

УДК 004:681.518
КП
№ держреєстрації 0112U006083
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. Черноус

**ЗВІТ
ПРО НАУКОВО-ДОСЛІДНУ РОБОТУ
МЕТОДИ ТА МАТЕМАТИЧНІ МОДЕЛІ СУЧАСНИХ ІНФОРМАЦІЙНО-
КОМУНІКАЦІЙНИХ ТЕХНОЛОГІЙ
(заключний)**

Начальник НДЧ
канд. фіз.-мат. наук,
старш. наук. співроб.

(підпис)
(дата)

Д.І. Курбатов

Науковий керівник НДР
Керівник НДР,
канд. техн. наук, доцент

(підпис)
(дата)

В.К. Ободяк

2017

Рукопис закінчено 15 травня 2017р.

Результати цієї роботи розглянуто науковою радою СумДУ, протокол від 28.12.2017р. № 4

СПИСОК АВТОРІВ

Керівник НДР, канд. техн. наук, доцент	_____	В.К. Ободяк (розділ 2.2)
	12.05.2017 р.	
Доктор техн. наук, професор	_____	А.С. Довбиш (розділ 4.2, 4.3)
	12.05.2017 р.	
Канд. техн. наук, доцент	_____	В.В. Авраменко (розділ 1.1)
	12.05.2017 р.	
Канд. техн. наук, доцент	_____	М.С. Бабій (розділ 1.2)
	12.05.2017 р.	
Канд. техн. наук, доцент	_____	В.О. Боровик (розділ 2.3)
	12.05.2017 р.	
Канд. техн. наук, доцент	_____	З.І. Маслова (розділ 2.5)
	12.05.2017 р.	
Канд. фіз.-мат. наук, ст. викладач	_____	Д.В. Великодний (розділ 2.1)
	12.05.2017 р.	
Асистент	_____	О.В. Власенко (розділ 3.4)
	12.05.2017 р.	
Канд. фіз.-мат. наук, доцент	_____	О.Б. Проценко (розділ 4.6)
	12.05.2017 р.	
Канд. фіз.-мат. наук, доцент	_____	Н.В. Тиркусова (розділ 3.2)
	12.05.2017 р.	
Асистент	_____	Г. А. Стадник (розділ 1.9)
	12.05.2017 р.	
Канд. техн. наук, ст.викладач	_____	Б.О. Кузіков (розділ 4.1, 4.6,)
	12.05.2017 р.	
Канд. техн. наук, доцент	_____	І.В. Шелехов (розділ 1.5)
	12.05.2017 р.	
Ст. викладач	_____	Л.Д. Назаренко (розділ 1.1)
	12.05.2017 р.	
Аспірант	_____	М. В. Бібик (розділ 1.10)
	12.05.2017 р.	

Аспірант	Д.В. Прилепа (розділ 1.6)
	12.05.2017 р.
Канд. фіз.-мат. наук, доцент	С.П. Шаповалов (розділ 3.1)
	12.05.2017 р.
Канд. техн. наук, ст. викладач	Т.В. Лаврик (розділ 1.2)
	12.05.2017 р.
Канд. економ. наук, ст.викладач	Т.О. Маринич (розділ 3.3)
	12.05.2017 р.
Канд. техн. наук, ст. викладач	В.В. Москаленко (розділ 2.4)
	12.05.2017 р.
Канд. техн. наук, асистент	А.С. Москаленко (розділ 1.3)
	12.05.2017 р.
Асистент	М.С. Руденко (розділ 1.4)
	12.05.2017 р.
Аспірант	В.І. Зимовець (розділ 1.7)
	12.05.2017 р.
Аспірант	Ю.В. Симоновський (розділ 1.8)
	12.05.2017 р.
Аспірант	А.С. Осадчий (розділ 4.2)
	12.05.2017 р.
Аспірант	Є. С. Кулік (розділ 4.3)
	12.05.2017 р.
Аспірант	З. В. Козлов(розділ 4.3)
	12.05.2017 р.
Аспірант	С. О. Пилипенко (розділ 4.4)
	12.05.2017 р.
Асистент	Н.А. Андрієнко (розділ 4.5)
	12.05.2017 р.
Аспірант	А.Г. Коробов (розділ 2.6)
	12.05.2017 р.

РЕФЕРАТ

Звіт: 383 с., 50 рисунків, 3 таблиці, 218 джерел.

МАТЕМАТИЧНА МОДЕЛЬ, ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ, МАШИННЕ НАВЧАННЯ, РОЗПІХНАВАННЯ ОБРАЗІВ, ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ, ІНФОКОМУНІУАЦІЙНА СИСТЕМА, ФУНКЦІОНАЛЬНЕ ДІАГНОСТУВАННЯ, ПСИХОДІАГНОСТУВАННЯ, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ, ІНФОРМАЦІЙНИЙ КРИТЕРІЙ, ІДЕНТИФІКАЦІЯ КАДРІВ, ДИСТАНЦІЙНЕ НАВЧАННЯ, СИСТЕМА КЕРУВАННЯ, ШИФРУВАННЯ, МЕРЕЖЕВА БЕЗПЕКА, ОЦІНКА ЯКОСТІ НАВЧАЛЬНОГО ПРОЦЕСУ

Мета роботи – розроблення методів, моделей та інформаційних технологій підвищення функціональної ефективності систем підтримки прийняття рішень в освіті та промисловості.

Об’єкт дослідження – слабо формалізовані процеси прийняття рішень в освіті та промисловості.

Предмет дослідження – методи, моделі та інформаційні технології прийняття рішень в освіті та промисловості, оцінка функціональної ефективності інтелектуальних систем аналізу даних, методи захисту інформації в інфокомунікаційних системах, інформаційно-аналітичні системи в освіті.

На основі аналітичного огляду та аналізу тенденції розвитку інтелектуальних систем аналізу даних створено основи інформаційного аналізу та синтезу системи підтримки прийняття рішень, які функціонують в режимах машинного навчання, кластер-аналізу, факторного кластер-аналізу і прогнозування. Отримала подальший розвиток інформаційно-екстремальна інтелектуальна технологія аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи в процесі її машинного навчання. Розроблено методи та математичні моделі аналізу і керування слабо формалізованими процесами в промисловості та освіті.

ЗМІСТ

ВСТУП.....	8
1 ІНТЕЛЕКТУАЛЬНИЙ АНАЛІЗ ДАНИХ.....	9
1.1 ОПЕРАТИВНИЙ КОНТРОЛЬ КВАЗІСТАЦІОНАРНИХ ДИНАМІЧНИХ ОБ'ЄКТІВ ЗА ДОПОМОГОЮ ФУНКЦІЙ НЕПРОПОРЦІОНАЛЬНОСТЕЙ.....	9
1.2 РОЗПІЗНАВАННЯ ЗОБРАЖЕНЬ НА ОСНОВІ ДВОВИМІРНОГО ВЕЙВЛЕТ- АНАЛІЗУ.....	21
1.3 ІНТЕЛЕКТУАЛЬНА СИСТЕМА ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ РАДІОНУКЛІДНОЇ ДІАГНОСТИКИ В КАРДІОЛОГІЇ.....	26
1.4 ІДЕНТИФІКАЦІЯ КАДРІВ В ЗАДАЧАХ РОЗПІЗНАВАННЯ ЗОБРАЖЕНЬ МЕДИЧНИХ І БІОЛОГІЧНИХ ОБ'ЄКТІВ.....	38
1.5 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИЙ АЛГОРИТМ НАВЧАННЯ СИСТЕМИ ДІАГНОСТУВАННЯ ЕМОЦІЙНО-ПСИХІЧНОГО СТАНУ ЛЮДИНИ.....	52
1.6 ОПТИМІЗАЦІЯ ПАРАМЕТРІВ НАВЧАННЯ КОМП'ЮТЕРИЗОВАНОЇ СИСТЕМИ ДІАГНОСТУВАННЯ ЕМОЦІЙНО-ПСИХІЧНОГО СТАНУ ЛЮДИНИ.....	65
1.7 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ МАШИННЕ НАВЧАННЯ СИСТЕМИ ФУНКЦІОНАЛЬНОГО ДІАГНОСТУВАННЯ З ІЄРАРХІЧНОЮ СТРУКТУРОЮ ДАНИХ.....	75
1.8 БОРТОВА ГЕОІНФОРМАЦІЙНА СИСТЕМА ІДЕНТИФІКАЦІЇ КАДРІВ.....	98
1.9 ОЦІНКА ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ, ЩО НАВЧАЄТЬСЯ.....	107
1.10 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ МАШИННЕ НАВЧАННЯ СИСТЕМИ КЕРУВАННЯ ЕНЕРГОБЛОКОМ ТЕПЛОЕЛЕКТРОЦЕНТРАЛІ.....	117
2 КОМП'ЮТЕРНІ НАУКИ.....	136
2.1 ШИФРУВАННЯ ДАНИХ ПРИ ПЕРЕДАЧІ В КАНАЛІ ЗВ'ЯЗКУ НА ПРИКЛАДІ GRE-ТУНЕЛЮ.....	136
2.2 МЕРЕЖЕВА БЕЗПЕКА НА ОСНОВІ ПРОТОКОЛІВ IPSEC І SSL VPN.....	162
2.3 ОРГАНІЗАЦІЯ ШИФРУВАННЯ ДАНИХ ПРИ ПЕРЕДАЧІ В КАНАЛІ ЗВ'ЯЗКУ НА ПРИКЛАДІ GRE-ТУНЕЛЮ В СИМУЛЯТОРІ GNS3.....	163
2.4 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИЙ МЕТОД ІДЕНТИФІКАЦІЇ.....	164

ТИПУ МЕРЕЖЕВОГО ТРАФІКА.....	164
2.5 ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ФУНКЦІОНУВАННЯ СИСТЕМИ КЕРУВАННЯ ІТ-ІНФРАСТРУКТУРОЮ ДАТАЦЕНТРУ.....	209
2.6 АВТОНОМНА БОРТОВА СИСТЕМА ДЕТЕКТУВАННЯ ОБ'ЄКТІВ НА МІСЦЕВОСТІ.....	235
3 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ СКЛАДНИХ СИСТЕМ.....	239
3.1 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ВЛАСТИВОСТЕЙ ПКМ, НАПОВНЕНОГО КОРОТКО-ВОЛОКНИСТИМИ ВКЛЮЧЕННЯМИ ТА ДИСПЕРСНИМИ ЧАСТИНКАМИ СФЕРИЧНОЇ ФОРМИ.....	239
3.2 ІНЖЕКЦІЙНА СПЕКТРОСКОПІЯ ГЛИБОКИХ ПАСТОК У ПЛІВКАХ НАНОСТРУКТУРОВАНОГО СУЛЬФІДУ КАДМІЮ.....	270
3.3 КОМПАРАТИВНИЙ АНАЛІЗ МЕТОДІВ МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ НЕСТАБІЛЬНИХ ЧАСОВИХ РЯДІВ КОРОТКОЇ ВИБІРКИ.....	280
3.4 МАГНІТООПТИЧНІ ВЛАСТИВОСТІ ПЛІВКОВИХ МАТЕРІАЛІВ НА ОСНОВІ FE I GE ЯК ЧУТЛИВИХ СЕНСОРНИХ ЕЛЕМЕНТІВ.....	295
4. ЕЛЕКТРОННІ ТЕХНОЛОГІЇ В ОСВІТІ.....	297
4.1 ПІДХОДИ ДО ОЦІНКИ ЕФЕКТИВНОСТІ АДАПТИВНОЇ СИСТЕМИ ДИСТАНЦІЙНОГО НАВЧАННЯ.....	297
4.2 ІНФОРМАЦІЙНИЙ СИНТЕЗ ІНФОРМАЦІЙНО-АНАЛІТИЧНОЇ СИСТЕМИ ОЦІНКИ ЯКОСТІ НАВЧАЛЬНОГО КОНТЕНТУ.....	307
4.3 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ НАВЧАННЯ СИСТЕМИ ОЦІНКИ ЯКОСТІ НАВЧАЛЬНОГО КОНТЕНТУ ВИПУСКОВОЇ КАФЕДРИ.....	319
4.4 ОЦІНКА ІНФОРМАТИВНОСТІ ОЗНАК РОЗПІЗНАВАННЯ УНІМОДАЛЬНОГО КЛАСИФІКАТОРУ.....	333
4.5 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИЙ АЛГОРИТМ НАВЧАННЯ ІНФОРМАЦІЙНО-АНАЛІТИЧНОЇ СИСТЕМИ ОЦІНКИ ЯКОСТІ НАВЧАЛЬНОГО КОНТЕНТУ.....	345
ВИСНОВКИ.....	356
ПЕРЕЛІК ПОСИЛАНЬ.....	359

ПЕРЕЛІК УМОВНИХ СКОРОЧЕНЬ

- ІЕІ-технологія – інформаційно-екстремальна інтелектуальна технологія;
- СППР – система підтримки прийняття рішень;
- КФЕ – критерій функціональної ефективності;
- АЦП – аналого-цифровий перетворювач;
- БПОІ – блок первинної обробки інформації;
- БФВР – блок формування векторів розпізнавання;
- БРА – блок розвідувального аналізу;
- ВП – виконавчий пристрій;
- ІЕІ – технологія – інформаційно-екстремальна інтелектуальна технологія;
- М – мультиплексор;
- МК – мікроконтролер;
- НТР – науково-технічна розробка;
- ОК – об'єкт керування;
- ОПР – особа, що приймає рішення;
- СКД – система контрольних допусків;
- СППР – система підтримки прийняття рішень;

ВСТУП

НДР виконувалася в рамках створених на кафедрі комп'ютерних наук Сумського державного університету наукових шкіл, основними напрямками яких є:

- інформаційний синтез інтелектуальних систем аналізу даних на основі машинного навчання та розпізнавання образів;
- математичне моделювання слабо формалізованих процесів в різних галузях промисловості та освіти.

Науковий звіт складається із чотирьох розділів.

В першому розділі наведено результати наукових досліджень, спрямованих на подальший розвиток так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології), яка ґрунтується на максимізації інформаційної спроможності системи керування в процесі машинного навчання. Основна перевага методів, створених в рамках ІЕІ-технології, полягає в тому, що вирішальні правила, побудовані в процесі машинного навчання за оптимальними геометричними параметрами контейнерів класів розпізнавання, характеризуються на відміну від відомих методів Data Mining інваріантністю до багатовимірності простору ознак розпізнавання.

Другий розділ присвячено розробленню інформаційних технологій обробленню, передачі та захисту інформації в інфокомунікаційних системах.

В третьому розділі розробленню інформаційне, алгоритмічне та програмне забезпечення систем керування слабо формалізованими процесами в різних галузях промисловості та освіти.

Четвертий розділ присвячено створенню інформаційних технологій електронного навчання.

Результати наукових досліджень, одержаних виконавцями проекту, опубліковано в працях згідно до розділів.

1 ІНТЕЛЕКТУАЛЬНИЙ АНАЛІЗ ДАНИХ

1.1 ОПЕРАТИВНИЙ КОНТРОЛЬ КВАЗІСТАЦІОНАРНИХ ДИНАМІЧНИХ ОБ'ЄКТІВ ЗА ДОПОМОГОЮ ФУНКЦІЙ НЕПРОПОРЦІОНАЛЬНОСТЕЙ

Оперативний контроль динамічних об'єктів дозволяє вирішувати такі задачі, як прогнозування значень вихідних процесів, визначення параметрів адаптивної системи керування цим об'єктом й ін. Для цього доцільно визначати диференціальне рівняння, що описує об'єкт у сучасний момент часу. При цьому часто ставиться умова мінімізації поточного інтервалу часу, необхідного для одержання цього рівняння.

Ще однією задачею оперативного контролю є розпізнавання поточного стану об'єкта. Діагностуємий об'єкти звичайно піддаються впливам, що викликають зміни їх статичних і динамічних характеристик. У результаті можуть змінюватися значення коефіцієнтів диференціального рівняння, що описує об'єкт. Можуть також виникати й такі стани об'єкта, коли змінюється порядок диференціального рівняння. Крім того, раніше лінійний об'єкт може стати нелінійним, а в нелінійному об'єкті можуть змінюватися параметри нелінійності. Так, наприклад, якщо діагностуємий об'єкт є системою автоматичного регулювання, те зазначені вище стани виникають при обривах у ланцюгах зворотних зв'язків або в коригувальних ланках, з появою зони нечутливості в характеристиці датчика, при виникненні люфту у виконавчому механізмі й ін. Виявлення таких подій є важливою практичною задачею. Для її рішення необхідно створити систему контролю, що була б інваріантною щодо значень коефіцієнтів при доданках у диференціальному рівнянні, що описує контрольований об'єкт.

Оперативний контроль динамічних об'єктів також потрібно для визначення інтервалів часу, на яких в об'єкті відбуваються перехідні процеси. За умовою об'єкт квазістаціонарний, однак, можуть відбуватися події, що приводять до швидкої зміни параметрів об'єкта від одних постійних значень до іншим

також постійним. Виявлення перехідних процесів необхідно при ідентифікації об'єкта в процесі його нормальної роботи.

ПОСТАНОВКА ЗАДАЧІ

Розглядається квазістаціонарний об'єкт із одним вхідним й одним вихідним процесами, описуваними функціями відповідно $x(t)$ й $y(t)$ часу t . Ці функції безперервні й гладкі й для них існують похідні, необхідні для рішення задачі. Об'єкт описується звичайним лінійним або нелінійним диференціальним рівнянням, у правій частині якого перебувати тільки $x(t)$.

Коефіцієнти рівняння за час рішення задачі вважаються постійними.

Відома оцінка зверху порядку диференціального рівняння.

Для нелінійних об'єктів апріорно відомі характеристики нелінійних елементів й які функції вони перетворюють.

Контрольований об'єкт працює в умовах, коли можна зневажити впливом перешкод на вихідний сигнал.

Потрібно по відомим у сучасний момент часу t значенням функцій $x(t)$, $y(t)$ і їхніх похідних різного порядку вирішити одну з наступних задач.

1. Одержати диференціальне рівняння, що описує контрольований об'єкт у момент часу t .
2. Визначити, чи має місце в сучасний момент часу зміна стану об'єкта в порівнянні з вихідним.

Конкретно можуть змінитися коефіцієнти диференціального рівняння, його порядок, характеристики нелінійних елементів.

В об'єкті можуть відбуватися перехідні процеси.

Ці задачі можна вирішити за допомогою запропонованих в [1, 2] функцій непропорциональностей. Існують функції непропорциональностей по похідних, за значеннями й відносні непропорційності. Передбачається використати непропорційності по похідних.

Для функції $y = f(x)$ непропорційність по похідній **n-го** порядку має вигляд

$$\textcircled{d} d_x^{(n)} y = \frac{y}{x^n} - \frac{1}{n!} \frac{d^n y}{dx^n} . \quad (1)$$

Тут символ « \textcircled{d} » позначає операцію обчислення непропорційності.

Символ «**d**» (від англ. derivative) – означає, що непропорційність по похідній. У дужках зазначений порядок похідної – **n**. Ліва частина (1) читається як «ет d n y по x ». Ця непропорційність рівняється нулю, якщо $f(x)$ описується вираженням

$$y = kx^n \quad (2)$$

незалежно від значення k .

Тут k - постійний коефіцієнт, n - ціле число більше нуля.

Конкретно буде використатися непропорційність по похідній 1-го порядку для функцій, заданих параметрически. Для $x(t)$ й $y(t)$ непропорційність по похідній 1-го порядку $y(t)$ по $x(t)$ має вигляд:

$$\textcircled{d} d_{x(t)}^{(1)} y(t) = \frac{y(t)}{x(t)} - \frac{dy/dt}{dx/dt} \quad (3)$$

Якщо в момент часу t залежність між $x(t)$ і $y(t)$ пропорційна

$$y(t) = kx(t), \quad (4)$$

те непропорційність (3) рівняється нулю незалежно від значення постійного множника k в (4).

Для оперативного визначення диференціального рівняння по поточної $x(t)$, $y(t)$ і їхнім похідним пропонується використати розроблений в [1.3] алгоритм. Він призначений для аналізу сигналу, що представляє собою суму деяких еталонних функцій із заданої множини. Алгоритм дозволяє розпізнати які функції утворять розпізнаваний сигнал, з якими ваговими коефіцієнтами й з якими тимчасовими зрушеннями.

Вхідну функцію $x(t)$ в правій частині диференціального рівняння можна розглядати як розпізнаваний сигнал, а його ліву частину – як суму еталонних функцій з невідомими ваговими коефіцієнтами. За умовою $x(t)$, $y(t)$ і їхні похідні відомі. Тобто фактично є відомими значення еталонних функцій. Необхідно довідатися які з них, і з якими коефіцієнтами входять у суму, що утворить вхідну функцію $x(t)$.

АЛГОРИТМ ВИЗНАЧЕННЯ ДИФЕРЕНЦІАЛЬНОГО РІВНЯННЯ.

Спочатку необхідно задати еталонні функції $f_i(t)$, де $i = 1, 2, \dots, n+1$. Тут n - апріорно задана межа порядку диференціального рівняння. Для лінійного об'єкта.

$$\begin{aligned} f_1(t) &= y(t), \\ f_2(t) &= y'(t), \\ f_3(t) &= y''(t), \\ &\dots \\ f_{n+1}(t) &= y^n(t). \end{aligned} \tag{5}$$

Також позначимо

$$f_0(t) = x(t). \tag{6}$$

Для нелінійного об'єкта за умовою відомі характеристики нелінійних елементів (НЭ) і які функції вони перетворюють. У цьому випадку для завдання еталонів треба отримані в момент часу t функції перетворити відповідно до заданих характеристик нелінійностей. Так, наприклад, якщо $y(t)$ піддається нелінійному перетворення $F_1[y(t)]$, те відповідна еталонна функція $f_1(t)$ повинна мати вигляд

$$f_1(t) = F_1[y(t)] \tag{7}$$

Інші еталонні функції визначаються як і для лінійного об'єкта.

З урахуванням позначень (5-7) шукане диференціальне рівняння запишемо у вигляді

$$\sum_{i=1}^{n+1} k_i f_i(t) = f_0(t) \quad (8)$$

де k_i - невідомі коефіцієнти. Потрібно довідатися які еталонні функції із множини $\{f_1, f_2, \dots, f_{n+1}\}$ входять в (8) і з якими коефіцієнтами з обліком того, що порядок рівняння невідомий.

Задача вирішується поетапно.

Перший етап. Припускаємо, що

$$f_0(t) = k_i f_i(t), \quad (9)$$

де $i = 1, 2, \dots, n+1$.

Перебираючи значення i від 1 до $n+1$, обчислюємо непропорційність (1.3) функції $f_0(t)$ по $f_i(t)$. Позначимо її через $F_{0i}(t)$.

$$F_{0i}(t) = @ d_{f_i(t)}^{(1)} f_0(t) = \frac{f_0(t)}{f_i(t)} - \frac{f_0'}{f_i'}. \quad (10)$$

Перевіряємо умову

$$F_{0i}(t) = 0. \quad (11)$$

Якщо воно виконується, виходить, диференціальне рівняння має вигляд (9). У нього входить лише одна еталонна функція $f_i(t)$ з ваговим коефіцієнтом

$$k_i = \frac{f_0(t)}{f_i(t)} \quad (12)$$

Якщо для жодної еталонної функції умова (11) не виконується, варто перейти до другого етапу.

Другий етап. Припускаємо, що $f_0(t)$ є сумою, варіанти якої можна розглядати як сполучення по двох еталона з $n+1$. Припустимо, що це $f_i(t)$ й $f_j(t)$. Тоді

$$f_0(t) = k_i f_i(t) + k_j f_j(t), \quad (13)$$

де k_i, k_j - невідомі коефіцієнти. Для $f_0(t)$ у вигляді (13) непропорційність (3) $f_0(t)$ по $f_i(t)$ має вигляд

$$\begin{aligned} F_{0i}(t) &= @d_{f_i(t)}^{(1)} f_0(t) = \frac{k_i f_i(t) + k_j f_j(t)}{f_i(t)} - \frac{\frac{d}{dt}[k_i f_i(t) + k_j f_j(t)]}{\frac{d}{dt}[f_i(t)]} = \\ &= k_j \left[\frac{f_j}{f_i} - \frac{f_j'}{f_i'} \right] = k_j @d_{f_i(t)}^{(1)} f_j(t) \end{aligned} \quad (14)$$

Позначимо

$$F_{ji}(t) = @d_{f_i(t)}^{(1)} f_j(t) \quad (15)$$

Тоді згідно (15) вираження (14) має вигляд

$$F_{0i}(t) = k_j F_{ji}(t) \quad (16)$$

Вираження (16) відбиває пропорційну залежність між $F_{0i}(t)$ й $F_{ji}(t)$ у момент часу t з невідомим коефіцієнтом пропорційності k_j .

Позначимо через $F_{0iji}(t)$ непропорційність (3) функції $F_{0i}(t)$ по $F_{ji}(t)$ й обчислимо неї.

$$F_{0iji}(t) = \frac{F_{0i}(t)}{F_{ji}(t)} - \frac{\frac{d}{dt}[F_{0i}(t)]}{\frac{d}{dt}[F_{ji}(t)]} \quad (17)$$

Перевіряємо умову

$$F_{0iji}(t) = 0. \quad (18)$$

Якщо для сполучення i -é й j -é еталонних функцій умова (18) виконується, виходить, $F_{0i}(t)$ має вигляд (13). Вхідні в нього коефіцієнти обчислюються по формулах

$$k_j = \frac{F_{0i}(t)}{F_{ji}(t)}, \quad (19)$$

$$k_i = \frac{f_0(t) - k_j f_j(t)}{f_i(t)}. \quad (20)$$

Якщо умова (18) не виконується ні для одного зі сполучень по двох з $n+1$ еталонних функцій, варто перейти до третього етапу.

Третій етап. Припускаємо, що $f_0(t)$ є сумою, варіанти якої можна розглядати як сполучення по трьох з $n+1$ еталонних функцій. Нехай розглядається сполучення з $f_i(t)$, $f_j(t)$ і $f_q(t)$. Тоді

$$f_0(t) = k_i f_i(t) + k_j f_j(t) + k_q f_q(t). \quad (21)$$

Для $f_0(t)$ (21) обчислимо її непропорційність (3) по одній із цих трьох еталонних функцій, наприклад, по $f_i(t)$.

$$F_{0i}(t) = @ d_{f_i(t)}^{(1)} f_0(t) = k_j @ d_{f_i(t)}^{(1)} f_j(t) + k_q @ d_{f_i(t)}^{(1)} f_q(t). \quad (22)$$

З урахуванням позначень (15) перепишемо (22)

$$F_{0i}(t) = k_j F_{ji} + k_q F_{qi}. \quad (23)$$

Позначимо через $F_{0iji}(t)$ і $F_{qiji}(t)$ відповідно непропорційності (3) функції $F_{0i}(t)$ по $F_{ji}(t)$ й функції $F_{qi}(t)$ по $F_{ji}(t)$.

Тоді

$$F_{0iji}(t) = @ d_{F_{ji}(t)}^{(1)} F_{0i}(t) = k_q @ d_{F_{ji}(t)}^{(1)} F_{qi}(t) = k_q F_{qiji}(t). \quad (24)$$

Вираження (24) відбиває пропорційну залежність між $F_{0iji}(t)$ й $F_{qiji}(t)$ у момент часу t з невідомим коефіцієнтом пропорційності k_q .

Обчислимо непропорційність (3) функції $F_{0iji}(t)$ по $F_{qiji}(t)$. Позначимо її через $F_{0ijiqij}(t)$.

$$F_{0ijiqij}(t) = \frac{F_{0iji}(t)}{F_{qiji}(t)} - \frac{\frac{d}{dt}[F_{0iji}(t)]}{\frac{d}{dt}[F_{qiji}(t)]}. \quad (25)$$

Перевіряємо умову

$$F_{0ijiqij}(t) = 0. \quad (26)$$

Якщо для $f_i(t)$, $f_j(t)$ і $f_q(t)$ умова (26) дотримується, значить $f_0(t)$ має вигляд (21). Коефіцієнти k_q , k_j і k_i обчислюються по формулах

$$k_q = \frac{F_{0ijiqij}(t)}{F_{qij}(t)}, \quad (27)$$

$$k_j = \frac{F_{0i}(t) - k_q F_{qj}(t)}{F_{ji}(t)}, \quad (28)$$

$$k_i = \frac{f_0(t) - k_j f_j(t) - k_q f_q(t)}{f_i(t)}. \quad (29)$$

Якщо умова (1.26) не виконується ні для одного зі сполучень по трьох з $n+1$ еталонів, варто перейти до сполучення по чотирьох з $n+1$ і т.д.

Так виглядає алгоритм визначення диференціального рівняння, що описує об'єкт у сучасний момент часу.

У випадку, якщо навіть для сполучення, що включає $n+1$ еталонів, не підтверджується, що $f_0(t)$ має вигляд (18), варто перевірити наступні припущення.

1. Порядок диференціального рівняння вище, ніж задана межа зверху n .
2. В об'єкті виникла нелінійність.
3. У нелінійного об'єкта змінилися характеристики нелінійних елементів.
4. В об'єкті відбувається перехідний процес.

ОПЕРАТИВНИЙ КОНТРОЛЬ СТАНУ ОБ'ЄКТА.

Отримане диференціальне рівняння дозволяє здійснити оперативний контроль об'єкта, у тому числі оцінювати його поточний стан.

Так регулярне визначення коефіцієнтів рівняння дозволяє кількісно оцінити динаміку зміни параметрів об'єкта.

По зміні виду диференціального рівняння або його порядку можна визначити факт появи подій, що приводять до структурних перетворень в об'єкті.

При відносно швидкому в порівнянні із вхідним процесом зміні параметрів об'єкта від одних постійних значень до інших має місце перехідний процес. Його можна виявити по тому, що непропорційність, що при оперативному визначенні диференціального рівняння звичайно дорівнює нулю, перестає бути нульовий, поки відбувається перехідний процес. Звичайно відома оцінка зверху тривалості перехідних процесів. Якщо через цей час контрольована непропорційність не стає нульовий, виходить, має місце яке-небудь із подій, перерахованих у пунктах 1-3.

Розглянемо приклади, що ілюструють застосування пропонованого алгоритму. Спочатку розглянемо приклад, що дозволяє уникнути громіздких виразів при аналітичному визначенні непропорційностей, використовуваних для одержання диференціального рівняння.

Нехай об'єкт описується нелінійним диференціальним рівнянням.

$$y' + y^2 = \cos(t) + \sin^2(t)$$

Рішенням такого рівняння є

$$y = \sin(t) + C_0.$$

При $y(0) = 0$ $C_0 = 0$.

За умовою контролюються поточні значення вхідного й вихідного процесів й їхніх похідних. Також відомо, що $y(t)$ піддається нелінійному перетворенню, а саме зводиться у квадрат.

Тут вхідний процес:

$$f_0(t) = \cos(t) + \sin^2(t).$$

Еталонні функції:

$$f_1(t) = y^2 = \sin^2(t),$$

$$f_2(t) = y' = \cos(t).$$

Знаходимо

$$\begin{aligned} F_{01}(t) &= @ d_{f_1(t)}^{(1)} f_0(t) = \frac{\cos(t) + \sin^2(t)}{\sin^2(t)} - \frac{-\sin(t) + 2\sin(t)\cos(t)}{2\sin(t)\cos(t)} = \\ &= \frac{\cos(t)}{\sin^2(t)} + \frac{1}{2\cos(t)}, \end{aligned}$$

$$\begin{aligned} F_{21}(t) &= @ d_{f_1(t)}^{(1)} f_2(t) = \frac{\cos(t)}{\sin^2(t)} - \frac{-\sin(t)}{2\sin(t)\cos(t)} = \\ &= \frac{\cos(t)}{\sin^2(t)} + \frac{1}{2\cos(t)}. \end{aligned}$$

Очевидно, що $F_{0121}(t) = @ d_{F_{21}(t)}^{(1)} F_{01}(t) = 0$.

Таким чином, підтверджується припущення, що

$$f_0(t) = k_1 f_1(t) + k_2 f_2(t),$$

де відповідно до (19) і (20)

$$k_1 = \frac{F_{01}(t)}{F_{21}(t)} = 1,$$

$$k_2 = \frac{f_0(t) - k_1 f_1(t)}{f_2(t)} = 1.$$

У наступних прикладах контролюється об'єкт, описуваний диференціальним рівнянням.

$$y'' - 3y' + 2y = 2\sin(t).$$

Похідні обчислюються за допомогою чисельних методів по формулі Ньютона-Стирлінга з використанням різностей сьомого порядку [4]. Рівняння вирішується методом Рунге-Кутта четвертого порядку. Початкові умови - нульові.

Тут $f_0(t) = 2\sin(t)$, $f_1(t) = y(t)$, $f_2(t) = y'(t)$, $f_3(t) = y''(t)$.

Таким чином, передбачається, що $f_0(t) = k_1 f_1(t) + k_2 f_2(t) + k_3 f_3(t)$. У цьому випадку повинна бути рівної або близької до нуля непропорційність (25). І тільки у випадку виникнення перехідного процесу або зміни виду диференціального рівняння ця непропорційність ставати ненульовою.

Так, наприклад, на малюнку 1 наведена залежність непропорційності (1.25) від часу t при наявності перехідного процесу на інтервалі від 0,1 до 0,2. У цей час коефіцієнт k_1 при $y(t)$ змінюється від 2 до 4 відповідно до формули

$$k_1 = 2 + 20 * dt$$

Де $dt = 0,001$ - час одного відліку.

Видно, як непропорційність (25) відхилилася від нуля під час перехідного процесу й знову повернулася до нуля після його закінчення.




Рисунок 1.1 – Непропорційність $F_{01213121}(t)$

На малюнку 1.2 приводиться приклад обчислення непропорційності (25) для випадку, коли об'єкт описується нелінійним диференціальним рівнянням

$$y'' - 3y' + 2y^{0.5} = 2 \sin(t).$$

Тут $f_0(t) = 2 \sin(t)$, $f_1(t) = y^{0.5}(t)$, $f_2(t) = y'(t)$, $f_3(t) = y''(t)$.

У момент часу $t = 0.1$ виникає зміна параметрів нелінійності. У результаті диференціальне рівняння описується вираженням.

$$y'' - 3y' + 2y^{0.6} = 2 \sin(t).$$

Однак, про ці зміни невідомо й у процесі контролю еталонна функція $f_1(t)$ як і раніше береться рівної $y^{0.5}(t)$, як це було задано апріорно. У результаті непропорційність (25) відхилилася від нуля й більше до нього не поверталася у відмінності від попереднього прикладу.




Рисунок 1.2 – Непропорційність $F_{01213121}(t)$.

Наведені приклади свідчать про те, що при наявності необхідних похідних для вхідного й вихідного процесів і відсутності впливу перешкод запропонований алгоритм може бути використаний для оперативного контролю динамічних об'єктів. У випадку використання аналогових диференціальних пристроїв й аналогових процесорів для обчислення непропорційностей можна реалізувати практично миттєве визначення диференціального рівняння, що описує реальний стан об'єкта.

У випадку застосування комп'ютерної техніки час, необхідне для одержання поточного диференціального рівняння визначається вимогами чисельних методів для обчислення похідних із заданою точністю.

1.2 РОЗПІЗНАВАННЯ ЗОБРАЖЕНЬ НА ОСНОВІ ДВОВИМІРНОГО ВЕЙВЛЕТ-АНАЛІЗУ

Методи розпізнавання зображень, у яких ознаками є яскравості окремих пікселів, часто не враховують взаємне розташування цих пікселів. У результаті двовимірна задача вирішується власне кажучи як одновимірна.

Те ж саме можна сказати і про більшість нейромережових методів, зокрема про широко використовуваний метод зворотного поширення помилки в багатосаровій нейронній мережі. Двовимірний характер зображення враховується, наприклад, у згорткових нейронних мережах, що містять згорткові шари, у яких фрагменти вхідного зображення, узяті з деяким зрушенням, перетворюються в пікселі наступного шару [1]. Однак така мережа досить складна в реалізації.

Методи, засновані на Фур'є-аналізі, не одержали великого поширення, тому що якість розпізнавання у значній мірі залежить від масштабу й орієнтації розпізнаваного об'єкта на зображенні.

Більш перспективним виявився метод, заснований на використанні вейвлетів Габора [2,3]. За рахунок обнуління постійної складової метод вейвлетів Габора стійкий до зміни яскравості зображення. Розходження в контрастності зображень можуть бути легко усунуті нормалізацією. Нарешті, вейвлети характеризують зображення в локальній області навколо точки, а не тільки в самій точці.

Аналіз літературних джерел показує, що більшість робіт по вейвлетах Габора пов'язана з розпізнаванням зображень осіб. Відповідно в теорію вводяться додаткові поняття і процедури: еластичні графи, високоенергетичні точки, локалізація овалу особи. При цьому практично не приводяться подробиці програмної реалізації.

Метою даної роботи є розробка алгоритму і програми розпізнавання зображень на основі двовимірного вейвлет-аналізу. При цьому алгоритм повинен бути загальним і не орієнтованим на конкретний клас зображень.

Обсяг обчислень і витрати оперативної пам'яті повинні бути мінімально необхідними для забезпечення високої якості розпізнавання. Програма повинна ґрунтуватися на некомерційному програмному забезпеченні.

РЕАЛІЗАЦІЯ МЕТОДУ ВЕЙВЛЕТІВ

Двовимірний вейвлет Габора має форму плоскої хвилі, обмеженої по амплітуді функцією Гауса. Кожен вейвлет ψ_j із заданого набору вейвлетів визначається своїм хвильовим вектором k_j [3]:

$$\psi_j(\vec{r}) = \frac{k_j^2}{\sigma^2} \exp\left(-\frac{k_j^2 r^2}{2\sigma^2}\right) \left[\exp(i\vec{k}_j \vec{r}) - \exp\left(-\frac{\sigma^2}{2}\right) \right], \quad (1.2.1)$$

де $\vec{r} = \vec{r}(x, y)$. Вектор k_j визначимо для п'яти різних частот, індекс $p = 0, \dots, 4$, і восьми різних орієнтацій, індекс $q = 0, \dots, 7$:

$$\begin{aligned} \vec{k}_j &= (k_{jx}, k_{jy}) = (k_p \cos \varphi_q, k_p \sin \varphi_q); \\ k_p &= 2^{-\frac{p+2}{2}} \pi; \quad \varphi_q = q \frac{\pi}{8}; \quad j = q + 8p. \end{aligned}$$

Нехай зображення задане масивом $I(\vec{r})$ яскравостей пікселів у точках $\vec{r}(x, y)$. Вейвлет-перетворення зображення можна представити як згортку $R_j(\vec{r}_0)$ зображення з j -м вейвлетом з набору вейвлетів Габора:

$$R_j(\vec{r}_0) = \int I(\vec{r}) \psi_j(\vec{r} - \vec{r}_0) dx dy. \quad (2)$$

За аналогією з іншими роботами величини R_j будемо називати коефіцієнтами відгуку фільтрів Габора.

Вектор ознак розпізнавання для зображення будемо будувати зі значень R_j у вузлах ґратки із кроком 8 пікселів по горизонталі і вертикалі. Такий крок цілком прийнятний для зображень з довжиною сторони порядку ста пікселів.

Для введення метрики умовимося вважати відстань між сусідніми пікселями рівною одиниці. Тоді, якщо ми виберемо значення $\sigma = 2\pi$, то для вейвлета з індексом $p=2$ стандартне відхилення функції Гауса $\sigma/k_p=8$, що дорівнює відстані до наступної точки ґратки. Відповідно, при $p=0$ відхилення буде в два рази менше, а при $p=4$ – у два рази більше.

Безпосереднє обчислення згортки

$$R(\vec{r}) = I(\vec{r}) * \psi(\vec{r}) \quad (3)$$

досить трудомістке. Застосуємо до обох частин дискретне перетворення Фур'є F , у результаті операція згортки перетвориться в множення спектрів

$$F[R(\vec{r})] = F[I(\vec{r})] F[\psi(\vec{r})] . \quad (4)$$

Виконуючи зворотне перетворення Фур'є, одержимо

$$R(\vec{r}) = F^{-1} \{ F[I(\vec{r})] F[\psi(\vec{r})] \} . \quad (5)$$

Дискретне перетворення Фур'є для двовимірного випадку має вигляд

$$f_{k_x k_y} = \sum_{n_x=0}^{N_x-1} \sum_{n_y=0}^{N_y-1} x_{n_x n_y} \exp\left(-\frac{2\pi i}{N_x} k_x n_x\right) \exp\left(-\frac{2\pi i}{N_y} k_y n_y\right) .$$

Для його виконання зручно використовувати алгоритм швидкого перетворення Фур'є (БПФ).

Обробку графічних зображень будемо проводити за допомогою некомерційної бібліотеки OpenCV. У її склад входить функція `cvDFT`, що реалізує алгоритм прямого і зворотного БПФ у тому числі і для двовірних вхідних даних. Особливістю БПФ є зведення задачі для N чисел до задачі для $N_1 = N/m$, де m – дільник числа N . У реалізації `cvDFT` оптимальний розмір сторони зображення являє собою добуток цілих ступенів чисел 2, 3 і 5. Відповідно для економії пам'яті доцільно заздалегідь задати розмір сторони зображення рівним такому добуткові.

Для зменшення обчислювальної складності обмежимося тільки дійсною (парною) компонентою вейвлета Габора. У цьому випадку обсяг вхідних даних зменшується в два рази, а для комплексних вихідних даних використовується спеціальний упакований формат, що також дозволяє в два рази зменшити обсяг вихідних даних.

Приклад декомпозиції зображення можна бачити на рис. 1.3. Ліворуч дано вихідне зображення, у центрі показані зображення декількох вейвлетів Габора: зліва направо для значень $q=0,2,4$, зверху вниз – для значень $p=0,2,4$. Значення сигналу тут приведені до діапазону яскравості малюнка. Праворуч

показано результати декомпозиції вихідного зображення по цих вейвлетах у вигляді амплітуди відгуку вейвлетів на зображення.




Рисунок 1.3 – Результати декомпозиції зображення: а) - вхідне зображення; б) - вейвлети Габора; в) - амплітуди відгуку вейвлетів

ПРОГРАМА І РЕЗУЛЬТАТИ ТЕСТУВАННЯ

Відповідно до описаного алгоритму розроблена програма розпізнавання чорно-білих графічних зображень. Програма написана мовою C++ для середовища Visual Studio 2008. Комп'ютерна обробка зображень виконується за допомогою додаткової бібліотеки OpenCV v2.0, скомпільованої для Visual Studio.

На першому етапі роботи програми створюється банк із 40 вейвлетів Габора для п'яти різних частот і восьми орієнтацій. Їхні приклади показані на мал. 1б.

На другому етапі відповідно до вхідного списку файлів вводяться графічні зображення, для кожного з яких за результатами декомпозиції будується вектор ознак. Припустимими форматами для зображень є `pgm`, `bmp`, `dib`, `png`, `tif`, `jpg`, `jreg`. Для уніфікації процесу побудови вектора ознак вхідне зображення масштабується до стандартного розміру.

На третьому етапі виконується розпізнавання зображень. Вхідними даними тут є навчальний і тестовий набори зображень. У даній реалізації програми використано найпростіший метод розпізнавання – метод найближчих сусідів.

Для тестування програми була взята база даних ORL [4], що містить по 10 фотографій осіб у форматі `pgm` для 40 чоловік у відповідних каталогах від `s1` до `s40`.

У першому тесті навчальний набір складався з зображень з номерами 1 – 5 у каталогах `s1` – `s5`, а тестовий – із зображень з номерами 6 – 10 у тих же каталогах. Тестування показало, що всі зображення з тестового набору правильно віднесені до відповідних класів.

Тестування для 10 класів розпізнавання, для якого були узяті ті ж номери зображень, але вже для каталогів `s1` – `s10`, показало наступний результат (табл.1.1). Кожен запис у таблиці представлений у форматі “ім'я тестового зображення – ім'я зображення з навчальної вибірки, найближчого до тестового в просторі ознак”.

Таблиця 1.1 –Результати тестування

s1/6	–	s3/6	–	s5/6	–	s7/6	–	s9/6	–	s9/4
s1/4		s3/1		s5/5		s7/3				
s1/7	–	s3/7	–	s5/7	–	s7/7	–	s9/7	–	s3/4
s1/1		s3/5		s5/4		s7/3				
s1/8	–	s3/8	–	s5/8	–	s7/8	–	s9/8	–	s9/4
s1/1		s3/4		s5/2		s7/1				
s1/9	–	s3/9	–	s5/9	–	s7/9	–	s9/9	–	s9/4
s1/1		s3/1		s5/5		s7/1				
s1/10–		s3/10–		s5/10–		s7/10–		s9/10	–	
s1/5		s3/3		s5/5		s7/4		s9/2		
s2/6	–	s4/6	–	s6/6	–	s8/6	–	s10/6	–	
s2/2		s4/3		s6/2		s8/5		s10/2		
s2/7	–	s4/7	–	s6/7	–	s8/7	–	s10/7	–	
s2/3		s4/4		s6/5		s8/2		s10/3		
s2/8	–	s4/8	–	s6/8	–	s8/8	–	s10/8	–	
s2/3		s4/3		s6/1		s8/5		s10/2		
s2/9	–	s4/9	–	s6/9	–	s8/9	–	s10/9	–	
s2/4		s4/2		s6/4		s8/1		s10/5		
s2/10–		s4/10–		s6/10–		s8/10–		s10/10–		
s2/3		s4/5		s6/4		s8/3		s10/2		

Таким чином з 50 тестових зображень тільки s9/7 було неправильно віднесене до класу s3. Це підтверджує високу ефективність розробленої програми.

Проте, якість розпізнавання можна підвищити за рахунок непарної компоненти вейвлетів Габора, введення еталонних векторів для класів розпізнавання, спеціальної локалізації вейвлетів для конкретного класу розпізнаваних зображень.

ВИСНОВКИ

1 Запропонований алгоритм побудови вектора ознак розпізнавання, заснований на використанні вейвлетів Габора і не зв'язаний з конкретним типом розпізнаваних об'єктів.

2 Розроблена програма розпізнавання двомірних зображень, яка не потребує попереднього масштабування зображення і допускає використання різних типів графічних файлів.

3 Тестування програми на зразках з ORL-бази зображень осіб показало високу ефективність її роботи навіть при використанні тільки парної компоненти вейвлетів Габора і при використанні найпростішого з методів розпізнавання – методу найближчих сусідів.

1.3 ІНТЕЛЕКТУАЛЬНА СИСТЕМА ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ РАДІОНУКЛІДНОЇ ДІАГНОСТИКИ В КАРДІОЛОГІЇ

Є численні методи обстеження хворих з серцево-судинними захворюваннями.

Унікальне місце займає сцинтиграфія міокарда, яка дозволяє виявити порушення перфузії міокарда на ранній стадії захворювання, оцінити тяжкість патологічного процесу у хворих, які перенесли інфаркт міокарда, і визначити траєкторію лікування хворого.

У зазначених хворих з інфарктом результатом сцинти-графічного

дослідження є реконструйовані зрізи серця, полярна діаграма та 3D зображення. При цьому найбільш інформативною з точки зору візуального та кількісного аналізу є полярна карта, що розділяє міокард на 17 або 20 сегментів і дозволяє оцінити долю включення радіофармпрепарату в кожен з них [1,2]. Однак достовірність інтерпретації даних радіонуклідного дослідження визначається як рівнем професійної кваліфікації лікаря-діагноста, так і наявністю в нього практичного досвіду, оскільки виявлення невеликих відхилень від норми потребує врахування індивідуальних анатомо-фізіологічних і вікових мінливостей органів пацієнтів, особливостей наявного апаратно-програмного інструментарію та контекстних даних, до яких належать симптоми, наявність шкідливих звичок та хронічних хвороб [2,3].

Одним з напрямів зниження навантаження на лікаря-діагноста та підвищення точності діагностичних висновків є розробка та впровадження систем підтримки прийняття рішень (СППР), які здійснюють машинну інтерпретацію результатів радіонуклідного обстеження. Однак в задачах проектування систем підтримки прийняття рішень для оцінки порушень перфузії міокарда за даними радіонуклідної діагностики на основі відомих методів аналізу даних, таких як алгоритм найближчих сусідів, нейронні мережі та дерева рішень загальна точність діагностичних висновків не перевищує 81,3% [4-6]. Основними причинами такого стану є ігнорування контекстних даних та перетину класів розпізнавання в просторі ознак. Тому підвищення точності систем підтримки прийняття рішень для радіонуклідної діагностики в кардіології є актуальною задачею.

Оригінальна матриця зображення полярної карти містить 1088 пікселів, що ускладнює попиксельний процес розпізнавання патологічних функціональних станів [1-3]. Тому для спрощення інтерпретації полярних карт у працях [5,6] розглядається використання позначень перфузії окремих ділянок міокарда або в процентах від нормальної активності, або за 5-ти бальними шкалами оцінки порушень перфузії. У працях [6,7] розглядається використання різноманітних методів редукції даних сцинтиграфії міокарда, серед яких

набули поширення посегментне усереднення яскравості, розклад зображення на компоненти просторових частот за допомогою перетворення Фур'є. При цьому діагностичний висновок формується лікарем-діагностом на основі простих правил або автоматично шляхом розпізнавання класифікатором, синтезованим на основі методів машинного навчання. Однак використання простих правил інтерпретації зображень та перелічених методів редукції призводить до штучного огрублення результатів дослідження та втрати інформативних ознак, що обумовлює зниження точності діагностичних висновків.

Одним із перспективних підходів до аналізу та синтезу систем медичної діагностики є застосування ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технологія), яка дозволяє адаптувати вхідний математичний опис діагностичного класифікатора до умов та способу формування спостережень в процесі максимізації його інформаційної спроможності [7-9]. Однак в рамках ІЕІ-технології можна використовувати різні схеми кодування як кількісних, так і категоріальних ознак, від вибору якої залежить ефективність машинного навчання.

В даній роботі в рамках ІЕІ-технології пропонується використовувати для кодування ознак розпізнавання багаторівневу систему контрольних допусків на їх значення і дослідити вплив параметрів функціонування інформаційно-екстремальної діагностичної СППР на функціональну ефективність її машинного навчання за вибірками сцинтиграм міокарда та контекстних ознак.

Розглянемо формалізовану постановку задачі інформаційного синтезу здатної навчатися діагностичної системи радіонуклідного обстеження. Дано алфавіт класів розпізнавання $\{X_m^o \mid m = \overline{1, M}\}$, що характеризують M функціональних станів міокарду. Сформовано апріорно класифіковану навчальну матрицю типу «об'єкт-властивість» $\|y_i^{(j)} \mid i = \overline{1, N}, j = \overline{1, n_m}\|$, де N, n_m – кількість ознак розпізнавання та реалізацій образу відповідно. При цьому

$$N = N_1 + N_2,$$

де N_1 – кількість кількісних ознак розпізнавання, що характеризують яскравість пікселів діагностичного зображення радіонуклідного дослідження;

N_2 – кількість категоріальних ознак розпізнавання, що відповідають контекстним даним, до яких належать симптоми, наявність шкідливих звичок, хронічних хвороб та інше.

Крім того дано структурований вектор параметрів функціонування діагностичної системи, який у загальному випадку в рамках ІЕІ-технології має структуру

$$g = \langle \delta_{1,i}, d_m \rangle \quad (1)$$

де $\delta_{1,i}$ – параметр поля контрольних допусків 1-го рівня на значення i -ї ознаки розпізнавання; d_m – радіус гіперсферичного контейнера класу x_m^o , що будується в процесі навчання в радіальному базисі бінарного простору ознак Ω_B .

При цьому відомі обмеження на відповідні параметри функціонування: $d_m \in [1; d(x_m \oplus x_c) - 1]$, де $d(x_m \oplus x_c)$ – кодова відстань від еталонного вектора x_m класу x_m^o до еталонного вектора x_c сусіднього класу $x_c^o \in \{X_m^o\}$; $\delta_i \in [0; 100]$.

Необхідно в процесі машинного навчання діагностичної системи знайти оптимальні значення координат вектору параметрів g^* , що забезпечують максимальне значення усередненого за алфавітом класів розпізнавання інформаційного критерію функціональної ефективності (КФЕ)

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{\{k\}} E_m, \quad (2)$$

де E_m – інформаційний КФЕ навчання діагностичної системи розпізнавати реалізації класу x_m^o ;

$\{k\}$ – множина кроків машинного навчання.

У робочому режимі діагностичної системи необхідно визначити належність вектора-реалізації, що розпізнається, до одного з класів алфавіту $\{X_m^o\}$, сформованого на етапі машинного навчання.

Алгоритм функціонування діагностичної системи

Основна ідея ІЕІ-технології полягає в зміні значень ознак в субпарацептуальному просторі шляхом допустимих перетворень. Одним із таких перетворень є двійкове кодування кількісних ознак розпізнавання шляхом порівняння їх значень з відповідними контрольними допусками. При цьому наявність категоріальних ознак розпізнавання потребує додаткових перетворень з метою їх приведення до форми, яка має прямий зв'язок з імовірнісними характеристиками ознак і дозволяє порівнювати їх значення з контрольними допусками. Як було показано в працях [9], частотне перекодування та Димму-кодування категоріальних ознак дозволяють виконати перетворення, що задовольняє вказаним вимогам.

В рамках ІЕІ-технології розробка структури вирішальних правил основана на гіпотезі про наявність базового класу розпізнавання $X_B^0 \in \{X_m^0\}$, відносно якого всі інші образи розглядаються як відхилення певного рівня та напрямку. При цьому з метою врахування частоти появи категоріальних ознак в базовому класі контур оптимізації повинен включати оператор їх частотного перекодування. У найпростішому випадку перекодування навчальної матриці полягає у заміні номінальних значень категоріальних ознак вхідної навчальної матриці відповідними частотами їх появи в базовому класі.

Інформаційно-екстремальне машинне навчання, основане на адаптивному грубому кодуванні ознак розпізнавання шляхом порівняння значення i -ї ознаки з відповідними нижнім $A_{H,l,i}$ та верхнім $A_{B,l,i}$ порогами l -го рівня, які розраховуються за формулами

$$A_{H,l,i} = \overline{y_{l,i}} \left[1 - \frac{\delta_i}{\delta_{\max}} \right]^l, \quad A_{B,l,i} = \overline{y_{l,i}} \left[1 - \frac{\delta_i}{\delta_{\max}} \right]^l,$$

де $\overline{y_{B,i}}$ – середнє вибіркоче значення ознаки в базовому класі X_1^0 .

Двійкове подання ознак розпізнавання з трирівневою системою контрольних допусків в рамках ІЕІ-технології здійснюється за правилами:

$$x_{m,3^*i-2}^{(j)} = \begin{cases} 1, & \text{якщо } A_{H,3,i} \leq y_{m,i}^{(j)} \leq A_{B,1}; \\ 0, & \text{інакше} \end{cases}$$

$$x_{m,3^*i-1}^{(j)} = \begin{cases} 1, & \text{якщо } A_{H,2,i} \leq y_{m,i}^{(j)} \leq A_{B,2,i}; \\ 0, & \text{інакше} \end{cases}$$

$$x_{m,3^*i}^{(j)} = \begin{cases} 1, & \text{якщо } A_{H,1,i} \leq y_{m,i}^{(j)} \leq A_{B,3,i}; \\ 0, & \text{інакше} \end{cases}$$

де $y_{m,i}^{(j)}$ – числове значення i -ї ознаки в j -й реалізації m -го класу розпізнавання.

При цьому ітераційна процедура оптимізації параметра полів контрольних допусків на ознаки розпізнавання здійснювалася шляхом максимізації в процесі навчання СППР усередненого за алфавітом класів розпізнавання інформаційного критерію (2)

$$\{\delta_i^* | i = \overline{1,n}\} = \arg \max_{G_\delta} \left\{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \right\}, \quad (3)$$

де $\bar{E}^{(k)}$ – усереднене значення інформаційного КФЄ, обчислене на k -му кроці машинного навчання;

G_δ – область допустимих значень параметра поля контрольних допусків на значення ознак розпізнавання;

$\{k\}$ – множина кроків навчання.

Для оптимізації вектора $\{\delta_i | i = \overline{1,n}\}$ запропоновано використовувати алгоритм рою частинок (particle swarm optimization), який характеризується простотою реалізації та високою оперативністю знаходження глобального максимуму усередненого критерію (2) [8]. Розглянемо основні кроки реалізації алгоритму рою частинок.

1. Ініціалізація рою:

1) ініціалізація кількості частинок;

2) ініціалізація розмірності кожної частинки N та ініціалізація меж зміни i -ї координати j -ї частинки $\delta_{j,i}$;

3) ініціалізація початкових позицій частинок

$$P_j[0] := 100 \cdot U(0,1),$$

де $U(0,1)$ – генератор випадкових чисел з діапазону $(0,1)$;

4) ініціалізація початкових швидкостей частинок $V_j(0) := 0$;

5) ініціалізація максимальної швидкості частинок в $V_{\max,i}$;

6) ініціалізація вагових коефіцієнтів для формули швидкості, тобто ваги інерції w та констант прискорення c_1 і c_2 .

2. Інкремент номера ітерації: $k := k + 1$.

3. Інкремент номера частинки: $j := j + 1$.

4. Інкремент номера координати в позиції: $i := i + 1$.

5. Розрахунок нового стану частинки:

1) розрахунок i -ї компоненти швидкості для j -ї частинки за правилами

$$V_{j,i}[k+1] := wV_{j,i}[k] + c_1a_{1,i}[k] * (Pbest_{j,i}[k] - P_{j,i}[k]) + c_2a_{2,i}[k] * (Gbest_j - P_{j,i}[k]);$$

$$V_{j,i}[k+1] := \begin{cases} V_{j,i}[k+1] & \text{if } V_{j,i}[k+1] < V_{\max,i}, \\ V_{\max,i} & \text{if else,} \end{cases}$$

де $a_1[k] = U(0,1)$, $a_2[k] = U(0,1)$;

2) оновлення позиції частинки

$$P_j[k+1] := P_j[k] + V_j[k+1];$$

3) перевірка перетину меж простору, і зміна швидкості у випадку перетину за правилом

$$V_{j,i}[k+1] := V_{j,i}[k+1] \cdot \alpha,$$

де α – параметр типу межі простору ($\alpha = 0$ – поглинаюча межа; $\alpha = 1$ – прозора;

$$\alpha = -1 \text{ – відзеркалююча; } \alpha = -U(0,1) \text{ – демпфуюча);}$$

4) обчислення цільової функції $J_j[k+1]$;

5) оновлення значень найкращої персональної $Pbest$ та глобальної $Gbest$ позицій

$$Pbest_{j,i}[k+1] := \begin{cases} Pbest_{j,i}[k], & \text{if } J(P_j[k+1]) \leq J(Pbest_{j,i}[k]); \\ P_j[k+1], & \text{if else;} \end{cases} \quad Gbest[k+1] := \arg \max_j \{J(Pbest_{j,i}[k+1])\}.$$

6. Перевірка умови зупини: якщо $k < 1000$ & $J(Gbest[k+1]) < 1,0$, то перехід до кроку

2, інакше до кроку 7.

7. ЗУПИН.

Як інформаційний КФЕ машинного навчання діагностичної СППР запропоновано використовувати модифіковану в праці [9] нормовану міру

С. Кульбака, робоча формула якої має вигляд

$$J_m^{(k)} = \frac{K_{1,m}^{(k)} - K_{2,m}^{(k)}}{n_m (\log(2n_m + 10^{-\omega}) + \omega)} * \log \left(\frac{10^{-\omega} + n_m + [K_{1,m}^{(k)} - K_{2,m}^{(k)}]}{10^{-\omega} + n_m - [K_{1,m}^{(k)} - K_{2,m}^{(k)}]} \right) \quad (4)$$

де $K_{1,m}^{(k)}$ – кількість подій, що характеризують належність реалізацій класу X_m^o до контейнера класу X_m^o на k -му кроці машинного навчання;

$K_{2,m}^{(k)}$ – кількість подій, що характеризують належність реалізацій класу X_c^o до контейнера класу X_m^o .

Значення КФЕ, розраховане за формулою (4) лежить в діапазоні дійсних чисел $[0;1]$. При цьому від параметра ω залежить тільки чутливість КФЕ до зміни точнісних характеристик. Значення параметра ω , як правило, обирають в діапазоні $[3;9]$.

Допустима область визначення функції інформаційного КФЕ обмежена нерівностями $K_1 \geq 0,5 \cdot n_m$ і $K_2 < 0,5 \cdot n_m$.

У базовому алгоритмі ІЕІ-технології близькість класів визначається кодовою відстанню між їх двійковими еталонними (усередненими) векторами, однак це призводить до ігнорування дисперсії векторів-реалізацій (діаметру нечітких множин). Тому для обґрунтування вибору найближчого сусіднього класу слід використовувати оптимізаційну процедуру

$$E_m^* = \min_{c \neq m} \{E_{m,c}^*\},$$

де $E_{m,c}^*$ – значення критерію при оптимальну радіусі гіперсферичного контейнера класу X_m^o за умови, що клас X_c^o обрано як сусідній.

Визначення належності вхідної реалізації $x^{(t)}$ до класу X_m^o за максимумом значення функції належності, яка має такий вигляд

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

де $d(x_m^* \oplus x^{(t)})$ – кодова відстань між еталонним вектором x_m^* та вектором-реалізацією $x^{(t)}$;

d_m^* – оптимальний в інформаційному сенсі радіус контейнера класу x_m^0 .

Таким чином, алгоритм машинного навчання діагностичної СППР в рамках ІЕІ-технології полягає в адаптивному кодуванні різнотипних ознак розпізнавання при використанні багаторівневої, у загальному випадку, системи контрольних допусків та оптимізації радіусів контейнерів класів в процесі пошуку глобального максимуму функції КФЕ в робочій області багатовимірного простору рішень.

Результати фізичного моделювання

Запропонований алгоритм машинного навчання діагностичної системи був використаний для синтезу класифікатора функціонального стану міокарда за вибіркою сцинтиграм в стані спокою і навантаження (стресу) та категоріальних контекстних ознак. Алфавіт класів розпізнавання з потужністю $M=4$ характеризує перфузію міокарда: x_1^0 – норма; x_2^0 – тиха ішемія; x_3^0 – гостра ішемія; x_4^0 – рубці на серці. На рис.1.4 показано приклади полярних карт перфузії міокарда для різних класів функціонального стану. При цьому матриця зображення полярної карти має формат 17×64 пікселів, тому $N_1 = 17 * 64 * 2 = 2176$. Кількість категоріальних ознак становить $N_2 = 10$. Обсяг вибірки для кожного класу становить $n_m = 100$. В таблиці 1.2 показано результати інформаційно-екстремального навчання при різних кількостях рівнів контрольних допусків L .

Результати машинного навчання при різній кількості рівнів вкладеності контрольних допусків на значення ознак

Таблиця 1.2– Результати інформаційно-екстремального навчання

	Значення максимуму усередненого КФЕ		
	L=1	L=2	L=3
Кількісні ознаки	0,51	0,75	0,81
Кількісні та контекстні категоріальні ознаки	0,57	0,78	1,00

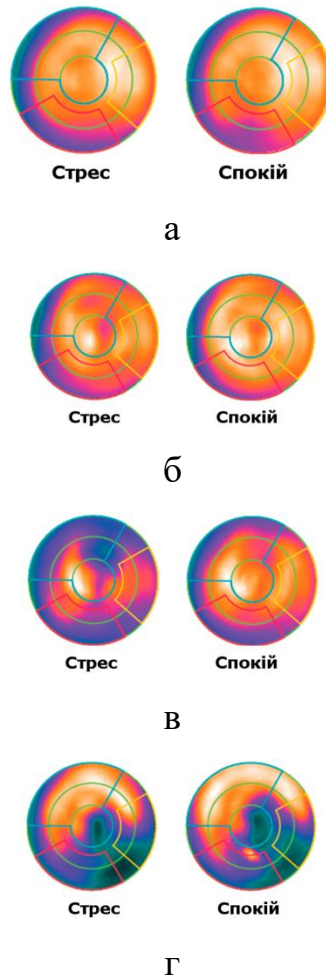


Рис. 1.4 –Полярні карти перфузії міокарда для різних класів функціонального стану: а – норма; б – тиха ішемія; в – гостра ішемія; г – рубці на серці

Аналіз табл. показує, що як збільшення рівнів вкладених контрольних допусків, так і додавання контекстних ознак дозволяє отримати більші значення усередненого КФЕ (4) за однакову кількість ітерацій оптимізації параметрів функціонування СППР. При цьому використання категоріальних контекстних ознак та трирівневої системи вкладених контрольних допусків на значення як кількісних, так і перекодованих категоріальних ознак дозволяє досягнути граничного значення функції КФЕ. Графік зміни максимумів КФЕ в процесі ройової оптимізації параметру поля контрольних допусків показано на рис.1.5. Лічильник кроків k відповідає кількості міграцій агентів рою.




Рис. 1.5 Графік зміни максимумів усередненого КФЕ в процесі оптимізації вектора $\{\delta_i \mid i = \overline{1, n}\}$

Аналіз рис.1.6 показує, що протягом 1200 ітерацій ройового алгоритму пошуку знайдено глобальний оптимум функції КФЕ. На рис. 3 показано графіки залежності критерію (4) від радіусів контейнерів класів розпізнавання, отримані в процесі оптимізації геометричних параметрів розбиття простору ознак. Сірим кольором позначено допустиму область визначення функції КФЕ.




Рис.1.6– Графіки залежності значення КФЕ від радіусу контейнерів: а – клас x_1^0 ; б – клас x_2^0 ; в – клас x_3^0 ; г – клас x_4^0

Аналіз рис. 3 показує, що оптимальні значення радіусу контейнерів класів x_1^o , x_2^o , x_3^o та x_4^o відповідно рівні $d_1^* = 370$, $d_2^* = 249$, $d_3^* = 187$ та $d_4^* = 253$.

Таким чином, запропонований алгоритм машинного навчання дозволяє здійснювати синтез безпомилкових вирішальних правил за навчальною матрицею з різнотипними ознаками розпізнавання, які описують функціональний стан перфузії міокарда.

Висновки

В рамках інформаційно-екстремальної технології синтезовано вирішальні правила з багаторівневою системою вкладених контрольних допусків на значення ознак розпізнавання. При цьому для обробки різнотипних ознак розпізнавання запропоновано використовувати частотне перекодування категоріальних ознак. За результатами фізичного моделювання з використанням даних сцинтиграфії міокарда та контекстних даних, що характеризують симптоми, наявність хронічних хвороб та шкідливих звичок підтверджено можливість побудови безпомилкових за навчальною вибіркою вирішальних правил.

1.4 ІДЕНТИФІКАЦІЯ КАДРІВ В ЗАДАЧАХ РОЗПІЗНАВАННЯ ЗОБРАЖЕНЬ МЕДИЧНИХ І БІОЛОГІЧНИХ ОБ'ЄКТІВ

Розпізнавання морфологічних зображень тканин, отриманих за методом біопсії, при діагностуванні онкопатологій на практиці здійснюється за довільних початкових умов формування зображень, що обумовлює апріорну невизначеність. Тому основним шляхом підвищення функціональної ефективності комп'ютеризованої системи діагностування (КСД), яка виконує функції системи підтримки прийняття рішень (СППР) для лікаря-онколога, є надання їй властивості адаптивності на основі машинного навчання та розпізнавання образів [1,2]. Більшість відомих методів розпізнавання

носять модельний характер, оскільки вони не враховують перетин класів розпізнавання, що має місце в практичних задачах діагностування [3,4]. У цих випадках виникає необхідність попередньої нормалізації образів з метою їх наближення до еталонних. Одним із перспективних напрямів аналізу і синтезу КСД, що функціонують за умов апріорної невизначеності, є використання ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технологія), яка ґрунтується на максимізації одержаної в процесі навчання системи розпізнавання кількості інформації шляхом введення додаткових інформаційних обмежень [5,6]. У праці [7] запропоновано інформаційно-екстремальний алгоритм навчання КСД онкологічних захворювань молочної залози, але авторам не вдалося побудувати безпомилкові за навчальною матрицею вирішальні правила через суттєвий вплив фону зображень на достовірність розпізнавання. Це пояснюється тим, що на рецепторному полі зображень існують однакові для всіх захворювань фонові ділянки, які вносять додаткові завади в навчальну матрицю.

З метою підвищення функціональної ефективності КСД у статті задача розпізнавання морфологічних зображень тканин пацієнтів з онкологічними захворюваннями розглядається як задача ідентифікації кадрів загального зображення, розв'язок якої дозволяє безпосередньо виявляти локалізації конгломератів онкологічних клітин.

1. Постановка задачі

Нехай задано алфавіт класів розпізнавання $\{X_m^o \mid m=1, M\}$, елементи якого характеризують різні патології молочної залози. Існує розбиття рецепторного поля зображення на K кадрів певного розміру і для кожного k -го кадру сформовано навчальну матрицю яскравості $\|y_{k,i}^{(j)} \mid i=1, \overline{N}; j=1, \overline{n}\|$, де N, n – кількість ознак розпізнавання і векторів-реалізацій образу відповідно. Для кожного класу X_m^o , які приймаються за еталони, сформовано навчальні матриці яскравості аналогічної розмірності.

Необхідно в процесі ідентифікації k -го кадру рецепторного поля, який характеризується класом X_k^o , побудувати вирішальні правила шляхом відновлення у радіальному базисі простору ознак контейнерів для кожної пари «кадр – еталон» і обчислити критерій схожості.

$$C_{k,m} = 1 - E_{k,m}^*, \quad (1)$$

де $E_{k,m}^*$ – глобальний максимум нормованого інформаційного критерію функціональної ефективності (КФЕ) системи діагностування, що обчислюється в робочій допустимій області визначення його функції.

Необхідно за максимальним значенням критерію схожості (1) прийняти рішення про належність ідентифікованого кадру відповідному класу із заданого алфавіту $\{X_m^o\}$.

2. Математична модель

Вхідний математичний опис системи компараторного розпізнавання кадрів подамо у вигляді структури

$$\Delta = \langle G \times T \times \Omega \times Z \times K, Y^{[2]}, X^{[2]}; \Phi_1, \Phi_2 \rangle,$$

де G – множина вхідних сигналів (факторів), які впливають на КСД; T – множина моментів часу зняття інформації; Ω – простір ознак розпізнавання; Z – простір можливих функціональних станів КСД; K – множина кадрів для ідентифікації; $Y^{[2]}$ – навчальна матриця для двох класів; $X^{[2]}$ – бінарна навчальна матриця; $\Phi_1 : G \times T \times \Omega \times Z \rightarrow Y^{[2]}$ – оператор формування вхідної навчальної матриці; $\Phi_2 : Y^{[2]} \rightarrow X^{[2]}$ – оператор формування бінарної навчальної матриці $X^{[2]}$.

Розглянемо категорійну модель розпізнавання образів у рамках ІЕІ-технології, показану на рис. 1.7. Оператор $\theta : X^{[2]} \rightarrow \mathfrak{R}^{[2]}$ будує розбиття простору ознак на два класи розпізнавання, яке є апріорно нечітким. Оператор класифікації ψ перевіряє основну статистичну гіпотезу про належність

реалізацій $\{x_m^{(j)} \mid j = \overline{1, n}\}$ класу X_m^o . Оператор $\gamma: I^{|l|} \rightarrow \mathfrak{S}^{|q|}$ шляхом оцінки статистичних

гіпотез формує множину точнісних характеристик, де l – кількість статистичних гіпотез; $q = l^2$ – кількість точнісних характеристик. Оператор ϕ формує терм-множину E , яка складається із значень інформаційного критерію функціональної ефективності (КФЕ). Контур оптимізації геометричних параметрів розбиття $\mathfrak{R}^{|2|}$ замикається оператором d , а контур оптимізації системи контрольних допусків (СКД), яка утворює множину D , замикається послідовно оператором $\delta_1: E \rightarrow D$ і оператором $\delta_2: D \rightarrow Y$, який змінює реалізації образу в процесі навчання. Оператор $U: E \rightarrow G \times T \times \Omega \times Z \times K$ – регламентує процес навчання КСД.

Подання слабо формалізованого процесу навчання КСД у вигляді категорійної моделі суттєво спрощує розроблення структурної схеми алгоритму навчання.




Рис. 1.7 – Категорійна модель навчання системи

3. Алгоритм ідентифікації кадрів

Згідно з постановкою задачі алгоритм ідентифікації кадрів полягає в обчисленні для кожного поточного кадру критерію схожості (1) з відповідними еталонами із алфавіту $\{X_m^o\}$. Обчислення максимального значення інформаційного КФЕ $E_{k,m}^*$ здійснюється в процесі інформаційно-екстремального навчання КСД за ітераційною двоциклічною процедурою

$$E_{k,m}^* = \max_{G_\delta} \max_{G_E \cap G_d} E_{k,m}, \quad (2)$$

де $E_{k,m}$ – значення КФЕ навчання системи розпізнавати реалізації поточного k -го кадру і m -го еталону, що обчислюється в робочій допустимій області визначення його функції; G_δ, G_E, G_d – області допустимих значень параметра δ поля контрольних допусків, значень КФЕ і радіусів гіперсферичних контейнерів класів компараторного розпізнавання, що відновлюються в радіальному базисі простору ознак Ω відповідно.

Таким чином зовнішній цикл оптимізує параметр δ поля контрольних допусків, за допомогою якого обчислюються нижні $A_{H,k}$ і верхні $A_{B,k}$ контрольні допуски

$$A_{H,k} = y_k - \delta; \quad A_{B,k} + \delta, \quad (3)$$

де y_k – еталонний (усереднений) вектор-реалізація навчальної матриці $Y^{[2]}$ для k -го кадру.

З метою підвищення оперативності алгоритму навчання розглянемо паралельну оптимізацію СКД на ознаки розпізнавання, за якою контрольні допуски на кожному кроці навчання змінюються за формулою (3) для всіх ознак одночасно.

Структурна схема алгоритму паралельної оптимізації СКД на ознаки розпізнавання показано на рис.1.8. Вхідними даними є масив навчальних вибірок $Y[kl][realization][j]$, де kl – номер навчальної матриці класу розпізнавання, *realization* – номер реалізації в навчальній матриці і j – номер ознаки розпізнавання в реалізації образу. Розглянемо коротко призначення функціональних блоків у структурній схемі алгоритму навчання КСД з паралельною оптимізацією СКД на ознаки розпізнавання:

Блок 3. Занулюється значення тимчасової змінної e_optim_sred , яка використовується для прямого пошуку глобального максимуму усередненого значення КФЕ ідентифікації кадрів.

Блок 4. Ініціалізується лічильник циклу параметра δ (*delta*) поля контрольних допусків.

Блок 5. Формуються на кожному кроці навчання за формулою (3) масиви поточних верхніх та нижніх контрольних допусків на ознаки розпізнавання.

Блок 6. Виконується базовий інформаційно-екстремальний алгоритм навчання [5], який реалізує внутрішній цикл процедури (2).

Функціями базового інформаційно-екстремального алгоритму навчання системи розпізнавання для ідентифікації кадрів є:

- обчислення на кожному кроці ідентифікації кадрів інформаційного КФЕ;
- пошук глобального максимуму КФЕ в робочій (допустимій) області визначення його функції.

Оскільки критерій $E_{k,m}^*$ є функціоналом від точнісних характеристик ідентифікації кадрів, то за робочу приймається область визначення його функції, в якій ймовірності правильних рішень перебільшують відповідні ймовірності помилкових рішень, що складають однакові групи подій.

Як КФЕ навчання при компаративному розпізнаванні можна використовувати будь-яку статистичну інформаційну характеристику, що є мірою різноманітності двох класів розпізнавання. Наприклад, при двох альтернативних рішеннях і рівно ймовірних гіпотезах модифікація нормованого ентропійного критерію (за Шенноном) [6] при компаративному розпізнаванні буде мати вигляд

$$\begin{aligned}
 E_{k,m} = 1 + & \\
 & + \frac{1}{2} \left(\frac{\alpha_{k,m}(d_k)}{\alpha_{k,m}(d_k) + D_{2k,m}(d_k)} \log_2 \frac{\alpha_{k,m}(d_k)}{\alpha_{k,m}(d_k) + D_{2k,m}(d_k)} + \right. \\
 & + \frac{D_{1k,m}(d_k)}{D_{1k,m}(d_k) + \beta_{k,m}(d_k)} \log_2 \frac{D_{1k,m}(d_k)}{D_{1k,m}(d_k) + \beta_{k,m}(d_k)} + \\
 & + \frac{\beta_{k,m}(d_k)}{D_{1k,m} + \beta_{k,m}(d_k)} \log_2 \frac{\beta_{k,m}(d_k)}{D_{1k,m} + \beta_{k,m}(d_k)} + \\
 & \left. \frac{D_{2k,m}(d_k)}{\alpha_{k,m}(d_k) + D_{2k,m}(d_k)} \log_2 \frac{D_{2k,m}(d_k)}{\alpha_{k,m}(d_k) + D_{2k,m}(d_k)} \right), \tag{4}
 \end{aligned}$$

де $\alpha_{k,m}(d_k)$, $\beta_{k,m}(d_k)$, $D_{1k,m}(d_k)$, $D_{2k,m}(d_k)$ – значення точнісних характеристик, отриманих в процесі ідентифікації k -го кадру з m -м еталоном: помилки першого і другого родів, перша і друга достовірності відповідно; d_k – радіус гіперсферичного класифікатора, що відновлюється на кожному кроці ідентифікації в радіальному просторі ознак розпізнавання.

