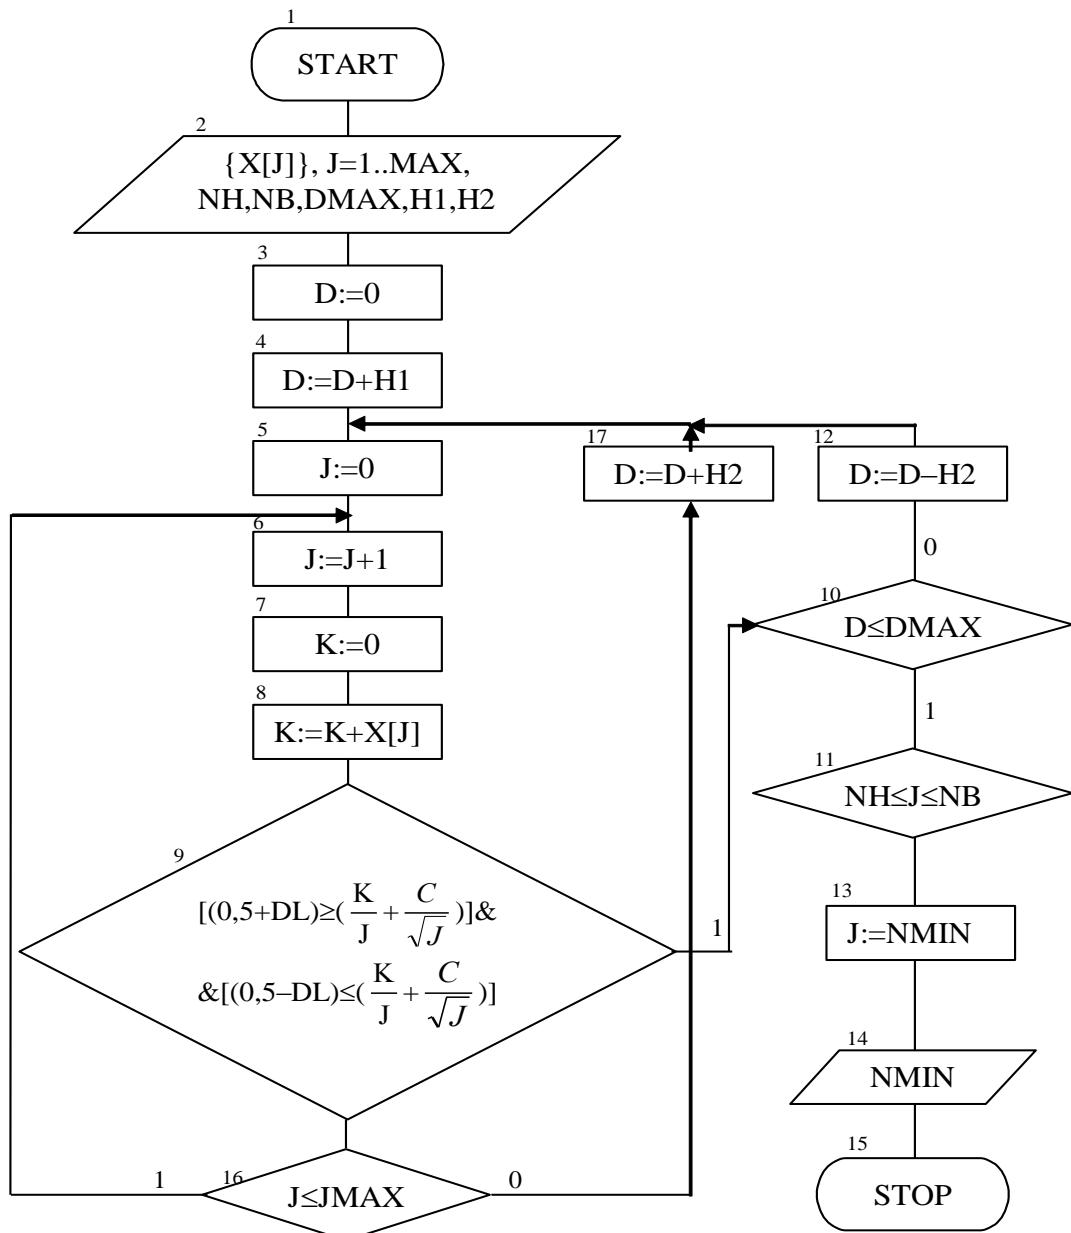


Рисунок 1.3 – Структурна схема алгоритму визначення репрезентативної навчальної вибірки

Вхідними даними алгоритму визначення мінимального обсягу репрезентативної навчальної вибірки є:  $\{X[J]\}$  – бінарна навчальна вибірка,  $J = \overline{1, MAX}$ ;  $DL$  – константа  $\Delta$ ;  $NH$  – межа забороненої області I (рис. 1.2);  $C$  – табличне значення аргументу функції Лапласа;  $H, SH$  – припущення константи  $\Delta$  (в прикладі, що розглядається, прийнято  $H=0,1$  і  $SH=0,01$ ). Визначення  $n_{min}$  здійснювалося для кожногі вибірки стовпчиків навчальної

матриці. Блок 7 обчислює суму одиниць для кожної навчальної вибірки. Блок порівняння 8 визначає випробування, при якому заданий інтервал  $[0,5 \pm \Delta]$  покриває поточний довірчий інтервал (1.2). При позитивному рішенні умови блоку 11 поточне значення параметра  $\Delta$  зменшується на крок  $H$  і алгоритм запускається спочатку. Якщо при негативному рішенні блоку 9 інтервал  $[0,5 \pm \Delta]$  не покриває довірчий (1.2), то блок 10 збільшує значення  $[0,5 \pm \Delta]$  на крок  $SH$  і запускає алгоритм спочатку.

Алгоритм полягає в реалізації таких основних етапів:

- 1) задається система контрольних допусків, які забезпечують знаходження значення ознаки розпізнавання в полі допусків з імовірністю  $0 < p_i < 1$ ;
- 2) генерується для  $i$ -ї ознаки розпізнавання бінарна навчальна вибірка обсягом  $n = n_{\max}$ , яка характеризується інформаційною надлишковістю;
- 3) визначається число “успіхів”  $n_i$  шляхом визначення знаходження значення  $i$ -ї ознаки в своєму полі контрольних допусків ( $i$ -та ознака приймає значення «1», інакше – «0»);
- 4) обчислюється на кожному випробуванні емпірічна ймовірність  $\tilde{p}_i$  – вибіркове середнє навчальної вибірки

$$\bar{k}_i = n_i / n ;$$

- 5) будується на кожному випробуванні динамічний довірчий інтервал (1.2), верхня  $\sup_{\{n\}} \tilde{p}_i$  і нижня  $\inf_{\{n\}} \tilde{p}_i$  межі якого визначаються відповідно як

$$\sup_{\{n\}} \tilde{p}_i = \frac{n_i}{n} + \varepsilon_{Q \max}(n); \quad \inf_{\{n\}} \tilde{p}_i = \frac{n_i}{n} - \varepsilon_{Q \max}(n),$$

де відповідне значення статистичної похибки  $\varepsilon_{Q_{\max}}(n)$  визначається із графіка, показаного на рис. 1.2;

6) з метою машинного зупину процесу формування мінімальної репрезентативної навчальної вибірки задається інтервал  $[0,5 \pm Delta]$ , де величина  $Delta$  вибирається розробником інформаційного забезпечення або визначається автоматично програмно;

7) задається компромісна область

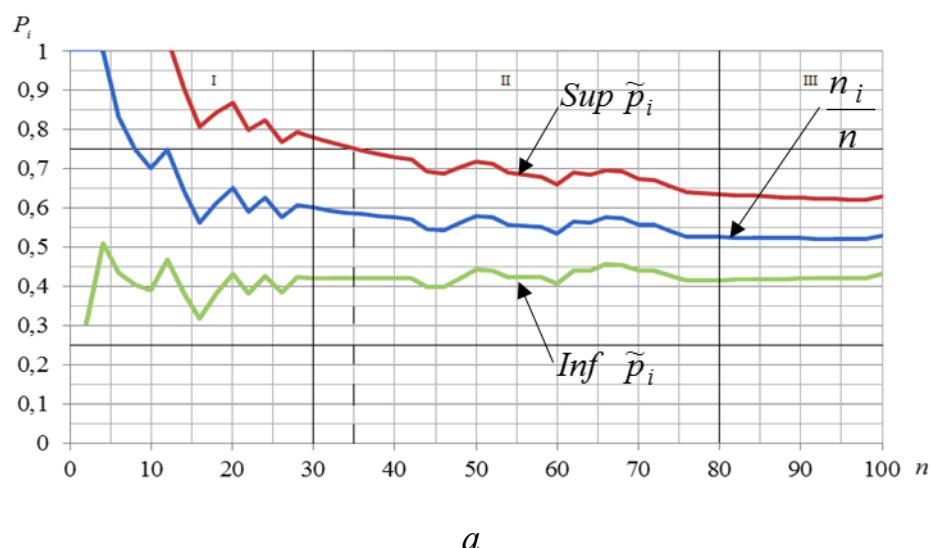
$$30 < n < 100$$

для визначення мінімального обсягу репрезентативної навчальної вибірки;

8) визначається випробування  $n$ , при якому заданий інтервал  $[0,5 \pm Delta]$  покриває динамічний довірчий інтервал (1.2) і присвоюється йому значення  $n := n_{\min}$ ;

9) ЗУПИН.

На рис. 1.4 показано приклади визначення мінімальних обсягів навчальних вибірок для трьох ознак розпізнавання вектора-реалізації класу  $X_1^o$ , який характеризував рух протезу «Згинання долоні» при заданому параметрі  $Delta = 0,2$ .



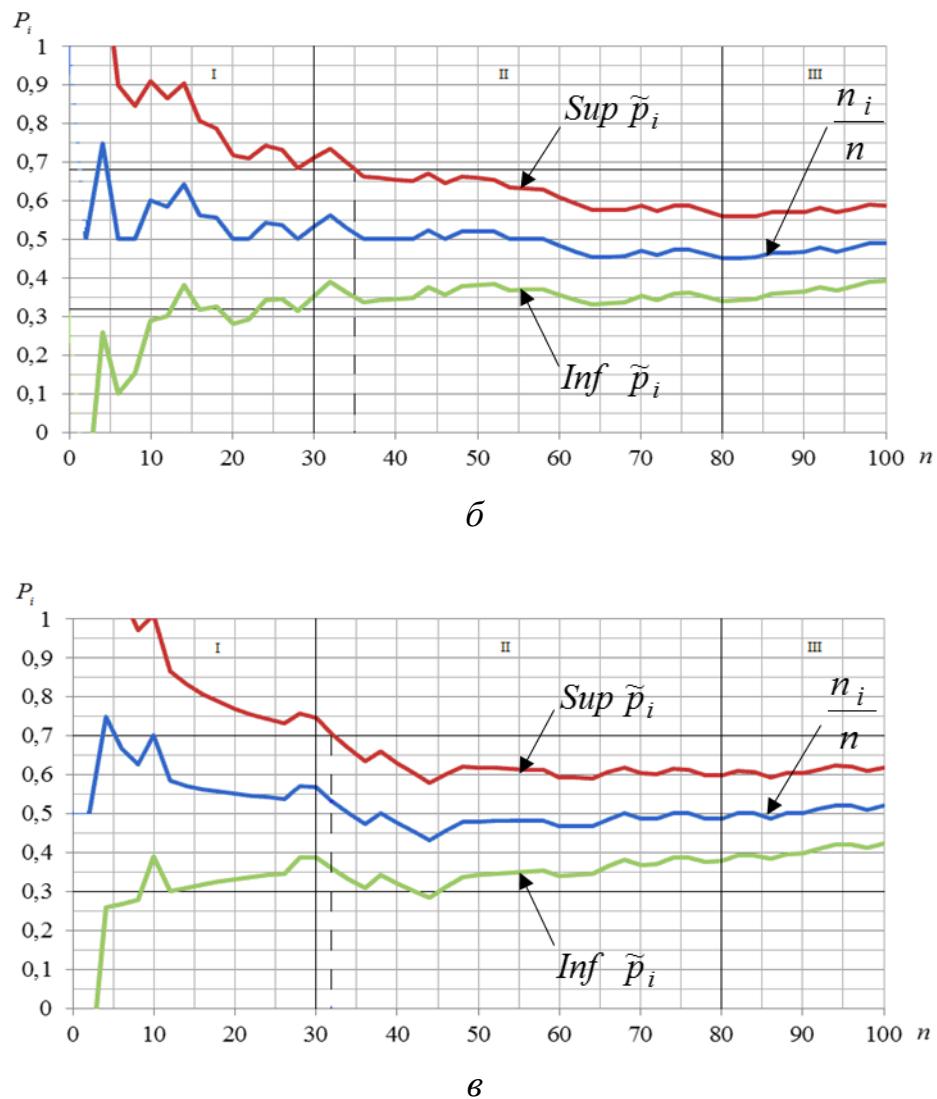


Рисунок 1.4 – Графіки визначення мінімального обсягу трьох навчальних вибірок навчальної матриці класу  $X_1^o$

Аналіз рис. 1.4 показує, що в компромісній області II мінімальні обсяги репрезентативних навчальних вибірок для першої і другої ознак розпізнавання дорівнюють  $n_{\min} = 35$  (рис. 1.4а і рис. 1.4б відповідно) і для третьої ознаки –  $n_{\min} = 32$  (рис. 1.4в).