Блоки 7, 8. В масиві E_optim виконується безпосередній пошук оптимального параметра поля контрольних допусків ($delta$) для ознак розпізнавання, шляхом пошуку максимального усередненого значення КФЕ, отриманого в блоках 5,6, який знаходиться в робочій області для двох класів розпізнавання.

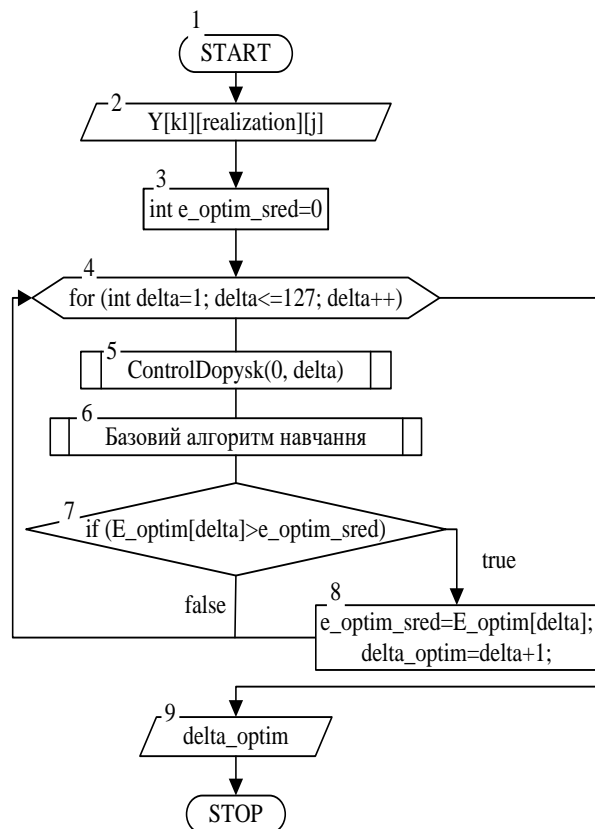


Рис. 1.8– Структурна схема алгоритму ідентифікації кадрів з оптимізацією СКД

Після проведення навчання обчислюється критерій схожості (1) між кадром та еталоном зображення і приймається рішення про належність ідентифікованого кадру m -му еталону. Чим вищий критерій схожості тим

вище достовірність правильного діагностування захворювання, оскільки значення інформаційного КФЕ, який є мірою різноманітності стає досить малим, що свідчить про відсутність суттєвих відмінностей між кадром, що ідентифікується, і еталонним зображенням.

4. Результати фізичного моделювання

Реалізацію вищенаведеного алгоритму ідентифікації кадрів розглянемо на прикладі розпізнавання морфологічних зображень тканин пацієнтів, одержаних за методом біопсії. Зображення формуються за допомогою вбудованого в мікроскоп цифрового фотоапарата, з'єданого з ЕОМ, і відображається на екрані монітора.

Як еталонні розглядалися зображення трьох онкологічних захворювань молочної залози (мастопатія, рак і фіброаденома) розміром 200×200 пікселів. При цьому загальне зображення тканини пацієнта розміром 1280×1024 , яка мала конгломерати онкологічних клітин, розбивалося на кадри, що ідентифікувалися, розмір яких дорівнював еталонним зображенням.

Ідентифікація кадрів здійснювалася за вищенаведеним алгоритмом, концепцію якого схематично показано на рис. 1.9. Тут прийнято такі позначення: *М* – мастопатія; *Р* – рак молочної залози; *Ф* – фіброаденома і *К* – кадр, що ідентифікується.

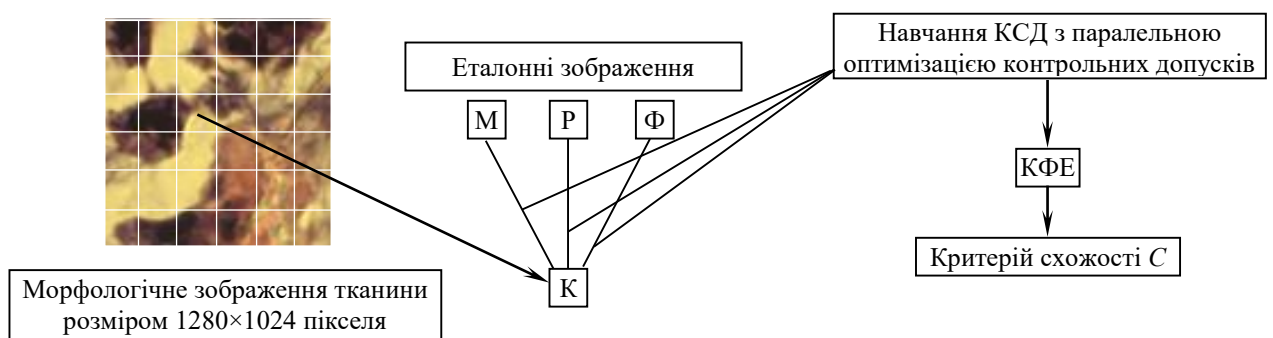


Рис. 1.9– Процес ідентифікації кадрів

На рис.1.10 наведенні приклади трьох еталонних зображень онкологічних захворювань відібраних експертом.




*a**б**в*

Рис. 1.10– Еталонні зображення трьох онкологічних захворювань розміром 200×200 (*a* – мастопатія, *б* – рак, *в* – фіброаденома)

Результати реалізації базового алгоритму ідентифікації 11-го кадру загального зображення показано на рис. 1.11, де наведено графіки залежності критеріїв оптимізації від радіусу d_{11} контейнера зображення кадру, який послідовно відновлюється в процесі ідентифікації з трьома еталонами.

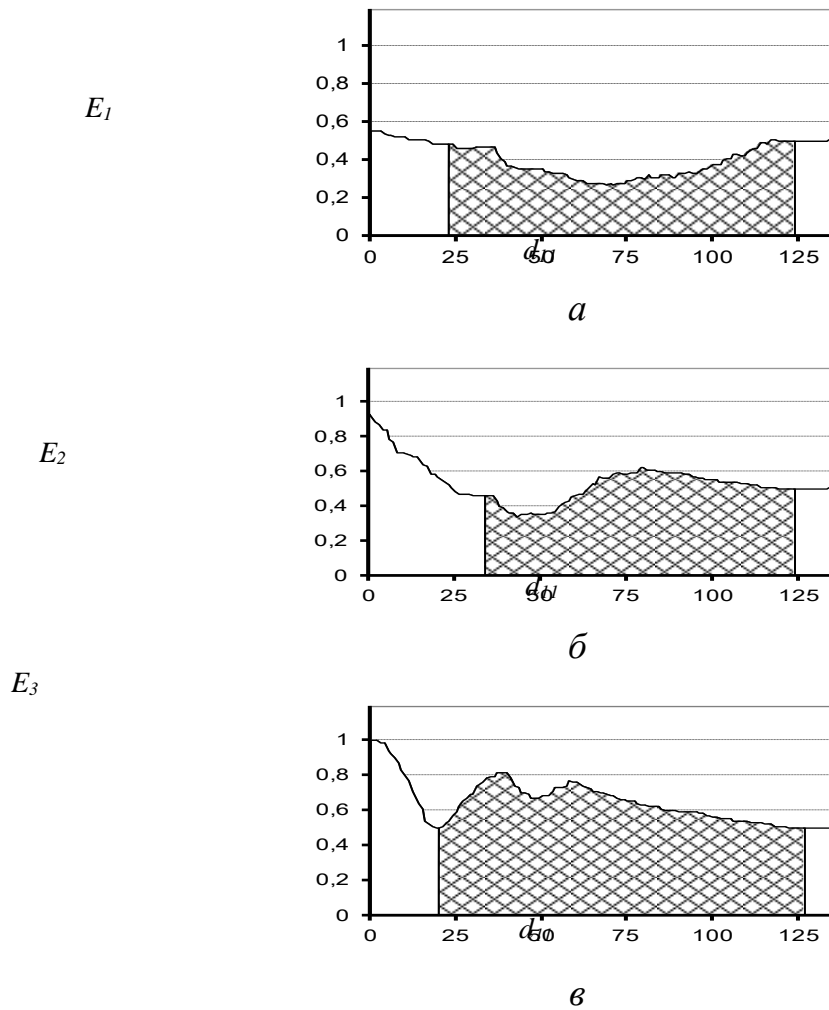



Рис. 1.11– Графіки залежності КФЕ від радіусів контейнера зображення кадру, що ідентифікується (*a* – мастопатія, *б* – рак, *в* – фіброаденома)

На рис.1.11 заштрихована ділянка визначає робочу (допустиму) область визначення КФЕ навчання системи ідентифікації кадрів, в якій перша та друга достовірності більше 0,5, тобто помилки першого і другого роду будуть менше відповідних достовірностей. Аналіз графіків показую, що КФЕ не досягає свого максимального граничного значення ($E_{гран}^* = 1$) в процесі ідентифікації кадру з заданими еталонами. При цьому максимальне значення КФЕ для класу мастопатія дорівнює $E_1^* = 0,51$, а оптимальний радіус – $d_{11}^* = 119$ (тут і далі у кодових одиницях); для класу рак відповідно – $E_2^* = 0,62$ і $d_{11}^* = 80$; для класу фіброаденома – $E_3^* = 0,81$ і $d_{11}^* = 38$. При цьому критерії схожості відповідно дорівнюють $C_1 = 0,49$, $C_2 = 0,38$ і $C_3 = 0,19$. Тобто одержані результати


не дозволяють з високою достовірністю визначити належність поточного кадру до одного із захворювань. Тому доцільним є проведення навчання КСД з паралельною оптимізацією СКД. На рис.1.12 показано результати оптимізації СКД в процесі ідентифікації 11-го кадру загального зображення.

E_1




a

E_2



b

E_3



v

Рис. 1.12. Графіки залежності КФЕ від параметру поля контрольних допусків на ознаки розпізнавання (a – мастопатія, b – рак, v – фіброаденома)

Аналіз рисунку показує, що для мастопатії і для фіброаденоми значення КФЕ навчання КСД дорівнюють максимальному граничному ($E_1^* = E_3^* = 1$). Оскільки відповідні критерії схожості згідно з формулою (1) дорівнюють нулю, то можна зробити висновок, що гіпотези про належність

кадру, що ідентифікується, до класів мастопатія та фіброаденома відкидаються. При цьому аналіз рис. 6б показує, що максимальне значення КФЕ дорівнює $E_2^* = 0,31$ при відповідному значенні критерію схожості $C_{11,2} = 0,79$. Таким чином, має місце висока достовірність ідентифікації кадру з класом рак молочної залози.

В табл. 1.3 наведено результати ідентифікації всіх 30 кадрів загального зображення тканини пацієнта.

Таблиця 1.3–Результати процесу ідентифікації кадрів

№ кадру	Критерій схожості на мастопатію, C	Критерій схожості на рак, C	Критерій схожості на фіброаденому, C
1	0,36	0,75	0
2	0	0,78	0
3	0	0,82	0,12
4	0,1	0,69	0
5	0,28	0,71	0
6	0	0,89	0
7	0	0,85	0
8	0	0,83	0
9	0	0,92	0
10	0,08	0,63	0,37
11	0	0,95	0
12	0	0,83	0
13	0,39	0,49	0
14	0	0,91	0
15	0	0,32	0,15
16	0	0,85	0
17	0	0,88	0
18	0	0,73	0

Продовження таблиці 1.3

19	0,23	0,5	0
20	0	0,63	0
21	0	0,89	0
22	0	0,86	0,34
23	0	0,93	0
24	0,4	0,69	0
25	0	0,25	0,06
26	0	0,89	0
27	0	0,84	0
28	0	0,91	0
29	0	0,81	0
30	0,02	0,54	0


Аналіз табл. 1.3 показує, що після проведення процесу ідентифікації кадрів морфологічного зображенні тканини пацієнта було виявлено 5 кадрів з критерієм схожості на рак більше 0,9 та 12 кадрів з критерієм схожості на рак більше 0,8. При цьому середнє значення критерію схожості на рак для всіх кадрів зображення дорівнює 0,75, що дозволяє зробити з високою достовірністю діагностичний висновок про наявність раку молочної залози.

Особливість системи компараторного розпізнавання, що здійснює ідентифікацію кадрів, полягає у відсутності етапу екзамену. Тому задачею навчання такої системи є не побудова вирішальних правил, як це має місце для традиційних задач розпізнавання образів, а обчислення в процесі ідентифікації кадрів максимального значення нормованого інформаційного критерію оптимізації параметрів навчання. З іншого боку, досягнення глобального максимуму критерію (4) в робочій області визначення його функції можливо за оптимальних в інформаційному розумінні параметрів навчання. Наприклад, аналіз рис. 5 показує, що оптимальними параметрами


контрольних полів допусків на ознаки розпізнавання ϵ для класу мастопатія $\delta_1^* = 56$ (тут і далі в градаціях яскравості пікселів рецепторного поля зображень), для класу рак молочної залози $\delta_2^* = 25$ і для класу фіброаденома $\delta_3^* = 29$.

Оптимальні параметри контейнерів, що відновлюються в процесі ідентифікації 11-го кадру визначаються за показаними на рис. 1.13 графіками залежності КФЕ від радіусу d_{11} контейнерів зображення цього кадру в процесі паралельної оптимізації СКД.

E_1



E_2



E_3




Рисунок 1.13– Графіки залежності КФЕ від радіусу контейнерів для еталонних зображень (a – мастопатія, b – рак, v – фіброаденома)

Аналіз рис.1.13б показує, що максимальне значення інформаційного КФЕ ідентифікації кадру щодо еталонного зображення дорівнює $E_2^* = 0,05$, що свідчить про погану роздільність поточного кадру з еталонним. При цьому критерій схожості (1) дорівнює $c = 0,95$. При порівнянні кадру, що ідентифікується, з кадрами-еталонами класів мастопатія і фіброаденома (рис. 1.13а і рис.1.13б відповідно) КФЕ навпаки досягає максимального значення, що свідчить про відмінність поточного кадру від еталонних зображень цих класів. Таким чином можна зробити остаточний висновок, що текстура даного кадру належить до раку молочної залози.

Висновки

1. Запропоновано новий інформаційно-екстремальний метод ідентифікації кадрів, в основу якого покладено принцип максимізації кількості інформації між поточним кадром, що ідентифікується, і кадром-еталоном класу відповідної онкопатології.

2. З метою підвищення достовірності ідентифікації при збільшенні потужності алфавіту класів розпізнавання перспективним розвитком запропонованого методу є побудова ієрархічної структури інформаційно-екстремального алгоритму ідентифікації, що дозволить вирішити в певних межах проблему багато вимірності.

1.5 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИЙ АЛГОРИТМ НАВЧАННЯ СИСТЕМИ ДІАГНОСТУВАННЯ ЕМОЦІЙНО-ПСИХІЧНОГО СТАНУ ЛЮДИНИ

Технологія психодіагностування та корекції привертала увагу спеціалістів з давніх часів. Комп'ютерні технології психодіагностування за зображенням обличчя та його фрагментів дозволяють підвищити достовірність оцінки психічного стану людини та функціональну ефективність його корекції [1,2].

Відомі методи розпізнавання зображень [3,4] носять в основному модельний характер, оскільки не враховують перетин класів розпізнавання, що характеризують різні психічні стани пацієнта та довільні початкові умови формування зображень. Тому основним шляхом підвищення функціональної ефективності системи психодіагностування за зображеннями обличчя пацієнта є надання їй властивості адаптивності на основі машинного навчання. Одним із перспективних підходів до вирішення цієї проблеми є застосування ідей і методів ІЕІ-технології, яка оснований на максимізації інформаційної спроможності системи підтримки прийняття рішень в процесі її навчання [5]. У праці [1] запропоновано в рамках ІЕІ-технології алгоритм навчання системи психодіагностування за зображенням обличчя, але асимптотична достовірність розпізнавання виявилася недостатньо високою.

В статті розглядається інформаційно-екстремальний алгоритм навчання СППР для відео-комп'ютерної психодіагностики та корекції [2], з використанням фрагментів зображення обличчя людини [7].

1. Постановка задачі

Розглянемо формалізовану постановку задачі інформаційного синтезу для розпізнавання емоційно-психічного стану людини за фрагментами зображення її обличчя. Нехай дано алфавіт $\{X_m^o | m = \overline{1, M}\}$ класів розпізнавання, які характеризують різні психологічні стани пацієнта, і навчальну матрицю яскравості зображення обличчя пацієнта $\|y_{m,i}^{(j)}\|$, $i = \overline{1, N}$, $j = \overline{1, n}$, де N, n – кількість ознак розпізнавання та векторів-реалізацій (далі просто реалізації) класів розпізнавання відповідно. При цьому рядок матриці $\{y_{m,i}^{(j)} | i = \overline{1, N}\}$ визначає j -у реалізацію, а стовпчик $\{y_{m,i}^{(j)} | j = \overline{1, n}\}$ – навчальну вибірку значень i -ї ознаки. Відомий структурований вектор параметрів навчання СППР $g = \langle x_m, d_m \rangle$, де x_m – еталонна реалізація, яка визначає геометричний центр контейнера класу X_m^o ; d_m – радіус контейнера класу X_m^o . Необхідно на етапі навчання СППР оптимізувати

координати вектора g шляхом пошуку глобального максимуму усередненого за алфавітом класів розпізнавання інформаційного КФЕ навчання системи

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M \max_{G_E} E_m, \quad (1)$$

де E_m – інформаційний КФЕ навчання системи розпізнавати реалізації класу X_m^o ; G_E – робоча (допустима) область визначення функції КФЕ.

На етапі екзамену, тобто безпосереднього діагностуванні, необхідно прийняти рішення про належність реалізації, що розпізнається, до одного із класів заданого алфавіту.

2. Математична модель

Категорійну модель процесу навчання системи психодіагностування в рамках ІЕІ-технології подамо у вигляді діаграми відображень множин. При цьому вхідний математичний опис СППР представимо у вигляді структури

$$\Delta_B = \langle G, T, \Omega, Z, Y; \Pi, \Phi, f \rangle,$$

де G – простір вхідних факторів; T – множина моментів часу зняття інформації; Ω – простір ознак розпізнавання; Z – простір можливих емоційно-психологічних станів людини; Y – вибіркова множина (вхідна навчальна матриця); $\Pi: G \times T \times \Omega \rightarrow Z$ – оператор переходів, що відбиває механізм зміни емоційно-психологічних станів; $\Phi: G \times T \times \Omega \times Z \rightarrow Y$ – оператор оброблення зображення (формування вхідної навчальної матриці Y); $f: Y \rightarrow X^p$ – оператор відображає вхідну навчальну матрицю яскравості Y зображення обличчя в бінарну матрицю X^{lp} , яка враховує значення яскравості виділених на зображенні заданих p фрагментів.

Діаграму відображень множин у процесі навчання СППР за інформаційно-екстремальним алгоритмом з оптимізацією геометричних параметрів гіперсферичних контейнерів класів розпізнавання показано на рис. 1.14.




Рисунок 1.14 – Категорійна модель навчання СППР

На діаграмі (рис.1.14) показано такі множини: $\mathfrak{R}^{[2]}$ – розбиття простору ознак розпізнавання, яке в загальному випадку є нечітким; $I^{[l]}$ – множина допустимих гіпотез, де l – кількість статистичних гіпотез; $\mathfrak{Z}^{[q]}$ – множина точнісних характеристик, де $q = l^2$; E – терм-множина значень інформаційного КФЕ, який обчислюється на кожному кроці навчання СППР; $\tilde{\mathfrak{L}}^{[2]}$ – множина діагнозів емоційно-психологічних станів людини. Відповідні оператори мають таке призначення: оператор θ будує розбиття $\mathfrak{R}^{[2]}$ простору ознак на класи розпізнавання; оператор ψ перевіряє основну статистичну гіпотезу про належність реалізації $x_{m,i}^{(j)}$ класу X_m^o ; оператор γ формує множину точнісних характеристик для заданої системи оцінок рішень; оператор φ обчислює множину значень інформаційного КФЕ; оператор r реалізує ітераційний процес оптимізації геометричних параметрів розбиття $\mathfrak{R}^{[2]}$; оператор U регламентує процес навчання і дозволяє оптимізувати параметри його планування. Правий контур операторів реалізує в рамках ІЕІ-технології базовий алгоритм навчання СППР, основною задачею якого є оптимізація геометричних параметрів розбиття $\mathfrak{R}^{[2]}$ при заданій системі контрольних допусків на ознаки розпізнавання.

3. Алгоритм навчання

Розглянемо модифікований базовий алгоритм навчання СППР для психодіагностування за фрагментами зображення обличчя пацієнта в рамках ІЕІ-технології, який відновлює в радіальному базисі простору ознак

гіперсферичні контейнери класів розпізнавання. При цьому оптимальний радіус контейнера класу розпізнавання визначається за ітераційною процедурою

$$d_m^* = \arg \max_{G_E \cap G_d} \bar{E}, \quad (2)$$

де G_E, G_d – області допустимих значень КФЕ та радіусів контейнерів класів розпізнавання.

Вхідною інформацією для навчання СППР є багатовимірна навчальна матриця яскравості пікселів рецепторного поля зображення обличчя $\|y_{m,i}^{(j)}\|_{m=\overline{1,M}; I=\overline{1,N}; J=\overline{1,n}}$, де N, n – кількість ознак розпізнавання та векторів-реалізацій класів відповідно; система полів контрольних допусків $\{\delta_i\}$ на ознаки розпізнавання і рівні селекції $\{\rho_m\}$ координат еталонних двійкових векторів-реалізацій, які за замовчуванням дорівнюють 0,5 для всіх класів розпізнавання. Крім того, задається структура координат вершин прямокутних фрагментів зображення обличчя пацієнта $\langle i_B, i_E, j_B, j_E \rangle$. При цьому потужність словника ознак розпізнавання, сформованого за фрагментом зображень, дорівнює $i_E - i_B$ ознак, а кількість реалізацій – $j_E - j_B$.

Розглянемо основні етапи реалізації базового алгоритму навчання:

1. Формується по фрагменту зображення бінарна навчальна матриця $\|x_{m,i}^{(j)}\|^{(p)}$, елементи якої дорівнюють

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_i; \\ 0, & \text{if } y_{m,i}^{(j)} \notin \delta_i. \end{cases} \quad (3)$$

де $i = i_B \dots i_E$, $j = j_B \dots j_E$, де i – кількість ознак розпізнавання фрагмента зображення; j – кількість реалізацій класів фрагмента зображення обличчя пацієнта.

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

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m; \\ 0, & \text{if else,} \end{cases}, \quad (4)$$

де $\rho_m^{(p)}$ – рівень селекції координат вектора $x_m^{(p)} \in X_m^{(p)}$.

3. Для кожного класу $X_m^{(p)}$ здійснюється пошук найближчого «сусіда» $X_l^{(p)}$, для якого виконується умова $l = \arg \min_{\{t\}} d(x_m \oplus x_t)$, де $\{t\} = \{\overline{1, m-1}, \overline{m+1, M}\}$.

4. Оптимізація кодової відстані $d_m^{(p)}$ відбувається за рекурентною процедурою $d_m(k) = [d_m(k-1) + h | d_m(k) \in G_m^d]$. При цьому приймається $E_m^{(p)}(0) = 0$.

5. Процедура закінчується при знаходженні максимуму КФЕ в робочій області визначення його функції

$$E_m^{*(p)} = \max_{\{d\}} E_m, \quad (5)$$

де $\{d\} = \{d_1, \dots, d_{\max}\} \in [0; d(x_m \oplus x_l) - 1]$ - множина радіусів концентрованих гіперсфер, центр яких визначається вершиною еталонного вектора $x_m^{(p)} \in X_m^{(p)}$. При цьому множина $\{d\}$ є так само множиною кроків навчання системи розпізнавання.

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

Як критерій оптимізації параметрів навчання у рамках ІЕІ-технології може розглядатися будь-яка статистична інформаційна міра, яка є функціоналом від точнісних характеристик. Широкого використання в алгоритмах навчання набула модифікація інформаційної міри Кульбака [6]:

$$E_m^{(k)} = 0,5 \log_2 \left(\frac{D_1^{(k)} + D_2^{(k)} + 10^{-r}}{\alpha^{(k)} + \beta^{(k)} + 10^{-r}} \right) * \left[(D_1^{(k)} + D_2^{(k)}) - (\alpha^{(k)} + \beta^{(k)}) \right], \quad (6)$$

де $D_1^{(k)}$, $D_2^{(k)}$ – перша та друга достовірності, обчислені на k -му кроці навчання; $\alpha^{(k)}$, $\beta^{(k)}$ – помилка першого та другого роду; 10^{-r} – достатньо мале число для уникнення поділу на нуль.

4. Результати моделювання

Формування навчальної матриці здійснювалося за відомою технологією відео-комп'ютерної психодіагностики та корекції, яка базується на порівнянні лівопівкульного та правопівкульного портретів для оцінки психологічного стану людини. Вхідний математичний опис СППР було сформовано за графічними даними, наведеними в праці [2]. На рис. 1.15 показано портрети особи з нестабільним станом, які характеризують клас X_1^o , сформований із лівопівкульних (рис. 1.15а) і клас X_2^o , сформований із правопівкульних портретів (рис. 1.15б). Відповідно сформовано портрети особи із стабільним емоційно-психологічним станом – клас X_3^o (рис. 1.15в) і клас X_4^o (рис. 1.15г).



а) б) в) г)

Рисунок 1.15 – Портрети, які використані при психодіагностиці: а) – клас X_1^o ; б) – клас X_2^o ; в) – клас X_3^o ; г) – клас X_4^o

Результат оптимізації за критерієм (6) геометричних параметрів контейнерів класів розпізнавання, що відновлюються в радіальному базисі простору ознак за ітераційною процедурою базового алгоритму навчання, для повних портретів (рис.1.15) показано на рис. 1.16.

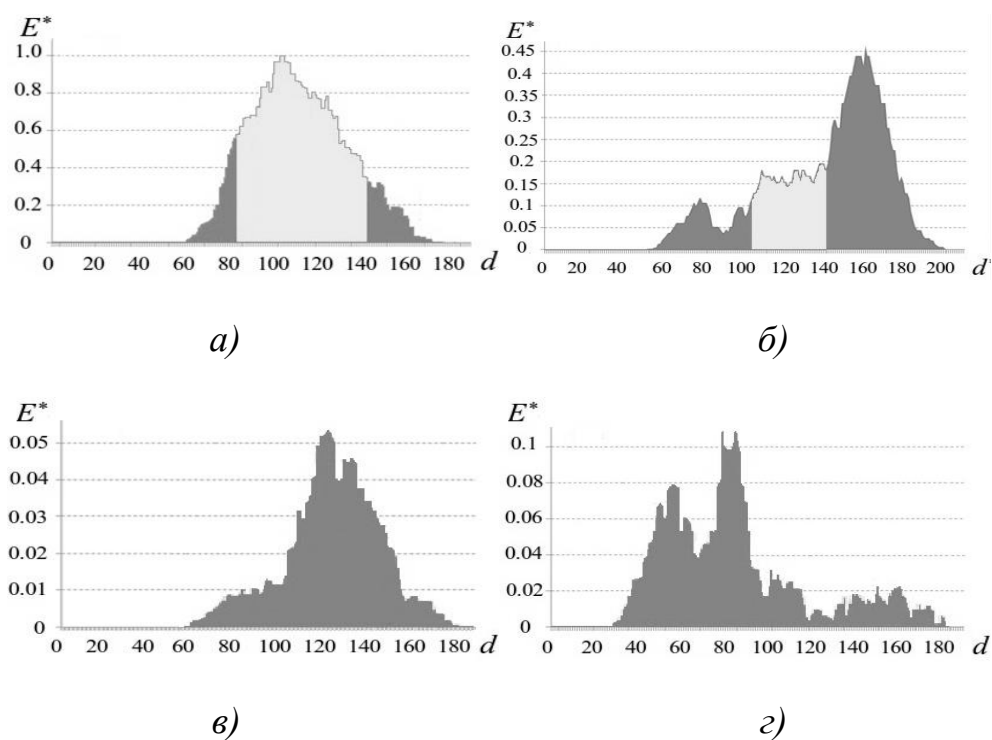


Рисунок 1.16 – Графіки залежності КФЕ (б) від радіусів контейнерів класів розпізнавання для повного портрету: *а)* – клас X_1^o ; *б)* – клас X_2^o ; *в)* – клас X_3^o ; *з)* – клас X_4^o

На рис. 1.6 світлим кольором показано робочі (допустимі) області визначення функції КФЕ, в яких перша та друга достовірності перевершують відповідно помилки першого та другого роду. Аналіз рис. 1.16 показує, що незначні максимальні значення КФЕ характерні для особи зі стабільним емоційно-психологічним станом, що пояснюється схожістю лівопівкульних і правопівкульних портретів. Крім того, через близькість центрів класів X_3^o і X_4^o на рис. 1.16*в* і рис. 1.16*з* відсутні робочі області.

З метою дослідження інформативності фрагментів обличчя було сформовано навчальну матрицю яскравості для зображень фрагментів, які характеризували зону очей та носа. На рис. 1.17 показано портрети особи з нестабільним станом, які характеризують клас X_1^o , сформований із лівопівкульних (рис. 1.17*а*) і клас X_2^o , сформований із правопівкульних портретів (рис. 1.17*б*). Відповідно сформовано портрети особи із стабільним емоційно-психологічним станом – клас X_3^o (рис. 1.17*в*) і клас X_4^o (рис. 1.17*з*).




Рисунок 1.17 – Фрагменти портрета обличчя, які включають зону очей та носу:

a) – клас X_1^o ; *б)* – клас X_2^o ; *в)* – клас X_3^o ; *з)* – клас X_4^o

Графіки залежності динаміки зміни КФЕ при формуванні вирішальних правил для портретів пацієнта до та після проведення психокорекції показано на рис. 1.8.

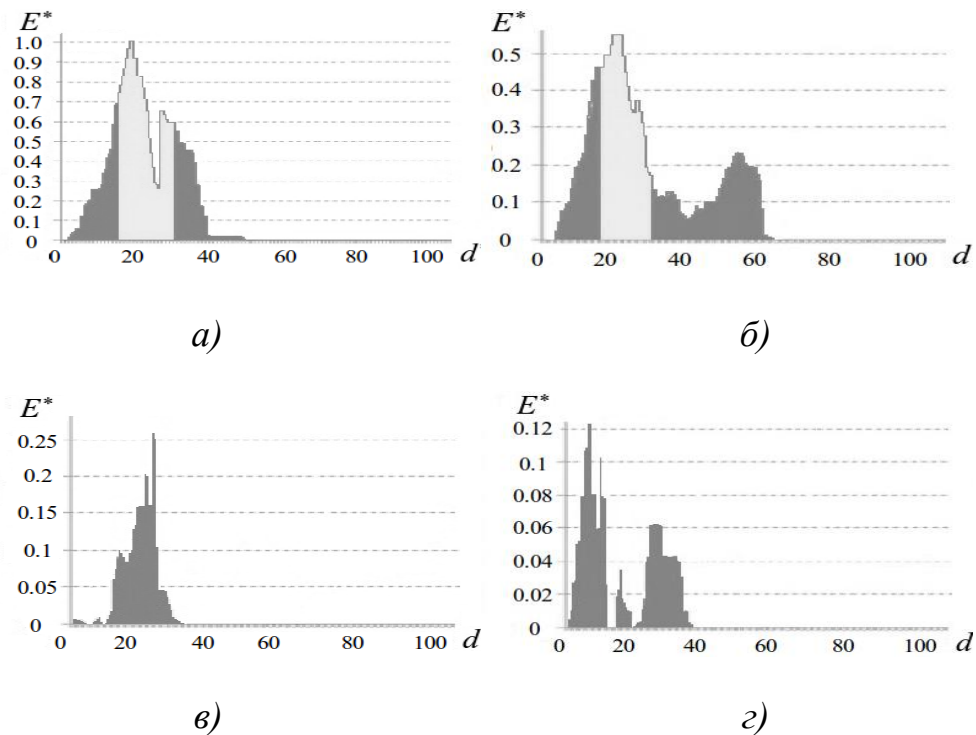


Рисунок 1.18 – Графіки залежності КФЕ (E^*) від радіусів контейнерів класів розпізнавання для фрагментів портрету, які включають зону очей та носу: *a)*

– клас X_1^o ; *б)* – клас X_2^o ; *в)* – клас X_3^o ; *з)* – клас X_4^o

Аналіз рис. 1.8а і рис. 1.18б, одержаних за ліво- та правопівкульним портретом особи з нестабільним емоційно-психологічним станом, вказує на можливість створення вирішальних правил, перша та друга достовірності яких перевищують 0,5. Результати навчання для особи зі стабільним емоційно-психологічним станом за аналогічними алгоритмами, які подано на рис. 1.18в і рис. 1.18г, показують неможливість формування релевантних вирішальних правил, оскільки значення КФЕ є близькими до нуля, що свідчить про високий ступінь схожості ліво- та правопівкульних портретів. Таким чином, запропонований алгоритм навчання дозволяє будувати вирішальні правила, здатні визначати різноманітність між право- і лівопівкульними портретами обличчя.

На наступному етапі, з метою дослідження інформативності фрагментів обличчя було сформовано навчальну матрицю яскравості для зображень фрагментів, які характеризували зону носа (рис. 1.19).




Рисунок 1.19 – Фрагменти портрета, що включають зону носа: а) – клас X_1^o ; б) – клас X_2^o ; в) – клас X_3^o ; г) – клас X_4^o .

Графіки залежності динаміки зміни КФЕ при формуванні вирішальних правил для портретів пацієнта до та після проведення психокорекції показано на рис. 1.20.

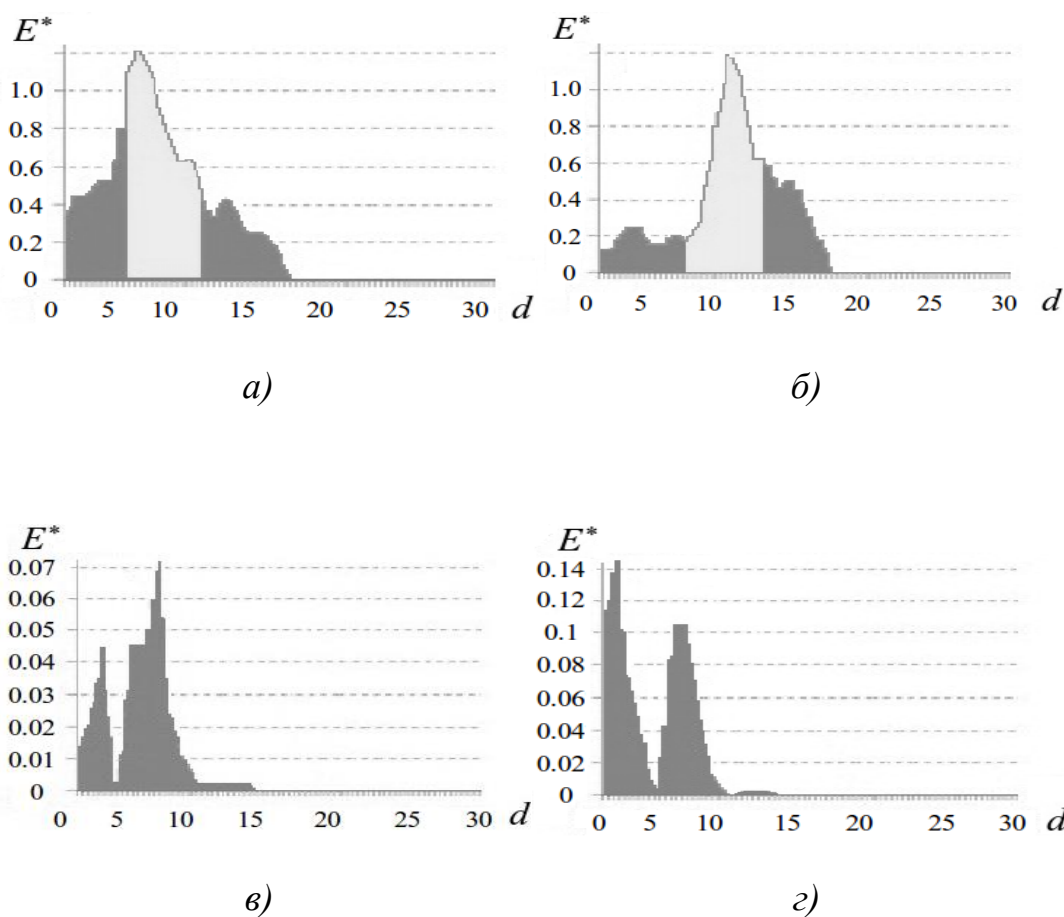


Рисунок 1.20 – Графіки залежності КФЕ (б) від радіусів контейнерів класів розпізнавання для фрагментів портрету, які включають зону носу: а) – клас X_1^o ; б) – клас X_2^o ; в) – клас X_3^o ; г) – клас X_4^o

Аналіз рис. 1.20а і рис. 1.20б, одержаних за ліво- та правопівкульним портретом особи з нестабільним емоційно-психологічним станом, вказує на можливість створення вирішальних правил. Результати навчання для особи зі стабільним емоційно-психологічним станом за аналогічними алгоритмами, які подано на рис. 1.20в і рис. 1.20г, показують неможливість формування релевантних вирішальних правил, оскільки значення КФЕ є близькими до нуля, що свідчить про високий ступінь схожості ліво- та правопівкульних портретів. Таким чином, запропонований алгоритм навчання дозволяє будувати вирішальні правила, здатні визначати різноманітність між право- і лівопівкульними портретами обличчя.

Аналогічний аналіз зображень пацієнта, що були отримані на різних етапах психокорекції, дозволяє відслідкувати динаміку зміни КФЕ при формуванні вирішальних правил протягом всього періоду лікування (рис. 1.21).




Рисунок 1.21 – Графіки зміни КФЕ (б) при формуванні вирішальних правил протягом всього періоду лікування: *а)* - повний портрет; *б)* - зона очей і носу; *в)* - зона носу

Аналіз рис. 1.21*а* показує, що на другому етапі лікування відбулося погіршення психологічного стану. На це вказує збільшення значення КФЕ при формуванні вирішальних правил. Після цього КФЕ, а отже і відмінність між правопівкульним і лівопівкульним портретами, поступово зменшувалася і на четвертому кроці відповідні вирішальні правила не було сформовано. Аналіз рис. 1.21*б* показує, що на другому етапі лікування не відбулося погіршення психологічного стану, але на третьому етапі мало місце певне «гальмування» процесу психокорекції. На це вказують незначні зміни значення КФЕ при формуванні вирішальних правил на третьому етапі лікування відносно другого етапу. На четвертому - аналогічно до рис. 1.21*а*

відповідні вирішальні правила не було сформовано. Аналіз рис. 1.21в показує, що аналогічно до рис. 1.21б, на другому етапі лікування не відбулося погіршення психологічного стану, але на третьому етапі мало місце певне «гальмування» процесу психокорекції. На це вказують незначні зміни значення КФЕ при формуванні вирішальних правил на третьому етапі лікування відносно другого етапу. На четвертому кроці аналогічно до рис. 1.21а – 1.21б відповідні вирішальні правила не було сформовано.

Узагальнена траєкторія психокорекції за динамікою зміни КФЕ для двох різних частин портрету подана на рис. 1.22.




Рисунок 1.22 – Траєкторія психокорекції за динамікою зміни КФЕ

На рис. 1.22 траєкторія психокорекції формується на площині E_1E_2 . При цьому дана площина розбита на чотири області, що відповідають об'єктивній типології психологічних станів людини [2]. В верхній правій частині показана область логічних дестабільних психологічних станів, правій нижній – інтуїтивних дестабільних, лівій верхній – логічних стабільних, лівій нижній – інтуїтивних стабільних. Використання такого способу відображення процесу лікування дозволяє спостерігати за коректністю вжитих засобів, ефективністю окремих етапів та лікування в цілому.

Висновки

1. В роботі запропоновано модифікацію технології відео-комп'ютерної психодіагностики та корекції, що застосовується в Центрі Екології Людини НИКАР при Інституті Проблем Керування Російської Академії Наук шляхом її інтеграції з інформаційно-екстремальною інтелектуальною технологією.

2. Для сформованих навчальних матриць на базі фрагмента ліво- та право півкульних портретів людини, що проходить психодіагностику, запропоновано алгоритм обчислення інформаційної міри між цими портретами з метою визначення їх різноманітності. Порівняння максимальних значень інформаційних мір, отриманих при оптимізації параметрів навчання системи за портретами людини до та після проведення психокорекції показало, що використання частини портрета пацієнта для психоаналізу є більш ефективним, оскільки портрет може бути нестабільним, наприклад, через вікові особливості чи різні специфічні обмеження .

3. Показана можливість використання лише частини зображення для психодіагностики та об'єднання результатів психодіагностики за окремими фрагментами портрету, що дозволяє відобразити процес лікування у вигляді траєкторії психокорекції на площині об'єктивних типологій психологічних станів людини.

1.6 ОПТИМІЗАЦІЯ ПАРАМЕТРІВ НАВЧАННЯ КОМП'ЮТЕРИЗОВАНОЇ СИСТЕМИ ДІАГНОСТУВАННЯ ЕМОЦІЙНО-ПСИХІЧНОГО СТАНУ ЛЮДИНИ

В теперішній час увагу спеціалістів-психологів привертає технологія відео-комп'ютерного психодіагностування та корекції, заснована на визначенні функціональної асиметрії двох півкуль головного мозку шляхом аналізу асиметрії зображення обличчя людини, яке вводиться в комп'ютер за допомогою відеокамери [1]. При цьому задача комп'ютерної психодіагностики зводиться до розпізнавання зображень лівої та правої

половин обличчя людини і встановлення їх асиметричних відмінностей. Встановлено, що функціональна ефективність комп'ютерного психодіагностування за зображенням обличчя пацієнта суттєво залежить від достовірності методу розпізнавання. Відомі методи розпізнавання зображень [2-4] носять в основному модельний характер, оскільки не враховують перетин класів розпізнавання, що характеризують різні психічні стани пацієнта, і довільні початкові умови формування зображень. Тому основним шляхом підвищення функціональної ефективності системи психодіагностування за зображеннями обличчя пацієнта є надання їй властивості адаптивності на основі машинного навчання (самонавчання). Одним із перспективних підходів до вирішення цієї проблеми є застосування ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології), яка оснований на максимізації інформаційної спроможності системи підтримки прийняття рішень в процесі її навчання [5,6].

У статті розглядається інформаційно-екстремальний алгоритм навчання комп'ютеризованої системи діагностування (КСД) емоційно-психічного стану людини за зображенням її обличчя.

Постановка задачі

Розглянемо формалізовану постановку задачі інформаційного синтезу КСД, основною складовою якої є здатна навчатися система підтримки прийняття рішень (СППР) для розпізнавання емоційно-психічного стану людини за зображенням її обличчя. Нехай дано алфавіт $\{X_m^o \mid m = \overline{1, M}\}$ класів розпізнавання, які характеризують різні психологічні стани пацієнта, і навчальну матрицю яскравості зображення обличчя пацієнта

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

де N, n – кількість ознак розпізнавання та векторів-реалізацій (далі реалізації) класів розпізнавання відповідно. При цьому строчка матриці $\{y_{m,i}^{(j)} \mid i = \overline{1, N}\}$ визначає j -у реалізацію, а стовпчик $\{y_{m,i}^{(j)} \mid j = \overline{1, n}\}$ – навчальну вибірку значень i -ї ознаки. Відомий структурований вектор параметрів

навчання КСД $g = \langle x_m, d_m \rangle$, де x_m – еталонна реалізація, яка визначає геометричний центр контейнера класу x_m^o ; d_m – радіус контейнера класу x_m^o . Необхідно на етапі навчання КСД оптимізувати координати вектора g шляхом пошуку глобального максимуму усередненого за алфавітом класів розпізнавання інформаційного критерію функціональної ефективності (КФЕ) навчання системи контрольних допусків (СКД)

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M \max_{G_E} E_m, \quad (1)$$

де E_m – інформаційний КФЕ навчання системи розпізнавати реалізації класу x_m^o ;

G_E – робоча (допустима) область визначення функції КФЕ.

При функціонуванні СКД в режимі екзамену, тобто безпосереднього діагностування, необхідно прийняти рішення про належність реалізації, що розпізнається, до одного із класів заданого алфавіту.

Математична модель

Оскільки процес психодіагностування є слабо формалізованим, то математичну категорійну модель здатної навчатися системи психодіагностування розглянемо у вигляді діаграми відображення відповідними операторами множин, що застосовуються в процесі навчання [7]. При цьому вхідний математичний опис КСД подамо у вигляді структури множин

$$\Delta_{\hat{A}} = \langle G, T, \Omega, Z, P, \Phi \rangle,$$

де G – простір вхідних сигналів (факторів);

T – множина моментів часу зняття інформації;

Ω – простір ознак розпізнавання;

Z – простір можливих емоційно-психологічних станів людини;

Y – множина сигналів після первинної обробки інформації;

$P: G \times T \times \Omega \rightarrow Z$ – оператор переходів, що відбиває механізм зміни емоційно-психологічних станів людини;

$\hat{O}: G \times T \times \Omega \times Z \rightarrow Y$ – оператор оброблення зображення (формування вибіркової множини Y на вході КСД). Як універсум випробувань W розглядається декартовий добуток: $W = G \times T \times \Omega \times Z$.

У загальному випадку математичну модель КСД яка розв'язує задачу інформаційного синтезу класифікатора емоційно-психологічного стану людини, подамо у вигляді структурної діаграми відображення операторами множин, що застосовуються в процесі навчання, в рамках ІЕІ-технології має вигляд, показаний на рис.1.23 [5]




Рисунок 1.23 – Категорійна модель навчання КСД

На діаграмі (рис.1.23) показано такі множини: $\mathbb{R}^{|M|}$ – розбиття простору ознак розпізнавання; $I^{|I|}$ – множина допустимих гіпотез; $\mathcal{S}^{|q|}$ – множину точнісних характеристик; E - інформаційний КФЕ навчання КСД. Показані на рис. 1 оператори мають такі призначення: оператор θ будує розбиття $\mathbb{R}^{|M|}$ простору ознак на класи розпізнавання; оператор ψ перевіряє основну статистичну гіпотезу про належність реалізацій образу; оператор γ формує множину точнісних характеристик; оператор φ обчислює множину значень інформаційного КФЕ; оператор r реалізує ітераційний процес оптимізації геометричних параметрів розбиття $\mathbb{R}^{|M|}$; оператор U регламентує процес навчання і дозволяє оптимізувати параметри його плану. При цьому правий контур операторів безпосередньо оптимізує геометричні параметри розбиття $\mathbb{R}^{|M|}$ при заданій системі контрольних допусків на ознаки розпізнавання.

Алгоритм навчання КСД

Інформаційно-екстремальне навчання КСД у загальному випадку здійснюється за багатоциклічною ітераційною процедурою пошуку глобального максимуму інформаційного КФЕ в робочій (допустимій) області визначення його функції, яка у загальному випадку має вигляд

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_E \cap G_1} \bar{E} \} \dots \} \}, \quad (2)$$

де \bar{E} – усереднене для ієрархічної структури класів розпізнавання значення інформаційного КФЕ навчання КСД;

G_{ξ} – допустима область значень ξ -ї ознаки;

G_E – допустима область значень КФЕ.

Внутрішній цикл алгоритму (2) реалізує базовий алгоритм навчання, в якому параметром функціонування, що оптимізується, є радіус гіперсферичного класифікатора:

$$d_m^* = \arg \max_{G_E \cap \{d\}} E_m, \quad (3)$$

де $\{d\}$ – множина значень радіусів контейнера класу X_m^0 , що відновлюється в радіальному базисі простору ознак розпізнавання.

Розглянемо етапи реалізації алгоритму навчання КСД:

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

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{1,i} - \delta \leq y_{1,i}^{(j)} \leq y_{1,i} + \delta, \\ 0, & \text{if else.} \end{cases} \quad (4)$$

де δ – параметр поля контрольних допусків на діагностичні ознаки.

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

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

де ρ_m – рівень селекції координат вектора $x_m \in X_m^0$, який за замовчанням дорівнює $\rho_m = 0,5$.

3. Розбиття множини еталонних векторів на пари найближчих "сусідів": $\mathfrak{R}_m^{[2]} = \langle x_m, x_1 \rangle$, де x_1 – еталонний вектор сусіднього класу X_1^0 . При цьому сусіднім еталонним вектором вважається такий, кодова відстань до якого є мінімальною. За наявності декількох однакових мінімальних елементів

вибирається з них будь-який, оскільки вони є рівноправними. Сформується структурована множина елементів попарного розбиття $\{\mathfrak{R}_m^{[2]} \mid m = \overline{1, M}\}$, яка задає план навчання.

4. Оптимізація кодової відстані d_m відбувається за рекурентною процедурою

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

При цьому береться $E_m(0) = 0$.

5. Процедура закінчується при знаходженні максимуму КФЕ в робочій області його визначення:

$$E_m^* = \max_{\{d\}} E_m,$$

де $\{d\} = \{d_1, \dots, d_k, \dots, d_{\max}\} \in [0; d(x_m \oplus x_1) - 1]$ —

множина радіусів концентрованих гіперсфер, центр яких визначається вершиною еталонного вектора $x_m \in X_m^o$. При цьому множина $\{d\}$ є так само множиною кроків навчання КСД.

Як КФЕ навчання в ІЕІ-технології використовуються дві інформаційні міри: нормована ентропійна міра Шеннона

$$\begin{aligned} E_m^{(k)} = & 1 + \frac{1}{2} \left(\frac{\alpha^{(k)}}{\alpha^{(k)} + D_2^{(k)}} \log_2 \frac{\alpha^{(k)}}{\alpha^{(k)} + D_2^{(k)}} + \right. \\ & + \frac{\beta^{(k)}}{D_1^{(k)} + \beta^{(k)}} \log_2 \frac{\beta^{(k)}}{D_1^{(k)} + \beta^{(k)}} + \frac{D_1^{(k)}}{D_1^{(k)} + \beta^{(k)}} \log_2 \frac{D_1^{(k)}}{D_1^{(k)} + \beta^{(k)}} + \\ & \left. + \frac{D_2^{(k)}}{\alpha^{(k)} + D_2^{(k)}} \log_2 \frac{D_2^{(k)}}{\alpha^{(k)} + D_2^{(k)}} \right), \end{aligned} \quad (6)$$

і міра Кульбака

$$\begin{aligned} E_m^{(k)} = & 0,5 \log_2 \left(\frac{D_1^{(k)} + D_2^{(k)} + 10^{-r}}{\alpha^{(k)} + \beta^{(k)} + 10^{-r}} \right) * \\ & * \left[(D_1^{(k)} + D_2^{(k)}) - (\alpha^{(k)} + \beta^{(k)}) \right] \end{aligned} \quad (7)$$

де $D_1^{(k)}$, $D_2^{(k)}$ — перша та друга достовірності, обчислені на k -му кроці навчання;

$\alpha^{(k)}$, $\beta^{(k)}$ — помилка першого та другого роду;

10^{-1} – достатньо мале число для уникнення поділу на нуль.

У загальному випадку побудований за формулами (6) та (7) графіки функцій $E=f(D_1, D_2)$ та $J=f(D_1, D_2)$ є поверхнями в тривимірному просторі показано на рис. 1.24.

Аналіз рис. 1.24 показує, що функції (6) та (7) є взаємно-неоднозначні. На практиці цей недолік усувається шляхом введення робочої (допустимої) області визначення функцій, в якій перша та друга достовірності становляться більше відповідних помилок першого та другого роду, тобто $D1 \geq 0,5$ та $D2 \geq 0,5$. Робочі області на рис. 1.24 показано на відповідних графіках темним кольором. Аналіз цих графіків показує, що при збільшенні у робочій області як першої, так і другої достовірностей кількість інформації теж збільшується, що знаходиться у відповідності з другим принципом адитивності інформації.




Рисунок 1.24– Графіки залежності КФЕ від точнісних характеристик при двохальтернативних рішеннях: а – ентропійний критерій (6); б – критерій Кульбака (7)

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

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

Результати моделювання

Формування навчальної матриці здійснювалося згідно з відомою технологією відео-комп'ютерної психодіагностики та корекції, що застосовується в Центрі Екології Людини НИКАР при Інституті Проблем Керування Російської Академії Наук шляхом її інтеграції з ІЕІ-технології. Ця технологія базується на порівнянні лівопівкульного та правопівкульного портретів для оцінки психологічного стану людини.

Вхідний математичний опис було скориговано за графічними даними наведеними в роботі [1]. Для формування таких портретів фотографія людини розділяється на дві половини праву та ліву, кожна з цих половин відображається дзеркально по ліній розділу та поєднується зі своєю не модифікованою копією (рис. 1.25).



а

б

в

г

Рис. 1.25 Портрети, які використані при психодіагностиці: а, б – правопівкульний та лівопівкульний портрети відповідно при нестабільному емоційно-психологічному стані особи; в, г – правопівкульний та лівопівкульний портрети відповідно при стабільному емоційно-психологічному стані особи

Результат оптимізації геометричних параметрів контейнерів класу розпізнавання з використанням як КФЕ інформаційної міри Шеннона (б) для особи з нестабільним станом x_0^o - лівопівкульний (а) та x_1^o - правопівкульний (б) портрети, та стабільним емоційно-психологічним станом x_2^o - лівопівкульний (в), та x_3^o - правопівкульний (г) портрети показано на рис. 1.26.

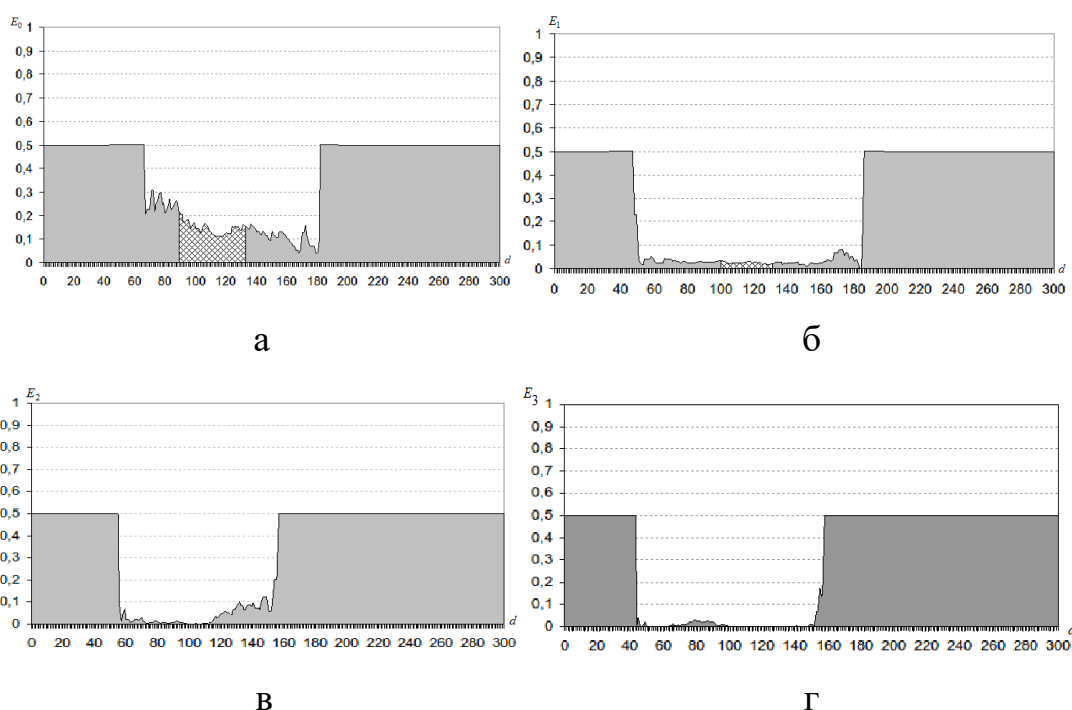


Рисунок 1.26– Динаміка зміни КФЕ при оптимізації контейнерів з використанням інформаційної міри Шеннона:

а – клас x_0^o ; б – клас x_1^o ; в – клас x_2^o ; г – клас x_3^o

На рис. 1.26 робочі області позначено подвійною штриховкою. При цьому незначні максимальні значення КФЕ пояснюються тим, що право і лівопівкульний портрети сформовано з двох частин одного зображення, але наявність робочих областей вказує на певну відмінність цих портретів.

Таким чином, для особи зі стабільним емоційно-психологічним станом різноманітність між право і лівопівкульними портретами зменшилася, на що

вказує зниження максимальних значень КФЕ при формуванні геометричних параметрів класів.

Результат оптимізації геометричних параметрів контейнерів класу розпізнавання з використанням як КФЕ інформаційної міри Кульбака [7] для особи з нестабільним станом x_0^o - лівопівкульний (рис.1.27а) і x_1^o - правопівкульний портрети (рис.1.27б), та стабільним емоційно-психологічним станом x_2^o - лівопівкульний (рис.1.27в) і x_3^o - правопівкульний (рис.1.27г) портрети показано на рис. 1.27.

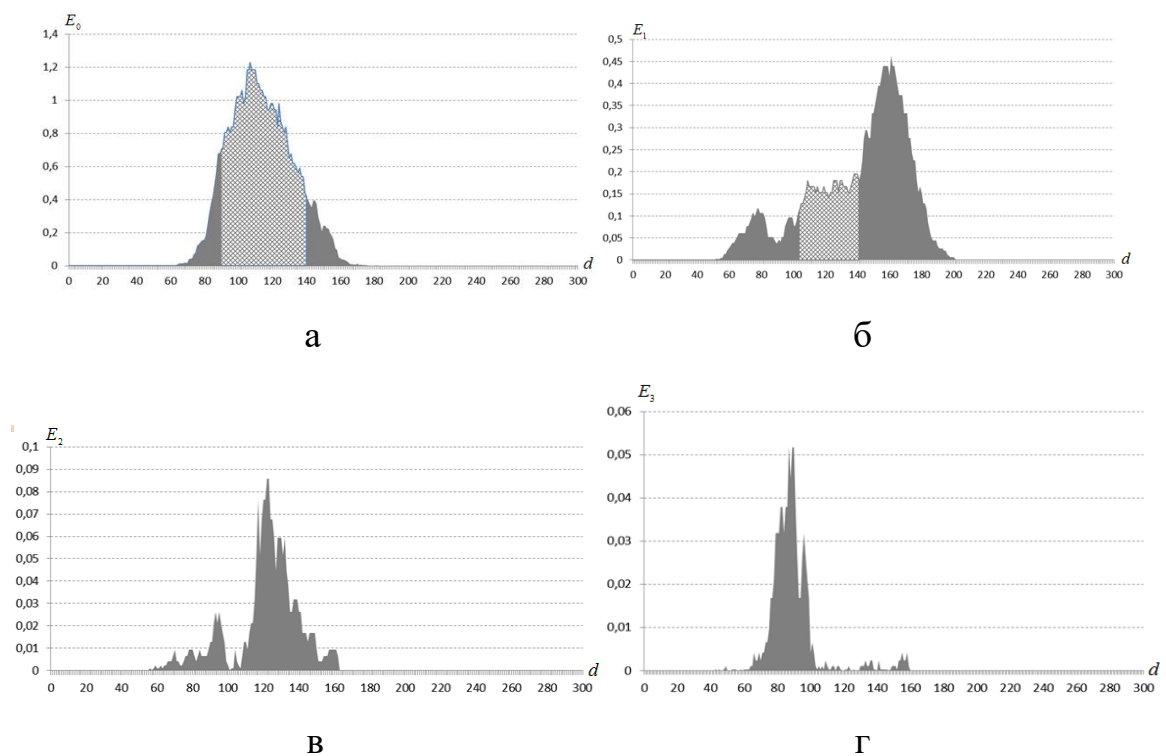


Рисунок 1.27– Динаміка зміни КФЕ при формуванні контейнера з використанням інформаційної міри Кульбака: а – для класу x_0^o ; б – для класу x_1^o ; в – для класу x_2^o ; г – для класу x_3^o

Аналіз рис. 1.27а і рис.1.27б, одержаних за ліво- та правопівкульним портретом особи з нестабільним емоційно-психологічним станом, вказує на можливість створення вирішальних правил, перша та друга достовірності яких перевищують 0,5. Результати навчання для особи зі стабільним емоційно-психологічним станом за аналогічними алгоритмами, які подано на рис. 1.27в і рис. 1.27д, показують неможливість формування вирішальних

правил, оскільки значення КФЕ є близькими до нуля, що свідчить про високий ступінь схожості ліво- та правопівкульних портретів.

Таким чином, запропонований алгоритм навчання дозволяє будувати вирішальні правила, здатні визначати різноманітність між право- і лівопівкульними портретами обличчя.

Висновки

1. Запропоновано в рамках ІЕІ-технології модифікацію відомого методу відео-комп'ютерної психодіагностики за ліво- та правопівкульними портретами обличчя особи. Розроблено інформаційно-екстремальний алгоритм навчання системи психодіагностування, який дозволив побудувати вирішальні правила, здатні визначати різноманітність ліво- та правопівкульних портретів обличчя особи, що діагностується. Крім того, проведена оцінка ефекту психокорекції шляхом порівняння інформаційних мір між портретами особи до та після її проведення.

2. Шляхом фізичного моделювання доведено рівноцінність застосування в системах комп'ютерної психодіагностики інформаційних критеріїв за Шенноном і Кульбаком і для цих критеріїв побудовано вирішальні правила за навчальними матрицями, сформованими на базі право- та лівопівкульних портретів особи, що діагностується.

1.7 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ МАШИННЕ НАВЧАННЯ СИСТЕМИ ФУНКЦІОНАЛЬНОГО ДІАГНОСТУВАННЯ З ІЄРАРХІЧНОЮ СТРУКТУРОЮ ДАНИХ

Однією з тенденцій сучасної гірничої практики є освоєння родовищ з глибоким заляганням корисних копалин. Тому підвищення функціональної ефективності та безпеки експлуатації багатоканатних шахтних підйомних машин (ШПМ) є актуальною науково-технічною задачею. Складність розв'язання цієї задачі обумовлена тим, що автоматизована система керування ШПМ повинна виконувати велику кількість контрольних і

захисних функцій і забезпечувати керування потужним електроприводом при значній варіативності навантаження і при цьому підтримувати задану швидкість з великою точністю на всіх ділянках руху. На практиці підвищення надійності і довговічності устаткування, зменшення витрат електроенергії, збільшення продуктивності, а також контроль всіх технологічних параметрів, які впливають на робочий стан ШПМ, здійснюється за допомогою сучасних засобів автоматизації технологічного процесу. Оскільки підвищення техніко-економічних показників функціонування ШПМ суттєво залежить від функціональної ефективності автоматизованої системи керування, то основним перспективним напрямком досягнення цієї мети є надання системі властивості адаптивності шляхом застосування інтелектуальних інформаційних технологій аналізу даних. При цьому однією з важливих умов адаптивності автоматизованої системи керування ШПМ є наявність системи функціонального діагностування. Основним завданням системи функціонального діагностування є визначення безпосередньо в процесі експлуатації ШПМ тенденції відхилення динамічних характеристик її пристроїв від нормального технологічного режиму. За результатами функціонального діагностування дається оцінка залишкового ресурсу та видача рекомендацій про здійснення у разі необхідності компенсуючих заходів. Створення інтелектуальних автоматизованих систем керування ШПМ дозволяє застосовувати методи класифікаційного керування. Такі методи на відміну від традиційних дозволяють системі підтримки прийняття рішень створювати базу знань, оцінювати поточний функціональний стан технологічного процесу і за результатами його аналізу видавати оператору рекомендації щодо здійснення необхідних заходів з метою забезпечення високої функціональної ефективності системи керування.

Одним із перспективних шляхів підвищення функціональної ефективності автоматизованої системи керування ШПМ є надання їй інтелектуальної складової на основі машинного навчання та розпізнавання образів. Тому

розроблення високо достовірних вирішальних правил, побудованих за результатами машинного навчання, є актуальною задачею, розв'язанню якої присвячена стаття.

Аналіз літературних даних та постановка проблеми

В праці [1] показано, що переважна більшість систем діагностування ШПМ оцінюють технічний стан окремих елементів, підсистем і вузлів диференційовано, без взаємозв'язку з іншими підсистемами, що значно знижує точність діагностування. При цьому системи діагностування, як правило, не реалізують алгоритми постановки діагнозу технічного стану системи та її вузлів, а лише фіксують локальні прояви несправностей. У цьому випадку оцінку технічного стану ШПМ за сукупністю діагностичних параметрів здійснює оператор. Крім того, стаціонарні діагностуючі системи не враховують динамічні навантаження, які діють на робочі органи машини, що не дозволяє розв'язувати одну з головних задач діагностування – прогнозування технічного стану ШПМ. Як основний шлях усунення цих недоліків в працях [2 – 4] обґрунтовано доцільність застосування в тягових машинах функціонального діагностування, яке дозволяє в режимі реального часу за даними поточних вимірювань критичних параметрів ідентифікувати динамічні навантаження, відповідні їм динамічні режими роботи і технічний стан машини. Стратегія функціонального діагностування передбачає можливість проведення як повноцінного технічного обслуговування в процесі експлуатації ШПМ, так і планування профілактичних робіт, під час яких здійснюються необхідні ремонтні заходи з урахуванням реального стану обладнання та залишкових системних ресурсів. При цьому основні ускладнення підвищення ефективності функціональної діагностики обумовлені такими причинами [2]:

- неможливість отримання повної і об'єктивної інформації для прийняття адекватних рішень і обумовлена цією обставиною необхідність залучення неформальній (суб'єктивної, евристичної) інформації;

- наявність невизначеності у вихідних даних, а також присутність неоднозначності (багатоваріантності) процесу пошуку рішення;
- необхідність вироблення і обґрунтування рішень проблеми, що визначається за умови жорстких часових обмежень керованого технологічного процесу;
- необхідність коригування і введення додаткової інформації в процес пошуку рішень, інтерактивний характер логічного висновку рішень.

Врахування цих факторів вимагає відмови від традиційних методів і моделей прийняття діагностичних і керуючих рішень та перехід до технологій інтелектуального аналізу даних [5]. В працях [6, 7] для підвищення функціональної ефективності діагностичних систем розглядається застосування штучних нейронних мереж. Але оскільки при функціональному діагностуванні накопичується великий обсяг діагностичних ознак, які безперервно реєструються і мають відмінні значення на різних циклах тахограми функціонування ШПМ, то застосування штучних нейронних мереж на практиці є обмеженим через їх чутливість до багатовимірності простору ознак, що контролюються. Крім того, функціональне діагностування характеризується суттєвим перетином класів розпізнавання в просторі діагностичних ознак, що також зменшує достовірність класифікаційних рішень. Тому в праці [8] запропоновано при функціональному діагностуванні застосовувати нечіткі нейронні мережі. Такий підхід теж не вирішує для штучних нейронних мереж проблему багатовимірності простору діагностичних ознак. Крім того, застосування нечітких методів подання та виведення нових знань є обґрунтованим при якісних шкалах виміру діагностичних ознак. При кількісних шкалах виміру ознак доцільно використовувати більш ефективні і добре розвинені методи багатовимірного статистичного аналізу, приймаючи до уваги той факт, що функція належності Заде є аналогом функції щільності ймовірностей.

Одним із перспективних шляхів підвищення функціональної ефективності ШПМ є використання ідей і методів так званої інформаційно-екстремальної

інтелектуальної технології (ІЕІ-технології), яка ґрунтується на максимізації інформаційної спроможності системи керування в процесі її машинного навчання [9, 10]. У праці [11] досліджувалася у рамках ІЕІ-технології задача машинного навчання системи функціонального діагностування електроприводу ШПМ за неієрархічним (лінійним) алгоритмом, який не забезпечує високу достовірність діагностичних рішень при збільшенні потужності алфавіту класів розпізнавання. Тому актуальною задачею є підвищення функціональної ефективності системи функціонального діагностування ШПМ шляхом машинного навчання ха ієрархічною структурою даних.

Розглянемо формалізовану постановку задачі інформаційного синтезу здатної навчатися за ієрархічною структурою даних систему функціонального діагностування ШПМ. 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 -й страті. При цьому кожний клас розпізнавання характеризує несправність відповідного вузла ШПМ. За результатами періодичної реєстрації діагностичних ознак в процесі всіх технологічних циклів переміщення скіпа згідно з діаграмою швидкості 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 датчиків на всіх технологічних циклах роботи ШПМ. Таким чином, i -й стовпчик матриці $\| y_{m,i}^{(j)} \|$ містить значення навчальної вибірки, а j -й рядок є реалізацією з N діагностичними ознаками.

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

$$g_{h,s} = \langle x_{h,s,m}, d_{h,s,m}, \delta_{K,h,s,m,i} \rangle, \quad (1)$$

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

$$\bar{E}_{h,s} = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap G_d} E_{h,s,m}(d_{h,s,m}), \quad (2)$$

де $E_{h,s,m}(d_{h,s,m})$ – інформаційний критерій оптимізації параметрів машинного навчання системи функціонального діагностування 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 функціонального діагностування, прийняти класифікаційне рішення про належність поточного вектору-реалізації, що розпізнається, до одного із класів розпізнавання із заданої ієрархічної структури.

Мета та задачі дослідження

Проведені дослідження ставили за мету підвищення функціональної ефективності машинного навчання системи функціонального діагностування ШПМ за ієрархічною структурою даних.

Для досягнення поставленої мети вирішувалися такі завдання:

- розробити категорійну модель інформаційно-екстремального машинного навчання системи функціонального діагностування ШПМ за ієрархічною структурою даних;
- на основі категорійної моделі розробити алгоритм інформаційно-екстремального машинного навчання системи функціонального діагностування ШПМ за ієрархічною структурою даних;
- дослідити вплив контрольних допусків на функціональну ефективність машинного навчання системи функціонального діагностування ШПМ;

– здійснити порівняльний аналіз функціональної ефективності машинного навчання системи функціонального діагностування ШПМ за ієрархічною і лінійною структурами даних.

Матеріали та методи досліджень

Категорійна модель ієрархічного машинного навчання

Вхідний математичний опис системи функціонального діагностування ШПМ подамо у вигляді структури

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

де G – множина вхідних факторів; T – множина моментів часу зняття інформації; Ω – 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 ; $f_2 : Y \rightarrow X$ – оператор формування бінарної навчальної матриці X .

Категорійну модель машинного навчання системи функціонального діагностування ШПМ з ієрархічною структурою даних представимо у вигляді узагальненого орієнтованого графу (рис.1.28). При цьому ребрами такого графу є оператори, які відображають відповідні множини на інші, що застосовуються в процесі машинного навчання.




Рисунок 1.28– Категорійна модель ієрархічного навчання системи функціонального діагностування

На рис. 1.28 оператор θ відображає двійкові вектори-реалізації навчальної матриці X на розбиття \mathfrak{R}^{M_1} простору діагностичних ознак на класи розпізнавання, а оператор ψ 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 γ формує множину точнісних характеристик \mathfrak{Z}^{qI} , де $q = s^2$. Оператор ϕ 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 контрольних 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, яка в процесі навчання адаптується до високо достовірних вирішальних правил.

Таким чином, показана на рис. 1.28 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-множину E , елементи якої обчислюються на кожному кроці машинного навчання.

Інформаційний критерій оптимізації параметрів машинного навчання

Як критерій оптимізації параметрів машинного навчання в методах ІЕІ-технології може використовуватися будь-яка інформаційна статистична міра. Найбільшого поширення в рамках ІЕІ-технології знайшли ентропійні (за

Шенноном) критерії та інформаційна міра Кульбака. Для оптимізації параметрів машинного навчання розглянемо модифікований критерій Кульбака, який має вигляд [5]

$$E_{h,s,m}^{(k)} = \{2 - [\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)] \log_2 \left(\frac{2 - (\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d)) + 10^{-r}}{\alpha_{h,s,m}^{(k)}(d) + \beta_{h,s,m}^{(k)}(d) + 10^{-r}} \right)\}, \quad (3)$$

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 ; $\beta_m(d)$ – помилка другого роду при прийнятті класифікаційних рішень, обчислена в процесі відновлення гіперсферичного контейнера класу розпізнавання X_m^o з радіусом d ; 10^{-r} – достатньо мале число, яке вводиться для уникнення поділу на нуль ($1 < r \leq 3$).

Алгоритм машинного навчання системи функціонального діагностування

Згідно з категорійною моделлю (рис 1) інформаційно-екстремальний алгоритм навчання системи функціонального діагностування ШПМ з заданою ієрархічною структурою даних представимо у вигляді ітераційної процедури пошуку глобального максимуму усередненого за алфавітом $\{X_m^o\}$ інформаційного критерію (2) в робочій області визначення його функції

$$\delta_{K,h,s}^* = \arg \max_{G_{\delta,h,s}} \{ \max_{G_E \cap G_d} \bar{E}_{h,s}(d) \}, \quad (4)$$

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

Оцінка функціональної ефективності навчання системи функціонального діагностування ШПМ здійснюється за базовим інформаційно-екстремальним алгоритмом, який реалізується у внутрішньому циклі процедури (3).

Основними функціями базового алгоритму є обчислення на кожному кроці машинного навчання інформаційного критерію оптимізації (4), 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 міжцентрових відстаней для заданого алфавіту класів розпізнавання шляхом обчислення кодових відстаней між усередненими векторами-реалізаціями класів розпізнавання.
- б) пошук найближчого сусіда або k -найближчих сусідів шляхом визначення мінімальних кодових відстаней між центрами класів розпізнавання;

7) обчислення на кожному кроці навчання точнісних 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

$$d_{m,h,s}^* = \arg \max_{G_E \cap G_d} \bar{E}_{h,s}(d_{h,s,m}), m = \overline{1, M_{h,s}}, \quad (5)$$

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

10) ЗУПИН.

Розглянемо узагальнену схему ієрархічного алгоритму паралельної оптимізації контрольних допусків на діагностичні ознаки в рамках інформаційно-екстремального навчання системи функціонального діагностування ШПМ:

- 1) обнуління лічильника ярусів структури даних: $h := 0$;
- 2) ініціалізація лічильника ярусів структури даних: $h := h + 1$;
- 3) обнуління лічильника страт h -го ярусу ієрархічної структури: $s := 0$;
- 4) ініціалізація лічильника страт яруса: $s := s + 1$;
- 5) обнуління 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 (4) 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 -ї 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

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

за яким обчислюються оптимальні верхні $A_{HK_i}^*$ та нижні контрольні допуски для всіх діагностичних ознак:

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

(6)

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 (6) формується оптимальна бінарна навчальна матриця $\|x_{h,s,m,i}^{(j)}\|^*$ за правилом

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

12) формуються оптимальні усереднені вектори-реалізації класів розпізнавання $\{x_{h,s,m}^*\}$, 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

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

де $\rho_{h,s,m}$ – рівень селекції (квантування) координат усереднених двійкових векторів класів

розпізнавання s -ї страти h -го ярусу ієрархічної структури;

13) якщо $s \leq S_h$, то виконується пункт 4, інакше – пункт 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 функціонального діагностування ШПМ до її максимальної інформаційної спроможності, яка визначається інформаційним критерієм оптимізації параметрів навчання.

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

$$(\forall X_m^o \in \mathfrak{R}^{(M)}) (\forall x^{(j)} \in \mathfrak{R}^{(M)}) \{ \text{if } [(\mu_m > 0) \& (\mu_m = \max_{\{m\}} \{ \mu_m / m = \overline{1, M} \})] \text{ then } x^{(j)} \in X_m^o \}, \quad (7)$$

де $x^{(j)}$ – вектор-реалізація, що розпізнається; μ_m – функція належності вектора $x^{(j)}$ гіперсферичному контейнеру класу розпізнавання X_m^o , яка визначається за формулою

$$\mu_m = 1 - \frac{d(x^{(j)} \oplus x_{h,s,m}^*)}{d_{h,s,m}^*}. \quad (8)$$

Таким чином, вектор-реалізація, що розпізнається, відноситься до того класу із заданого алфавіту відповідної страти ієрархічної структури, для якого функція належності (8) максимальна і є додатною.

Результати реалізації ієрархічного алгоритму машинного навчання системи функціонального діагностування ШПМ

Реалізація розглянутого вище алгоритму здійснювалася на прикладі машинного навчання системи функціонального діагностування вузлів ШПМ. Навчальна матриця була сформована за архівними даними, наданими підприємством «УЛІС Системс», яке займається модернізацією системи керування ШПМ в «ДТЕК Павлоградвугілля» (м. Павлоград, Україна). Для наочності діагностування здійснювалося для чотирьох класів розпізнавання: клас X_1^o характеризував функціональний стан електроприводу «Норма», клас X_2^o – стан підвищеної температури підшипників електродвигуна, клас X_3^o – стан тормозних колодок «Норма» і клас X_4^o – радіуси канавок канатоведучих шківів, які відповідали функціональному стану «Більше норми».

Для кожного із заданих класів розпізнавання за архівними даними були сформовані вхідні навчальні матриці. Кожний рядок матриці – вектор-реалізація відповідного класу розпізнавання складався із 60 структурованих кількісних і категорійних діагностичних ознак, які характеризували електричні, температурні та механічні характеристики вузлів ШПМ. Як діагностичні ознаки, які характеризують технічний стан обладнання, розглядалися рівень шуму, вібрація, час експлуатації обладнання, зменшення запасу міцності, збільшення діаметра отвору в зоні підвісного пристрою, знос шийки вала, температура масла, тиск повітря, вміст механічних домішок в маслі, суцільність металу, сумарний зазор в шарнірному з'єднанні, зміна радіуса органу навивки, знос провідника, ширина провідників, зазор між контактними поверхнями провідників, вимір в горизонтальній площині на двох суміжних ярусах, величина площадки на стиках провідників, товщина металу трубопроводів, різниця натягів головних канатів багатоканатних

підйомних установок, пошкодження канатів, характер руху стрілок контрольно-вимірювальних приладів тощо.

На рис. 1.29 показано графіки залежності інформаційного критерію (3) від радіусів контейнерів класів розпізнавання, одержані в процесі реалізації базового алгоритму машинного навчання системи функціонального діагностування ШПМ для лінійної структури даних ($h=1$ і $s=1$).

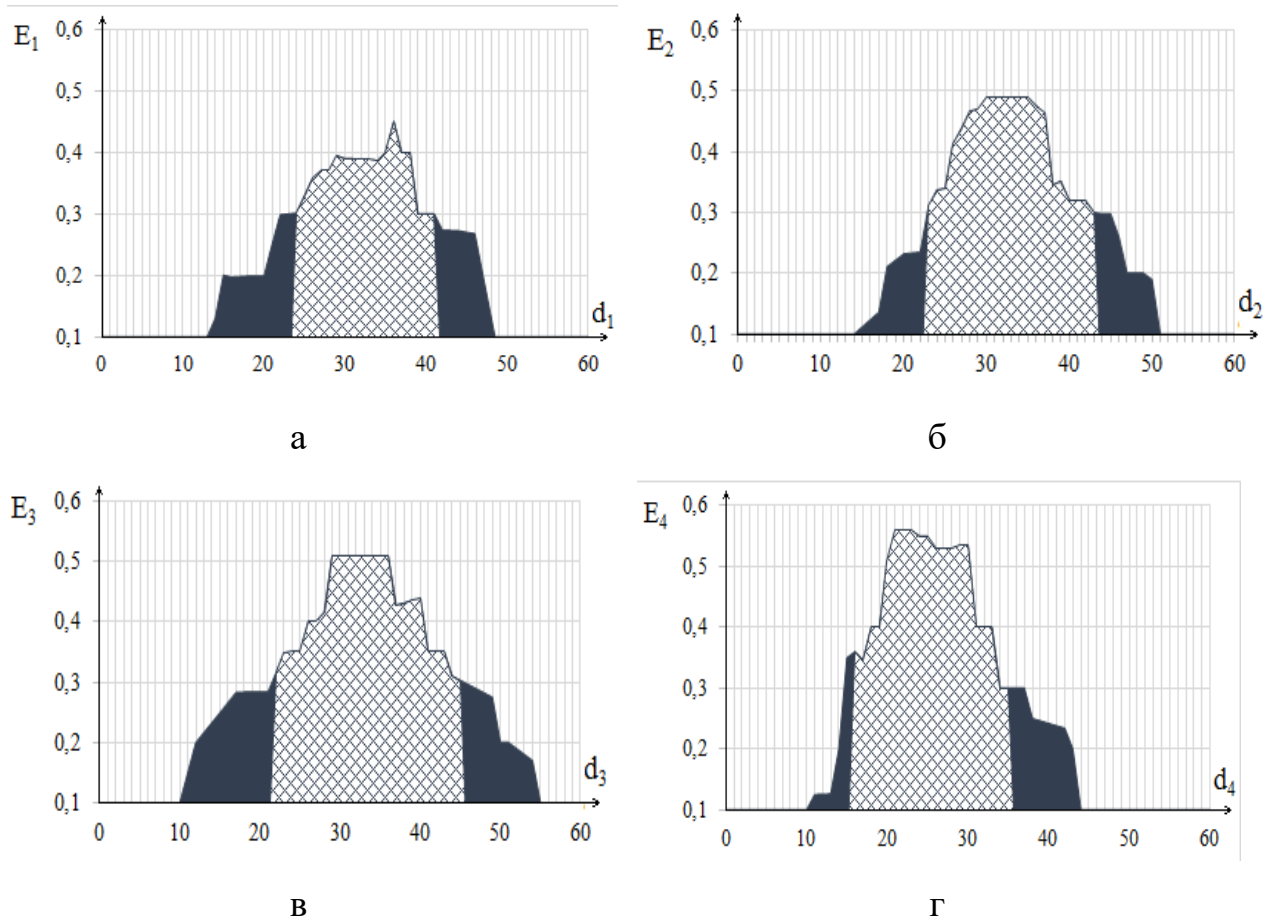


Рис. 1.29 Графіки залежності інформаційного критерію від радіусів контейнерів класів розпізнавання: *а* – клас X_1^o ; *б* – клас X_2^o ; *в* – клас X_3^o ; *г* – клас X_4^o

На рис. 1.29 подвійною штриховкою позначено робочі області визначення функції критерію, в якій точнісні характеристики приймають допустимі значення: $D_{1,m} > 0,5$ і $\beta_m < 0,5$. Аналіз рис. 1.29 показує, що максимальне значення критерію (5) для класу X_1^o дорівнює $E_1^* = 0,42$, для класу X_2^o –

$E_2^* = 0,49$, для класу X_3^o – $E_3^* = 0,51$ і для класу X_4^o – $E_4^* = 0,56$. Таким чином, середнє значення інформаційного критерію оптимізації параметрів машинного навчання дорівнює $\bar{E} = 0,49$.

На рис.1.30 показано графік залежності усередненого за алфавітом класів розпізнавання інформаційного критерію (3) від параметра δ поля контрольних допусків, одержаний в процесі реалізації наведеного вище алгоритму паралельної оптимізації системи контрольних допусків на діагностичні ознаки.




Рисунок 1.30 –Графік залежності інформаційного критерію від параметра поля контрольних допусків на діагностичні ознаки для лінійної структури даних

Аналіз рис. 1.30 показує, що усереднений критерій після проведення паралельної оптимізації контрольних допусків досягає свого максимального значення $\bar{E}^* = 0,63$ при оптимальному значенні параметра поля допусків $\delta^* = \pm 34\%$ від номінальних значень діагностичних ознак.

Для побудови вирішальних правил, що є метою машинного навчання, при реалізації алгоритму паралельної оптимізації контрольних допусків на діагностичні ознаки було визначено оптимальні радіуси контейнерів класів розпізнавання, що відновлювалися в процесі навчання в радіальному базисі простору діагностичних ознак.

На рис 1.31. показано графіки залежності інформаційного критерію (3) від радіусів контейнерів класів розпізнавання, одержані в процесі реалізації алгоритму паралельної оптимізації контрольних допусків на діагностичні

ознаки розпізнавання при оптимальному параметрі поля контрольних допусків.




Рисунок 1.31 –Графіки залежності інформаційного критерію від радіусів контейнерів:

a – клас X_1^o ; *б* – клас X_2^o ; *в* – клас X_3^o ; *г* – клас X_4^o

Аналіз рис. 1.31 показує, що оптимальні радіуси контейнерів класів розпізнавання дорівнюють $d_1^* = 35$ для класу X_1^o ; $d_2^* = 34$ для класу X_2^o ; $d_3^* = 34$ для класу X_3^o і $d_4^* = 23$ для класу X_4^o .

Реалізація алгоритму машинного навчання здійснювалася за ієрархічною структурою даних, показану на рис. 1.32.




Рисунок 1.32– Ієрархічна структура даних

На рис. 1.33 показано графік залежності усередненого за алфавітом класів розпізнавання для першого ярусу ієрархічної структури (рис. 1.32) інформаційного критерію (3) від параметра δ поля контрольних допусків, одержаний при паралельній оптимізації системи контрольних допусків на діагностичні ознаки.




Рисунок 1.33– Графік залежності інформаційного критерію від параметра поля контрольних допусків на діагностичні ознаки для першого ярусу ієрархічної структури

На рис.1.34 показано графік залежності усередненого за алфавітом класів розпізнавання першої страти другого ярусу ієрархічної структури (рис. 1.35) інформаційного критерію (3) від параметра δ поля контрольних допусків, одержаний в процесі паралельної оптимізації системи контрольних допусків на діагностичні ознаки.




Рисунок 1.34 –Графік залежності усередненого інформаційного критерію від параметра поля контрольних допусків для першої страти другого ярусу ієрархічної структури

Аналіз рис. 1.34 показує, що максимальне значення усередненого за алфавітом класів розпізнавання першої страти другого ярусу інформаційного критерію дорівнює $\bar{E}^* = 0,68$.

На рис. 1.35 показано графіки залежності критерію (3) від радіусів контейнерів класів розпізнавання першої страти другого ярусу ієрархічної структури, одержані в процесі паралельної оптимізації контрольних допусків на діагностичні ознаки.




Рисунок 1.35 –Графіки залежності інформаційного критерію від радіусів контейнерів класів розпізнавання першої страти другого ярусу ієрархічної структури:

а – клас X_1^o ; *б* – клас X_3^o

Аналіз рис. 1.35 показує, що оптимальні радіуси контейнерів дорівнюють: для класу X_1^o — $d_1^* = 34$ і для класу X_3^o — $d_3^* = 32$.

На рис. 1.36 показано графік залежності усередненого за алфавітом класів розпізнавання другої страти другого ярусу ієрархічної структури (рис. 1.36) інформаційного критерію (3) від параметра δ поля контрольних допусків, одержаний в процесі паралельної оптимізації системи контрольних допусків на діагностичні ознаки.




Рисунок 1.36. –Графік залежності усередненого інформаційного критерію від параметра поля контрольних допусків для другої страти другого ярусу ієрархічної структури

Аналіз рис. 1.36 показує, що максимальне значення усередненого для алфавіту класів розпізнавання другої страти другого ярусу ієрархічної структури інформаційного критерію дорівнює $\bar{E}^* = 0,76$. Таким чином, середнє значення інформаційного критерію оптимізації параметрів навчання для заданого алфавіту класів розпізнавання дорівнює $\bar{E}^* = 0,72$, що перевершує його значення, отримане для лінійного класифікатора (рис. 1.36).

На рис. 1.37 показано графіки залежності критерію (3) від радіусів контейнерів класів розпізнавання другої страти другого ярусу ієрархічної структури, одержані в процесі паралельної оптимізації контрольних допусків на діагностичні ознаки.

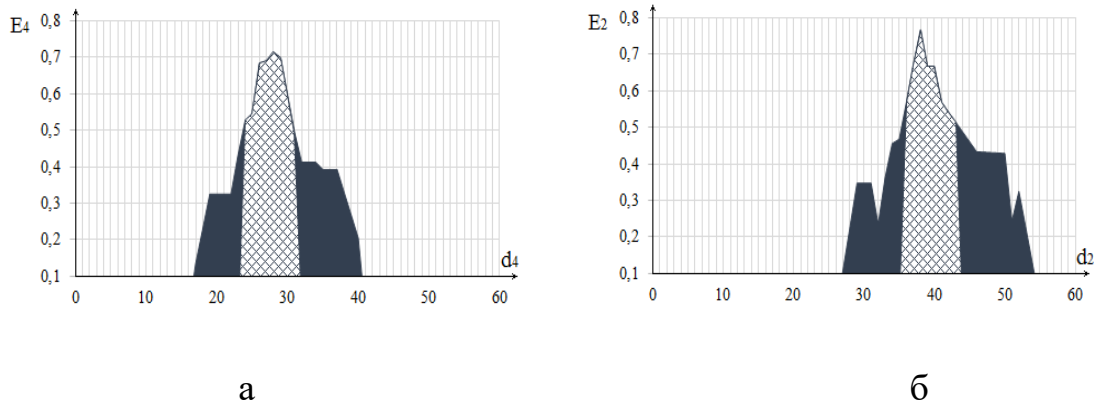


Рисунок 1.37– Графіки залежності інформаційного критерію від радіусів контейнерів класів розпізнавання: *a* – клас X_2^o ; *б* – клас X_4^o

Аналіз рис. 1.37 показує, що оптимальні радіуси контейнерів дорівнюють: для класу X_2^o – $d_{12}^* = 26$ і для класу X_4^o – $d_4^* = 38$.

Обговорення результатів

Оцінка функціональної ефективності інформаційно-екстремального машинного навчання системи функціонального діагностування ШПМ здійснювалася для лінійної та ієрархічної структур даних. При цьому досліджувався вплив контрольних допусків на повну ймовірність правильного діагностування технічного стану вузлів ШПМ. Спочатку було реалізовано машинне навчання системи функціонального діагностування за базовим інформаційно-екстремальним алгоритмом для лінійної структури даних чотирьох класів розпізнавання, які характеризували діагностичні стани відповідних вузлів ШПМ. Аналіз отриманих результатів показав недостатньо високу функціональну ефективність машинного навчання, що підтверджується згідно з рис. 1.34 відносно низьким середнім значенням інформаційного критерію (3) оптимізації параметрів навчання. В першу чергу, цей факт можна пояснити тим, що система контрольних допусків на діагностичні ознаки апіорно була не оптимальною в інформаційному розумінні. Тому було реалізовано алгоритм інформаційно-екстремального машинного навчання з оптимізацією контрольних допусків на діагностичні ознаки. В цьому випадку, як показує аналіз рис. 1.34 і рис. 1.35, вдалося

підвищити максимальне значення усередненого за алфавітом класів розпізнавання інформаційного критерію оптимізації параметрів навчання. Але отриманий результат так само можна вважати недостатньо високим. Пояснення цього факту полягає в тому, що збільшення потужності алфавіту класів розпізнавання призводить до збільшення ступеню їх перетину в просторі діагностичних ознак. Це в свою чергу збільшує помилки першого і другого роду, які безпосередньо зменшують максимальне значення інформаційного критерію оптимізації параметрів машинного навчання.

З метою зменшення впливу багатовимірності алфавіту класів розпізнавання на функціональну ефективність інформаційно-екстремального машинного навчання було реалізовано алгоритм (4) паралельної оптимізації контрольних допусків на діагностичні ознаки за ієрархічною структурою даних, показаною на рис. 5. Аналіз наведених на рис. 6 – 10 результатів машинного навчання за ієрархічною структурою даних показав, що максимальне значення інформаційного критерію вдалося підвищити у порівнянні із лінійним класифікатором. Такий результат отримано через зменшення ступеня перетину класів розпізнавання шляхом їх поділу на страти відповідного ярусу ієрархічної структури.

При застосуванні вирішальних правил (7), побудованих в процесі ієрархічного інформаційно-екстремального навчання за процедурою (4), повна ймовірність правильного розпізнавання векторів-реалізацій дорівнювала $P_i = 0,91$ для класу X_1^o , $P_i = 0,89$ для класу X_2^o , $P_i = 0,92$ для класу X_3^o і $P_i = 0,94$ для класу X_4^o , що для функціонального діагностування є достатньо високими показниками.

Висновки

Розроблено новий метод ієрархічного інформаційно-екстремального машинного навчання системи функціонального діагностування ШПМ з ієрархічною структурою даних, який дозволяє підвищити достовірність діагностування та зменшити чутливість системи до збільшення потужності алфавіту класів розпізнавання. У рамках розробленого методу запропоновано

категорійну модель інформаційно-екстремального машинного навчання з ієрархічною структурою даних, яка є композицією контурів оптимізації параметрів навчання за інформаційним критерієм. Згідно з категорійною моделлю розроблено алгоритм інформаційно-екстремального ієрархічного машинного навчання, який полягає в ітераційному наближенні усередненого за алфавітом класів розпізнавання значення інформаційного критерію оптимізації параметрів навчання до максимального граничного.

Порівняльний аналіз інформаційно-екстремального машинного навчання за лінійною та ієрархічною структурами даних показав, що ієрархічне навчання забезпечує більш високу достовірність діагностування через зменшення ступеня перетину класів розпізнавання шляхом їх поділу на страти відповідного ярусу ієрархічної структури.

У перспективі при розширенні потужності алфавіту класів розпізнавання для побудови безпомилкових за навчальною вибіркою вирішальних правил необхідно збільшувати глибину машинного навчання шляхом розгляду додаткових параметрів оптимізації.

1.8 БОРТОВА ГЕОІНФОРМАЦІЙНА СИСТЕМА ІДЕНТИФІКАЦІЇ КАДРІВ

Широке використання бортових геоінформаційних систем (ГІС) літальних апаратів за спостереженням поверхні Землі дозволяє розв'язувати багато важливих задач для соціально-економічної сфери суспільства. Однією із важливих задач бортової ГІС є сегментація місцевості з метою локалізації об'єкту спостереження. Ця задача може розв'язуватися, наприклад, при пошуку транспортного засобу, при спостереженні за станом посівів агрокультур, у природоохоронній діяльності тощо.

Складність розв'язання цієї задачі полягає в довільних початкових умовах формування зображень об'єкту, що розпізнається, обумовлених різними ракурсами аерофотозйомки, висотами літального апарату, положенням і

орієнтацією об'єкту в кадрі електронної карти місцевості тощо. Це вимагає високої обчислювальної потужності бортової ЕОМ і накладає на систему жорсткі вимоги щодо достовірності та оперативності рішень, що приймаються. Тому важливого значення для підвищення функціональної ефективності бортової ГІС набуває задача визначення зони інтересу, в якій очікується знаходження об'єкту, що розшукується. При пошуку транспортного засобу такою зоною інтересу в першу чергу слід розглядати транспортні магістралі на місцевості, а у випадку негативного результату переходити до розпізнавання об'єктів у інших зонах інтересу.

Таким чином, актуальною задачею при сегментації місцевості є забезпечення інваріантності вирішальних правил до положення та орієнтації об'єктів в кадрах електронної карти місцевості.

Найбільш поширеним шляхом розв'язання задачі автоматичної сегментації місцевості є застосування методів кластер-аналізу [1, 2]. Побудовані кластери в подальшому ідентифікуються безпосередньо бортовою ГІС шляхом порівняння з накопиченими в базі даних еталонами. Якщо при великій кількості кластерів необхідна оперативність ідентифікації об'єкту досягається шляхом застосування сучасних потужних бортових комп'ютерів, то точність кластеризації суттєво залежить від початкових умов сегментації та перетину кластерів, що має місце на практиці. Тому одним із перспективних шляхів підвищення точності сегментації місцевості є застосування ідей і методів машинного навчання і розпізнавання образів. При цьому найбільшого поширення при інтелектуальному аналізі даних отримали методи, що базуються на штучних нейронних мережах [3]. Основний недолік більшості відомих методів технології Data Mining, включаючи штучні та імунні мережи, пов'язаний із їх чутливістю до багатовимірності словника ознак розпізнавання і алфавіту класів розпізнавання. Особливо актуальним усунення цього недоліку є в задачах розпізнавання нестационарних за яскравістю зображень, що має, наприклад, місце при розпізнаванні об'єктів на місцевості.

Одним з перспективних підходів до аналізу та синтезу бортових ГІС розпізнавання об'єктів шляхом попередньої сегментації електронної карти місцевості є використання ідей та методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технологія), що ґрунтується на максимізації інформаційної спроможності системи в процесі її машинного навчання [4, 5]. У праці [6] в рамках ІЕІ-технології розглядалася задача сегментації електронної карти місцевості бортовою ГІС безпілотного літального апарату. При цьому побудовані в процесі машинного навчання вирішальні правила не забезпечили високу повну ймовірність правильної ідентифікації кадрів зображення. Причина такого результату полягає в тому, що зображення кадрів розглядалися як текстура і оброблялися відповідно в декартовій системі координат. Це не дозволило забезпечити інваріантність вирішальних правил при ідентифікації кадрів, які містили, наприклад, довільно орієнтовані фрагменти автомагістралі.

У статті розглядається алгоритм інформаційно-екстремального машинного навчання бортової ГІС за навчальними матрицями, сформованими при обробленні кадрів електронної карти місцевості в полярній системі координат.

Розглянемо формалізовану постановку інформаційно-екстремального машинного навчання бортової ГІС за навчальною матрицею, сформованою за результатами оброблення кадрів електронної карти місцевості. Нехай електронна карта місцевості розбивається на k кадрів, серед яких формується алфавіт $\{X_m^o \mid m = \overline{1, M}\}$ класів розпізнавання. До кожного класу розпізнавання відносяться кадри, які характеризують різні зони інтересу. Для заданого алфавіту класів розпізнавання сформовано навчальну матрицю $\|y_{m,i}^{(j)}\|$ яскравості пікселів рецепторного поля кадрів. В навчальній матриці рядок $\{y_{m,i}^{(j)} \mid i = \overline{1, N}\}$, де N – кількість ознак розпізнавання, є вектором-реалізацією m -го кадру, а стовпчик матриці – випадкова навчальна вибірка $\{y_{m,k,i}^{(j)} \mid j = \overline{1, n}\}$ з

обсягом n . Крім того, для кожного класу розпізнавання X_m^o задано структурований вектор параметрів навчання

$$g_m = \langle \delta; d_m, x_m \rangle, \quad (1)$$

де δ – параметр симетричного поля контрольних допусків на ознаки розпізнавання; d_m – радіус гіперсферичного контейнера класу розпізнавання X_m^o , який відновлюється в радіальному базисі бінарного простору ознак; x_m – усереднений двійковий вектор-реалізація класу розпізнавання X_m^o .

У виразі (1) параметр машинного навчання δ дорівнює половині симетричного поля контрольних допусків на ознаки розпізнавання.

На області значень параметрів навчання накладаються такі обмеження:

– область значень параметра δ_i задається нерівністю

$$\delta_i < \delta_{H,i} / 2,$$

де $\delta_{H,i}$ – нормоване поде допусків на i -ту ознаку розпізнавання, яке визначає область значень параметра δ_i ;

– область значень яскравості пікселів рецепторного поля зображення кадру знаходиться в інтервалі $[0; 255]$ градацій яскравості;

– область значень радіуса контейнера класу розпізнавання X_m^o задається нерівністю

$$d_m < d(x_m \oplus x_c),$$

де $d(x_m \oplus x_c)$ – міжцентрова відстань між вектором-реалізацією $x_m \in X_m^o$ і усередненим вектором-реалізацією x_c сусіднього (найближчого) класу X_c^o .

В процесі машинного навчання ПС необхідно:

1) оптимізувати координати вектора (1), які забезпечують максимальне значення усередненого за алфавітом класів розпізнавання інформаційного критерію оптимізації параметрів машинного навчання

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap \{k\}} E_m^{(s)}, \quad (2)$$

де $E_m^{(k)}$ – обчислене на k -му кроці навчання значення інформаційного критерію оптимізації параметрів машинного навчання системи розпізнавати реалізації класу x_m^o ; G_E – область допустимих значень функції інформаційного критерію; $\{k\}$ – впорядкована множина кроків навчання;

2) за оптимальними геометричними параметрами контейнерів класів розпізнавання побудувати вирішальні правила.

При оптимізації параметрів машинного навчання необхідно врахувати, що пошук глобального максимуму інформаційного критерію (2) здійснюється в робочій (допустимій) області визначення його функції. Оскільки інформаційний критерій (2) є функціоналом від точнісних характеристик, то робоча область визначення його функції для двох альтернативних рішень характеризується достовірностями першого і другого роду, які приймають значення більше 0,5.

При функціонуванні бортової ГІС в режимі екзамену необхідно за побудованими на етапі машинного навчання вирішальними правилами ідентифікувати кадри з метою визначення зони інтересу на місцевості..

Таким чином, задача інформаційного синтезу здатної навчатися бортової ГІС сегментації місцевості полягає в оптимізації параметрів її машинного навчання шляхом наближення глобального максимуму інформаційного критерію (2) до його максимального граничного значення, яке обчислюється в робочій області визначення функції критерію.

Матеріали та методи

Розглянемо в рамках ІЕІ-технології основні етапи машинного навчання бортової ГІС з метою ідентифікації кадрів електронної карти місцевості.

Вхідними даними для алгоритму інформаційно-екстремального машинного навчання бортової ГІС є тривимірний масив навчальної матриці, елементи якого характеризують яскравість пікселів рецепторного поля. Крім навчальної матриці вхідний математичний опис здатної навчатися бортової ГІС повинен включати алфавіт класів розпізнавання, які характеризують відмінні кадри електронної карти місцевості, і словник ознак розпізнавання.

На етапі формування вхідного математичного опису бортової ГІС було сформовано три класи розпізнавання, які характеризували відповідні зони інтересу: клас x_1^o – поле, клас x_2^o – ліс і клас x_3^o – автомагістраль. Потужність словника ознак розпізнавання визначалася розміром рецепторного поля кадру електронної карти місцевості.

На рис. 1 показано кадри зображення місцевості, отриманого за результатами аеророзвідки.



Рисунок 1.38– Кадри зображення місцевості: а – поле; б – ліс; в – автомагістраль

Зображення кадрів електронної карти місцевості, показані на рис. 1.38а і рис. 1.38 б, є стаціонарними за яскравістю і відносяться до типу “текстура”. Зображення кадру, показаного на рис. 1.38в, є нестаціонарним за яскравістю, оскільки містить у загальному випадку довільно орієнтований об’єкт – автомагістраль.

З метою забезпечення інваріантності вирішальних правил до зсуву і повороту об'єктів в кадрі формування вхідної навчальної матриці здійснювалося шляхом оброблення зображень кадрів полярній системі координат. При цьому усереднена яскравість пікселів кожного кола зчитування, побудованого навколо геометричного центру кадру розміром 100×100 пікселів, обчислювалася за формулою [5]

$$\Theta_j = \frac{1}{N_j} \sum_{i=1}^{N_j} \theta_i \quad (3)$$

де Θ_j – усереднене значення яскравості пікселів, які входять у коло зчитування j -го радіусу, $j = \overline{0, R}$; θ_i – значення яскравості RGB-складової в i -му пікселі рецепторного поля зображення кадру; N_j – загальна кількість пікселів в j -му колі зчитування; R – радіус кола зчитування.

На рис. 1.39 показано одержані за формулою (3) вхідні RGB-криві яскравості пікселів зображення кадру класу розпізнавання X_3^o – фрагмент автомагістралі

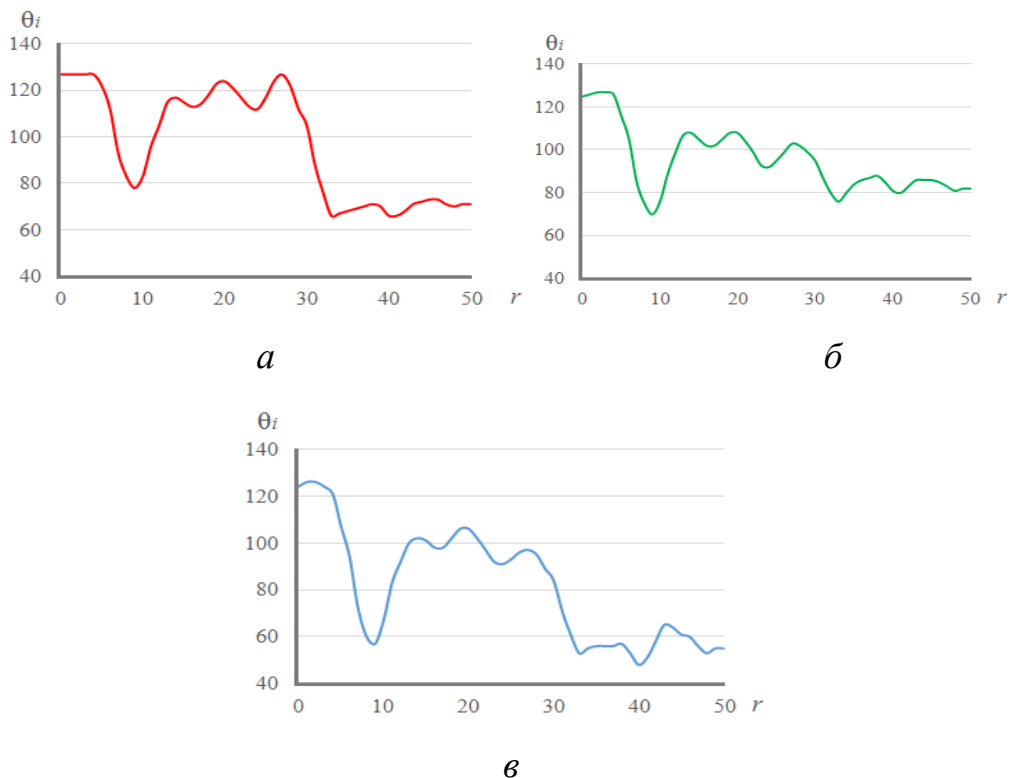


Рисунок 1.39– Криві яскравості RGB- складових кадру класу x_3^o : : *a* – червона складова; *б* – зелена складова; *в* – синя складова

За одержаними в процесі квантування за радіусом кола зчитування дискретами RGB -кривих яскравості були сформовані структуровані вектори-реалізації вхідної навчальної матриці для показаних на рис. 1.38 кадрів зображення. Таким чином, як ознаки розпізнавання розглядалися дискрети квантованих RGB -кривих. При цьому структура вектора-реалізації складалася із послідовності ознак розпізнавання всіх RGB -складових зображення кадра.

Алгоритм навчання ГІС з оптимізацією системи контрольних допусків на ознаки розпізнавання було реалізовано у вигляді двохциклічної процедури пошуку глобального максимуму інформаційного критерію (2) в робочій області визначення його функції

$$\delta^* = \arg \max_{G_\delta} \left[\frac{1}{M} \sum_{m=1}^M \max_{G_{Em} \cap \{k\}} E_m^{(k)} \right], \quad (4)$$

де $E_m^{(k)}$ – інформаційний критерій оптимізації параметрів навчання системи розпізнавати вектори-реалізації класу X_m^o ; G_δ – допустима область значень параметра δ поля контрольних допусків на ознаки розпізнавання; G_{Em} – робоча (допустима) область визначення критерію $E_m^{(k)}$; $\{k\}$ – множина кроків навчання, на яких змінювалися радіуси гіперсферичних контейнерів класів розпізнавання.

Як інформаційний критерій оптимізації параметрів машинного навчання розглядалася модифікована міра Кульбака, яка для двохальтернативних рішень з апіорно рівноймовірними гіпотезами має вигляд

$$E_m^{(k)} = [D_{1,m}^{(k)} - \beta_m^{(k)}] \times \log_2 \left[\frac{1 + [D_{1,m}^{(k)} - \beta_m^{(k)}] + 10^{-r}}{1 - [D_{1,m}^{(k)} - \beta_m^{(k)}] + 10^{-r}} \right], \quad (5)$$

де $D_{1,m}^{(k)}$ – перша достовірність, яка характеризує ймовірність правильної класифікації вектора-реалізації класу X_m^o ; $\beta_m^{(k)}$ – помилка другого роду, яка

характеризує помилкове віднесення до класу X_m^o ; вектора-реалізації найближчого сусіднього класу; 10^{-r} – достатньо мале число, яке вводиться для уникнення поділу на нуль.

У формулі (5) величина r дорівнює кількості знаків мантиси інформаційного критерію і на практиці вибирається в інтервалі $1 < r \leq 3$.

За отриманими в процесі машинного навчання оптимальними геометричними параметрами контейнерів класів розпізнавання побудовано вирішальні правила для ідентифікації кадрів зображення місцевості при функціонуванні ГІС в режимі екзамену. Для гіперсферичних контейнерів класів розпізнавання вирішальні правила мають вигляд

$$(\forall X_m^o \in \mathfrak{R}^{|M|})(x^{(j)} \in \mathfrak{R}^{|M|}) \{if (\mu_m > 0) \& \& \mu_m = \max(\mu_1, \dots, \mu_M)\} then x^{(j)} \in X_m^o\}, \quad (6)$$

де $x^{(j)}$ – вектор-реалізація, що розпізнається; μ_m, μ_c функції належності вектора-реалізації, що розпізнається, контейнерам сусідніх (найближчих) класів розпізнавання X_m^o і X_c^o відповідно.

У випадку гіперсферичних контейнерів класів розпізнавання функції належності у виразі (6) відповідно можуть мати вигляд

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

де x_c – усереднений вектор-реалізація найближчого сусіднього класу розпізнавання X_c^o ; d_m^*, d_c^* – отримані в процесі машинного навчання оптимальні радіуси контейнерів класів розпізнавання X_m^o і X_c^o відповідно.

Одержані на етапі екзамену результати порівнювалися із результатами ідентифікації аналогічних кадрів, наведеними в праці [6]. Наприклад, за результатами екзамену повна ймовірність правильної ідентифікації кадру класу X_3^o (фрагмент автомагістралі) дорівнювала $P_i = 0,96$ проти $P_i = 0,83$, отриманої в праці [6]. При цьому достовірності ідентифікації кадрів інших

класів розпізнавання практично не відрізнялися, оскільки їх зображення відносяться до типу “текстура”.

1.9 ОЦІНКА ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ СИСТЕМИ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ, ЩО НАВЧАЄТЬСЯ

Одним із перспективних напрямів підвищення функціональної ефективності систем підтримки прийняття рішень (СППР) є надання їм властивості адаптивності на основі машинного навчання та розпізнавання образів [1-3]. При цьому важливого значення набуває задача оцінки функціональної ефективності навчання СППР, яка дозволяє визначити максимальні асимптотичні точнісні характеристики системи на етапі екзамену, тобто безпосереднього прийняття рішень в робочому режимі. В працях [1-3] ця задача розв’язується шляхом введення мінімально-максимальних дистанційних критеріїв, що за умови апріорно нечіткого розбиття класів розпізнавання не дозволяє побудувати безпомилкові за навчальною матрицею вирішальні правила. В працях [4-6] для оцінки функціональної ефективності системи запропоновано обчислювати в процесі її навчання точнісні характеристики, що вимагає для забезпечення їх статистичної стійкості та однорідності наявності навчальних вибірок достатньо великих обсягів. Для усунення вказаних недоліків оцінки функціональної ефективності машинного навчання перспективним є застосування ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології), що ґрунтується на максимізації інформаційної спроможності інтелектуальної системи, що навчається [7,8]. В праці [9] запропоновано модифіковані критерії функціональної ефективності (КФЕ) машинного навчання на основі ентропійного (за Шенноном) критерію і міри Кульбака для двохальтернативної системи оцінок рішень.

В статті розглядається побудова КФЕ навчання СППР для трьохальтернативної системи оцінок рішень і аналізується доцільність його використання у порівнянні з двоохальтернативним.

ФОРМАЛІЗОВАНА ПОСТАНОВКА ЗАДАЧІ

Розглянемо здатну навчатися СППР, яка є складовою частиною інтелектуальної КСД. Нехай дано алфавіт класів розпізнавання $\{X_m^o \mid m = \overline{1, M}\}$, що характеризують функціональні стани патологічного процесу, і навчальну багатовимірну матрицю типу «об'єкт-властивість» $\|y_{m,i}^j \mid i = \overline{1, N}, j = \overline{1, n}\|$, де N, n – кількість діагностичних ознак та векторів-реалізацій образу відповідно. Відомо структурований вектор $g = \langle g_1, \dots, g_\xi, \dots, g_\Xi \rangle$ параметрів функціонування, що впливають на функціональну ефективність СППР, та його обмеження $R_\xi(g_1, \dots, g_\Xi) \leq 0$.

Необхідно в процесі навчання СППР оптимізувати значення координат вектора g , забезпечивши максимум усередненого за алфавітом $\{X_m^o\}$ інформаційного критерію функціональної ефективності (КФЕ) навчання СППР

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{\{k\}} E_m, \quad (1)$$

де E_m – КФЕ навчання СППР розпізнавати реалізації класу X_m^o ; $\{k\}$ – впорядкована множина кроків розпізнавання.

В режимі екзамену необхідно прийняти рішення про належність реалізації образу, що розпізнається, до одного із класів алфавіту $\{X_m^o\}$.

АЛГОРИТМ НАВЧАННЯ СППР

Ідея алгоритму навчання у рамках ІЕІ-технології полягає в оптимізації координат вектора параметрів навчання g шляхом пошуку максимального значення критерію (1) в робочій (допустимій) області його визначення. При цьому як параметри навчання СППР виступають параметри, що впливають

на геометричну форму контейнерів класів розпізнавання, що відновлюються в радіальному базисі бінарного простору ознак, та параметри, що впливають на топологію розподілу реалізацій образів.

Розглянемо алгоритм навчання СППР у рамках ІЕІ-технології за двоциклічною ітераційною процедурою оптимізації параметра δ поля контрольних допусків на ознаки розпізнавання

$$\delta^* = \arg \langle \max_{G_\delta} \{ \max_{\{k\}} \bar{E} \} \rangle, \quad (2)$$

де G_δ – область допустимих значень контрольних допусків на ознаки розпізнавання.

При цьому відновлення оптимальних контейнерів класів розпізнавання відбувається шляхом визначення для базового класу x_i^o оптимальної системи контрольних допусків (СКД) за процедурою (2) при одночасній зміні параметра δ для всіх діагностичних ознак розпізнавання.

Вхідними даними алгоритму навчання СППР є навчальна матриця та системи нормованих допусків $\{\delta_H\}$, що визначає область значень відповідних контрольних допусків на ознаки розпізнавання. За область значень параметра δ приймається інтервал $[0; \delta_H / 2]$.

Розглянемо основні етапи реалізації алгоритму (2):

1. Обнулюється лічильник кроків зміни параметра δ : $l := 0$.
2. Ініціалізується лічильник: $l := l + 1$ та обчислюються нижні $A_{HK_i}[l]$ і верхні $A_{BK_i}[l]$ контрольні допуски для всіх ознак розпізнавання одночасно:

$$A_{HK_i}[l] = y_{1,i} - \delta \frac{\delta_{H_i}}{100}; \quad A_{BK_i}[l] = y_{1,i} + \delta \frac{\delta_{H_i}}{100}, \quad (3)$$

де $y_{1,i}$ – i -та ознака еталонного вектора-реалізації y_1 базового класу x_1^o , що характеризує найбільш бажаний для особи, що приймає рішення, функціональний стан СППР.

3. Для кожного m -го класу розпізнавання x_m^o виконується процедура пошуку глобального максимуму КФЕ в робочій області визначення його функції: $E_m^*[l] := \text{extrem}_{\{d\}} E_m[l, d]$, де $\{d\}$ – множина радіусів концентрованих

гіперсфер, центр яких визначається еталонною вершиною x_m класу розпізнавання x_m^o , та визначається оптимальний радіус контейнера: $d_m^* := \arg \text{extrem}_{\{d\}} E_m[l, d]$;

4. Якщо $\delta \leq \delta_H / 2$, то виконується п. 2, інакше п. 5.

5. Якщо максимальне значення критерію (1) знаходиться у робочій області визначення його функції, то виконується п. 6, інакше п. 2.

6. Визначається оптимальне значення параметра поля контрольних допусків на ознаки розпізнавання: $\delta^* := \arg E_1^*$.

7. Обчислюється за формулою (3) оптимальні значення поля контрольних допусків на ознаки розпізнавання та визначаються оптимальні геометричні параметри контейнерів класів розпізнавання, що формують вирішальні правила.

8. Зупин

Таким чином, алгоритм інформаційно-екстремального навчання СППР полягає у оптимізації СКД на діагностичні ознаки розпізнавання шляхом ітераційної процедури пошуку глобального максимуму КФЕ (1) у робочій області визначення його функції.

ІНФОРМАЦІЙНІ КРИТЕРІЇ ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ НАВЧАННЯ СППР

Розглянемо інформаційну міру Кульбака, що застосовується в ІЕІ-технології при оцінці функціональної ефективності навчання СППР розпізнавати реалізації класу x_m^o , у вигляді

$$E_m^{(k)} = [P_{t,m}^{(k)} - P_{f,m}^{(k)}] * \log_2 \frac{P_{t,m}^{(k)}}{P_{f,m}^{(k)}} \quad (1)$$

де $P_{t,m}^{(k)}$ – повна ймовірність правильного розпізнавання реалізацій класу x_m^o на k -му кроці навчання; $P_{f,m}^{(k)}$ – повна ймовірність неправильного розпізнавання реалізацій класу x_m^o на k -му кроці навчання.

Модифікована міра Кульбака для двухальтернативних рішень і рівноймовірних гіпотез ($p(\mu_1) = p(\mu_2) = 0,5$) має вигляд [5]

$$E_m^{(k)} = \frac{1}{2} \{ [D_{1,m}^{(k)} + D_{2,m}^{(k0)}] - [\alpha_m^{(k)} + \beta_m^{(k)}] \} * \log_2 \left[\frac{D_{1,m}^{(k)} + D_{2,m}^{(k0)}}{\alpha_m^{(k)} + \beta_m^{(k)}} \right] \quad (2)$$

де $D_{1,m}^{(k)}$ – перша достовірність, обчислена на k -му кроці навчання СППР розпізнавати реалізації класу x_m^o ; $D_{2,m}^{(k)}$ – друга достовірність; $\alpha_m^{(k)}$ – помилка першого роду; $\beta_m^{(k)}$ – помилка другого роду.

Для визначення залежності міри Кульбака від точнісних характеристик при трьохальтернативних рішеннях введемо основну гіпотезу γ_1 про належність діагностичної ознаки показнику «НОРМА», гіпотезу γ_2 про належність діагностичної ознаки показнику «МЕНЬШЕ НОРМЫ» та гіпотезу γ_3 про належність діагностичної ознаки показнику «БОЛЬШЕ НОРМЫ». Відповідно позначимо їх апостеріорні гіпотези: μ_1 – значення ознаки дійсно знаходиться у полі допусків δ , μ_2 – лівіше за поле допусків δ та μ_3 – правіше за поле допусків δ . Як відомо, можливі результати трьох альтернативних рішень оцінюються дев'ятьма точнісними характеристиками:

- перша достовірність $D_{1,m}^{(k)} = p(\gamma_1 / \mu_1)$;
- перша помилка першого роду $\alpha_{1,m}^{(k)} = p(\gamma_2 / \mu_1)$;
- друга помилка другого роду $\alpha_{2,m}^{(k)} = p(\gamma_3 / \mu_1)$;

- друга достовірність $D_{2,m}^{(k)} = p(\gamma_2 / \mu_2)$;
- перша помилка другого роду $\beta_{1,m}^{(k)} = p(\gamma_1 / \mu_2)$;
- друга помилка другого роду $\beta_{2,m}^{(k)} = p(\gamma_3 / \mu_2)$;
- третя достовірність $D_{3,m}^{(k)} = p(\gamma_3 / \mu_3)$;
- перша помилка третього роду $\sigma_{1,m}^{(k)} = p(\gamma_1 / \mu_3)$;
- друга помилка третього роду $\sigma_{2,m}^{(k)} = p(\gamma_2 / \mu_3)$.

Введемо наступні припущення:

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

З метою спрощення наступних перетворень введемо

$$\alpha_m^{(k)} = \alpha_{1,m}^{(k)} = \alpha_{2,m}^{(k)}; \quad \beta_m^{(k)} = \beta_{1,m}^{(k)}; \quad \sigma_m^{(k)} = \sigma_{1,m}^{(k)}. \quad (3)$$

З урахуванням припущень (3) при трьох альтернативних рішеннях повні ймовірності $P_{t,m}^{(k)}$ та $P_{f,m}^{(k)}$ відповідно будуть дорівнювати

$$\begin{aligned} P_{t,m}^{(k)} &= p(\mu_1)D_{1,m}^{(k)} + p(\mu_2)D_{2,m}^{(k)} + p(\mu_3)D_{3,m}^{(k)}; \\ P_{f,m}^{(k)} &= p(\mu_1)\alpha_m^{(k)} + p(\mu_2)\beta_m^{(k)} + p(\mu_3)\sigma_m^{(k)}; \end{aligned} \quad (4)$$

Згідно з принципом Бернулї-Лапласа приймемо

$$p(\mu_1) = p(\mu_2) = p(\mu_3) = \frac{1}{3}; \quad (5)$$

Після підстановки рівностей (4) та умови (5) в формулу (1) отримаємо

$$E_m^{(k)} = \frac{1}{3} \{ [D_{1,m}^{(k)} + D_{2,m}^{(k)} + D_{3,m}^{(k)}] - [\alpha_m^{(k)} + \beta_m^{(k)} + \sigma_m^{(k)}] \} * \log_2 \frac{D_{1,m}^{(k)} + D_{2,m}^{(k)} + D_{3,m}^{(k)}}{D_{1,m}^{(k)} + D_{2,m}^{(k)} + D_{3,m}^{(k)}}. \quad (6)$$

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

$$D_{1,m}^{(k)} + 2\alpha_m^{(k)} = 1; \quad D_{2,m}^{(k)} + \beta_m^{(k)} + \sigma_m^{(k)}; \quad D_{3,m}^{(k)} + \beta_m^{(k)} + \sigma_m^{(k)}. \quad (7)$$

З урахуванням співвідношень (7) представимо формулу (6) у вигляді

$$E_m^{(k)} = \frac{1}{3} \{D_{1,m}^{(k)} + 1 - 2[\beta_m^{(k)} + \sigma_m^{(k)}]\} * \log_2 \frac{2D_{1,m}^{(k)} + 4 - 4[\beta_m^{(k)} + \sigma_m^{(k)}]}{1 - D_{1,m}^{(k)} + 2[\beta_m^{(k)} + \sigma_m^{(k)}]} \quad (8)$$

ПРИКЛАД РЕАЛІЗАЦІЇ АЛГОРИТМУ НАВЧАННЯ СППР

Розглянемо застосування вищенаведеного алгоритму навчання СППР за трьохальтернативною системою оцінок: «Норма», «Менше норми» і «Більше норми» для діагностування опортуністичних інфекції у ВІЛ-інфікованих осіб. Алфавіт класів розпізнавання складався із трьох класів. При цьому клас x_1^o характеризує контрольну групу осіб (практично здорові донори крові). Клас x_2^o – ВІЛ-інфіковані особи з середньотяжким перебігом захворювання (кількість опортуністичних інфекцій на одного хворого – 1-2-і) і клас x_3^o – ВІЛ-інфіковані особи з тяжким перебігом захворювання (кількість опортуністичних інфекцій на одного хворого більше 3-х). Навчальні матриці класів мали по 35 реалізацій, кожна з яких складалася з 63 ознак розпізнавання. При цьому вектори-реалізації класів подано у вигляді структурованої послідовності клініко-лабораторних та імуногенетичних ознак розпізнавання, які характеризують: загальний стан пацієнта при зверненні за медичною допомогою, ураження органів і систем, показники клінічного, біохімічного аналізу крові, дослідження рівнів популяцій лімфоцитів та сироваткові рівні ІЛ-4, ІЛ-10, TNF- α , поліморфізми

поодиноких нуклеотидів генів цитокинів IL-4 (-590С/Т), IL-10 (-592С/А), TNF- α (-308G/А).

На рис. 1.40 показано графік залежності усередненого нормованого трьох альтернативного КФЕ (8) від параметра поля допусків δ , отриманого в процесі паралельної оптимізації системи контрольних допусків на діагностичні ознаки для унімодального (з вкладеними контейнерами класів розпізнавання) класифікатора.




Рисунок 1.40 – Графік залежності критерію Кульбака від величини параметра поля контрольних допусків для базового класу x_1^0 для унімодального класифікатора

На рис.1.40 світлі ділянки графіка позначають робочі (допустимі) області визначення функції КФЕ (8), в яких виконуються умови: $2\alpha_m^{(k)} < 0,5$, $c = \beta_m^{(k)} + \sigma_m^{(k)} < 0,5$ та $d_m > d_{m-1}$. Аналіз показує, що оптимальне значення параметра поля контрольних допусків дорівнює $\delta = \pm 21$ (у відносних одиницях) при максимальному значенні КФЕ $\bar{E}^* = 0,5$

З метою підвищення функціональної ефективності навчання СППР було реалізовано алгоритм послідовної оптимізації контрольних допусків. При цьому значення нормованого КФЕ досягло в процесі навчання свого максимального значення ($E^* = 1$), що свідчить про побудову безпомилкових за навчальною матрицею вирішальних правил.

На рис. 1.40 показано графік залежності усередненого КФЕ від параметра поля допусків δ , одержаного в процесі паралельної оптимізації системи

контрольних допусків на діагностичні ознаки розпізнавання при застосуванні системи оцінок двохальтернативних рішень для полімодального класифікатора. Тут темні ділянки графіків позначають робочі (допустимі) області визначення функції КФЕ (), в яких виконуються умови $\alpha_m^{(k)} < 0,5$, $\beta_m^{(k)} < 0,5$ та $d_m < d(x_m \oplus x_c)$.




Рисунок 1.41 – Графік залежності критерію Кульбака від величини параметра поля контрольних допусків

Аналіз рис. 1.41 показує, що оптимальне значення параметра поля контрольних допусків дорівнює $\delta^* = \pm 78\%$ від усереднених для класу x_1^o значень ознак розпізнавання при усередненому нормованому максимальному значенні КФЕ $\bar{E}^* = 0,75$. На рис. 1.42 наведено залежність усередненого за алфавітом класів розпізнавання нормованого КФЕ від кількості ітерацій (прогонів) s за послідовним алгоритмом оптимізації контрольних допусків на діагностичні ознаки розпізнавання при застосуванні двохальтернативних рішень для мультимодального класифікатора.




Рисунок 1.42– Графік залежності критерію Кульбака від кількості ітерацій алгоритму навчання

Аналіз рис. 1.42 показує, що вже на першому прогоні алгоритму послідовної оптимізації отримано максимальне значення усередненого значення КФЕ, яке дорівнює $\bar{E}^* = 0,79$.

На рис.1.43 показано графіки залежності КФЕ () від радіусів гіперсферичних контейнерів класів розпізнавання, одержаних при застосуванні системи оптимальних контрольних допусків на діагностичні ознаки розпізнавання, одержаної за алгоритмом (). Тут темні ділянки графіків позначають робочі (допустимі) області визначення функції КФЕ (), в яких виконуються умови $\alpha_m^{(k)} < 0,5$, $\beta_m^{(k)} < 0,5$.

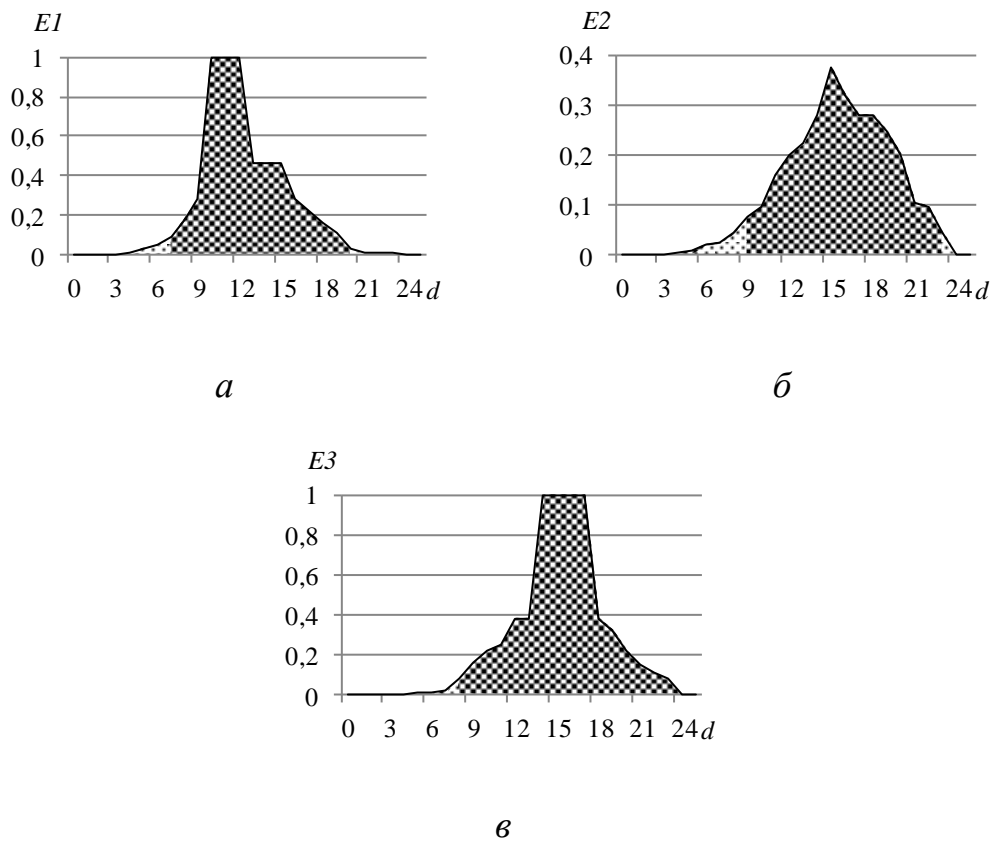


Рисунок 1.43 – Графіки залежності нормованого критерію Кульбака від радіусів гіперсферичних контейнерів класів розпізнавання: а – клас X_1^o ; б – клас X_2^o ; в – клас X_3^o

Аналіз рис. 1.43 показує, що оптимальні радіуси контейнерів класів розпізнавання дорівнюють: для класу $x_1^o - d_1^* = 10$ (тут і далі у кодових одиницях), для класу $x_2^o - d_2^* = 15$ і для класу $x_3^o - d_3^* = 14$, а міжцентрові відстані між парами найближчих класів – $d(x_1 \oplus x_2) = 23$, $d(x_2 \oplus x_3) = 23$ та $d(x_3 \oplus x_1) = 23$, при значеннях нормованого КФЕ $E_1^* = 1$, $E_2^* = 0,38$ та $E_3^* = 1$ відповідно.

1.10 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ МАШИННЕ НАВЧАННЯ СИСТЕМИ КЕРУВАННЯ ЕНЕРГОБЛОКОМ ТЕПЛОЕЛЕКТРОЦЕНТРАЛІ

Застосування інтелектуальних інформаційних технологій аналізу даних дозволяє підвищити функціональну ефективність систем керування слабо формалізованими процесами, до яких відносяться і процеси, що відбуваються в генеруючих енергоблоках теплоелектроцентралей (ТЕЦ). Як перспективний шлях підвищення функціональної ефективності слабо формалізованих керованих процесів є використання ідей і методів машинного навчання та розпізнавання образів. При цьому високу точність керування, як це доведено на практиці, забезпечують методи аналізу даних в рамках так званої інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології), яка ґрунтується на максимізації інформаційної спроможності системи керування в процесі її навчання. На відміну від інших методів інтелектуального аналізу даних, включаючи нейронні та імунні мережі, методи, побудовані в рамках ІЕІ-технології дозволяють будувати високо достовірні вирішальні правила за умов суттєвого перетину класів розпізнавання в просторі ознак, довільних початкових умов, впливу неконтрольованих збурюючих факторів, великих обсягів даних, що має місце в керованих розподілених технологічних процесах.

В статті розглядається інформаційно-екстремальний алгоритм навчання системи підтримки прийняття рішень для керування енергоблоком ТЕЦ з оптимізацією контрольних допусків на ознаки розпізнавання.

Аналіз літературних даних та постановка проблеми

Більшість існуючих методів керування генеруючими енергоблоками ТЕЦ ґрунтуються на традиційному математичному моделюванні об'єктів керування і не враховують через науково-методологічні обмеження реальні властивості слабо формалізованого технологічного процесу [1, 2]. Інший перспективний підхід полягає в застосуванні інтелектуальних інформаційних технологій аналізу даних, який ґрунтується на ідеях машинного навчання та розпізнавання образів [3-5]. При цьому достовірність запропонованих методів класифікаційного керування слабо формалізованими об'єктами суттєво залежить від вибору методу розпізнавання. В працях [6, 7] розглядалися методи оцінки функціонального стану енергоблоку шляхом розпізнавання спектральних характеристик полум'я в котлоагрегаті. При цьому розпізнавання зображень здійснювалося з використанням штучних нейронних мереж, які є чутливими до багатовимірності простору ознак розпізнавання, що не дозволило достовірно оцінювати поточний функціональний стан технологічного процесу. Тому відомі практичні реалізації цього підходу в основному пов'язані із розв'язанням задачі недопущення загасання котлоагрегату, що може привести до важких техногенних наслідків. Найбільш придатними є методи машинного навчання та розпізнавання образів вирішальні правила яких побудовані в рамках ІЕІ-технології аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи керування в процесі її навчання [8, 9]. В праці [10] в рамках ІЕІ-технології розглядалася задача інформаційного синтезу здатної навчатися СППР для керування енергоблоком ТЕЦ, але не було досягнуто високої достовірності розпізнавання функціональних станів технологічного процесу через апріорно неоптимальні контрольні допуски на ознаки розпізнавання

Розглянемо в рамках ІЕІ-технології формалізовану постановку задачі інформаційного синтезу здатної навчатися СППР для стабілізації тиску і температури пару на вході турбоагрегату. При цьому в процесі

інформаційно-екстремального машинного навчання в рамках геометричного підходу будуть будуватися вирішальні правила двох типів з метою порівняння їх функціональної ефективності. Вирішальні правила першого типу будуються за геометричними параметрами контейнерів класів розпізнавання з розподіленими в просторі ознак центрами розсіювання їх векторів-реалізацій. Вирішальні правила такого типу будемо називати полімодальними. Вирішальні правила другого типу будемо називати унімодальними, оскільки в цьому випадку класи розпізнавання мають єдиний центр розсіювання їх векторів-реалізацій, контейнери класів розпізнавання мають вкладену структуру.

Спочатку розглянемо постановку задачі інформаційного синтезу СППР з полімодальними вирішальними правилами. Нехай задано алфавіт класів розпізнавання $\{X_m^o \mid m = \overline{1, M}\}$, які характеризують можливі функціональні стани керованого технологічного процесу. Для алфавіту $\{X_m^o\}$ сформовано вхідну багатовимірну навчальну матрицю $\|y_{m,i}^{(j)}\|$, в якій рядок є реалізацією образу $\{y_{m,i}^{(j)} \mid i = \overline{1, N}\}$, де N – кількість структурованих ознак розпізнавання, а стовпчик матриці – випадкова навчальна вибірка $\{y_{m,i}^{(j)} \mid j = \overline{1, n}\}$, де n – обсяг вибірки. Крім того, відомий структурований вектор параметрів навчання системи розпізнавати реалізації деякого класу X_m^o із заданого алфавіту

$$g_m = \langle x_m, d_m, \delta \rangle, \quad (1)$$

де x_m – статистично усереднений двійковий вектор-реалізація класу X_m^o , який визначає геометричний центр контейнеру класу розпізнавання, що відновлюється в радіальному базисі простору ознак розпізнавання; d_m – радіус контейнера класу X_m^o , величина якого в бінарному просторі Хеммінга задається кодовою відстанню; δ – параметр поля контрольних допусків на ознаки розпізнавання, який дорівнює половині симетричного поля

контрольних допусків і визначається відносно базового класу X_1^0 , що характеризує найбільш бажаний функціональний стан технологічного процесу. При різних шкалах виміру ознак розпізнавання параметр δ задається у відсотках від номінального (усередненого за вибіркою) значення ознаки. При цьому задано такі обмеження: $d_m \in [0; d(x_m \oplus x_c) - 1]$, де $d(x_m \oplus x_c)$ – кодова відстань від центра контейнера класу X_m^0 до центра контейнера сусіднього класу X_c ; $\delta_i \in [0; \delta_{H,i}/2]$, де $\delta_{H,i}$ – нормоване поле допусків, що визначає область значень параметра δ_i для i -ї ознаки розпізнавання.

Необхідно в процесі навчання визначити оптимальні значення координат вектора параметрів (1), які забезпечують максимум усередненого за алфавітом класів розпізнавання інформаційного критерію в робочій (допустимій) області визначення його функції:

$$\bar{E}^* = \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap \{k\}} E_m, \quad (2)$$

де E_m – інформаційний критерій навчання СППР розпізнавати реалізації класу X_m^0 ; G_E – робоча (допустима) область визначення функції інформаційного критерію; $\{k\}$ – множина кроків навчання (кроків відновлення контейнерів класів розпізнавання).

Постановка задачі інформаційного синтезу СППР з унімодальними вирішальними правилами буде мати такі відмінності у порівнянні з вище наведеною постановкою:

- 1) алфавіт $\{X_m^0\}$ є впорядкованим, в якому класи розпізнавання характеризуються величиною відхилення технологічних параметрів від норми;
- 2) відсутня необхідність оптимізації усереднених векторів-реалізацій

класів розпізнавання, оскільки всі вони мають єдиний центр розсіювання;

3) відсутня необхідність оптимізації радіусу зовнішнього контейнеру.

На етапі екзамену, тобто безпосередньо в робочому режимі, необхідно прийняти рішення про належність вектора-реалізації, що характеризує поточний функціональний стан технологічного процесу, одному із класів заданого алфавіту і видати рекомендації оператору для прийняття керуючих рішень.

Таким чином, розв'язок задачі інформаційного синтезу здатної навчатися СППР в рамках ІЕІ-технології полягає в оптимізації параметрів навчання шляхом пошуку глобального максимуму інформаційного критерію в робочій (допустимій) області визначення його функції.

Мета та задачі дослідження

Мета проведених досліджень полягала в розробленні інформаційно-екстремального алгоритму машинного навчання СППР для стабілізації тиску і температури на вході турбіни енергоблоку.

Для досягнення поставленої мети вирішувалися такі задачі:

- формування репрезентативної вхідної навчальної матриці за результатами аналізу архівних даних;
- розробка математичної моделі та алгоритмів глибокого навчання СППР в рамках ІЕІ-технології;
- програмна реалізація алгоритму навчання СППР з використанням полімодальних вирішальних правил, отриманих при використанні гіперсферичних контейнерів класів розпізнавання, центри яких розподілено в просторі ознак;
- програмна реалізація алгоритму навчання СППР з використанням унімодальних вирішальних правил, отриманих при використанні вкладених контейнерів класів розпізнавання;
- аналіз одержаних результатів.

Матеріали та методи дослідження

Оскільки керований технологічний процес є слабо формалізованим, то категорійну модель інформаційно-екстремального навчання СППР розглянемо у вигляді узагальненого орієнтованого графу, в якому ребро характеризує оператор відображення відповідної множини на іншу.

При цьому вхідний математичний опис подамо у вигляді структури множин

$$\Delta_B = \langle G, T, \Omega, Z, Y, X; \Phi_1, \Phi_2 \rangle,$$

де G – множина вхідних факторів; T – множина моментів часу зняття інформації; Ω – простір ознак розпізнавання; Z – простір можливих функціональних станів технологічного процесу; Y – вибіркова множина (вхідна навчальна матриця); $\Phi_1 : G \times T \times \Omega \times Z \rightarrow Y$ – оператор формування вибіркової множини Y ; $\Phi_2 : Y \rightarrow X$ – оператор формування бінарної навчальної матриці X .

Категорійну математичну модель здатної навчатися СППР з полімодальними вирішальними правилами і оптимізацією системи контрольних допусків показано на рис. 1.44.




Рисунок 1.44 – Категорійна модель навчання СППР з полімодальними вирішальними правилами

На рис.1.44 оператор θ відображає двійкові вектори-реалізації навчальної матриці на розбиття $\mathfrak{R}^{|M|}$ простору ознак на класи розпізнавання, а оператор ψ перевіряє основну статистичну гіпотезу про належність реалізацій відповідному класу розпізнавання. За результатами статистичної перевірки формується множина допустимих гіпотез $I^{|l|}$, де l – кількість статистичних гіпотез, а оператор γ формує множину точнісних характеристик $\mathfrak{Z}^{|q|}$, де $q = l^2$. E - інформаційний КФЕ навчання КСД; V – множина типів радіально-базисних вирішальних правил; C – множина складових кольорової палітри зображень. Оператор ϕ обчислює множину E значень інформаційного критерію оптимізації параметрів навчання, а оператор r відновлює на кожному кроці машинного навчання контейнери класів розпізнавання, що будуються в радіальному базисі простору ознак. Категорійна модель, показана на рис. 1.44, має додатковий контур оптимізації контрольних допусків на ознаки розпізнавання, який замикається через терм-множину D – систему контрольних допусків. Оператор ν вибирає із множини V тип радіально-базисного вирішального правила, а оператор u регламентує процес машинного навчання.

Згідно з категорійною моделлю (рис. 1.44) інформаційно-екстремальний алгоритм навчання СППР з оптимізацією системи контрольних допусків на ознаки розпізнавання подамо у вигляді ітераційної процедури пошуку глобального максимуму усередненого за алфавітом класів розпізнавання інформаційного критерію (2) в робочій (допустимій) області визначення його функції

$$\delta_K^* = \arg \max_{G_\delta} \left\{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \right\}, \quad (3)$$

де G_δ – допустима область значень параметра δ поля контрольних допусків на ознаки розпізнавання.

Таким чином, оптимізація системи контрольних допусків на ознаки розпізнавання полягає в організації пошуку в процесі машинного навчання глобального максимуму інформаційного критерію (4) в робочій (допустимій) області визначення його функції. Основні етапи реалізації інформаційно-екстремального алгоритму (3) навчання СППР з паралельною оптимізацією системи контрольних допусків на ознаки розпізнавання розглянуто в праці [11].

Як інформаційний критерій оптимізації параметрів машинного навчання в методах ІЕІ-технології використовуються модифіковані критерії Шеннона або Кульбака, які забезпечують однакові результати оптимізації. Для оцінки функціональної ефективності машинного навчання будемо використовувати модифіковану міру Кульбака, яка для двохальтернативних рішень з апіорно рівноймовірними гіпотезами має вигляд [10]

$$\begin{aligned}
 E_m^{(k)}(d) &= [P_{t,m}^{(k)}(d) - P_{f,m}^{(k)}(d)] \log_2 \frac{P_{t,m}^{(k)}(d)}{P_{f,m}^{(k)}(d)} = \\
 &= [D_{1,m}^{(k)}(d) - \beta_m^{(k)}(d)] \log_2 \frac{1 + [D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)] + 10^{-r}}{1 - [D_{1,m}^{(k)}(d) + \beta_m^{(k)}(d)] + 10^{-r}}, \quad (4)
 \end{aligned}$$

де $P_{t,m}^{(k)}(d), P_{f,m}^{(k)}(d)$ – повні ймовірності відповідно правильного і неправильного прийняття рішень, обчислені на k -му кроці оптимізації параметрів навчання СППР; $D_{1,m}^{(k)}(d)$ – перша достовірність, яка характеризує ймовірність правильної класифікації вектора-реалізації класу X_m^o ; $\beta_m^{(k)}(d)$ – помилка другого роду, яка характеризує помилкове віднесення до класу X_m^o вектора-реалізації іншого класу; d – дистанційна міра, яка визначає величину радіусу гіперсферичного контейнера класу розпізнавання X_m^o ; 10^{-r} – достатньо мале число, яке вводиться для уникнення поділу на нуль (величина r на практиці вибирається в інтервалі $1 < r \leq 3$).

Побудовані в праці [11] полімодальні вирішальні правила не забезпечували високу функціональну ефективність машинного навчання, оскільки контрольні допуски змінювалися на кожному кроці навчання одночасно для всіх ознак розпізнавання. Тому контрольні допуски, отримані при досягненні інформаційним критерієм (2) свого максимального значення, слід розглядати як квазіоптимальні. 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 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 здійснюється тільки в робочій області визначення його функції.

Послідовну оптимізацію контрольних допусків на ознаки розпізнавання в процесі машинного навчання будемо здійснювати за ітераційною процедурою наближення глобального максимуму інформаційного критерію оптимізації (4) до граничного значення в допустимій області визначення його функції

$$\delta_i^* = \arg \otimes_{l=1}^L \left[< \max_{G_{\delta_i}} \left\{ \frac{1}{M} \sum_{m=1}^M \left[\max_{G_{E_m} \cap (k)} E_m^{(l)}(d_m) \right] \right\} > \right], i = \overline{1, N}, \quad (5)$$

де G_{δ_i} – область допустимих значень параметра поля δ_i контрольних допусків для i -ї ознаки розпізнавання; L – кількість прогонів ітераційної процедури послідовної оптимізації контрольних допусків на ознаки розпізнавання; \otimes – символ операції повторення.

Згідно з принципом Уолтера Ешбі процес машинного навчання повинен продовжуватися до тих пір, поки не будуть отримані безпомилкові за навчальною матрицею вирішальні правила. З цією метою як один із параметрів навчання в ІЕІ-технології розглядається рівень селекції

$\rho_{m,i}$, $m = \overline{1, M}$, $i = \overline{1, N}$ координат усереднених двійкових векторів-реалізацій класів розпізнавання. Під рівнем селекції в ІЕІ-технології розуміється порогове значення частоти знаходження ознак розпізнавання в своєму полі контрольних допусків, відносно якого здійснюється кодування координат двійкових усереднених векторів реалізацій класів розпізнавання. Ідея оптимізації такого параметра в процесі інформаційно-екстремального машинного навчання пов'язана з необхідністю реалізації максимально-дистанційного принципу теорії розпізнавання образів [Гонсалес], який полягає в максимізації середньої міжцентрової відстані класів розпізнавання із заданого алфавіту $\{X_m^o \mid m = \overline{1, M}\}$.

На рис. 1.46 показано категорійну модель машинного навчання з полімодальними вирішальними правилами. При цьому глибина навчання, яка визначається кількістю контурів оптимізації параметрів функціонування СППР, дорівнює трьом.




Рисунок 1.45 – Категорійна модель навчання СППР з оптимізацією рівнів квантування усереднених векторів-реалізацій класів розпізнавання

Показана на рис. 1.45 категорійна модель у порівнянні з моделлю містить додатковий контур оптимізації з терм-множиною C , елементами якої є значення рівня квантування в інтервалі $[0; 1]$.

Структура ітераційної процедури паралельної оптимізації рівня квантування $\rho_m, m = \overline{1, M}$, координат усередненого вектора-реалізації базового класу розпізнавання X_m^o , відносно якого задається система контрольних допусків на ознаки розпізнавання має вигляд []

$$\rho_m^* = \langle \operatorname{argmax}_{G_\rho} \{ \max_{G_\delta} \{ \max_{G_E \cap (k)} \overline{E}^{(k)} \} \} \rangle, m = \overline{1, M}, \quad (6)$$

де G_ρ – допустима область значень параметра ρ ;

Алгоритм послідовної оптимізації рівня селекції $\rho_{m,i}, m = \overline{1, M}, i = \overline{1, N}$ так само полягає у наближенні глобального максимуму інформаційного критерію оптимізації до максимального граничного значення в робочій (допустимій) області визначення його функції і має таку структуру:

$$\{\rho_{m,i}^*\} = \langle \operatorname{arg} \otimes_{s=1}^S \left[\max_{G_{\rho_i}} \left\{ \frac{1}{M} \sum_{m=1}^M \max_{G_E \cap (k)} E_m^{(l)}(d_m) \right\} \right] \rangle, i = \overline{1, N}, \quad (7)$$

де G_{ρ_i} – область допустимих значень параметра $\rho_{m,i}$ для i -ї ознаки розпізнавання; S – кількість прогонів ітераційної процедури послідовної оптимізації рівня квантування координат усереднених векторів-реалізацій образів; \otimes – символ операції повторення.

Для підвищення функціональної ефективності машинного навчання було структуровано алфавіт класів розпізнавання, які відповідали функціональним станам технологічного процесу за оцінкою «Менше норми «Норма» і «Більше норми». Така структуризація алфавіту класів розпізнавання дозволяє перейти від полімодальних вирішальних правил, побудованих в процесі машинного навчання за геометричними параметрами контейнерів класів розпізнавання з розподіленими центрами розсіювання їх відповідних векторів-реалізацій до

унімодальних вирішальних правил, побудованих для вкладених контейнерів із єдиним геометричним центром.

На рис. 1.46 показано категорійну модель інформаційно-екстремального машинного навчання із вкладеною структурою контейнерів класів розпізнавання.




Рисунок 1.46– Категорійна модель навчання СППР з унімодальними вирішальними правилами

Категорійна модель, показана на рис. 1.46 у порівнянні з вище наведеними моделями має додатковий контур, призначенням якого є послідовний вибір із впорядкованого алфавіту A сусіднього класу для подальшого визначення оптимального зовнішнього радіусу його гіперсферичного контейнера.

Показані категорійні моделі є по суті узагальненими структурними схемами алгоритмів інформаційно-екстремального машинного навчання і широко використовуються в задачах функціонального програмування.

Результати машинного навчання СППР

Реалізація вище наведених алгоритмів навчання СППР для керування енергоблоком здійснювалася за навчальною матрицею, сформованою за архівними даними, одержаними на Шосткінській ТЕЦ. Загальна кількість ознак розпізнавання, що періодично вимірялися, дорівнювала 64. При цьому впорядкований алфавіт складався із трьох класів, які характеризували

функціональний стан технологічного процесу на вході парової турбіни. Клас X_1^o «Норма» характеризував функціональний стан, коли температура і тиск пари відповідали технологічному режиму. Відповідно визначалися клас X_2^o – «Менше норми» і клас X_3^o – «Більше норми».

На рис. 1.47 показано графік залежності усередненого за алфавітом класів розпізнавання інформаційного критерію (4) від параметра δ поля контрольних допусків, одержаний в результаті їх паралельної оптимізації з полімодальними вирішальними правилами. На графіку темним кольором показано робочу (допустиму) область визначення функції критерію (4), в якій його величина обчислюється за умови, що перша достовірність приймає значення більше 0.5, а помилка другого роду менше.




Рисунок 1.47 –Графік залежності інформаційного критерію від параметра поля контрольних допусків на ознаки розпізнавання

Аналіз рис. 1.47 показує, що максимальне значення усередненого за алфавітом класів розпізнавання інформаційного критерію (4) в робочій області дорівнює $\bar{E} = 0,45$. Оскільки на графіку максимальні значення критерію належать ділянці типу плато, то оптимальне значення параметра оптимізації вибиралося за найменшим усередненим коефіцієнтом нечіткої компактності реалізацій класів розпізнавання:

$$L_p = \frac{1}{M} \sum_{m=1}^M \frac{d_m^*}{d(x_m \oplus x_{c,m})}, \quad (8)$$

де d_m^* – оптимальний радіус контейнера класу X_m^o ; $d(x_m^* \oplus x_{m,c})$ – кодова відстань між оптимальним усередненим вектором-реалізацією класу X_m^o і усередненим вектором-реалізацією класу розпізнавання X_c^o , найближчого до класу X_m^o .

В результаті мінімальне значення виразу (8) було отримано при оптимальному параметрі поля контрольних допусків $\delta = \pm 3\%$ від номінального значення ознак розпізнавання.

Для підвищення функціональної ефективності машинного навчання було реалізовано алгоритм (5) послідовної оптимізації контрольних допусків на ознаки розпізнавання. На рис. 1.48 показано графік зміни інформаційного критерію (4) від кількості кроків навчання при послідовній оптимізації контрольних допусків на ознаки розпізнавання.










Рисунок 1.48– Графік зміни інформаційного критерію при послідовній оптимізації контрольних допусків

Аналіз рис. 1.48 показує, що вже на другому прогоні алгоритму послідовної оптимізації отримано максимальне значення усередненого інформаційного

критерію оптимізації $\bar{E}^* = 0,45$, яке перевершує отримане при реалізації алгоритму паралельної оптимізації значення $\bar{E}^* = 0,35$. При цьому кожний прогон складається із 64 кроків навчання, на яких відбувається ітераційний пошук оптимального поля контрольних допусків для i -ї ознаки розпізнавання.