У загальному випадку, коли заданий інтервал може накривати довірчий в забороненій області I, необхідно застосовувати ітераційну процедуру зменшення параметру *Delta* до тих пір, поки нижня і верхня межи довірчого інтервалу (1.2) не будуть покриватися в компромісній області II інтервалом  $[0,5 \pm Delta]$ .

Оскільки результати машинного зупину алгоритму визначення випробування  $n_{\min}$  дають для розглянутих ознак розпізнавання різні значення, то з метою отримання однакової кількості векторів-реалізацій в навчальній матроці доцільно приймати за мінімальний обсяг всіх вибірок максимальне значення

$$n_{\min} = \max_{\{i\}} n_{\min,i}.$$

Можливість використання визначених за наведеним вище алгориттом навчальних вибірок супермінімального обсягу ( $n \leq 100$ ) в методах IEI-технології обумовлена сгладжувальним ефектом логарифмічних статистичних інформаційних критеріїв оптимізації параметрів машинного навчання. Крім того, в інтелектуальних системах при визначенні обсягів навчальних вибірок пріоритетним є забезпечення їх інформаційної репрезентативності на відміну від задач статистичного аналізу, в яких розглядається репрезентативність випадкових вибірок в статистичному розумінні.

### **1.3 Визначення нормованих допусків на ознаки розпізнавання**

При оптимізації параметрів машинного навчання в рамках IEI-технології важливим питанням є визначення системи нормованих допусків (СНД), яка задає області значень відповідних контрольних допусків на ознаки розпізнавання. При цьому нормованим називається поле допусків  $\{\delta_{H,i} | i = 1, \overline{N}\}$ , в якому значення  $i$ -ї ознаки розпізнавання знаходиться з імовірністю  $p_i = 1$  або  $p_i = 0$  за умови, що функціональний стан інтелектуальної системи належить до базового – найбільш бажаного для особи, що приймає рішення, класу  $X_1^o$ .

Як відомо, контрольним називається поле допусків  $\{\delta_{K,i} \mid i = \overline{1, N}\}$ , в якому значення  $i$ -ї ознаки знаходиться з імовірністю  $0 < p_i < 1$  за умови, що функціональний стан інтелектуальної системи належить до базового класу  $X_1^o$ .

У методах IEI-технології контрольні допуски на ознаки розпізнавання вводяться з метою:

- рандомізації процесу прийняття рішень, оскільки для повного дослідження процесу необхідно використовувати як детерміновані, так і статистичні характеристики;
- трансформації у процесі навчання інтелектуальної системи параметрів розподілу реалізацій образу шляхом допустимих перетворень в дискретному просторі ознак розпізнавання.

Зрозуміло, що  $|\delta_{K,i}| \leq |\delta_{H,i}|$  і базова СКД є сталою для всього алфавіту класів розпізнавання. При цьому основні обмеження зверху (справа) на значення полів контрольних допусків  $\{\delta_{K,i} \mid i = \overline{1, N}\}$  повинні забезпечувати:

- збереження випадковості координат векторів-реалізацій образу;
- недопущення збігу еталонних векторів, які є центрами відповідних контейнерів класів розпізнавання, що може привести до невиконання умов (2.2.2) або (2.2.4) розбиття простору ознак.

Відомі методи оцінки випадковості реалізацій образу обумовлюють наявність навчальної вибірки великого обсягу, що не завжди є здійсненим на практиці. Один із шляхів вирішення цієї проблеми ґрунтуються на такій гіпотезі: чим більша середня кодова відстань між реалізаціями одного образу, тим більше вони будуть мати відмінних ознак розпізнавання, що свідчить про їх випадковість. Розглянемо постановку задачі оптимізації СНД за дистанційно-максимальним критерієм. Нехай  $\{x_i^{(j)} \mid j = \overline{1, n}\}$  – множина реалізацій базового, тобто найбільш бажаного для ОПР класу  $\{X_1^o\}$ , яку

розіб'ємо на пари сусідніх векторів і визначимо кодові відстані між ними за правилом

$$d_j = \sum_{i=1}^N [x_{1,i}^{(j)} \oplus x_{c,i}], \quad j = \overline{1, n}, \quad (1.4)$$

де  $x_{c,i}$  –  $i$ -та координата реалізації  $\{x_{c,i} \mid i = \overline{1, N}\} \in X_c^o$ , яка є найближчою сусідньою до реалізації  $\{x_{1,i}^{(j)}\} \in X_1^o$ .

Необхідно вибрати таку систему допусків  $\{\delta_{H,i}^*\}$ , щоб середнє вибіркове

$$\bar{d}_n = \frac{1}{n} \sum_{j=1}^n d_j \quad (1.5)$$

сусідніх реалізацій класу  $X_1^o$  було максимальним, тобто  $\{\delta_{H,i}\} = \{\delta_{H,i}^*\}$ , якщо

$$\bar{d}_n^* = \max_{\{j\}} \bar{d}_j.$$

Таким чином, параметром, що оптимізується, є величина симетричного поля допусків  $\delta_{H,i}$ , центром якого є значення дискрети еталонного вектора  $y_{1,i} \in X_1^o$ . Алгоритм складається із послідовного проведення етапів оптимізації, на кожному з яких формується при поточній СКД множина двійкових векторів  $\{x_1^{(j)} \mid j = \overline{1, n}\}$ , здійснюється її розбиття на пари сусідніх реалізацій за умови мінімальної кодової відстані між ними, обчислюється за формулою (1.5) середня кодова відстань для сусідніх реалізацій і здійснюється наступний крок ітераційної процедури пошуку максимуму  $\bar{d}_m^*$ .

Вхідні дані:  $\{y_{1,i}^{(j)} \mid i = \overline{1, N}; j = \overline{1, n_{\min}}\}$  – масив дискрет реалізацій, що аналізуються, де  $n_{\min}$  – мінімальний обсяг репрезентативної навчальної вибірки;  $\delta$  – змінна поля допусків;  $h$  – крок зміни поля допусків;  $l$  – змінна кроків ітерації. Результатом алгоритму оптимізації є поля нормованих допусків  $\{\delta_{H,i}^*\}$ , які задають допустиму область значень контрольних допусків і цим забезпечують випадковість ознак розпізнавання.

Розглянемо схему реалізації паралельного алгоритму оптимізації нормованих допусків за критерієм (1.5).

1. Обчислюється еталонна реалізація дискрет  $\{y_{1,i} \mid i = \overline{1, N}\}$  шляхом статистичного усереднення значень дискрет реалізацій  $\{y_{1,i}^{(j)}\}$  класу  $X_1^o$  і задається стартове значення параметра  $\delta$ .
2. Формується масив  $\{x_{1,i}^{(j)}\}$  двійкових векторів-реалізацій класу  $X_1^o$  за правилом

$$x_1^{(j)} = \begin{cases} 1, & \text{if } y_{1,i} - \delta \leq y_{1,i}^{(j)} \leq y_{1,i} + \delta, \\ 0, & \text{if else.} \end{cases} \quad (1.6)$$

3. Будується для векторів  $\{x_1^{(j)} \mid j = \overline{1, n}\}$  матриця кодових відстаней  $\|d_{i,j} \mid i, j = \overline{1, n}\|$ , елементи якої визначаються за правилом

$$d_{i,j} = \begin{cases} \sum_{i=1}^N (x_1^{(j)} \oplus x_1^{(i)}), & \text{if } i \neq j; \\ N + 1, & \text{if } i = j. \end{cases} \quad (1.7)$$

Таким чином, нульовим діагональним елементам матриці  $\|d_{i,j}\|$  штучно присвоюється значення  $N+1$  – максимальна кодова відстань у матриці.

4. Формуються пари найближчих сусідніх реалізацій  $\mathfrak{R}_j^{|2|} = \langle x_1^{(j)}, x_c^{(l)} \rangle$  за умови, що

$$d_j(x_1^{(j)} \oplus x_c^{(l)}) = \min_{\{i\}} (d_{i,j}),$$

де  $x_c^{(l)}$  – найближча до вектора  $x_1^{(j)}$  реалізація, отримана на  $l$ -му кроці оптимізації.

5. Обчислюється за формулою (2.5.2) вибіркова середня відстань  $\bar{d}_n$  для розбиття  $\{\mathfrak{R}_j^{|2|}\}$ .

6. Порівнюється поточне середнє значення  $\bar{d}_n(l)$  з попереднім  $\bar{d}_n(l-1)$ . Якщо  $\bar{d}_n(l) \geq \bar{d}_n(l-1)$ , то  $\delta = \delta + h$ , і виконується крок 1, інакше  $\bar{d}_n^* = \bar{d}_n(l-1)$  і  $\delta^* = \delta - h$ .

7. Формується оптимальна СНД  $\{\delta_{H,i}^*\}$ , де нижні допуски дорівнюють

$$\{A_{H,i} = (y_{1,i} - \delta^*) \mid i = \overline{1, N}\}$$

і верхні допуски –

$$\{A_{B,i} = (y_{1,i} + \delta^*) \mid i = \overline{1, N}\}.$$

Як приклад розглянемо визначення оптимальної за критерієм (1.5) системи нормованих допусків на ознаки розпізнавання

На рис. 1.5 наведено залежність середньої кодової відстані  $\overline{d}_n$  від параметра  $\delta$  поля допусків.

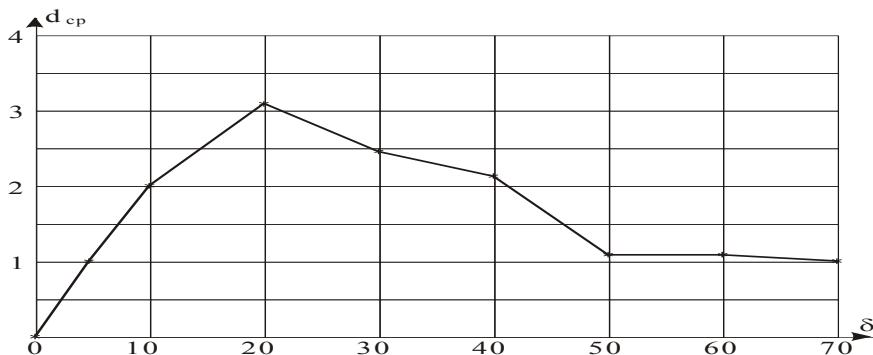


Рисунок 1.5 – Графік залежності середньої кодової відстані між еталонними векторами класу  $X_1^o$  від параметра поля допусків

Аналіз рис. 1.5 показує, що область значення контрольних допусків на ознаки розпізнавання задається оптимальним значенням відповідних полів нормованих допусків

$$\{\delta_{H,i}^*\} = \{y_{1,i} \pm \delta^*\},$$

де  $\delta^* = 20$ , які гарантують випадковість реалізацій образу згідно із принципом рандомізації вхідних даних для IEI-технології. При цьому система нормованих допусків знизу обмежується вимогою виключення переходу реалізацій образу в нульові. Так, вже при  $\delta = \pm 5$  перша, друга і шоста реалізації стають нульовими. З іншого боку, при збільшенні параметра  $\delta$  до 70 збігаються друга та четверта реалізації, що робить подальше збільшення нормованого поля недоцільним. Крім того, вибір занижених нормованих полів допусків призводить до погрешення точністних

характеристик класифікатора, а вибір завищених – до зменшення оперативності навчання.

Таким чином, розроблення ефективних критеріїв оцінки випадковості навчальної вибірки у рамках IEI-технології набуває важливого значення.

#### **1.4 Оцінка статистичної стійкості та однорідності навчальної вибірки**

Важливим етапом формування навчальної вибірки є оцінка її статистичної стійкості та однорідності, оскільки ці властивості суттєво впливають на величину повної ймовірності прийняття правильних рішень. Основним способом недопущення зниження достовірності рішень, що приймає система, є блокування її функціонування як в режимах навчання, так і екзамену, якщо не виконуються умови статистичної стійкості або статистичної однорідності вибірок. У загальному випадку IC блокує режими навчання й екзамену за таких причин:

- переходний процес, що відбувається, наприклад, в задачах керування при зміні функціональних станів технологічного процесу під впливом як керованих, так і некерованих факторів;
- відмова технологічного обладнання;
- неправильне функціонування датчиків інформації;
- неоптимальні значення контрольних і нормованих допусків на ознаки розпізнавання.

Як критерії статистичної стійкості використовуються відомі в математичній статистиці вибіркові критерії оцінки параметрів імовірнісних розподілів [18, 19] критерії статистичної однорідності доцільно використовувати критерій згоди Пірсона (критерій  $\chi^2$ ) [18], серійний критерій Вальда-Вольфсона [19], критерій Колмогорова-Смірнова (критерій  $\lambda$ ) [19], критерій серій [19] та інші. Як критерії інформативності ознак

можуть використовуватися коефіцієнти парної та множинної кореляції і прямі статистичні інформаційні критерії [18 – 20]. Одну із ієрархічних структур алгоритму прийняття рішень при оцінці статистичних стійкості та однорідності навчальної вибірки за статистичними критеріями наведено на рис. 1.6.

Аналіз рис. 1.6 показує, що невиконання основної гіпотези навіть за одним будь-яким критерієм призводить до заблокування процесу формування навчальної матриці  $\| y_{m,i}^{(j)} \|$ , а тим самим і навчання ІС.



Рисунок 1.6 – Ієрархічна структура алгоритму оцінки статистичних стійкості та однорідності навчальної вибірки

Таким чином, архітектура програмного забезпечення ІС, що навчається, крім інформаційних агентів «Навчання» і «Екзамен», повинна включати агента «Розвідувальний аналіз», який у процесі прийняття багатокритеріальних рішень дає дозвіл на функціонування системи у відповідному режимі.

## 2 ОЦІНКА ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ СИСТЕМИ КЕРУВАННЯ, ЩО НАВЧАЄТЬСЯ

### 2.1 Оцінка функціональної ефективності здатної навчатися системи керування при двохальтернативних рішеннях

При реалізації методів IEI-технології важливе значення має обчислення інформаційного критерію функціональної ефективності (КФЕ) машинного навчання системи керування. Для оцінки функціональної ефективності машинного навчання може бути застосовано будь-який статистичний інформаційний критерій, який відповідає вимогам інформаційних мір, які є функціоналами від точністних характеристик, що утворюють систему оцінок рішень, що приймаються. В рамках IEI-технології знайшли практичне застосування модифікації ентропійного (за Шенноном) критерію оптимізації та інформаційної міри Кульбака [17].

Для побудови КФЕ як функції, що залежить від емпіричних значень ознак розпізнавання, розглянемо симетричний інформаційний критерій у вигляді дивергенції Кульбака-Лейблера [22]:

$$D_{KL}(p, q) = \sum_{x \in R} (p(x) - q(x)) \ln \frac{p(x)}{q(x)} \quad (2.1)$$

де  $p(x)$  – функція ймовірності випадкової величини  $x$  із вибірки

$\{p\}$ , яка приймає значення на множині раціональних чисел  $R$ ;

$q(x)$  – функція ймовірності випадкової величини  $x$  із вибірки

$\{q\}$ , яка приймає значення на множині раціональних чисел  $R$ ;

$D_{KL}$  – відстань між ансамблями  $\{p\}$  і  $\{q\}$ .

Практичне застосування формула (2.1) знайшла в методах IEI-технології, де використовується для обчислення інформаційного КФЕ машинного навчання. Розглянемо класифікатор, в якому вирішальні правила будуються на кожному  $k$ -му кроці навчання системи шляхом відновлення в радіальному базисі простору ознак контейнерів класів розпізнавання. Тоді диференційна інформаційна міра різноманітності класу  $X_m^o$  відносно найближчого (сусіднього) класу  $X_c^o$  визначається за модифікованим критерієм Кульбака [17]

$$E_{Km}^{(k)} = [P_{t,m}^{(k)} - P_{f,m}^{(k)}] \times \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} \quad (2.2)$$

де  $P_{t,m}^{(k)}$  – повна ймовірність правильного прийняття рішень на  $k$ -ому кроці машинного навчання;

$P_{f,m}^{(k)}$  – повна ймовірність неправильного прийняття рішень на  $k$ -ому кроці машинного навчання.

Приймемо за основну априорну гіпотезу  $\gamma_1$  знаходження значення ознаки розпізнавання в полі допусків  $\delta$ , а за альтернативну гіпотезу  $\gamma_2$  – знаходження ознаки за межами поля допусків. При цьому як апостеріорні відповідно приймемо гіпотези  $\mu_1$  і  $\mu_2$ . Тоді повні ймовірності правильного і неправильного прийняття рішень для двохальтернативної системи їх оцінок мають згідно з теоремою повної ймовірності вигляд

$$\begin{cases} P_{t,m}^{(k)} = p(\mu_1)p(\gamma_1 / \mu_1) + p(\mu_2)p(\gamma_2 / \mu_2) \\ P_{f,m}^{(k)} = p(\mu_1)p(\gamma_2 / \mu_1) + p(\mu_2)p(\gamma_1 / \mu_2) \end{cases} \quad (2.3)$$

Так як у формулах (2.3) умовні ймовірності є точнісними характеристиками класифікаційних рішень а саме:  $p(\gamma_2 / \mu_1)$  це помилка першого роду  $\alpha$ ,  $p(\gamma_1 / \mu_2)$  – помилка другого роду  $\beta$ ,  $p(\gamma_1 / \mu_1)$  – перша достовірність  $D_1$ ,  $p(\gamma_2 / \mu_2)$  – друга достовірність  $D_2$ , то після їх перетворення за формулою Байєса при рівномовірних гіпотезах (згідно з принципом Лапласа-Бернуллі), відповідних замін

$$\alpha_m^{(k)}(d) = 1 - D_{1,m}^{(k)}(d) \text{ і } \beta_m^{(k)}(d) = 1 - D_{2,m}^{(k)}(d)$$

та їх підстановки у формулу (2.2) отримаємо відому модифікацію критерію Кульбака [17]

$$E_{Km}^{(k)} = \log_2 \left( \frac{2 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right) \times \left[ 1 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)) \right] \quad (2.4)$$

де  $\alpha_m^{(k)}(d) \in [0,1]$  – помилка першого роду, яка обчислюється на  $k$ -му кроці машинного навчання;

$\beta_m^{(k)}(d) \in [0,1]$  – помилка другого роду;

$d$  – значення радіуса гіперсферичного контейнера, що відновлюється в радіальному базисі простору ознак розпізнавання.

Для дослідження критерію (2.4) представимо його у вигляді функції [23]

$$z(t) = \log_2 \left( \frac{2-t}{t} \right) \times (1-t) \quad (2.5)$$

де

$$\begin{cases} z(t) = E_{Km}^{(k)}(d) \\ t = \alpha_m^{(k)}(d) + \beta_m^{(k)}(d); t \in [0; 2] \end{cases}$$

Функцію (2.5) будемо досліджувати за схемою:

- 1) область визначення функції;
- 2) точки перетину з осями координат;
- 3) похідна і критичні точки;
- 4) проміжки зростання, спадання та точки екстремуму функції (i значення в цих точках);
- 5) друга похідна і дослідження функції на опуклість і угнутість;
- 6) контрольні точки для уточнення графіка функції;
- 7) якщо дії до п.7 не дозволять знайти глобальний максимум функції,

то слід використати наближені чисельні методи його знаходження (метод простих ітерацій або метод Ньютона).

По кожному з вищепереліканих пунктів схеми дослідження одержано такі результати:

$$1) \begin{cases} \left(\frac{2-t}{t}\right) > 0 \\ t \in [0, 2] \end{cases} \Rightarrow t \in (0, 2);$$

$$2) \begin{cases} t = 0 \Rightarrow z \text{ невизначено} \\ z = 0 \Rightarrow t = 1 \end{cases};$$

$$z'(t) = [\log_2\left(\frac{2-t}{t}\right) \times (1-t)]' = \log_2\left(\frac{2-t}{t}\right)' \times (1-t) + (1-t)' \times$$

$$3) \log_2\left(\frac{2-t}{t}\right)' = (\log_2(2-t)' - \log_2(t)') \times (1-t) - \log_2\left(\frac{2-t}{t}\right)' =$$

$$\left(-\frac{1}{(2-t) \times \ln 2} - \frac{1}{t \times \ln 2}\right) \times (1-t) - \log_2\left(\frac{2-t}{t}\right)' = (t-1) \times$$

$$\frac{2}{(2-t) \times t \times \ln 2} - \log_2\left(\frac{2-t}{t}\right)' = \frac{2 \times (t-1)}{(2 \times t - t^2) \times \ln 2} - \log_2\left(\frac{2-t}{t}\right)'$$

Знаходження розв'язку рівняння  $z'(t) = 0$  викликає труднощі, хоча корінь в точці  $t = 1$  очевидний. За допомогою чисельних методів знаходимо решту

коренів даного рівняння, і, порівнявши значення функції при отриманих розв'язках, знайти глобальний максимум критерію Кульбака;

$$4) \begin{cases} z'(1) = 0 \\ z(1) = 0 \end{cases} \text{ при цьому } \begin{cases} z'(0,99) < 0 \\ z'(1,01) > 0 \end{cases},$$

що свідчить про глобальний мінімум функції у даній точці.

Знаходження інших точок на даному етапі неможливе.

$$\begin{aligned} z''(t) &= (z'(t))' = \left[ \frac{2 \times (t-1)}{(2 \times t - t^2) \times \ln 2} - \log_2 \left( \frac{2-t}{t} \right) \right]' = \frac{1}{\ln 2} \times \left( \frac{1}{2-t} - \frac{1}{t} \right)' \\ &+ \left( \frac{1}{(2-t) \times \ln 2} + \frac{1}{t \times \ln 2} \right) = \frac{1}{\ln 2} \times \left( \left( \frac{1}{2-t} \right)' - \left( \frac{1}{t} \right)' \right) + \frac{2}{(2 \times t - t^2) \times \ln 2} = \\ 5) \quad &\frac{1}{\ln 2} \times \left( \frac{1}{(2-t)^2} + \frac{1}{t^2} \right) + \frac{2}{(2 \times t - t^2) \times \ln 2} = \frac{1}{\ln 2} \times \left( \frac{t^2 + 4 - 4 \times t + t^2}{(2-t)^2 \times t^2} \right) + \\ &\frac{1}{\ln 2} \times \frac{2}{(2-t) \times t} = \frac{1}{\ln 2} \times \left( \frac{2 \times t^2 - 4 \times t + 4 - 2 \times t^2 + 4 \times t}{(2-t)^2 \times t^2} \right) = \frac{1}{\ln 2} \times \\ &\left( \frac{4}{(2-t)^2 \times t^2} \right) > 0 \forall t \in (0, 2) \end{aligned}$$

Оскільки в кожній точці інтервалу  $t \in (0, 2)$   $z''(t) > 0$ , то згідно з достатніми умовами опукlosti i угнутостi функцiї на інтервалi  $t \in (0, 2)$  графiк функцiї  $z(t)$  спрямовано опуклiстю вниз.

6) результати табуляцiї функцiї (2.5) в контрольних точках з кроком 0.1 наведено в табл. 2.1.

Таблиця 2.1 – Табуляція функції  $z(t)$  з кроком  $\Delta = 0.1$ 

| Значення функції | Перша похідна | Аргумент функції |
|------------------|---------------|------------------|
| 3.82             | -17.91        | 0.1              |
| 2.53             | -9.58         | 0.2              |
| 1.75             | -6.46         | 0.3              |
| 0.79             | -3.50         | 0.5              |
| 0.26             | -1.84         | 0.7              |
| 0.02             | -0.58         | 0.9              |
| 0.02             | 0.58          | 1.1              |
| 0.26             | 1.84          | 1.3              |
| 0.79             | 3.50          | 1.5              |
| 1.75             | 6.46          | 1.7              |
| 3.82             | 17.91         | 1.9              |

Аналіз табл. 2.1 показує що функція має лише один корінь на проміжку  $t \in (0, 2)$ , до того ж він є глобальним мінімумом на даному проміжку.

7) якщо не вдалося знайти глобальний максимум функції (2.7), то слід область її визначення розбити з кроком  $\Delta = 0.1$  і перевірити достатню умову знаходження кореня на кожному з проміжків  $[\Delta i, \Delta i + 1]$   $[\Delta i, \Delta i+1]$ . Якщо ця умова виконується, то за допомогою метода Ньютона знаходимо корінь із заданою точністю. Для створення високодостовірної системи керування в процесі інформаційно-екстремального машинного навчання здійснюється пошук глобального максимуму критерію (2.4). На рис. 2.1 показано графік залежності критерію (2.4) від параметра

$$t = \alpha_m^{(k)}(d) + \beta_m^{(k)}(d).$$

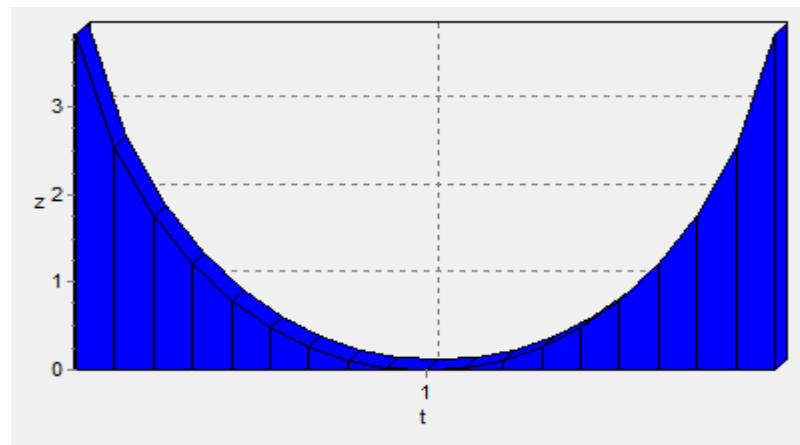


Рисунок 2.1 – Графік залежності КФЕ від параметра

Як видно з рис. 2.5 графік функції для обраного конкретного випадку досягається на краях області визначення при  $t \rightarrow 0$  і  $t \rightarrow 2$ , де згідно з формулою (2.5) маємо

$$\alpha_m^{(k)}(d) + \beta_m^{(k)}(d) \rightarrow 0 \text{ або } \alpha_m^{(k)}(d) + \beta_m^{(k)}(d) \rightarrow 2.$$

Приймемо такі оцінки помилок першого та другого роду:

$$\alpha^{(k)} = \frac{K_2^{(k)}}{n_{\min}} \text{ і } \beta^{(k)} = \frac{K_3^{(k)}}{n_{\min}},$$

де  $K_2^{(k)}$  – кількість подій, які означають неналежність реалізації контейнеру

$K_{1,k}^o$ , якщо дійсно  $\{x_1^{(j)}\} \in X_1^o$ ;

$K_3^{(k)}$  – кількість подій, які означають належність реалізації контейнеру

$K_{1,k}^o$ , якщо вони насправді належать класу  $X_2^o$ ;

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

З цього випливає що класифікатор буде тим більш достовірний, чим будуть менші значення помилок  $\alpha_m^{(k)}(d)$ ,  $\beta_m^{(k)}(d)$ .