Обговорення результатів дослідження КСД

Запропонований метод інформаційного синтезу здатної навчати системи підтримки прийняття рішень для керування енергоблоком теплоелектроцентралі реалізовано в рамках ІЕІ-технології аналізу даних. В процесі машинного навчання контейнери класів розпізнавання, які характеризують функціональні стани технологічного процесу на вході парової турбіни, відновлювалися в радіальному базисі простору ознак. При цьому оптимізація геометричних параметрів гіперсферичних контейнерів класів розпізнавання здійснювалася за модифікованим інформаційним критерієм Кульбака. В запропонованому методі вхідна навчальна матриця трансформувалася в бінарну навчальну матрицю, що дозволило змінювати її

з метою адаптації вхідного математичного опису СППР до максимальної функціональної ефективності машинного навчання. Реалізація методу машинного навчання здійснювалася за архівними даними, одержаними на Шосткінській ТЕЦ. Оскільки класи розпізнавання суттєво перетиналися в просторі ознак, то було застосовано глибоке машинне навчання з оптимізацією системи контрольних допусків на ознаки розпізнавання і рівнів селекції координат двійкових усереднених векторів реалізацій. При цьому спочатку було реалізовано інформаційно-екстремальний алгоритм машинного навчання з полімодальними вирішальними правилами для класів розпізнавання з розподіленими в просторі ознак центрами розсіювання їх векторів-реалізацій. Аналіз отриманих графіків залежності інформаційного критерію оптимізації від параметрів машинного навчання показав, що побудовані полімодальні вирішальні правила характеризуються невисокою функціональною ефективністю. Тоді було реалізовано інформаційно-екстремальний алгоритм машинного навчання з унімодальними вирішальними правилами, які будувалися за геометричними параметрами контейнерів класів розпізнавання із вкладеною структурою. При цьому необхідно було впорядкувати алфавіт класів розпізнавання, які відповідали функціональним станам технологічного процесу «Менше норми» і «Більше норми». Аналіз графіків залежності інформаційного критерію (4) від зовнішніх радіусів вкладених контейнерів класів розпізнавання показав, що вдалося побудувати безпомилкові за навчальною матрицею вирішальні правила. Крім того, при побудові унімодального класифікатора підвищується оперативність машинного навчання, оскільки відпадає необхідність визначення найближчого сусіда для класу розпізнавання і не потрібно визначати радіус контейнера зовнішнього класу розпізнавання.

Таким чином, застосування унімодальних вирішальних правил в рамках ІЕІ-технології дозволяє підвищити функціональну ефективність і зменшити

обчислювальну трудомісткість машинного навчання у порівнянні з полімодальними.

Висновки

1. Запропоновано в рамках інформаційно-екстремальної інтелектуальної технології аналізу даних метод глибокого машинного навчання системи підтримки прийняття рішень для керування енергоблоком теплоелектроцентралі. При цьому в процесі машинного навчання здійснювалася оптимізація системи контрольних допусків на ознаки розпізнавання і рівнів селекції координат усереднених векторів-реалізацій класів розпізнавання, що дозволило побудувати безпомилкові за навчальною матрицею вирішальні правила.

2. Експериментально доведено, що застосування унімодальних вирішальних правил у випадку впорядкованих класів розпізнавання за величиною відхилення функціонального стану технологічного процесу від нормального режиму дозволяє підвищити функціональну ефективність і зменшити обчислювальну трудомісткість машинного навчання у порівнянні з полімодальними.

2 КОМП'ЮТЕРНІ НАУКИ

2.1 ШИФРУВАННЯ ДАНИХ ПРИ ПЕРЕДАЧІ В КАНАЛІ ЗВ'ЯЗКУ НА ПРИКЛАДІ GRE-ТУНЕЛЮ

Огляд існуючих рішень

Інтернет – це мережа мереж, яка складається з безлічі локальних і глобальних, приватних, публічних, академічних, ділових і урядових мереж, пов'язаних між собою, з використанням різноманітних дротових, оптичних і бездротових технологій. Іноді важко просто осмислити її масштаби. А коли постає питання безпеки в комп'ютерній мережі, то до її організації підхід має бути серйозним та відповідальним. На сьогоднішній день існує певна кількість протоколів для організації безпеки, способів побудови мережі та певних прикладних засобів. Але кожне з цих рішень має, як переваги, так і ряд недоліків.

Необхідність захисту даних

Наприкінці шістдесятих років американське агентство перспективних досліджень в обороні DARPA ухвалило рішення про створення експериментальної мережі під назвою ARPANet. У семидесятих роках ARPANet стала вважатися діючою мережею США, і через цю мережу можна було отримати доступ до провідних університетських і наукових центрів США. На початку вісімдесятих років розпочалася стандартизація мов програмування, а потім і протоколів взаємодії мереж. Результатом цієї роботи стала розробка семирівневої моделі мережевої взаємодії ISO / OSI і сімейства протоколів TCP / IP, яке стало основою для побудови як локальних, так і глобальних мереж.

Базові механізми інформаційного обміну в мережах TCP / IP були в цілому сформовані на початку вісімдесятих років, і були спрямовані насамперед на

забезпечення доставки пакетів даних між різними операційними системами з використанням різнорідних каналів зв'язку. Незважаючи на те, що ідея створення мережі ARPANet (згодом перетворилася в сучасний Інтернет) належала урядовій оборонній організації, фактично мережа зародилася в дослідницькому світі, і наслідувала традиції відкритості академічної спільноти. Ще до комерціалізації Інтернету (яка відбулася в середині дев'яностих років) багато авторитетних дослідників відзначали проблеми, пов'язані з безпекою стека протоколів TCP / IP. Основні концепції протоколів TCP / IP не цілком задовольняють (а в ряді випадків і суперечать) сучасним уявленням про комп'ютерну безпеку.

До недавнього часу мережа Інтернет використовувалася в основному для обробки інформації по відносно простих протоколах: електронна пошта, передача файлів, віддалений доступ. Сьогодні, завдяки широкому розповсюдженню технологій WWW, все активніше застосовуються засоби розподіленої обробки мультимедійної інформації. Одночасно з цим зростає обсяг даних, що обробляються в середовищах клієнт / сервер і призначених для одночасного колективного доступу великого числа абонентів. Розроблено кілька протоколів прикладного рівня, що забезпечують інформаційну безпеку таких додатків, як електронна пошта (PEM, PGP і т.п.), WWW (Secure HTTP, SSL і т.п.), мережеве управління (SNMPv2 тощо). Однак наявність засобів забезпечення безпеки в базових протоколах сімейства TCP / IP дозволить здійснювати інформаційний обмін між широким спектром різних додатків і сервісних служб.

Шифрування в комп'ютерній мережі

Оскільки рівень комп'ютерних злочинів, пов'язаних із несанкціонованим доступом до інформації в мережах різного масштабу, дуже високий, то існує необхідність створювати певні механізми захисту мереж. Практика показала,

що єдино надійним механізмом захисту інформації в мережевих каналах зв'язку є її шифрування, а значить, використання криптографічного перетворення конфіденційних даних. При цьому забезпечення захисту інформації зазначеним методом не повинно порушувати роботу мережі в реальному масштабі часу, що можливо при виконанні шифрування зі швидкістю до 1 Гбіт / с і вище.

Види шифрування в мережевих каналах зв'язку

Однією з відмінних характеристик будь-якої комп'ютерної мережі є її поділ на так звані рівні, кожен з яких відповідає за дотримання певних умов і виконання функцій, необхідних для спілкування між комп'ютерами, з'єднаними в мережу. Цей розподіл на рівні має фундаментальне значення для створення стандартних комп'ютерних мереж. Тому в 1984 році кілька міжнародних організацій і комітетів об'єднали свої зусилля і виробили приблизну модель комп'ютерної мережі, відому під назвою OSI (Open Systems Interconnection - Модель відкритих мережевих з'єднань).

Відповідно до моделі OSI, комунікаційні функції розподілені по рівнях. Функції кожного рівня не залежать від функцій нижчих-і вищих рівнів. Кожен рівень може безпосередньо спілкуватися тільки з двома сусідніми. Модель OSI визначає 7 рівнів: верхні 3 служать для зв'язку з кінцевим користувачем, а 4 нижніх орієнтовані на виконання комунікаційних функцій в реальному масштабі часу.

Теоретично шифрування даних для передачі по каналах зв'язку комп'ютерної мережі може здійснюватися на будь-якому рівні моделі OSI. На практиці це зазвичай робиться або на найнижчих, або на найвищих рівнях. Якщо дані шифруються на нижніх рівнях, шифрування називається каналним, а якщо на верхніх, то таке шифрування називається наскрізним. Обидва ці підходи до шифрування даних мають свої переваги і недоліки.

При каналному шифруванні шифруються абсолютно всі дані, що проходять по кожному каналу зв'язку, включаючи відкритий текст повідомлення, а також інформацію про його маршрутизацію і про використаний комунікаційний протокол. Однак у цьому випадку будь який інтелектуальний мережевий вузол (наприклад, комутатор) буде змушений розшифровувати вхідний потік даних, щоб відповідним чином його обробити, знову зашифрувати і передати на інший вузол мережі.

Тим не менш, каналне шифрування являє собою дуже ефективний засіб захисту інформації в комп'ютерних мережах. Оскільки шифруванню підлягають всі дані, передані від одного вузла мережі до іншого, у криптоаналітика немає ніякої додаткової інформації про те, хто служить джерелом цих даних, кому вони призначені, яка їхня структура і т. д. А якщо ще подбати і про те, щоб , поки канал простоює, передавати по ньому випадкову бітову послідовність, сторонній спостерігач не зможе навіть сказати, де починається і де закінчується текст переданого повідомлення.

Не надто складною є і робота з ключами. Однаковими ключами слід забезпечити тільки два сусідніх вузла мережі зв'язку, які потім можуть міняти використовувані ключі незалежно від інших пар вузлів.

Найбільший недолік каналного шифрування полягає в тому, що дані доводиться шифрувати при передачі по кожному фізичному каналу комп'ютерної мережі. Відправка інформації в незашифрованому вигляді по якомусь з каналів ставить під загрозу забезпечення безпеки всієї мережі. В результаті вартість реалізації каналного шифрування у великих мережах може виявитися надмірно високою.

Крім того, при використанні каналного шифрування додатково необхідно захищати кожен вузол комп'ютерної мережі, по якому передаються дані. Якщо абоненти мережі повністю довіряють один одному, і кожен її вузол знаходиться там, де він захищений від зловмисників, на цей недолік

канального шифрування можна не звертати уваги. Однак на практиці таке положення зустрічається надзвичайно рідко. Адже в кожній фірмі є конфіденційні дані, ознайомитися з якими можуть тільки співробітники одного відділу, а за його межами доступ до цих даних необхідно обмежувати до мінімуму.

При наскрізному шифруванні криптографічний алгоритм реалізується на одному з верхніх рівнів моделі OSI. Шифруванню підлягає тільки змістовна частина повідомлення. У міру шифрування додається службова інформація, необхідна для маршрутизації повідомлення, і результат переправляється на більш низькі рівні для відправки адресату.

Передане повідомлення тепер не потрібно постійно шифрувати і розшифровувати при його проходженні через кожен проміжний вузол мережі. Воно залишається зашифрованим на всьому шляху від відправника до одержувача.

Основна проблема, з якою стикаються користувачі мереж, де застосовується наскрізне шифрування, пов'язана з тим, що службова інформація, яка використовується для маршрутизації повідомлень, передається по мережі в незашифрованому вигляді. Досвідчений криптоаналітик може отримати для себе масу корисної інформації, знаючи, хто з ким, як довго і в які години спілкується через комп'ютерну мережу. Для цього йому навіть не буде потрібно бути в курсі предмета спілкування.

Наскрізне шифрування в порівнянні з канальним характеризується більш складною роботою з ключами, так як кожна пара користувачів комп'ютерної мережі повинна бути забезпечена однаковими ключами, перш ніж вони зможуть зв'язатися один з одним. А оскільки криптографічний алгоритм реалізується на верхніх рівнях моделі OSI, доводиться також стикатися з багатьма суттєвими відмінностями в комунікаційних протоколах і

інтерфейсах залежно від типів мереж і об'єднаних в мережу комп'ютерів. Все це ускладнює практичне застосування наскрізного шифрування.

Комбінація каналного і наскрізного шифрування даних в комп'ютерній мережі обходиться значно дорожче, ніж кожне з них. Однак саме такий підхід дозволяє якнайкраще захистити дані, передані по мережі. Шифрування в кожному каналі зв'язку не дозволяє зловмиснику аналізувати службову інформацію, використовувану для маршрутизації, а при наскрізному шифруванні зменшується ймовірність доступу до незашифрованих даних у вузлах мережі.

При комбінованому шифруванні робота з ключами ведеться наступним чином: мережеві адміністратори відповідають за ключі, використовувані при каналному шифруванні, а про ключі, застосовуваних при наскрізному шифруванні, дбають самі користувачі.

Апаратне шифрування

Більшість засобів криптографічного захисту даних реалізовано у вигляді спеціалізованих фізичних пристроїв. Ці пристрої вбудовуються в лінію зв'язку і шифрують всю передану по ній інформацію. Переваги апаратного шифрування над програмним обумовлено декількома причинами:

- більш висока швидкість шифрування;
- апаратуру легше фізично захистити від проникнення ззовні;
- апаратура шифрування більш проста в налагодженні.

Криптографічні алгоритми складаються з величезного числа складних операцій з бітами відкритого тексту. Сучасні універсальні комп'ютери погано пристосовані для ефективного виконання цих операцій, а спеціалізоване обладнання вміє робити це набагато швидше.

Програма, що виконується на персональному комп'ютері, практично беззахисна. Озброївшись відладчиком, зловмисник може внести в неї

приховані зміни, щоб понизити стійкість використовуваного криптографічного алгоритму, і ніхто нічого не помітить. Апаратура ж зазвичай поміщається в особливі контейнери, щоб не можна було змінити схему її функціонування. Чіп покривають спеціальним хімічним складом, і при будь-якій спробі подолати захисний шар цього чіпа відбувається самознищення його внутрішньої логічної структури. І навіть у випадку, коли електромагнітне випромінювання може служити хорошим джерелом інформації про те, що діється всередині мікросхеми, від цього випромінювання легко позбутися, заекранувавши мікросхему. Аналогічним чином можна заекранувати і комп'ютер, проте зробити це набагато складніше, ніж мініатюрну мікросхему.

Дуже часто шифрування потрібно там, де додаткове комп'ютерне обладнання абсолютно зайве. Телефони, факсимільні апарати та модеми значно дешевше обладнати пристроями апаратного шифрування, ніж вбудовувати в них мікрокомп'ютери з відповідним програмним забезпеченням.

Навіть в комп'ютерах установка спеціалізованого шифрувального обладнання створює менше проблем, ніж модернізація системного програмного забезпечення з метою додавання в нього функцій шифрування даних. В ідеалі шифрування має здійснюватися непомітно для користувача. Щоб досягти цього за допомогою програмних засобів, засоби шифрування повинні бути сховані глибоко в надрах операційної системи. З готовою і налагодженою операційною системою проробити це безболісно не так-то просто. Але навіть будь який непрофесіонал зможе під'єднати шифрувальний блок до персонального комп'ютера, з одного боку, і до зовнішнього модему, з іншого.

Сучасний ринок апаратних засобів шифрування інформації пропонує потенційним покупцям такі різновиди таких засобів:

1. самодостатні шифрувальні модулі (вони самостійно виконують всю роботу з ключами);
2. блоки шифрування в каналах зв'язку;
3. шифрувальні плати розширення.

Більшість пристроїв першого і другого типів є вузькоспеціалізованими, і тому перш ніж приймати остаточне рішення про їх придбання, необхідно досконально вивчити обмеження, які при установці накладають ці пристрої на загальну конструкцію, операційні системи та прикладне програмне забезпечення. А інакше можна витратити кошти, ні на крок не наблизившись до бажаної мети. Щоправда, іноді вибір полегшується тим, що деякі компанії пропонують комунікаційне обладнання, яке вже має встановлену апаратуру шифрування даних.

Плати розширення для персональних комп'ютерів є більш універсальним засобом апаратного шифрування і зазвичай можуть бути легко налаштовані таким чином, щоб шифрувати всю інформацію, яка записується на жорсткий диск комп'ютера, а також всі дані, що пересилаються на дискети і в послідовні порти. Як правило, захист від електромагнітного випромінювання в шифрувальних платах розширення відсутня, оскільки немає сенсу захищати ці плати, якщо аналогічні заходи не робляться щодо всього комп'ютера.

Програмне шифрування файлів

Будь-який криптографічний алгоритм можна реалізувати у вигляді відповідної програми. Переваги такої реалізації очевидні: програмні засоби шифрування легко копіювати, вони прості у використанні, їх неважко модифікувати у відповідності з конкретними потребами.

У всіх поширених операційних системах є вбудовані засоби шифрування файлів. Зазвичай вони призначені для шифрування окремих файлів, і робота з ключами цілком покладається на користувача. Тому застосування цих засобів вимагає особливої уваги. По-перше, ні в якому разі не можна зберігати ключі

на диску разом з зашифрованими з їх допомогою файлами, а, по-друге, незашифровані копії файлів необхідно видалити відразу після шифрування.

На перший погляд, шифрування файлів можна повністю уподібнити шифруванню повідомлень, відправником та одержувачем яких є одна і та ж особа, а середовищем передачі служить одне з комп'ютерних пристроїв зберігання даних (магнітний або оптичний диск, магнітна стрічка, оперативна пам'ять). Проте все не так просто, як здається на перший погляд.

Якщо при передачі по комунікаційних каналах повідомлення загубиться по дорозі від відправника до одержувача, його можна спробувати передати знову. При шифруванні даних, призначених для зберігання у вигляді комп'ютерних файлів, справи йдуть інакше. Якщо ви не в змозі розшифрувати свій файл, вам навряд чи вдасться зробити це і з другої, і з третьої, і навіть з сотої спроби. Ваші дані будуть втрачені раз і назавжди. Це означає, що при шифруванні файлів необхідно передбачити спеціальні механізми запобігання виникнення помилок в шифротексті.

Криптографія допомагає перетворити великі секрети в маленькі. Замість того щоб безуспішно намагатися запам'ятати вміст величезного файлу, людині достатньо його зашифрувати і зберегти в пам'яті використаний для цієї мети ключ. Якщо ключ застосовується для шифрування повідомлення, то його потрібно мати під рукою лише до тих пір, поки повідомлення не дійде до свого адресата і не буде ним успішно розшифровано. На відміну від зашифрованих повідомлень, шифровані файли можуть зберігатися роками, і протягом усього цього часу необхідно пам'ятати і тримати в секреті відповідний ключ.

Є й інші особливості шифрування файлів, про які необхідно пам'ятати незалежно від застосовуваного криптографічного алгоритму:

4. нерідко після шифрування файлу його незашифрована копія залишається на іншому магнітному диску, на іншому комп'ютері або у вигляді роздруківки, зробленої на принтері;
5. розмір блоку в блоковому алгоритмі шифрування може значно перевищувати розмір окремої порції даних в структурованому файлі, в результаті чого зашифрований файл виявиться набагато довше початкового;
6. швидкість шифрування файлів за допомогою обраного для цієї мети криптографічного алгоритму повинна відповідати швидкостям, на яких працюють пристрої введення / виводу сучасних комп'ютерів;
7. робота з ключами є досить непростою справою, оскільки різні користувачі повинні мати доступ не тільки до різних файлів, але і до окремих частин одного і того ж файлу.

Якщо файл являє собою єдине ціле (наприклад, містить якийсь текст), відновлення цього файлу у вихідний вид не зажадає великих зусиль: перед використанням досить просто розшифрувати весь файл. Однак якщо файл структурований (наприклад, розділений на записи і поля, як це робиться в базах даних), то розшифрування всього файлу цілком потрібно кожного разу, коли необхідний доступ до окремих порцій даних, за рахунок чого робота з таким файлом надзвичайно неефективна. Шифрування порцій даних в структурованому файлі робить його вразливим по відношенню до атаки, при якій зломисник відшукує в цьому файлі потрібну порцію даних і замінює її на іншу за своїм розсудом.

У користувача, який хоче зашифрувати кожен файл, розміщений на жорсткому диску комп'ютера, є дві можливості. Якщо він використовує один і той же ключ для шифрування всіх файлів, то згодом виявиться не в змозі розмежувати доступ до них з боку інших користувачів. Крім того, це призведе до того, що у криптоаналітика буде багато шифротексту, отриманого на одному ключі, що істотно полегшить розкриття цього ключа.

Краще шифрувати кожен файл на окремому ключі, а потім зашифрувати всі ключі за допомогою майстер-ключа. Тим самим користувачі будуть позбавлені від метушні, пов'язаної з організацією надійного зберігання безлічі ключів. Розмежування доступу груп користувачів до різних файлів здійснюватиметься шляхом розподілу безлічі всіх ключів на підмножини і шифрування цих підмножин на різноманітних майстер-ключах. Стійкість такої криптосистеми буде значно вище, ніж у випадку використання єдиного ключа для шифрування всіх файлів на жорсткому диску, оскільки ключі можна генерувати випадковим чином, тому вони будуть більш стійкими проти словникової атаки.

Віртуальні приватні мережі (VPN).

Останнім часом у світі телекомунікацій спостерігається підвищений інтерес до так званих віртуальних приватних мереж (Virtual Private Network - VPN). Це обумовлено необхідністю зниження витрат на утримання корпоративних мереж за рахунок більш дешевого підключення віддалених офісів і віддалених користувачів через мережу Internet . Дійсно, при порівнянні вартості послуг по з'єднанню декількох мереж через Internet, наприклад, з мережами Frame Relay можна помітити суттєву різницю у вартості. Однак, необхідно відзначити, що при об'єднанні мереж через Internet, відразу ж виникає питання про безпеку передачі даних, тому виникла необхідність створення механізмів, які дозволяють забезпечити конфіденційність і цілісність переданої інформації. Мережі, побудовані на базі таких механізмів, і отримали назву VPN (див. рисунок 2.1).




Рисунок 2.1 — Віртуальна приватна мережа

Що ж таке VPN? Існує безліч визначень, однак головною відмінною рисою даної технології є використання мережі Internet як магістралі для передачі корпоративного IP-трафіку. Мережі VPN призначені для вирішення завдань підключення кінцевого користувача до віддаленої мережі та з'єднання декількох локальних мереж. Структура VPN включає в себе канали глобальної мережі, захищені протоколи і маршрутизатори.

Як же працює Віртуальна приватна мережа? Для об'єднання віддалених локальних мереж у віртуальну мережу корпорації використовуються так звані віртуальні виділені канали. Для створення подібних з'єднань використовується механізм тунелювання. Ініціатор тунелю інкапсулює пакети локальної мережі (в тому числі, пакети протоколів, котрі не маршрутизуються) в нові IP-пакети, що містять в своєму заголовку адресу цього ініціатора тунелю та адресу термінатора тунелю. На протилежному кінці термінатором тунелю проводиться зворотний процес вилучення вихідного пакета.

Як вже зазначалося вище, при здійсненні подібної передачі потрібно враховувати питання конфіденційності і цілісності даних, які неможливо забезпечити простим тунелюванням. Для досягнення конфіденційності переданої корпоративної інформації необхідно використовувати певний алгоритм шифрування, причому однаковий на обох кінцях тунелю.

Для того щоб була можливість створення VPN на базі обладнання і програмного забезпечення від різних виробників необхідний деякий стандартний механізм. Таким механізмом побудови VPN є протокол Internet Protocol Security (IPSec). IPSec описує всі стандартні методи VPN. Цей протокол визначає методи ідентифікації при ініціалізації тунелю, методи шифрування, використовувані кінцевими точками тунелю і механізми обміну та управління ключами шифрування між цими точками. З недоліків цього протоколу можна відзначити те, що він орієнтований на IP.

Іншими протоколами побудови VPN є протоколи PPTP (Point-to-Point Tunneling Protocol), розроблений компаніями Ascend Communications і 3Com, L2F (Layer-2 Forwarding) - компанії Cisco Systems і L2TP (Layer-2 Tunneling Protocol), який об'єднав обидва вищеназваних протоколи. Однак ці протоколи, на відміну від IPSec, не є повнофункціональними (наприклад, PPTP не визначає метод шифрування).

Говорячи про IPSec, не можна забувати про протокол IKE (Internet Key Exchange), що дозволяє забезпечити передачу інформації по тунелю, виключаючи втручання ззовні. Цей протокол вирішує завдання безпечного управління та обміну криптографічними ключами між віддаленими пристроями, в той час, як IPSec кодує і підписує пакети. IKE автоматизує процес передачі ключів, використовуючи механізм шифрування відкритим ключем, для встановлення безпечного з'єднання. Крім цього, IKE дозволяє виробляти зміну ключа для вже встановленого з'єднання, що значно підвищує конфіденційність переданої інформації.

Програмне забезпечення для шифрування.

Альтернативним способом організації безпеки в комп'ютерній мережі є встановлення на користувачський комп'ютер різноманітних прикладних програм. Перевагою такого способу захисту трафіку є те, що звичайний

користувач Інтернету може встановити дане ПЗ, налаштувати його і, власне, користуватися. Але, все таки, більшість таких програм не є безкоштовними, налаштування потребує деяких навиків роботи в мережі. А для організації безпеки даних на рівні офісу чи підприємства такий спосіб узагалі не є вигідним. По перше, це витрати на придбання ПЗ чи ліцензії. Різноманітні програми мають різноманітне призначення. Наприклад, є такі, що захищають дані, які зберігаються на жорсткому диску, а інші просто забезпечують анонімний “серфінг” в мережі.

Але, як альтернативне рішення, воно має право на існування. Тому далі наведено короткий огляд існуючих програм для організації безпеки даних.

Hotspot Shield - надає можливість убезпечити свої сеанси відвідування Мережі. Програма здатна виявляти і блокувати шкідливе ПЗ, забезпечувати конфіденційність і доступ до заблокованих ресурсів. Доступна як безкоштовна версія, так і більш функціональна платна підписка. Основні можливості:

- захист перегляду веб-сторінок, передачі даних, Інтернет-покупок і особистої інформації в мережі за допомогою HTTPS шифрування;
- захист від крадіжки особистих даних в мережі;
- приховування IP адреси для захисту конфіденційності, забезпечення анонімного доступу до мережі;
- доступ до всієї інформації без цензури, обхід фільтрів;
- захист від прослуховування мережевих з'єднань - Wi-Fi точки доступу, готелі, аеропорти і офіси компаній.

Easy Hide IP - програма, яка дозволяє приховати реальну IP адресу і географічне місце розташування. У Easy Hide IP присутня велика кількість віддалених серверів, IP адреси яких і будуть відображатися в лог файлах Інтернет Сервіс Провайдера. Повернути свій реальний IP можна в будь-який

момент, клікнувши для цього по кнопці “Restore MY Identity”. Основні можливості Easy Hide IP:

- включення / виключення приховування реального IP адреси за бажанням користувача;
- автоматична зміна IP адреси через задані інтервали часу;
- вибір географічного розташування;
- підтримка браузерів Internet Explorer, Firefox і Chrome.
- Secure Net - дозволяє приховати роботу в мережі Інтернет, приховуючи IP адресу і забезпечуючи повністю анонімний серфінг. Використання сервісу потребує щомісячної оплати. Ключові особливості:
- Анонімний серфінг. Приховування IP адреси забезпечує приховування вашого місця розташування і повністю анонімний веб серфінг. Ніхто не буде знати хто ви і де ви знаходитесь.
- Шифрування Інтернет трафіку. Шифрування трафіку проводиться автоматично у фоновому режимі, не надаючи ніякого впливу на робочий процес.
- Захист електронної пошти. Надсилання і отримання повідомлень електронної пошти є безпечними, як частина Інтернет трафіку. Повідомлення будуть зашифровані і не можуть бути прочитані або підмінені ким-небудь.

Системи миттєвого обміну повідомленнями (ICQ та інші). Secure Net автоматично захищає всю переписку в ІМ системах.

Вибір методу рішення

Для моделювання ситуації, в якій необхідним є захист даних, що передаються в мережі, був обраний емулятор GNS3 як прикладна програма для створення і налаштування віртуальної мережі. Як рішення проблеми безпеки було обрано шифрування даних на мережевому рівні за допомогою

протоколу безпеки IPSec, налаштування якого є можливим на основі віртуального каналу зв'язку – GRE-тунелю.

Емулятор GNS3.

Існує достатньо велика кількість симуляторів та емуляторів для моделювання та конфігурування віртуальних мереж. Симулятори – імітують деякий набір команд, який є вбудованим і не можна від нього відхилитися. Прикладом є Cisco Packet Tracer. Емулятори ж навпаки – дозволяють “програвати” (виконуючи байт-трансляцію) образи (так звані прошивки) реального обладнання, без значних обмежень. Яскравим прикладом є GNS3, який і був обраний для реалізації даної роботи.

Отже, GNS3 – графічний інтерфейс для емулятора dynamips, який дозволяє змодельовати віртуальну мережу з маршрутизаторів та віртуальних машин. Дане програмне забезпечення випускається під вільною ліцензією, працює практично на всіх платформах. GNS3 має досить простий в користуванні графічний інтерфейс. Проектування мережі в даній програмі дозволяє наглядно вивчати її особливості та структуру.

Цей емулятор працює зі справжніми прошивками IOS. Наприклад, якщо придбати маршрутизатор Cisco, можна взяти їх звідти. Також в програмі можна підключати віртуальні машини VirtualBox або VMware Workstation і створювати достатньо складні схеми. Створені схеми можна прив'язувати до реальної мережі, тобто організовувати доступ до Internet.

Також однією з можливостей роботи в емуляторі є відслідковування трафіку, який передається в змодельованій мережі. Wireshark являється корисним додатком GNS3, це програмне забезпечення, що дозволяє перехоплювати та аналізувати трафік. Це може бути корисним для аналізу роботи протоколів, крім цього, аналіз даних, що передаються всередині мережі, як правило, пояснює ту чи іншу поведінку обладнання.

Початкове налаштування в GNS3 досить просте. Перш за все, необхідно додати образи IOS, зробити це можна просто через екранні форми, використовуючи спеціальний елемент головного меню.

Для створення нового проекту, потрібно заповнити екранні форми, поставити необхідні галочки для того, щоб всі налаштування збереглися і відтворилися після наступного відкриття раніше збереженого проекту.

Для вибору певного обладнання необхідно просто “перетягнути” його іконку з панелі з переліком обладнання на робочу область, все досить просто. Для запуску будь-якого обладнання є відповідна кнопка на панелі головного меню, або це можна зробити через контекстне меню. У програмі передбачене налаштування для регулювання навантаження на CPU, це додаток Idle PC. Саме цей механізм дозволяє оптимізувати використання ресурсів процесора. GNS3 служить не тільки для навчання. Програма є корисною, наприклад, для системних адміністраторів, які можуть віртуально спробувати нові конфігурації, різні образи IOS в роботі, чи взагалі зробити реконструкцію деяких частин складної мережі.

Архітектура IPsec.

IP Security - це комплект протоколів, що стосуються питань шифрування, аутентифікації і забезпечення захисту при транспортуванні IP-пакетів; до його складу зараз входять майже 20 пропозицій за стандартами і 18 RFC.

Специфікація IP Security (відома сьогодні як IPsec) розробляється Робочою групою IP Security Protocol IETF. Спочатку IPsec включав в себе 3 алгоритмозалежні базові специфікації, опубліковані в якості RFC-документів “Архітектура безпеки IP”, “Аутентифікуючий заголовок (AH)”, “Інкапсуляція зашифрованих даних (ESP)” (RFC1825, 1826 і 1827). Необхідно зауважити, що в листопаді 1998 року Робоча група IP Security Protocol запропонувала нові версії цих специфікацій, що мають у даний час

статус попередніх стандартів, це RFC2401 - RFC2412. Відзначимо, що RFC1825-27 впродовж вже декількох років вважаються застарілими і реально не використовуються. Крім цього, існують декілька алгоритмозалежних специфікацій, що використовують протоколи MD5, SHA, DES. Загальна схемі архітектури IPSec наведена на рис. 2.2.

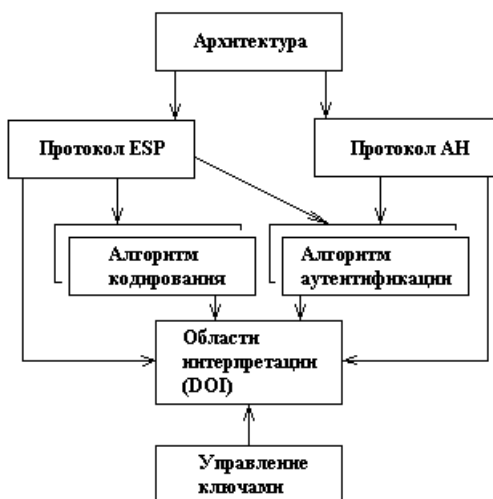


Рисунок 2.2 — Архітектура IPSec

Робоча група IP Security Protocol розробляє також і протоколи управління ключовою інформацією. У завдання цієї групи входить розробка Internet Key Management Protocol (IKMP), протоколу управління ключами прикладного рівня, не залежного від використовуваних протоколів забезпечення безпеки. В даний час розглядаються концепції управління ключами з використанням специфікації Internet Security Association and Key Management Protocol (ISAKMP) і протоколу Oakley Key Determination Protocol. Специфікація ISAKMP описує механізми узгодження атрибутів використовуваних протоколів, тоді як протокол Oakley дозволяє встановлювати сесійні ключі на комп'ютери мережі Інтернет. Раніше розглядалися також можливості використання механізмів управління ключами протоколу SKIP, проте зараз такі можливості реально практично ніде не використовуються. Створювані стандарти управління ключовою інформацією, можливо, підтримуватимуть

Центри розподілу ключів, аналогічні використуваним в системі Kerberos. Протоколами ключового управління для IPSec на основі Kerberos зараз займається відносно нова робоча група KINK (Kerberized Internet Negotiation of Keys).

Гарантії цілісності та конфіденційності даних в специфікації IPSec забезпечуються за рахунок використання механізмів аутентифікації і шифрування відповідно. Останні, в свою чергу, засновані на попередньому узгодженні сторонами інформаційного обміну т.з. “Контексту безпеки” - вживаних криптографічних алгоритмів, алгоритмів управління ключовою інформацією і їх параметрів. Специфікація IPSec передбачає можливість підтримки сторонами інформаційного обміну різних протоколів і параметрів аутентифікації і шифрування пакетів даних, а також різних схем розподілу ключів. При цьому результатом узгодження контексту безпеки є встановлення індексу параметрів безпеки (SPI), що представляє собою показник на певний елемент внутрішньої структури сторони інформаційного обміну, яка описує можливі набори параметрів безпеки.

По суті, IPSec, який стане складовою частиною IPv6, працює на третьому рівні, тобто на мережевому рівні. В результаті передані IP-пакети будуть захищені прозорим для мережевих програм та інфраструктури чином. На відміну від SSL (Secure Socket Layer), який працює на четвертому (тобто транспортному) рівні і тісніше пов’язаний з вищими рівнями моделі OSI (див. рисунок 2.3), IPSec покликаний забезпечити низькорівневий захист.

Уровни TCP/IP	Уровни ISO/OSI
4. Прикладных программ	7. Прикладных программ 6. Представление данных
3. Транспортный	5. Сеансовый 4. Транспортный
2. Межсетевой	3. Сетевой
1. Доступа к сети	2. Канальный 1. Физический

Рисунок 2.3 — Модель OSI/ISO

До IP-даних, готових до передачі по віртуальній приватній мережі, IPSec додає заголовок для ідентифікації захищених пакетів. Перед передачею по Internet ці пакети інкапсулюються в інші IP-пакети. IPSec підтримує кілька типів шифрування, в тому числі Data Encryption Standard (DES) і Message Digest 5 (MD5).

Щоб встановити захищене з'єднання, обидва учасники сеансу повинні мати можливість швидко узгодити параметри захисту, такі як алгоритми аутентифікації і ключі. IPSec підтримує два типи схем управління ключами, за допомогою яких учасники можуть узгодити параметри сеансу.

З поточною версією IP, IPv4, можуть бути використані або Internet Secure Association Key Management Protocol (ISAKMP), або Simple Key Management for Internet Protocol. З новою версією IP, IPv6, доведеться використовувати ISAKMP, відомий зараз як IKE, хоча не виключається можливість використання SKIP. Однак, слід мати на увазі, що SKIP вже давно не розглядається як кандидат управління ключами, і був виключений зі списку можливих кандидатів ще в 1997 р.

Заголовок АН

Аутентифікуючий заголовок (АН) є звичайним опціональним заголовком, і, як правило, розташовується між основним заголовком пакету IP і полем даних. Наявність АН ніяк не впливає на процес передачі інформації транспортного і більш високого рівнів. Основним і єдиним призначенням АН є забезпечення захисту від атак, пов'язаних з несанкціонованою зміною вмісту пакету, і в тому числі від підміни початкової адреси мережевого рівня. Протоколи вищого рівня повинні бути модифіковані в цілях здійснення перевірки автентичності отриманих даних.

Формат АН достатньо простий і складається з 96-бітового заголовка і даних змінної довжини, що складаються з 32-бітових слів. Назви полів достатньо ясно відображають їх вміст: Next Header указує на наступний заголовок,

Payload Len представляє довжину пакета, SPI є покажчиком на контекст безпеки і Sequence Number Field містить послідовний номер пакету (див. рисунок 2.4).

Следующий заголовок	Длина нагрузки	Зарезервировано
Индекс параметров безопасности		
Поле последовательного номера		
Данные аутентификации (переменной длины)		

Рисунок 2.4 — Формат заголовку АН

Послідовний номер пакету був введений в АН в 1997 році в ході процесу перегляду специфікації IPsec. Значення цього поля формується відправником і служить для захисту від атак, пов'язаних з повторним використанням даних процесу аутентифікації. Оскільки мережа Інтернет не гарантує порядок доставки пакетів, одержувач повинен зберігати інформацію про максимальний послідовний номер пакета, що пройшов успішну аутентифікацію, і про отримання деякого числа пакетів, що містять попередні послідовні номери (звичайно це число дорівнює 64).

Заголовок ESP

У разі використання інкапсуляції зашифрованих даних заголовки ESP є останнім у ряду опціональних заголовків, “видимих” в пакеті. Оскільки основною метою ESP є забезпечення конфіденційності даних, різні види інформації можуть вимагати застосування істотно різних алгоритмів шифрування. Отже, формат ESP може зазнавати значні зміни залежно від використовуваних криптографічних алгоритмів. Тим не менш, можна виділити такі обов'язкові поля: SPI, яке вказує на контекст безпеки і Sequence Number Field, що містить послідовний номер пакету. Поле “ESP Authentication Data” (контрольна сума), не є обов'язковим в заголовку ESP. Одержувач пакету ESP розшифровує ESP заголовок і використовує

параметри і дані вживаного алгоритму шифрування для декодування інформації транспортного рівня (див. рисунок 2.5).

Розрізняють два режими застосування ESP і АН (а також їх комбінації) - транспортний і тунельний.

Индекс параметров безопасности (SPI)		
Последовательный номер		
Данные нагрузки (переменной длины)		
Дополнение (0..255 байт)	Длина дополнения	Следующий заголовок
Данные аутентификации (переменной длины)		

Рисунок 2.5 — Формат заголовку ESP

Транспортний режим використовується для шифрування поля даних IP пакету, містить протоколи транспортного рівня (TCP, UDP, ICMP), яке, в свою чергу, містить інформацію прикладних служб. Прикладом застосування транспортного режиму є передача електронної пошти. Всі проміжні вузли на маршруті пакету від відправника до одержувача використовують тільки відкриту інформацію мережевого рівня і, можливо, деякі опціональні заголовки пакету (в IPv6). Недоліком транспортного режиму є відсутність механізмів приховування конкретних відправника і одержувача пакету, а також можливість проведення аналізу трафіку. Результатом такого аналізу може стати інформація про обсяги і напрямки передачі інформації, області інтересів абонентів, розташування керівників.

Тунельний режим застосування передбачає шифрування всього пакету, включаючи заголовок мережевого рівня. Тунельний режим застосовується у разі необхідності приховування інформаційного обміну організації із зовнішнім світом. При цьому, адресні поля заголовка мережевого рівня пакета, що використовує тунельний режим, заповнюються міжмережним екраном організації і не містять інформації про конкретний відправника

пакета. При передачі інформації з зовнішнього світу в локальну мережу конкретної організації, як адреса призначення використовується мережева адреса брандмауера. Після розшифровки фаєрволом початкового заголовка мережевого рівня пакет направляється одержувачу.

ISAKMP

Протокол ISAKMP визначає загальну структуру протоколів, які використовуються для встановлення SA і для виконання інших функцій управління ключами. ISAKMP підтримує кілька Областей Інтерпретації (DOI), однією з яких є IPSec-DOI. ISAKMP не визначає закінчений протокол, а надає “будівельні блоки” для різних DOI і протоколів обміну ключами.

Оцінка протоколу

Протокол IPSec отримав неоднозначну оцінку з боку фахівців. З одного боку, відзначається, що протокол IPSec є кращим серед всіх інших протоколів захисту переданих по мережі даних, розроблених раніше (включаючи розроблений Microsoft PPTP). На думку іншої сторони, присутня надмірна складність і надмірність протоколу. Так, Niels Ferguson і Bruce Schneier у своїй роботі “A Cryptographic Evaluation of IPsec” відзначають, що вони виявили серйозні проблеми безпеки практично у всіх головних компонентах IPsec. Ці автори також відзначають, що набір протоколів вимагає серйозного доопрацювання для того, щоб він забезпечував хороший рівень безпеки. У роботі наведено опис ряду атак, що використовують як слабкості загальної схеми обробки даних, так і слабкості криптографічних алгоритмів.

Одним із найрозповсюдженіших і найнадійніших стандартів шифрування, які використовує протокол IPSec є стандарт AES (Advanced Encryption Standard).

З моменту появи в публічному доступі, стандарт шифрування AES (Advanced Encryption Standard) став одним з найбільш часто використовуваних і найбільш безпечних алгоритмів, доступних на сьогоднішній день. Агентство Національної Безпеки США (NSA), котре додатково займається криптоаналізом, відносить цей алгоритм до рівня “Цілком Таємно”. Історія його успіху почалася в 1997 році, коли Національний Інститут Стандартів і Технологій США (NIST) оголосив конкурс на заміну застарілого стандарту шифрування DES. Алгоритм під назвою “Rijndael”, розроблений бельгійськими криптографами Джоном Діменом і Вінсентом Ріджменом, виявився дуже безпечним, високопродуктивним і гнучким. Він перевершив ряд конкурентів, і був офіційно оголошений новим стандартом шифрування AES в 2001 році.

Алгоритм “Rijndael” представляє собою симетричний блоковий шифр, котрий використовує ключі довжиною 128, 192 та 256 біт (версії AES-128, AES-192 і AES-256). Механізм роботи заснований на декількох замінах, підстановках та лінійних перетворення, кожне з яких виконується блоками по 16 байт (128 біт). Операції повторюються кілька разів, кожен з яких називається “раунд”. Протягом кожного раунду, на основі ключа шифрування обчислюється унікальний ключ раунду і вбудовується в обчислення. Завдяки подібній блокової структурі AES, зміна навіть одного біта або в ключі, або в текстовому блоці призводить до повної зміни всього шифру, що є явною перевагою щодо традиційних потокових шифрів.

Усі перетворення в шифрі мають суворе математичне обґрунтування. Сама структура і послідовність операцій дозволяють виконувати цей алгоритм ефективно як на 8-бітних, так і на 32-бітних процесорах. Це дозволяє досягти прийнятної продуктивності при роботі на найрізноманітніших платформах: від смарткарт до великих серверів. У структурі алгоритму закладена можливість паралельного виконання деяких операцій, що на

багатопроеесорних робочих станціях може підняти швидкість шифрування ще в 4 рази.

Різниця між AES-128, AES-192 і AES-256 полягає тільки в довжині ключа: 128, 192 або 256 біт - радикальне поліпшення в порівнянні з 56-бітовим ключем DES. Навіть при використанні навіть 128-бітного ключа необхідно буде витратити 149 трильйонів років для його зламу, за запевненнями NSA.

Завдяки описаним пріоритетам, AES залишається кращим алгоритмом для урядових організацій, банків та інших систем, що вимагають високий рівень безпеки, по всьому світу. Разом з тим, завдяки можливості ефективно працювати на 8 та 32-бітних процесорах, AES набув достатньо широкого використання і на рівні мережевого обладнання.

GRE тунель як спосіб організації передачі даних.

Часто зустрічається ситуація, коли необхідно з'єднати мережу віддаленого офісу з центральним. Але передача даних через транзитну мережу повинна бути організована таким чином, щоб зловмисник не зміг перехопити ці дані. IPSec протокол забезпечує шифрування даних на мережевому рівні, але він не пропустить протоколи внутрішньої динамічної маршрутизації OSPF та EIGRP. Саме тому необхідним є прокладання статичного захищеного GRE-тунелю між маршрутизаторами двох офісів через транзитну мережу Інтернет.

GRE (Generic Routing Encapsulation - загальна інкапсуляція маршрутів) - протокол тунелювання мережевих пакетів, розроблений компанією CISCO Systems. Його основне призначення - інкапсуляція пакетів мережевого рівня мережевої моделі OSI в IP пакети. Номер протоколу в IP - 47.

GRE тунель являє собою з'єднання точка - точка, його можна вважати одним з різновидів VPN тунелю, без шифрування. Основна перевага GRE це можливість передавати ширококомовний трафік, що дозволяє пропускати через такий тунель протоколи маршрутизації використовуючі його, IPSec тунелі в чистому вигляді цього не можуть. Причин для організації GRE тунелю може

бути безліч: від банальної необхідності прокинути свою мережу через чужий IP простір до використання протоколів OSPF, RIPv2, EGRP спільно з IPSec. Так само GRE може допомогти прокинути немаршрутизуючі протоколи, такі як NetBios, IPX, AppleTalk.

Тунелювання включає три протоколи:

- пасажир - інкапсульований протокол (IP, CLNP, IPX, AppleTalk, DECnet Phase IV, XNS, VINES і Apollo);
- протокол інкапсуляції (GRE);
- транспортний протокол (IP).

Застосування тунелів корисне у наступних ситуаціях:

- для підтримки багатопрокольних локальних мереж за допомогою однопротокової опорної мережі;
- для обходу обмежень ряду роутингових протоколів (наприклад: по числу проміжних станцій на шляху пакета);
- для з'єднання розосереджених підмереж;
- для організації віртуальних приватних мереж (VPN) поверх глобальних мереж (WAN).

У процесі конфігурування GRE-тунелю можна виділити обов'язкові та необов'язкові дії. До обов'язкових дій можна віднести:

- задання тунельного інтерфейсу;
- вказівка точки початку тунелю;
- вказівка точки приймача тунелю.

Необов'язковими діями під час конфігурування GRE-тунелю є:

- задання режиму тунелювання;
- задання режиму контрольного підсумовування;
- задання ключа ідентифікації тунелю;

- включення відкидання “заблудлих” пакетів.

2.2 МЕРЕЖЕВА БЕЗПЕКА НА ОСНОВІ ПРОТОКОЛІВ IPSEC I SSL VPN

Історично склалося, що багатьом організаціям важко знайти вдале співвідношення між ступенем захисту інформації в комп’ютерній мережі і витратами, що необхідно здійснити на підтримку такого захисту. Для вирішення проблеми захисту, на сьогодні існує велика кількість можливих рішень. Найактуальнішими серед них є стек протоколів IPsec та SSL VPN. Кожен з них зайняв свою нішу, та має високу популярність у своєму сегменті.

Технологію IPsec використовують для створення захищеної мережі середніх на великих компаній. Вона дозволяє безпечно передавати будь які повідомлення через IP-протокол на мережевому рівні.

Для дослідження протоколу IPsec використовувався мережевий емулятор GNS3. Модель комп’ютерної мережі являла собою поєднання, за допомогою маршрутизаторів, двох окремих офісів на комп’ютерах яких був налаштований чат. Оскільки клієнтська чат-програма передавала повідомлення без шифрування, то перехоплення пакетів за допомогою WireShark відкривало можливість повного аналізу та обробки незахищеної інформації. Після налаштування IPsec перехоплені повідомлення прочитати було не можливо.

SSL VPN найчастіше використовують для захищеного з’єднання з веб-клієнтом. SSL VPN створює захищене сесійне з’єднання, що дозволяє не турбуватися про важливу, конфіденційну інформацію.

Практична реалізація та дослідження проводилися за допомогою стимулятора Cisco Packet Tracer 7.0. Роль мережевого екрану виконував Cisco ASA. Було створено декілька груп користувачів з обмеженням доступу на

певні веб-сайти. Доступ до інформації можна було отримати лише після успішної авторизації на Cisco ASA завдяки встановленню безпечного з'єднання https, що фактично і є SSL VPN.

Отже, на сьогодні безпечна передача даних є надзвичайно важливою задачею. Проте існує багато методів вирішення цієї проблеми. Знання особливостей таких методів дозволить ефективно використовувати їх у залежності від поставленої задачі.

2.3 ОРГАНІЗАЦІЯ ШИФРУВАННЯ ДАНИХ ПРИ ПЕРЕДАЧІ В КАНАЛІ ЗВ'ЯЗКУ НА ПРИКЛАДІ GRE-ТУНЕЛЮ В СИМУЛЯТОРІ GNS3

Програмна реалізація шифрування даних при передачі в каналі зв'язку була здійснена в симуляторі GNS3 на прикладі локальних мереж двох офісів, об'єднаних через транзитну мережу Інтернет.

Для забезпечення передачі даних у змодельованій мережі були надані IP адреси інтерфейсам маршрутизаторів та комп'ютерам. Для динамічної маршрутизації використовувався EIGRP. На кожній з ОС у віртуальних машинах був встановлений клієнт-серверний чат, який працює за протоколом TCP/IP. Оскільки мережа була налаштована коректно, з'явилася можливість передачі текстової інформації між двома користувачами. Для перевірки роботи мережі клієнт з одного комп'ютеру відправив повідомлення іншому клієнту з тестовим повідомленням «mypasswordispassword».

Оскільки у даній схемі не було налаштоване шифрування, то відстежуючи трафік за допомогою програми Wireshark можна було перехопити клієнтські повідомлення. Тому відфільтрувавши трафік за протоколом TCP, є змога побачити відправлений пакет з хоста 192.168.11.1 на хост 192.168.33.1, а також повідомлення користувача з текстом «mypasswordispassword».

Для запобігання відстеження даних були проведені додаткові налаштування мережі на граничних маршрутизаторах. А саме, був

організований GRE-тунель між граничними роутерами (R1 та R3), та налаштовані параметри протоколу IPSec для шифрування даних.

Повторно відстежуючи трафік за допомогою програми WireShark було виявлено наступну різницю в клієнтських повідомленнях: адреси відправника та отримувача відображалися не як адреси хостів, а як адреси інтерфейсів маршрутизаторів 192.168.12.1 та 192.168.23.1 відповідно. Також по протоколу TCP вже неможливо відстежити дані, так як завдяки використанню протоколу IPSec, вони позначені як ESP. І найголовніше те, що тепер неможливо прочитати відправлене повідомлення. WireShark відображає лише деякі дані про те, що передані дані зашифровані.

2.4 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИЙ МЕТОД ІДЕНТИФІКАЦІЇ ТИПУ МЕРЕЖЕВОГО ТРАФІКА

Сучасні телекомунікаційні мережі характеризуються високими і надвисокими показниками пакетообігу, що обумовлює необхідність пріоритезації трафіка відповідно до вимог рівня обслуговування користувачів – Service Level Agreement (SLA) та якості мережевих сервісів – Quality of Service (QoS). Для визначення пріоритету при формуванні смуги пропускання окремого трафіка необхідно мати інструмент точної ідентифікації та класифікації трафіка. При цьому поширення мережевих додатків, які динамічно змінюють порти транспортних протоколів, використовують шифрування та інкапсуляцію трафіка в тунельний протокол, призводить до низької ефективності класифікації трафіка на основі портів чи корисного навантаження (Deep Packet Inspection) [1,2]. Вирішення цих проблем пов'язується з використанням методів машинного навчання та розпізнавання образів, де, як правило, ознаками розпізнавання виступають статистичні характеристики потоку пакетів (Flow-based Classification) [1-3]. Проте різноманітність та параметрична невизначеність інформаційних процесів, які

генерують мережевий трафік, використання методів маскуванню трафіка призводять до значного перетину класів розпізнавання в просторі ознак, що зменшує достовірність класифікації [3,4]. Особливо критично це проявляється при збільшенні потужності алфавіту класів та незбалансованості навчальних наборів даних [3,5].

Одним із перспективних шляхів підвищення точності класифікації мережевого трафіка є інформаційний синтез класифікатора в рамках інформаційно-екстремальної інтелектуальної технології (ІЕІ-технологія), яка дозволяє трансформувати апріорно нечітке розбиття простору ознак в чітку еквівалентність класів розпізнавання [6-8]. Крім цього, важливими перевагами ІЕІ-технології, є невисока обчислювальна складність вирішальних правил, що сприяє економії ресурсів мережевого пристрою в умовах високого пакетобігу.

У статті пропонується в рамках ІЕІ-технології класифікатор з ієрархічною структурою вирішальних правил, який навчається за незбалансованими наборами даних, для ідентифікації зашифрованого мережевого трафіка на прикладі додатків VoIP, SSH та BitTorrent.

Формалізована постановка задачі

Нехай дано алфавіт $\{x_m^o \mid m = \overline{1, M}\}$ класів розпізнавання, які характеризують трафік різних типів мережевого сервісу. Як реалізації кожного класу розпізнавання розглядаються впорядковані вектори статистичних характеристик потоку пакетів. Відома навчальна матриця $\{y_{m,i}^{(j)} \mid m = \overline{1, M}; j = \overline{1, n_m}; i = \overline{1, N}\}$, де M – потужність алфавіту класів розпізнавання; n_m – кількість реалізацій класу x_m^o ; N – кількість ознак розпізнавання.

Відомі s -ярусна деревоподібна бінарна ієрархічна структура класів розпізнавання і структурований вектор параметрів:

$$g = \langle \delta_{s_i}, d_s \rangle, s = \overline{1, M-1} \quad (1)$$

де $\delta_{i,s}$ – параметр, який визначає півширину симетричного рецептивного поля для i -ї ознаки розпізнавання відносно усередненого значенню i -ї ознаки класу $X_s^o \in \{X_m^o\}$, який відокремлюється у листок дерева на s -му ярусі ;

d_s – кодовий радіус гіперсферичного (вписаного в одиничний гіперпаралелепіпед) контейнера класу X_s^o , який відновлюється в радіальному базисі бі-нарного простору Хеммінга Ω_B з центром, що визначається вершиною одиничного еталонного вектора $x_{s,i} = 1, i = \overline{1, N}$.

При цьому відомі обмеження на параметри функціонування g : $\delta_{s_i} \in [0; 0,5 \cdot \delta_{H,i}]$, де $\delta_{H,i}$ – максимальна ширина рецептивного поля для i -ї ознаки розпізнавання; $0 < d_s < N$.

Необхідно в процесі навчання класифікатора трафіка визначити оптимальні значення координат вектора параметрів функціонування (1), що забезпечують максимальне значення усередненого за алфавітом класів розпізнавання критерію функціональної ефективності (КФЕ)

$$\bar{E} = \frac{1}{M-1} \sum_{s=1}^{M-1} E_s, \quad (2)$$

де E_s – інформаційний критерій функціональної ефективності навчання класифікатора розпізнавати реалізації класу X_s^o ;

$\{k\}$ – упорядкована множина кроків навчання (відновлення контейнерів класів розпізнавання).

При функціонуванні класифікатора трафіка в режимі розпізнавання необхідно прийняти рішення про належність реалізації мережевого трафіка до одного з класів мережевих сервісів $\{X_m^o | m = \overline{1, M}\}$ і призначити трафіку клас обслуговування, що відповідає вимогам SLA.

Для формування деревоподібної бінарної ієрархічної структури вирішальних правил послідовно на кожному ярусі здійснюється розбиття більших груп класів на дві менші. У найпростішому випадку достатньо здійснювати на кожному ярусі побудову контейнера для одного класу розпізнавання для його відокремлення в листок дерева. При цьому рецептивні поля для ознак розпізнавання визначаються на кожному ярусі окремо [6].

Квазіоптимізація параметра $\delta_s = \delta_{s_i}, i = \overline{1, N}$ рецептивного поля призначена для визначення стартових значень, які відповідають робочій області визначення функції інформаційного КФЕ, і здійснюється за ітераційною процедурою

$$\delta_s^* = \arg \max_{G_\delta} \left\{ \frac{1}{M-1} \sum_{s=1}^{M-1} \left[\max_{G_E \cap G_d} E_s \right] \right\} \quad (3)$$

де G_δ – область допустимих значень параметра рецептивного поля;

G_d – область допустимих значень радіусу гіперсферичного контейнера;

G_E – робоча область визначення функції КФЕ;

E_s – КФЕ навчання класифікатора на s -ярусі ієрархічної структури.

Послідовна оптимізація параметра δ_{s_i} рецептивного поля для i -ї ознаки здійснюється за ітераційною процедурою

$$\delta_{s_i}^* = \arg \left\{ \bigotimes_{l=1}^L \max_{G_\delta} \left\{ \frac{1}{M-1} \sum_{m=1}^{M-1} \left[\max_{G_E \cap G_d} E_s^{(l)} \right] \right\} \right\}, \quad (4)$$

де $E_s^{(l)}$ – КФЕ навчання класифікатора на s -ярусі при l -му прогоні послідовної процедури оптимізації;

\otimes – символ операції повторення;

L – кількість прогонів ітераційної процедури послідовної оптимізації рецептивних полів.

Базовий алгоритм [6,8] є вкладеним в процедури (3) та (4) і здійснює побудову контейнера тільки для базового класу $X_s^o \in \{X_m^o\}$, що

відокремлюється у листок деревоподібної структури

$$d_s^* = \arg \max_{\{d_s\} \in G_d} E_s, \quad (5)$$

Вибір базового класу $X_s^0 \in \{X_m^0\}$ для s -го ярусу ієрархічної структури базується на ідеї найкращого відокремлення від реалізацій чужих класів і здійснюється за таким алгоритмом (алгоритм LEARNING-1):

Крок 1. Ініціалізація лічильника ярусів дерева рішень: $s := 0$.

Крок 2. Ініціалізація лічильника класів: $k := 1$.

Крок 3. Оптимізація радіусу гіперсферичного контейнера класу X_k^0 за ітеративною процедурою (5), прийнявши за сусідній клас X_c^0 сукупність найближчих до ядра класу X_k^0 реалізацій $\{x_c^{(j)} \mid j = \overline{1, n_k}\} \in \left[\bigcup_{c=1}^{M-h} X_c^0 \right] \setminus X_k^0$.

Крок 4. $k := k + 1$.

Крок 5. Порівняння: якщо $k < M - s$, то виконується крок 3, інакше – крок 6.

Крок 6. Прийняти за листок дерева клас, що забезпечує максимальне значення інформаційного КФЕ $X_s^0 = \arg \{ \max_{\{X_m\}} \{ \max_{G_\delta} \{ \max_{G_E} \{ E_k \} \} \}$ і вилучити його з подальшого розгляду.

Крок 7. $s := s + 1$.

Крок 8. Якщо $s < M - 1$, то перехід на крок 2, інакше – «ЗУПИН».

Як КФЕ навчання класифікатора на s -му ярусі розглянемо модифіковану інформаційну міру Кульбака [7,8], в якій відношення правдоподібності представлено у вигляді відношення повної ймовірності правильного прийняття рішень P_{true} до повної ймовірності помилкового прийняття рішень P_{false} . В цьому випадку для двохальтернативних гіпотез міра Кульбака має вигляд

$$E_s^{(k)} = \left[P_{\text{true},s}^{(k)} - P_{\text{false},s}^{(k)} \right] \log_2 \frac{P_{\text{true},s}^{(k)}}{P_{\text{false},s}^{(k)}} = \left[\begin{array}{l} P_{\text{true},s}^{(k)} = p_1 D_{1,s} + p_2 D_{2,s} \\ P_{\text{false},s}^{(k)} = p_1 \alpha_s + p_2 \beta_s \\ p_1 = \frac{n_s}{n_s + n_c}; p_2 = \frac{n_c}{n_s + n_c} \\ \alpha_s = 1 - D_{1,s}; D_{2,s} = 1 - \beta_s \end{array} \right] =$$

$$= \frac{\left[n_c - n_s + 2 \cdot (n_s D_{1,s}^{(k)} - n_c \beta_s^{(k)}) \right]_*}{n_s + n_c}$$

$$\log_2 \left(\frac{n_c + (n_s D_{1,s}^{(k)} - n_c \beta_s^{(k)})}{n_s - (n_s D_{1,s}^{(k)} - n_c \beta_s^{(k)})} \right), \quad (6)$$

де $D_{1,s}^{(k)}$ – перша достовірність, обчислена на k -му кроці навчання для s -го ярусу;

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

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

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

n_s – кількість реалізацій у навчальній вибірці базового класу X_s^0 ;

n_c – кількість сусідніх реалізацій, що належать до інших класів s -го ярусу.

Нормовану модифікацію критерію (6) представимо у вигляді

$$\hat{E}_s^{(k)} = \frac{E_s^{(k)}}{E_{\max}}, \quad (7)$$

де E_{\max} – значення критерію при $D_{1,h}^{(k)} = 1$ і $\beta_h^{(k)} = 0$.

При цьому робоча (допустима) область визначення функції інформаційного КФЕ обмежена нерівностями $D_1 \geq 0,5$ та $D_2 \geq 0,5$.

Визначення належності тестової реалізації $x^{(j)}$ до контейнера класу X_s^0 здійснюється за правилом

$$\text{if } d[x_s \oplus x^{(j)}] \leq d_s \text{ then } x^{(j)} \in X_s^0 \text{ else } x^{(j)} \notin X_s^0, \quad (8)$$

де $d[x_s \oplus x^{(j)}]$ – кодова відстань від вектора $x^{(j)}$

до x_s ;

d_s – радіус контейнера класу X_s^0 , що відновлюється в бінарному просторі

ознак на s -му ярусі.

Як правило дані архівів моніторингу мережевого трафіку мають дуже великий обсяг та характеризуються різноманітністю і незбалансованістю, різним розподілом різних типів трафіку. Навчання класифікатора з використанням повного обсягу навчальних даних займе досить тривалий час, а формування вибірок меншого обсягу не гарантуватиме їх репрезентативності і призведе до втрат інформації. Для підвищення оперативності навчання інформаційно-екстремального класифікатора трафіка запропоновано наступну модифікацію алгоритму навчання (алгоритм LEARNING-2):

Крок 1. Ініціалізація масивів оптимального $\delta_{s_i}^*$ та стартового $\delta_{s_i}^{\text{start}}$ параметрів рецептивних полів для ознак розпізнавання: $\delta_{s_i}^* := 0$; $\delta_{s_i}^{\text{start}} := 0$ при $i = \overline{1, N}$.

Крок 2. Поділ великого масиву апріорно-класифікованих векторів-реалізацій на навчальну $Y = \{y_{m,i}^{(j)} \mid m = \overline{1, M}; j = \overline{1, n_{\min}}; i = \overline{1, N}\}$, де n_{\min} – мінімальний за замовчуванням обсяг вибірки, та тестову $Y_{\text{test}} = \{y_i^{(t)} \mid t = \overline{1, T}; i = \overline{1, N}\}$ матриці.

Крок 3. Запуск інформаційно-екстремального навчання за навчальною матрицею Y з квазіоп-тимізацією параметра рецептивних полів $\delta_s = \delta_{s_i}$ за процедурою (3) при стартових параметрах $\{\delta_{s_i}^{\text{start}}\}$.

Крок 4. $\delta_{s_i}^{\text{start}} := \delta_s^*$.

Крок 5. Ініціалізація лічильника векторів-реалізацій тестової матриці Y_{test} : $t := 0$.

Крок 6. Запуск інформаційно-екстремального навчання з послідовною оптимізацією параметра рецептивних полів $\{\delta_{s_i}\}$ за процедурою (4) при стартових параметрах $\{\delta_{s_i}^{\text{start}}\}$.

Крок 7. $\delta_{s_i}^{\text{start}} := \delta_{s_i}^*$.

Крок 8. $t:=t+1$.

Крок 9. Якщо $t \leq T$ то визначити належність $y^{(t)}$ до одного з класів алфавіту $\{X_m^o\}$ за правилом (7), інакше перехід до кроку 12.

Крок 10. Якщо належність вектора-реалізації $y^{(t)}$ не співпадає з апріорною класифікацією, то додати $y^{(t)}$ до навчальної матриці γ та перейти до кроку 6, інакше до кроку 8.

Крок 11. ЗУПИН.

Таким чином, алгоритм навчання класифікатора трафіку в рамках ІЕІ-технології полягає в ітераційній процедурі наближення глобального максимуму інформаційного КФЕ (2) до його граничного значення шляхом оптимізації параметрів рецептивних полів та геометричних параметрів контейнерів на кожному ярусі ієрархічної структури вирішальних правил. При цьому отримані вирішальні правила за навчальною вибіркою малого обсягу використовуються для сканування тестової вибірки з метою донавчання при невірних класифікаціях.

Реалізація системи ідентифікації мережевого трафіку

Розглянемо результати реалізації запропонованого алгоритму навчання інформаційно-екстремального класифікатора для ідентифікації зашифрованого трафіку таких застосувань як SSH (трафік дистанційного керування операційними системами та тунелювання TCP-з'єднань), VoIP (представлений в основному голосовим трафіком Skype) та BitTorrent (зашифрований трафік пірінгової мережі обміну файлами), оскільки вони останнім часом займають значну частину від загального мережевого трафіку і враховуються адміністратором при настройці QoS-механізму.

Навчальні набори даних були сформовані в процесі трасування трафіку

утилітою TcpDump [4] з наступним формуванням потоків і обчисленням ознак розпізнавання за допомогою утиліти NetMate [4,5]. Априорна класифікація реалізацій навчального трафіку основана на результатах моніторингу сокетів утилітою CurrPorts (для Windows) [5] та Net Activity Viewer (для Linux) [9].

Ознаками розпізнавання є статистичні характеристики двонаправленого потоку пакетів, де як потік розглядається ряд пакетів, що поділяють однаковий кортеж з п'яти елементів: IP-адреса джерела та отримувача, номер портів джерела і отримувача, номер протоколу. При цьому TCP-потоки обмежені тривалістю до 600 с, а UDP-потоки обмежені максимальною тривалістю між прибуттям пакетів, що становить 64 с. Загальна кількість ознак розпізнавання становить $N=37$, а саме: кількість пакетів та байтів в прямому/зворотному напрямках потоку; відношення кількості пакетів до кількості байтів корисного навантаження в прямому/ зворотному напрямках; середнє значення, мінімальне значення, перша та третя квартилі, медіана та дисперсія розміру корисного навантаження (в байтах) для вхідних/вихідних пакетів двонаправленого потоку; відношення кількості пакетів малого розміру (до 50 байтів корисного навантаження) до загальної кількості пакетів в прямому/зворотному та в обох напрямках; відношення кількості пакетів великого розміру (більше 1300 байтів корисного навантаження) до загальної кількості пакетів в прямому/зворотному та в обох напрямках; мінімальне, максимальне та середнє значення тривалості часового інтервалу між прибуттям пакетів в прямому/зворотному напрямках; відношення кількості пакетів без корисного навантаження до загальної кількості пакетів в прямому/зворотному та в обох напрямках; кількість прапорців ACK / PSN в потоці прямого/зворотного напрямку.

Збір даних моніторингу мережевого трафіку здійснювався на 10-ти комп'ютерах локальної мережі кафедри комп'ютерних наук Сумського державного університету протягом 5 годин робочого дня. Загальний обсяг

накопичених наборів даних становить 5,31 Гбайт (22 271 754 реалізацій). Набір даних незбалансований, проте була здійснена процедура видалення однакових реалізацій, що зменшило обсяг даних до 4,11 Гбайт (17 238 589 реалізацій). Для побудови в процесі виконання алгоритму LEARNING-1 ієрархічної структури вирішальних правил (рис.2.6) для 4-х класів розпізнавання використано випадкові вибірки з наявного набору даних по 100 векторів-реалізацій для кожного класу.





Рисунок 2.6– Ієрархічна структура вирішальних правил для чотирьох класів розпізнавання


Аналіз рис.1 показує, що на першому ярусі побудовано контейнер для класу x_1^o (трафік SSH), на другому ярусі побудовано контейнер для класу x_2^o (трафік VoIP), а на третьому ярусі побудовано контейнер для класу x_3^o (трафік BitTorrent). Клас x_4^o є сусіднім до класу x_3^o і представлений реалізаціями трафіка, які характеризують веб-серфінг, незашифрований обмін файлами та деякі фонові процеси оновлення системного та користувацького програмного забезпечення, DNS-запити та інше.

З метою підвищення точності класифікатора реалізується його донавчання за алгоритмом LEARNING-2. Графіки зміни максимумів нормованого КФЕ в


процесі послідовної оптимізації параметра рецептивних полів на кожному ярусі ієрархічної структури в режимах навчання (до першого максимуму $E_s^o = 1,0$) за алгоритмом LEARNING-1 та донавчання (після першого максимуму $E_s^o = 1,0$) за алгоритмом LEARNING-2 показано на рис.2.7 При цьому кожен крок оптимізації збільшує лічильник кроків k і відповідає одній зміні параметра рецептивного поля для будь-якої ознаки розпізнавання.



а



б




в

Рисинук 2.7– Графіки зміни максимумів КФЕ в процесі послідовної оптимізації параметра рецептивних полів в режимах навчання та донавчання:

а – перший ярус; б – другий; в – третій

Аналіз рис.2.7 показує, що в процесі навчання на кожному ярусі деревоподібної структури було отримано безпомилкове за навчальною матрицею вирішальне правило. Однак в процесі донавчання за алгоритмом LEARNING-2 на першому ярусі було виявлено дві помилкові класифікації тестових реалізацій, на другому ярусі – три помилкові класифікації, а на третьому ярусі – 15 помилкових класифікацій. Після додавання до навчальної матриці помилково класифікованих реалізацій вдалося побудувати безпомилковий за навчальною та тестовою матрицями класифікатор.

На рис.2.8 показано графіки залежності радіусу гіперсферичного контейнера для кожного класу, що розпізнається на s-му ярусі при оптимальних рецептивних полях для ознак розпізнавання.



Рисинук 2.8– Графіки залежності нормованого КФЕ при оптимальних рецептивних полях для ознак розпізнавання від радіусу контейнера класу:

$$a - x_1^0; a - x_2^0; a - x_3^0$$

Аналіз рис.2.8 показує, що оптимальні значення радіусів контейнерів для класів розпізнавання дорівнюють: для класу $x_1^0 - d_1^* = 7$ (тут і далі в кодових одиницях), для класу $x_2^0 - d_2^* = 3$, для класу $x_3^0 - d_3^* = 9$.

Таким чином, запропонований алгоритм інформаційно-екстремального навчання дозволяє отримати безпомилкові вирішальні правила за незбалансованими навчальними наборами даних для розпізнавання

зашифрованого трафіку додатків SSH, VoIP та BitTorrent.

Висновки

В рамках інформаційно-екстремальної інтелектуальної технології синтезовано класифікатор мережевих трафіків з підвищеною достовірністю та оперативністю. Оперативність навчання класифікатора підвищена за рахунок використання отриманих вирішальних правил в результаті навчання за вибірками малого розміру для сканування апіорно-класифікованої тестової матриці великого розміру для виявлення неправильно класифікованих реалізацій трафіку з метою донавчання. При цьому побудова безпомилкових за навчальною матрицею вирішальних правил у рамках геометричного підходу забезпечує прийняття рішень в робочому режимі в реальному темпі часу.

За результатами фізичного моделювання за даними моніторингу трафіків SSH, VoIP та BitTorrent було доведено високу ефективність розроблених алгоритмів і отримано безпомилкові за навчальними матрицями вирішальні правила.

2.5 ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ФУНКЦІОНУВАННЯ СИСТЕМИ КЕРУВАННЯ ІТ-ІНФРАСТРУКТУРОЮ ДАТАЦЕНТРУ

Останнім часом корпоративні додатки, електронна пошта, пошукові системи та електронна комерція все частіше розгортаються в обчислювальному середовищі хмарних датацентрів. Конкурентоздатність хмарних провайдерів визначається можливостями безвідмовної роботи датацентру у форматі 24/7. При цьому внаслідок високого рівня споживання електроенергії в хмарних датацентрах провайдери намагаються максимізувати ефективність використання електроенергії шляхом перерозподілу віртуальних ресурсів і відключення простоюючих фізичних серверів. Однак при мінімізації затрат

оператор хмари повинен забезпечувати відповідність метрик якості сервісу вимогам угоди про рівень обслуговування (Service Level Agreement, SLA), оскільки порушення умов SLA призводить до штрафних санкцій та віддтоку клієнтів [1].

Розроблення ефективних алгоритмів розподілу ресурсів у хмарному середовищі ускладнено відсутністю або неточністю інформації про ресурсні вимоги та поведінку конкретного завдання на навантажених гетерогенних вузлах датацентру. Априорна невизначеність функціонального стану вузла при виконанні завдання і неспроможність точної оцінки часу його виконання можуть призвести до виділення надлишкових ресурсів, які будуть простоювати, знижуючи завантаженість обчислювального середовища, або виділення недостатнього обсягу ресурсів, що призводить до накладних витрат, пов'язаних з процесом введення до експлуатації додаткових ресурсів чи міграцією задач на інший вузол. Крім того, здійснення моніторингу віртуальних машин засобами їх операційних систем чи гіпервізора пов'язане із споживанням додаткових ресурсів та некоректністю роботи засобів моніторингу при значних зниженнях продуктивності.

Найбільш ефективними інструментами підтримки безвідмовного та ефективного функціонування датацентру є аналітичні засоби аналізу архівних даних моніторингу компонентів ІТ-інфраструктури та суб'єктивно-статистичних досліджень оцінки якості сервісів [2]. Метою аналітичних засобів є формування в процесі машинного навчання чи самонавчання вирішальних правил для вчасного виявлення (активне детектування) чи прогнозування (проактивне детектування) аномальних функціональних станів компонентів ІТ-інфраструктури датацентру та аномальної поведінки користувачів чи хмарних додатків. Отримані вирішальні правила дозволяють в процесі функціонування системи керування датацентром знімати невизначеність щодо функціонального стану ІТ-інфраструктури датацентру і

як наслідок підвищити ефективність дій щодо реконфігурації та перерозподілу ресурсів.

Задача розподілу ресурсів датацентру є багатокритеріальною, оскільки необхідно одночасно забезпечити мінімум енергоспоживання, обсягу невикористаних ресурсів та порушень SLA-угод. Однак ці частинні критерії є попарно суперечливими, мають різну розмірність і є нелінійними функціями контрольованих характеристик і конфігурацій IT-інфраструктури хмарного датацентру. Подібні задачі в компромісній області мають безліч оптимальних у розумінні Парето рішень. При цьому у задачах пошуку оптимальних за Парето рішень для багатокритеріальних задач оптимізації найбільш перспективним є використання ідей та методів ройового інтелекту, що дозволяє підвищити оперативність рішень для динамічно змінюваних умов функціонування.

Таким чином, розробка нових схем кодування ознак порушення умов SLA в алгоритмах інформаційно-екстремального машинного навчання та способів згортки частинних критеріїв ефективності функціонування датацентру в популяційних алгоритмах пошуку є актуальними напрямками дослідження, що спрямовані на зниження енергозатрат та підвищення якості обслуговування кінцевих користувачів.

Аналіз літературних даних і постановка проблеми

При розробці автономних датацентрів з властивостями самоконфігурування, самонастроювання та самодіагностики набуває важливого значення задача прогнозування функціонального стану компонентів IT-інфраструктури та сервісів. Для прогнозування функціонального стану фізичних серверів при розміщенні на них нової віртуальної машини в працях [3, 4] було запропоновано використовувати багатоваріантну нейронну мережу з обчисленням ознак розпізнавання за принципом мішка слів (Bag-of-Words). Вхідний математичний опис такої прогностичної моделі формується шляхом

пошуку в архівній історії функціонування датацентру моментів зниження продуктивності його вузлів та формування за результатами кластер-аналізу архівних даних моніторингу словника віртуальних машин з різними шаблонами споживання ресурсів. Основними недоліками такого підходу є ігнорування категорійних контекстних даних і помітне зниження оперативності навчання та розпізнавання при розширенні словника ознак та алфавіту класів. При цьому, як було показано в працях [5, 6], зниження продуктивності віртуальних машин нерідко призводить до затримок та некоректності в роботі засобів моніторингу, вбудованих в гіпервізор чи операційну систему віртуальної машини, що є причиною помилкових рішень. В працях [7, 8] розглядається використання класифікатора Байеса для прогнозування зниження продуктивності вузлів хмарного кластера при призначенні на нього задачі з черги. Для уникнення перевантажень та некоректної роботи системи моніторингу авторами пропонується встановлювати конфігураційний поріг доступних ресурсів нижчим за максимальну ємність фізичного вузла. При цьому словник ознак класифікатора містить статичні та динамічні ресурсні ознаки задачі та вузла призначення, а алфавіт класів розпізнавання характеризує успішність виконання задачі. Однак статистичний метод машинного навчання класифікатора обмежує його ефективність в умовах незбалансованих та неоднорідних наборів навчальних даних, що має місце на практиці. Крім того, задача прогнозування зниження функціональної ефективності сформованих вирішальних правил досі не розглядалася.