Можна вважати, що ефективність інтелектуальної системи буде високою, якщо більше ніж 90% реалізацій буде вірно класифіковано.

Розглянемо поведінку функції  $z(t)$  в околі точки  $t = 0$ . Оскільки

$$\alpha^{(k)} + \beta^{(k)} = \frac{K_2^{(k)}}{n_{\min}} + \frac{K_3^{(k)}}{n_{\min}} = \frac{K_2^{(k)} + K_3^{(k)}}{n_{\min}} = \frac{1}{60} = 0.017,$$

і відповідно менш, ніж 2% реалізацій не було класифіковано, то згідно табл. 2.2 максимальне значення КФЕ (2.8) буде дорівнювати 6.84.

Таблиця 2.2 – Поведінка функції  $z(t)$  в околі точки  $t = 0$

| Значення функції | Перша похідна | Аргумент функції |
|------------------|---------------|------------------|
| 10.95            | -1452.93      | 0.001            |
| 9.35             | -489.55       | 0.003            |
| 8.59             | -296.45       | 0.005            |
| 8.09             | -213.52       | 0.007            |
| 7.71             | -167.36       | 0.009            |
| 7.41             | -137.92       | 0.011            |
| 7.16             | -117.50       | 0.013            |
| 6.94             | -91.00        | 0.015            |
| 6.74             | -81.90        | 0.017            |

Після підстановки у формулу (2.4) оцінок точністних характеристик

$$\alpha_m^{(k)} = \frac{K_2^{(k)}}{n_{\min}}, \quad \beta_m^{(k)} = \frac{K_3^{(k)}}{n_{\min}},$$

де  $K_2^{(k)}$  – кількість подій, при яких приймаються помилкові рішення про те, що «своя» реалізація  $\{x_m^{(j)}\}$  не належить класу  $X_m^o$ ;

$K_3^{(k)}$  – кількість подій, при яких «чужа» реалізація  $\{x_c^{(j)}\}$  належить класу  $X_m^o$ ;

отримаємо таку робочу формулу модифікації критерію Кульбака []

$$E = \frac{1}{n} \log_2 \left\{ \frac{2n + 10^{-r} - [K_2^{(k)} + K_3^{(k)}]}{[K_2^{(k)} + K_3^{(k)}] + 10^{-r}} \right\} \times [n - (K_2^{(k)} + K_3^{(k)})], \quad (2.6)$$

де  $10^{-r}$  – доданок, який вводиться з метою усунення проблеми поділу на нуль ( $1 < r \leq 3$ ).

## 2.2 Оцінка функціональної ефективності системи керування при трьохальтернативних рішеннях

Одним із шляхів підвищення достовірності оцінки функціонального стану технологічного процесу є перехід від двухальтернативної системи оцінок прийнятих рішень до трьохальтернативної у формі «Менше норми»-«Норма»-«Більше норми».

Розглянемо використання трьохальтернативної системи оцінок керуючих рішень для оцінки функціональної ефективності інформаційно-екстремального навчання системи керування. В даному випадку основна гіпотеза  $\gamma_1$  буде свідчити про належність ознаки показнику «Норма», гіпотеза  $\gamma_2$  – показнику «Менше норми» і гіпотеза  $\gamma_3$  – показнику «Більше норми». Відповідно їх апостеріорні гіпотези:  $\mu_1$  – значення ознаки дійсно знаходиться в полі допусків  $\delta$ ,  $\mu_2$  – лівіше поля допусків  $\delta$  і  $\mu_3$  – правіше поля допусків  $\delta$ .

При цьому можливі результати для трьохальтернативного рішення можна представити у вигляді дев'яти характеристик:

- 1) перша достовірність  $D_{1,m}^{(k)} = p(\gamma_1 / \mu_1)$ ;
- 2) перша помилка першого роду  $\alpha_{1,m}^{(k)} = p(\gamma_2 / \mu_1)$ ;
- 3) друга помилка першого роду  $\alpha_{2,m}^{(k)} = p(\gamma_3 / \mu_1)$ ;
- 4) друга достовірність  $D_{2,m}^{(k)} = p(\gamma_2 / \mu_2)$ ;
- 5) перша помилка другого роду  $\beta_{1,m}^{(k)} = p(\gamma_1 / \mu_2)$ ;
- 6) друга помилка другого роду  $\beta_{2,m}^{(k)} = p(\gamma_3 / \mu_2)$ ;
- 7) третя достовірність  $D_{3,m}^{(k)} = p(\gamma_3 / \mu_3)$ ;
- 8) перша помилка третього роду  $\sigma_{1,m}^{(k)} = p(\gamma_1 / \mu_3)$ ;
- 9) друга помилка третього роду  $\sigma_{2,m}^{(k)} = p(\gamma_2 / \mu_3)$ .

Згідно з принципом Бернуллі-Лапласа будемо вважати гіпотези рівноЯмовірні, і тоді повні ймовірності правильного і неправильного прийняття рішень відповідно дорівнюють

$$\begin{cases} P_{t,m}^{(k)} = p(\mu_1)p(\gamma_1 / \mu_1) + p(\mu_2)p(\gamma_2 / \mu_2) + p(\mu_3)p(\gamma_3 / \mu_3) \\ P_{f,m}^{(k)} = \sum_{i=2}^3 (p(\mu_1)p(\gamma_i / \mu_1) + p(\mu_i)p(\gamma_1 / \mu_i)) + p(\mu_2)p(\gamma_3 / \mu_2) + p(\mu_3)p(\gamma_2 / \mu_3) \end{cases}$$

Після підстановки цього виразу в формулу (2.4) КФЕ СППР з трьохальтернативним унімодальним класифікатором приймає вигляд

$$E_m^{(k)} = \frac{1}{3} \{ D_{1,m}^{(k)} + 1 - 2[\beta_m^{(k)} + \sigma_m^{(k)}] \} \times \log_2 \frac{2D_{1,m}^{(k)} + 4 - 4[\beta_m^{(k)} + \sigma_m^{(k)}]}{1 - D_{1,m}^{(k)} + 2[\beta_m^{(k)} + \sigma_m^{(k)}]} \quad (2.7)$$

Таким чином, інформаційна міра Кульбака є функціоналом від точністних характеристик рішень, що приймається і тому може використовуватися як загальний КФЕ машинного навчання.

### 2.3 Оцінка функціональної ефективності системи керування при трьохальтернативних рішеннях при застосуванні методу К-найближчих сусідів

Розглянемо спосіб формування КФЕ навчання системи керування з трьохальтернативним полімодальним гіперсферичним класифікатором для загального випадку, коли класи розпізнавання перетинаються, як це показано на рис. 2.2.



Рисунок 2.2 – Можливі варіанти належності реалізації, що розпізнається, до класів розпізнавання

В табл. 2.3 наведені можливі варіанти знаходження в просторі ознак реалізації, що розпізнається, базового класу  $X_1^0$ , що відповідає функціональному стану СППР «Норма». При цьому віднесення цієї реалізації

класу  $X_1^o$  у випадку, коли вона належить двом та більше класам, будемо вважати неефективним.

Таблиця 2.3 – Можливі варіанти класифікації реалізації класу «Норма»

|                           |   |
|---------------------------|---|
| Правильне розпізнавання   | Вектор-реалізація належить тільки базовому класу.   |
|                           | Вектор-реалізація належить базовому класу і класу «Менше норми». Неефективне розпізнавання  |
|                           | Вектор-реалізація належить базовому класу і класу «Більше норми». Неефективне розпізнавання |
|                           | Вектор-реалізація належить всім класам розпізнавання. Неефективне розпізнавання             |
| Неправильне розпізнавання | Вектор-реалізація належить класу «Менше норми»  |
|                           | Вектор-реалізація належить класу «Більше норми»   |
|                           | Вектор-реалізація належить класам «Менше норми» і «Більше норми»                            |
|                           | Вектор-реалізація не належить ні до одного з існуючих класів                                |

Таким чином, тільки в першому випадку класифікатор розпізнає реалізацію класу  $X_1^o$  з максимально повною ймовірністю правильного прийняття рішень.

Згідно з табл. 2.3 і рис. 2.2 апостеріорні гіпотези мають такі значення:

- 1)  $\mu_1$  – реалізація знаходиться в полі допусків δ класу «Норма» (область 1);
- 2)  $\mu_2$  – реалізація знаходиться в полі допусків δ класу «Менше норми» (область 5);
- 3)  $\mu_3$  – реалізація знаходиться в полі допусків δ класу «Більше норми» (область 6);
- 4)  $\mu_4$  – реалізація знаходиться в полі допусків δ класу «Менше норми» і класу «Норма» одночасно (область 2);
- 5)  $\mu_5$  – реалізація знаходиться в полі допусків δ класу «Більше норми» и класу «Норма» одночасно (область 3);
- 6)  $\mu_6$  – реалізація знаходиться в полі допусків δ класу «Менше норми», класу «Норма» и класу «Більше норми» одночасно (область 4);
- 7)  $\mu_7$  – реалізація знаходиться в полі допусків δ класу «Більше норми» и класу «Менше норми» одночасно (область 7);

Крім того, введемо додаткову гіпотезу  $\mu_8$  – реалізація знаходиться поза межами існуючих класів, тобто в області 8.

Тоді можливі результати для трьохальтернативних рішень будуть оцінюватися такими точністними характеристиками:

- 1) перша достовірність  $D_1^{(k)} = p(\gamma_1 / \mu_1)$ ;
- 2) перша помилка другого роду  $\alpha_2^{(k)} = p(\gamma_1 / \mu_2)$ ;
- 3) перша помилка третього роду  $\alpha_3^{(k)} = p(\gamma_1 / \mu_3)$ ;
- 4) перша помилка четвертого роду  $\alpha_4^{(k)} = p(\gamma_1 / \mu_4)$ ;
- 5) перша помилка п'ятого роду  $\alpha_5^{(k)} = p(\gamma_1 / \mu_5)$ ;
- 6) перша помилка шостого роду  $\alpha_6^{(k)} = p(\gamma_1 / \mu_6)$ ;
- 7) перша помилка сьомого роду  $\alpha_7^{(k)} = p(\gamma_1 / \mu_7)$ ;
- 8) перша помилка восьмого роду  $\alpha_8^{(k)} = p(\gamma_1 / \mu_8)$ ;

- 9) друга достовірність  $D_2^{(k)} = p(\gamma_2 / \mu_2)$ ;
- 10) друга помилка першого роду  $\beta_2^{(k)} = p(\gamma_2 / \mu_1)$ ;
- 11) друга помилка третього роду  $\beta_3^{(k)} = p(\gamma_2 / \mu_3)$ ;
- 12) друга помилка четвертого роду  $\beta_4^{(k)} = p(\gamma_2 / \mu_4)$ ;
- 13) друга помилка п'ятого роду  $\beta_5^{(k)} = p(\gamma_2 / \mu_5)$ ;
- 14) друга помилка шостого роду  $\beta_6^{(k)} = p(\gamma_2 / \mu_6)$ ;
- 15) друга помилка сьомого роду  $\beta_7^{(k)} = p(\gamma_2 / \mu_7)$ ;
- 16) друга помилка восьмого роду  $\beta_8^{(k)} = p(\gamma_2 / \mu_8)$ ;
- 17) третя достовірність  $D_3^{(k)} = p(\gamma_3 / \mu_3)$ ;
- 18) третя помилка першого роду  $\sigma_1^{(k)} = p(\gamma_3 / \mu_1)$ ;
- 19) третя помилка другого роду  $\sigma_2^{(k)} = p(\gamma_3 / \mu_2)$ ;
- 20) третя помилка четвертого роду  $\sigma_4^{(k)} = p(\gamma_3 / \mu_4)$ ;
- 21) третя помилка п'ятого роду  $\sigma_5^{(k)} = p(\gamma_3 / \mu_5)$ ;
- 22) третя помилка шостого роду  $\sigma_6^{(k)} = p(\gamma_3 / \mu_6)$ ;
- 23) третя помилка сьомого роду  $\sigma_7^{(k)} = p(\gamma_3 / \mu_7)$ ;
- 24) третя помилка восьмого роду  $\sigma_8^{(k)} = p(\gamma_3 / \mu_8)$ .

Таким чином, приведені 24 точністні характеристики дозволяють повністю оцінити належність реалізацій одному з трьох класів розпізнавання.

Оскільки для системи розпізнавання незалежно від прийнятої системи оцінок рішень базовим є клас  $X_1^0$  – «НОРМА», то використавши формулу (2.3), повні ймовірності правильного і неправильного прийняття рішень представимо у вигляді

$$\left\{ \begin{array}{l} P_t^{(k)} = p(\mu_1)p(\gamma_1 / \mu_1) + p(\mu_2)p(\gamma_2 / \mu_2) + p(\mu_3)p(\gamma_3 / \mu_3); \\ P_f^{(k)} = p(\mu_1)p(\gamma_2 / \mu_1) + p(\mu_1)p(\gamma_3 / \mu_1) + p(\mu_2)p(\gamma_1 / \mu_2) + p(\mu_2)p(\gamma_3 / \mu_2) \\ + p(\mu_3)p(\gamma_1 / \mu_3) + p(\mu_3)p(\gamma_2 / \mu_3) + \sum_{i=4}^8 (p(\mu_i)p(\gamma_1 / \mu_i) + p(\mu_i)p(\gamma_2 / \mu_i)) \\ + p(\mu_i)p(\gamma_3 / \mu_i)) \end{array} \right.$$

Згідно з принципом Лапласа-Бернуллі за умов апріорної невизначеності доцільним є припущення про рівномовірне потрапляння реалізацій в кожну область. Тоді прийнявши

$$p(\mu 1) = p(\mu 2) = p(\mu 3) = p(\mu 4) = p(\mu 5) = p(\mu 6) = p(\mu 7) = p(\mu 8) = 1/8,$$

вищеприведену систему подамо у вигляді

$$\left\{ \begin{array}{l} P_t^{(k)} = \frac{1}{8}(D_1^{(k)} + D_2^{(k)} + D_3^{(k)}) \\ P_f^{(k)} = \frac{1}{8}(\alpha_2^{(k)} + \alpha_3^{(k)} + \beta_1^{(k)} + \beta_3^{(k)} + \sigma_1^{(k)} + \sigma_2^{(k)} + \sum_{i=4}^8 (\alpha_i^{(k)} + \beta_i^{(k)} + \sigma_i^{(k)})) \end{array} \right.$$

Після відповідної підстановки даних рівностей в формулу (2.2) отримаємо

$$\begin{aligned} E^{(k)} &= [P_t^{(k)} - P_f^{(k)}] \times \log_2 \frac{P_t^{(k)}}{P_f^{(k)}} = \frac{1}{8}(D_1^{(k)} + D_2^{(k)} + D_3^{(k)} - (\alpha_2^{(k)} + \alpha_3^{(k)} + \\ &\quad \beta_1^{(k)} + \beta_3^{(k)} + \sigma_1^{(k)} + \sigma_2^{(k)} + \sum_{i=4}^8 (\alpha_i^{(k)} + \beta_i^{(k)} + \sigma_i^{(k)})) \times \\ &\quad \log_2 \frac{D_1^{(k)} + D_2^{(k)} + D_3^{(k)}}{\alpha_2^{(k)} + \alpha_3^{(k)} + \beta_1^{(k)} + \beta_3^{(k)} + \sigma_1^{(k)} + \sigma_2^{(k)} + \sum_{i=4}^8 (\alpha_i^{(k)} + \beta_i^{(k)} + \sigma_i^{(k)})} \end{aligned} \quad (2.8)$$

З урахуванням того, що сума повних ймовірностей правильного та неправильного прийняття рішень дорівнює одиниці для кожного  $m$ -го класу, формула (2.10) матиме вигляд

$$\begin{aligned} E^{(k)} &= \frac{1}{8}(D_1^{(k)} + D_2^{(k)} + D_3^{(k)} - (3 - D_1^{(k)} - D_2^{(k)} - D_3^{(k)})) \times \\ &\log_2 \frac{D_1^{(k)} + D_2^{(k)} + D_3^{(k)}}{(3 - D_1^{(k)} - D_2^{(k)} - D_3^{(k)})} = \\ &= \frac{1}{8}(2(D_1^{(k)} + D_2^{(k)} + D_3^{(k)}) - 3) \times \log_2 \frac{D_1^{(k)} + D_2^{(k)} + D_3^{(k)}}{(3 - D_1^{(k)} - D_2^{(k)} - D_3^{(k)})}. \end{aligned} \quad (2.9)$$

Аналіз виразу (2.9) показує, що інформаційний КФЕ є функціоналом від точністних характеристик, значення яких, у свою чергу, залежать від геометричних параметрів контейнерів класів розпізнавання.

Розглянемо обчислювальний аспект оцінки функціональної ефективності СППР, що навчається. При обмеженому обсязі навчальних матриць, введемо такі оцінки точністних характеристик

$$D_1^{(k)} = \frac{K_1^{(k)}}{n_{\min}}; \quad D_2^{(k)} = \frac{K_2^{(k)}}{n_{\min}}; \quad D_3^{(k)} = \frac{K_3^{(k)}}{n_{\min}} \quad (2.10)$$

де  $K_1^{(k)}$  – кількість подій, які полягали у належності реалізацій, що розпізнаються, до класу  $X_m^o$ , якщо вони дійсно належать цьому класу;

$K_2^{(k)}$  – кількість подій, які полягали у належності реалізацій, що розпізнаються, до класу «Менше норми», якщо вони дійсно належать цьому класу;

$K_3^{(k)}$  – кількість подій, які полягали у належності реалізацій, що розпізнаються, до класу «Більше норми», якщо вони дійсно належать цьому класу.

Після відповідної підстановки оцінок точністних характеристик (2.10) у вираз (2.9) робоча формула обчислення інформаційного критерію оптимізації параметрів машинного навчання приймає вигляд

$$E^{(k)} = \frac{1}{8n_{\min}} [2(K_1^{(k)} + K_2^{(k)} + K_3^{(k)} - 3n_{\min}] \times \log_2 \frac{K_1^{(k)} + K_2^{(k)} + K_3^{(k)} + 10^{-r}}{3n_{\min} - K_1^{(k)} - K_2^{(k)} - K_3^{(k)} + 10^{-r}}, \quad (2.11)$$

де  $10^{-r}$  – мале додатне число для уникнення поділу на нуль ( $1 < r \leq 3$ ).

У формулі (2.11) підрахунок кількості подій для кожного класу розпізнавання відбувається наступним чином:

1) одночасна зміна в процесі навчання радіусів контейнерів трьох класів в інтервалі  $[1, d_{\min}]$ , де  $d_{\min}$  – мінімальна міжкласова кодова відстань;

2) обчислення в бінарному просторі Хемінга кодової відстані  $d(x_m \otimes x^j)$  між центрами гіперсфер та реалізаціями навчальних матриць, де  $x_m$  – еталонний вектор-реалізація, вершина якого визначає центр контейнера, і  $x^j$  –  $j$ -а реалізація класу  $X_m^o$ ;

3) віднесення реалізації до класу розпізнавання  $X_m^o$ , здійснюється для гіперсферичних вирішальних правил за функцією належності [17]

$$\mu_m = 1 - \frac{d[x_m \oplus x^{(j)}]}{d_m^*} \quad (2.12)$$

де  $d[x_m \oplus x^{(j)}]$  – кодова відстань між еталонним вектором  $x_m$  і реалізацією  $x^{(j)}$ , що розпізнається;  $d_m^*$  – визначений на етапі навчання оптимальний радіус контейнера класу  $X_m^o$ .

Рис. 2.3 ілюструє геометричний зміст функції належності (2.12).

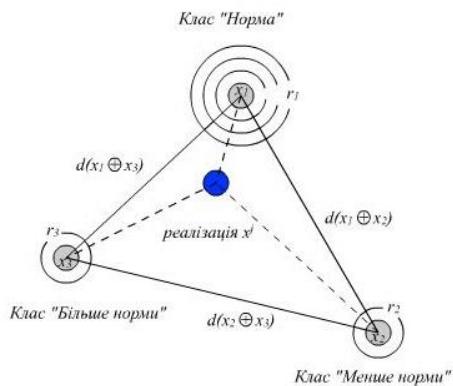


Рисунок 2.3 – Розташування класів в бінарному просторі Хемінга в загальному випадку

Запропонований КФЕ (2.11) на базі модифікації інформаційної міри Кульбака для трьохальтернативної системи оцінок рішень, дозволяє оцінювати функціональну ефективність машинного навчання для розподілів реалізацій класів розпізнавання у просторі ознак довільної конфігурації і, таким чином, володіє універсальністю в порівнянні з аналогічними критеріями оптимізації параметрів навчання у тих випадках, коли точнісні характеристики визначаються за методом найближчого сусіда. Крім того, використання запропонованого КФЕ для побудови в процесі машинного навчання вирішальних правил характеризується більш високими достовірністю і оперативністю в порівнянні з двохальтернативним критерієм. При цьому підвищення оперативності алгоритму машинного навчання досягається за рахунок відсутності в процесі його реалізації усереднення значень інформаційного критерію. Крім того, якщо побудовані при використанні методу найближчого сусіда вирішальні правила послідовно визначають належність вектора-реалізації образу, який розпізнається, до кожного із класів заданого алфавіту, то при застосуванні методу *K*-найближчих сусідів належність вектора-реалізації визначається одночасно для трьох класів розпізнавання.

## З ІНФОРМАЦІЙНИЙ СИНТЕЗ СИСТЕМИ КЕРУВАННЯ ПРОТЕЗОМ РУКИ

**3.1 Категорійна модель машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.**

Оскільки керований процес є слабо формалізованим через довільні умови формування образів, то категорійну модель інформаційно-екстремального навчання системи керування розглянемо у вигляді узагальненого орієнтованого графу, в якому ребром є оператор відображення відповідної множини на іншу. При цьому вхідний математичний опис здатної навчатися системи керування протезом подамо у вигляді структури

$$\Delta_B = \langle T, \Omega, Z, G, G^*, Y, X; f_1, f_2, f_3 \rangle,$$

де  $T$  – множина моментів часу зняття інформації;

$\Omega$  – простір ознак розпізнавання;

$Z$  – простір можливих функціональних станів керованого процесу;

$G$  – множина вхідних факторів – біосигналів, які читаються системою;

$G^*$  – множина квантованих за рівнем біосигналів;

$Y$  – множина векторів реалізацій класів розпізнавання, яка утворює вхідну навчальну матрицю;

$X$  – бінарна навчальна матриця;

$f_1$  – оператор кантування за рівнем біосигналів;

$f_2$  – оператор формування вхідної навчальної матриці  $Y$ ;

$f_3$  - оператор формування бінарної навчальної матриці  $X$ .

Категорійну модель інформаційного машинного навчання системи керування протезом руки з оптимізацією контрольних допусків на ознаки розпізнавання та рівнів квантування біосигналів показано на рис. 3.1.

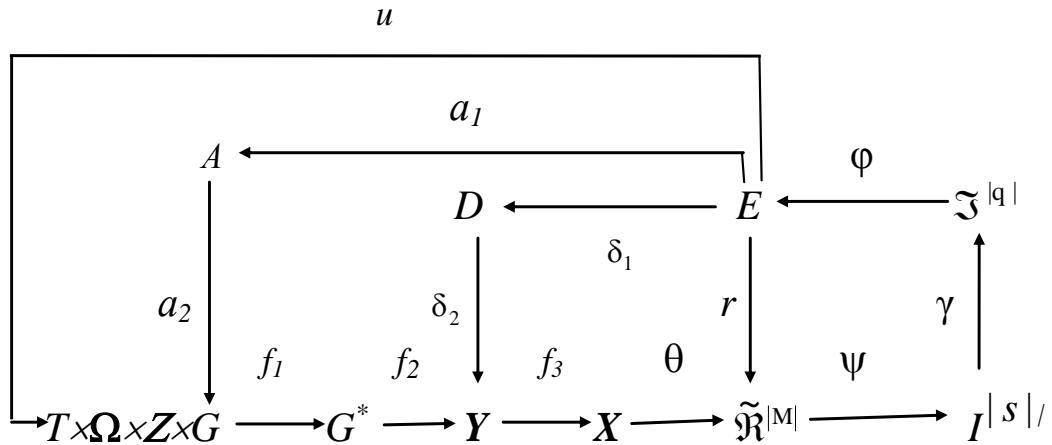


Рисунок 3.1 – Категорійна модель машинного навчання системи керування протезом кінцівки руки

На рис. 3.1 декартовий добуток  $T \times \Omega \times Z \times G$  задає універсум випробувань. Оператор  $\theta$  відображає двійкові вектори-реалізації навчальної матриці  $X$  на загальному випадку нечітке розбиття  $\tilde{\mathfrak{R}}^{|M|}$  простору ознак на класи розпізнавання, а оператор  $\psi$  перевіряє основну статистичну гіпотезу про належність реалізацій відповідному класу розпізнавання. За результатами статистичної перевірки гіпотез формується множина статистичних гіпотез  $I^{|s|}$ , де  $s$  – кількість статистичних гіпотез, а оператор  $\gamma$  формує множину точністних характеристик  $\mathfrak{I}^{|q|}$ , де  $q = s^2$ . Оператор  $\varphi$  обчислює множину  $E$  значень інформаційного критерію оптимізації параметрів навчання, а оператор  $r$  на кожному кроці машинного навчання відновлює в радіальному базисі простору ознак контейнери класів розпізнавання. В категорійній моделі контур оптимізації контролює допусків на ознаки розпізнавання замикається через терм-множину  $D$  – систему контрольних допусків, які використовуються як рівні квантування ознак розпізнавання при формуванні робочої бінарної навчальної матриці. Відмінність показаної на рис. 3.1 категорійної моделі від запропонованої моделі в попередньому проміжному звіті полягає у наявності додаткового

контуру оптимізації рівня квантування біосигналів. Цей контур замикається через множину  $A$  – терм-множину рівнів квантування.