В працях [9, 10] розглядається застосування грубого двійкового кодування спостережень, що дозволяє уніфікувати подання різнотипних ознак та прискорити обробку вхідних даних в режимах навчання та прийняття рішень. При цьому, в праці [10] було обґрунтовано використання логарифмічного інформаційного критерію функціональної ефективності (КФЕ) навчання для побудови високодостовірних вирішальних правил за малими навчальними

вибірками. Запропонована схема кодування ознак дозволяє використовувати нормовану статистику числа потраплянь значень ознак у свої поля контрольних допусків як прогностичну функцію ефективності вирішальних правил [10]. Однак даний підхід передбачає вибір одного, базового, класу, відносно якого визначається верхня і нижня межі контрольних допусків на ознаки розпізнавання. Закодовані спостереження класів розпізнавання характеризують відхилення певного рівня та напрямку лише від базового класу, що призводить до втрати частини значущої статистичної інформації про взаємне розміщення в просторі ознак спостережень будь-якої пари класів. З метою підвищення достовірності та завадозахищеності вирішальних правил може розглядатися альтернативна схема кодування, у якій система контрольних допусків на значення ознак будується відносно кожного класу розпізнавання, однак особливості реалізації та ефективність такого підходу досі не були дослідженими. При цьому підвищення інформаційної спроможності вирішальних правил є актуальною задачею, оскільки ряд частинних критеріїв ефективності функціонування датацентру обчислюються за результатами прогнозу функціонального стану його компонентів та сервісів.

Для спрощення багатокритеріальної задачі керування параметрами функціонування датацентру її, як правило, зводять до однокритеріальної багатопараметричної задачі оптимізації. У праці [11] було запропоновано евристичний алгоритм розміщення віртуальних машин на фізичних серверах, оснований на максимізації адитивної згортки частинних критеріїв, однак використання цієї згортки має сенс лише у випадку випуклості множини допустимих рішень і як показано в праці [12] на практиці це нерідко призводить до нестійкості рішень. В праці [13] пропонується мультиплікативна згортка частинних критеріїв, яка з успіхом використовується у багатьох економічних задачах, однак умовою парето-оптимальності рішень за цією згортою крім випуклості множини

допустимих рішень є увігнутість функції логарифму згортки відносно кожного з частинних критеріїв. В працях [14, 15] показано, що на адекватність способу згортки частинних критеріїв впливає топологічний розподіл аналізованих альтернатив в просторі частинних критеріїв – випуклість чи увігнутість області Парето відносно кожної пари координат. При цьому різні способи згортки частинних критеріїв можуть призводити до суттєво відмінних результатів, а вибір процедури згортки не може бути до кінця формалізований і визначається специфікою задачі, цілями, досвідом та інтуїцією дослідника. Тому дослідження та аналіз алгоритмів формування узагальненого показника ефективності функціонування датацентру є важливими задачами інформаційного синтезу системи керування ІТ-інфраструктурою датацентру.

Ціль і задачі дослідження

Мета даної роботи полягає в підвищенні ефективності функціонування здатної навчатися системи керування хмарним датацентром в умовах гетерогенності фізичних вузлів та сервісів.

Для досягнення поставленої мети пропонується розв’язання таких задач:

– розробити алгоритми інформаційно-екстремального машинного навчання системи керування датацентром з використанням системи контрольних допусків на значення ознак, яка окремо визначається для кожного класу розпізнавання;

– розробити алгоритм прогнозування моменту зниження функціональної ефективності прогностичних вирішальних правил з метою визначення моменту перенавчання системи керування датацентром;

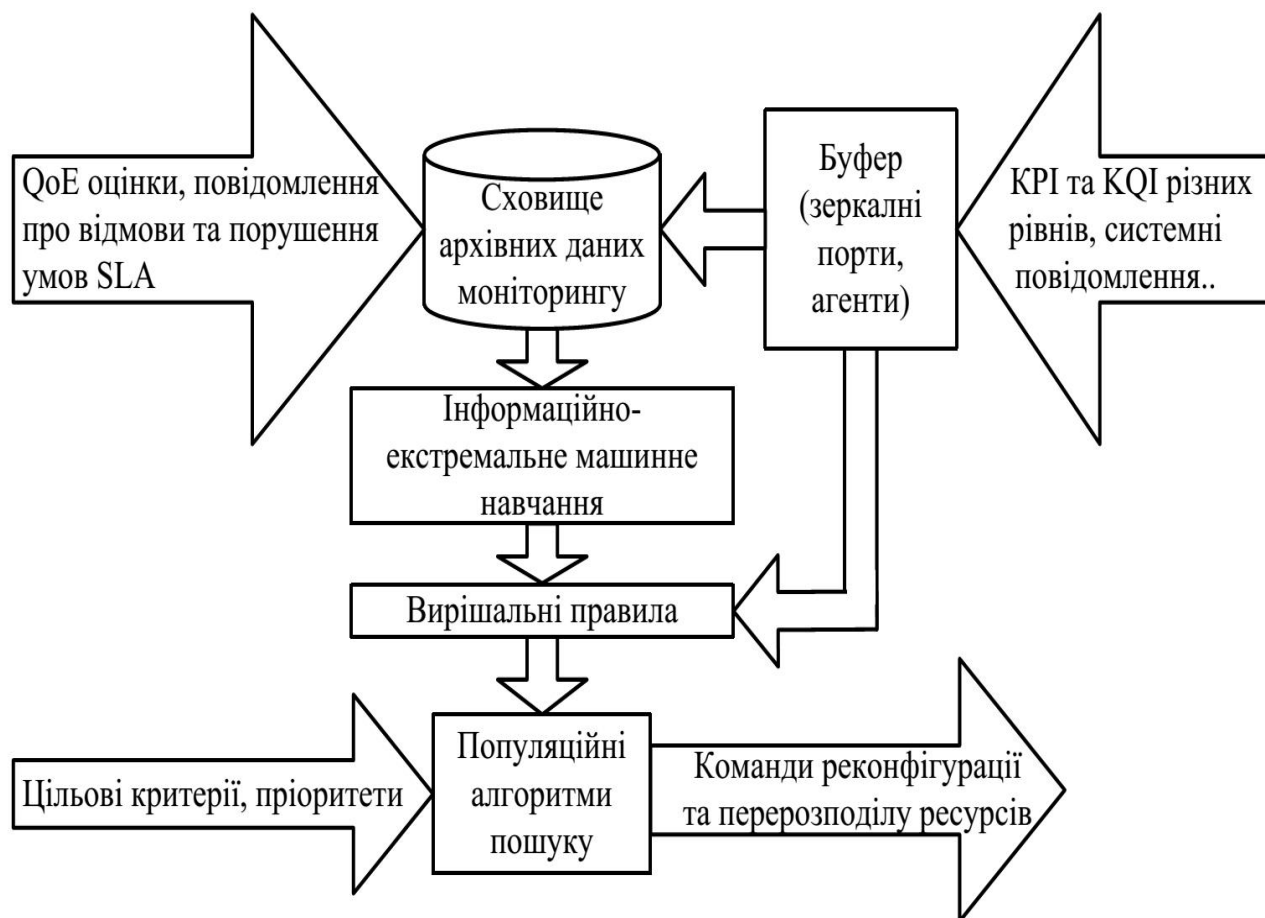
– визначити оптимальний спосіб згортки частинних критеріїв для задачі розміщення віртуальних машин на фізичних серверах хмарного датацентру.

Алгоритми функціонування інтелектуальної системи керування ІТ-інфраструктурою датацентру

Алгоритм функціонування інтелектуальної системи керування датацентром повинен включати в себе процедури моніторингу обчислювального середовища та накопичення знань про взаємозв'язок небажаних функціональних станів середовища з його характеристиками та подіями в ньому, що реєструються та архівуються.

При цьому основним джерелом інформації є ключові показники продуктивності (Key Performance Indicators, KPI), ключові показники якості KQI (Key Quality Indicator, KQI) та системні повідомлення, які зчитуються на різних рівнях хмарної системи.

На рис. 2.8. показано узагальнену структурну схему системи керування датацентром.



Рисинок 2.8.– Узагальнена структурна схема системи керування датацентром

Оцінка поточного функціонального стану може бути здійснена шляхом перевірки виконання умов договору про рівень обслуговування (Service Level Agreement, SLA), що містить граничні значення цільових параметрів (Service Level Objectives, SLO), до яких належить і сприйняття якості обслуговування (Quality of Experience, QoE). При використанні категоріальних ознак з метою врахування частоти їх появи в тому чи іншому функціональному стані компонента датацентру здійснюється їх частотне перекодування, при якому кожне значення категоріальної ознаки представляють частотами її появи в кожному з класів розпізнавання. При цьому процес кодування векторів спостережень пропонується здійснювати шляхом порівняння значення i -ї ознаки з відповідним нижнім $A_{L,m,i}$ та верхнім $A_{U,m,i}$ контрольними допусками класу розпізнавання, які розраховуються за формулами

$$A_{L,m,i} = \bar{y}_{m,i} \left[1 - \frac{\delta_{m,i}}{\delta_{\max}} \right], \quad (1)$$

$$A_{U,m,i} = \bar{y}_{m,i} \left[1 + \frac{\delta_{m,i}}{\delta_{\max}} \right], \quad (2)$$

де $\bar{y}_{m,i}$ – усереднене значення ознаки в базовому класі; $\delta_{m,i}$ – параметр поля контрольних допусків для i -ї ознаки розпізнавання; δ_{\max} – максимальне значення параметра поля контрольних допусків.

Формування бінарної навчальної матриці $\{x_{m,j}^{(i)} \mid i = \overline{1, N}; j = \overline{1, n}; m = \overline{1, M}\}$, де N – кількість ознак розпізнавання, n – кількість векторів-реалізацій в класі та M – кількість класів функціонального стану, здійснюється за правилом

$$x_{m, M^*(i-1)+k}^{(i)} = \begin{cases} 1, & \text{if } A_{L,k,i} \leq y_{m,i}^{(i)} \leq A_{U,k,i}; \\ 0, & \text{else;} \end{cases} \quad k = \overline{1, M}. \quad (3)$$

Запропонована схема кодування (3) дозволяє збільшити різноманітність двійкових векторів-реалізацій та враховувати рівень та напрям відхилення розподілу векторів-реалізацій кожної пари образів між собою.

Ітераційна процедура оптимізації параметра полів контрольних допусків на ознаки розпізнавання здійснюється шляхом максимізації в процесі навчання системи керування усередненого за алфавітом класів розпізнавання інформаційного критерію функціональної ефективності навчання (КФЕ)

$$\{\delta_i^* | i = \overline{1, n}\} = \operatorname{argmax}_{G_\delta} \left\{ \max_{G_E \cap G_d} \bar{E} \right\}, \quad (4)$$

де $\bar{E}^{(k)}$ – усереднене значення інформаційного КФЕ; G_δ – область допустимих значень параметра полів контрольних допусків на значення ознак; G_E – допустима область визначення функції інформаційного КФЕ; G_d – область допустимих значень радіусу гіперсферичних контейнерів класів розпізнавання, що відновлюються у бінарному просторі Хеммінга.

Процедура оптимізація радіусу контейнерів є вкладеною в процедуру (4) і може здійснюватися методом прямого перебору з заданим кроком, оскільки кількість кроків такого пошуку є відносно малою.

Як критерій ефективності машинного навчання класифікатора розглядається модифікація інформаційної міри Кульбака [10]:

$$E_m = [1 - (\alpha_m^{(k)} + \beta_m^{(k)})] * \log_2 \left[\frac{2 - (\alpha_m^{(k)} + \beta_m^{(k)})}{(\alpha_m^{(k)} + \beta_m^{(k)})} \right], \quad (5)$$

де α_m – помилка другого роду при розпізнаванні реалізацій класу x_m^o ; β_m – помилка другого роду.

Допустима область визначення функції інформаційного КФЕ (5) обмежена нерівностями $\alpha_m < 0,5$, $\beta_m < 0,5$ та $d_m < d(x_m \oplus x_c)$, де d_m – радіус гіперсферичного

контейнера класу x_m^o , $d(x_m \oplus x_c)$ – кодова відстань між усередненим вектором класу x_m^o та найближчого до нього усередненим вектором класу x_c^o .

Для прогнозування моменту зниження функціональної ефективності інформаційно-екстремальних вирішальних правил на останньому етапі машинного навчання здійснюється відображення двійкової матриці $\|x_{m,i}^{(i)}\|$ на множину вільних статистик, інваріантних до широкого сімейства законів розподілу ймовірностей, з подальшим формуванням варіаційного ряду екстремальних порядкових статистик (ЕПС) $\langle \{S_{m,n}^*\} \rangle$. При цьому як одновимірна статистична характеристика вибіркової множини розглядається нормована статистика числа потраплянь ознак у свої поля контрольних допусків за n випробувань [10]

$$S_{m,n} = \sum_{j=1}^n \left(\frac{k_{m,j} - \bar{k}_{m,n}}{s_{m,n}} \right)^2, \quad m = \overline{1, M}, \quad (6)$$

де $k_{m,j}$ – число успіхів при j -му випробуванні; $\bar{k}_{m,n}$ – вибіркове середнє числа успіхів після n випробувань; $s_{m,n}^2$ – вибіркова незміщена дисперсія за n випробувань.

Статистика (6) має розподіл χ^2 і залежить тільки від обсягу випробувань n . Вільна статистика $S_{m,n}$ є членом варіаційного ряду – порядковою статистикою, ранг якої визначається номером кроку навчання. При цьому нижні та верхні довірчі межі блоків варіаційного ряду $\langle \{S_m^*\} \rangle$ рекомендується обчислювати поділивши відстані між сусідніми ЕПС на рівні частини.

У робочому режимі системи керування визначається поточний клас функціонального стану віртуальної машини та формується поточна ЕПС. Якщо ЕПС виходить за межі варіаційних блоків, то приймається рішення про необхідність перенавчання системи, внаслідок зміни структури споживання ресурсів віртуальними машинами датацентру.

Кожне z -те рішення P_z щодо розподілу фізичних ресурсів датацентру між R віртуальними машинами, які очікують рішення в часовому вікні Δt , кодується вектором натуральних чисел

$$P_z = \langle p_{z,1}, \dots, p_{z,r}, \dots, p_{z,R} \rangle, \quad (7)$$

де $p_{z,r}$ – номер фізичного вузла на який призначається r -та віртуальна машина.

В робочому режимі система керування повинна приймати оптимальне оперативне рішення P_z^* щодо розподілу ресурсів датацентру. Оцінка оптимальності рішення відбувається на кожному кроці пошуку глобального екстремуму згортки частинних критеріїв, до яких належить рівень енергоспоживання та прогнозованих порушень умов SLA, обсяг невикористаних ресурсів та інші.

У загальному випадку для надання рівномірності впливу кожного з частинних критеріїв на значення згортки необхідно вирівняти діапазони зміни значень частинних критеріїв шляхом масштабування і зведення їх значень до безрозмірної шкали $[0,1]$ за правилом

$$k_i' = \begin{cases} 0, & k_i \leq k_i^{\min}; \\ \frac{(k_i - k_i^{\min})}{(k_i^{\max} - k_i^{\min})}, & k_i^{\min} < k_i < k_i^{\max}; \\ 1, & k_i > k_i^{\max}; \end{cases}$$

де k_i^{\min} , k_i^{\max} – відповідно нижня та верхня межі допустимої області значень i -го частинного критерію.

Під час нормування та формування формули згортки необхідно враховувати, що часткові критерії не є односпрямованими: частина часткових критеріїв має бути максимізована, частина – мінімізована. Тому часткові критерії поділяють на стимулятори (які мають бути максимізовані) та дестимулятори

(які повинні мінімізуватися). Формула нормування стимуляторів може бути спрощена і мати вигляд

$$k_i' = \frac{k_i}{k_i^{\max}}. \quad (8)$$

Формула нормування дестимуляторів може бути спрощена аналогічно

$$k_i' = \frac{k_i^{\min}}{k_i}. \quad (9)$$

Для охоплення широкого кола задач було розроблено велику кількість модифікацій адитивно-мультиплікативних згорток як класичного виду, так і побудованих на основі поліному Колмогорова-Габора [16]. В працях [15, 16] було запропоновано експоненціальну та ентропійну згортки, які охоплюють широке коло задач, мають просту формулу обчислення і мінімальну кількість параметрів. З урахування (8) та (9) адитивно-мультиплікативну згортку можна представити у вигляді

$$F = \sum_{i=1}^{K_1} \omega_i \frac{k_i}{k_i^{\max}} + \sum_{i=K_1+1}^{K_2} \omega_i \frac{k_i^{\min}}{k_i} + \prod_{i=1}^{K_1} \left(\frac{k_i}{k_i^{\max}} \right)^{\omega_i} \prod_{i=K_1+1}^{K_2} \left(\frac{k_i^{\min}}{k_i} \right)^{\omega_i}, \quad (10)$$

де ω_i – вага (пріоритет) і-го критерію, для якого повинна виконуватися умова

$$\sum_{i=1}^{K_1+K_2} \omega_i = 1.$$

Формула згортки, побудована за принципом інформаційної ентропії, відбиває змістовне наповнення поняття корисності як інформаційної категорії і має такий вигляд

$$F = \sum_{i=1}^{K_1} \omega_i \left(\frac{k_i}{k_i^{\max}} \right)^{\omega_i} + \sum_{i=K_1+1}^{K_2} \omega_i \left(\frac{k_i^{\min}}{k_i} \right)^{\omega_i}. \quad (11)$$

Значення ваги кожного частинного критерію може бути обчислене на основі методів, які ґрунтуються на попарному порівнянні критеріїв чи аналітичній залежності показників важливості критеріїв, та формальних методів, таких як метод базового критерію чи метод Черчмена-Акоффа [17]. Проте в умовах апріорної невизначеності відповідно до принципу Бернуллі-Лапласа можна прийняти вагу критеріїв однаковою і рівною

$$\omega_i = \frac{1}{K_1 + K_2}.$$

Гетерогенність, ієрархічність інформаційно-телекомунікаційного середовища, багатофакторність та нестационарність процесів споживання ресурсів обумовлюють нелінійність, багатоекстремальність та високу розмірність оптимізаційної задачі. З метою підвищення оперативності пошуку як оптимального рішення щодо розподілу ресурсів, так і оптимального вектора параметрів прогностичних вирішальних правил має сенс використати популяційні алгоритми, в основі яких лежать ідеї, запозичені в природи, а також базові постулати універсальності, фундаментальності, властиві самоорганізації природних систем. В даній роботі пропонується обрати популяційний алгоритм пошуку косяком риб (Fish School Search, FSS), який відрізняється простотою реалізації, інтерпретабельністю та високою швидкістю збіжності [18]. В цьому алгоритмі позиція агента в N-вимірному просторі рішень представлена у вигляді числового вектору R^N довжиною N, який відповідає вектору параметрів, що оптимізується.

В алгоритмі FSS косяк риб є агрегацією агентів популяції, які рухаються приблизно з однією й тією ж швидкістю і орієнтацією, підтримуючи

приблизно однакову відстань між собою. Індивідуальний успіх кожної риби в процесі пошуку рішення характеризується її вагою, що відіграє роль пам'яті. Кожна ітерація пошуку виконує дві групи операторів – оператори годування та оператори плавання.

Оператор годування формалізує успішність дослідження агентами тих чи інших областей “акваріуму” і полягає в обчисленні ваги z -го агента, яка пропорційна нормалізованій різниці значень фітнес-функції на наступній та поточній ітераціях

$$w_z[k+1] = w_z[k] + \frac{J(P_z[k+1]) - J(P_z[k])}{\max(J(P_z[k+1]), J(P_z[k]))}, \quad z = \overline{1, Z},$$

де $P_z[k+1]$, $P_z[k]$ – позиція z -го агента в багатовимірному просторі рішень на k -й та $(k+1)$ -й ітерації алгоритму FSS.

Максимально можливе значення ваги агента w_z у алгоритмі FSS обмежується значенням $w_{\max} > 0$. При цьому під час ініціалізації популяції всім агентам присвоюється вага, що рівна $w_{\max} \cdot 0,5$.

В алгоритмі FSS розрізняють три види плавання – індивідуальне, інстинктивно-колективне та колективно-вольове. Ці види плавання здійснюються послідовно один за одним в окремі інтервали часу

$$(t_1, t_2], (t_2, t_3], (t_3, t_4), \quad t_1 < t_2 < t_3 < t_4, t_4 = t_1 + 1.$$

Під час індивідуального плавання агентів відбувається їх переміщення, що має рівноймовірний випадковий характер. При цьому за одну ітерацію алгоритму FSS крок індивідуального плавання виконується фіксовану кількість разів. Компоненти кроку переміщення v_z^{ind} рівномірно розподілені в заданому інтервалі v_{\max}^{ind}

$$V_z^{\text{ind}} = U(0;1)v_{\text{max}}^{\text{ind}}, \quad z = \overline{1, Z},$$

де $U(0;1)$ – випадкове число із діапазону $(0;1)$.

В процесі інстинктивно-колективного плавання на кожного з агентів чинять вплив всі інші агенти популяції і цей вплив пропорційний індивідуальним успіхам агентів. При цьому позиції агентів обчислюються за формулою

$$P_z^{t_3} = P_z^{t_2} + \frac{\sum_j V_j^{\text{ind}}(t_2)(J(P_j^{t_2}) - J(P_j^{t_1}))}{\sum_j J(P_j^{t_2}) - J(P_j^{t_1})}, \quad j = \overline{1, Z}. \quad (12)$$

Колективно-вольове плавання полягає у зміщенні всіх агентів у напрямку поточного центру тяжіння популяції за умови збільшення сумарної ваги косяка риб в результаті індивідуального та інстинктивно-колективного плавання. Якщо сумарна вага зменшилась, то зміщення відбувається в протилежному напрямку. Колективно-вольове плавання виконується за правилами

$$P_z^i = P_z^{t_3} \pm v^{\text{vol}}(P_z^{t_3} - P_c^{t_3}), \quad z = \overline{1, Z}, \quad (13)$$

де $P_c^{t_3}$ – координати центра тяжіння косяка риб, що визначаються за формулою

$$P_c^{t_3} = \frac{\sum_z w_z^{t_3} P_z^{t_3}}{\sum_z w_z^{t_3}}.$$

У формулі (6) знак плюс використовується за умов $\sum_z w_z^{t_3} > \sum_z w_z^{t_3-1}$, а знак мінус – в протилежному випадку. При цьому розмір кроку переміщення агентів v^{vol} є випадковою величиною

$$v^{vol} = v_{max}^{vol} U(0;1),$$

де v_{max}^{vol} – знакододатне значення максимально допустимої довжини кроку переміщення при колективно-вольовому плаванні.

Таким чином, запропонований алгоритм функціонування системи керування датацентром оснований на зведенні багатокритеріальної задачі оптимізації до однокритеріальної та пошуці за популяційним алгоритмом косяка риб глобального максимуму узагальненого критерію ефективності функціонування датацентру. При цьому такі частинні критерії як рівень дотримання умов SLA знаходять шляхом прогнозування, де прогностичні вирішальні правила формуються в процесі інформаційно-екстремального машинного навчання за вибірковими даними моніторингу і автоматично корегуються при зміні структури споживання віртуальними машинами фізичних ресурсів датацентру.

Результати фізичного моделювання інтелектуальної системи керування ІТ-інфраструктурою дата центру

Для фізичного моделювання було створено датацентр на базі 20 серверів з процесорами типу Intel (в тому числі Atom і Xeon), які відрізняються між собою кількістю ядер, розміром кеш-пам'яті, тактовою частотою та споживанням енергії. На серверах розгортаються віртуальні машини, одна частина з яких виконує функції віртуальних вузлів Hadoop кластера для обробки гетерогенних задач розподіленої обробки даних за технологією MapReduce, таких як PiEstimator (оцінка числа Pi з точністю 1-го мільйонного знаку), WordCount (обчислення частоти появи слів в 15GB даних); Sort (сортування 18GB даних), Grep (пошук співпадінь за випадково обраним регулярним виразом в 6GB даних), TeraSort (сортування 1GB даних), Kmeans (кластер-аналіз 6GB числових даних). Інша частина віртуальних

машин виконує функції веб-серверів, на базі яких працюють сервіси онлайн доступу до книг та додатки типу Micro Web App чи PHP/MySQL. Робоче навантаження на сервери генерується клієнтами, що запрограмовані на формування сумарної мінімальної потреби в ресурсах, яка змінюється в часі за законом, який показано на рис. 2.9




Рисунок 2.9– Графік зміни навантаження датацентру протягом доби

Як інструмент розгортання хмарної платформи датацентру використано вільне програмне забезпечення Apache CloudStack, написане на мові java [19]. Функцію гіпервізора виконує XenServer [19]. Сховище даних керується за допомогою NetApp та Cumulus [19]. Apache CloudStack підтримує різноманітні алгоритми керування розміщенням віртуальних машин, наприклад, firstfit, random, worstfit та інші, проте в даному дослідженні було розроблено власний планувальник шляхом наслідування від класу nova.scheduler.driver.Scheduler та перевизначення згідно із метою дослідження наступних методів `schedule_run_instance` та `select_destinations`.

Задача консолідації віртуальних машин датацентру поділяється на чотири підзадачі: детектування недовантаження серверів; детектування перевантаження серверів; відбір віртуальних машин для переміщення; розміщення віртуальних машин на серверах. Для простоти порівняння спочатку було реалізовано алгоритм розміщення віртуальних машин MBFD (Modified Best Fit Decreasing), основна ідея якого полягає в сортуванні

віртуальних машин, що підлягають міграції, в порядку спадання їх ресурсних потреб і їх призначенні на найбільш енергоефективні сервери, що мають достатній обсяг ресурсів [20]. При цьому за замовчуванням алгоритм детектування недовантаження знаходить найменш завантажені сервери і намагається перемістити його віртуальні машини за алгоритмом MBFD на інші сервери. Для дослідження запропонованих алгоритмів їх ефективність буде порівнюватися з алгоритмом MBFD.

В даному дослідженні пропонується здійснювати оптимізацію розподілу віртуальних машин шляхом популяційного пошуку за інтегральними критеріями (10) та (11). При цьому з метою врахування гетерогенності віртуальних машин та серверів пропонується перед переміщенням прогнозувати порушення умов SLA внаслідок конкуренції віртуальних машин на спільні фізичні ресурси.

Навчання системи керування прогнозуванню порушень умов SLA внаслідок конкуренції віртуальних машин за ресурси фізичних серверів здійснюється як для рівня IaaS (Infrastructure-as-a-Service), так і для рівня SaaS (Software-as-a-Service). Тому для запитів клієнтів було прикріплено умови користувацького SLA у вигляді таких показників:

- максимальний час, протягом якого користувач згоден очікувати результат, T_d ;
- ціна яку користувач готовий заплатити за послугу, B_d ;
- розмір компенсації за порушення дедлайну, C_p ;
- обсяг файлів, що надсилають користувачі, F_s ;
- довжина запиту користувача (в мільйонах інструкцій, що виконуватимуться на віртуальному вузлі), M_i .

Кожен фізичний вузол в експериментальній середовищі було описано ресурсним SLA у вигляді показників:

- час розгортання віртуальної машини, T_{vm} ;
- вартість години використання віртуальної машини, C_{vm} ;

- вартість переміщення даних між користувачами та віртуальною машиною, Cfs;
- швидкість опрацювання задач користувача в мільйонах інструкцій за секунду, M;
- швидкість передачі даних між користувачем та фізичним вузлом, Sfs.

У зв'язку з обмеженістю ресурсів датацентру прогнозування порушень умов SLA внаслідок конкуренції віртуальних машин за спільні фізичні ресурси дозволяє приймати рішення оптимальні у вартісному сенсі. При цьому повторюваний характер задач, що вирішуються додатками віртуальних машин, забезпечує можливість застосування методів машинного навчання для аналізу log-даних трасування роботи віртуальних машин для синтезу прогностичної моделі. Вхідний математичний опис такої моделі включає результати кластер-аналізу даних трасування роботи віртуальних машин за алгоритмом k-середніх. Утворені таким чином групи (класи) віртуальних машин характеризують існуючі в датацентрі шаблони споживання різного типу ресурсів фізичного сервера. При цьому словник ознак класифікатора віртуальних машин включає середній обсяг використання ресурсу процесорів, оперативної пам'яті, файлу підкачки, мережевого каналу, дискового простору, середню інтенсивність операцій вводу-виводу з дисковою пам'яттю.

Для навчання прогностичного класифікатора порушення умов SLA внаслідок розміщення обраної віртуальної машини на обраному фізичному вузлі пропонується використати такий словник ознак:

- нормалізовані відносно потреб обраної віртуальної машини обсяги вільних ресурсів (CPU, RAM, I/O Disk, Network) обраного фізичного вузла;
- нормалізовані кількості віртуальних машин кожного класу (б кластерів) на обраному фізичному вузлі з урахуванням обраної віртуальної машини, що планується на ньому розмістити;
- розрахунковий час виконання запиту $T_e = T_d - T_{vm} - F_s / S_{fs} - M_i / M$;

– розрахунковий залишок бюджету $B_r = B_d - C_{fs} * F_s / S_{fs} - C_{vm} * M_i / M$.

Визначення належності вектора розглянутих ознак до одного з класів порушення умов SLA з метою формування навчальної вибірки здійснюється за результатами фіксації в даних моніторингу таких подій: задача направлена планувальником на хостову машину для запуску; для задачі виконується перепланування (міграція); задача виконана без порушень умов SLA.

На рис. 2.10 показано графік залежності усередненого значення нормованого інформаційного КФЕ (5) від кількості ітерацій оптимізації параметра поля контрольних допусків на значення ознак (4) за ройовим алгоритмом пошуку.




Рисунок 2.10– Графік зміни максимумів усередненого за алфавітом класів значення нормованого критерію (5) в процесі ройової оптимізації системи контрольних допусків: *а* – однорівнева система контрольних допусків; *б* – багаторівнева система контрольних допусків

Аналіз рис.2.10а показує, що інформаційно-екстремальне машинне навчання за триційним алгоритмом з єдиним базовим класом не дозволяє отримати високодостовірні вирішальні правила, а відповідне значення глобального максимуму усередненого нормованого КФЕ навчання класифікатора становить $\bar{E} = 0,29$, що відповідає такому значенню точності $\bar{P}_{true} = 0,92$. Аналіз

рис. 2.10б показує, що побудова системи контрольних допусків для кожного класу розпізнавання $\{\delta_{i,m}^*, i=\overline{1,N}; m=\overline{1,M}\}$ дозволяє отримати граничне значення інформаційного критерію $\bar{E}^* = 1,0$ та отримати безпомилкові за навчальною матрицею вирішальні правила, тобто $\bar{P}_{\text{true}}^* = 1,0$.

На рис. 2.11 наведено графіки залежності нормованого КФЕ (5) від радіусів контейнерів відповідних класів при оптимальній системі контрольних допусків на значення ознак розпізнавання.




Рисунок 2.11– Графіки залежності нормованого КФЕ (5) від радіусів контейнерів класів: *а* – x_1^o ; *б* – x_2^o

Аналіз рис. 2.11 показує, що максимальні значення КФЕ навчання для класів x_1^o та x_2^o дорівнюють $E_1^* = 1,0$ та $E_2^* = 1,0$ відповідно, а оптимальні значення радіусів відповідних контейнерів класів розпізнавання – $d_1^* = 7$, $d_2^* = 7$ (в кодівих одиницях). Граничні значення КФЕ для класів x_1^o та x_2^o свідчать про побудову для них безпомилкових за навчальною матрицею вирішальних правил. При цьому міжцентрова кодова відстань становить $d(x_1^o \otimes x_2^o) = 14$, що

свідчить про компактність векторів-реалізацій в субперецептуальному та чіткість розбиття в двійковому просторі Хеммінга.

На рис.2.12 показано залежність операційних витрат (у відносних одиницях), які включають сумарну вартість міграції віртуальних машин, компенсацій за порушення SLA та витрати на електроенергію, на кожному кроці прийняття рішень за алгоритмом MBFD та його модифікаціями з прогнозуванням порушення SLA та оптимізацією за критеріями (10) та (11) відповідно.




Рисунок 2.12– Гістограма зміни операційних витрат для різних алгоритмів планування залежно від навантаження датацентру на відповідному кроці прийняття рішень: *a* – MBFD; *б* – прогностична модифікація MBFD з критерієм (10); *в* – прогностична модифікація MBFD з критерієм (11)

Аналіз рис. 2.12 показує, що використання прогностичних вирішальних правил дозволяє зменшити операційні витрати внаслідок зменшення кількості порушення умов SLA та зменшення простоюючих фізичних ресурсів без перевантаження навантажених фізичних вузлів. При цьому під час збільшення навантаження датацентру більш оптимальною є згортка критеріїв (10), а при зменшенні навантаження датацентру кращі результати можна отримати при використанні згортки (11).

Таким чином, розроблений алгоритм інформаційно-екстремального машинного навчання для прогнозування порушення SLA дозволяє підвищити ефективність мінімізації операційних витрат щодо керування ресурсами датацентру. При цьому одна з розглянутих згорток частинних критеріїв оптимізації є більш ефективною при збільшенні навантаження датацентру, а інша – при зменшенні потреб у фізичних ресурсах датацентру.

Обговорення результатів імітаційного моделювання

Як видно з рис. 2.12, зростання операційних витрат системи керування датацентром пропорційне сумарним ресурсним потребам користувачів в обслуговуванні, однак використання популяційного пошуку з прогнозуванням порушень умов SLA дозволяє зменшити рівень витрат порівняно з алгоритмом MBFD. При цьому згортка критеріїв (10) виявилась більш чутливою до рівня енергоспоживання, що дозволяє підвищити ефективність планування на етапі наростання навантаження датацентру, в той час як згортка (11) є більш чутливою до рівня простоюючих фізичних ресурсів, що обумовлює її ефективність при зниженні навантаження датацентру.

Запропонована модифікація алгоритму інформаційно-екстремального машинного навчання за вибіркою, що сформована в процесі моніторингу роботи датацентру, керованого за алгоритмом MBFD, порівняно з традиційним алгоритмом дозволяє підвищити функціональну ефективність системи керування та отримати безпомилкові за навчальною матрицею вирішальні правила. Проте внаслідок розширення набору сервісів, що розгортаються на базі віртуальних машин датацентру, з'являються нові шаблони споживання фізичних ресурсів, що призводить до зміни статистичних характеристик образів і відповідно зменшення функціональної ефективності сформованих до цього вирішальних правил. На рис. 6, а показано одержані при оптимальних параметрах навчання порядкові

статистики (б) за першими $n=100$ векторами-реалізаціями навчальної матриці для заданого алфавіту класів розпізнавання. На рис. 6, б показано зміну в часі екзаменаційних порядкових статистик у своїх варіаційних блоках впродовж n розпізнавання при зростанні попиту до нових сервісів, які не використовувалися при зборі навчальної вибірки. При цьому криві ЕПС червоного кольору відповідає статистиці для класу x_1^o , а крива синього кольору відповідає статистиці для класу x_2^o .




Рисунок 2.13– Графіки залежності ЕПС: *а* – від кількості випробувань при оптимальних параметрах навчання; *б* – від кількості періодів екзамену в процесі зростання попиту на нові сервіси

Аналіз рис. 2.13а показує що клас x_1^o , який характеризує задоволення умов SLA, має найменше значення ЕПС, рівне $s_1=98,5$. Класу x_2^o , що характеризує функціональний стан порушення умов SLA, відповідає більше значення ЕПС, рівне $s_2=131$. Аналіз рис. 2.13 б показує, що після зміни структури споживання ресурсів протягом 72 розпізнавань функціонального стану одновимірною статистичною характеристикою s_1 реалізацій класу x_1^o переходить у варіаційний блок класу x_2^o , що створює статистичну невизначеність. З метою запобігання

зниженню функціональної ефективності системи керування в цей момент слід ініціювати її перенавчання.

Таким чином, розроблене інформаційне та алгоритмічне забезпечення інтелектуальної системи керування датацентром дозволяє визначати момент зниження її функціональної ефективності та адаптуватися до нових умов функціонування.

Висновки

1. Показано перевагу у застосуванні в інформаційно-екстремальному навчанні запропонованого алгоритму двійкового кодування ознак розпізнавання, у якому на відміну від традиційного алгоритму система контрольних допусків визначається для кожного з класів розпізнавання, а не лише для базового, що дозволяє збільшити кодову відстань між центрами контейнерів класів та підвищити достовірність вирішальних правил.

2. Доведено за результатами фізичного моделювання ефективність запропонованого алгоритму планування розміщень віртуальних машин на фізичних серверах з використанням інтегрального критерію оптимізації, отриманого за допомогою згорток частинних критеріїв. При цьому було відмічено, що адитивно-мультиплікативна згортка є більш чутливою до рівня енергоспоживання, що дозволяє підвищити ефективність планування на етапі наростання навантаження датацентру, в той час як ентропійна згортка є більш чутливою до рівня простоюючих фізичних ресурсів, що обумовлює її вищу ефективність при зниженні навантаження датацентру.

3. Показано, що використання екстремальних порядкових статистик у вигляді нормованих статистик числа потраплянь ознак у свої поля контрольних допусків дозволяє в робочому режимі системи керування виявити появу в датацентрі нових шаблонів споживання фізичних ресурсів внаслідок активного використання нових сервісів датацентру, що дозволяє вчасно

донавчити або перенавчити систему керування і підтримувати її функціональну ефективність на високому рівні.

ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ СИСТЕМИ

Моделювання мережі.

Програмна реалізація поставленого завдання була здійснена в емуляторі GNS3. Організація шифрування даних була проведена на прикладі локальних мереж двох офісів, зв'язаних через транзитну мережу (Інтернет), як це показано на рис. 2.9.

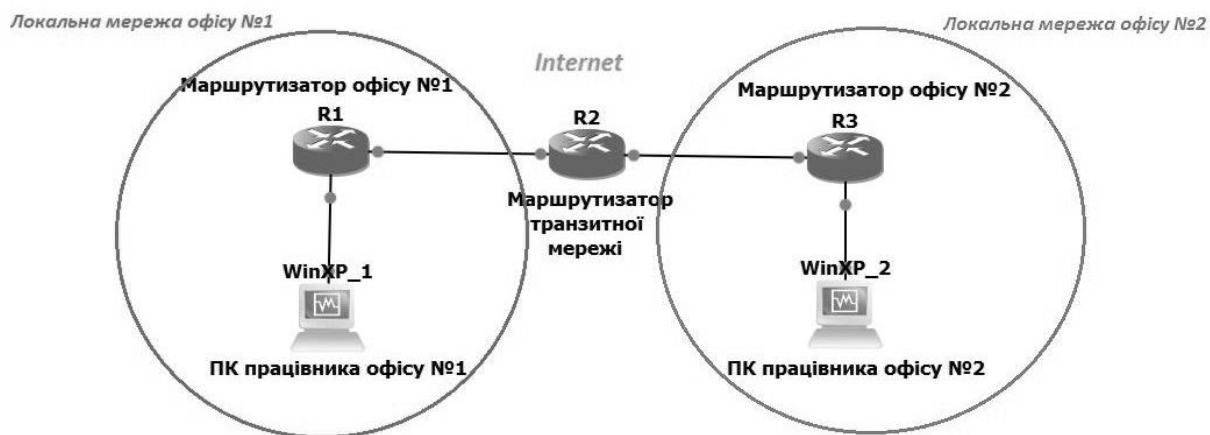


Рисунок 2.9 — Структура змодельованої мережі

Для здійснення передачі даних в змодельованій мережі були проведені початкові налаштування. Кожній мережі були задані свої адресні простори. Також були надані IP адреси інтерфейсам маршрутизаторів. Для симуляції роботи з персональним комп'ютером були використані віртуальні машини зі встановленою заздалегідь ОС Windows XP. Деталі наведено на рис.2.10.




Рисунок 2.10 — Налаштована мережа

На усіх маршрутизаторах також був налаштований протокол маршрутизації EIGRP. Це необхідно для того, щоб прокласти маршрут між мережами, щоб елементи не сусідніх мереж “бачили один одного”. Використані команди приведені нижче:

□ для маршрутизатора офісу №1 (R1):

```
R1(config)#router eigrp 1
R1(config-router)#no auto-summary
R1(config-router)#network 192.168.11.0
R1(config-router)#network 192.168.12.0
```

□ для маршрутизатора офісу №1 (R3):

```
R3(config)#router eigrp 1
R3(config-router)#no auto-summary
R3(config-router)#network 192.168.33.0
R3(config-router)#network 192.168.23.0
```

□ для маршрутизатора транзитної мережі (R2):

```
R2(config)#router eigrp 1
R2(config-router)#no auto-summary
R2(config-router)#network 192.168.23.0
R2(config-router)#network 192.168.12.0
```

На кожній з ОС у віртуальних машинах був встановлений клієнт-серверний чат, який працює по протоколу TCP/IP. Оскільки мережа була налаштована коректно, то чат працював між цими двома користувацькими комп'ютерами (див. рисунок 2.11 – 2.12).

У даній схемі не було налаштоване шифрування даних, котрі передаються у мережі. Тому можна відстежити трафік між ком'ютерами користувачів із офісу №1 та №2 за допомогою програми WireShark. При перехопленні трафіка (див рис. 2.11) у мережі видно, що відфільтрувавши трафік за протоколом TCP, є змога побачити відправлений пакет від хоста 192.168.11.1 на хост 192.168.33.1, та побачити передані дані – повідомлення користувача з текстом “my password is password”, відправлене у чаті. За допомогою даної утиліти з легкістю вдалося не тільки відстежити трафік, а і прочитати особисте повідомлення. Як можна зрозуміти, дані, передані у такий спосіб, легкодоступні для зловмисників.



Рисунок 2.11 — Обмін повідомленнями у вікні чату користувача з офісу №1

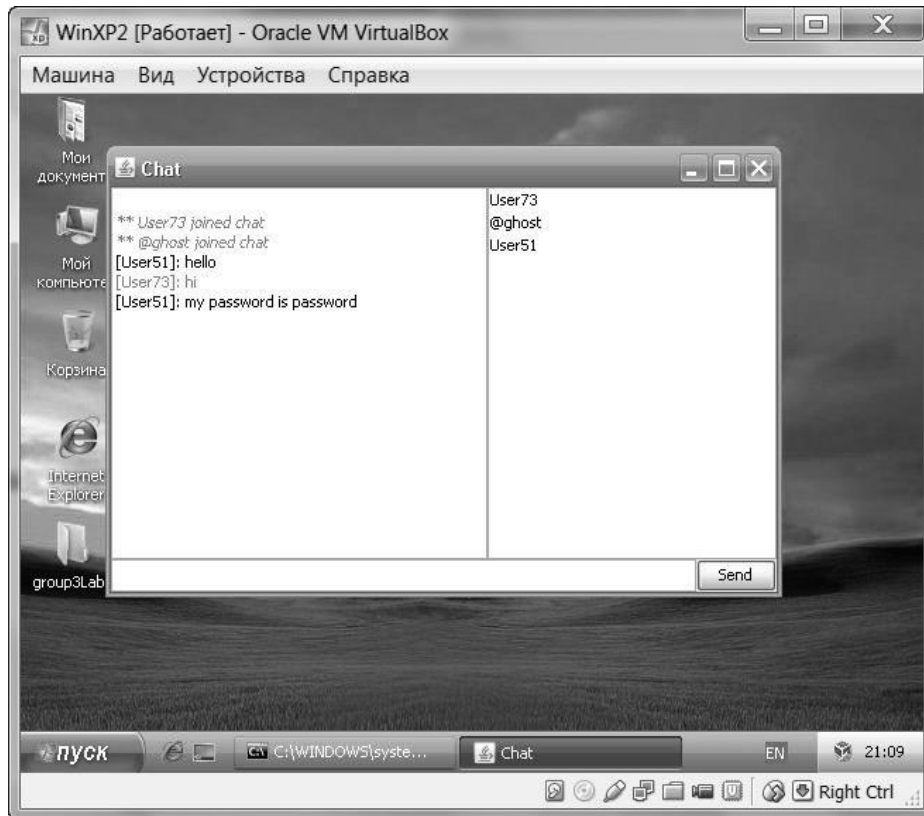


Рисунок 2.12 — Обмін повідомленнями у вікні чату користувача з офісу №1

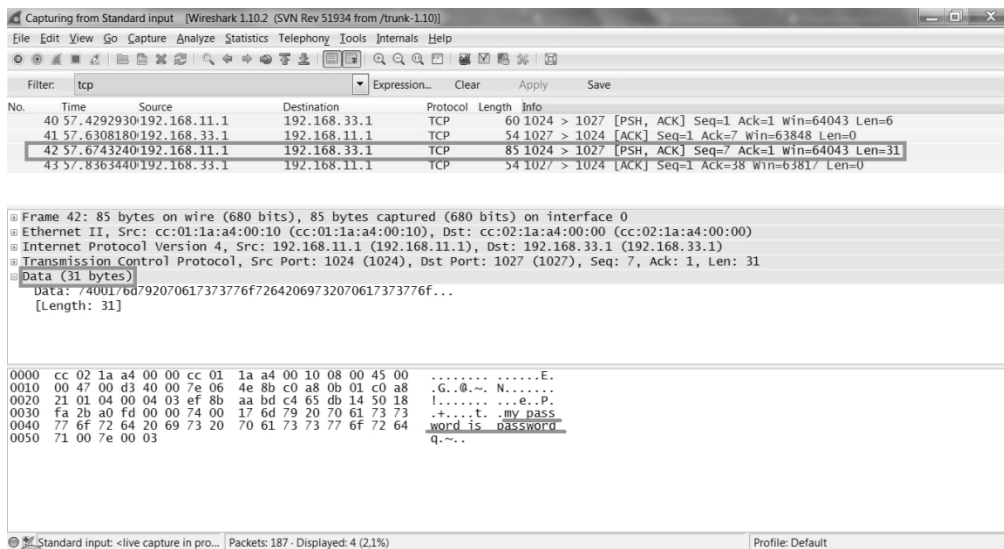


Рисунок 2.13 — Відстеження даних в програмі Wireshark

Організація шифрування даних.

Для запобігання відстеження даних, проведемо додаткові налаштування мережі на граничних маршрутизаторах(на маршрутизаторах з двох офісів). Перш за все, організуємо GRE-тунель між граничними роутерами (R1 та R3) за допомогою наведених нижче команд:

```
R1(config)#interface tunnel 13
R1(config-if)#ip add 192.168.13.1 255.255.255.0
R1(config-if)#tunnel source fa 0/0
R1(config-if)#tunnel destination 192.168.23.3
```

```
R3(config)#interface tunnel 13
R3(config-if)#ip add 192.168.13.3 255.255.255.0
R3(config-if)#tunnel source fa 0/0
R3(config-if)#tunnel destination 192.168.12.1
```

Наступним кроком буде налаштування loopback-інтерфейсів на граничних маршрутизаторах R1 та R3:

```
R1(config)#interface loopback 0
R1(config-if)#ip add 1.1.1.1 255.255.255.0
R1(config)#interface loopback 1
R1(config-if)#ip add 11.11.11.11 255.255.255.0
```

```
R3(config)#interface loopback 0
R3(config-if)#ip add 3.3.3.3 255.255.255.0
R3(config)#interface loopback 1
R3(config-if)#ip add 33.33.33.33 255.255.255.0
```

Далі виконаємо налаштування протоколу динамічної маршрутизації OSPF на маршрутизаторах R1 та R3:

```
R1(config)#router ospf 1
```

```
R1(config-router)#network 192.168.13.0 0.0.0.255 area 0
```

```
R1(config-router)#network 11.11.11.0 0.0.0.255 area 0
```

```
R3(config)#router ospf 1
```

```
R3(config-router)#network 192.168.13.0 0.0.0.255 area 0
```

```
R3(config-router)# network 33.33.33.0 0.0.0.255 area 0
```

Далі налаштуємо необхідні параметри IPSec протоколу та безпосередньо параметри шифрування за допомогою відповідних команд на кожному з маршрутизаторів із використанням стандарту шифрування AES-256.

Налаштування маршрутизатора офісу №1:

```
R1(config)#crypto isakmp policy 10
```

```
R1(config-isakmp)#authentication pre-share
```

```
R1(config-isakmp)#encryption aes 256
```

```
R1(config-isakmp)#hash sha
```

```
R1(config-isakmp)#group 5
```

```
R1(config-isakmp)#lifetime 3600
```

```
R1(config-isakmp)#exit
```

```
R1(config)#crypto isakmp key 0 VAULT address 192.168.23.3
```

```
R1(config)# crypto ipsec transform-set MYTRANS esp-aes 256 esp-sha-hmac ah-  
sha-hmac
```

```
R1(config) #access-list 100 permit gre host 192.168.12.1 host 192.168.23.3
```

```
R1(config)# crypto map MYMAP 10 ipsec-isakmp
```

```
R1(config-crypto-map)# match address 100
```

```
R1(config-crypto-map)#set peer 192.168.23.3
```

```
R1(config-crypto-map)#set transform-set MYTRANS
```

```
R1(config-crypto-map)#exit
```

```
R1(config)#int f0/0
```

```
R1(config-if)#crypto map MYMAP
```

Налаштування маршрутизатора офісу №2:

```
R3(config)#crypto isakmp policy 10
```

```
R3(config-isakmp)#authentication pre-share
```

```
R3(config-isakmp)#encryption aes 256
```

```
R3(config-isakmp)#hash sha
```

```
R3(config-isakmp)#group 5
```

```
R3(config-isakmp)#lifetime 3600
```

```
R3(config-isakmp)#exit
```

```
R3(config)#crypto isakmp key 0 VAULT address 192.168.12.1
```

```
R3(config)# crypto ipsec transform-set MYTRANS esp-aes 256 esp-sha-hmac ah-  
sha-hmac
```

```
R3(config)# access-list 100 permit gre host 192.168.23.3 host 192.168.12.1
```

```
R3(config)# crypto map MYMAP 10 ipsec-isakmp
```

```
R3(config-crypto-map)# match address 100
```

```
R3(config-crypto-map)#set peer 192.168.12.1
```

```
R3(config-crypto-map)#set transform-set MYTRANS
```

```
R3(config-crypto-map)#exit
```

```
R3(config)#int f0/0
```

```
R3(config-if)#crypto map MYMAP
```

Після проведених налаштувань проведемо повторний тест – відправимо те саме повідомлення у чаті між користувачами із офісів №1 та №2 і відстежимо переданий трафік за допомогою програми WireShark. Результати перехоплення трафіка наведено на рис. 2.14. При перегляді перехопленого трафіку видно, що адреси відправника та отримувача, це вже не адреси конкретних хостів, а адреси інтерфейсів маршрутизаторів: 192.168.12.1 та 192.168.23.1 відповідно. Також по протоколу TCP дані уже неможливо відстежити, так як завдяки використанню протоколу IPSec, вони позначені як ESP. І, звісно ж, найголовніше це те, що тепер неможливо прочитати

відправлене повідомлення, Wireshark відображує лише деякі дані про те, що передані дані зашифровані.

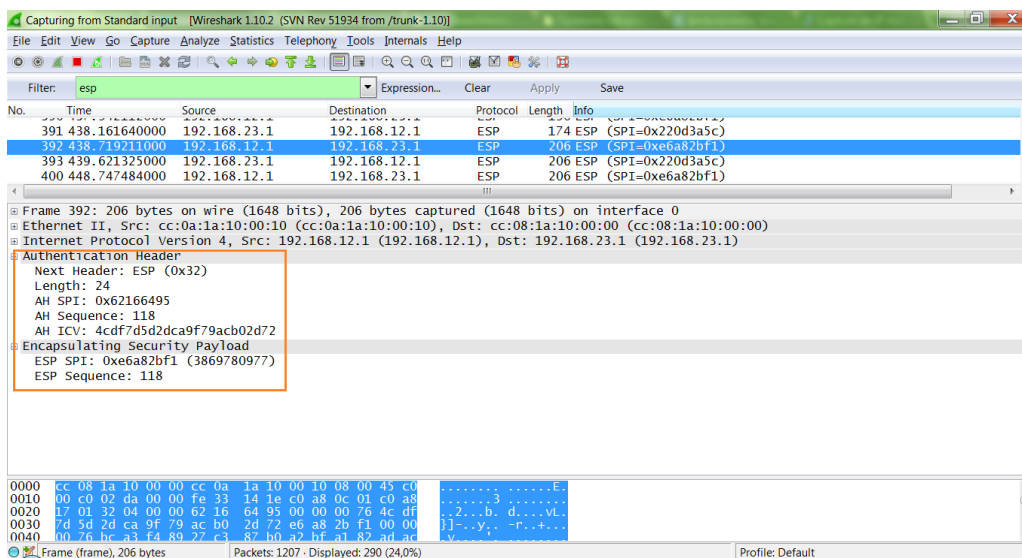


Рисунок 2.14 — Відстеження зашифрованих даних в програмі Wireshark

ВИСНОВКИ

Дана наукова робота присвячена проблемі організації безпечної передачі даних в комп'ютерній мережі. У ході роботи було розглянуто існуючі рішення для організації шифрування даних, побудови мережі, способи тунелювання для створення каналів зв'язку, основні протоколи захисту мережевого трафіку, наведено їх основні переваги та недоліки.

При детальному огляді відомих на сьогодні методів організації безпечної передачі даних, було розглянуто налаштування протоколу IPSec та VPN як спосіб об'єднання віддалених локальних мереж у віртуальну мережу. Підчас розгляду було виявлено, що всі варіанти побудови VPN мають недоліки. Для проведення порівняльного аналізу і вибору методу вирішення проблеми враховувалися наступні критерії: вартість обладнання, необхідного для реалізації методу, складність налаштувань, спосіб шифрування даних.

Проаналізувавши ці критерії на прикладі налаштування VPN та IPSec на основі GRE-тунелю, був обраний останній спосіб організації шифрування

даних, що передаються в каналі зв'язку. Змодельована ситуація – це мережі двох офісів, з'єднані через транзитну мережу. Тому одноразове прокладення тунелю та нескладне налаштування протоколу IPSec виявилось більш оптимальним рішенням. Для реалізації даного методу не потрібне додаткове обладнання, налаштування проводиться на маршрутизаторах в офісах.

У результаті налаштування такого шифрування, дані шифруються ще на мережевому рівні IP, шифруються абсолютно всі дані, які передаються в каналі зв'язку, включаючи відкритий текст повідомлення, а також інформацію про його маршрутизацію і про використаний комунікаційний протокол.

Обраний метод вирішення проблеми був реалізований за допомогою емулятора GNS3. У цій програмі була змодельована наглядна віртуальна мережа та були безпосередньо налаштовані маршрутизатори. Результатом роботи являється неможливість відстеження повідомлень, які передаються з персонального комп'ютера користувача в одному офісі через транзитну мережу на персональний комп'ютер користувача з іншого офісу. Програмний додаток WireShark дозволяє перевірити цю можливість.

Отже, за допомогою налаштування IPSec на основі GRE-тунелю можна без зайвих затрат організувати надійний захист даних, які будуть передаватися через транзитну мережу, через Інтернет. Команди налаштування доступні для розуміння для будь-якого мережевого адміністратора, або, навіть, для впевненого користувача мережі.

2.5 ОПТИМІЗАЦІЯ ПАРАМЕТРІВ ФУНКЦІОНУВАННЯ СИСТЕМИ КЕРУВАННЯ ІТ-ІНФРАСТРУКТУРОЮ ДАТАЦЕНТРУ

Останнім часом корпоративні додатки, електронна пошта, пошукові системи та електронна комерція все частіше розгортаються в

обчислювальному середовищі хмарних датацентрів. Конкуレントоздатність хмарних провайдерів визначається можливостями безвідмовної роботи датацентру у форматі 24/7. При цьому внаслідок високого рівня споживання електроенергії в хмарних датацентрах провайдери намагаються максимізувати ефективність використання електроенергії шляхом перерозподілу віртуальних ресурсів і відключення простоюючих фізичних серверів. Однак при мінімізації затрат оператор хмари повинен забезпечувати відповідність метрик якості сервісу вимогам угоди про рівень обслуговування (Service Level Agreement, SLA), оскільки порушення умов SLA призводить до штрафних санкцій та відтоку клієнтів [1].

Розроблення ефективних алгоритмів розподілу ресурсів у хмарному середовищі ускладнено відсутністю або неточністю інформації про ресурсні вимоги та поведінку конкретного завдання на навантажених гетерогенних вузлах датацентру. Априорна невизначеність функціонального стану вузла при виконанні завдання і неспроможність точної оцінки часу його виконання можуть призвести до виділення надлишкових ресурсів, які будуть простоювати, знижуючи завантаженість обчислювального середовища, або виділення недостатнього обсягу ресурсів, що призводить до накладних витрат, пов'язаних з процесом введення до експлуатації додаткових ресурсів чи міграцією задач на інший вузол. Крім того, здійснення моніторингу віртуальних машин засобами їх операційних систем чи гіпервізора пов'язане із споживанням додаткових ресурсів та некоректністю роботи засобів моніторингу при значних зниженнях продуктивності.

Найбільш ефективними інструментами підтримки безвідмовного та ефективного функціонування датацентру є аналітичні засоби аналізу архівних даних моніторингу компонентів ІТ-інфраструктури та суб'єктивно-статистичних досліджень оцінки якості сервісів [2]. Метою аналітичних засобів є формування в процесі машинного навчання чи самонавчання вирішальних правил для вчасного виявлення (активне детектування) чи

прогнозування (проактивне детектування) аномальних функціональних станів компонентів ІТ-інфраструктури датацентру та аномальної поведінки користувачів чи хмарних додатків. Отримані вирішальні правила дозволяють в процесі функціонування системи керування датацентром знімати невизначеність щодо функціонального стану ІТ-інфраструктури датацентру і як наслідок підвищити ефективність дій щодо реконфігурації та перерозподілу ресурсів.

Задача розподілу ресурсів датацентру є багатокритеріальною, оскільки необхідно одночасно забезпечити мінімум енергоспоживання, обсягу невикористаних ресурсів та порушень SLA-угод. Однак ці частинні критерії є попарно суперечливими, мають різну розмірність і є нелінійними функціями контрольованих характеристик і конфігурацій ІТ-інфраструктури хмарного датацентру. Подібні задачі в компромісній області мають безліч оптимальних у розумінні Парето рішень. При цьому у задачах пошуку оптимальних за Парето рішень для багатокритеріальних задач оптимізації найбільш перспективним є використання ідей та методів ройового інтелекту, що дозволяє підвищити оперативність рішень для динамічно змінюваних умов функціонування.

Таким чином, розробка нових схем кодування ознак порушення умов SLA в алгоритмах інформаційно-екстремального машинного навчання та способів згортки частинних критеріїв ефективності функціонування датацентру в популяційних алгоритмах пошуку є актуальними напрямками дослідження, що спрямовані на зниження енергозатрат та підвищення якості обслуговування кінцевих користувачів.

Аналіз літературних даних і постановка проблеми

При розробці автономних датацентрів з властивостями самоконфігурування, самонастроювання та самодіагностики набуває важливого значення задача прогнозування функціонального стану компонентів ІТ-інфраструктури та

сервісів. Для прогнозування функціонального стану фізичних серверів при розміщенні на них нової віртуальної машини в працях [3, 4] було запропоновано використовувати багат шарову нейронну мережу з обчисленням ознак розпізнавання за принципом мішка слів (Bag-of-Words). Вхідний математичний опис такої прогностичної моделі формується шляхом пошуку в архівній історії функціонування датацентру моментів зниження продуктивності його вузлів та формування за результатами кластер-аналізу архівних даних моніторингу словника віртуальних машин з різними шаблонами споживання ресурсів. Основними недоліками такого підходу є ігнорування категорійних контекстних даних і помітне зниження оперативності навчання та розпізнавання при розширенні словника ознак та алфавіту класів. При цьому, як було показано в працях [5, 6], зниження продуктивності віртуальних машин нерідко призводить до затримок та некоректності в роботі засобів моніторингу, вбудованих в гіпервізор чи операційну систему віртуальної машини, що є причиною помилкових рішень. В працях [7, 8] розглядається використання класифікатора Байеса для прогнозування зниження продуктивності вузлів хмарного кластера при призначенні на нього задачі з черги. Для уникнення перевантажень та некоректної роботи системи моніторингу авторами пропонується встановлювати конфігураційний поріг доступних ресурсів нижчим за максимальну ємність фізичного вузла. При цьому словник ознак класифікатора містить статичні та динамічні ресурсні ознаки задачі та вузла призначення, а алфавіт класів розпізнавання характеризує успішність виконання задачі. Однак статистичний метод машинного навчання класифікатора обмежує його ефективність в умовах незбалансованих та неоднорідних наборів навчальних даних, що має місце на практиці. Крім того, задача прогнозування зниження функціональної ефективності сформованих вирішальних правил досі не розглядалася.

В працях [9, 10] розглядається застосування грубого двійкового кодування спостережень, що дозволяє уніфікувати подання різнотипних ознак та прискорити обробку вхідних даних в режимах навчання та прийняття рішень. При цьому, в праці [10] було обгрунтовано використання логарифмічного інформаційного критерію функціональної ефективності (КФЕ) навчання для побудови високодостовірних вирішальних правил за малими навчальними вибірками. Запропонована схема кодування ознак дозволяє використовувати нормовану статистику числа потраплянь значень ознак у свої поля контрольних допусків як прогностичну функцію ефективності вирішальних правил [10]. Однак даний підхід передбачає вибір одного, базового, класу, відносно якого визначається верхня і нижня межі контрольних допусків на ознаки розпізнавання. Закодовані спостереження класів розпізнавання характеризують відхилення певного рівня та напрямку лише від базового класу, що призводить до втрати частини значущої статистичної інформації про взаємне розміщення в просторі ознак спостережень будь-якої пари класів. З метою підвищення достовірності та завадозахищеності вирішальних правил може розглядатися альтернативна схема кодування, у якій система контрольних допусків на значення ознак будується відносно кожного класу розпізнавання, однак особливості реалізації та ефективність такого підходу досі не були дослідженими. При цьому підвищення інформаційної спроможності вирішальних правил є актуальною задачею, оскільки ряд частинних критеріїв ефективності функціонування датацентру обчислюються за результатами прогнозу функціонального стану його компонентів та сервісів.

Для спрощення багатокритеріальної задачі керування параметрами функціонування датацентру її, як правило, зводять до однокритеріальної багатопараметричної задачі оптимізації. У праці [11] було запропоновано евристичний алгоритм розміщення віртуальних машин на фізичних серверах, оснований на максимізації адитивної згортки частинних критеріїв, однак

використання цієї згортки має сенс лише у випадку випуклості множини допустимих рішень і як показано в праці [12] на практиці це нерідко призводить до нестійкості рішень. В праці [13] пропонується мультиплікативна згортка частинних критеріїв, яка з успіхом використовується у багатьох економічних задачах, однак умовою парето-оптимальності рішень за цією згортою крім випуклості множини допустимих рішень є увігнутість функції логарифму згортки відносно кожного з частинних критеріїв. В працях [14, 15] показано, що на адекватність способу згортки частинних критеріїв впливає топологічний розподіл аналізованих альтернатив в просторі частинних критеріїв – випуклість чи увігнутість області Парето відносно кожної пари координат. При цьому різні способи згортки частинних критеріїв можуть призводити до суттєво відмінних результатів, а вибір процедури згортки не може бути до кінця формалізований і визначається специфікою задачі, цілями, досвідом та інтуїцією дослідника. Тому дослідження та аналіз алгоритмів формування узагальненого показника ефективності функціонування датацентру є важливими задачами інформаційного синтезу системи керування ІТ-інфраструктурою датацентру.

Ціль і задачі дослідження

Мета даної роботи полягає в підвищенні ефективності функціонування здатної навчатися системи керування хмарним датацентром в умовах гетерогенності фізичних вузлів та сервісів.

Для досягнення поставленої мети пропонується розв'язання таких задач:

– розробити алгоритми інформаційно-екстремального машинного навчання системи керування датацентром з використанням системи контрольних допусків на значення ознак, яка окремо визначається для кожного класу розпізнавання;

– розробити алгоритм прогнозування моменту зниження функціональної ефективності прогностичних вирішальних правил з метою визначення моменту перенавчання системи керування датацентром;

– визначити оптимальний спосіб згортки частинних критеріїв для задачі розміщення віртуальних машин на фізичних серверах хмарного датацентру.

Алгоритми функціонування інтелектуальної системи керування ІТ-інфраструктурою датацентру

Алгоритм функціонування інтелектуальної системи керування датацентром повинен включати в себе процедури моніторингу обчислювального середовища та накопичення знань про взаємозв'язок небажаних функціональних станів середовища з його характеристиками та подіями в ньому, що реєструються та архівуються. При цьому основним джерелом інформації є ключові показники продуктивності (Key Performance Indicators, KPI), ключові показники якості KQI (Key Quality Indicator, KQI) та системні повідомлення, які зчитуються на різних рівнях хмарної системи. На рис. 2.15 показано узагальнену структурну схему системи керування датацентром.



Рисунок 2.15– Узагальнена структурна схема системи керування датацентром

Оцінка поточного функціонального стану може бути здійснена шляхом перевірки виконання умов договору про рівень обслуговування (Service Level Agreement, SLA), що містить граничні значення цільових параметрів (Service Level Objectives, SLO), до яких належить і сприйняття якості обслуговування (Quality of Experience, QoE). При використанні категоріальних ознак з метою врахування частоти їх появи в тому чи іншому функціональному стані компонента датацентру здійснюється їх частотне перекодування, при якому кожне значення категоріальної ознаки представляють частотами її появи в кожному з класів розпізнавання. При цьому процес кодування векторів спостережень пропонується здійснювати шляхом порівняння значення i -ї ознаки з відповідним нижнім $A_{L,m,i}$ та верхнім $A_{U,m,i}$ контрольними допусками класу розпізнавання, які розраховуються за формулами

$$A_{L,m,j} = \bar{y}_{m,j} \left[1 - \frac{\delta_{m,i}}{\delta_{\max}} \right], \quad (1)$$

$$A_{U,m,j} = \bar{y}_{m,j} \left[1 + \frac{\delta_{m,i}}{\delta_{\max}} \right], \quad (2)$$

де $\bar{y}_{m,j}$ – усереднене значення ознаки в базовому класі; $\delta_{m,i}$ – параметр поля контрольних допусків для i -ї ознаки розпізнавання; δ_{\max} – максимальне значення параметра поля контрольних допусків.

Формування бінарної навчальної матриці $\{x_{m,j}^{(i)} | i = \overline{1, N}; j = \overline{1, n}; m = \overline{1, M}\}$, де N – кількість ознак розпізнавання, n – кількість векторів-реалізацій в класі та M – кількість класів функціонального стану, здійснюється за правилом

$$x_{m, M^*(i-1)+k}^{(i)} = \begin{cases} 1, & \text{if } A_{L,k,i} \leq y_{m,j}^{(i)} \leq A_{U,k,i}; \\ 0, & \text{else;} \end{cases} \quad k = \overline{1, M}. \quad (3)$$

Запропонована схема кодування (3) дозволяє збільшити різноманітність двійкових векторів-реалізацій та враховувати рівень та напрям відхилення розподілу векторів-реалізацій кожної пари образів між собою.

Ітераційна процедура оптимізації параметра полів контрольних допусків на ознаки розпізнавання здійснюється шляхом максимізації в процесі навчання системи керування усередненого за алфавітом класів розпізнавання інформаційного критерію функціональної ефективності навчання (КФЕ)

$$\{\delta_i^* | i = \overline{1, n}\} = \operatorname{argmax}_{G_\delta} \left\{ \max_{G_E \cap G_d} \bar{E} \right\}, \quad (4)$$

де $\bar{E}^{(k)}$ – усереднене значення інформаційного КФЕ; G_δ – область допустимих значень параметра полів контрольних допусків на значення ознак; G_E – допустима область визначення функції інформаційного КФЕ; G_d – область

допустимих значень радіусу гіперсферичних контейнерів класів розпізнавання, що відновлюються у бінарному просторі Хеммінга.

Процедура оптимізація радіуса контейнерів є вкладеною в процедуру (4) і може здійснюватися методом прямого перебору з заданим кроком, оскільки кількість кроків такого пошуку є відносно малою.

Як критерій ефективності машинного навчання класифікатора розглядається модифікація інформаційної міри Кульбака [10]:

$$E_m = [1 - (\alpha_m^{(k)} + \beta_m^{(k)})] * \log_2 \left[\frac{2 - (\alpha_m^{(k)} + \beta_m^{(k)})}{(\alpha_m^{(k)} + \beta_m^{(k)})} \right], \quad (5)$$

де α_m – помилка другого роду при розпізнаванні реалізацій класу x_m^o ; β_m – помилка другого роду.

Допустима область визначення функції інформаційного КФЕ (5) обмежена нерівностями $\alpha_m < 0,5$, $\beta_m < 0,5$ та $d_m < d(x_m \oplus x_c)$, де d_m – радіус гіперсферичного контейнера класу x_m^o , $d(x_m \oplus x_c)$ – кодова відстань між усередненим вектором класу x_m^o та найближчого до нього усередненим вектором класу x_c^o .

Для прогнозування моменту зниження функціональної ефективності інформаційно-екстремальних вирішальних правил на останньому етапі машинного навчання здійснюється відображення двійкової матриці $\|x_{m,i}^{(j)}\|$ на множину вільних статистик, інваріантних до широкого сімейства законів розподілу ймовірностей, з подальшим формуванням варіаційного ряду екстремальних порядкових статистик (ЕПС) $\langle \{S_{m,n}\} \rangle$. При цьому як одновимірна статистична характеристика вибіркової множини розглядається нормована статистика числа потраплянь ознак у свої поля контрольних допусків за n випробувань [10]

$$S_{m,n} = \sum_{j=1}^n \left(\frac{k_{m,j} - \bar{k}_{m,n}}{s_{m,n}} \right)^2, \quad m = \overline{1, M}, \quad (6)$$

де $k_{m,j}$ – число успіхів при j -му випробуванні; $\bar{k}_{m,n}$ – вибіркоче середнє числа успіхів після n випробувань; $s_{m,n}^2$ – вибіркова незміщена дисперсія за n випробувань.

Статистика (6) має розподіл χ^2 і залежить тільки від обсягу випробувань n . Вільна статистика $S_{m,n}$ є членом варіаційного ряду – порядковою статистикою, ранг якої визначається номером кроку навчання. При цьому нижні та верхні довірчі межі блоків варіаційного ряду $\langle \{S_m\} \rangle$ рекомендується обчислювати поділивши відстані між сусідніми ЕПС на рівні частини.

У робочому режимі системи керування визначається поточний клас функціонального стану віртуальної машини та формується поточна ЕПС. Якщо ЕПС виходить за межі варіаційних блоків, то приймається рішення про необхідність перенавчання системи, внаслідок зміни структури споживання ресурсів віртуальними машинами датацентру.

Кожне z -те рішення P_z щодо розподілу фізичних ресурсів датацентру між R віртуальними машинами, які очікують рішення в часовому вікні Δt , кодується вектором натуральних чисел

$$P_z = \langle p_{z1}, \dots, p_{zr}, \dots, p_{zR} \rangle, \quad (7)$$

де $p_{z,r}$ – номер фізичного вузла на який призначається r -та віртуальна машина.

В робочому режимі система керування повинна приймати оптимальне оперативне рішення p_z' щодо розподілу ресурсів датацентру. Оцінка оптимальності рішення відбувається на кожному кроці пошуку глобального екстремуму згортки частинних критеріїв, до яких належить рівень енергоспоживання та прогнозованих порушень умов SLA, обсяг невикористаних ресурсів та інші.

У загальному випадку для надання рівномірності впливу кожного з частинних критеріїв на значення згортки необхідно вирівняти діапазони

зміни значень частинних критеріїв шляхом масштабування і зведення їх значень до безрозмірної шкали $[0,1]$ за правилом

$$k_i' = \begin{cases} 0, k_i \leq k_i^{\min}; \\ \frac{(k_i - k_i^{\min})}{(k_i^{\max} - k_i^{\min})}, k_i^{\min} < k_i < k_i^{\max}; \\ 1, k_i > k_i^{\max}; \end{cases}$$

де k_i^{\min} , k_i^{\max} – відповідно нижня та верхня межі допустимої області значень i -го частинного критерію.

Під час нормування та формування формули згортки необхідно враховувати, що часткові критерії не є односпрямованими: частина часткових критеріїв має бути максимізована, частина – мінімізована. Тому часткові критерії поділяють на стимулятори (які мають бути максимізовані) та дестимулятори (які повинні мінімізуватися). Формула нормування стимуляторів може бути спрощена і мати вигляд

$$k_i' = \frac{k_i}{k_i^{\max}}. \quad (8)$$

Формула нормування дестимуляторів може бути спрощена аналогічно

$$k_i' = \frac{k_i^{\min}}{k_i}. \quad (9)$$

Для охоплення широкого кола задач було розроблено велику кількість модифікацій адитивно-мультиплікативних згорток як класичного виду, так і побудованих на основі поліному Колмогорова-Габора [16]. В працях [15, 16] було запропоновано експоненціальну та ентропійну згортки, які охоплюють широке коло задач, мають просту формулу обчислення і мінімальну кількість

параметрів. З урахування (8) та (9) адитивно-мультиплікативну згортку можна представити у вигляді

$$F = \sum_{i=1}^{K_1} \omega_i \frac{k_i}{k_i^{\max}} + \sum_{i=K_1+1}^{K_2} \omega_i \frac{k_i^{\min}}{k_i} + \prod_{i=1}^{K_1} \left(\frac{k_i}{k_i^{\max}} \right)^{\omega_i} \prod_{i=K_1+1}^{K_2} \left(\frac{k_i^{\min}}{k_i} \right)^{\omega_i}, \quad (10)$$

де ω_i – вага (пріоритет) i -го критерію, для якого повинна виконуватися умова

$$\sum_{i=1}^{K_1+K_2} \omega_i = 1.$$

Формула згортки, побудована за принципом інформаційної ентропії, відбиває змістовне наповнення поняття корисності як інформаційної категорії і має такий вигляд

$$F = \sum_{i=1}^{K_1} \omega_i \left(\frac{k_i}{k_i^{\max}} \right)^{\omega_i} + \sum_{i=K_1+1}^{K_2} \omega_i \left(\frac{k_i^{\min}}{k_i} \right)^{\omega_i}. \quad (11)$$

Значення ваги кожного частинного критерію може бути обчислене на основі методів, які ґрунтуються на попарному порівнянні критеріїв чи аналітичній залежності показників важливості критеріїв, та формальних методів, таких як метод базового критерію чи метод Черчмена-Акоффа [17]. Проте в умовах апріорної невизначеності відповідно до принципу Бернуллі-Лапласа можна прийняти вагу критеріїв однаковою і рівною

$$\omega_i = \frac{1}{K_1 + K_2}.$$

Гетерогенність, ієрархічність інформаційно-телекомунікаційного середовища, багатofакторність та нестационарність процесів споживання

ресурсів обумовлюють нелінійність, багатоекстремальність та високу розмірність оптимізаційної задачі. З метою підвищення оперативності пошуку як оптимального рішення щодо розподілу ресурсів, так і оптимального вектора параметрів прогностичних вирішальних правил має сенс використати популяційні алгоритми, в основі яких лежать ідеї, запозичені в природи, а також базові постулати універсальності, фундаментальності, властиві самоорганізації природних систем. В даній роботі пропонується обрати популяційний алгоритм пошуку косяком риб (Fish School Search, FSS), який відрізняється простотою реалізації, інтерпретабельністю та високою швидкістю збіжності [18]. В цьому алгоритмі позиція агента в N-вимірному просторі рішень представлена у вигляді числового вектору $P^{(n)}$ довжиною N, який відповідає вектору параметрів, що оптимізується.

В алгоритмі FSS косяк риб є агрегацією агентів популяції, які рухаються приблизно з однією й тією ж швидкістю і орієнтацією, підтримуючи приблизно однакову відстань між собою. Індивідуальний успіх кожної риби в процесі пошуку рішення характеризується її вагою, що відіграє роль пам'яті. Кожна ітерація пошуку виконує дві групи операторів – оператори годування та оператори плавання.