Таким чином, показана на рис. 3.1 категорійна модель може розглядатися як узагальнена структурна схема алгоритму інформаційно-екстремального навчання системи керування. Якщо за результатами машинного навчання побудовані за оптимальними геометричними параметрами контейнерів класів розпізнавання вирішальні правила не будуть безпомилковими за навчальною матрицею, то згідно з принципом відкладених рішень може виникнути необхідність оптимізації інших параметрів навчання. У цьому випадку збільшення глибини машинного навчання призводить до появи в категорійній моделі додаткових контурів оптимізації параметрів машинного навчання, для яких загальною буде терм-множина  $E$ .

### **3.2 Алгоритм машинного навчання системи керування протезом руки з неінвазивною системою зчитування біосигналів**

Згідно з категорійною моделлю (рис. 3.1) інформаційно-екстремальний алгоритм машинного навчання системи керування протезом кінцівки руки з оптимізацією системи контрольних допусків на ознаки розпізнавання та рівнів квантування біосигналів подається у вигляді процедури пошуку глобального максимуму інформаційного критерію оптимізації в робочій області визначення його функції

$$a^* = \arg \max_{G_a} \left\{ \max_{G_\delta} \left[ \frac{1}{M} \sum_{m=1}^M \max_{G_{E_m} \cap \{d\}} E_m(d) \right] \right\}, \quad (3.1)$$

де  $E_m(d)$  – інформаційний критерій оптимізації параметрів навчання системи розпізнавати реалізації класу  $X_m^o$ ;

$G_a$  – допустима область значень рівня квантування біосигналів;

$G_\delta$  – допустима область значень параметра  $\delta$  поля контрольних допусків на ознаки розпізнавання;

$G_{Em}$  – робоча (допустима) область визначення критерію  $E_m(d)$ ;

$\{d\}$  – множина значень радіусів гіперсферичних контейнерів класів розпізнавання.

Центральним питанням методів IEI-технології аналізу даних є конструювання, обчислення на кожному кроці машинного навчання та пошук глобального максимуму інформаційного критерію оптимізації параметрів функціонування системи розпізнавання. Як інформаційний критерій оптимізації параметрів машинного навчання будемо використовувати модифіковану міру Кульбака, яка для двохальтернативних рішень з априорно рівномовірними гіпотезами має вигляд

$$E_m(d) = [D_{1,m}(d_m) - \beta_m(d_m)] \log_2 \left[ \frac{1 + [D_{1,m}(d_m) - \beta_m(d_m)] + 10^{-p}}{1 - [D_{1,m}(d_m) - \beta_m(d_m)] + 10^{-p}} \right], \quad (3.2)$$

де  $D_{1,m}(d_m)$ ; – перша достовірність, яка характеризує правильність класифікації вектора-реалізації класу  $X_m^o$ ;

$\beta_m(d)$ ; – помилка другого роду, яка характеризує помилкове віднесення до класу  $X_m^o$  вектора-реалізації іншого класу;

$d_m$  – дистанційна міра, яка визначає величину радіусу гіперсферичного контейнера класу розпізнавання  $X_m^o$ ;

$10^{-p}$  – достатньо мале число, яке вводиться для уникнення поділу на нуль (величина  $r$  на практиці вибирається в інтервалі  $1 < p \leq 3$  ).

Нормалізацію критерію (3.2) доцільно здійснювати за формулою

$$J_m(d) = \frac{E_m(d)}{E_{\max}}, \quad (3.3)$$

де  $E_{\max}$  – максимальне значення критерію (3.2), яке він приймає при  $D_{1,m}(d_m) = 1$  і  $\beta_m(d_m) = 0$ .

Вхідною інформацією для алгоритму навчання є масив вхідної навчальної матриці  $\{y_{m,i}^{(j)}\}$ , система полів нормованих допусків  $\{\delta_{H,i}\}$  на ознаки розпізнавання, яка задає область значень відповідних контрольних допусків, масив  $\{a_k\}$  рівнів квантування біосигналів і максимальний діапазон  $k_{\max}$  зміни напруги біосигналів, який дорівнював  $200 \text{ mV}$ .

Розглянемо основні етапи реалізації алгоритму навчання системи керування 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 рівня квантування біосигналів:  $a := 0$ ;

2)  $a = a + 1$ ;

3) ініціалізація лічильника кроків зміни параметра  $\delta$  поля контрольних допусків на ознаки розпізнавання:  $\delta := 0$ ;

4)  $\delta := \delta + 1$ ;

5) обчислюються для всіх ознак розпізнавання нижні  $A_{HK,i}$  і верхні  $A_{BK,i}$  контрольні допуски на ознаки розпізнавання:

$$A_{HK,i} = \bar{y}_i - \delta; \quad A_{BK,i} = \bar{y}_i + \delta. \quad (3.4)$$

6) реалізується внутрішній цикл процедури (3.1), який полягає в обчисленні на кожному кроці зміни радіусів контейнерів класів розпізнавання інформаційного критерію оптимізації параметрів навчання,

пошуку глобального максимуму інформаційного критерію і визначені оптимальних радіусів контейнерів класів розпізнавання за процедурою

$$d_m^* = \arg \frac{1}{M} \sum_{m=1}^M \max_{G_{Em} \cap \{d\}} E_m(d_m);$$

- 7) якщо  $\delta < \delta_H / 2$ , то виконується пункт 4, інакше – пункт 8;
- 8) обчислюється усереднене за алфавітом класів розпізнавання максимальне значення критерію  $\bar{E}^*$ ;
- 9) визначається оптимальний параметр поля контрольних допусків, який забезпечує максимальне значення усередненого критерію  $\bar{E}^*$ :

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

- 10) обчислюється за формулою (3.4) оптимальна система контрольних допусків на ознаки розпізнавання:

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

- 11) якщо  $a \leq k_{\max}$ , то виконується пункт 2, інакше – пункт 12;
- 12) визначення оптимального рівня квантування біосигналів для заданого алфавіту класів розпізнавання:

$$a^* = \arg \bar{E}^*(a, \delta);$$

- 13) ЗУПИН.

Таким чином, параметрами інформаційно-екстремального навчання системи керування за процедурою (3.1) є оптимальні радіуси  $\{d_m^*\}$  гіперсферичних контейнерів класів розпізнавання, оптимальні усереднені вектори-реалізації  $\{x_m^*\}$  класів розпізнавання, оптимальний параметр  $\delta^*$  поля контрольних допусків на ознаки розпізнавання та оптимальний рівень квантування  $a^*$ .

Отримані за результатами паралельної оптимізації параметри машинного навчання є по суті квазіоптимальними, оскільки вони на кожному кроці навчання змінювалися для всіх ознак на однакову величину.

Підвищення функціональної ефективності машинного навчання можна досягнути шляхом реалізації паралельно-послідовної оптимізації контрольних допусків на ознаки розпізнавання. При цьому отримані за результатами паралельної оптимізації квазіоптимальні контрольні допуски на ознаки розпізнавання розглядаються як стартові для послідовної оптимізації. Такий підхід дозволяє підвищити як достовірність прийняття рішень, так і оперативність алгоритму послідовної оптимізації, оскільки пошук глобального максимуму інформаційного критерію не виходить за межі робочої області визначення його функції.

Послідовна оптимізація контрольних допусків на ознаки розпізнавання в процесі машинного навчання здійснюється за процедурою наближення глобального максимуму інформаційного критерію оптимізації (3.2) до граничного значення в робочій області визначення його функції:

$$a_k^* = \arg \max_{G_a} \left\{ \bigotimes_{l=1}^L \left\{ \max_{G_{\delta i}} \left[ \frac{1}{M} \sum_{m=1}^M \max_{G_{Em} \cap \{G_d\}} E_m^{(l)}(d_m) \right] \right\} \right\}, \quad k = \overline{1, k_{\max}}, \quad (3.5)$$

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

$L$  – кількість прогонів процедури послідовної оптимізації контрольних допусків на ознаки розпізнавання;

$\otimes$  – символ операції повторення.

За схемою реалізації процедура (3.5) відрізняється від процедури паралельної оптимізації (3.1) тим, що на кожному кроці машинного навчання послідовно змінюються контрольні допуски тільки для однієї ознаки розпізнавання. Оскільки контрольні допуски починають змінюватися дляожної ознаки при неоптимальних допусках інших ознак, то процедура (3.5) потребує декількох її прогонів до тих пір, поки значення інформаційного критерію перестануть змінюватися.

За отриманими в процесі машинного навчання оптимальними геометричними параметрами навчання будуються вирішальні правила для прийняття класифікаційних рішень при функціонуванні системи керування безпосередньо в робочому режимі. Для гіперсферичних контейнерів класів розпізнавання вирішальні правила мають вигляд

$$(\forall X_m^o \in \Re^{|\mathcal{M}|})(x^{(j)} \in \Re^{|\mathcal{M}|})[if (\mu_m > 0) \& (\mu_m > \mu_c) then x^{(j)} \in X_m^o], \quad (3.6)$$

де  $x^{(j)}$  – вектор-реалізація, що розпізнається;

$\mu_m, \mu_c$  функції належності реалізації, що розпізнається, контейнерам сусідніх (найближчих) класів розпізнавання  $X_m^o$  і  $X_c^o$  відповідно.

У виразі (3.6) відповідні функції належності для гіперсферичних контейнерів визначаються за формулами

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

$$\mu_c = 1 - \frac{d(x^{(j)} \oplus x_c)}{d_c^*},$$

де  $x_c$  – усереднений вектор-реалізація класу розпізнавання  $X_c^o$ ;  $d_c^*$  – отриманий в процесі машинного навчання оптимальний радіус контейнера класу розпізнавання  $X_c^o$ .

Таким чином, оптимізація параметрів функціонування системи керування протезом кінцівки руки з неінвазивою системою зчитування біосигналів полягає в організації пошуку в процесі машинного навчання глобального максимуму інформаційного критерію (3.2) в робочій (допустимій) області визначення його функції.

### **3.3 Формалізована постановка задачі інформаційного синтезу системи керування протезом, що навчається за ієрархічним алгоритмом**

У попередньому проміжному звіті НДР було наведено результати фізичного моделювання машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів для трьох класів розпізнавання, 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. Аналіз одержаних результатів показав, що навіть для алфавіту із трьох класів розпізнавання не вдалося побудувати безпомилкові за навчальною матрицею вирішальні правила через високий ступінь перетину цих класів в просторі ознак розпізнавання. Тому при подальшому збільшенні потужності алфавіту класів розпізнавання, пов’язаному з необхідністю розпізнавання різних комбінацій рухів пальців, виникає необхідність переходу від лінійних вирішальних правил до ієрархічних.

Розглянемо формалізовану постановку задачі інформаційного синтезу здатної навчатися за ієрархічною структурою даних системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

Нехай задана ієрархічна структура класів розпізнавання  $\{X_{h,s,m}^o | h = \overline{1,H}; s = \overline{1,S}; m = \overline{1,M}\}$ , де  $H$  – кількість ярусів ієрархічної структури;  $S$  – кількість страт на  $h$ -му ярусі;  $M$  – кількість класів розпізнавання в  $s$ -ї страті. При цьому кожний клас розпізнавання характеризує відповідний рух протезу. За результатами оброблення біосигналів всіх рухів кінцівки руки згідно із заданим алфавітом класів розпізнавання сформовано для кожного класу розпізнавання вхідну навчальну матрицю

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

де  $N$  – кількість ознак розпізнавання в багатовимірному векторі- реалізації класу розпізнавання  $X_{h,s,m}^o$ ;

$n$  – кількість векторів-реалізацій, яка дорівнює кількості періодів зчитування інформації з міографічного датчика.

Таким чином,  $i$ -й стовпчик матриці  $\| y_{m,i}^{(j)} \|$  містить значення навчальної вибірки, а  $j$ -й рядок є структурованою реалізацією з  $N$  ознак розпізнавання.

Задано структурований вектор параметрів навчання системи розпізнавати вектори-реалізації класу  $X_{h,s,m}^o$ :

$$g_{h,s} = \langle x_{h,s,m}, d_{h,s,m}, \delta_{K,h,s,m,i} \rangle, \quad (3.7)$$

де  $x_{h,s,m}$  – двійковий усереднений вектор-реалізація, вершина якого визначає геометричний центр гіперсферичного контейнеру класу розпізнавання  $X_{h,s,m}^o$  в бінарному просторі діагностичних ознак;

$d_{h,s,m}$  – кодова відстань, яка визначає радіус гіперсферичного контейнера класу  $X_{h,s,m}^o$ ;

$\delta_{K,h,s,m,i}$  – параметр, який дорівнює половині симетричного поля контрольних допусків  $i$ -ї діагностичної ознаки усередненого вектору-реалізації  $x_{h,s,m}$  класу розпізнавання  $X_{h,s,m}^o$ .