Оператор годування формалізує успішність дослідження агентами тих чи інших областей “акваріуму” і полягає в обчисленні ваги z-го агента, яка пропорційна нормалізованій різниці значень фітнес-функції на наступній та поточній ітераціях

$$w_z[k+1] = w_z[k] + \frac{J(P_z[k+1]) - J(P_z[k])}{\max(J(P_z[k+1]), J(P_z[k]))}, \quad z = \overline{1, Z},$$

де $P_z[k+1]$, $P_z[k]$ – позиція z-го агента в багатовимірному просторі рішень на k-й та (k+1)-й ітерації алгоритму FSS.

Максимально можливе значення ваги агента w_z у алгоритмі FSS обмежується значенням $w_{\max} > 0$. При цьому під час ініціалізації популяції всім агентам присвоюється вага, що рівна $w_{\max} \cdot 0,5$.

В алгоритмі FSS розрізняють три види плавання – індивідуальне, інстинктивно-колективне та колективно-вольове. Ці види плавання здійснюються послідовно один за одним в окремі інтервали часу

$$(t_1, t_2], (t_2, t_3], (t_3, t_4), \quad t_1 < t_2 < t_3 < t_4, t_4 = t_1 + 1.$$

Під час індивідуального плавання агентів відбувається їх переміщення, що має рівноймовірний випадковий характер. При цьому за одну ітерацію алгоритму FSS крок індивідуального плавання виконується фіксовану кількість разів. Компоненти кроку переміщення V_z^{ind} рівномірно розподілені в заданому інтервалі V_{\max}^{ind}

$$V_z^{\text{ind}} = U(0;1) V_{\max}^{\text{ind}}, \quad z = \overline{1, Z},$$

де $U(0;1)$ – випадкове число із діапазону $(0;1)$.

В процесі інстинктивно-колективного плавання на кожного з агентів чинять вплив всі інші агенти популяції і цей вплив пропорційний індивідуальним успіхам агентів. При цьому позиції агентів обчислюються за формулою

$$P_z^{t_3} = P_z^{t_2} + \frac{\sum_j V_j^{\text{ind}}(t_2) (J(P_j^{t_2}) - J(P_j^{t_1}))}{\sum_j (J(P_j^{t_2}) - J(P_j^{t_1}))}, \quad j = \overline{1, Z}. \quad (12)$$

Колективно-вольове плавання полягає у зміщенні всіх агентів у напрямку поточного центру тяжіння популяції за умови збільшення сумарної ваги косяка риб в результаті індивідуального та інстинктивно-колективного

плавання. Якщо сумарна вага зменшилась, то зміщення відбувається в протилежному напрямку. Колективно-вольове плавання виконується за правилами

$$P'_z = P_z^{t_3} \pm v^{vol} (P_z^{t_3} - P_c^{t_3}), z = \overline{1, Z}, \quad (13)$$

де $P_c^{t_3}$ – координати центра тяжіння косяка риб, що визначаються за формулою

$$P_c^{t_3} = \frac{\sum_z w_z^{t_3} P_z^{t_3}}{\sum_z w_z^{t_3}}.$$

У формулі (6) знак плюс використовується за умов $\sum_z w_z^{t_3} > \sum_z w_z^{t_3-1}$, а знак мінус – в протилежному випадку. При цьому розмір кроку переміщення агентів v^{vol} є випадковою величиною

$$v^{vol} = v_{max}^{vol} U(0;1),$$

де v_{max}^{vol} – знакододатне значення максимально допустимої довжини кроку переміщення при колективно-вольовому плаванні.

Таким чином, запропонований алгоритм функціонування системи керування датацентром оснований на зведенні багатокритеріальної задачі оптимізації до однокритеріальної та пошуці за популяційним алгоритмом косяка риб глобального максимуму узагальненого критерію ефективності функціонування датацентру. При цьому такі частинні критерії як рівень дотримання умов SLA знаходять шляхом прогнозування, де прогностичні вирішальні правила формуються в процесі інформаційно-екстремального машинного навчання за вибірковими даними моніторингу і автоматично

корегуються при зміні структури споживання віртуальними машинами фізичних ресурсів датацентру.

Результати фізичного моделювання інтелектуальної системи керування ІТ-інфраструктурою дата центру

Для фізичного моделювання було створено датацентр на базі 20 серверів з процесорами типу Intel (в тому числі Atom і Xeon), які відрізняються між собою кількістю ядер, розміром кеш-пам'яті, тактовою частотою та споживанням енергії. На серверах розгортаються віртуальні машини, одна частина з яких виконує функції віртуальних вузлів Hadoop кластера для обробки гетерогенних задач розподіленої обробки даних за технологією MapReduce, таких як PiEstimator (оцінка числа π з точністю 1-го мільйонного знаку), WordCount (обчислення частоти появи слів в 15GB даних); Sort (сортування 18GB даних), Grep (пошук співпадінь за випадково обраним регулярним виразом в 6GB даних), TeraSort (сортування 1 GB даних), Kmeans (кластер-аналіз 6GB числових даних). Інша частина віртуальних машин виконує функції веб-серверів, на базі яких працюють сервіси онлайн доступу до книг та додатки типу Micro Web App чи PHP/MySQL. Робоче навантаження на сервери генерується клієнтами, що запрограмовані на формування сумарної мінімальної потреби в ресурсах, яка змінюється в часі за законом, який показано на рис. 2.16.




Рисунок 2.16– Графік зміни навантаження датацентру протягом доби

Як інструмент розгортання хмарної платформи датацентру використано вільне програмне забезпечення Apache CloudStack, написане на мові java [19]. Функцію гіпервізора виконує XenServer [19]. Сховище даних керується за допомогою NetApp та Cumulus [19]. Apache CloudStack підтримує різноманітні алгоритми керування розміщенням віртуальних машин, наприклад, firstfit, random, worstfit та інші, проте в даному дослідженні було розроблено власний планувальник шляхом наслідування від класу nova.scheduler.driver.Scheduler та перевизначення згідно із метою дослідження наступних методів `schedule_run_instance` та `select_destinations`.

Задача консолідації віртуальних машин датацентру поділяється на чотири підзадачі: детектування недовантаження серверів; детектування перевантаження серверів; відбір віртуальних машин для переміщення; розміщення віртуальних машин на серверах. Для простоти порівняння спочатку було реалізовано алгоритм розміщення віртуальних машин MBFD (Modified Best Fit Decreasing), основна ідея якого полягає в сортуванні віртуальних машин, що підлягають міграції, в порядку спадання їх ресурсних потреб і їх призначенні на найбільш енергоефективні сервери, що мають достатній обсяг ресурсів [20]. При цьому за замовчуванням алгоритм детектування недовантаження знаходить найменш завантажені сервери і

намагається перемістити його віртуальні машини за алгоритмом MBFD на інші сервери. Для дослідження запропонованих алгоритмів їх ефективність буде порівнюватися з алгоритмом MBFD.

В даному дослідженні пропонується здійснювати оптимізацію розподілу віртуальних машин шляхом популяційного пошуку за інтегральними критеріями (10) та (11). При цьому з метою врахування гетерогенності віртуальних машин та серверів пропонується перед переміщенням прогнозувати порушення умов SLA внаслідок конкуренції віртуальних машин на спільні фізичні ресурси.

Навчання системи керування прогнозуванню порушень умов SLA внаслідок конкуренції віртуальних машин за ресурси фізичних серверів здійснюється як для рівня IaaS (Infrastructure-as-a-Service), так і для рівня SaaS (Software-as-a-Service). Тому для запитів клієнтів було прикріплено умови користувацького SLA у вигляді таких показників:

- максимальний час, протягом якого користувач згоден очікувати результат, T_d ;
- ціна яку користувач готовий заплатити за послугу, V_d ;
- розмір компенсації за порушення дедлайну, C_p ;
- обсяг файлів, що надсилають користувачі, F_s ;
- довжина запиту користувача (в мільйонах інструкцій, що виконуватимуться на віртуальному вузлі), M_i .

Кожен фізичний вузол в експериментальній середовищі було описано ресурсним SLA у вигляді показників:

- час розгортання віртуальної машини, T_{vm} ;
- вартість години використання віртуальної машини, C_{vm} ;
- вартість переміщення даних між користувачами та віртуальною машиною, C_{fs} ;
- швидкість опрацювання задач користувача в мільйонах інструкцій за секунду, M ;

– швидкість передачі даних між користувачем та фізичним вузлом, Sfs .

У зв'язку з обмеженістю ресурсів датацентру прогнозування порушень умов SLA внаслідок конкуренції віртуальних машин за спільні фізичні ресурси дозволяє приймати рішення оптимальні у вартісному сенсі. При цьому повторюваний характер задач, що вирішуються додатками віртуальних машин, забезпечує можливість застосування методів машинного навчання для аналізу log-даних трасування роботи віртуальних машин для синтезу прогностичної моделі. Вхідний математичний опис такої моделі включає результати кластер-аналізу даних трасування роботи віртуальних машин за алгоритмом k-середніх. Утворені таким чином групи (класи) віртуальних машин характеризують існуючі в датацентрі шаблони споживання різного типу ресурсів фізичного сервера. При цьому словник ознак класифікатора віртуальних машин включає середній обсяг використання ресурсу процесорів, оперативної пам'яті, файлу підкачки, мережевого каналу, дискового простору, середню інтенсивність операцій вводу-виводу з дисковою пам'яттю.

Для навчання прогностичного класифікатора порушення умов SLA внаслідок розміщення обраної віртуальної машини на обраному фізичному вузлі пропонується використати такий словник ознак:

- нормалізовані відносно потреб обраної віртуальної машини обсяги вільних ресурсів (CPU, RAM, I/O Disk, Network) обраного фізичного вузла;
- нормалізовані кількості віртуальних машин кожного класу (б кластерів) на обраному фізичному вузлі з урахуванням обраної віртуальної машини, що планується на ньому розмістити;
- розрахунковий час виконання запиту $T_e = T_d - T_{vm} - F_s / S_{fs} - M_i / M$;
- розрахунковий залишок бюджету $B_r = B_d - C_{fs} * F_s / S_{fs} - C_{vm} * M_i / M$.

Визначення належності вектора розглянутих ознак до одного з класів порушення умов SLA з метою формування навчальної вибірки здійснюється за результатами фіксації в даних моніторингу таких подій: задача направлена

планувальником на хостову машину для запуску; для задачі виконується перепланування (міграція); задача виконана без порушень умов SLA.

На рис. 2.17 показано графік залежності усередненого значення нормованого інформаційного КФЕ (5) від кількості ітерацій оптимізації параметра поля контрольних допусків на значення ознак (4) за ройовим алгоритмом пошуку.




Рисунок 2.17– Графік зміни максимумів усередненого за алфавітом класів значення нормованого критерію (5) в процесі ройової оптимізації системи контрольних допусків: *a* – однорівнева система контрольних допусків; *б* – багаторівнева система контрольних допусків

Аналіз рис. 2.17а показує, що інформаційно-екстремальне машинне навчання за триційним алгоритмом з єдиним базовим класом не дозволяє отримати високодостовірні вирішальні правила, а відповідне значення глобального максимуму усередненого нормованого КФЕ навчання класифікатора становить $\bar{E} = 0,29$, що відповідає такому значенню точності $\overline{P_{\text{true}}} = 0,92$. Аналіз рис. 2.17б показує, що побудова системи контрольних допусків для кожного класу розпізнавання $\{\delta_{i,m}^*, i = \overline{1,N}; m = \overline{1,M}\}$ дозволяє отримати граничне значення інформаційного критерію $\bar{E} = 1,0$ та отримати безпомилкові за навчальною матрицею вирішальні правила, тобто $\overline{P_{\text{true}}} = 1,0$.

На рис. 2.18 наведено графіки залежності нормованого КФЕ (5) від радіусів контейнерів відповідних класів при оптимальній системі контрольних допусків на значення ознак розпізнавання.




Рисунок 2.18— Графіки залежності нормованого КФЕ (5) від радіусів контейнерів класів: $a - x_1^o$; $b - x_2^o$

Аналіз рис. 2.18 показує, що максимальні значення КФЕ навчання для класів x_1^o та x_2^o дорівнюють $E_1^* = 1,0$ та $E_2^* = 1,0$ відповідно, а оптимальні значення радіусів відповідних контейнерів класів розпізнавання — $d_1^* = 7$, $d_2^* = 7$ (в кодових одиницях). Граничні значення КФЕ для класів x_1^o та x_2^o свідчать про побудову для них безпомилкових за навчальною матрицею вирішальних правил. При цьому міжцентрова кодова відстань становить $d(x_1 \otimes x_2) = 14$, що свідчить про компактність векторів-реалізацій в субперцептуальному та чіткість розбиття в двійковому просторі Хеммінга.

На рис. 2.19 показано залежність операційних витрат (у відносних одиницях), які включають сумарну вартість міграції віртуальних машин, компенсацій за порушення SLA та витрати на електроенергію, на кожному кроці прийняття

рішень за алгоритмом MBFD та його модифікаціями з прогнозуванням порушення SLA та оптимізацією за критеріями (10) та (11) відповідно.




Рисунок 2.19– Гістограма зміни операційних витрат для різних алгоритмів планування залежно від навантаження датацентру на відповідному кроці прийняття рішень: *a* – MBFD; *б* – прогностична модифікація MBFD з критерієм (10); *в* – прогностична модифікація MBFD з критерієм (11)

Аналіз рис. 2.19 показує, що використання прогностичних вирішальних правил дозволяє зменшити операційні витрати внаслідок зменшення кількості порушення умов SLA та зменшення простоючих фізичних ресурсів без перевантаження навантажених фізичних вузлів. При цьому під час збільшення навантаження датацентру більш оптимальною є згортка критеріїв (10), а при зменшенні навантаження датацентру кращі результати можна отримати при використанні згортки (11).

Таким чином, розроблений алгоритм інформаційно-екстремального машинного навчання для прогнозування порушення SLA дозволяє підвищити ефективність мінімізації операційних витрат щодо керування ресурсами датацентру. При цьому одна з розглянутих згорток частинних критеріїв

оптимізації є більш ефективною при збільшенні навантаження датацентру, а інша – при зменшенні потреб у фізичних ресурсах датацентру.

Обговорення результатів імітаційного моделювання

Як видно з рисунків, зростання операційних витрат системи керування датацентром пропорційне сумарним ресурсним потребам користувачів в обслуговуванні, однак використання популяційного пошуку з прогнозуванням порушень умов SLA дозволяє зменшити рівень витрат порівняно з алгоритмом MBFD. При цьому згортка критеріїв (10) виявилась більш чутливою до рівня енергоспоживання, що дозволяє підвищити ефективність планування на етапі наростання навантаження датацентру, в той час як згортка (11) є більш чутливою до рівня простоючих фізичних ресурсів, що обумовлює її ефективність при зниженні навантаження датацентру.

Запропонована модифікація алгоритму інформаційно-екстремального машинного навчання за вибіркою, що сформована в процесі моніторингу роботи датацентру, керованого за алгоритмом MBFD, порівняно з традиційним алгоритмом дозволяє підвищити функціональну ефективність системи керування та отримати безпомилкові за навчальною матрицею вирішальні правила. Проте внаслідок розширення набору сервісів, що розгортаються на базі віртуальних машин датацентру, з'являються нові шаблони споживання фізичних ресурсів, що призводить до зміни статистичних характеристик образів і відповідно зменшення функціональної ефективності сформованих до цього вирішальних правил. На рис. 2.20а показано одержані при оптимальних параметрах навчання порядкові статистики (б) за першими $n=100$ векторами-реалізаціями навчальної матриці для заданого алфавіту. На рис. 2.20б показано зміну в часі екзаменаційних порядкових статистик у своїх варіаційних блоках впродовж n розпізнавання при зростанні попиту до нових сервісів, які не

використовувалися при зборі навчальної вибірки. При цьому криві ЕПС червоного кольору відповідає статистиці для класу X_1^o , а крива синього кольору відповідає статистиці для класу X_2^o .

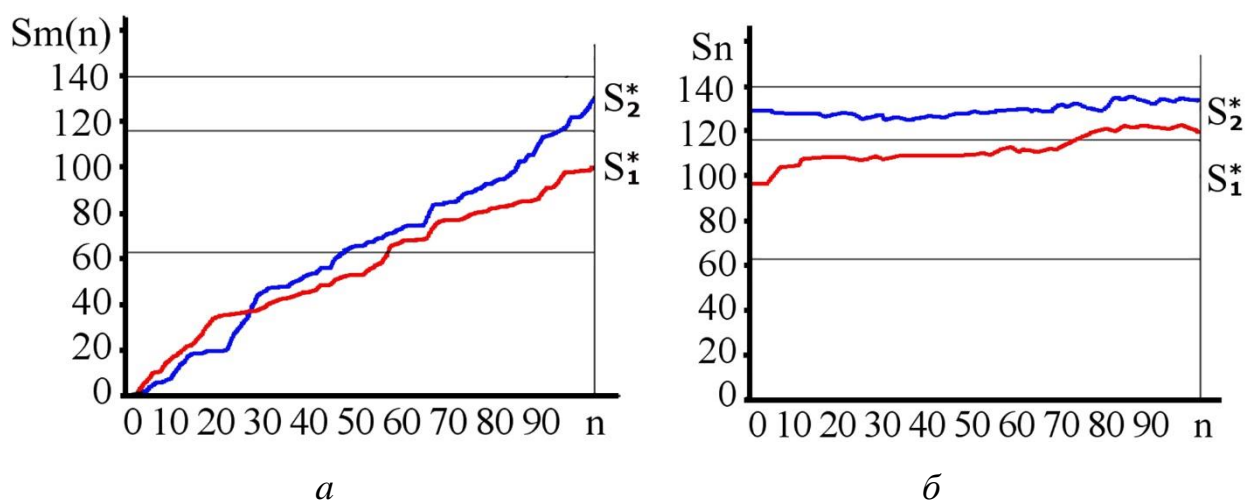


Рисунок 2.21– Графіки залежності ЕПС: *а* – від кількості випробувань при оптимальних параметрах навчання; *б* – від кількості періодів екзамену в процесі зростання попиту на нові сервіси

Аналіз рис. 2.21а показує що клас X_1^o , який характеризує задоволення умов SLA, має найменше значення ЕПС, рівне $S_1^* = 98,5$. Класу X_2^o , що характеризує функціональний стан порушення умов SLA, відповідає більше значення ЕПС, рівне $S_2^* = 131$. Аналіз рис. 2.21б показує, що після зміни структури споживання ресурсів протягом 72 розпізнавань функціонального стану одновимірної статистичної характеристики S_1 реалізацій класу X_1^o переходить у варіаційний блок класу X_2^o , що створює статистичну невизначеність. З метою запобігання зниженню функціональної ефективності системи керування в цей момент слід ініціювати її перенавчання.

Таким чином, розроблене інформаційне та алгоритмічне забезпечення інтелектуальної системи керування датацентром дозволяє визначати момент

зниження її функціональної ефективності та адаптуватися до нових умов функціонування.

Висновки

1. Показано перевагу у застосуванні в інформаційно-екстремальному навчанні запропонованого алгоритму двійкового кодування ознак розпізнавання, у якому на відміну від традиційного алгоритму система контрольних допусків визначається для кожного з класів розпізнавання, а не лише для базового, що дозволяє збільшити кодову відстань між центрами контейнерів класів та підвищити достовірність вирішальних правил.
2. Доведено за результатами фізичного моделювання ефективність запропонованого алгоритму планування розміщень віртуальних машин на фізичних серверах з використанням інтегрального критерію оптимізації, отриманого за допомогою згорток частинних критеріїв. При цьому було відмічено, що адитивно-мультиплікативна згортка є більш чутливою до рівня енергоспоживання, що дозволяє підвищити ефективність планування на етапі наростання навантаження датацентру, в той час як ентропійна згортка є більш чутливою до рівня простоюючих фізичних ресурсів, що обумовлює її вищу ефективність при зниженні навантаження датацентру.
3. Показано, що використання екстремальних порядкових статистик у вигляді нормованих статистик числа потраплянь ознак у свої поля контрольних допусків дозволяє в робочому режимі системи керування виявити появу в датацентрі нових шаблонів споживання фізичних ресурсів внаслідок активного використання нових сервісів датацентру, що дозволяє вчасно донавчити або перенавчити систему керування і підтримувати її функціональну ефективність на високому рівні.

2.6 АВТОНОМНА БОРТОВА СИСТЕМА ДЕТЕКТУВАННЯ ОБ'ЄКТІВ НА МІСЦЕВОСТІ

Сучасні безпілотні літальні апарати, які оснащені бортовими відео камерами мають дуже широке комерційне застосування в різних галузях. При цьому на сьогоднішній день практично відсутні малогабаритні БЛА загального призначення, здатні здійснювати в автономному режимі детектування об'єктів інтересу на місцевості і здійснювати адаптацію під нові умови спостереження. При розробці бортових систем детектування об'єктів набуло поширення використання глобальних дескрипторів таких як мішок слів (Bag-of-words, BoW), що обчислюється на основі локальних дескрипторів SIFT або SURF [1] для ключових точок, та гістограми орієнтованих градієнтів (Histogram of Oriented Gradients) у вікні пошуку, яке формується за алгоритмом адаптивного ковзного вікна (Run-time Adaptive Sliding Window, RASW) [2], або алгоритмом ефективного пошуку підвікна ([Efficient Subwindow Search](#), ESS) [3]. Перевагою такого підходу є можливість навчання системи бортовими обчислювальними ресурсами, що дозволяє краще адаптуватись під умови середовища. Проте такий підхід має невисоку точність у порівнянні зі згортковими нейронними мережами та потребує налаштування багатьох параметрів. Алгоритми детектування, основані на використанні згорткових нейронних мережі, такі як Yolo, SSD, Faster R-CNN [4] демонструють високу точність детектування за нестационарних умов польоту БЛА (масштабу, поля зору, умов освітлення, типу фонові місцевості). Однак такі алгоритми мають високу обчислювальну складність процесу навчання на основі зворотного поширення помилки, що ускладнює оперативну адаптацію до зміни умов функціонування. Тому актуальною є розробка обчислювально-ефективного алгоритму детектування об'єктів на місцевості зі здатністю донавчання (online learning) бортовими засобами, що

дозволить системі працювати в умовах нестационарності зовнішнього середовища та модифікації об'єктів інтересу.

У роботі пропонується підхід до реалізації системи детектування об'єктів який базується на принципах концепції передачі знань (Transfer learning) та використанні ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології), що ґрунтується на максимізації інформаційної спроможності системи на етапі машинного навчання [5]. На рис. 1 показано блок-схему системи ідентифікації об'єктів на місцевості, що пропонується

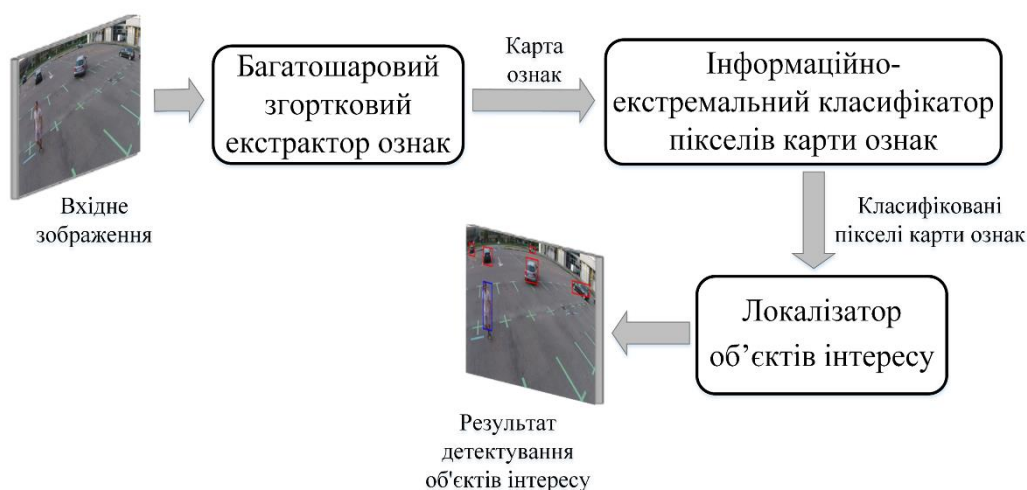


Рисунок 2.22– Схема системи детектування об'єктів на місцевості.

На рис. 2.22 показано узагальнену схему системи детектування об'єктів на місцевості. Локалізація об'єкту інтересу в кадрі зображення відбувається шляхом розбиття кадру зображення на фіксовану решітку з розміром клітинки в половину менше за розмір найменшого можливого об'єкта який необхідно детектувати. У випадку, коли декілька об'єктів припадають на одну клітинку, то перевага надається тому об'єкту який має більшу площу. Якщо площа однакова то обирається той, який має найменшу ординату (OY). Приймається що висота польоту є стаціонарною, а розмір сітки співпадає з шириною і висотою карти ознак, що формується на основі переднавченої

згорткової мережі згідно з принципом передачі знань. Тобто екстракція ознакового опису кадру зображення здійснюється попередньо навченою на великому наборі навчальних даних згортковою нейронною мережею, що дозволяє зменшити обчислювальне навантаження при навчанні вирішальних правил за умов обмеженого обсягу ресурсів та навчальних зразків. Якщо доменна область, в рамках якої навчалась згорткова нейромережа, далека від цільової доменної області, то декілька верхніх шарів нейромережі потрібно навчити самостійно. Нами пропонується навчання без вчителя на основі розріджено кодуєчого нейронного газу [6], а уточнення на основі імітації відпалу (Simulated Annealing, SA), початковий стан якого ініціалізується за результатами навчання без вчителя [7].

Глибина карти ознак відповідає розмірності ознакового опису елементарної клітинки детектування. Кожен піксель карти ознак надходить на вхід інформаційно-екстремального класифікатора, що характеризується низькою обчислювальною складністю та високою достовірністю за умов обмеженого обсягу навчальних зразків. При цьому побудова вирішальних правил в рамках ІЕІ-технології здійснюється згідно з принципом відкладених рішень в процесі оптимізації параметрів навчання за багатоциклічною ітераційною процедурою пошуку максимального граничного значення інформаційного критерію у вигляді [5]

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_1} \bar{E} \} \dots \} \},$$

де g_{ξ}^* – ξ -й оптимальний в інформаційному розумінні параметр навчання класифікатора зон інтересу розпізнавати реалізації алфавіту класів $\{X_m^o\}$; G_{ξ} – область допустимих значень ξ -го параметру навчання; \bar{E}_m – усереднений за алфавітом класів інформаційний критерій, що є функціоналом від точнісних характеристик вирішальних правил.

Вирішальні правила у вигляді гіперсферичних контейнерів класів розпізнавання будуються в бінарному субпарацептуальному просторі ознак і

їх параметри використовуються в режимі екзамену при обчисленні функції належності j -ї екзаменаційної реалізації до m -го класу розпізнавання [5]

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

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 .

Таким чином, реалізація системи детектування об'єктів на місцевості з використанням концепції передачі знань та ідей і методів інформаційно-екстремального машинного навчання дозволяє заощадити ресурси системи при адаптації до зміни умов спостереження і модифікації об'єктів інтересу.

3 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ СКЛАДНИХ СИСТЕМ

3.1 МАТЕМАТИЧНЕ МОДЕЛЮВАННЯ ВЛАСТИВОСТЕЙ ПКМ, НАПОВНЕНОГО КОРОТКО-ВОЛОКНИСТИМИ ВКЛЮЧЕННЯМИ ТА ДИСПЕРСНИМИ ЧАСТИНКАМИ СФЕРИЧНОЇ ФОРМИ

Досвід застосування абразивних композитних матеріалів на основі полімерів у вузлах тертя технологічного обладнання різного призначення показав [1-3], що максимального успіху можна домогтися, лише творчо підходячи до проектування виробів з композитних матеріалів, враховуючи особливості побудови моделей цих матеріалів на основі механіки композитних матеріалів та особливостей технологічного процесу їх виготовлення.

Комплексне завдання, яке розв'язується в поєднанні теоретичних та експериментальних досліджень є завданням оптимального проектування абразивне зносостійкого композитного матеріалу на основі полімерної матриці, армованої коротко-волокнистим наповнювачем та дисперсними включеннями округлої форми, що забезпечить надійну роботу виготовлених конструкцій з цього матеріалу при мінімальних технологічних витратах.

В даному разі, вирішенням завдання оптимального проектування послуговує підбір складу композитного матеріалу, що забезпечить максимально-можливе значення абразивної зносостійкості при заданих фізико-механічних характеристиках. При цьому слід враховувати багатofакторну залежність абразивної зносостійкості композитного матеріалу від його властивостей, що описують деформаційні процеси в рамках пружності, в'язкості та пластичності. Важливо також врахувати теплофізичні властивості композита, бо процеси тертя визивають підвищення температури, що спричиняє до появи теплових полів в матеріалі та впливає на зміну макроскопічних характеристик. А впливи температури та пластичні деформації можуть привести до зміни навіть структури матеріалу.

Одним із шляхів вирішення поставленої задачі є встановлення функціональних залежностей фізико-механічних властивостей композитного матеріалу від об'ємного складу, схеми розташування, геометричної форми та фізико-механічних характеристик компонентів, з яких складається композитний матеріал. Такого роду дослідження потребують розв'язку крайових задач механіки композитних матеріалів, що описують ті чи інші процеси деформування.

Інший підхід, що й застосовується в роботі, дозволяє застосувати варіаційні принципи механіки твердого тіла та сформулювати крайові задачі у вигляді умови мінімальності певного функціонала $\Phi(u)$ на множині кінематичне можливих переміщень u або їх швидкостей [4, 5]. Такий підхід є відображенням фундаментального енергетичного принципу, який стверджує, що деякий функціонал енергетичного типу приймає мінімальне значення тільки на значеннях змінних, які представляють собою рішення крайової задачі, на відміну від значень функціоналу для інших «допустимих» значень цих змінних.

Слід відмітити, що реальні абразивостійкі композитні матеріали мають випадкову структуру, зумовлену як неправильною формою включень, так і їх випадковим розташуванням в матриці. Технологічний процес виготовлення конструкцій вносить додаткову складність в структуру, наприклад, наявність пористості (захват повітря при спіканні), чи широкий розподіл довжин включень-волокон, які отримують з вуглецевої тканини шляхом здрібнення в дробарках-млинках. Цей розподіл довжин включень описують найчастіше гамма-функцією (гамма – розподіл в теорії ймовірностей) [3].

Зауважимо, що строго виведені теорії в механіці композитних матеріалів, мають в своїй основі деякі припущення або гіпотези, що визначають границі застосування одержаних результатів та можливе корегування теоретичних моделей проведенням експериментальних досліджень. Це ще раз підтверджує значимість поєднання теоретичних та експериментальних

досліджень при розв'язанні завдання оптимального проектування композитних матеріалів.

Надалі, основними структурами для досліджень визначимо трикомпонентні композитні матеріали, структуру яких складають матриця, статистично однорідне армовану включеннями різноманітної геометричної форми. На рисунках 3.1-3.2 приведені деякі з таких структур:




Рисунок 3.1 – Структура трикомпонентного матеріалу, на основі політетрафторетилену, армованого вуглецевими волокнами та включеннями коксу округлої форми





Рисунок 3.2 – Структура трикомпонентного матеріалу, на основі політетрафторетилену, армованого вуглецевими волокнами та волокнами базальту

Вибір моделі та методів розрахунку

Розглянемо двофазовий композитний матеріал випадкової структури, яку складають полімерна неперервна матриця, армована випадковим розподілом в ній дискретних включень. Вибір в якості об'єкта дослідження двофазного матеріалу дещо спрощує (у порівнянні з трикомпонентним композитом) математичні викладки і в той же час містить всі гіпотези і вихідні передумови проведених далі досліджень. Крім того такий підхід дозволяє

розглянути деякі добре вивчені двокомпонентні структури – матеріали зі сферичними включеннями і матеріали, армовані короткими волокнами. Наприклад, на рис. 3.3 представлена структура двокомпонентного матеріалу, включення в якому є короткими волокнами, на рис. 3.4 – включення є дисперсними частинками.



<p>Рисунок 3.3 – Структура двокомпонентного матеріалу, на основі політетрафторети-лену, армованого вуглецевими волокнами</p>	<p>Рисунок 3.4 – Структура двокомпонентного матеріалу, на основі політетрафторети-лену, армованого дисперсними частинками</p>
--	---

Композитний матеріал з випадковою структурою можна представити як середовище, фізико-механічні характеристики якого є випадковими функціями координат.

Включення представимо у вигляді витягнутих еліпсоїдів обертання з напівосями a і b , що дозволяє представити різні геометричні форми – як включення у вигляді дискретних частинок округлої форми (коли $a = b$), так і армування матриці короткими волокнами (коли співвідношення напівосей a/b представимо через геометрію волокон – $a/b \approx l/d$, де l – середня довжина волокон, d – їх діаметр).

Прийmemo статистично однорідний розподіл включень по об'єму матриці, що надасть можливість застосування гіпотезу ергодичності, за якою усереднення випадкових величин по об'єму матеріалу V співпадає зі

статистичним усередненням (по ансамблю реалізацій). Середні величини по об'єму V будемо позначати кутовими дужками і визначати наступне

$$\langle (\bullet) \rangle = \frac{1}{V} \int_V (\bullet) dV \quad (3.1)$$

Геометричну структуру матеріалу задамо індикаторними випадковими функціями координат $\chi_n = (x_1, x_2, x_3)$, що приймають значення одиниці в області включень n -го напрямку і нуля – в іншому разі.

Нехай маємо множину L_k – включення k -го напрямку, для яких задані χ_k . З умови, що множини не перетинаються, отримуємо $\langle \chi'_n \chi'_n \rangle = c_n(1 - c_n)$.

Визначення макроскопічних властивостей пружності

Будемо вважати обидві фази (матрицю і включення) в композитному матеріалі ізотропним, міцно з'єднаними по межі розділу (безперервність переміщень при переході через границю з'єднання) та таким, що підпорядковується закону Гука, що зв'язує напруги і деформації співвідношеннями:

для включень

$$\sigma_{ij} = 2\mu_1 e_{ij} + \lambda_1 \delta_{ij} e_{ll} \quad (3.2)$$

та матриці

$$\sigma_{ij} = 2\mu e_{ij} + \lambda \delta_{ij} e_{ll}, \quad (3.3)$$

де μ , λ , μ_1 , λ_1 – коефіцієнти Ламе матриці та включень відповідно, індексом 1 відмічені величини, що відносяться до включень.

За допомогою індикаторних функцій зв'язок напружень з деформаціями для композитного матеріалу представимо у вигляді

$$\sigma_{ij} = 2\mu e_{ij} + \lambda \delta_{ij} e_{ll} + \sum_n (2\bar{\mu}_1 \chi_n e_{ij} + \bar{\lambda}_1 \delta_{ij} \chi_n e_{ll}), \quad (3.4)$$

де $\bar{\mu}_1 = \mu_1 - \mu$, $\bar{\lambda}_1 = \lambda_1 - \lambda$

Функції χ_n , напруги σ_{ij} та деформації e_{ij} вважаються випадковими статистичними однорідними функціями координат та згідно умови ергодичності, їх усереднення по ансамблю збігається з усередненням по

характерному об'єму. При цьому в умовах статистичної однорідності середнє по тілу (по всьому об'єму V) є рівним середньому по будь-якому характерному об'єму.

Випадкові поля напруг, деформацій, переміщень і індикаторних функцій представимо у вигляді суми математичних очікувань і флуктуацій

$$\begin{aligned}\sigma_{ij} &= \langle \sigma_{ij} \rangle + \sigma'_{ij}, & e_{ij} &= \langle e_{ij} \rangle + e'_{ij}, \\ u_i &= \langle u_i \rangle + u'_i, & \chi_n &= \langle \chi_n \rangle + \chi'_n\end{aligned}$$

При цьому

$$\langle \chi_n \rangle = \frac{1}{V} \int_V \chi_n dV = \frac{1}{V} \int_{V_n} dV = \frac{V_n}{V} = c_n, \quad (3.5)$$

де c_n – концентрація включень, орієнтованих в n -му напрямку.

Для зв'язку $\langle e_{ij} \rangle_1$ та $\langle e_{ij} \rangle$ маємо співвідношення

$$\langle e_{ij} \rangle_1 = \langle e_{ij} \rangle + \langle \chi' e'_{ij} \rangle / c_1. \quad (3.6)$$

Розрахунок властивостей пружності композитного матеріалу передбачає визначення напружено-деформованого стану в умовах навантаження і обчислення макроскопічних властивостей пружності.

Усереднене рівняння визначає закон деформування (закон Гука) в умовах суцільності матеріалу

$$\langle \sigma_{ij} \rangle = 2\mu \langle e_{ij} \rangle + \lambda \delta_{ij} \langle e_{ll} \rangle + 2\bar{\mu}_1 \chi_n \langle e_{ij} \rangle_1 + \bar{\lambda}_1 \delta_{ij} \chi_n \langle e_{ll} \rangle_1 \quad (3.7)$$

$$\sum_n c_n = c_1, \quad \sum_n c_n \langle e_{ij} \rangle_n = c_1 \langle e_{ij} \rangle_1, \quad (3.8)$$

в загальному вигляді являє залежністю

$$\langle \sigma_{ij} \rangle = \lambda^*_{ijkl} \langle e_{kl} \rangle, \quad (3.9)$$

де λ^*_{ijkl} тензор макроскопічних модулів пружності.

Порівняння двох останніх виразів показує, що знаходження макромодулів пов'язано з встановленням залежності між полем середніх деформацій у включеннях і макродеформацій всього матеріалу. З огляду на властивості необхідна функціональна зв'язок між кореляційним моментом і середніми деформаціями

$$\langle \chi'_i e'_{ij} \rangle = \phi \langle e_{ij} \rangle. \quad (3.10)$$

Для вирішення поставлених завдань скористаємося варіаційним принципом, згідно з яким абсолютний мінімум пружної енергії деформування, визначеної на всіх кінематичних можливих розподілів деформацій, відповідає дійсному полю переміщень (або деформацій, дотримуючись закону Коші). Для композитного матеріалу його сформулюємо наступне: пружна енергія деформування матеріалу досягає мінімуму на множині статистичних полів переміщень u_i при заданих середніх деформаціях $\langle e_{ij} \rangle$.

Представимо пружну енергію деформування, віднесену до об'єму V , у вигляді

$$\langle W \rangle = \frac{1}{V} \left(\int_{V-V_1} W_1 dV + \sum_n \int_{V_n} W_2 dV \right), \quad (3.11)$$

$$\text{де } W_1 = \mu e_{ij} e_{ij} + \frac{1}{2} \lambda e_{ii}^2. \quad W_2 = \mu_1 e_{ij} e_{ij} + \frac{1}{2} \lambda_1 e_{ii}^2.$$

Або використовуючи прийняті вище позначення середніх, одержимо

$$\langle W \rangle = \mu \langle e_{ij} e_{ij} \rangle + \frac{1}{2} \lambda \langle e_{ii}^2 \rangle + \sum_n (\bar{\mu}_1 c_n \langle e_{ij} e_{ij} \rangle_n + \frac{1}{2} \bar{\lambda}_1 \langle e_{ii}^2 \rangle_n). \quad (3.12)$$

Введемо деякі обмеження на поле кінематично можливих деформацій, виконавши в функціоналі припущення $\langle e_{ij} e_{ij} \rangle_n \approx \langle e_{ij} \rangle_n \langle e_{ij} \rangle_n$.

Це наближення, що відповідає випадку $e_{ij} e_{ij} = const$ в області включень n -го типу, дозволяє уникнути труднощів, пов'язаних з нелінійністю статистичної задачі. Внаслідок введеного припущення, функціонал набуде вигляду

$$\langle W \rangle = \mu \langle e_{ij} e_{ij} \rangle + \frac{1}{2} \lambda \langle e_{ii}^2 \rangle + \sum_n (\bar{\mu}_1 c_n \langle e_{ij} \rangle_n \langle e_{ij} \rangle_n + \frac{1}{2} \bar{\lambda}_1 \langle e_{ii}^2 \rangle_n). \quad (4.13)$$

Розглядаючи варіацію одержаного функціоналу на незалежних флуктуаціях переміщень $\delta u'_i$, одержимо умову мінімальності функціонала (4.13)

$$2\mu e'_{ij,j} + \lambda e'_{ii} + \sum_n (2\bar{\mu}_1 \chi'_{n,j} \langle e_{ij} \rangle_n + \bar{\lambda}_1 \chi'_{n,i} \langle e_{ii} \rangle_n) = 0. \quad (3.14)$$

Отримана система диференціальних рівнянь визначає флуктуації поля деформацій композиту. Її рішення, після множення на χ'_m і усереднення отриманого виразу по об'єму V , визначає необхідний функціональний зв'язок.

Рівняння вирішуються методом інтегрального перетворення Фур'є. Спектральні розкладання флуктуацій випадкових функцій будемо розрізняти зазначенням аргументу ξ , що служить параметром перетворення Фур'є. Рішення в просторі змінних, має вигляд

$$\begin{aligned} \mu e'_{ij}(\xi) = \frac{\lambda + \mu}{\lambda + 2\mu} \cdot \frac{\sum_n (2\bar{\mu}_n \chi'_n(\xi) \langle e_{kl} \rangle_n + \bar{\lambda}_n \chi'_n(\xi) \langle e_{\pi} \rangle_n \delta_{kl})}{\xi^4} \xi_i \xi_j \xi_k \xi_l - \\ - \sum_n \bar{\mu}_n \chi'_n(\xi) \langle e_{\pi} \rangle_n \frac{\xi_i \xi_j}{\xi^2} - \sum_n \bar{\mu}_n \chi'_n(\xi) \langle e_{jl} \rangle_n \frac{\xi_i \xi_l}{\xi^2} - \\ - \sum_n \bar{\lambda}_n \chi'_n(\xi) \langle e_{\pi} \rangle_n \frac{\xi_i \xi_j}{\xi^2} \end{aligned} \quad (3.15)$$

Співвідношення (4.15) вирішимо для трансверсально ізотропного середовища, коли включення мають однакову спрямованість.

Помножимо на χ'_m і усереднимо, приходимо до співвідношень:

$$\begin{aligned} \langle e_{12} \rangle_1 &= \frac{\langle e_{12} \rangle}{1 - (4R\mu'A - 2L\mu')/C_1}, \\ \langle e_{i3} \rangle_1 &= \frac{\langle e_{i3} \rangle}{1 - (4R\mu'(A+B) - \mu'(2L+M))/C_1}, (i=1,2), \\ \langle e_{11} \rangle_1 &= X_1 \langle e_{11} \rangle + Y_1 \langle e_{22} \rangle + Z_1 \langle e_{33} \rangle, \langle e_{22} \rangle_1 = X_2 \langle e_{11} \rangle + Y_2 \langle e_{22} \rangle + Z_2 \langle e_{33} \rangle, \\ \langle e_{33} \rangle_1 &= X_3 \langle e_{11} \rangle + Y_3 \langle e_{22} \rangle + Z_3 \langle e_{33} \rangle, \\ X_1 &= \frac{a_1 a_5 - a_3 a_4}{\Delta}, Y_1 = \frac{a_3 a_4 - a_2 a_5}{\Delta}, Z_1 = \frac{a_2 a_3 - a_1 a_3}{\Delta}, \\ X_2 &= Y_1, Y_2 = X_1, Z_1 = Z_2, X_3 = \frac{a_2 a_4 - a_1 a_4}{\Delta}, Y_3 = X_3, Z_3 = \frac{a_1^2 - a_2^2}{\Delta}, \\ R &= (\lambda + \mu)/(\lambda + 2\mu), a_1 = 1 - [R(6\mu'A + \lambda'L) - \lambda'L - 2\mu L]/C_1, \\ a_2 &= -[R(2\mu'A + \lambda'L) - \lambda'L]/C_1, a_3 = a_2 - 2\mu'RB/C_1, \\ a_4 &= -[R(2\mu'A + 2\mu'B + \lambda'(L+M)) - \lambda'(L+M)]/C_1, \end{aligned}$$

$$a_5 = 1 - [R(6\mu'A + 12\mu'B + 2\mu'C + \lambda'(L + M)) - \lambda'(L + M) - 2\mu'(L + M)] / C_1$$

$$\Delta = (a_1 - a_2)(a_5(a_1 + a_2) - 2a_3a_4).$$

Підстановка співвідношень в функціоналі пружної енергії W дозволяє встановити закон деформування композитного матеріалу. В загальному разі закон представимо таким:

$$\begin{aligned} \langle \sigma_{11} \rangle &= C_{11} \langle e_{11} \rangle + C_{12} \langle e_{22} \rangle + C_{13} \langle e_{33} \rangle, \langle \sigma_{22} \rangle = C_{12} \langle e_{11} \rangle + C_{11} \langle e_{22} \rangle + C_{13} \langle e_{33} \rangle, \\ \langle \sigma_{33} \rangle &= C_{13} \langle e_{11} \rangle + C_{13} \langle e_{22} \rangle + C_{33} \langle e_{33} \rangle, \\ \langle \sigma_{12} \rangle &= 2\mu_{12}^* \langle e_{12} \rangle, \langle \sigma_{13} \rangle = 2\mu_{13}^* \langle e_{13} \rangle, \langle \sigma_{23} \rangle = 2\mu_{13}^* \langle e_{23} \rangle, \end{aligned} \quad (3.16)$$

де $C_{11}, C_{12}, C_{13}, C_{33}, \mu_{12}^*, \mu_{13}^*$ – ефективні властивості пружності композита. Так, наприклад, модулі зсуву μ_{12}^*, μ_{13}^* дорівнюють

$$\begin{aligned} \mu_{12}^* &= \mu + \frac{\bar{\mu}_1 C_1}{1 - (4R\mu'A - 2L\mu') / C_1}, \\ \mu_{13}^* &= \mu + \frac{\bar{\mu}_1 C_1}{1 - [(4R\mu'(A + B) - \mu'(2L + M)) / C_1]} \end{aligned} \quad (3.17)$$

У разі просторового статистично однорідного армування можна застосувати процедуру переходу до властивостей ізотропності, описану, наприклад, в [5]. Отримані при цьому формули модулів пружності представлені нижче.

У разі структури композитного матеріалу з коротко волокнистими включеннями (рис. 4.3) модуль пружності композита E^* визначається наступне

$$E^* = E / [1 + (1 - c_f) / (Qc_f) + E / (E_f - E)], \quad (3.18)$$

де E, E_f – модулі пружності матриці та волокнистих включень, c_f – об'ємний зміст волокон у композитному матеріалі, Q – функція геометричних параметрів волокон, яка визначається через параметр $\alpha = \sqrt{1 - z^2}$, $z = \frac{d}{l}$, в якому d – діаметр волокна, l – його довжина

$$Q = 2\{1 + 0,1 / [6R_2 + E / (E_f - E)]\}, \quad (3.19)$$

$$R_1 = \frac{1 - \alpha^2}{4\alpha^5} \left[(3 - \alpha^2) \frac{1}{2} \ln \frac{1 + \alpha}{1 - \alpha} - 3\alpha \right],$$

$$R_2 = \frac{3}{8}[1-4R_1-R_3],$$

$$R_3 = \frac{1-\alpha^2}{\alpha^5} \left[(1-\alpha^2)\alpha + \frac{1}{2}(1-\alpha^2) \ln \frac{1+\alpha}{1-\alpha} \right].$$

У разі структури композитного матеріалу дисперсно армованого включеннями округлої форми (рис. 4.4) модуль пружності композита E^* визначається наступне

$$E^* = E \{1 + Q_I c_s / (1 - c_s)\}, \quad (3.20)$$

$$Q_I = 1 / [E / (E_s - E) + 0,4], \quad (3.21)$$

де E , E_s – модулі пружності матриці та дисперсних включень, c_s – об'ємний зміст дисперсних включень, Q_I – функція пружних властивостей.

Визначення в'язко-пластичних та теплофізичних властивостей

Розглянемо двофазову структуру композитного матеріалу, що складається з в'язко-пластичних компонент, підпорядкованим реологічним рівнянням Бінгама, що задають зв'язок між напруженнями σ_{ij} та швидкостями деформацій ε_{ij}

$$s_{ij} = k \frac{\varepsilon_{ij}}{\sqrt{\varepsilon_{kl}\varepsilon_{kl}}} + \eta \varepsilon_{ij}, \quad s_{ij} = \sigma_{ij} - \frac{1}{3} \sigma_{ll} \delta_{ij}, \quad (3.22)$$

де k – границя пластичності матеріалу, η – в'язкість матеріалу.

Варіаційну задачу визначення в'язко-пластичних властивостей двокомпонентного композитного матеріалу сформулюємо, по аналогії з постановкою задачі 1.1, як умову екстремальності функціоналу W^* , що представляє собою дисипацію енергії [4]

$$W^* = \frac{1}{V} \int_{V-V_1} (k \sqrt{\varepsilon_{ij}\varepsilon_{ij}} + \frac{1}{2} \eta \varepsilon_{ij}\varepsilon_{ij}) dV + \frac{1}{V} \int_{V_1} (k_1 \sqrt{\varepsilon_{ij}\varepsilon_{ij}} + \frac{1}{2} \eta_1 \varepsilon_{ij}\varepsilon_{ij}) dV. \quad (3.23)$$

де індексом 1 відмічені величини, що належать включенням.

Нехай структура матеріалу знову описується ізотропною функцією χ , що приймає значення 1 на включеннях, та 0 в матриці. Очевидно, $\langle \chi \rangle = c_1 = V_1/V$ та мають місце співвідношення

$$\begin{aligned} (1 - c_1) \langle \varepsilon_{ij} \varepsilon_{ij} \rangle_2 &= \langle \varepsilon_{ij} \varepsilon_{ij} \rangle - c_1 \langle \varepsilon_{ij} \varepsilon_{ij} \rangle_1, \\ \langle \chi' \varepsilon'_{ij} \rangle &= c_1 (\langle \varepsilon_{ij} \rangle_1 - \langle \varepsilon_{ij} \rangle), \end{aligned} \quad (3.24)$$

де індексом 2 позначено усереднення по матриці, штрихом – флуктуації випадкових величин. Введемо позначення: $I_0^2 = \langle \varepsilon_{ij} \rangle \langle \varepsilon_{ij} \rangle$; $I_1^2 = \langle \varepsilon_{ij} \rangle_1 \langle \varepsilon_{ij} \rangle_1$; $I^2 = I_0^2 + \langle \varepsilon'_{ij} \varepsilon'_{ij} \rangle - c_1 I_1^2$. Тоді (4.24) представимо

$$W^* = k \sqrt{1 - c_1} I + k_1 c_1 I_1 + \frac{1}{2} \eta I^2 + \frac{1}{2} \eta_1 c_1 I_1^2. \quad (3.25)$$

Мінімізація функціонала (4.25) по флуктуаціям ε'_{ij} за умови фіксованих середніх $\langle \varepsilon_{ij} \rangle$ приводить до обчислення $W^*(\langle \varepsilon_{ij} \rangle)$ а, отже визначає середні значення напружень

$$\langle \sigma_{ij} \rangle = \partial W^* / \partial \langle \varepsilon_{ij} \rangle.$$

Формули для обчислення інваріантів утворюють систему рівнянь

$$\begin{aligned} I_1(1 - 2(1 - c_1)A/5) &= I_0; \quad I^2 = I_0^2 - c_1 I_1^2 + \\ &+ 2c_1(1 - c_1)A^2 I_1^2/5; \end{aligned} \quad (3.26)$$

$$A = (\eta_1 + k_1/I_1) / (\eta + k\sqrt{1 - c_1}/I).$$

Залежно від напружень $\langle \sigma_{ij} \rangle$ можливий процес деформування, коли включення ведуть себе як жорсткі частинки. Для такого стану деформування ($I_1=0$) маємо [4]

$$\begin{aligned} W^* &= k\sqrt{1 - c_1}I + \frac{1}{2}\eta I^2, \quad I_0 = \frac{2}{5}(1 - c_1) \frac{k_1}{\eta + k\sqrt{1 - c_1}/I}, \\ I^2 &= I_0^2 + \frac{2}{5}c_1(1 - c_1)k_1^2 / (\eta + k\sqrt{1 - c_1}/I)^2, \end{aligned} \quad (3.27)$$

Співвідношення (4.28) дають можливість визначити дисипаційну функцію у випадку жорстких включень

$$W^* = k\sqrt{1 + \frac{3}{2}c_1}I_0 + \frac{1}{2}\eta \frac{1 + \frac{3}{2}c_1}{1 - c_1} I_0^2. \quad (3.28)$$

Неважко встановити в залежності (4.28) значення границь пластичності та в'язкості композитного матеріалу з жорсткими включеннями.

Критичні значення інтенсивності I^*_0 деформування, при якому напруження у включеннях досягнуть границі пластичності, слідує з (3.27)

$$k_1 = \frac{5}{2} \left(\frac{k}{\sqrt{1 + \frac{3}{2}c_1}} + \frac{\eta}{1 - c_1} I^*_0 \right). \quad (3.29)$$

Для спрощення прийемо, що включення (як волокна так і дисперсні частки) абсолютно тверді в порівнянні з матрицею. Тоді функціональна залежність межі пластичності композиту з дисперсними частками набуде вигляду

$$k^* = k \sqrt{1 + 1,5c_s} \quad (3.30)$$

а в разі волокнистих включень

$$k^* = k \sqrt{1 + (Q_2 - 1)c_f}, \quad (3.31)$$

$$\text{де } Q_2 = \frac{1 - \frac{2(1 - 8R_1 - 7R_2)}{5(1 - 4R_1 - 5R_2)} + \frac{2(R_1 - R_2)}{15R_2}}{2(2R_1 + R_2)} \quad (3.32)$$

Метод в'язкопружної аналогії Вольтера дозволяє отримати співвідношення, що визначають в'язкість композитного матеріалу. З урахуванням умови абсолютної жорсткості включень в порівнянні з матрицею, одержимо для композитного матеріалу першого рівня (матриця дисперсно армована включеннями округлої форми)

$$\eta^* = \eta(1 + 2,5c_s / (1 - c_s)) \quad (3.33)$$

і для композитного матеріалу другого рівня (композитний конгломерат першого рівня, в якому стохастичне однорідне розташовані коротковолокністі включеннями)

$$\eta^k = \eta^*(1 + Qc_f / (1 - c_f)). \quad (4.34)$$

У формулах (3.33-3.34), η - в'язкість матриці, c_s - об'ємний вміст дисперсних частинок, c_f - об'ємний вміст волокнистого наповнювача, Q визначається співвідношенням (3.19).

Теплофізичні властивості мають дуже важливе значення для визначення практичної цінності полімерних матеріалів. Такі пластмасові деталі технічних пристроїв, як ущільнювальні конструкції і багато інших, що працюють в нестационарних теплових полях, вимагають знання теплофізичних характеристик застосовуваних полімерних матеріалів. Ці дані необхідні для вибору параметрів процесів переробки пластмас у виробі з використанням нагрівання або охолодження робочого тіла (розплавлення, затвердіння, розм'якшення і т. д.). Коефіцієнт температуропровідності композитного матеріалу β^* є фізичним параметром, що характеризує теплоінерційні властивості фізичного об'єкта. Чим більше його значення, тим швидше відбувається вирівнювання температури у всіх точках тіла. Відповідно, чим нижче величина β^* , тим кращим теплоізолятором є матеріал. Знання температуропровідності необхідно в технологічних цілях для оцінки часу охолодження виробів, одержуваних з розплаву полімеру або з його розм'якшеної заготовки, для оцінки поведінки полімерної деталі в нестационарних теплових полях.

Розглядається трифазний композитний матеріал, який займає об'єм V , одна з компонент якого неперервна, дві інші мають форму дискретних включень, розподілених статистично однорідне в першій фазі. Будемо вважати всі компоненти в матеріалі ізотропним, що мають свої теплофізичні властивості і з'єднані з умов ідеального теплового контакту на границі розділу (безперервність температурного поля і теплового потоку при переході через границю) і підпорядковується закону Фур'є, що зв'язує потік тепла q_i і градієнт температури $T_{,j}$:

$$q_i = -\beta_{ij} T_{,j} \quad (3.35)$$

де β_{ij} – тензор коефіцієнтів теплопровідності.

Ефективні коефіцієнти теплопровідності композитного матеріалу β_{ij}^* визначають як коефіцієнти, що входять до співвідношення

$$\langle q_i \rangle = -\beta_{ij}^* \langle T_{,j} \rangle \quad (3.36)$$

Тут і в подальшому кутовими дужками позначаються середні по об'єму (3.1).

Знову геометричну структуру матеріалу задамо індикаторними випадковими функціями координат $\chi_n = (x_1, x_2, x_3)$, що приймають значення одиниці в області n -го включення і нуля - в іншому разі.

Теплофізичні властивості компонент композитного матеріалу (коефіцієнти теплопровідності) вважаємо заданими, включення композитного матеріалу будемо вважати близькими до сферичних.

Розрахунок теплофізичних властивостей композитного матеріалу пропонує визначення розподілу температур в структурі матеріалу і обчислення макроскопічних теплофізичних властивостей (коефіцієнтів теплопровідності).

Для вирішення поставлених завдань скористаємося варіаційним принципом, згідно з яким абсолютний мінімум теплової енергії, визначеної всіх можливих розподілах температур, відповідає дійсному полю температури. Для композитного матеріалу його сформулюємо наступне: тепла енергія матеріалу досягає мінімуму на множині статистичних полів температур при заданих середніх градієнтах температури.

Представимо функціонал для теплового поля, віднесений до об'єму V

$$\langle U \rangle = \frac{1}{V} \left(\int_{V-V_1} U_1 dV + \sum_n \int_{V_n} U_2 dV \right), \quad (3.37)$$

де $U_1 = \beta E_i E_i$, $U_2 = \beta_k E_i E_i$, ($k=1,2$), $E_i = T_{,i}$ – градієнт температури, β , β_k – коефіцієнти теплопровідності матриці та включень.

В макрооб'ємі V випадкові поля температури T і індикаторні функції є статистично однорідними, і ми застосовуємо гіпотезу ергодичності.

Використовуючи визначення середніх i , замінюючи температурні стану включень середніми по об'єму включень, отримаємо

$$\langle U \rangle = \beta \langle E_i E_i \rangle + \bar{\beta}_k c_k \langle E_i \rangle_k \langle E_i \rangle_k \quad (3.38)$$

$$\bar{\beta}_k = \beta_k - \beta_k c_k = V_k / V$$

Варіаційна постановка задачі теплопровідності передбачає відшукування при заданих середніх $\langle E_i \rangle$ статистично однорідного поля флуктуацій температур T' , яке відповідає мінімальному значенню функціонала (4.38). З умови екстремальності слідує

$$\beta E'_{i,i} + \bar{\beta}_k \langle E_i \rangle_k \chi'_{k,i} = 0 \quad (3.39)$$

Для зв'язку температурних полів у включеннях з температурними полями композиту має місце співвідношення

$$\langle E_i \rangle_k = \langle E_i \rangle + \langle \chi'_k E'_i \rangle / c_k \quad (3.40)$$

Застосувавши метод перетворення Фур'є, помноження на χ'_1 та χ'_2 , з виконанням усереднення, одержимо

$$\begin{aligned} \langle \chi'_1 E'_i \rangle &= (-\beta'_1 \langle E_i \rangle_1 c_1 (1 - c_1) + \beta'_2 \langle E_i \rangle_2 c_1 c_2) / 3, \\ \langle \chi'_2 E'_i \rangle &= (-\beta'_1 \langle E_i \rangle_1 c_1 c_1 + \beta'_2 \langle E_i \rangle_2 c_1 (1 - c_2)) / 3, \end{aligned} \quad (3.41)$$

де $\beta'_k = \bar{\beta}_k / \beta$

Розв'язуючи сумісно одержимо

$$\begin{aligned} \langle E_i \rangle_1 &= (1 + \beta'_2 / 3) \langle E_i \rangle / L, \quad \langle E_i \rangle_2 = (1 + \beta'_1 / 3) \langle E_i \rangle / L, \\ L &= (1 + \beta'_1 (1 - c_1) / 3) (1 + \beta'_2 (1 - c_2) / 3) - \beta'_1 \beta'_2 c_1 c_2 / 9 \end{aligned} \quad (3.42)$$

Спростимо функціонал (3.38), використовуючи (3.42). Згортка останніх з T' та усереднення призводять до рівняння

$$\beta \langle E'_i E'_i \rangle + \bar{\beta}_k \langle E_i \rangle_k c_k (\langle E_i \rangle_k - \langle E_i \rangle) = 0,$$

підстановка якого в (3.38) з врахуванням (3.41), приведе функціонал до виду

$$\begin{aligned} \langle U \rangle &= \beta \langle E_i \rangle \langle E_i \rangle + (\bar{\beta}_1 c_1 (1 + \beta'_2 / 3) / L) \langle E_i \rangle \langle E_i \rangle + \\ &+ (\bar{\beta}_2 c_2 (1 + \beta'_1 / 3) / L) \langle E_i \rangle \langle E_i \rangle \end{aligned} \quad (3.43)$$

З рівняння (4.43) слідує формула для визначення ефективного коефіцієнта теплопровідності трифазового композитного матеріалу

$$\beta^* = \beta + \bar{\beta}_1 c_1 (1 + \beta'_2 / 3) / L + \bar{\beta}_2 c_2 (1 + \beta'_1 / 3) / L \quad (3.44)$$

Одержана формула визначає залежність коефіцієнта теплопровідності трифазового композитного матеріалу від властивостей компонент, що створюють даний композит та їх об'ємного складу. Включення за формою близькі до сферичних.

Рівняння теплопровідності математично описує залежність між середніми (за об'ємом) значеннями потоку тепла і градієнта температури. Для знаходження температурного поля, тобто розподілу температури в структурі композитного матеріалу, потрібно скористатись одержаними співвідношеннями та задати граничні умови.

Визначення міцності полімерного матеріалу, хаотично армованого короткими волокнами

(дослідження виконані спільно с к. ф.–м. н. Долгіх В. М.)

Прогнозування властивостей міцності пов'язане з аналізом процесів, що відбуваються в структурі композитного матеріалу при виникненні та поширенні тріщин. Механіка композитних матеріалів [7, 8] розглядає, в основному, однонаправлено армовані матеріали з полімерною чи металевою матрицею, що володіє більшою граничною деформацією, а ніж волокна, внаслідок чого руйнування композита починається з обриву волокон. Перетинаючи поверхню тріщини волокна, чинять опір її розкриттю, що приводить до збільшення межі міцності композита.

Розглянемо композитний матеріал, що представляє собою полімерну матрицю, хаотично армовану короткими вуглецевими волокнами, що має в структурі плоску дископодібну тріщину радіуса a , пересічну в різних напрямках волокнами. На нескінченності, перпендикулярно тріщині, діє напруга σ^∞ , що розтягує, (рис. 3.5).




Рисунок 3.5 – Розрахункова схема композита з макротріщиною

Нехай r – полярний радіус точки. Область $0 \leq r \leq a$ відповідає розірваним зв'язкам між частками матриці. Замінімо дію волокон, що стримують розкриття тріщини, рівномірно розподіленими по її поверхні напругами σ_p . Відповідно до моделі Леонова – Панасюка [8], у кільцевій області $a \leq r \leq c$ протилежні береги тріщини притягаються з постійною напругою σ_0 , якщо відстань між ними не перевищує граничної величини розкриття тріщини δ_k . Величина σ_0 дорівнює межі міцності композита. Умова поширення тріщини має вигляд [8]:

$$2w(a,0) = \delta_k \quad (3.45)$$

де $w(r, z)$ – переміщення уздовж осі Z точки з координатами (r, z) .

Зсув точок матеріалу на поверхні тріщини щодо площини $z=0$ можна обчислити за формулою [8]

$$w(r,0) = B_k \int_0^{\pi/2} d\alpha \int_{r \sin \alpha}^{c \sin \alpha} \frac{q(\rho) d\rho}{\sqrt{\rho^2 - r^2 \sin^2 \alpha}}, \quad B_k = \frac{4(1-\nu_k^2)}{\pi E_k},$$

$$q(r) = \begin{cases} \sigma^\infty - \sigma_p, & 0 \leq r \leq a \\ \sigma^\infty - \sigma_0, & a < r \leq c \end{cases},$$

$$c = a \left[1 - \frac{(\sigma^\infty - \sigma_p)^2}{(\sigma_0 - \sigma_p)^2} \right]^{-1/2} \quad (3.46)$$

де ν_k, E_k - коефіцієнт Пуассона і модуль Юнга композита.

Обчислюючи внутрішній інтеграл, одержуємо

$$w(r,0) = B_k(\sigma_0 - \sigma_p) \int_{\arcsin(a/c)}^{\pi/2} \sqrt{a^2 - r^2 \sin^2 \alpha} d\alpha, \quad 0 \leq r \leq a, \quad (3.47)$$

$$w(r,0) = B_k(\sigma_0 - \sigma^\infty) \int_{\arcsin(a/c)}^{\arcsin(a/r)} \sqrt{a^2 - r^2 \sin^2 \alpha} d\alpha, \quad a < r \leq c,$$

При $r = a$ із формули (4.42) визначаємо переміщення точок на лінії, що розділяє зону зчеплення й зону розірваних зв'язків

$$w(a,0) = B_k(\sigma_0 - \sigma_p) a(1 - a/c). \quad (3.48)$$

Використовуючи критерій (4.41), знаходимо зовнішню граничну напругу

$$\sigma_*^\infty = \sigma_p^* + (\sigma_0 - \sigma_p^*) \sqrt{\frac{2a_*}{a} \sqrt{1 - \frac{a_*}{2a}}}, \quad a \geq a_* = \frac{\pi E_k \sigma_k}{8(1 - \nu_k^2)}, \quad (3.49)$$

де a_* – критичний розмір тріщини. При $a = a_*$ досягається найбільша величина міцності композита

$$\sigma_*^\infty = \sigma_p^* + \sigma_m^*, \quad (\sigma_m^* = \sigma_0 - \sigma_p^*) \quad (3.50)$$

При подальшому збільшенні радіуса тріщини ($a > a_*$), гранична напруга σ_*^∞ зменшується, тому σ_*^∞ є руйнівним навантаженням для композитного матеріалу з дископодібною тріщиною радіусом $a \geq a_*$. Композит із тріщиною радіусом $a < a_*$ має міцність бездефектного матеріалу.

Розглянемо пружне циліндричне волокно довжини L , що витягається силоміць P із пружної матриці, що заповнює півпростір $z \geq 0$ (рис. 3.6)




Рисунок 3.6 – Схема витягування волокна з матриці

Знайдемо розподіл уздовж волокна контактних напружень τ_{rz} та напружень у волокні σ_z^f . В роботі [9] задача зведена до чисельного рішення інтегрального

рівняння. Для одержання наближеного аналітичного рішення скористаємося теорією, викладеною в [8].

Рівняння для матриці:

$$\frac{\partial^2 w}{\partial r^2} + \frac{\partial w}{r \partial r} = 0, \quad \sigma_z = E_m \frac{\partial w}{\partial z}, \quad \tau_{rz} = G_m \frac{\partial w}{\partial r}, \quad (3.51)$$

де $w(r, z)$ – переміщення уздовж осі Z точки матриці з координатами (r, z) ; E_m, G_m – модулі Юнга і зсуву матеріалу матриці.

Рівняння рівноваги елемента волокна представимо у вигляді

$$\frac{d\sigma_z^f}{dz} = -\frac{2}{R} \tau_{rz}, \quad (3.52)$$

де σ_z^f – напруження у волокні, τ_{rz} – дотичне напруження на поверхні роздязнула волокна з матрицею, R – радіус поперечного перерізу волокна.

Позначаючи r_* – радіус зони погранслоя, $W(z)$ – переміщення точки волокна з координатою z і, використовуючи закон Гука

$$\sigma_z^f = E_f \frac{dW}{dz}, \quad (3.53)$$

а також умову спільності деформацій волокна й матриці, одержуємо

$$\frac{d^2 W}{dz^2} + k^2 W = 0, \quad k^2 = 2G_m \left[E_f R^2 \ln \frac{R}{r_*} \right]^{-1}. \quad (3.54)$$

Розв'язок рівняння, що задовольняє крайовим умовам $\sigma(0) = P/\pi R^2$, $\sigma(l) = 0$ має вигляд

$$W(z) = -\frac{P \operatorname{ch}[k(l-z)]}{k \pi R^2 \operatorname{sh}(kl)} \quad (3.55)$$

Співвідношення (4.52 – 4.55) дозволяють знайти шукані напруження

$$\sigma_z^f(z) = \frac{2\tau_0 \operatorname{sh}[k(1-z)]}{kR \operatorname{ch}(kl)}, \quad \tau_{rz}(z) = \tau_0 \frac{\operatorname{ch}[k(1-z)]}{\operatorname{ch}(kl)}, \quad \tau_0 = \tau_{rz}(0) \quad (3.56)$$

При $r_* = 8R$ і $E_f / E_m = 4$ напруження σ_z^f , обумовлена формулою (3.56), збігається з точністю до 4% з чисельним рішенням, приведеним у [9].

При зростанні сили P максимальне дотичне напруження збільшується, досягаючи деякого граничного значення $\langle \tau \rangle$, при якому відбувається відшарування волокна від матриці. Припускаючи, що на ділянці відшарування діє рівномірно розподілене по поверхні волокна дотичне напруження тертя τ_s , одержуємо наступні закони зміни $\tau_{rz}(z)$, $\sigma_z^f(z)$ волокна, що відшарувалося на глибину h

$$\tau_{rz}(z) = \begin{cases} \tau_s, & 0 \leq z \leq h, \quad \chi = \sqrt{(1 + \nu_m) \frac{E_f}{E_m} \ln \left(\frac{r_*}{R} \right)} \\ \langle \tau \rangle \operatorname{ch}[(l-z)/(\chi R)] / \operatorname{ch}[(l-h)/(\chi R)], & h \leq z \leq l \end{cases} \quad (3.57)$$

$$\sigma_z^f(z) = \begin{cases} 2\langle \tau \rangle \chi \operatorname{sh}[(l-z)/(\chi R)] / \operatorname{ch}[(l-h)/(\chi R)], & h \leq z \leq l \\ 2\tau_s(h-z)/R + 2\langle \tau \rangle \chi \operatorname{th}[(l-h)/(\chi R)], & 0 \leq z \leq h \end{cases} \quad (3.58)$$

З (3.57), (3.58) знаходимо подовження частини волокна на ділянці відшарування

$$W(h) - W(0) = \left\{ \tau_s h^2 / R + 2\langle \tau \rangle \chi h \operatorname{th}[(l-h)/(\chi R)] \right\} / E_f \quad (3.59)$$

Для визначення $W(h)$ скористаємося рішенням задачі Міндліна [11], що дозволяє обчислити поле переміщень, викликане дією зосередженої сили, прикладеної в деякій точці пружного півпростору. Припускаючи, що на ділянці $0 \leq z \leq h$ уздовж осі Z на матрицю діє погонне навантаження інтенсивністю $\tau_s 2\pi r$, а в точці $z = h$ прикладена зосереджена сила, рівна сумарному зусиллю, сприйманому не відшарованою ділянкою волокна, одержуємо вираз для $W(h)$, що після лінеаризації по h , прийме вигляд

$$W(h) = -\frac{R}{2G_m} \left\{ \left(1 - \frac{h}{l} \right) \langle \tau \rangle \chi \operatorname{th} \left(\frac{l}{\chi R} \right) + \tau_s \frac{h}{l} \ln \left(\frac{l}{R} \right) \right\} \quad (3.60)$$

Зв'язок напруги у волокні з переміщенням $W_0 = |W(0)|$ має вигляд

$$\begin{aligned} \sigma_z^f(0) &= 2\tau_s h/R + 2\langle \tau \rangle \chi \operatorname{th}[(l-h)/(\chi R)], \quad l > l_0, \\ \sigma_z^f(0) &= 2\tau_s l/R, \quad l \leq l_0 = \sqrt{RW_0 E_f / \tau_s}. \end{aligned} \quad (3.61)$$

Для волокна, зануреного в матрицю на глибину l під кутом θ до осі Z (рис. 3.7), співвідношення, аналогічні (3.61), запишемо у вигляді

$$\begin{aligned}
\sigma_z^f(0) &= \left\{ 2\tau_s \sqrt{VE_f \cos \theta / (R\tau_s)} + 2\langle \tau \rangle \chi \operatorname{th} \left[(1 - h_\theta) / (\chi R) \right] \right\} \cos \theta, \\
1_0 \leq 1 \leq L, \quad 0 \leq \theta \leq \theta_*, \quad \sigma_z^f(0) &= 2\tau_s 1 \cos \theta / R, \\
0 \leq 1 < 1_0 = \sqrt{RVE_f \cos \theta / \tau_s}, \quad 0 \leq \theta \leq \theta_*, \\
\sigma_z^f(0) &= E_f V \cos^2 \theta \operatorname{th} [1 / (\chi R)] / (\chi R), \\
\theta_* \leq \theta < \pi/2, \quad 0 \leq 1 \leq L.
\end{aligned}
\tag{3.62}$$




Рисунок 3.7 – Витягування волокна з матриці

Тут $2L$ – довжина волокна, $h_\theta = \sqrt{RV \cos \theta E_f / \tau_s}$, $\theta_* = \arccos[\langle \tau \rangle R \ln(r/R) / (VG_m)]$ – граничний кут (при $0 \leq \theta < \theta_*$ волокна відшаровуються, при $\theta_* \leq \theta < \pi/2$ – волокна не відшаровуються). Далі приймемо $\theta_* = \pi/2$.

Усереднення співвідношення (4.62) по орієнтаціям і глибинах занурення, дасть змогу одержати значення середньої напруги у волокні $\langle \sigma_f \rangle$, що перетинає тріщину. Наприклад, при статистично однорідному в площині армуванні воно дорівнює

$$\langle \sigma_f \rangle = \frac{4}{\pi L} \int_0^{\pi/2} d\theta \int_0^L \sigma_z^f(l, \theta) dl = \frac{8\tau_s}{\pi} \left\{ 0,8741 \sqrt{\frac{VE_f}{R\tau_s}} + \chi \frac{\langle \tau \rangle}{\tau_s} - \frac{\pi VE_f}{8 L \tau_s} \right\}
\tag{3.63}$$

Співвідношення (4.50), (4.51), (4.63) дозволяють установити залежність міцності композитного матеріалу від геометричних і механічних характеристик його компонентів. Кількість волокон N , що перетинають поверхню тріщини площею F при статистично однорідному об'ємному армуванні визначається формулою $N = c_f F / (2S)$, при площинному армуванні $N = 2c_f F / (\pi S)$, де c_f – об'ємний зміст волокон у композитному матеріалі, S – площа поперечного перерізу волокна. Перемножуючи середню напругу у

волокні $\langle \sigma_f \rangle$, що відповідає граничному розкриттю тріщини δ_k , на N , одержимо сумарне зусилля, що діє на береги тріщини з боку волокон. Розділивши це зусилля на площу поверхні тріщини, знайдемо σ_p^* . Залежність межі міцності композита $\sigma_k = \sigma_*^\infty$ від c_f , межі міцності матриці на розтягання σ_m й усередненої по орієнтаціям і глибинах анкеровки напруги у волокні $\langle \sigma_f \rangle$ представимо у вигляді:

$$\sigma_k = \langle \sigma_f \rangle c_f / 2 + \sigma_m (1 - c_f) \quad \text{— для об'ємного армування,} \quad (3.64);$$

$$\sigma_k = \langle \sigma_f \rangle c_f / \pi + \sigma_m (1 - c_f) \quad \text{— для площинного армування} \quad (3.65).$$

Використання побудованої моделі знаходження меж міцності вимагає знання деяких експериментально визначених характеристик.

Покажемо її застосування для матеріалів, характеристики для застосування яких представлені в науковій літературі.

У таблиці 4.1 порівнюються розраховані за пропонованою методикою й експериментально визначені [11] межі міцності на розтягання склогіпсу і склоцементу.

Характеристики композицій:

а) склогіпс — $E_m = 1,7 \cdot 10^4 \text{ MN/m}^2$, $\sigma_m = 2,75 \text{ MN/m}^2$,
 $E_f = 7,6 \cdot 10^4 \text{ MN/m}^2$, $\tau_s = 5,52 \text{ MN/m}^2$, $2L = 43 \text{ mm}$;

б) склоцемент — $E_m = 1,7 \cdot 10^4 \text{ MN/m}^2$, $\sigma_m = 2,75 \text{ MN/m}^2$, $E_f = 7,6 \cdot 10^4 \text{ MN/m}^2$,
 $\tau_s = 10,34 \text{ MN/m}^2$, $2L = 34 \text{ mm}$.

Скляні нитки складаються з 204 моноволокон, міцністю на розтягання $\sigma_f = 1210 \text{ MN/m}^2$, ефективний діаметр нитки $d = 0,144 \text{ mm}$. Армування в обох випадках — статистично однорідне в площині. При розрахунках покладалося $\langle \tau \rangle / \tau_s = 3$, $\delta_k = 2,2 \div 2,5 \cdot 10^{-3} \text{ mm}$.

Таблиця 3.1 – Порівняння розрахункових і експериментальних меж міцності

Матеріал	Склогіпс	Склоцемент
Об'ємна частка волокон	0,047 0,089	0,0325
Межа міцності на розтягання:		
розрахований	12,39	13,38
експериментальний	21,0 13,8 21,8	13,4

Створення критеріїв оптимального проектування структури композитного матеріалу

Абразивне зношування композиту залежить від того, наскільки ефективно мікроструктура композитного матеріалу може чинити опір різним процесам відділення матеріалу. Тому, при проектуванні абразивостійкого композиту, який деформується та зношується, необхідно врахувати його пластичну і пружну поведінку, зміну фізико-механічних характеристик властивостей, вплив концентрації, форми і відносних розмірів частинок двокомпонентного наповнювача на твердість, модуль пружності і деформацію композиту, на співвідношення в'язких і пружних властивостей, абразивну стійкість і теплофізичні властивості. Таким чином, виникає завдання розрахунків механічних характеристик трикомпонентних полімерних композитів з бінарним наповнювачем за властивостями вихідних інгредієнтів.

У багатьох роботах основними критеріями зносостійкості при абразивному зношуванні приймаються механічні характеристики матеріалу, які визначаються експериментально. Аналіз цих робіт свідчить, що абразивна зносостійкість полімерних композитів обумовлена його фізико-механічними, реологічними та деформаційно-міцнісними характеристиками властивостей. Тому, розробка критерію оптимізації наповненого полімеру за цими

характеристиками, які би визначалися теоретично за властивостями вихідних інгредієнтів на технологічній стадії виготовлення композиту, має практичне значення, так як дозволяє скоротити високовартісні експериментальні роботи. Закономірності абразивного зношування матеріалів приведені в роботах [1, 6, 12].

Дослідження показують на особливі межі пластичності композитів у залежності від концентрації наповнювачів: лінійний характер залежності (для випадку пластичного стану частинок наповнювачів) або закону квадратного кореня (для випадку жорсткого стану частинок). У загальному випадку необхідно визначити чотири ділянки на кривих деформування композиту:

- матриця і частинки наповнювачів деформуються пружно;
- матриця деформується пластично, частинки – пружно;
- матриця і частинки деформуються пластично;
- один з компонентів починає руйнуватися.

Від концентрації наповнювачів залежить поступ руйнації композиту, який є наслідком руйнації одного із компонентів. Для випадку, коли еліпсоїдні частинки руйнуються, використаємо метод, який (за аналогією з теорією пружних композитів) приводить до виразу:

$$H_k = H_0 \sqrt{1 + \frac{1}{\frac{1-c_f}{c_s Q_f} + \frac{\sigma_f^2}{\sigma_f^2 - \sigma_0^2}}}, \quad (3.66)$$

де функція визначається за формулою

$$Q_f = \frac{1 + \frac{4(R_1 - R_2)}{5\sigma_0^2(\sigma_f^2 - \sigma_0^2)^{-1} - 1 + 6R_2}}{\sigma_0^2(\sigma_f^2 - \sigma_0^2)^{-1} + 2(R_1 - R_2)}. \quad (3.67)$$

Завдання оптимального проектування трикомпонентного абразивостійкого композиту поставимо таким чином: необхідно підібрати склад композиту на основі полімеру та двокомпонентного наповнювача, змодельованого сферичними та еліпсоїдними частинками, який забезпечує

максимум абразивостійкості при заданих механічних властивостях полімерної матриці і наповнювачів.

Нехай структура композиційного матеріалу утворена полімерною матрицею і частинками наповнювача, в'язко-пружні, пластичні та міцнісні властивості яких відомі; компоненти композиту однорідні і міцно зв'язані з матрицею на межі розділу фаз, а матриця, крім пружних властивостей – модуля пружності E_0 – має в'язкість η_0 і межу пластичності τ_0 , які підпорядковані умовам текучості Мізеса та рівнянню в'язкопружності Максвела. Індокси у символах величин відносяться до сферичних (s) та еліпсоїдних (f) частинок, матриці (o) відповідно. Припустимо, що пружні деформації малі порівняно з пластичними. Поля швидкостей деформацій ϵ_{ij} і напружень σ_{ij} є статистично однорідними і задовольняють умовам ергодичності.

Для вибору критерію оптимізації, який надійно може дати оцінку абразивостійкості наповнених полімерів, необхідно брати характеристики композиту, які надійно визначаються за характеристиками вихідних компонентів. Критерії гранично допустимого зносу композиту повинні характеризувати початкові прояви процесу катастрофічного абразивного зношування (наприклад, текучості, граничної деформації), які передують повному руйнуванню композиту. Таким чином, у зв'язку з таким широким тлумаченням критерію граничного стану і абразивного зношування, практично неможливо охарактеризувати його з достатнім ступенем визначення.

Граничним станом полімеру часто називають такий напружений стан, при якому подальше підвищення напруження супроводжується процесом вимушеної деформації. При сумісництві в одному аналітичному виразі умов крихкого руйнування і вимушеної високоеластичної деформації можна створити узагальнені критерії гранично напруженого стану. Необхідність в розробці таких узагальнених критеріїв виникає у зв'язку з тим, що при зміні стану напруження

Прийmemo відоме положення, згідно якого межі текучості матриці σ_0 і композиту σ_k пропорційні їх твердості H_0 і H_k відповідно. Межі текучості розглянемо як межі міцності, виходячи з тих умов, що процес руйнування полімеру під час абразивного зношування супроводжується значними пластичними деформаціями, а крихкий характер руйнування привносять волокна і сферичні частинки. Досягнення частинками наповнювача напружень, при яких відбуваються їх руйнування, можна виразити умовами, коли міцність частинок наповнювача σ_1 дорівнює величині напруження, яка обчислена для незруйнованих жорстких частинок наповнювача:

Узгодження пружних і пластичних властивостей i , відповідно, максимальної абразивостійкості композиту досягається при певному оптимальному вмісту наповнювача. Згідно рис. 4.7, відносний модуль пружності збільшується, а відносна деформація зменшується при зростанні c_f і c_s . Серед розрахункових параметрів абразивостійкості вибираємо в'язкість матеріалу η і модуль пружності під час розтягу E , використовуючи методи теорії $T = \eta/E$, що має фізичний зміст часу релаксації напружень.

Для виключення розмірностей з критерію узгодження та зносостійкості використаємо поняття відносних характеристик:

$$\tau = \frac{T_0}{T_k} = \frac{\eta_0}{E_0 \frac{\eta_k}{E_k}} = \left(\frac{\eta_0}{\eta_k} \right) \cdot \left(\frac{E_k}{E_0} \right); \quad j = \frac{J_k}{J_0} = \frac{I}{I_k} \frac{I_0}{I_k}, \quad (3.68)$$

де τ – відносний критерій узгодження пружних та пластичних властивостей композиту;

T_0, T_k – критерії узгодження пружних та пластичних властивостей полімерної матриці і композиту відповідно; J_0, J_k – абразивна зносостійкість полімерної матриці і композиту відповідно; I_0, I_k – інтенсивність (або питома інтенсивність) абразивного зношування полімерної матриці і композиту відповідно; j – відносна абразивна зносостійкість композиту.




Рисунок 3.8 – Залежність відносного модуля пружності E_k/E_0 (1–6) та відносної деформації δ_k/δ_0 (1'–6') трикомпонентного композиту від об'ємної частки сферичних C_s частинок при об'ємній частці еліпсоїдних частинок C_f :

1,1' – 0; 2,2' – 0,05; 3,3' – 0,10; 4,4' – 0,15; 5,5' – 0,20; 6,6' – 0,25.

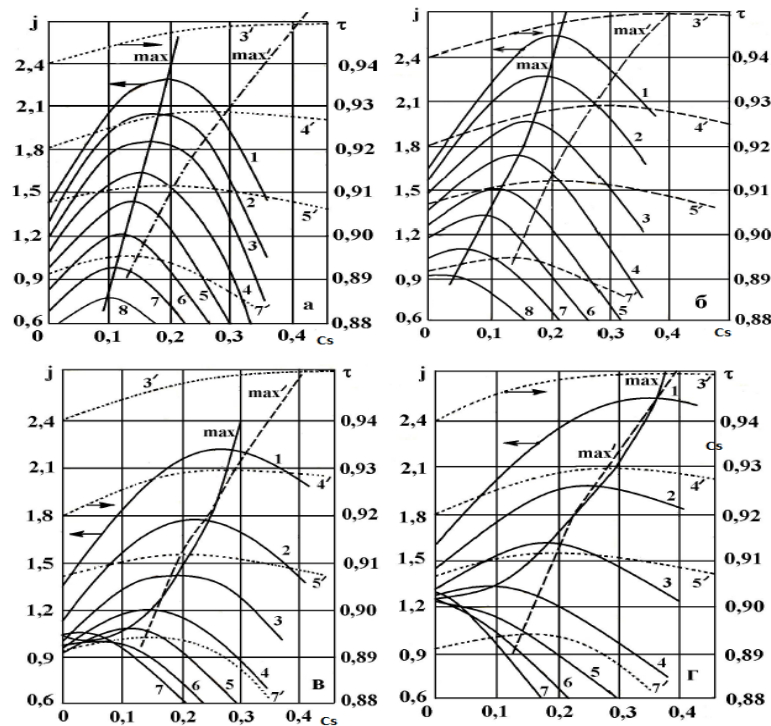


Рисунок 3.9– Залежність відносної абразивної зносостійкості I_0/I_k (1-8) при нормальному навантаженні $N = 20$ Н (а), 50 Н (б) 105 Н (в), 160 Н (г) на зразок та відносного критерію узгодження пластичних та пружних властивостей T_0/T_k (3' – 5', 7') трикомпонентного композиту на основі ПТФЕ від об'ємної частки порошку карбіду титану (C_s) при об'ємній частці вуглецевого волокна УТМ-8 (C_f): 1 – 0; 2 – 0,05; 3,3' – 0,10; 4,4' – 0,15; 5,5' – 0,20; 6 – 0,25; 7,7' – 0,30; 8 – 0,35.

Розрахунки ефективних властивостей композиційних матеріалів та порівняння з результатами за іншими дослідженнями

Розглянемо трикомпонентний композиційний матеріал як ієрархічну структуру, що розподілена на рівні:

- перший рівень – матричний конгломерат, який складається із полімерної матриці та статистично однорідне розподілених у ній включень першого типу;
- другий рівень – матричний конгломерат першого рівня, в якому статистично однорідне розподілені включення другого типу.

У такій постановці ми зможемо розрахувати макровластивості як композитних матеріалів, поданих на рисунках 3.1, 3.2, так і змоделювати інші трикомпонентні структури. Наприклад, розглянемо антифрикційні композити на епоксидній основі, дисперсно армовані включеннями двох видів, геометрично близькими до сферичних, пружні характеристики яких досліджувались в роботі [13]. У цій роботі матричний конгломерат першого рівня складають – матриця УП-610 ($E = 5,2$ ГПа), в якій розподілені включення графіту ($E_1 = 10,9$ ГПа) з фіксованою 10% масовою концентрацією, а на другому рівні до нього додається компонент другого типу, концентрація якого змінюється від 0 до 0,8. З тих варіантів, що розглянуті в роботі, вибрані компоненти другого рівня – скло ($E = 7$ ГПа) та мідь ($E = 125$ ГПа). На рис. 3.10 наведені розрахунки модуля Юнга E^* композитного матеріалу на основі полімерного зв'язуючого УП-610, при фіксованій концентрації включень графіту (10%) та включень зі скла (на графіку макровластивості цієї композиції вказані синім кольором), або включень з міді (на графіку макровластивості цієї композиції вказані червоним кольором). Розрахунки проводились за формулами (3.22), (3.23). Порівнюючи одержані результати з результатами роботи [13], можна зробити висновок, що при малих концентраціях включень, вони мало відрізняються (при $c_s \leq 0,2$), а для достатньо великих концентрацій ($c_s \geq 0,5$) – результати наших досліджень перевищують результати [13]. Тобто, для майже лінійних

ділянок графіки співпадають, а також співпадають з відомим рішенням для часткового випадку, коли включення абсолютно тверді порівняно з матрицею – $E^* = E \{1 + 5c_s/2\}$.




Рисунок 3.10 – Ефективні характеристики антифрикційних композитів за вхідними даними з [7]




Рисунок 3.11 – Залежність модуля Юнга композита від довжини волокна

Вплив довжини волокна на ефективні пружні властивості композитного матеріалу досліджено для двофазового композитного матеріалу такого складу: полімерна матриця на основі політетрафторетилену (Ф-4) з $E = 410$ МПа, армована вуглецевими волокнами $E_f = 35$ ГПа, що статистично однорідне розподілені в ній з концентрацією по об'єму $c_f = 0,18$. Діаметр включень визначався незмінним $d = 10$ мкм. Довжина волокон змінювалась в діапазоні $120 \div 240$ мкм. На графіку (рис. 4.11) спостерігаємо незначний спад E^* при збільшенні довжини армованих волокон. Якщо,

довжина волокна постійна (в даному разі приймалось, що $l=150$ мкм), а діаметр його змінювався в діапазоні $5\div 17$ мкм, спостерігається незначне збільшення E^* (рис. 4.12).




Рисунок 3.12 - Залежність модуля Юнга композита від діаметра волокна

На рис. 3.13 подані розрахунки відносного модуля пружності композитного матеріалу E_k/E_m , структуру якого складають: матриця – фторопласт (ПТФЕ) з $E_m = 410$ МПа; вуглецеві волокна $E_f = 35$ ГПа; дисперсні частинки коксу $E_s = 500$ МПа.




Рисунок 3.13 – Залежність модуля Юнга композитного матеріалу від об'ємного складу вуглецевих волокон та дисперсного армування

На рис. 3.14 представлені в'язко-пластичні властивості одержаної композиції.

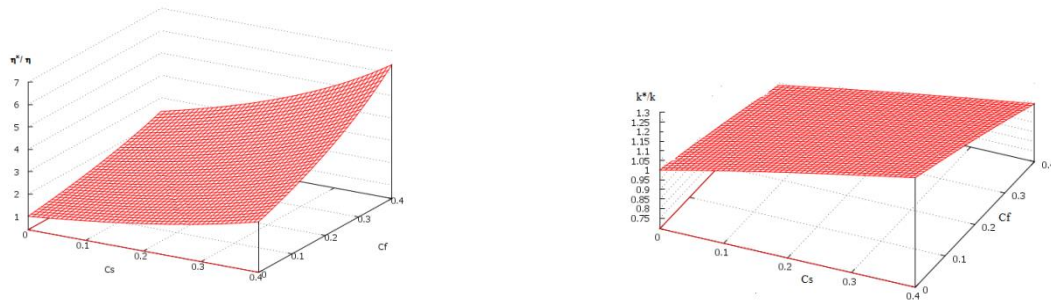


Рисунок 3.14 – В'язко-пластичні властивості трикомпонентного композитного матеріалу

Поставимо завдання розрахувати підбір компонентів трифазової структури, що забезпечує високу абразивну зносостійкість за критерієм узгодження властивостей

$$\tau = T / T_0 = (k^*E) / (kE^*). \quad (3.69)$$

В даному дослідженні зафіксуємо вміст включень волоконної геометрії (їх об'ємний зміст в матриці представлений в легенді до графіків), а за об'ємним складом дисперсних включень знаходимо максимальне значення критерію (4.69). Дослідження представлені рисунком 4.15.




Рисунок 3.15 – Оптимальне проектування трикомпонентної структури за критерієм узгодження властивостей

Графіки рис. 3.15 вказують, що при проектуванні трифазової структури композитного матеріалу на основі фторопласту (ПТФЕ), армованого об'ємним вмістом вуглецевих волокон в кількості $C_f = 0,2$ або $C_f = 0,1$, другу

компоненту - дисперсні частинки коксу слід прийняти C_s в кількості 0,2-0,22 за об'ємною змістом, що забезпечить згідно з прийнятим критерієм, максимум зносостійкості. Такий висновок добре підкріплений практичними (експериментальними) даними.

Висновки

Використовуючи варіаційний метод теорії композитних матеріалів, досліджується як пружна, так і в'язко-пластична поведінка матеріалу. Метод апробований на трикомпонентних композитних матеріалах, включення яких геометрично та фізико-механічно відрізняються між собою (мають форму коротких волокон або близьких до сферичних). Розрахунки пружних та в'язко-пластичних властивостей порівнюються з результатами інших досліджень.

У математичну процедуру оптимізації складу композитного матеріалу введений критерій абразивної стійкості, що узгоджує пластичні і пружні властивості – відношення динамічної в'язкості до модуля пружності. Наведені розрахунки за цим критерієм. Досліджується процес руйнування композитного матеріалу під дією напруги. Визначена межа міцності композиційного матеріалу, армованого короткими волокнами в залежності від геометричних і механічних характеристик його компонентів.

Запропоноване математичне моделювання апробоване на розрахунках реальних трикомпонентних три-ботехнічних матеріалів, які використовуються у вузлах тертя, що показало його ефективність і застосовність в задачах створення і проектування нових матеріалів.

3.2 ІНЖЕКЦІЙНА СПЕКТРОСКОПІЯ ГЛИБОКИХ ПАСТОК У ПЛІВКАХ НАНОСТРУКТУРОВАНОГО СУЛЬФІДУ КАДМІЮ

Плівки сульфід кадмію останнім часом інтенсивно досліджуються завдяки можливості використання як базові шари фото- та газових

детекторів, тонкоплівкових транзисторів, відіконів, світлодіодів, електродів електрохімічних комірок, електролюмінесцентних приладів, вікон високоефективних сонячних елементів на базі поглинаючих шарів CdTe, CuInSe₂ (CIS), CuIn_{1-x}Ga_xSe₂ (CIGS), Cu₂ZnSnSe₄ (CZTSe) та ін. [1-2].

Для практичного використання плівок CdS у мікро- та оптоелектроніці, сонячній енергетиці необхідна оптимізація їх оптичних та електрофізичних характеристик які, у значній мірі, визначаються ансамблем власних точковими дефектів та неконтрольованими домішками [3]. Ці дефекти будучи зарядженими утворюють у забороненій зоні матеріалу пасткові та рекомбінаційні локалізовані стани (ЛС). Необхідність цілеспрямованого керування властивостями обумовила значний інтерес дослідників до вивчення дефектної структури сульфїду кадмію та визначення її впливу на фізичні характеристики матеріалу. У той же час, незважаючи на велику кількість робіт, присвячених цьому питанню, енергетичний спектр ЛС у забороненій зоні (ЗЗ) сульфїду кадмію залишається дослідженим недостатньо, у першу чергу, це стосується плівкових зразків, одержаних різними методами конденсації у вакуумі.

Одним з найбільш прийнятних методів дослідження ЛС у напівізолюючих матеріалах, таких, як CdS, що поєднує у собі простоту експериментального обладнання та високу чутливість до їх низьких концентрацій, є метод, що базується на аналізі стаціонарних вольт-амперних характеристик (ВАХ) у режимі струмів, обмежених просторовим зарядом (СОПЗ) [4-5]. Цей метод у різних модифікаціях [6-8] знайшов широке розповсюдження для визначення параметрів пасток у великій групі широкозонних напівпровідників та діелектриків. Однак у класичному вигляді, метод ВАХ СОПЗ має ряд недоліків, які призводять до істотного зменшення інформативності і деякої некоректності отриманих за його допомогою результатів [9]. Саме тому у ряді досліджень [10-12] були запропоновані підходи, які дозволяють позбавитися недоліків існуючого методу аналізу ВАХ СОПЗ та отримати найбільш детальну інформацію про

спектр ЛС у ЗЗ матеріалу безпосередньо з експериментальних ВАХ шляхом їх диференціальної обробки (метод інжекційної спектроскопії (ІС)), тобто шляхом розв'язання зворотної задачі досліджень. Диференціальний метод також дозволяє однозначно визначити механізм зарядоперенесення у багатошарових структурах шляхом аналізу особливостей ВАХ [13-15].

У даній роботі наведені результати визначення механізмів зарядоперенесення та розрахунку параметрів ЛС у нанокристалічних плівках CdS з використанням низькотемпературного наближення диференціального методу у залежності від стехіометрії та умов одержання зразків.

EXPERIMENTAL DETAILS

Плівки сульфід кадмію одержували методом осадження у квазізамкненому об'ємі з шихти напівпровідникової чистоти при температурах підкладки $T_H = 600-640$ °С та випарника $T_B = 720-750$ °С. Для регулювання стехіометрії шарів в процесі їх нанесення співвипаровувалася сірка при температурах $T_C = 60-200$ °С. Як підкладки використовувалося покрівне скло з провідним підшаром ІТО. Особливості отримання плівок більш докладно описані у роботі [16]. У якості верхнього струмознімального контакту застосовані шари In (площею $0,02$ см²), одержані вакуумним випаровуванням. Цей матеріал дозволяє реалізувати інжекцію носіїв струму у сульфід кадмію при прикладенні напруги.

Морфологія поверхні отриманих плівок та їх стехіометрія досліджувалися з використанням електронного мікроскопу S-806 Hitachi та Superprobe-733 JEOL, відповідно.

Темнові та світлові квазістаціонарні ВАХ при прямій та зворотній напрузі знімалися при кімнатній температурі за допомогою стандартизованого автоматичного тестера 14 ТКС-100. Напруга змінювалася покроково з періодом 160 мс, а вимірювання струму проводилось через 90 мс після подачі напруги. При вимірюванні світлових ВАХ застосовувалася

галогенова лампа, що забезпечувала освітлення зразків білим світлом, еквівалентним 0,1 потужності Сонця (3 мВт/см²).

ТЕОРЕТИЧНА ЧАСТИНА

Визначення механізму зарядоперенесення, який обумовлює проходження струму через зразки, проводилось за допомогою методу диференціальної обробки ВАХ, розвиненого у роботах []. Метод дозволяє шляхом сумісного аналізу $j-U, \eta-U$ та $d(\lg \eta)/d(\lg U)-U$ залежностей ($\eta = \frac{d(\ln j)}{d(\ln U)}, \eta' = \frac{d^2(\ln j)}{d(\ln U)^2}, \eta'' = \frac{d^3(\ln j)}{d(\ln U)^3}$) розрізнити супутні та конкуруючі механізми зарядоперенесення у структурах, а також виділяти серед них високопольові.

Метод ІС використовувався нами лише для обробки ВАЗ обумовлених СОПЗ. Основні співвідношення методу ІС одержані у [10-12], мають вигляд

$$n_{fL} = \frac{\eta}{2\eta-1} \frac{jL}{e\mu U}, \quad (1)$$

$$n_{sL} = \frac{\rho_L}{e} = \frac{2\eta-1}{\eta} \frac{\eta-1}{\eta} \left[1 - \frac{\eta'}{\eta(2\eta-1)(\eta-1)} \right] \frac{\varepsilon\varepsilon_0 U}{eL^2}, \quad (2)$$

де j – густина струму, що протікає крізь зразок; U – зовнішня напруга; e – заряд електрона; μ – рухливість носіїв заряду в матеріалі; L – товщина зразка; ε_0 – діелектрична стала; ε – діелектрична проникність матеріалу; n_{fL} – концентрація вільних носіїв при інжекції на аноді (у подальшому індекс L у співвідношеннях будемо опускали); n_{sL} – фактична концентрація носіїв, що захоплені у пастки біля аноду; ρ_L – густина об'ємного заряду в матеріалі (на аноді), яка відповідає за обмеження наскрізного струму через зразок.

Скориставшись добре відомим співвідношенням, яке пов'язує концентрацію вільних носіїв у матеріалі та положення рівня Фермі, легко

записати рівняння, що дозволяє визначити енергетичний масштаб при дослідженні ЛС.

$$E_F = kT \ln \frac{N_{c(v)} e^{\mu}}{L} + kT \ln \frac{j}{U} + kT \ln \frac{\eta}{2\eta-1}, \quad (3)$$

де E_F – положення квазірівня Фермі при інжекції; k – стала Больцмана; T – температура вимірювання; $N_{c(v)}$ – ефективна густина вільних станів у зоні провідності (валентній зоні) матеріалу.

Функцію розподілу носіїв заряду, локалізованих на глибоких центрах, одержимо шляхом диференціювання співвідношення (2) за енергією

$$\frac{dn_s}{dE_f} = \frac{1}{kT} \frac{2\eta-1}{\eta} \left\{ 1 + \frac{3(\eta-1)\eta\eta' - \eta\eta'' + 3\eta'^2}{\eta^2[(2\eta-1)(\eta-1) - \eta'/2]} \right\} \frac{\varepsilon\varepsilon_0 U}{eL^2}. \quad (4)$$

При використанні низькотемпературного наближення вважається, що функція розподілу густини ЛС за енергією $h(E) = \frac{dN_t}{dE}$ співпадає з функцією, яка описує розподіл локалізованих носіїв заряду, але це призводить до похибок при відтворенні форми розподілів пасток та визначенні їх глибини залягання (E_t) і концентрації (N_t) [9, 12, 17]. При високих температурах функцію $h(E)$ можна знайти із згортки:

$$\frac{dn_s}{dE_f} = \int_E h(E) \frac{df(E - E_f)}{d(E - E_f)} dE, \quad (5)$$

де $f(E - E_f)$ - функція Фермі-Дірака.

Спільне розв'язання рівнянь (3), (4) та (5) дозволяє знайти функцію $h(E)$ у 33 матеріалу безпосередньо з експериментальних ВАХ СОПЗ, знятих при довільній температурі. Для цього необхідно визначити три похідні у кожній точці j - U залежності у подвійних логарифмічних координатах. Математично

задача зводиться до побудови згладжувального кубічного сплайна, що апроксимує експериментальні дані, диференціювання його у вузлах з подальшим знаходженням функції $h(E)$ із згортки (5).

Фізично можливість сканування енергетичних розподілів пасток при інжекції носіїв заряду з контакту обумовлена наступним. При збільшенні зовнішньої напруги квазірівень Фермі починає рухатись у ЗЗ матеріалу, при цьому відбувається заповнення ЛС вільними носіями та зміна провідності структури. Оскільки існує зв'язок між величинами, що можуть бути вимірні експериментально (j, U) , та тими, що характеризують розподіл пасток, (E_f, ρ) кожна точка ВАХ несе інформацію про відповідну ділянку енергетичного спектру ЛС.

У роботі для визначення параметрів ЛС у плівках CdS використано низькотемпературне наближення методу ІС. У цьому випадку функція Фермі-Дірака у (5) замінювалася функцією Хевісайда. Для розрахунку енергії залягання пасткових рівнів у ЗЗ матеріалу та їх концентрації використані методи запропоновані у роботах [11, 18]. Отримані результати перевірялися шляхом розв'язання прямої задачі експерименту, побудови за відомими параметрами ЛС ВАХ СОПЗ. Співпадання форми вхідної і реконструйованої ВАХ свідчило про правильність визначення параметрів глибоких пасток у матеріалі [17].

РЕЗУЛЬТАТИ ТА ОБГОВОРЕННЯ

Електронно-мікроскопічні знімки поверхні плівок CdS представлені на рис 1. Як і очікувалося, шари були суцільними та мали дрібнодисперсну полікристалічну (нанокристалічну) структуру (рис.1а). При подальшому осадженні на поверхні плівок сульфід кадмію формувалися нанострижні (рис.1б). Як свідчать дані дослідження елементного складу плівок, шари отримані при $T_C =$ містили надлишок кадмію ($Cd > S$ на 3-5%), при $T_C =$ надлишок сірки ($Cd < S$ на 2-3%).




Рисунок 3.16– Електронно-мікроскопічні знімки поверхні плівок CdS: короткострокова (а) та довгострокова стадії росту (б)

На рис. 3.16а наведені темнові та світлові ВАХ (при прямому та зворотному зміщенні) багатошарових структур ITO/CdS/In, де плівки CdS мають надлишок кадмію ($Cd > S$ на 3-5%), відповідно на рис. 2б представлені криві від шарів з надлишком сірки ($Cd < S$ на 2-3%). Аналіз ВАХ свідчить що матеріал плівок мав питомий опір що становив ($5 \cdot 10^6 - 10^7$) Ом·см. З рис.2 видно, що підвищений вміст сірки у плівці CdS призводить до збільшення фотопровідності матеріалу. При надлишку сірки провідність освітленого матеріалу збільшується майже три порядки (рис. 3.16б), у той час, коли при дефіциті сірки - тільки на один порядок за величиною. Встановлено також, що дефіцит кадмію знижує темнову провідність матеріалу на два порядки.

На темнових ВАХ від плівок CdS («+» ІТО) з надлишком та дефіцитом сірки, в області високих напруженостей поля, спостерігалось декілька майже лінійних ділянок з різним нахилом до осі напруги. Як правило, виділялись ділянки з залежністю струму від напруги виду: $I - U$, $I - U^{1,5-2}$, $I - U^{3-4}$. У ряді випадків після суперлінійних ділянок спостерігалась квадратична залежність I від U .

Особливості ВАХ добре розрізняються на залежностях $\eta - \log U$, які дозволяють виявити тонку структуру кривих струм-напруг. Кожна точка цього графіку визначає кут нахилу кривої струм-напруга у подвійному логарифмічному масштабі до осі напруги. Залежності $\eta - \log U$ були одержані нами шляхом знаходження похідної у кожній експериментальній точці ВАХ СОПЗ. Як вже вказувалося, математично задача зводилася до побудови згладжувального кубічного сплайна, що апроксимує експериментальні дані та його диференціювання у вузлах. Результати диференційної обробки темнових та світлових ВАХ наведені на рис. 3.17а-г та 3.17 д-з.

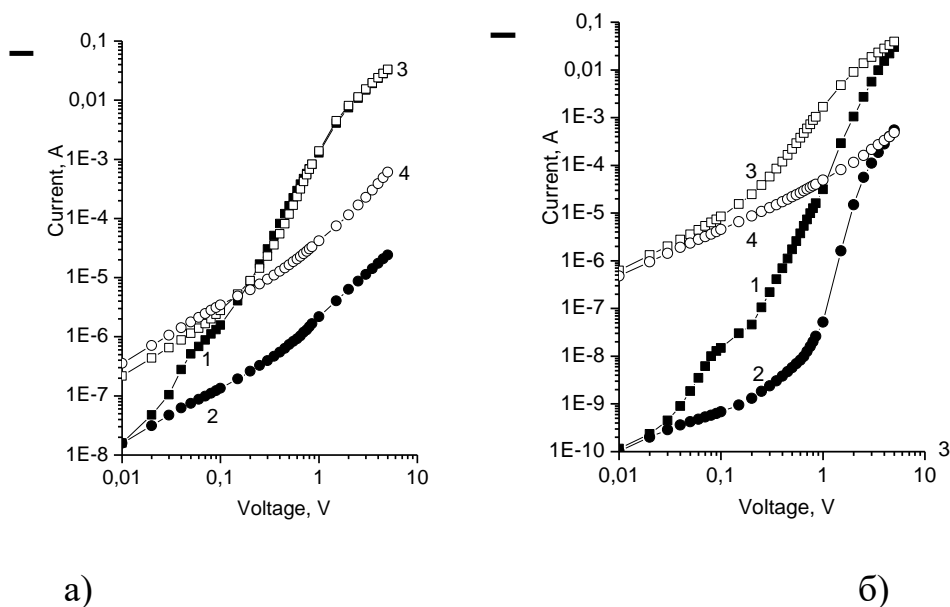


Рисунок 3.17– ВАХ у подвійному логарифмічному масштабі від багат шарових структур ІТО/CdS/In (а, б) плівки CdS з надлишком кадмію (а), з надлишком сірки (б); 1,3 – «+» ІТО, 2, 4 – «+» In. Затемнені символи відповідають темновим струмам, відкриті - струмам при освітленні зразків білим світлом

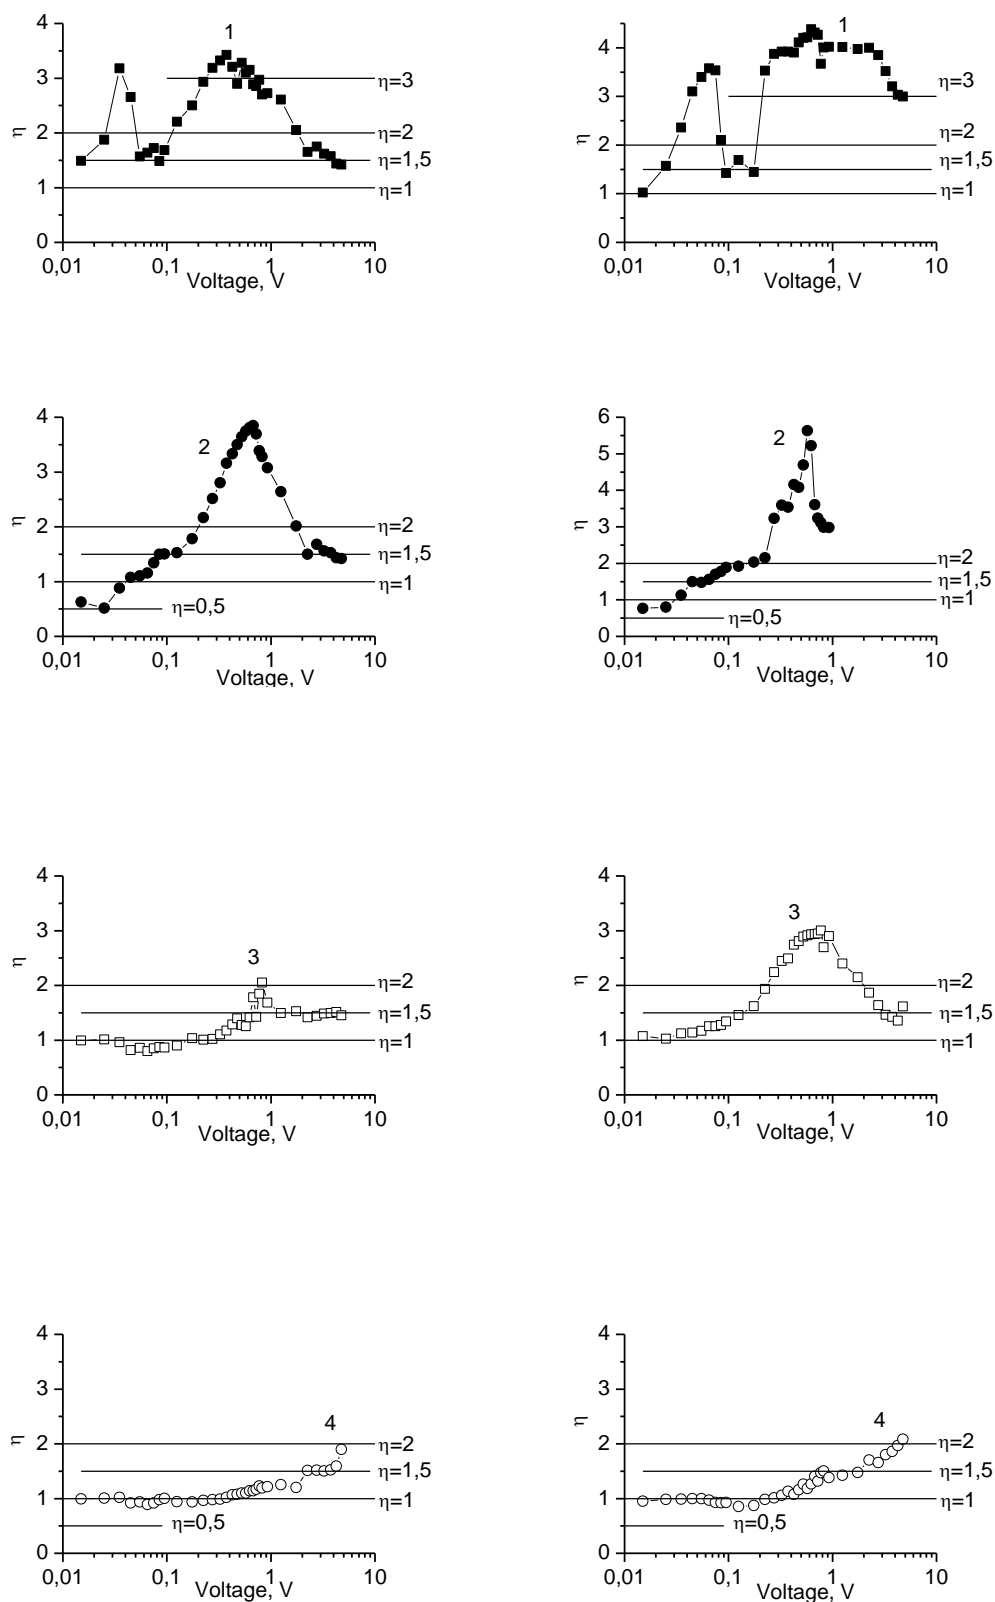


Рисунок 3.18– Диференційний нахил ВАХ: плівки з надлишком кадмію (а, в, д, ж), з надлишком сірки (б, г, е, з); 1,3 – «+» ІТО, 2, 4 – «+» Іп. Затемнені символи відповідають темновим струмам (а-г), відкриті (д-з) - струмам при освітленні зразків білим світлом

Диференційний аналіз нахилу ВАХ (рис. 3.18 в, г) [СП1, СП2] дозволив виявити два варіанти у характері інжекції носіїв у матеріал: у випадку надлишку кадмію ($S < Cd$) має місце бімолекулярна рекомбінація матеріалі як у темноті та при освітленні, вона забезпечує диференційний нахил ВАХ $\eta=1.5$. У випадку надлишку сірки ($S > Cd$) головним механізмом зарядоперенесення є мономолекулярна рекомбінація, саме вона забезпечує диференційний нахил кривих струм-напруга $\eta=2$. В усіх випадках на кривих мають місце стрибки струму, характерні для СОПЗ. Математична обробка відповідних кривих дозволила побудувати залежності $n_s - E_F$ (а) та $dn_s/dE_F - E_F$ (рис. 3.19) та визначити значення E_t , N_t пасток присутніх у ЗЗ матеріалу.




Рисунок 3.19– Типові диференціальні криві $n_s - E_F$ (а) та $dn_s/dE_F - E_F$ (б), одержані у результаті обробки ВАХ СОПЗ, які дозволили визначити параметри пасток у матеріалі

Було встановлено, що для сульфїду кадмію з надлишком кадмію ($S < Cd$) є характерними ЛС з енергією $E_t = 0.514 \pm 0.026$ eV, в той час як у матеріалі з надлишком сірки ($S > Cd$) у ЗЗ присутні рівні з $E_t = 0.514 \pm 0.026$ eV та $E_t = 0.700 \pm 0.026$ eV. Концентрація дозаповнення носіями цих ЛС становила від $2 \cdot 10^{21}$

м^3 до $5 \cdot 10^{22} \text{ м}^3$ в залежності від полярності та умов освітлення. Відповідно їх повна концентрація N_t є дещо вищою від цих значень.

Таким чином, виявлена залежність інжекційних параметрів та характеру інжекції у структурах ІТО/CdS/Іn на основі наноструктурованих плівок CdS від їх стехіометрії.

Висновки

Методом ВАХ досліджені полікристалічні наноструктуровані плівки CdS з регульованою стехіометрією, нанесені методом квазізамкненого об'єму. Встановлено, що шари отримані при $T_C < 80\text{C}$ містили надлишок кадмію ($\text{Cd} > \text{S}$ на 3-5%), при $T_C > 120\text{C}$ надлишок сірки ($\text{Cd} < \text{S}$ на 2-3%). Показано що у випадку надлишку кадмію ($\text{S} < \text{Cd}$) механізм зарядоперенесення у багат шарових структурах на основі плівок CdS визначається бімолекулярною рекомбінацією у матеріалі як у темноті та при освітленні. У випадку надлишку сірки ($\text{S} > \text{Cd}$) головним механізмом зарядоперенесення є мономолекулярна рекомбінація. Методом ІС у сульфіді кадмію з надлишком кадмію виявлені ЛС з енергією $E_t = 0.514 \pm 0.026 \text{ eV}$, в той час як у матеріалі з надлишком сірки - рівні з $E_t = 0.514 \pm 0.026 \text{ eV}$ та $E_t = 0.700 \pm 0.026 \text{ eV}$. Повна концентрація цих ЛС N_t перевищує $2 \cdot 10^{21} \text{ м}^3$ - $5 \cdot 10^{22} \text{ м}^3$. Виявлена залежність інжекційних параметрів та характеру інжекції у структурах ІТО/CdS/Іn на основі наноструктурованих плівок CdS від їх стехіометрії.

3.3 КОМПАРАТИВНИЙ АНАЛІЗ МЕТОДІВ МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ НЕСТАБІЛЬНИХ ЧАСОВИХ РЯДІВ КОРОТКОЇ ВИБІРКИ

В останні кілька десятиліть був досягнутий значний прогрес в аналізі часових рядів. З'явилися інноваційні теоретичні та методологічні інструменти для

декомпозиції часових рядів, моделювання причинно-наслідкових зв'язків і прогнозування. Досягнення в області комп'ютерних технологій, накопичення великих обсягів даних високої частотності, а також їх доступність в режимі реального часу, стимулювали широке використання чисельних, імітаційних та нелінійних непараметричних методів, спрямованих на розв'язання невизначеностей, пов'язаних з даними, параметрами чи моделями. Швидка еволюція економічного середовища і технологій актуалізує розробку методів машинного навчання, які можуть бути адаптовані до різних галузей і завдань. Одним з прикладів є фінансова та макроекономічна економетрика часових рядів, методологія якої динамічно розвивається та інтенсивно використовується в інших дисциплінах. Великою проблемою, зокрема для країн з перехідною економікою, де накопичені бази даних є обмеженими та недосконалими, є вибір оптимальних статистичних інструментів і підходів для моделювання короткої вибірки вола тильних даних з численними викидами та структурними зрушеннями.

Аналіз основних досягнень та літератури. Останні публікації доводять підвищений інтерес до змішаних методів моделювання, які поєднують в собі класичний авторегресійний підхід аналізу часових рядів [1, 2], частотний підхід, побудований на спектральному аналізі (експоненціальне згладжування) [2, 3], та каузальні підходи із включенням пояснювальних змінних [4, с. 351-398]. Декілька економетричних методів було запропоновано в області аналізу одновимірних часових рядів для поліпшення виявлення і оцінювання прихованих компонентів спостережувальних даних і генерування більш точних прогнозних інтервалів. Згадані вище класичні моделі було переглянуто в контексті інноваційного структурного підходу динамічних лінійних моделей «state space» [4, с. 382]. Введений спочатку Кальманом (1960) [5] для контролю лінійних систем, зазначений підхід потім використовувався при оцінці неспостережуваних компонентів або станів динамічних стохастичних систем [2], виділяючи, зокрема, рівень, тренд, циклічні та сезонні коливання, нерегулярні компоненти або збурення

часового ряду, з метою дослідження факторів невизначеності, викидів, негаусівських залишків. Щоб покращити апроксимаційні і прогнозні властивості моделей та їх стабільність дослідники враховували нелінійність, аномальні спостереження, параметри, що змінюються в часі, включали лагові залежні змінні і додаткові пояснювальні змінні [3, 6, 7]. При цьому особливою популярністю набули нелінійні непараметричні методи, включаючи нейронні мережі і машинне навчання, а також їх гібриди з класичними методами часових рядів [8]. Збільшення доступності і різноманітності джерел та типів даних сприяло інноваціям в технологіях багатовимірних часових рядів. Динамічна факторна модель є одним з таких рішень, яке дозволяє вирішити проблему ступенів свободи, узагальнюючи інформацію, що міститься в багатьох економічних змінних в невеликій кількості факторів [9]. Незважаючи на величезний вибір сучасних моделей і методів, експериментальні дослідження показали, що моделі, які спираються виключно на історичних спостереженнях залежної змінної, в тому числі моделі випадкового блукання, не можуть бути відкладені і часто перевершують багатofакторні моделі у точності прогнозів [3, 8].

В останнє десятиліття науковці розробили набір спеціалізованого статистичного програмного забезпечення та мов програмування (EViews, STATA, SAS, SPSS, R, Julia та інші), які автоматизують більшість економетричних методів і підходів. R – це відкрита мова програмування і середовище для статистичних обчислень, що найбільш динамічно розвивається. Дане дослідження було проведено за допомогою наступних пакетів R для аналізу часових рядів:

“Forecast” (пакет «Прогноз») – надає інструменти для «Box-Cox» трансформації даних, аналізу стаціонарності, декомпозиції часових рядів, Фур'є-аналізу, експоненціального згладжування, побудови моделей авторегресії та ковзного середнього (ARMA), в тому числі з додатковими регресорами, моделей нейронних мереж, крос-валідації моделей і т.д. [10].

“Stsm” – пакет для структурних Баєсівських моделей – оцінює попередні

значення параметрів моделі, визначає логарифмічну функцію правдоподібності за допомогою фільтра Кальмана, визначає апостеріорний розподіл параметрів на основі максимізації логарифмічної функції правдоподібності, реалізує ітераційний метод збіжності моделей [11];

“Ttsoutliers” пакет – допомагає у виявленні, оцінюванні та локалізації аномальних спостережень для відповідного коригування моделі [12].

Мета та задачі дослідження. Ця стаття проводить порівняльний аналіз існуючих методів прогнозування часових рядів, фокусуючись на пошуку можливих рішень моделювання, що забезпечать високу точність прогнозів для нестабільних даних короткої вибірки із викидами. Емпіричні дослідження проводилися в інтегрованому програмному середовищі R-Studio на базі 205 щомісячних даних українського реального ефективного обмінного курсу (*REER*) та інших макроекономічних змінних за 2000-2016 рр. [13].

Результати моделювання. Курси валют одні з найпопулярніших змінних, які використовуються для моделювання і прогнозування часових рядів як з погляду економістів, так і з погляду спеціалістів математики та статистики. Будь-який аналіз часових рядів вимагає попередньої оцінки їх властивостей та розподілу. Візуальний огляд плаваючих обмінних курсів різних країн виявив такі загальні риси їх поведінки [7]:

- випадкове блукання з незначним дрефтом або його відсутністю;
- зміна режимів (від стабільної до волатильної динаміки);
- наявність циклічної еволюції із періодами зростання та стрімкого раптового падіння;
- кластерна волатильність або непостійна дисперсія (періоди значних змін супроводжуються періодами незначних коливань).

Для цієї роботи ми обрали показник реального обмінного курсу замість міжбанківського чи офіційного курсу гривні до долара США для прогнозування і моделювання в Україні. *REER* представляє зважене середнє валюти країни щодо кошика інших основних валют, з поправкою на вплив

інфляції [13] і вирішує проблему зміни режимів валютного курсу. Аналіз розподілу ряду *REER* за допомогою коробчастої діаграми (*boxplot*) і функції квантилів щільності розподілу (*qqplot*) [14] (див. рис. 3.20) показує існування численних викидів і перекосів, що відкидає гіпотезу нормального розподілу ряду, що приймаються параметричними процедурами, такими як *t*-тест, *F*-тест (ANOVA) і тест Пірсона. Зауважимо, що згідно методології *boxplot* (див. рис. 3.20a) значення ряду, які відхиляються від значення першого квартиля більш ніж на 1,5*межквартильний діапазон (IQR), вважаються підозрюваними викидами. Відхилення, які перевищують трьохкратний IQR відносять до істинних аномалій [15]. Рис. 3.20b показує асиметрію спостережуваних даних через відхилення емпіричної щільності розподілу від щільності нормального розподілу, що має форму прямої.

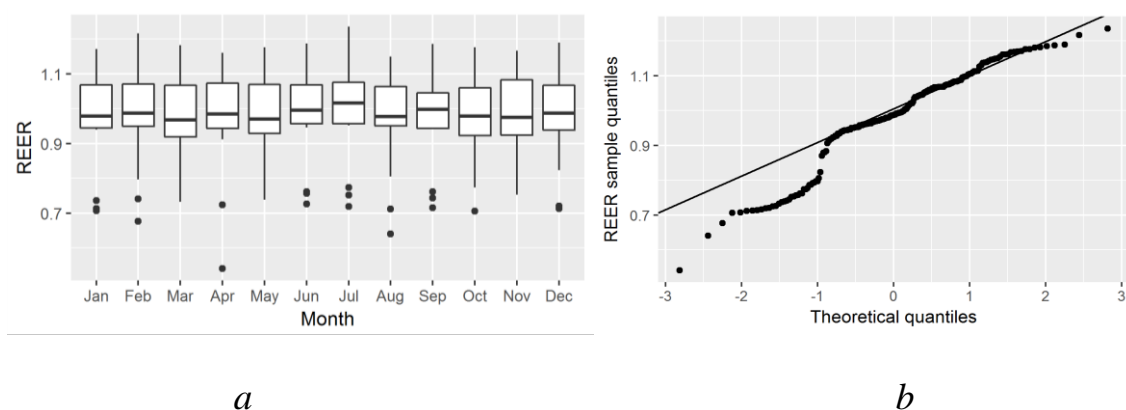


Рисунок 3.20 – Аналіз розподілу часового ряду: a – *boxplot*; b – *qqplot*.

Декомпозиція часових рядів на тренд-циклічні, сезонні та нерегулярні складові дає краще розуміння структури даних і може бути використана для поліпшення потужності прогнозу. Класичні адитивні та мультиплікативні методи декомпозиції часових рядів, що використовують процедуру ковзного середнього, не стійкі до викидів і зміни сезонних відхилень, а також не враховують спостереження на початку та в кінці ряду [2]. Непараметричний метод сезонної і тренд-циклічної декомпозиції (*stl*), розроблений Клівлендом і співавторами [16, 10], дає більш ефективні оцінки моделей часових рядів. Ми використовували *stl* декомпозицію для *REER*, щоб виявити структуру

ряду та властивості залишків та аномальних спостережень (див. рис. 3.21). Було встановлено, що функціональна форма компонентів серії є адитивною: $Reer_t = S_t + T_t + E_t$, де $Reer_t - REER$ дані на період t ; S_t – сезонна складова в період t ; T_t – тренд-циклічна складова в період t ; E_t – залишковий компонент (або нерегулярний компонент, або помилки) в час t . Для отримання згладженої лінії тренду ми застосували метод декомпозиції, який використовує зменшені ваги аномальних спостережень 2008, 2009 і 2014 років. На рис. 3.21 трендовий компонент виявляє спадний рух циклічного характеру, залишковий компонент відображає кластеризацію волатильності і серію аномальних спостережень. Відносні пропорції компонентів $REER$ такі: сезонність – 7%, тренд – 88%, залишковий компонент – 18.5%.




Рисунок 3.21 –Stl декомпозиція ряду $REER$

Зіткнувшись з проблемою непостійної дисперсії і ненормального розподілу, ми застосували метод “Вох-Сох логарифмічної та степеневі трансформації”. Дана процедура передбачає оцінку параметра λ , який є необхідним ступенем ряду, що стабілізує дисперсію залишків [3]:

$$\omega_t = \begin{cases} \log(y_t) & \text{якщо } \lambda = 0; \\ (y_t^\lambda - 1) / \lambda & \text{в іншому випадку.} \end{cases}$$

За розрахунками Вох-Сох лямбда для $REER$ $\lambda = -0.2$. Візуальний огляд трансформованого ряду не показав належної стабілізації залишкового компоненту. Хоча, логарифмічне перетворення ($\lambda = 0$) суттєво покращило апроксимуючі властивості оцінених моделей.

Подальше виявлення та аналіз викидів було проведено за допомогою R пакету "tsoutliers" [12]. Його автори розрізняють відомі ефекти і аномальні викиди, що відображують раптові зміни в динаміці даних. У разі існування попередньої інформації щодо поведінки ряду, вони пропонують включати додаткові пояснювальні змінні в модель. В іншому випадку, для забезпечення правильного вибору моделі і коректної оцінки відповідних параметрів, має бути реалізована процедура визначення і усунення ефекту викидів [6, 12]. Залежно від впливу на динаміку наступних спостережень ряду, дослідники виділяють п'ять типів викидів: інноваційний викид (ІО), адитивний викид (АО), зсув рівня або структурний розрив (LS), тимчасова зміна (ТС) і зрушення сезонного рівня (SLS). Загальне представлення викидів формулюється як: $L(B)I(t_j)$, де $L(B)$ є поліномом оператора лагу $By_t = y_{t-1}$ та $I(t_j)$ є змінною індикатора, який приймає значення 1 в момент часу $t = j$, коли відбувається аномальний стрибок і значення 0 в іншому випадку. Поліном $L(B)$ для кожного типу аномальних значень розраховується наступним чином [12]:

$$\text{ІО: } L(B) = \frac{\theta(B)}{\alpha(B)\phi(B)}; \quad \text{LS: } L(B) = \frac{1}{(1-B)}; \quad \text{АО: } L(B) = 1; \quad \text{ТС: } L(B) = \frac{1}{(1-\delta B)}; \quad \text{SLS: } L(B) = \frac{1}{(1-B^s)}. \quad (1)$$

Тут $\theta(B)$ являє собою ковзне середнє (МА) поліному; $\phi(B)$ – авторегресія (AR) поліному; $\alpha(B)$ – різницевий параметр (d) для стаціонарних даних; $\delta = 0.7$ в [11]; s – періодичність даних ($s=12$ для щомісячних даних).

ARIMA модель для ряду y_t^* із характерними m викидами, що мають ваги ω , представлена рівнянням [4, 12]:

$$y_t^* = \sum_{j=1}^m \omega_j L_j(B) I_j(t_j) + \frac{\theta(B)}{\phi(B)\alpha(B)} a_t, \quad (2)$$

де $a_t \sim \text{NID}(0, \sigma_a^2)$ – процес білого шуму з нульовим середнім і сталою дисперсією.




Рисунок 3.22 – Викиди *REER* (2000:01 - 2016:06)

У таблиці 1 представлені оцінені в пакеті R [12] аномалії досліджуваного ряду шляхом побудови моделі ARIMA (2) на навчальних даних *REER* за період, зменшений на 7 місяців (2000:01 - 2016:06) (див. рис. 3.22). Значення всіх видів викидів в різні періоди часу було підтверджено відповідними *t*-статистиками (див. табл. 3.1).

Таблиця 3.1 – Викиди *REER* (2000:01 - 2016:06)

№	Тип	Спостер.	Час	Коеф.	t-стат.
1	LS	64	2005:04	0.06621	4.107
2	TC	102	2008:06	0.06498	4.502
3	TC	104	2008:08	0.07452	4.554
4	AO	105	2008:09	0.04886	4.222
5	LS	107	2008:11	-0.11773	-6.429
6	LS	110	2009:02	0.06000	3.584
7	AO	176	2014:08	-0.04781	-4.754
8	AO	178	2014:10	0.05019	4.999
9	TC	182	2015:02	-0.27213	-19.184
10	LS	194	2016:02	-0.06305	-3.897

Аналіз стаціонарності досліджуваного ряду з використанням тестів на визначення одиничного кореню: тест Діккі-Фуллера (ADF) (має місце сильне

припущення про відсутність кореляції помилок та постійну дисперсію) і тест Філіпса-Перона (PP) (пом'якшує припущення про нормальний розподіл помилок) випробувань [17, с. 344-345], а також тесту на стаціонарність Kwiatkowski-Phillips-Schmidt-Shin (KPSS) [10] показали, що ряд *REER* стає стаціонарними після першого диференціювання. Оцінка функцій автокореляції (ACF) і часткової автокореляції (PACF) та подальша ідентифікація моделі із застосуванням підходу Бокса-Дженкінса [1, с. 282-319] вказували на вибір моделі ARIMA (0, 1, 1), із зазначенням параметру авторегресії $p = 0$, порядку диференціювання $d = 1$, і параметру ковзного середнього $Q = 1$. Усунення оцінених викидів (табл. 1) призвело до зміни параметрів відповідної моделі – ARMA ($p = 1, d = 0, q = 1$) (3), що вказувало на стаціонарність ряду в рівнях (див. рис. 3.):

$$\begin{aligned} Reer_t = & 95.926 + 96.88Reer_{t-1} + 49.31u_{t-1} + 6.62LS64 + 6.5TC102 + 7.45TC104 + 4.89AO105 \\ & - 11.77LS107 + 6LS110 - 4.78AO176 + 5.02AO178 - 27.21TC182 - 6.31LS194 + a_t \end{aligned} \quad (3)$$

Константа в (3) показує середнє значення ряду; оцінені компоненти авторегресії і ковзного середнього відображають властивості автокореляції залишків; фіктивні змінні викидів демонструють динаміку аномальних спостережень та їх впливу на подальші значення ряду. Для перевірки прогнозної точності моделі ми розділили спостереження *REER* на навчальні та випробувальні вибірки різної довжини (7 місяців і 12 місяців). Незважаючи на те, що оцінені параметри ARIMA моделі (3) були визначені, щоб задовольнити припущення білого шуму залишків, аналіз результативності прогнозування вказує на погіршення якості прогнозу зі збільшенням горизонту прогнозування і відповідного скорочення навчальної вибірки. У таблиці 2 наведені результати моделювання, реалізовані як на необроблених даних, так і на його логарифмічному перетворенні (значення ряду помножені попередньо на 100 в обох випадках). Модель (3) із навчальною вибіркою 2000:01-2016:06 мала найнижчий рівень правдоподібності оцінки (MLE) дисперсії інновацій:

$$\sigma^2 = \sum (y - \hat{y})^2 / \text{кількість залишків} , \quad \text{найбільше значення логарифмічної}$$

правдоподібності (логарифм ймовірності даних спостережень з розрахункової моделі [2]) і найменшого інформаційного критерію Акаїке, скорегованого на розмір вибірки (AICc). Навчальні моделі 1 і 2 в таблиці 2, показали хороші апроксимаційні властивості в термінах середньої абсолютної похибки (MAE) і середніх показників абсолютної процентної помилки (MAPE). Точність медіанного прогнозу поза межами вибірки MAPE для моделі необроблених даних погіршилася з 1,43% до 3,19%, і 10,78% зі збільшенням горизонту прогнозування. Логарифмічне перетворення призвело до зміни параметрів моделі – ARIMA (2, 0, 0) і виявлених викидів, що покращило точність прогнозу моделі до 1,86% MAPE для 7-місячного випробувального періоду, але погіршило відповідні результати для 12-місячного горизонту прогнозу на 12,52%.

Таблиця 3.2 – Резюме і точність прогнозу моделі ARIMA, скорегованої на викиди (3)

N	Тренувальна вибірка (Тестова вибірка)	MLE дисперсії σ^2	Log likelihood	Інформ. критерій		Точність тренувальної мод.		Точність прогнозу для тест. вибірки	
				AICc	BIC	MAE	MAPE	MAE	MAPE
1.	2000:01-2016:06 (2016:07-2017:01)	0.0003532	510.74	-991.18	-947.43	1.3650	1.433	2.3637	3.188
	Log transformed	0.0005057	473.83	-926.48	-894.77	1.0157	1.4087	1.0271	1.8601
2.						1.3718	1.423	7.9412	10.783

Продовження таблиці 3.2

(2016:02- 2017:01)			5	7					
Log transformed	0.00050 73	461.1	- 903.2 2	- 874.8 4	1.015 8	1.408 9	1.115 0	12.52 38	

Ми спробували поліпшити прогнозу потужність моделі включенням додаткових пояснювальних змінних, що відображають наявну інформацію щодо руху *REER* в різні періоди часу замість усунення викидів. Перший викид типу LS (табл. 3.1) відноситься до ревальвації гривні в квітні 2005 року, скерованої урядом. Наступні три викиди (спостереження номер 102, 104, 105) демонструють короткострокове зміцнення національної валюти в 2008 році у зв'язку зі сприятливою кон'юнктурою на зовнішніх ринках. Викиди спостережень 107 (LS), 176 (AO), 182 (TC) і 194 (LS) відносяться до девальвації гривні в 2008 році через світову фінансову кризу, в 2014 році і наступні роки через політичну та макроекономічну дестабілізацію в Україні. Ми ввели набір фіктивних біноміальних змінних для пояснення зазначених вище ефектів залишків. Це три змінних структурного розриву (LS), які включають підвищення рівня, починаючи з квітня 2005 року, зменшення рівня, починаючи з листопада 2008 року і наступне з березня 2014 року; фіктивна змінна *dreer*, яка приймає значення 1 для від'ємних викидів адитивного типу; і сезонна змінна *dseas*, що відображує збільшення значень ряду кожного червня. Для зниження волатильності дисперсії, ми усунули викиди тимчасових змін № 102-105 і 182 (табл. 3.1) через процедуру згладжування середнього. Визначення параметрів моделі як за допомогою підходу Бокса-Дженкінса [1], так і за алгоритмом Гайндмана-Хандакара [2, 10] довели гіпотезу про неправильну специфікацію тестів одиничного кореня і стаціонарності часових рядів у разі існування викидів, із зазначенням моделі ARMA (1, 0, 0) для логарифмічно перетвореного ряду на основі додаткової інформації про аномальні спостереження:

$$\ln(Reer_t) = 4.61 + 0.96 \ln(Reer_{t-1}) + 0.06d_{2005} - 0.12d_{2008} - 0.13d_{2014} - 0.05dreer + 0.01dseas + \varepsilon_t \quad (4)$$

(0.036)
(0.019)
(0.018)
(0.019)
(0.019)
(0.005)
(0.003)

Помилки оцінених коефіцієнтів, наведених в дужках (4) доводять значимість всіх змінних на підставі t -статистики (розрахунковий коефіцієнт, поділений на відповідну похибку). Діагностичне тестування залишкової автокореляції за допомогою тесту Льюнг-Бокса [4, с. 328-329] і графічного представлення ACF показало покращені статистики моделі, які засвідчують некорельованість залишків і правильну специфікацію моделі після повного опису викидів фіктивними змінними (табл. 3.2). Включення додаткової пояснювальної змінної ($Xreg$), що представляє логарифм відношення грошової бази до вартості міжнародних резервів, покращило як тренувальну, так і позавибіркову точність прогнозу, а також характеристики адекватності моделі (MLE, LL, AIC, BIC, LB). Ми порівняли моделі ARMA порядків (1, 0, 0) і (1, 0, 1) з додатковими регресорами, описані рівняннями (4), (3), з моделлю ARIMA (0, 1, 0), інтегрованої порядку 1 без будь-яких регресорів. Наші результати показали кращі короткострокові апроксимаційні властивості моделі ARMA, і більш точні довгострокові результати прогнозування моделі ARIMA, яка розглядає ряд нестационарними в присутності зсуву рівнів і адитивних викидів і зводиться до моделі випадкового блукання без дрейфу (див табл. 3.3).

Таблиця 3.3 – Резюме і точність прогнозу моделі ARIMA з фіктивними змінними (4)

N	Тренувальна вибірка (Тестова вибірка)	MLE дисперсії σ^2	Log likelihood (LL)	Інформ. критерій		Точність тренувальної моделі		Точність прогнозу (тест. вибірка)	
				AICc	BIC	LB stat	MAPE	MAE	MAPE
1.	Full sample size 2000:01-2017:01	0.0003498	527.06	-1037.38	-1011.53	$Q=17.691$ $p=0.397$	1.3047		
2.	2000:01-2016:06 (2016:07-2017:01)	0.0003494	509.21	-1001.66	-976.12	$Q=18.061$ $p=0.385$	1.3330	1.2756	1.6769
	with $X_{reg}: \ln(mb/rez)$	0.0003298	515.99	-1010.81	-979.1	$Q=15.102$ $p=0.444$	1.3167	1.1927	1.5651
3.	2000:01-2016:01 (2016:02-2017:01)	0.0003379	500.47	-981.96	-953.58	$Q=18.614$ $p=0.351$	1.3103	4.8390	6.5137
	with $X_{reg}: \ln(mb/rez)$	0.0003227	504.69	-990.4	-962.02	$Q=17.388$ $p=0.361$	1.3048	4.6103	6.2101

Емпіричні оцінки доводять, що для забезпечення точного прогнозування з ARMA (4), ми повинні забезпечити надійні сценарії для пояснювальних регресорів. Ці прогнози повинні бути засновані на оцінці несподіваного компонента оголошення новин, а не на їх історичній цінності [7]:

$$n_{k,t} = (A_{k,t} - E_{k,t}) / \sigma_k, \quad (5)$$

де $n_{k,t}$ являє собою стандартизований компонент новини для індикатора k до моменту t ; $A_{k,t}$ – заявлене значення змінної протягом періоду часу $(t; t+1)$; $E_{k,t}$ – відповідне очікуване значення змінної; σ_k – дисперсія чисельнику.

Дослідивши можливі способи використання моделей ARMA класичного підходу аналізу часових рядів для нестабільних коротких даних, ми спробували порівняти їх продуктивність з іншими методами моделювання, описаних в огляді публікацій. В Таблиці 4 наведені показники точності тренувальних моделей та позавибіркового прогнозу для наступних типів моделей, реалізованих в пакеті R ‘forecast’ [10]: випадкове блукання; ARIMA і ARMA з виявленими викидами (3), (4); сезонна і трендова декомпозиція з використанням Loess (stl); експоненціальне згладжування; експоненціальне згладжування із визначенням станів («state space»), трендового і сезонного компонентів, Вох-Сох перетворенням ряду, ARMA оцінюванням помилок (tbats); експоненціальне згладжування з дрейфом (theta); структурна компонента «state space» модель, що використовує метод максимальної правдоподібності для оцінювання коефіцієнтів; модель прямої нейронної мережі. Всі моделі були оцінені з використанням логарифмічно перетвореного ряду. Модель нейронної мережі та модель ARMA (4) з фіктивними змінними і пояснювальною змінною *mb/rez* показали кращі апроксимаційні властивості навчальних моделей періодів 2000:01-2016:06 і 2000:01-2016:01. Краща позавибіркова точність прогнозу була отримана за допомогою моделей ARMA (4) і stl для 7-місячного горизонту прогнозу, та на підставі структурної і theta моделей для 12-місячного горизонту прогнозу. Слід зауважити, що ARMA модель з додатковими регресорами має вузчі

межі прогнозних інтервалів за умови відсутності кореляції і нормального розподілу залишків, що обумовлює її більшу надійність.

Таблиця 3.4 – Порівняльний аналіз прогновної точності різних моделей

Model	log data 2000:01-2016:06				log data 2000:01-2016:01			
	Train		test (7 mic.)		Train		test (12 mic.)	
	MAE	MAP E	MAE	MAP E	MAE	MAP E	MAE	MAPE
randomwalk	1.022 3	1.640 2	1.024 8	1.762 8	1.022 1.022	1.628 1.628	1.069 1.069	4.7266 4.7266
ARIMA(0,1,0)	1.021 9	1.626 2	1.025 1	1.771 9	1.021 9	1.624 8	1.069 1.069	4.7266 4.7266
ARMA (3)	1.015 7	1.408 7	1.027 1	1.860 1	1.015 8	1.408 9	1.115 0	12.523 8
ARMA (4)	1.014 7	1.316 7	1.192 7	1.565 1	1.014 9	1.304 8	4.610 3	6.2101
Stl	1.022 1	1.633 8	1.023 6	1.719 4	1.022 1	1.633 8	1.074 4	5.3075
Expsmooth	1.247 8	1.643 1	1.024 9	1.765 6	1.022 1	1.630 6	1.068 6	4.6834
Tbats	1.021 9	1.626 7	1.024 7	1.759 0	1.021 6	1.613 2	1.064 5	4.2845
Theta	1.023	1.665 2	1.028 5	1.909 6	1.022 7	1.650 8	1.060 6	3.9287
Structural	1.694 4	11.82 7	1.029 9	1.971 7	1.684 9	11.67 8	1.054 2	3.4184
Neural	1.004 6	1.105	1.115 7	12.65 5	1.004 4	1.098 8	1.155 6	28.742

Перспективи подальших досліджень. Автори розглядають перспективні методи дослідження для часових рядів з аномальними даними, пов'язані з нелінійними і Байесовськими моделями зміни режимів, які зарекомендували себе як альтернативний спосіб дослідження прихованих закономірностей в даних. Для поліпшення довгострокового прогнозування автори рекомендують подальші дослідження нелінійних методів, в тому числі структурних та інноваційних методів експоненціального згладжування. У багатовимірному моделюванні зусилля мають бути спрямовані на покращення опису і прогнозування екзогенних пояснювальних змінних і включення додаткової інформації з використанням моделей динамічних факторів та індексів дифузії.

Висновок. В роботі реалізовано спосіб поліпшення якості прогнозу для часових рядів короткої вибірки з викидами на базі класичної моделі авторегресії і ковзного середнього шляхом належної ідентифікації викидів та включення відповідних пояснювальних змінних. Було доведено, що методи, основані на ідентифікації викидів, перевершили робастні підходи, які просто зменшують вагу аномальних спостережень, у короткострокових точкових прогнозах і показали більш вузькі інтервали прогнозу. Керуючись результатами порівняльного аналізу моделей, який показав поліпшені довгострокові характеристики прогнозування непараметричних нелінійних підходів, автори рекомендували подальші дослідження в області аналізу часових рядів нестабільних даних короткої вибірки.

3.4 МАГНІТООПТИЧНІ ВЛАСТИВОСТІ ПЛІВКОВИХ МАТЕРІАЛІВ НА ОСНОВІ FE I GE ЯК ЧУТЛИВИХ СЕНСОРНИХ ЕЛЕМЕНТІВ

Плівкові матеріали типу феромагнітний метал(ФМ)/ напівпровідник (НП) широко застосовуються для створення діодних і транзисторних структур, накопичувачів інформації великої ємності, сенсорів магнітного поля та

елементів спінтроніки. Однією з основних задач розвитку спінтроніки є формування нових матеріалів чутливих елементів приладів: магнітних напівпровідників та гібридних наноструктур типу феромагнетик/напівпровідник, перспективи застосування таких обумовлені можливістю використання спінів напівпровідникового шару як детектора, що реагує на зміни магнітного стану в феромагнетику, і унікальними магнітними властивостями.

Тришарові плівкові системи на основі Fe і Ge були отримані методом термічного випаровування на ситалові підкладки (П) у технологічному вакуумі ($p \sim 10^{-4}$ Па) та відпалені в автоматичному режимі в інтервалі температур $\Delta T = 300 - 800$ К протягом 3-4 циклів «нагрів \leftrightarrow охолодження». Вивчення магнітооптичних властивостей проводились методом магнітооптичного ефекту Керра (МОКЕ).

Результати дослідження магнітооптичних властивостей тришарових плівкових систем Fe(10 нм)/Ge(5 – 20 нм)/Fe(10 нм)/П показало, що при збільшенні товщини НП шару від 5 до 20 нм коерцитивність плівкових систем змінюється: від 42 до 15 мТл (невідпалені зразки) та від 70 до 8 мТл (відпалені до 800 К). Зміна величини коерцитивної сили в системах, які пройшли термообробку, пов'язана із формуванням германідів заліза FeGe_x ($1 \leq x < 2$) із феромагнітними властивостями по усьому об'єму зразка. У вищевказаних системах спостерігається залежність кута Керра від індукції магнітного поля у вигляді «ступінчатої» петлі гістерезису, що свідчить про реалізацію двох магнітних станів в них та можливість керування швидкодією чутливого елемента сенсора на основі плівки ФМ/НП в магнітному і температурному полях.

4. ЕЛЕКТРОННІ ТЕХНОЛОГІЇ В ОСВІТІ

4.1 ПІДХОДИ ДО ОЦІНКИ ЕФЕКТИВНОСТІ АДАПТИВНОЇ СИСТЕМИ ДИСТАНЦІЙНОГО НАВЧАННЯ

Виклики часу вимагають постійних інновацій у сфері освіти, зокрема впровадження методів її інтенсифікації та оптимізації. Для цього застосовуються засоби автоматизації керування навчальним процесом, індивідуалізації навчання, побудови адаптивного навчання, які є логічним продовженням тенденції впровадження нових інформаційних технологій навчання в освітній процес. [1] Застосування інформаційних технологій у навчальному процесі разом із перевагами несе й певні ризики, які можуть звести нанівець позитивний ефект від їх впровадження. Ці ризики лежать як у площині програмного забезпечення, яке використовується для організації навчання, так і організаційних проблемах чи навчальному контенті, що використовується для навчання.

При впровадженні інформаційних технологій навчання, зокрема системи дистанційного навчання (СДН), постає питання оцінки ефективності запропонованих рішень в цілому або їх окремих компонентів. Питання оцінки ефективності СДН викликає певні труднощі через слабку формалізованість об'єкта керування, складність систем, гетерогенність факторів, впливають на ефективність засобу, різномірність параметрів оптимізації у різних системах. У статті розглядаються підходи до оцінки показників ефективності функціонування СДН, зокрема адаптивних.

СИСТЕМА ДИСТАНЦІЙНОГО НАВЧАННЯ ЯК СКЛАДОВА ТЕЛЕКОМУНІКАЦІЙНОЇ МЕРЕЖІ

У статті під СДН розуміється мережево-центричний апаратно-програмний комплекс надання навчального контенту в електронній формі. Зауважимо, що СДН можуть використовуватись не лише для підтримки дистанційного навчання, але і студентами всіх форм навчання як основний засіб, додаткове

джерело інформації чи засіб організації самостійної роботи. В англomовній літературі близьким до СДН є термін «e-learning system». На думку В.Н. Khan [2] e-learning можна розглядати як інноваційний підхід для надання користувачу спеціально-організованої, сфокусованої на учня інтерактивної інформації. Обидва визначення розкривають мету СДН, насамперед, як засобу транспортування навчального контенту. Інтелектуальна складова при цьому може бути незначною або відсутньою. Саме тому, на думку деяких дослідників [3,4], такі системи слід оцінювати з точки зору виконання транспортних функцій - застосовуючи показники якості, притаманні телекомунікаційним мережам.

На думку Г.Г. Маклакової, для виконання функцій дистанційного навчання розподілена система повинна не лише надавати користувачу певні сервіси, але й забезпечувати їх якість – «Якість обслуговування» (Quality of Service, QoS). [3] Запропоновані науковцем засоби реалізовані у вигляді інтелектуальної системи, яка використовує апарат нечіткої логіки для прийняття рішень щодо якості телекомунікаційних послуг дистанційного навчання на основі таких параметрів, як смуга пропускання, затримка та втрата пакетів.

Незважаючи на важливість технічних характеристик мережевої складової СДН, на нашу думку, вказаний підхід не враховує призначення СДН, як засобу передачі саме навчального контенту, дозволяючи лише контролювати можливість застосування окремих технічних засобів, таких як передача потокового відео чи аудіо. Різні за можливостями та параметрами програмне забезпечення СДН за цими параметрами буде мати близькі показники.

Подібну аргументацію можна навести і для аналізу ефективності СДН з позиції використання матеріальних-технічних ресурсів. Ці показники є сталими (або сталими з розрахунку на одного студента) і можуть бути визначені на етапі вибору чи розроблення відповідного рішення.

ОПИТУВАННЯ, ЯК ЗАСІБ ОЦІНКИ ЕФЕКТИВНОСТІ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ

У склад СДН входить спеціальне програмне забезпечення навчального призначення, тому функціональну ефективність СДН можна розглядати з позиції якості програмного забезпечення. На думку О.О. Кривошеєва [5] ефективність комп'ютерної навчальної програми залежить як від методичного забезпечення, так і якості інтерфейсу, документації, зручності у використанні, якості контролю та оцінки результатів роботи із програмою. На нашу думку ефективність СДН залежить від того, наскільки вона задовольняє потреби усіх груп її користувачів. Серед основних груп користувачів слід виділити розробників контенту (авторів та програмістів), споживачів контенту (викладачів та студентів) та адміністративний персонал (адміністратори, методисти, співробітники деканату).

На різних етапах впровадження СДН можуть застосовуватись різні засоби для оцінки ефективності СДН, як специфічного програмного забезпечення. Так на етапі вибору СДН можна оцінити її можливості (а значить і придатність до задоволення потреб основних груп користувачів) завдяки порівнянню функціональних можливостей окремих систем. Показовими з цієї точки зору є методичні матеріали [6], в яких представлено 383 критерії для вибору СДН. При проведенні пілотного застосування вдалим може бути застосування А/Б (спліт) тестування, сутність якого полягає в порівнянні показників контрольної та тестових груп, яким були надані продукти, що відрізняються у незначній мірі. Після пілотного застосування ефективність СДН чи її окремих модулів можна оцінити завдяки опитуванню ключових груп користувачів за допомогою опитувальників. Такий підхід широко використовується в МООС EdX [7] для оцінки якості навчального процесу. Впродовж вивчення курсу користувачам декілька разів пропонується заповнити анкету. Питання анкети стосуються як навчального курсу, так і самого програмного засобу. Питання сформульовані в закритій формі з можливістю дати альтернативну відповідь у відкритій формі.