При цьому задано обмеження:

$$d_{h,s,m} \in [0; d(x_{h,s,m} \oplus x_{h,s,c}) - 1],$$

де  $d(x_{h,s,m} \oplus x_{h,s,c})$  – кодова відстань між усередненим вектором-реалізацією  $x_{h,s,m}$  класу розпізнавання  $X_{h,s,m}^o$  і усередненим вектором-реалізацією  $x_{h,s,c}$  найближчого сусіднього класу розпізнавання  $X_{h,s,c}^o$ ;

$$\delta_{K,h,s,i} \in [0; \delta_{E,h,s,i}/2)],$$

де  $\delta_{E,h,s,m,i}$  – поле експлуатаційних допусків  $i$ -ї діагностичної ознаки усередненого вектору-реалізації  $x_{h,s,m}$  класу розпізнавання  $X_{h,s,m}^o$

На етапі машинного навчання необхідно:

1) оптимізувати параметри вектора (3.2) за усередненим за алфавітом класів розпізнавання  $\{X_{h,s,m}^o\}$  інформаційним критерієм

$$\bar{E}_{h,s} = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap G_d} E_{h,s,m}(d_{h,s,m}), \quad (3.8)$$

де  $E_{h,s,m}(d_{h,s,m})$  – інформаційний критерій оптимізації параметрів машинного навчання системи розпізнавати вектори-реалізації класу  $X_{h,s,m}^o$ , значення якого обчислюються на кожному кроці машинного навчання при зміні радіусу контейнеру класу розпізнавання;

$G_E$  – робоча (допустима) область визначення інформаційного критерію оптимізації;  $G_d$  – допустима область зміни радіуса гіперсферичного контейнеру класу розпізнавання.

2) за отриманими в процесі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання побудувати для кожної страти ієрархічної структури вирішальні правила, які гарантують високу повну ймовірність прийняття правильних діагностичних рішень.

На етапі екзамену, тобто безпосередньо в робочому режимі

функціонування системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів, необхідно прийняти класифікаційне рішення про належність поточного вектору-реалізації, що розпізнається, до одного із класів розпізнавання із заданої ієрархічної структури.

### **3.4 Алгоритм інформаційно-екстремального ієрархічного машинного навчання**

Вхідний математичний опис здатної навчатися системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів подамо у вигляді структури

$$\mathcal{A}_B = \langle G, T, \Omega, Z, Y, X; f_1, f_2 \rangle,$$

де  $G$  – множина вхідних факторів;  $T$  – множина моментів часу зняття інформації;  $\Omega$  – простір діагностичних ознак;  $Z$  – простір можливих станів керованого процесу;  $Y$  – множина векторів-реалізацій класів розпізнавання, яка утворює вхідну навчальну матрицю;  $X$  – бінарна навчальна матриця;  $f_1 : G \times T \times \Omega \times Z \rightarrow Y$  – оператор формування вхідної навчальної матриці  $Y$ , де  $G \times T \times \Omega \times Z$  – декартовий добуток, який задає універсам випробувань;  $f_2 : Y \rightarrow X$  – оператор формування робочої бінарної навчальної матриці  $X$ .

Категорійну модель ієрархічного машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів представимо у вигляді узагальненого орієнтованого графу (рис. 3.2).

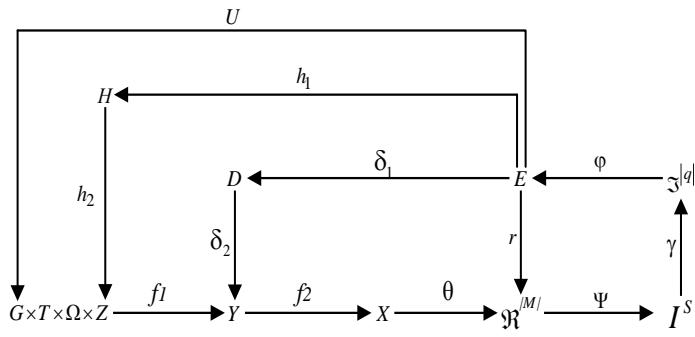


Рисунок 3.2 – Категорійна модель ієрархічного навчання системи керування протезом кінцівки руки

На рис. 3.2 оператор  $\theta$  відображає двійкові вектори-реалізації навчальної матриці  $X$  на розбиття  $\Re^{|M|}$  простору діагностичних ознак на класи розпізнавання, а оператор  $\psi$  перевіряє основну статистичну гіпотезу про належність реалізацій відповідному класу розпізнавання. За результатами статистичної перевірки гіпотез формується множина статистичних гіпотез  $I^{|s|}$ , де  $s$  – кількість статистичних гіпотез, а оператор  $\gamma$  формує множину точністних характеристик  $Z^{|q|}$ , де  $q = s^2$ . Оператор  $\phi$  обчислює множину  $E$  значень інформаційного критерію оптимізації параметрів навчання, а оператор  $r$  на кожному кроці машинного навчання відновлює в радіальному базисі простору ознак контейнерів класів розпізнавання. В категорійній моделі контур оптимізації контрольних допусків на діагностичні ознаки замикається через терм-множину  $D$  – систему контрольних допусків, які використовуються як рівні квантування ознак розпізнавання при формуванні робочої бінарної навчальної матриці.

Таким чином, показана на рис. 3.4 категорійна модель може розглядатися як узагальнена структурна схема алгоритму інформаційно-екстремального навчання системи керування. При цьому згідно з принципом відкладених рішень для максимізації інформаційної спроможності системи керування може бути необхідною оптимізація інших параметрів машинного навчання, які впливають на функціональну ефективність. У цьому випадку

категорійна модель буде мати додаткові контури оптимізації цих параметрів. Крім того, згідно з принципом повної композиції контури оптимізації повинні мати загальну терм-множина  $E$ , елементи якої обчислюються на кожному кроці машинного навчання.

Таким чином, показана на рис. 3.4 категорійна модель може розглядатися як узагальнена схема алгоритму інформаційно-екстремального машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

Як критерій оптимізації параметрів машинного навчання в методах IEI-технології може використовуватися будь-яка інформаційна статистична міра. Найбільшого поширення в рамках IEI-технології знайшли ентропійні (за Шенноном) критерії та інформаційна міра Кульбака. Для оптимізації параметрів навчання використаємо модифікований критерій Кульбака у вигляді

$$J_{h,s,m}^{(k)} = \{1 - [\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)] * \\ * \log_2 \left( \frac{2 - (\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)) + 10^{-r}}{\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d) + 10^{-r}} \right), \quad (3.9)$$

де  $\alpha_{h,s,m}^{(k)}(d)$  – помилка першого роду при прийнятті класифікаційних рішень, обчислена в процесі відновлення гіперсферичного контейнера класу розпізнавання  $X_m^o$  з радіусом  $d$ ;  $\beta_{h,s,m}^{(k)}(d)$  – помилка другого роду;  $10^{-r}$  – достатньо мале число, яке вводиться для уникнення поділу на нуль

У виразі (3.9) величина параметра  $r$  на практиці вибирається з інтервалу  $1 < r \leq 3$ .

З метою нормалізації інформаційного критерію (3.9) представимо його у вигляді

$$E_m^{(k)} = \frac{J_m^{(k)}}{J_{\max}}, \quad (3.10)$$

де  $J_{\max}$  – максимальне значення інформаційного критерію (3.9) при підстановці в нього значень точністних характеристик  $\alpha_{h,s,m}^{(k)}(d)=0$  і  $\beta_{h,s,m}^{(k)}(d)=0$ .

При обчисленні у процесі машинного навчання системи інформаційного критерію необхідно прийняти до уваги, що його функція є невзаємно-однозначною. Тому пошук максимального значення критерію здійснюється в робочій (допустимій) області визначення його функції, де перша і друга достовірності діагностичних рішень, які приймаються на кожному кроці машинного навчання, перевершують відповідно помилки першого та другого роду.

Згідно з категорійною моделлю (рис. 3.4) інформаційно-екстремальний алгоритм навчання системи функціонального діагностування з заданою ієрархічною структурою даних представимо у вигляді процедури пошуку глобального максимуму усередненого за алфавітом  $\{X_m^o\}$  критерію (3.10)

$$\delta_{K,h,s}^* = \arg \max_{G_{\delta,h,s}} \{ \max_{G_E \cap G_d} \bar{E}_{h,s}(d) \}, \quad (3.11)$$

де  $G_{\delta,h,s}$  – область допустимих значень параметра  $\delta_{K,h,s}$  поля контролюних допусків на діагностичні ознаки для класів розпізнавання  $s$ -ї страти  $h$ -го ярусу ієрархічної структури.

Оцінка функціональної ефективності навчання системи керування протезом кінцівки руки здійснюється за базовим інформаційно-екстремальним алгоритмом, який реалізується у внутрішньому циклі процедури (3.11). Основними функціями базового алгоритму є обчислення на кожному кроці машинного навчання інформаційного критерію оптимізації

(3.10), пошук його глобального максимуму в робочій області визначення функції та визначення екстремальних значень радіусів контейнерів класів розпізнавання.

У загальному випадку вхідними даними базового інформаційно-екстремального алгоритму є масив векторів-реалізацій класів розпізнавання  $\{y_{m,i}^{(j)} | m = \overline{1, M}; i = \overline{1, N}, j = \overline{1, n}\}$ , система контрольних допусків  $\{\delta_{K,i}\}$  на діагностичні ознаки та рівні селекції  $\{\rho_{m,i}\}$  координат двійкових усереднених векторів-реалізацій, які за замовчуванням дорівнюють  $\rho_{m,i} = 0,5$ .

Оптимізація геометричних параметрів контейнерів класів розпізнавання  $\{X_{m,h,s}^o\}$ , які належать  $s$ -й страті  $h$ -го ярусу ієрархічної структури відбувається за такими основними етапами базового алгоритму інформаційно-екстремального машинного навчання:

- 1) формування вхідної структурованої навчальної матриці, дійсні або цілі числа якої задаються в евклідовому просторі;
- 2) визначення усереднених векторів-реалізацій класів розпізнавання;
- 3) формування бінарної навчальної матриці при заданій системі контрольних допусків на діагностичні ознаки;
- 4) визначення усереднених векторів-реалізацій класів розпізнавання, координати яких обчислюються шляхом статистичного усереднення відповідних двійкових бінарних навчальних вибірок;
- 5) визначення міжцентрорвих відстаней для заданого алфавіту класів розпізнавання шляхом обчислення кодових відстаней між усередненими векторами-реалізаціями класів розпізнавання.
- 6) пошук найближчого сусіда або  $k$ -найближчих сусідів шляхом визначення мінімальних кодових відстаней між центрами класів розпізнавання;
- 7) обчислення на кожному кроці навчання точністних характеристик та усередненого інформаційного критерію оптимізації параметрів машинного навчання;

8) пошук глобального максимуму усередненого інформаційного критерію оптимізації параметрів машинного навчання, який знаходиться в робочій (допустимій) області визначення функції критерію;

9) визначення оптимальних радіусів контейнерів класів розпізнавання, які на кожному кроці навчання відновлюються в радіальному базисі простору діагностичних ознак за ітераційною процедурою

$$d_{m,h,s}^* = \arg \max_{G_E \cap G_d} \bar{E}_{h,s}(d_{h,s,m}), m = \overline{1, M}_{h,s}, \quad (3.12)$$

де  $M_{h,s}$  – кількість класів розпізнавання, які належать  $s$ -й страті  $h$ -го ярусу;

#### 10) ЗУПИН.

Розглянемо узагальнену схему ієрархічного алгоритму паралельної оптимізації контрольних допусків на діагностичні ознаки в рамках інформаційно-екстремального навчання системи керування протезом кінцівки руки:

- 1) обнулення лічильника ярусів:  $h := 0$ ;
- 2) ініціалізація лічильника ярусів:  $h := h + 1$ ;
- 3) обнулення лічильника страт  $h$ -го ярусу ієрархічної структури:  $s := 0$ ;
- 4) ініціалізація лічильника страт яруса:  $s := s + 1$ ;
- 5) обнулення лічильника кроків зміни параметра поля контрольних допусків:  $\delta_{K,h,s} := 0$ ;
- 6) ініціалізація лічильника кроків зміни параметра поля контрольних допусків:  $\delta_{K,h,s} := \delta_{K,h,s} + 1$ ;
- 7) реалізація базового алгоритму машинного навчання, який для  $s$ -ї страти  $h$ -го ярусу ієрархічної структури обчислює максимальне значення інформаційного критерію  $E_{h,s,m}(d_{h,s,m})$  та за процедурою (3.) визначає оптимальні геометричні параметри контейнерів класів розпізнавання
- 8) якщо  $\delta < \delta_H / 2$ , то виконується пункт 6, інакше – пункт 9.

9) обчислюється максимальне значення усередненого за алфавітом класів розпізнавання для  $s=і$  страти  $h$ -го ярусу ієрархічної структури значення інформаційного критерію  $\bar{E}_{h,s}^*$ ;

10) визначається для  $s$ -ї страти  $h$ -го ярусу оптимальне значення параметра поля контрольних допусків діагностичних ознак

$$\delta_{h,s}^* = \arg \bar{E}_{h,s}^*,$$

за яким обчислюються оптимальні нижні  $A_{HK_i}^*$  та верхні  $A_{BK_i}^*$  контрольні допуски:

$$A_{HK_i}^* = y_{h,s,m} - \delta_{h,s}^*; A_{BK_i}^* = y_{h,s,m} + \delta_{h,s}^*, \quad (3.13)$$

де  $y_{h,s,m}$  – номінальне усереднене значення  $i$ -ї діагностичної ознаки вектору-реалізації класу розпізнавання  $X_{h,s,m}$ ;

11) для оптимальної системи контрольних допусків формується оптимальна бінарна навчальна матриця  $\|x_{h,s,m,i}^{(j)}\|^*$  за правилом

$$x_{h,s,m,i}^{(j)*} = \begin{cases} 1, & \text{if } A_{HK,i}^* \leq y_{h,s,m,i}^{(j)} \leq A_{BK,i}^*; \\ 0, & \text{if else;} \end{cases}$$

12) формуються оптимальні усереднені вектори-реалізації  $\{x_{h,s,m}^*\}$ , які визначають геометричні центри контейнерів відповідних класів розпізнавання, що відновлюються в процесі машинного навчання в радіальному базисі простору діагностичних ознак. При цьому координати векторів  $\{x_{h,s,m}^*\}$  обчислюються за правилом

$$x_{h,s,m}^* = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{h,s,m,i}^{(j)*} \leq \rho_{h,s,m}; \\ 0, & \text{else,} \end{cases}$$

де  $\rho_{h,s,m}$  – рівень селекції (квантування) координат усереднених двійкових векторів класів розпізнавання  $s=і$  страти  $h$ -го ярусу ієрархічної структури;

13) якщо  $s \leq S_h$ , то виконується пункт 4, інакше –punkt 14.

14) Якщо  $h \leq H$ , то виконується пункт 2, інакше – пункт 15;

15) ЗУПИН.

Таким чином, алгоритм інформаційно-екстремального машинного навчання полягає в адаптації вхідного математичного опису системи керування протезом кінцівки руки до її максимальної інформаційної спроможності, яка визначається інформаційним критерієм оптимізації параметрів навчання.

За отриманими в процесі ієрархічного інформаційно-екстремального машинного навчання системи оптимальними геометричними параметрами гіперсферичних контейнерів класів розпізнавання було побудовано вирішальні правила, вираз яких в предикатній формі має вигляд

$$(\forall X_m^o \in \Re^{|M|})(\forall x^{(j)} \in \Re^{|M|}) \{ if [(\mu_m > 0) \& \& (\mu_m = \max_{\{m\}} \{\mu_m | m = \overline{1, M}\})] then x^{(j)} \in X_m^o \}, \quad (3.14)$$

де  $x^{(j)}$  – вектор-реалізація, що розпізнається;

$\mu_m$  – функція належності вектора  $x^{(j)}$  гіперсферичному контейнеру класу розпізнавання  $X_m^o$ , яка визначається за формулою

$$\mu_m = 1 - \frac{d(x^{(j)} \oplus x_{h,s,m}^*)}{d_{h,s,m}^*}. \quad (3.15)$$

Таким чином, вектор-реалізація, що розпізнається, відноситься до того класу із заданого алфавіту відповідної страти ієрархічної структури, для якого функція належності (3.15) максимальна і є додатною.

## ВИСНОВКИ

Одержані наукові результати спрямовані на підвищення функціональної ефективності машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

1. Розроблено метод визначення мінімального обсягу репрезентативної навчальної вибірки за умови отримання прийнятних з практичних міркувань статистичної похибки та оперативності алгоритму машинного навчання системи керування протезом кінцівки руки.

2. Запропоновано метод визначення нормованих допусків на ознаки розпізнавання, який шляхом максимізації середньої міжцентрової відстані для заданого алфавіту класів розпізнавання дозволяє визначити область значень для контрольних допусків в процесі їх оптимізації при машинному навчанні.

3. Удосконалено метод оцінки статистичної стійкості та однорідності навчальної вибірки, який дозволяє накладати обмеження на систему контрольних допусків на ознаки розпізнавання з метою усунення зменшення функціональної ефективності машинного навчання.

4. Отримав подальшого розвитку метод оцінки функціональної ефективності машинного навчання на основі інформаційного критерію. Запропоновано модифіковані інформаційні міри Кульбака для трьохальтернативної системи оцінки класифікаційних рішень у випадках визначення точністних характеристик за методами «найближчого сусіда» і « $K$ -найближчих сусідів». Показано, що при обчисленні точністних характеристик за методом « $K$ -найближчих сусідів» підвищується оперативність машинного навчання системи керування.

5. Розроблено категорійну модель машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів, на базі якої розроблено інформаційно-екстремальний алгоритм машинного навчання системи керування протезом кінцівки руки з

оптимізацію системи контрольних допусків на ознаки розпізнавання та рівнів квантування біосигналів. Алгоритм машинного навчання системи подається у вигляді процедури пошуку глобального максимуму інформаційного критерію оптимізації в робочій області визначення його функції.

6. Розроблено формалізовану постановку задачі інформаційного синтезу здатної навчатися за ієрархічною структурою даних системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів.

7. Розроблено алгоритм ієрархічного машинного навчання системи керування протезом кінцівки руки з неінвазивною системою зчитування біосигналів, який дозволяє підвищити повну ймовірність правильного розпізнавання біосигналів при збільшенні потужності алфавіту класів розпізнавання.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Довбиш А.С. Інформаційно-екстремальне машинне навчання системи керування протезом руки / А.С. Довбиш, В.В. Москаленко, В.Ю. П'ятаченко // Радіоелектронні та комп'ютерні системи, 2017.–№4.—С. 35–44.
2. Довбиш А. С. Інтелектуальний протез кінцівки руки з неінвазивною системою зчитування біосигналів / А.С. Довбиш, В. Ю. П'ятаченко // Інтелектуальні системи в промисловості і освіті (ІСПО-2017) : тези доповідей Четвертої міжн. наук.-техн. конференції, 29-31 жовтня 2017 р. – Вінниця: ВНТУ, 2017 – С. 38–39.
3. Москаленко В. В. Метод побудови вирішальних правил для прогнозування порушення умов обслуговування в хмарному середовищі / // Eastern-European Journal of Enterprise Technologies. – 2017. – No. 3. – P. 45.
4. A. S Moskalenko, V. V. Moskalenko, S. Pimonenko, and A. Korobov, "Development of the method of features learning and training decision rules for the prediction of violation of service level agreement in a cloud-based environment", Eastern-European Journal of Enterprise Technologies, no. 5/2 (89), pp. 26-33, 2017.(SCOPUS).
5. Moskalenko V.V. Information-extreme algorithm of the system for recognition of objects on the terrain with optimization para-meter feature extraction / A.G. Korobov, V.V. Moskalenko //Radio Electronics, Computer Science, Control. – Запорожжя : ЗНТУ. – 2017. – №2. – С. 38-45.
6. Шелехов И. В .Оперативное распознавание эталонного сигнала при его искажении нелинейным устройством с экспоненциальной статической характеристикой / В. В. Авраменко, И. В. Шелехов, Н. А. Зарецкий // Радіоелектроніка, Інформатика, Управління. – Запоріжжя , 2017. – № 1 (40). – С. 50-58.
7. Dovbysh A. S., Velikodnyi D. V., Protsenko J. B., Zimovets V. I. Optimization of parameters of machine learning of the system of functional diagnostics of the electric drive of a shaft lifting machine. Radio Electronics,

Computer Science, Control, 2018, No 2(45), pp. 44–50. DOI 10.15588/1607–3274–2018–2–5. <http://ric.zntu.edu.ua/article/view/142626>.

8. Довбиш А. С. Оптимізація ієрархічної структури даних інтелектуальної системи функціонального діагностування технічного стану складної машини/ А.С. Довбиш, В. І. Зимовець, М. В. Бібик // Вісник НТУ «ХПІ». Серія: Системний аналіз, управління та інформаційні технології. – Харків : НТУ «ХПІ», 2018. – № 48 (1220). – С 47–55.

9. Шелехов І. В. Інформаційно-екстремальне машинне навчання системи контролю знань / І. В. Шелехов, С.О. Пилипенко, О. О. Столлярчук, Т.А. Романенко // Вісник НТУ «ХПІ». Серія: Системний аналіз, управління та інформаційні технології. – Харків: НТУ «ХПІ», 2018. – № 48 (1220). – С 56–63.

10. Moskalenko V. Improving the effectiveness of training the on-board system for compact unmanned aerial vehicle / V. Moskalenko, A. Dovbysh, I. Naumenko, A. Moskalenko, A. Korobov // Eastern-European Journal of Enterprise Technologies. – 2018. – Vol. 4/9 (94). – P. 10-26. DOI: 10.15587/1729-4061.2018.139923. – <http://journals.uran.ua/eejet/article/> view/139923.

11. Патент118129 Україна, MKI F41G 5/14, F416G3/00. Автоматизована система керування вогнем мобільного мінометного комплексу / М. М. Будник, А.С. Довбиш, М.М. Ляпа, А.Ф. Раскошний, В.І. Макеєв, В. / Житник, М.Г. Ярема; заявник і патентовласник Сумський державний університет. № a20170156; заявл. 24.02.2018; опубл. 26.11.2018, Бюл. №22. – [https://library.uipv.org/document?fund=1&id=252879 &to\\_fund=1](https://library.uipv.org/document?fund=1&id=252879 &to_fund=1).

12. Довбиш А.С. П'ятаченко В. Ю. Машинне навчання протезу кінцівки руки// Матеріали НТК «Інформатика, математика, автоматика», Суми, 2018.– С.42. – <http://elitconf.sumdu.edu.ua/data/IMA-2018.pdf>.

13. Довбиш А.С. , Приходченко Р. С. Функціонування протезу кінцівки руки в режимі екзамену // Матеріали НТК «Інформатика, математика, автоматика», Суми, 2018.– С.43. – <http://elitconf.sumdu.edu.ua/data/IMA-2018.pdf>.

14. Anatoliy Dovbysh, Viktoriya Zimovets Hierarchical Algorithm of the Machine Learning for the System of Functional Diagnostics of the Electric Drive // Proceedings of the VI International Conference «Advanced Information Systems and Technologies – AIST-2018», Sumy, May 16 – 18, 2018. – Sumy. – Sumy State University, 2018. – pp. 85 – 88.

[http://essuir.sumdu.edu.ua/bitstream/123456789/67789/1/AIST\\_2018.pdf](http://essuir.sumdu.edu.ua/bitstream/123456789/67789/1/AIST_2018.pdf)

15. Juliy Simonovskiy, Vladislav Piatachenko, Nikita Mironenko. On-board Geographic Information System of Images Identification // Proceedings of the VI International Conference «Advanced Information Systems and Technologies – AIST-2018», Sumy, May 16 – 18, 2018. – Sumy. – Sumy State University, 2018. – pp. 115 – 118.

[http://essuir.sumdu.edu.ua/bitstream/123456789/67789/1/AIST\\_2018.pdf](http://essuir.sumdu.edu.ua/bitstream/123456789/67789/1/AIST_2018.pdf)

16. В. В. Москаленко. Метод самонавчання згорткового екстрактора ознак для розпізнавання багатоканальних діагностичних зображень / В. В. Москаленко, А. С. Москаленко, А. М. Кудрявцев // XIV International scientific conference «Intellectual systems of decision-making and problems of computational intelligence (ISDMCI'2018)», Україна. – 2018. – С. 258-260. – [https://sci.ldubgd.edu.ua/bitstream/handle/123456789/4977/isdmci\\_2018.pdf?sequence=1&isAllowed=y](https://sci.ldubgd.edu.ua/bitstream/handle/123456789/4977/isdmci_2018.pdf?sequence=1&isAllowed=y)

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

18. Довбиш А.С. Інтелектуальні інформаційні технології в електронному навчанні / А.С. Довбиш, А.В. Васильєв, В.О. Любчак. – Суми: Видавництво СумДУ, 2013.– 178 с.

19. Удод В. О. Лекції з теорії ймовірностей та математичної статистики. – Суми: Сумська обласна друкарня, 1999.– 188 с.

20. Большев Л. Н., Смирнов Н. В. Таблицы математической статистики. – М.: Наука, 1983. – 416 с.

21. Краснопоясовський А.С. Класифікаційний аналіз даних: Навчальний посібник.-Суми: Видавництво СумДУ, 2002.-159 с.
22. Кульбак С. Теория информации и статистика: Пер. с англ.– М.: Наука, 1967.– 408 с.
23. Довбиш А.С. Порівняльний аналіз двох- і трьохальтернативної систем оцінок рішень в задачах машинного навчання / А. С. Довбиш, О. Б. Берест, // Радіоелектронні і комп'ютерні системи: наук.-техн. журнал. – 2014.– №3(67).– С. 33-40.