Альтернативним підходом до тестування якості програмного забезпечення є надання користувачу можливості легкого переходу між новим і старим програмним забезпеченням. Так модуль адаптивного формування навчальної траєкторії за результатами тестового контролю знань в СДН Сумського державного університету (СДН СумДУ) реалізує свій інтерфейс у вигляді спеціального блоку із переліком необхідних посилань (див. рис 4.1.)

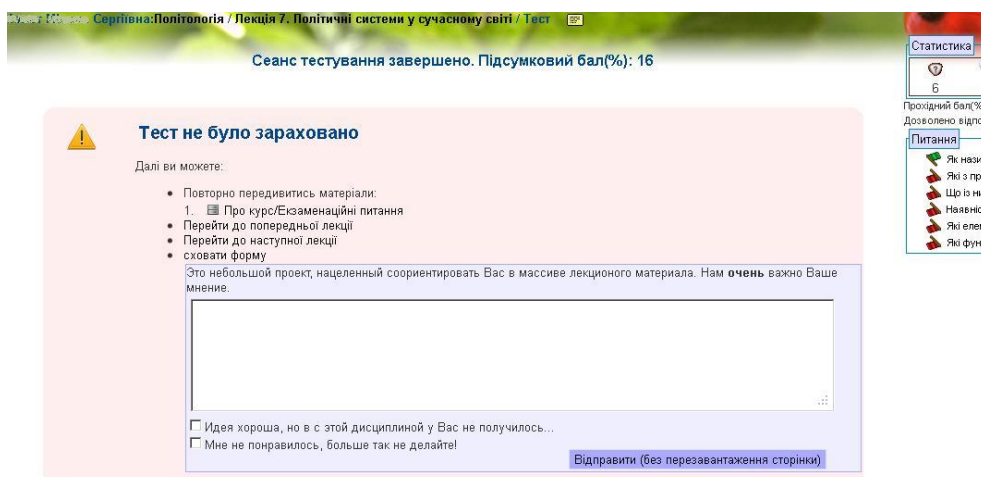


Рисунок 4.1 – Інтерфейс блоку адаптивної підтримки користувача

Для аналізу ефективності вказаного блоку, до переліку корисних посилань була додана можливість відмовитись від застосування адаптивної підказки як для конкретного курсу, так і усіх курсів, а також залишити коментар. Впродовж експерименту вказані опції були використані у 12 випадках (або 0,75% від загальної) кількості. При цьому у 7 випадках (0,43%) відбулась відмова від засобу в цілому, 5 (0,32%) відмова від застосування засобу для окремого курсу. Користувачами залишено 47 повідомлень, більшість (85%) з яких були зверненнями користувача до викладача з метою уточнення правильної відповіді на окремі тестові питання. 5 (9%) відповідей стосувалися роботи системи адаптивної підтримки, з них 3 (6%) висловлювали задоволення. Опитування наприкінці експерименту показало високий рівень схвалення засобу. [8]

ОЦІНКА ЕФЕКТИВНОСТІ АДАПТИВНОЇ СИСТЕМИ ДИСТАНЦІОНОГО НАВЧАННЯ

Критерії оцінки ефективності СДН

Особливої актуальності оцінка ефективності СДН набуває із впровадженням засобів адаптивного керування навчанням. При оцінці ефективності адаптивної СДН варто покладатися на показники, за якими проводиться адаптація навчального процесу, враховуючи параметри, обмеження і, насамперед, цілі цього процесу. Мета навчання, як один з параметрів моделі користувача, є основою для формування керуючих впливів. Слід враховувати, що користувачі такої системи можуть мати власну мету навчання.

Для студентів ефект від застосування адаптивних навчальних систем може полягати у наступному:

- більш міцному засвоєнню знань;
- збільшенню обсягів знань, що сприймаються студентом;
- зменшенню часу на засвоєння навчального матеріалу;
- збільшенню усвідомленості навчального матеріалу за рахунок створення інтегрованих навчальних курсів.

Саме ці показники, в залежності від мети користувача і параметрів оптимізації мають бути оцінені, бо є прямими показниками ефективності запропонованих рішень. В окремих випадках оцінці можуть підлягати якість сформованого навчального контенту, точність оцінки знань студента, інтегрованість навчального плану, тощо. Ці критерії є вузькоспецефічними і є оцінками роботи окремих підсистем, а не СДН загалом.

Розглянемо детальніше відомі підходи й критерії такої оцінки ефективності адаптивних СДН.

Оцінка прямих показників якості знань

Практика оцінювання якості СДН через показники якості отриманих студентом знань є досить поширеною. При цьому важливо відділити СДН, як

засіб організації та транспортування навчального контенту від самого контенту, що ускладнює проведення експерименту. Серед переваг підходу є можливість оцінки систем, різних за своїми технічними можливостями (різних програмних продуктів, старої і нової версії одного продукту). Прикладом ґрунтовного опису експериментів із порівнянням систем із використанням такого підходу є роботи [9,10]. П.І. Федорук пропонує оцінювати математичне очікування та дисперсію показників успішності контрольної та експериментальної групи за умови рівності показників їх успішності до початку експерименту. Аналіз публікацій дозволяє виділити наступні важливі моменти:

- Навчальний контент продуктів (форма подачі, формат основних документів, їх оформлення, обсяг), що беруть участь у порівнянні, має бути однаковим.
- Контрольна та експериментальні групи мають бути подібними та мати однаковий розподіл респондентів до початку експерименту за параметром, за яким виконується порівняння.
- Кількість респондентів повинна забезпечувати умови статистичної достовірності результатів.
- Оцінка параметру, який визначає ефективність у контрольній та експериментальній групах, повинна проходити за однакових умов (однією системою чи експертом тощо).

Пряма оцінка якості знань описує лише кінцевий результат та не дає змоги оцінити якість СДН у процесі використання. Для розв'язання цього протиріччя застосовуються інші показники. Так П.І. Федорук у свої подальших роботах [11] використовує додаткові критерії: швидкість сприйняття та швидкість засвоєння нової інформації.

Використання інтегральних показників

Недоліком прямої оцінки якості знань, як оцінки ефективності СДН є неможливість урахування додаткових параметрів оптимізації та специфічних обмежень системи. Для розв'язання цього недоліку науковці пропонують

використовувати інтегральні показники. Так С.О. Бояшова пропонує [12] показники: критерій оцінки ефективності процесів викладання (витрати часу на навчання, кількість і характер помилок, цілісність розуміння понять), швидкість засвоєння змісту навчальної програми (є функціоналом від змісту навчальної програми). Окрім вказаних, для інтегральної оцінки узагальнених характеристик системи пропонується сумарний показник опанування учнем навчальної програми:

$$\kappa_1 = \int_{t_0}^T \left(\frac{dK_1}{dt} + \frac{dK_2}{dt} + \frac{dK_3}{dt} \right) \quad (1)$$

де K_1, K_2, K_3 – частка обсягу знань, правил та дії засвоєних учнем за фіксований проміжок часу від їх загальної кількості, наданих учню за цей проміжок часу. Таким чином формула є лише розширеною оцінкою досягнень учня без урахування важливості окремих елементів навчальної діяльності. Серед недоліків міри (1) також можна вказати неможливість урахування міжпредметних зв'язків, на важливості яких для оптимізації керуючих впливів наголошує наступний дослідник.

Т.Л. Мазурок у своїй роботі [13] пропонує використовувати інтегральний показник ефективності:

$$\mathcal{E}\phi_{ACVO} = k_{ACVO} \cdot k_{им} \cdot k_{c^*} \cdot k_{T^*}, \quad (2)$$

множниками якого є k_{ACVO} – коефіцієнт використання СДН (частка часу, який студенти та викладачі використовували СДН у порівнянні із загальною тривалістю навчального процесу), $k_{им}$ – коефіцієнт інтегрованості змісту навчання (частка пов'язаних навчальних елементів, що належать до різних навчальних дисциплін в загальній кількості навчальних елементів), k_{c^*} – коефіцієнт досягнення мети (частка векторів результатів навчання, що

відповідають умовам достатньої успішності навчання), k_{t^*} – коефіцієнт використання часу навчання (частка навчальних елементів, які були вивчені в межах планових показників часу, серед усіх елементів). Зауважимо, що специфіка застосування СДН для дистанційної форми навчання не дозволяє оцінити всі з указаних показників (наприклад, $k_{асво}$).

Іншим недоліком показників (1) та (2) є неможливість урахування важливості окремих завдань. Найпростішим способом оцінки важливості окремих елементів є обсяг часу виділений на їх вивчення, кількість балів, кількість та параметри зв'язків із іншими елементами. Також міри (1) та (2) відхилення терміну виконання завдань від планових показників.

СДН як засіб організації навчальної діяльності

Розглянуті критерії підкреслюють, що підсумкова оцінка за дисципліну не може слугувати критерієм ефективності СДН. На нашу думку головним завданням СДН є організація процесу оволодіння знаннями. Актуальність такого підходу зростає із широким впровадженням відкритих навчальних ресурсів у освітній процес, що збільшує обсяг навчального матеріалу завдяки розширенню форм його представлення, подання альтернативного матеріалу. [14] Тому, головним ефектом застосування адаптивної СДН вважатимемо зменшення відхилення часу виконання навчальних завдань від планових показників. Для оцінки ефективності за цим параметром скористаємося модифікованими коефіцієнтами досягнення мети та коефіцієнтом використання часу навчання зі співвідношення (2). При оцінці будемо враховувати не тільки кількісні показники, але і якісні (складність, тип, відставання від графіку вивчення) за робочою формулою:

$$k_{plan} = \frac{1}{|C|} \sum_{c \in C} \frac{\sum_{q \in Q_c} \max \left(\max_{q_i \in q} (p_{q_i} - \max(t_{q_i} - t_q^*, 0)) \cdot f_c, 0 \right)}{\sum_{q \in Q_c} p_q^*} \quad (3)$$

де S – множина навчальних курсів, Q_c – множина навчальних завдань дисципліни c , t_q^* та p_q^* – плановий час виконання та максимальний бал для завдання q , t_{q_i} та p_{q_i} – час та отриманий бал за i -у спробу виконання

завдання q , $f_c = \frac{\sum_{q \in Q_c} p_q^*}{\max(t_q^*) - \min(t_q^*)}$ – штрафний коефіцієнт за затримку на один день

при виконанні завдання в дисципліні c .

Показник k_{plan} може використовуватись як непряма оцінка знань студентів. Аналіз результатів діяльності користувачів за 2007-2012 рік у СДН СумДУ показав значиму позитивну кореляцію між результатами навчання (експертна оцінка) та показником k_{plan} . ($r=0,241$, $n=501$, $r_{0.001}=0,147$)

Коефіцієнт використання часу навчання був застосований для оцінки ефективності модуля адаптивної навігації у СДН СумДУ. [14] У ході експерименту була сформована експериментальна та контрольна групи (загальна кількість 78 осіб). При формуванні груп використана сегрегація за унікальним ідентифікатором студента із бази даних. До початку експерименту між сформованими групами не виявлено значущих розбіжностей за показниками середніми значеннями успішності навчання та k_{plan} (за критерієм Стьюдента $t_{kplan}=1.82$, $t=1,47$, $t_{0.01}=2,63$). У ході експерименту система аналізу (СППР та оновлення моделі знань студента) була ввімкнена для обох груп користувачів, але надавала інформацію лише для користувачів із експериментальної групи. Такий підхід дозволив винести за рамки експерименту навчальний контент та особливості базового програмного забезпечення, які для обох груп були однаковими. Після впровадження модуля адаптивного керування середні значення критерію k_{plan} у контрольній групі становить 0.27, у експериментальній 0.35, що на 31% вище. Статистичний аналіз підтвердив значущість різниці середніх значень критерію у контрольній та експериментальній групі, наявність значущих змін у показниках експериментальної групи та відсутність значущих змін у показниках контрольної групи при рівні значущості 0,95.(див. рис. 4.2).




Рисунок 4.2 – Діаграма значень k_{plan} в контрольній та експериментальній групах

ІНШІ ПІДХОДИ ДО ОЦІНКИ ЕФЕКТИВНОСТІ СДН

Варто зауважити, що процес навчання за допомогою СДН передбачає не тільки передачу навчальних впливів (викладач \rightarrow)СДН \rightarrow учень, а й соціальну взаємодію учасників навчального процесу, яка може виявлятися у колективному виконанні завдань, спілкуванні із викладачем, практиці навчання у малих групах та парного навчання [15] тощо. Варто наголосити на важливості подібної взаємодії для майбутнього спеціаліста. Класичними засобами організації подібної взаємодії є колективне редагування ресурсу (вікі), форуми, чати. Ефект від подібних заходів може полягати у підвищенні вмотивованості учня, що відобразиться в тривалості чи частоті використання СДН, для яких можна отримати формальні значення.

Основними завданнями на шляху оцінки впливу засобів організації взаємодії учасників навчального процесу на загальну ефективність СДН є локальність впливу в часі та епізодичний характер їх застосування. Безумовно, розробка підходів до оцінки впливу засобів організації та інтенсифікації взаємодії учасників навчального процесу на загальну ефективність СДН є доцільною і вимагає подальших досліджень.

ВИСНОВКИ

Стаття аналізує різні підходи до оцінки ефективності СДН, зокрема адаптивних СДН. Розглянуто підходи, які використовують підходи до оцінки телекомунікаційних мереж, якості програмного забезпечення, пряму оцінку якості знань, інтегральні показники якості. Розглянувши переваги й недоліки вказаних підходів пропонується оцінювати ефективність адаптивної СДН як засобу організації навчальної діяльності. Для вимірювання за цим критерієм пропонується модифікований коефіцієнт використання навчального часу. Показник дозволяє оцінити відхилення поточного стану виконання навчальних завдань від планового із урахуванням календарного плану та важкості завдань.

Отримані результати підтверджують наявність значущої позитивної кореляції між показником та експертною оцінкою якості знань та можливість застосування для оцінки ефективності адаптивних СДН.

4.2 ІНФОРМАЦІЙНИЙ СИНТЕЗ ІНФОРМАЦІЙНО-АНАЛІТИЧНОЇ СИСТЕМИ ОЦІНКИ ЯКОСТІ НАВЧАЛЬНОГО КОНТЕНТУ

Якість навчального процесу визначається користю, яку отримують випускники університету та їх роботодавці [1]. Тому розробка інформаційно-аналітичної системи для встановлення постійного зворотного зв'язку між роботодавцями та навчальним закладом, який дозволяє виявити ефективні форми навчання, корегувати навчальні програми та позбутися неінформативного та застарілого навчального контенту, є актуальною науково-технічною задачею. Для переважної більшості навчальних закладів основним методом адаптації навчального контенту випускових кафедр до вимог ринку праці все ще залишається анкетування, аналіз результатів якого потребує значних матеріально-часових витрат. Тому важливою функцією інформаційно-аналітичної системи є автоматизація оброблення результатів опитування респондентів на основі інтелектуального аналізу даних [2, 3].

При цьому одним із напрямків підвищення функціональної ефективності комп'ютерних систем контролю якості навчального контенту є їх інформаційний синтез на основі машинного навчання та розпізнавання образів. Проте науково-методологічні питання створення таких систем все ще залишаються недостатньо дослідженими через багатofакторність і довільні початкові умови процесу оцінювання та вплив неконтрольованих факторів на організацію і керування навчальним процесом.

Одним із перспективних шляхів подолання вказаних вище ускладнень науково-методологічного характеру є застосування ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології), що ґрунтується на максимізації інформаційної спроможності системи в процесі її машинного навчання [4, 5]. В праці [6] розроблено інформаційно-екстремальний алгоритм машинного навчання інформаційно-аналітичної системи оцінки якості навчального контенту для полімодальної структури гіперсферичних контейнерів класів розпізнавання, яка передбачає наявність декількох центрів розсіювання векторів-реалізацій образів. Але у випадках прийняття рішень за оціночними шкалами алфавіт класів розпізнавання, які характеризують відповідні рівні якості, є впорядкованим. Це дозволяє для побудови вирішальних правил застосовувати так звану ієрархічну структуру контейнерів класів розпізнавання, які відновлюються в процесі машинного навчання в радіальному базисі простору ознак.

В статті розглядається метод інформаційно-екстремального навчання інформаційно-аналітичної системи адаптації навчального контенту випускової кафедри до вимог ринку праці з оптимізацією (тут і далі в інформаційному розумінні) геометричних параметрів гіперсферичних контейнерів класів розпізнавання з ієрархічною структурою.

1 Формалізована постановка задачі

При розробленні в рамках геометричного підходу структури вирішальних правил, побудова яких є головною задачею інформаційно-екстремального машинного навчання, приймемо гіпотезу про наявність базового класу X_1^0 ,

який характеризує найбільш бажаний для студентів і респондентів-роботодавців рівень якості навчального контенту. Інші класи розпізнавання, які характеризують відповідні нижчі рівні якості контенту слід розглядати як відхилення від базового класу. Оскільки респонденти оцінюють якість навчального контенту за кількісною оціночною шкалою, то алфавіт класів розпізнавання є впорядкованим. У цьому випадку як експериментально доведено в праці [5] доцільно застосовувати вкладену структуру контейнерів класів розпізнавання, які мають єдиний центр розсіювання. реалізацій образів. Наприклад, перший контейнер будується для базового класу x_1^0 , який характеризує якість навчального контенту з оцінкою “відмінно” і є вкладеним у контейнер класу x_2^0 , який характеризує рівень якості з оцінкою “добре”. Таким чином будується ієрархічна структура контейнерів для всіх упорядкованих класів розпізнавання.

Застосування унімодального класифікатора із вкладеними контейнерами класів розпізнавання суттєво зменшує обчислювальну трудомісткість алгоритму машинного навчання у порівнянні з полімодальним класифікатором, в якому згідно з принципом компактності кожний клас розпізнавання має свій центр розсіювання реалізацій. Наприклад, при вкладених гіперсферичних контейнерах в процесі навчання відпадає необхідність обчислення усереднених векторів-реалізацій класів розпізнавання, вершини яких визначають їх геометричні центри. При цьому специфіка навчання класифікатора з вкладеними контейнерами полягає у відсутності процедури визначення для кожного класу найближчого сусіда, оскільки класи розпізнавання апріорно є впорядкованими, що суттєво підвищує оперативність навчання. Крім того, не потрібно визначати зовнішній радіус найбільш віддаленого від центру розсіювання класу розпізнавання.

Розглянемо інформаційно-аналітичну систему оцінки якості навчального контенту, ядром якої є здатна навчатися система підтримки прийняття рішень (СППР) із вкладеною структурою контейнерів класів розпізнавання.

Нехай дано структурований алфавіт $\{X_m^o \mid m = \overline{1, M}\}$ класів розпізнавання, які характеризують рівні якості навчального контенту. За результатами опитування роботодавців та їх провідних фахівців сформовано вхідну багатовимірну (векторну) навчальну матрицю типу «об'єкт-властивість»

$$\{y_{m,i}^j, \mid i = \overline{1, N}, j = \overline{1, n}\},$$

де N – кількість ознак розпізнавання, які відповідають експертним оцінкам рівня якості змістовних модулів навчального контенту за кількісною шкалою, n – кількість векторів-реалізацій кожного класу.

Задано структурований вектор параметрів функціонування СППР

$$g = \langle x_1, d_m, \delta_i \rangle, \quad m = \overline{1, M}; i = \overline{1, N}, \quad (1)$$

де x_1 – статистично усереднений двійковий вектор-реалізація базового класу X_1^o , який визначає геометричний центр вкладених гіперсферичних контейнерів класів розпізнавання, що відновлюється в радіальному базисі простору ознак розпізнавання; d_m – зовнішній радіус контейнера класу X_m^o ; δ_i – параметр, який дорівнює половині симетричного поля контрольних допусків на i -ту ознаку розпізнавання.

Крім того, задано обмеження на радіуси контейнерів класів розпізнавання:

$$d_1 > 0; \quad d_{m-1} < d_m < d_{m+1},$$

i на параметр поля контрольних допусків на i -ту ознаку розпізнавання

$$\delta_i \in [0; \delta_{H,i} / 2],$$

де $\delta_{H,i}$ – нормоване поле допусків на i -ту ознаку розпізнавання, яке визначає область значень параметра δ_i .

В процесі інформаційно-екстремального навчання відновлення контейнерів класів розпізнавання відбувається в радіальному базисі дискретного простору ознак розпізнавання. При цьому зовнішній радіус, наприклад, контейнера класу X_m^o в бінарному просторі Хеммінга виміряється кодовою відстанню

$$d_m = d(x_1 \oplus \lambda_m) = \sum_{i=1}^N x_{1,i} \oplus \lambda_{m,i},$$

де λ_m – реалізація класу X_m^o , вершина якої знаходиться на роздільній гіперсфері з класом X_{m+1}^o ; $x_{1,i}$, $\lambda_{m,i}$ – i -та ознака розпізнавання в реалізаціях x_1 і λ_m відповідно; \oplus – символ операції складання за модулем два.

Необхідно в процесі навчання СППР визначити оптимальні значення координат вектора (1), які забезпечують максимум інформаційного критерію функціональної ефективності (КФЕ) навчання СППР розпізнавати реалізації класу X_m^o , пошук якого здійснюється в робочій (допустимій) області визначення його функції

На етапі екзамену, тобто при функціонуванні СППР безпосередньо в режимі моніторингу, необхідно прийняти рішення про належність сформованої респондентом реалізації до одного з класів алфавіту $\{X_m^o\}$ і у разі необхідності видати рекомендації щодо його корекції.

2 Інформаційно-екстремальний синтез здатної навчатися СППР

Інформаційно-екстремальний синтез здатної навчатися СППР складається із двох етапів:

- 1) машинного навчання, на якому шляхом оптимізації за інформаційним критерієм будуються вирішальні правила;
- 2) машинного екзамену, тобто функціонування системи безпосередньо в робочому режимі прийняття класифікаційних рішень про належність реалізації, що розпізнається, до одного із класів заданого алфавіту.

Інформаційно-екстремальне машинне навчання полягає в реалізації ітераційної процедури пошуку глобального максимуму інформаційного КФЕ в робочій області визначення його функції. Для алгоритму навчання з оптимізацією системи контрольних допусків на ознаки розпізнавання така двохциклічна процедура має вигляд

$$\delta^* = \arg \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \}, \quad (2)$$

де $\bar{E}^{(k)}$ – значення обчисленого на k -му кроці навчання усередненого за алфавітом класів розпізнавання КФЕ; G_δ – область допустимих значень параметра поля контрольних допусків на ознаки розпізнавання; $\{k\}$ – множина кроків навчання.

У процедурі (2) основними задачами внутрішнього циклу є обчислення інформаційного КФЕ, пошук його глобального максимуму та визначення екстремального значення зовнішнього радіуса гіперсферичного контейнера, яке приймається за оптимальне.

Розглянемо алгоритм паралельної оптимізації контрольних допусків на ознаки розпізнавання, за яким параметр поля контрольних допусків змінюється одночасно для всіх ознак. Така схема алгоритму (2) є доцільною у випадку, коли ознаки розпізнавання мають єдину шкалу вимірювань. Тоді нижній $A_{НК,i}$ і верхній $A_{ВК,i}$ контрольні допуски на i -ту ознаку розпізнавання обчислюються відповідно за формулами

$$A_{НК,i} = y_i - \delta ; A_{ВК,i} = y_i + \delta , \quad (3)$$

де y_i – усереднене значення i -ої ознаки розпізнавання в реалізаціях базового класу X_1^0 .

Вхідними даними є тривимірний масив навчальної матриці $\{y_{m,i}^j\}$ та поле δ_H нормованих допусків, яке для всіх ознак розпізнавання є однаковим і визначає область значень системи контрольних допусків.

Розглянемо схему алгоритму оптимізації системи контрольних допусків (СКД) на ознаки розпізнавання в процесі інформаційно-екстремального машинного навчання СППР за процедурою (2):

£

1) онулюється лічильник класів розпізнавання: $m := 0$;

2) $m := m + 1$;

3) онулюється лічильник кроків зміни параметра δ поля контрольних допусків на ознаки розпізнавання: $k := 0$;

4) $k := k + 1$

5) шляхом статистичного усереднення реалізацій вхідної навчальної матриці $\{y_{1,i}^j\}$ базового класу X_1^o визначається вектор y_1 , відносно координат якого на кожному кроці навчання задаються нижні та верхні контрольні допуски на ознаки розпізнавання;

6) за формулами (3) обчислюються нижній $A_{НК,i}[k]$ і верхній $A_{НК,i}[k]$ контрольні допуски для всіх ознак розпізнавання;

7) формується тривимірний масив бінарної навчальної матриці $\{x_{m,i}^j\}$, елементи якої обчислюються за правилом

$$x_{m,i}^j[k] = \begin{cases} 1, & \text{якщо } A_{НК,i}[k] < y_{m,i}^j < A_{ВК,i}[k]; \\ 0, & \text{якщо інакше.} \end{cases}$$

8) шляхом статистичного усереднення реалізацій бінарної навчальної матриці $\{x_{1,i}^j\}$ базового класу X_1^o визначається вектор x_1 , вершина якого визначає центр розсіювання реалізацій всіх класів розпізнавання;

9) формується контейнер класу розпізнавання X_m^o з радіусом $d[m] := k$;

10) за навчальними матрицями класу X_m^o і суміжного класу X_{m+1}^o обчислюється інформаційний КФЕ $E_{[m,k]}$;

11) якщо виконується умова $E_{[m,k]} \in G_E$, де G_E – робоча області визначення функції інформаційного критерію, то виконується пункт 12, інакше – пункт 4;

12) якщо виконується умова

$$d[m] < N,$$

де x_{m+1}^{\max} – максимально віддалена від центру розсіювання реалізація класу X_{m+1}^o , то реалізується пункт 3, інакше – пункт 12;

13) визначається глобальний максимум $E^*[m]$ інформаційного критерію в робочій області визначення його функції, де перша і друга достовірності більше 0,5;

14) якщо виконується умова

$$m < M-1,$$

то реалізується пункт 2, інакше – пункт 16;

15) на кожному кроці навчання в робочій області обчислюється усереднене значення інформаційного КФЕ за формулою

$$\bar{E}^{(k)} = \frac{1}{M-1} \sum_{m=1}^{M-1} E[m, k]$$

16) в робочій області визначається максимальне значення усередненого критерію $\bar{E}^{(k)}$:

$$\bar{E}^* = \max_{G_E \cap \{k\}} \bar{E}^{(k)},$$

де G_E – допустима область визначення функції інформаційного критерію.

17) визначається екстремальне значення k^* , при якому критерій $\bar{E}^{(k)}$ приймає максимальне значення:

$$k^* = \arg \max_{G_E \cap \{k\}} \bar{E}^{(k)}$$

18) визначається оптимальне значення параметра $\delta^* := k^*$;

19) визначаються радіуси оптимальних контейнерів класів розпізнавання:

$$d_m^* = \arg \max_{G_E \cap \{k\}} E[m, k];$$

20) будуються вирішальні правила у вигляді продукцій

if $d[x_1 \oplus x^{(j)}] \leq d_1^*$ then $x^{(j)} \in X_1^o$;
 $(\forall m < M) \{ \text{if } d_m^* \leq d[x_1 \oplus x^{(j)}] \leq d_{m+1}^* \text{ then } x^{(j)} \in X_m^o \}$; Де $x^{(j)}$ – реалізація образу, що
 if $d[x_1 \oplus x^{(j)}] > d_{M-1}^*$ then $x^{(j)} \in X_M^o$, (4)

розпізнається.

21) ЗУПИН.

Побудовані в процесі навчання вирішальні правила (4) характеризуються мінімальною обчислювальною трудомісткістю, що є перевагою геометричного підходу, і дозволяють приймати класифікаційні рішення в реальному темпі часу.

Як КФЕ інформаційно-екстремального навчання СППР може використовуватися будь-яка інформаційна міра [5, 6]. Розглянемо модифіковану інформаційну міру Кульбака у вигляді добутку логарифмічного відношення повної ймовірності правильного прийняття рішень P_i до повної

ймовірності помилкового прийняття рішень P_f на їх різницю. Для рівноймовірних двохальтернативних гіпотез, що характеризує найбільш складний у статистичному розумінні випадок прийняття рішень, міру Кульбака подамо у вигляді

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

де $D_{1,m}^{(k)}$ – перша достовірність, обчислена на k -му кроці навчання СППР розпізнавати реалізації класу X_m^o ; $D_{2,m}^{(k)}$ – друга достовірність; $\alpha_m^{(k)}$ – помилка першого роду; $\beta_m^{(k)}$ – помилка другого роду.

Нормовану модифікацію критерію (5) подамо у вигляді

$$E_m^{*(k)} = \frac{E_m^{(k)}}{E_{\max}}, \quad (6)$$

де E_{\max} – значення критерію (5) при $D_{1,m}^{(k)} = 1$ і $\beta_m^{(k)} = 0$.

Таким чином, процес інформаційно-екстремального навчання полягає в реалізації процедури пошуку глобального максимуму функції інформаційного критерію в робочій області її визначення і ітераційного наближення цього максимуму до його граничного максимального значення.

Алгоритм екзамену має такі вхідні дані: M – кількість класів, які СППР навчена розпізнавати; $\{d_m^*\}$ – масиви оптимальних радіусів контейнерів; оптимальні нижні $\{A_{HK,i}^*\}$ і верхні $\{A_{BK,i}^*\}$ контрольні допуски на ознаки розпізнавання, визначенні на етапі навчання; $\{x^{(i)}\}$ – масив двійкових векторів-реалізацій образу, що розпізнається.

Розглянемо основні етапи реалізації алгоритму екзамену:

1. Формування лічильника класів розпізнавання: $m := m + 1$;

2. Формування лічильника числа реалізацій, що розпізнаються: $j := j + 1$;
3. Обчислення кодової відстані $d(x_1 \oplus x^{(j)})$;
4. Порівняння: якщо $m \leq M$, то виконується крок 1, інакше – крок 7;
5. Визначення за вирішальними правилами (4) класу X_m^o , до якого належить реалізація образу, що розпізнається.

6. ЗУПИН

Після класифікації сформованих респондентами реалізацій задачею інформаційно-аналітичної системи є аналіз тенденції зміни запитів роботодавців шляхом оцінки частот віднесення

3 Приклад реалізації алгоритму

машинного навчання інформаційно-аналітичної системи

Реалізацію запропонованого алгоритму розглянемо на прикладі інформаційно-екстремального навчання інформаційно-аналітичної системи оцінки якості навчального контенту випускової кафедри комп'ютерних наук Сумського державного університету. Робочі дані системи накопичуються в процесі проведення опитування роботодавців, випускників та студентів навчального закладу, на основі їх оцінок навчальних модулів за шкалою від 0 до 100 балів. Для навчання інформаційно-аналітичної системи сформовано навчальну вибірку з трьох класів. Клас x_1^o відповідав навчальному контенту відмінної якості, в класі x_2^o контент отримав оцінку «Задовільно», а в x_3^o – «Незадовільно». Обсяг навчальної вибірки для кожного класу становить $n = 100$, а потужність словника ознак рівна кількості змістовних модулів дисципліни і становить $N = 50$.

На рис. 4.3 показано графік залежності нормованого критерію Кульбака (5) від параметра поля контрольних допусків δ , одержаний в процесі навчання інформаційно-аналітичної системи за процедурою (3). На графіку штрихована ділянка позначає робочу область визначення функції інформаційного критерію, в якій одночасно виконуються умови: $D_{1,m} > 0,5$, $D_{2,m} > 0,5$, і $d_m > d_{m-1}$.






Рисунок 4.3– Графік залежності КФЕ від параметра поля контрольних допусків

Аналіз рис.4.3 показує, що оптимальний параметр поля контрольних допусків дорівнює $\delta^* = \pm 67\%$ при максимальному значенні усередненого критерію $\bar{E}^* = 0,175$. Таким чином, отримані в процесі навчання вирішальні правила не є безпомилковими за навчальною матрицею.

Оскільки метою інформаційно-екстремального навчання є відновлення в просторі ознак оптимальних контейнерів класів розпізнавання, то на рис.4.4. наведено графіки залежності нормованого КФЕ (5) від радіусів контейнерів класів x_1^0 та x_2^0 .



а



б

Рисунок 4.4– Графіки зміни нормованого КФЕ при оптимізації радіусів контейнерів класів: а – клас x_1^0 ; б – клас x_2^0

Аналіз рис.4.4. показує, що оптимальні значення радіусів гіперсферичних контейнерів класів x_1^o , x_2^o відповідно рівні: $d_1 = 21, d_2 = 38$ (в кодових одиницях). При цьому радіус класу x_3^o рівний розмірності бінарного простору, тобто $d_3 = N$.

Таким чином, вище наведений алгоритм навчання системи дозволяє отримати квазіоптимальні параметри функціонування інформаційно-аналітичної системи, які знаходяться в робочій області визначення функції інформаційного критерію (4), проте не забезпечує досягнення граничного максимуму критерію (1). З метою побудови безпомилкових за навчальною матрицею вирішальних правил слід виконати уточнення СКД за послідовним алгоритмом, а також згідно з принципом відкладених рішень А.Г. Івахненка реалізувати алгоритми оптимізації додаткових параметрів функціонування інформаційно-аналітичної системи.

Висновки

1. У рамках ІЕІ-технології розроблено інформаційне, алгоритмічне та програмне забезпечення інформаційно-аналітичної системи оцінки якості навчального контенту за трьохальтернативною системою оцінок: «Відмінно», «Задовільно» і «Незадовільно» на базі інформаційно-екстремального класифікатора з вкладеними контейнерами. Розроблена інформаційно-аналітична система дозволяє автоматизувати інформування осіб, відповідальних за супроводження навчальних матеріалів, про необхідність оновлення, стиснення, ліквідації чи реорганізації відповідного контенту.

2. Вирішальні правила, отримані в процесі навчання, не є безпомилковим за навчальною матрицею і для підвищення функціональної ефективності інформаційно-аналітичної системи потрібна оптимізація додаткових просторово-часових параметрів функціонування.

4.3 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНЕ НАВЧАННЯ СИСТЕМИ ОЦІНКИ ЯКОСТІ НАВЧАЛЬНОГО КОНТЕНТУ ВИПУСКОВОЇ КАФЕДРИ

Суттєвим фактором, що впливає на якість освіти, є зміст та наповнення контенту як окремих навчальних модулів, так і дисциплін професійно-технічного циклу в цілому. Тому існуючі європейські рамкові освітні стандарти, спрямовані на вирішення проблеми оцінки якості освіти, суттєву увагу приділяють відповідності навчального контенту до вимог ринку праці. Аналіз сучасних інформаційних систем оцінки якості навчального контенту показав, що в більшості випадків вони аналізують в основному кількісні показники, які непрямо впливають на якість навчального контенту. В праці [1] наведено приклади створення експертних систем на основі нечіткої логіки, експертно-статистичних алгоритмів і методах інтелектуального аналізу даних [2]. Основні недоліки існуючих інформаційно-аналітичних систем оцінки якості освіти полягають в тому, що вони не забезпечують в режимі моніторингу зворотний зв'язок між випусковою кафедрою, роботодавцями та студентами, є негнучкими і головне не здатні автоматично формувати базу знань. Тому на практиці аналіз якості навчального процесу вимагає використання значних часових і викладацьких ресурсів і не гарантує об'єктивності оціночних рішень. Основним шляхом подолання цих основних недоліків є перехід від експертних систем оцінки якості навчального процесу до систем підтримки прийняття рішень (СППР), здатних аналізувати і видавати рекомендації відповідним користувачам. У зв'язку з цим актуальною науково-технічною задачею є надання інформаційно-аналітичній системі оцінки якості навчального контенту випускової кафедри властивості адаптивності на основі машинного навчання та розпізнавання образів [2]. Але існуючі методи інтелектуального аналізу даних характеризуються невисокою достовірністю прийняття класифікаційних рішень за умови суттєвого перетину класів розпізнавання.

Одним із перспективних шляхів вирішення цієї задачі є застосування ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи в процесі її машинного навчання [3, 4].

В статті розглядається інформаційно-екстремальний алгоритм навчання інформаційно-аналітичної системи адаптації навчального контенту випускової кафедри до вимог ринку праці.

Постановка задачі

Розглянемо формалізовану постановку задачі інформаційно-екстремального синтезу СППР як основної складової інформаційно-аналітичної системи адаптації навчального контенту випускової кафедри до вимог ринку праці.

Нехай дано алфавіт класів розпізнавання $\{X_m^o \mid m = \overline{1, M}\}$, де M — кількість класів, які характеризують якість навчального контенту, і навчальну матрицю, яка містить сформовані респондентами оцінки змістовних модулів навчальних дисциплін за стобальною шкалою, $\|y_{mi}^{(j)}\|, i = \overline{1, N}, j = \overline{1, n}$, де N — кількість змістовних модулів; n — кількість структурованих векторів-реалізацій (далі просто реалізації) образів, які формуються за результатами оцінок респондентів. Крім того, відомий вектор параметрів навчання системи, які прямо впливають на її функціональну ефективність,

$$g = \langle g_1, \dots, g_\xi, \dots, g_\Xi \rangle. \quad (1)$$

При цьому відомі обмеження на відповідні параметри функціонування:

$$R_\xi(g_1, \dots, g_\xi, \dots, g_\Xi) \leq 0.$$

Необхідно на етапі навчання у рамках ІЕІ-технології побудувати в радіальному базисі бінарного простору ознак оптимальне (тут і далі в

інформаційному розумінні) розбиття класів розпізнавання, яке відповідає умовам:

$$\begin{aligned} & (\forall X_m^o \in \tilde{\mathfrak{R}}^{[M]}) [X_m^o \neq \emptyset]; \\ & (\exists X_k^o \in \tilde{\mathfrak{R}}^{[M]}) (\exists X_l^o \in \tilde{\mathfrak{R}}^{[M]}) [X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset]; \\ & (\forall X_k^o \in \tilde{\mathfrak{R}}^{[M]}) (\forall X_l^o \in \tilde{\mathfrak{R}}^{[M]}) [X_k^o \neq X_l^o \rightarrow \text{Ker}X_k^o \cap \text{Ker}X_l^o = \emptyset]; \\ & (\forall X_k^o \in \tilde{\mathfrak{R}}^{[M]}) (\forall X_l^o \in \tilde{\mathfrak{R}}^{[M]}) [X_k^o \neq X_l^o \rightarrow (d_k^* < d(x_k \oplus x_l)) \& (d_l^* < d(x_k \oplus x_l))]; \\ & \bigcup_{X_m^o \in \tilde{\mathfrak{R}}} X_m^o \subseteq \Omega_B; k \neq l; k, l, m = \overline{1, M}. \end{aligned}$$

де $\text{Ker}X_k^o, \text{Ker}X_l^o$ – ядра найближчих класів розпізнавання X_k^o і X_l^o відповідно; d_k^*, d_l^* – оптимальні радіуси гіперсферичних контейнерів класів розпізнавання X_k^o і X_l^o відповідно.

При цьому усереднений за алфавітом класів розпізнавання інформаційний критерій функціональної ефективності (КФЕ) набуває максимуму в робочій області визначення його функції:

$$\bar{E}^* = \max_{G_E \cap \{k\}} \frac{1}{M} \sum_{m=1}^M E_m^{(k)}, \quad (2)$$

де $E_m^{(k)}$ – обчислений на k -му кроці ітераційної процедури КФЕ навчання системи розпізнавати реалізації класу X_m^o ; G_E – робоча область визначення функції КФЕ; $\{k\}$ – множина кроків ітерації.

Категорійна модель

Розглянемо категорійну модель навчання системи у вигляді узагальненого орієнтованого графу, в якому множини відображаються одна на одну відповідними операторами перетворення інформації, що застосовуються в процесі навчання.

Категорійна модель включає вхідний математичний опис, який подамо у вигляді структури

$\Delta_B = \langle G, T, \Omega, Z, Y, X; \Phi_1, \Phi_2 \rangle$,

де G – простір вхідних сигналів (факторів), T – множина моментів часу одержання інформації від респондентів; Ω – простір ознак розпізнавання; Z – простір станів якості навчального контенту, Y – вибіркова множина, яка утворює вхідну багатовимірну навчальну матрицю; X – бінарна навчальна матриця; $\Phi_1: G \times T \times \Omega \times Z \rightarrow Y$ – оператор формування вхідної навчальної матриці Y ; $\Phi_2: Y \rightarrow X$ – оператор трансформації вхідної навчальної Y в бінарну матрицю X шляхом допустимих перетворень.

На рис. 4.5 показано категорійну модель інформаційно-екстремального навчання СППР з оптимізацією геометричних параметрів контейнерів класів розпізнавання, що відновлюються в радіальному базисі простору ознак, і системи контрольних допусків на ознаки розпізнавання.




Рисунок 4.5 – Категорійна модель навчання СППР

На рис. 4.5 оператор $\theta: X \rightarrow \mathfrak{R}$ буде в загальному випадку нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$ бінарного простору ознак на класи розпізнавання, а оператор класифікації ψ перевіряє основну статистичну гіпотезу про належність вхідної реалізації класу x_m^o і таким чином формує множину гіпотез $I^{|l|}$, де l – кількість статистичних гіпотез. Оператор γ шляхом оцінки прийнятих гіпотез формує множину точнісних характеристик $\mathfrak{Z}^{|q|}$, де $q = l^2$, а оператор ϕ обчислює множину значень інформаційного КФЕ, який є функціоналом від точнісних характеристик. Контур моделі, який замикається оператором γ , реалізує ітераційний процес оптимізації геометричних параметрів розбиття

$\tilde{\mathfrak{R}}^{M1}$ шляхом пошуку глобального максимуму КФЕ в робочій (допустимій) області визначення його функції. Оптимізація контрольних допусків на ознаки розпізнавання здійснюється контуром операторів, який замикається через терм-множину \mathfrak{D} . При цьому множина \mathfrak{D} містить впорядковані значення системи контрольних допусків на ознаки розпізнавання, які задаються відносно еталонної (усередненої) реалізації класу X_1^0 , що характеризує найвищий рівень якості навчального контенту.

Показана на рис. 4.5 категорійна модель передбачає згідно з принципом відкладених рішень Івахненка О.Г. перехід до інших типів радіально-базисних вирішальних правил. З цією метою її зовнішній контур містить множину \mathfrak{V} типів вирішальних правил, які будуються із застосуванням більш складних радіально-базисних роздільних функцій.

Процес навчання регламентується оператором $U: \mathfrak{V} \rightarrow G \times T \times \Omega \times Z$. Таким чином, категорійна модель, показана на рис. 4.5, на відміну від інших теоретико-множинних моделей може розглядатися як узагальнена структура алгоритму інформаційного синтезу здатної навчатися СППР. Крім того, застосування категорійних моделей відкриває шлях до застосування сучасних інформаційних інтелектуальних технологій, орієнтованих на прогресивне функціональне моделювання.

3. Інформаційно-екстремальний алгоритм навчання

Згідно з категорійною моделлю (рис.1) інформаційно-екстремальний алгоритм навчання СППР з оптимізацією системи контрольних допусків на ознаки розпізнавання подамо у вигляді ітераційної процедури пошуку глобального максимуму інформаційного критерію (2) в робочій (допустимій) області визначення його функції

$$\delta_K^* = \arg \max_{G_\delta} \{ \max_{G_E \cap \{k\}} \bar{E}^{(k)} \}, \quad (3)$$

де δ_k^* – оптимальний параметр поля контрольних допусків на ознаки розпізнавання; G_δ – допустима область значень параметра δ поля контрольних допусків.

На рис. 4.6 показано двобічне симетричне поле контрольних допусків на ознаку розпізнавання y_i .




Рисунок 4.6 – Поле контрольних допусків на ознаки розпізнавання

На рис. 4.6 прийнято такі позначення: \bar{y}_i – номінальне (усереднене) значення ознаки y_i ; $A_{н_i}, A_{в_i}$ – нижній та верхній нормовані допуски на ознаку y_i ; $A_{нк_i}, A_{вк_i}$ – нижній та верхній контрольні допуски на ознаку y_i ; δ – параметр поля контрольних допусків.

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

Розглянемо основні етапи реалізації алгоритму навчання СППР з паралельною оптимізацією контрольних допусків на ознаки розпізнавання.

1. Ініціалізація лічильника кроків зміни параметра δ поля контрольних допусків.

2. Ініціалізація лічильника кроків зміни радіусів гіперсферичних контейнерів класів розпізнавання.

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

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

4. Обчислення еталонних (усереднених) двійкових векторів $\{x_{m,i}\}$ класів розпізнавання за правилом

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

де ρ_m – рівень селекції координат двійкового еталонного вектора $x_m \in X_m^0$, який за замовчуванням дорівнює 0,5.

5. Розбиття множини $\{x_{m,i}\}$ на пари сусідніх двійкових еталонних векторів: $\mathfrak{R}_m^{(2)} = \langle x_m, x_c \rangle$, де x_c – еталонний вектор сусіднього класу X_c^0

6. Оптимізація кодової відстані d_m відбувається за ітераційною процедурою пошуку глобального максимуму інформаційного КФЕ (2) в робочій області визначення його функції:

$$d_m^* = \arg \max_{G_E \cap \{k\}} E_m,$$

7. Якщо значення критерію (2) знаходиться в робочій (допустимій) області G_E , то виконується пункт 2 до тих пір коли буде знайдено глобальний максимум його функції

$$E_m^* = \max_{\{d\}} E_m,$$

де $\{d\} \in [0; d(x_m \oplus x_1) - 1]$ – множина радіусів гіперсферичних контейнерів класів, центр яких визначається вершиною еталонного вектора $x_m \in X_m^0$.

9. Визначається оптимальний параметр поля контрольних допусків δ^* та обчислюються для всіх ознак розпізнавання нижні і верхні контрольні допуски

$$A_{HK_i}^* = y - \delta^*;$$

$$A_{BK_i}^{\delta} = y_i + \delta^*.$$

Таким чином, параметрами інформаційно-екстремального навчання СППР є оптимальні радіуси $\{d_m^*\}$ гіперсферичних контейнерів класів розпізнавання, оптимальні еталонні вектори-реалізації $\{x_m^*\}$ класів розпізнавання і оптимальний параметр δ^* поля контрольних допусків, які дозволяють побудувати в просторі ознак розпізнавання вирішальні правила для прийняття рішень при функціонуванні системи безпосередньо в режимі моніторингу відповідності навчального контенту вимогам ринку праці.

Результати моделювання

Для перевірки ефективності синтезованої системи 120 респондентам, які склалися переважно із випускників Сумського державного університету за спеціальністю «Комп'ютерні науки та інформаційні технології» та технічних керівників ІТ-компаній, було запропоновано оцінити 50 змістовних модулів з 10 навчальних дисциплін бакалаврського рівня, пов'язаних із професійною підготовкою фахівця в галузі інформаційних технологій. Змістовні модулі безпосередньо вибиралися із обов'язкової та варіативної частин освітньо-професійної програми підготовки бакалавра і структурувалися по шести блокам: «Мови програмування та операційні системи», «Бази даних», «Web-програмування», «Теорія алгоритмів і структури даних», «Комп'ютерні мережі» і «Системний аналіз». Як респонденти виступали провідні фахівці десяти ІТ-компаній, серед яких переважну кількість склали випускники кафедри комп'ютерних наук. Після входження в систему респондентам пропонувалося шляхом установки повзунка на стобальній шкалі оцінити відповідний змістовний модуль.

За результатами відповідей респондентів автоматично формувалася навчальна матриця для трьох класів розпізнавання, які характеризували відповідні рівні якості навчального контенту. При цьому клас x_1^0 відповідав

навчальному контенту з оцінкою «добре», клас X_2^o – задовільно» і клас X_3^o – «незадовільно».

Машинне навчання СППР здійснювалося з паралельною оптимізацією системи контрольних допусків на ознаки розпізнавання за алгоритмом (3). Як КФЕ навчання СППР розглядалася модифікована інформаційна міра Кульбака у вигляді [5]

$$E_m^{(k)} = \log_2 \left(\frac{2 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))}{\alpha_m^{(k)}(d) + \beta_m^{(k)}(d)} \right)^* \quad (4)$$

$$* [1 - (\alpha_m^{(k)}(d) + \beta_m^{(k)}(d))],$$

де $\alpha_m^{(k)}(d)$ – помилка першого роду прийняття рішення на k -му кроці навчання; $\beta_m^{(k)}(d)$ – помилка другого роду; d – дистанційна міра, яка визначає радіуси гіперсферичних контейнерів, побудованих в радіальному базисі простору Хеммінга.

На рис 3 показано отриманий в процесі інформаційно-екстремального навчання інформаційно-аналітичної системи графік залежності усередненого ха алфавітом класів розпізнавання інформаційного критерію (4) від параметра поля контрольних допусків на ознаки розпізнавання.





Рисунок 4.7 – Графік залежності КФЕ від параметра поля контрольних допусків


На рис. 4.7 штриховкою позначено робочу (допустиму) область визначення функції критерію (4), в якій перша і друга достовірності перевершують відповідно помилки першого та другого роду.

Аналіз рисунку показує, що оптимальним в інформаційному розумінні є значення параметра $\delta^* = \pm 11$, яке вимірюється в градаціях стобальної оціночної шкали. При цьому максимальне усереднене за алфавітом класів розпізнавання значенні КФЕ навчання системи дорівнює $\bar{E}^* = 1,04$.


На рис. 4.8 показано процес оптимізації радіусів контейнерів класів розпізнавання.



а



б



в

Рисунок 4.8 – Графік зміни КФЕ при оптимізації радіусів контейнерів класів розпізнавання: а – клас x_1^0 -«добре»; б – клас x_2^0 – «задовільно»; в – клас x_3^0 - «незадовільно»

Аналіз рис. 4.8 показує, що оптимальні значення радіусів контейнерів класів розпізнавання дорівнюють: для класу $x_1^o - d_1^* = 6$ (тут і далі в кодових одиницях) при міжцентровій відстані із сусіднім (найближчим) класом $d_c = 15$; для класу $x_2^o - d_2^* = 10$ при міжцентровій відстані $d_c = 21$; для класу $x_3^o - d_3^* = 21$ при міжцентровій відстані $d_c = 18$. При цьому середнє значення радіусів контейнерів класів розпізнавання дорівнює $\bar{d}^* = 15$, а середня міжцентрова відстань класів розпізнавання – $\bar{d}_c^* = 17$. Цим параметрам контейнерів відповідають такі значення КФЕ і точнісних характеристик: для класу $x_1^o - E_1^* = 1,27$ (перша достовірність $D_1 = 0,85$ і помилка другого роду $\beta = 0,20$); для класу $x_2^o - E_2^* = 0,44$ ($D_1 = 0,55$ і $\beta = 0,15$) і для класу $x_3^o - E_3^* = 1,39$ ($D_1 = 0,93$; $\beta = 0,25$).

Отримані значення КФЕ навчання системи є недостатньо високими, що обумовлено високим ступенем перетину класів розпізнавання. З метою підвищення функціональної ефективності машинного навчання системи було застосовано алгоритм послідовної оптимізації контрольних допусків на ознаки розпізнавання. За цим алгоритмом оптимізація контрольних допусків здійснюється окремо для кожної ознаки. При цьому отримані за результатами паралельної оптимізації квазіоптимальні контрольні допуски на ознаки розпізнавання приймалися як стартові при реалізації алгоритму їх послідовної оптимізації. Такий підхід дозволяє суттєво підвищити оперативність алгоритму послідовної оптимізації, оскільки обчислення інформаційного критерію на кожному кроці навчання здійснюються в робочій області визначення його функції.

На рис. 4.9 показано динаміку зміни усередненого КФЕ в процесі послідовної оптимізації СКД на ознаки розпізнавання.






Рисунок 4.9 – Графік зміни усередненого КФЕ в процесі оптимізації СКД за послідовним алгоритмом

Оскільки послідовна оптимізація контрольних допусків здійснюється при квазіоптимальних допусках на інші ознаки, то ця процедура вимагає проведення її повторів (прогонів) до тих пір, поки значення інформаційного КФЕ перестане змінюватися. Аналіз рис. 4.9 показує, що оптимальна СКД на ознаки розпізнавання була отримана на третьому прогоні алгоритму оптимізації. Довжина одного прогону дорівнює кількості ознак ($N=50$). При цьому максимальне значення усередненого КФЕ дорівнює $\bar{E}^* = 1,40$, що суттєво перевершує значення, отримане після паралельної оптимізації контрольних допусків на ознаки розпізнавання ($\bar{E} = 1,04$)*.


Результати оптимізації радіусів контейнерів класів розпізнавання, які є параметрам вирішальних правил, наведено на рис. 4.10.



а



б



в

Рисунок 4.10 – Графік залежності КФЕ від радіусів контейнерів класів розпізнавання: а – клас X_1^0 ; б – клас X_2^0 ; в – клас X_3^0

Аналіз рис. 4.10 показує, що оптимальні радіуси контейнерів дорівнюють: для класу X_1^0 – $d_1^* = 9$ при міжцентровій відстані $d_c = 13$, для класу X_2^0 – $d_2^* = 11$ при $d_c = 21$ і для класу X_3^0 – $d_3^* = 13$ при $d_c = 23$. Цим параметрам контейнерів відповідають такі значення КФЕ і точнісних характеристик: для класу X_1^0 – $E_1^* = 1,39$ (перша достовірність $D_1 = 0,80$ і помилка другого роду $\beta = 0,13$); для

класу $x_2^o - E_2^* = 1,16$ ($D_1 = 0,72$ і $\beta = 0,10$) і для класу $x_3^o - E_3^* = 1,66$ ($D_1 = 0,97$; $\beta = 0,25$). При цьому середнє значення радіусів контейнерів класів розпізнавання стало дорівнювати $\bar{d}^* = 11$, що менше у порівнянні з паралельною оптимізацією, а середня міжцентрова відстань класів розпізнавання збільшилася і дорівнює $\bar{d}_c^* = 19$.

Таким чином, отримані результати відповідають основним принципам підвищення достовірності розпізнавання образів: дистанційно-мінімальному, який вимагає мінімізації радіусів контейнерів класів розпізнавання і дистанційно-максимальному щодо необхідності максимізації міжцентрових відстаней класів розпізнавання.

Висновки

1. В рамках інформаційно-екстремальної інтелектуальної технології аналізу даних реалізовано алгоритм машинного навчання інформаційно-аналітичної системи адаптації навчального контенту випускової кафедри до вимог ринку праці.

2. Працездатність розроблених алгоритмів перевірена при машинному оцінюванні трьох якісних рівнів навчального контенту випускової кафедри комп'ютерних наук Сумського державного університету за результатами проведеного опитування провідних фахівців ІТ-компаній.

3. Для побудови безпомилкових за навчальною вибіркою вирішальних правил необхідно здійснювати оптимізацію інших параметрів функціонування, які впливають на функціональну ефективність машинного навчання інформаційно-аналітичної системи. При цьому з метою оцінки контенту окремих навчальних дисциплін необхідно переходити до ієрархічної структури даних.

4.4 ОЦІНКА ІНФОРМАТИВНОСТІ ОЗНАК РОЗПІЗНАВАННЯ УНІМОДАЛЬНОГО КЛАСИФІКАТОРУ

На сьогодні відбувається стрімкий розвиток засобів визначення рівня знань студентів (у загальному випадку - учнів), які не вимагають великих витрат часу на підготовку, проведення й обробку результатів. Серед них виділяють машинні й безмашинні засоби перевірки знань [1-3].

Серед безмашинних засобів перевірки найпоширенішими в практиці є усне опитування учнів біля дошки, перевірка вчителем зошитів з домашнім завданням, диктант, самостійна або контрольна роботи.

Все частіше для контролю знань учнів використовують автоматизовані комп'ютерні системи. Для контролю знань учнів зручно застосовувати типові розрахунки, які включають найбільш характерні завдання базового курсу [4].

Надалі будемо говорити про машинні засоби контролю знань, і, зокрема, про тестування із застосуванням засобів обчислювальної техніки.

Основною проблемою будь-якої освіти є відсутність чіткого контролю за якістю засвоєння матеріалу. Причому якщо в шкільній практиці вчитель ще більш-менш має можливість із певною періодичністю перевіряти рівень поточних знань учня, то у вищому навчальному закладі викладач цілий семестр видає матеріал і лише наприкінці семестру переконується в рівні його засвоєння.

Важливим моментом систематичного контролю знань є об'єктивність, що обумовлено переносом акценту з виховної функції навчання на інформативну. Тільки в такому випадку учень буде позитивно налаштований на перевірку знань, а викладач матиме реальну картину знань учня.

Звертаючись до проблеми ролі штучного інтелекту у процесі навчання й освіти, будемо розглядати цей процес як один з різновидів взаємодії людини з ЕОМ, і розкривати серед перспективних можливостей ті, які спрямовані на створення так званих адаптивних систем, що навчаються, які імітують оперативний діалог учня й викладача-людини.

Постановка задачі

Розглянемо формалізовану постановку задачі інформаційного синтезу системи керування дистанційним навчанням (СКДН), основною складовою якої є здатна навчатися система підтримки прийняття рішень для оцінки рівня знань студентів за результатами їх тестування. Нехай дано алфавіт $\{X_m^o | m = \overline{1, M}\}$ класів розпізнавання, які характеризують різні рівні знань студента, і навчальну матрицю відповідей студентів на певну $\|y_{m,i}^{(j)}\|, i = \overline{1, N}, j = \overline{1, n}$, кількість тестових завдань де – N, n кількість ознак розпізнавання та векторів-реалізацій (далі реалізації) класів розпізнавання відповідно. При цьому строчка матриці $\{y_{m,i}^{(j)} | i = \overline{1, N}\}$ визначає j -у реалізацію, а стовпчик $\{y_{m,i}^{(j)} | j = \overline{1, n}\}$ – навчальну вибірку значень i -ї ознаки. Відомий структурований вектор параметрів навчання СКДН $g = \langle x_m, d_m \rangle$, де x_m – еталонна реалізація, яка визначає геометричний центр контейнера класу X_m^o ; d_m – радіус контейнера класу X_m^o . Необхідно на етапі навчання СКДН оптимізувати координати вектора g шляхом пошуку глобального максимуму усередненого за алфавітом класів розпізнавання інформаційного критерію функціональної ефективності (КФЕ) навчання системи контрольних допусків (СКД)

$$\bar{E} = \frac{1}{M} \sum_{m=1}^M \max_{G_E} E_m \quad (1)$$

де E_m – інформаційний КФЕ навчання системи розпізнавати реалізації класу

X_m^o ;

G_E – робоча (допустима) область визначення функції КФЕ.

При функціонуванні СКД в режимі екзамену, тобто безпосереднього оцінювання, необхідно прийняти рішення про належність реалізації, що розпізнається, до одного із класів заданого алфавіту.

Математична модель

Оскільки процес машинної оцінки знань є слабо формалізованим, то математичну категорійну модель здатної навчатися системи розглянемо у

вигляді діаграми відображення відповідними операторами множин, що застосовуються в процесі навчання [5, 6]. При цьому вхідний математичний опис СКДН подано у вигляді структури множин

$$\Delta_B = \langle G, T, \Omega, Z, \Pi, \Phi \rangle ,$$

де G – простір вхідних сигналів (факторів);

T – множина моментів часу зняття інформації;

Ω – простір ознак розпізнавання;

Z – простір можливих рівнів знань студента;

Y – множина сигналів після первинної обробки інформації;

$\Pi: G \times T \times \Omega \rightarrow Z$ – оператор переходів, що відбиває механізм зміни рівня знань в процесі засвоєння матеріалу;

$\Phi: G \times T \times \Omega \times Z \rightarrow Y$ – оператор оброблення зображення (формування вибіркової множини Y на вході СКДН). Як універсум випробувань W розглядається декартовий добуток: $w = G \times T \times \Omega \times Z$.

У загальному випадку математичну модель СКДН яка розв'язує задачу інформаційного синтезу класифікатора, подамо у вигляді структурної діаграми відображення операторами множин, що застосовуються в процесі навчання, в рамках інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) має вигляд, показаний на рис.4.11 [5].

На діаграмі (рис.4.11) показано такі множини: $\mathfrak{R}^{|M|}$ – розбиття простору ознак розпізнавання; $I^{|l|}$ – множина допустимих гіпотез; $\mathfrak{Z}^{|q|}$ – множину точнісних характеристик; E – інформаційний КФЕ навчання СКДН.




Рисунок 4.11– Категорійна модель навчання СКДН

Показані на рис. 4.11 оператори мають такі призначення: оператор θ будує розбиття $\mathfrak{R}^{|M|}$ простору ознак на класи розпізнавання; оператор ψ перевіряє основну статистичну гіпотезу про належність реалізацій образу; оператор γ формує множину точнісних характеристик; оператор φ обчислює множину значень інформаційного КФЕ; оператори r_1 та r_2 реалізують ітераційний процес оптимізації геометричних параметрів розбиття $\mathfrak{R}^{|M|}$; оператор U регламентує процес навчання і дозволяє оптимізувати параметри його плану. При цьому правий контур операторів безпосередньо оптимізує геометричні параметри розбиття $\mathfrak{R}^{|M|}$ при заданій системі контрольних допусків на ознаки розпізнавання.

На ефективність навчання СКДН значно впливає використання контуру оптимізації СКД. Оптимізація контрольних допусків за ІЕІ-технології полягає в виборі такої СКД з терм-множини значень цього параметру навчання D у наближенні глобального максимуму інформаційного критерію оптимізації E до найбільшого його значення в області значень функції. Оптимізація на структурній діаграмі подається у вигляді відповідного контуру:





Рисунок 4.12– Категорійна модель оптимізації СКД

Тут окремо виділено множину X , яка є аналогом множини Y у просторі розбиття ознак розпізнавання $\mathfrak{R}^{|M|}$ і проміжним результатом дії оператора θ нечіткої факторизації простору ознак, що безпосередньо залежить від значень СКД. Оператори δ_1 та δ_2 оцінюють вплив оптимізуємого параметра на СКДН в цілому і регламентують подальшу оптимізацію відповідно. Контур операторів



що безпосередньо оптимізує СКД, включає в себе і оптимізацію геометричних параметрів розбиття $\mathfrak{R}^{|M|}$, яка проводиться на кожному кроці оптимізації СКД.

Математичну модель оцінки інформативності ознак у рамках ІЕІ-технології можна описати як додатковий контур оптимізації в алгоритмі навчання. Модифікований алгоритм подамо у вигляді наступної діаграми відображень множин (рис. 4.13)





Рисунок 4.13 – Модель оцінки інформативності ознак

Множина Σ , яка вводиться в базову математичну модель ІЕІ-технології, є множиною всіх можливих варіантів словників, що можна сформувані шляхом видалення ознак з початкового словника. Введений контур оптимізації



що виділено на діаграмі, за допомогою оператора $\sigma_2: \Sigma \rightarrow \Omega$ видаляє ознаки розпізнавання із початкового словника і формує новий словник. Ефективність такого словника визначається після оптимізації інших параметрів системи та визначення КФЕ, що відповідає оптимальним в інформаційному розумінні значенням параметрів. Оператор $\sigma_1: E \rightarrow \Sigma$ визначає інформативність ознаки розпізнавання I_i , що обчислюється як різниця значень КФЕ ΔP_i , що було одержано при навчанні СКДН з

початковим словником $\overline{E_{ALL}^*}$ та з модифікованим його варіантом $\overline{E_i^*}$:

$$I_i = \Delta P_i = \overline{E_{ALL}} - \overline{E_i^*}$$

Алгоритм навчання СКДН

Інформаційно-екстремальне навчання СКДН у загальному випадку здійснюється за багатоциклічною ітераційною процедурою пошуку глобального максимуму інформаційного КФЕ в робочій (допустимій) області визначення його функції, яка у загальному випадку має вигляд

$$g_{\xi}^* = \arg \max_{G_{\xi}} \{ \max_{G_{\xi-1}} \{ \dots \{ \max_{G_E \cap G_1} \overline{E} \} \dots \} \}, \quad (2)$$

де \overline{E} – усереднене для ієрархічної структури класів розпізнавання значення інформаційного КФЕ навчання СКДН;

G_{ξ} – допустима область значень ξ -ї ознаки;

G_E – допустима область значень КФЕ.

Внутрішній цикл алгоритму (2) реалізує базовий алгоритм навчання, в якому параметром функціонування, що оптимізується, є радіус гіперсферичного класифікатора:

$$d_m^* = \arg \max_{G_E \cap \{d\}} E_m, \quad (3)$$

де $\{d\} = \{R_1, R_2\}$ – множина значень радіусів контейнера класу X_m^o , що відновлюється в радіальному базисі простору ознак розпізнавання.

Розглянемо етапи реалізації алгоритму навчання СКДН:

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

$$8. \quad x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_{K,i}; \\ 0, & \text{if } y_{m,i}^{(j)} \notin \delta_{K,i}. \end{cases}$$

2. Формування одиничного еталонного вектору $x = \left(\underbrace{11\dots 1}_N \right)$.

3. Ініціалізація лічильника класів $k = 2$.

4. Ініціалізація лічильника кроків оптимізації зовнішнього радіуса $R_2 = 0$.

5. Ініціалізація лічильника кроків оптимізації внутрішнього радіуса $R_I=0$.

6. Побудова вкладеного контейнеру класу з такими параметрами: центр контейнера x , внутрішній R_I та зовнішній R_2 радіус вкладеної гіперсфери.

7. Обчислення точносних характеристик такого контейнера, відповідного КФЕ та перевірка на знаходження його в робочій області.

8. Якщо $R_I < R_2$, то $R_I = R_I + 1$ та перехід на пункт 6.

9. Якщо $R_2 < N$, то $R_2 = R_2 + 1$ та перехід на пункт 5.

Процедура закінчується при знаходженні максимуму КФЕ в робочій області його визначення: $E_m^* = \max_{\{R_1, R_2\}} E_m$, де $\{R_1, R_2\}$ – множина радіусів вкладених гіперсфер, центр яких визначається вершиною x .

Як КФЕ навчання в ІЕІ-технології використовується інформаційні міра Кульбака:

$$E_m^{(k)} = 0,5 \log_2 \left(\frac{D_1^{(k)} + D_2^{(k)} + 10^{-r}}{\alpha^{(k)} + \beta^{(k)} + 10^{-r}} \right) \cdot \left[(D_1^{(k)} + D_2^{(k)}) - (\alpha^{(k)} + \beta^{(k)}) \right] \quad (4)$$

де $D_1^{(k)}$, $D_2^{(k)}$ – перша та друга достовірності, обчислені на k -му кроці навчання;

$\alpha^{(k)}$, $\beta^{(k)}$ – помилка першого та другого роду;

10^{-r} – достатньо мале число для уникнення поділу на нуль.

У загальному випадку побудований за формулою (4) графік функцій $E = f(D_1, D_2)$ та $J = f(D_1, D_2)$ є поверхнями в тривимірному просторі.

Аналіз рис. 4.14 показує, що функція (4) є взаємно-неоднозначною. На практиці цей недолік усувається шляхом введення робочої (допустимої) області визначення функцій, в якій перша та друга достовірності становляться більше відповідних помилок першого та другого роду, тобто $D_1 \geq 0,5$ та $D_2 \geq 0,5$.

Робочі області на рис. 4.14 показано на відповідних графіках темним кольором. Аналіз графіка показує, що при збільшенні у робочій області як

першої, так і другої достовірностей кількість інформації теж збільшується, що знаходиться у відповідності з другим принципом адитивності інформації.




Рисунок 4.14– Графік залежності КФЕ від точнісних характеристик при двохальтернативних рішеннях для критерія Кульбака

Існує декілька можливих стратегій оптимізації поля допусків серед яких відзначимо дві основні: симетрична стратегія, яка є виправданою, наприклад, за умови співпадання номінального значення з центром розсіювання реалізацій образу і асиметрична стратегія, яка має місце при неспівпаданні номінального значення A_0 з емпіричним центром розсіювання реалізацій.

Оптимізація СКД може здійснюватися за трьома алгоритмами:

- послідовний алгоритм TEACHING-1M, при якому контрольні допуски оптимізуються послідовно для кожної ОР при фіксованих значеннях інших ознак;
- паралельний алгоритм TEACHING-2M, при якому контрольні допуски оптимізуються для всіх ознак одночасно;
- алгоритм оптимізації за зведеним полем допусків.

Використання послідовного алгоритму доцільно в загальному випадку, коли ознаки розпізнавання складають різнофакторні групи. Паралельний алгоритм доцільно використовувати за умови, що ознаки розпізнавання відбивають вплив одного фактора. Алгоритм оптимізації СКД за зведеним полем

допусків може розглядатися як узагальнення послідовного та паралельного алгоритмів за наявності різних шкал виміру ознак розпізнавання.

Розглянемо кроки реалізації алгоритму оцінки інформативності ознак розпізнавання в рамках ІЕІ-технології:

1. За алгоритмом паралельної оптимізації СКД (TEACHING-2M) визначаємо оптимальні параметри навчання та максимальне усереднене значення КФЕ для початкового словника ознак розпізнавання(ОР) $\overline{E_{ALL}^*}$.

2. Формуємо лічильник ознак розпізнавання у словнику, $i=1$.

3. Видаляємо i -ту ознаку розпізнавання з початкового словника.

4. За алгоритмом TEACHING-2M визначаємо оптимальні параметри навчання та максимальне усереднене значення КФЕ для даного словника ОР $\overline{E_1^*}$.

5. Обчислюємо інформативність ОР $\Delta P_i = \overline{E_{ALL}^*} - \overline{E_1^*}$.

6. Повертаємо i -ту ознаку розпізнавання в словник.

7. $i=i+1$.

8. Якщо $i \leq N$, виконуємо пункт 3, інакше – 8.

9. Формуємо результуючу таблицю інформативності ознак розпізнавання.

10.Зупинка.

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

Результати моделювання

Розв'язання поставленої задачі будемо проводити для чотирьох класів, тобто для оцінки рівня знань студентів на «2», «3», «4» і «5» балів. Класи отримані в процесі перевірки знань студентів по дисципліні «Інтелектуальні системи». Тестові запитання складаються на базі матеріалу, який вивчався студентами

дистанційної форми навчання, і складає основу відповідного дистанційного курсу. При цьому однією з умов є невелика (менше 15) кількість тестів, що має розв'язати кожен студент. Відповідь на кожний з тестів оцінювалася за 100 бальною шкалою. В нашому випадку початковий словник ознак розпізнавання для оцінки функціонального стану знань кожного студента складалася із 28 ознак розпізнавання. Поле допусків на кожен ознаку однакове: верхній нормований допуск 100 балів, нижній 0 балів. Априорний алфавіт класів розпізнавання складався із чотирьох класів. При цьому базовий клас відповідав функціональному стану знань «2», «3», «4», «5». Кількість реалізацій для кожного з класів 40.

Одним з основних параметрів функціонування системи керування, що навчається за ІЕІТ, вважається СКД. Результати оптимізації даного параметру за паралельним алгоритмом наведені на рис. 4.15:




Рисунок 4.15– Динаміка зміни усередненого КФЕ при оптимізації СКД

При оптимальному значенні параметра СКД $\delta^* = \pm 65$, якому відповідає максимальне значення усередненого КФЕ $\bar{E}_{\max} = 1.34482$ в робочій області визначення даного параметра, проводилася оптимізація геометричних параметрів контейнерів класів розпізнавання. Аналіз результатів оптимізації показує, що оптимальними параметрами контейнера класу X_3^g «відмінно» є зовнішній радіус $R_1^{(5)} = 13$, внутрішній радіус $R_2^{(5)} = 0$; контейнера класу X_4^g «добре» є зовнішній радіус $R_1^{(4)} = 15$, внутрішній радіус $R_2^{(4)} = 13$; контейнера

класу X_3^o «задовільно» є зовнішній радіус $R_1^{(3)} = 17$, внутрішній радіус $R_2^{(3)} = 15$; контейнера класу X_2^o «незадовільно» є зовнішній радіус $R_1^{(2)} = 22$, внутрішній радіус $R_2^{(2)} = 17$. Цим параметрам контейнерів відповідають такі значення КФЕ і точносних характеристик системи керування: для класу X_5^o $E_{\max}^{(5)} = 1.88928$ ($D_1 = 0.95$; $\beta = 0.23$), для класу X_4^o $E_{\max}^{(4)} = 1.18402$ ($D_1 = 0.72$; $\beta = 0.13$), для класу X_3^o $E_{\max}^{(3)} = 0.87265$ ($D_1 = 0.78$; $\beta = 0.25$), для класу X_2^o $E_{\max}^{(2)} = 1.43332$ ($D_1 = 0.80$; $\beta = 0.15$).

Оцінка інформативності проводилася шляхом формування варіантів словників з потужністю менше на одиницю за потужність поточного словника ОР, для яких проводилася оптимізація параметрів навчання і обчислювалося максимальне усереднене значення КФЕ. На рис. 4.16 відображується динаміка зміни КФЕ в процесі розв'язання даної задачі.




Рисунок 4.16– Динаміка зміни усередненого КФЕ в процесі оцінки інформативності

Аналіз рис. 4.16 показує, що інформативними для СКДН в цілому є двадцять одна ознака. Одна ознака є неінформативною, оскільки її видалення не призводить до зміни КФЕ. Всі інші ознаки є заважаючими, відповідні тестові завдання потребують переробки.

Найбільш інформативною є ознака №17. Її інформативність дорівнює 0.38253. При видаленні цієї ознаки з словника змінюються оптимальні значення геометричних параметрів контейнера класу X_5^o «відмінно» є зовнішній радіус $R_1^{(5)} = 12$, внутрішній радіус $R_2^{(5)} = 0$; контейнера класу X_4^o

«добре» є зовнішній радіус $R_1^{(4)}=14$, внутрішній радіус $R_2^{(4)}=12$; контейнера класу X_3^o «задовільно» є зовнішній радіус $R_1^{(3)}=17$, внутрішній радіус $R_2^{(3)}=14$; контейнера класу X_2^o «незадовільно» є зовнішній радіус $R_1^{(2)}=22$, внутрішній радіус $R_2^{(2)}=17$. Цим параметрам контейнерів відповідають такі значення КФЕ і точносних характеристик системи керування: для класу X_5^o $E_{\max}^{(5)}=1.57310$ ($D_1=0.70$; $\beta=0.03$), для класу X_4^o $E_{\max}^{(4)}=0.42190$ ($D_1=0.85$; $\beta=0.47$), для класу X_3^o $E_{\max}^{(3)}=0.55018$ ($D_1=0.72$; $\beta=0.30$), для класу X_2^o $E_{\max}^{(2)}=1.30398$ ($D_1=0.70$; $\beta=0.03$). Найбільш заважаючою є ознака №19. Її інформативність дорівнює - 0.14645. При видаленні цієї ознаки з словника змінюються оптимальні значення геометричних параметрів контейнера класу X_5^o «відмінно» є зовнішній радіус $R_1^{(5)}=12$, внутрішній радіус $R_2^{(5)}=0$; контейнера класу X_4^o «добре» є зовнішній радіус $R_1^{(4)}=14$, внутрішній радіус $R_2^{(4)}=12$; контейнера класу X_3^o «задовільно» є зовнішній радіус $R_1^{(3)}=16$, внутрішній радіус $R_2^{(3)}=14$; контейнера класу X_2^o «незадовільно» є зовнішній радіус $R_1^{(2)}=21$, внутрішній радіус $R_2^{(2)}=16$. Цим параметрам контейнерів відповідають такі значення КФЕ і точносних характеристик системи керування: для класу X_5^o $E_{\max}^{(5)}=1.88928$ ($D_1=0.78$; $\beta=0.05$), для класу X_4^o $E_{\max}^{(4)}=0.96901$ ($D_1=0.78$; $\beta=0.23$), для класу X_3^o $E_{\max}^{(3)}=0.87265$ ($D_1=0.78$; $\beta=0.25$), для класу X_2^o $E_{\max}^{(2)}=2.06924$ ($D_1=0.95$; $\beta=0.20$).

Таким чином, тести 1, 9, 11, 19, 22, 26, 28 потребують доопрацювання або видалення з набору тестових завдань. Інші тести можна використовувати в розробленій СКДН.

Висновки

Запропоновано в рамках ІЕІ-технології модифікацію базового алгоритму навчання та похідного від нього алгоритмів оптимізації системи контрольних допусків на ознаки розпізнавання шляхом застосування унімодальних контейнерів класів розпізнавання. Розроблено алгоритм оцінки інформативності ознак для даного виду класифікаторів.

4.5 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНИЙ АЛГОРИТМ НАВЧАННЯ ІНФОРМАЦІЙНО-АНАЛІТИЧНОЇ СИСТЕМИ ОЦІНКИ ЯКОСТІ НАВЧАЛЬНОГО КОНТЕНТУ

Розглядається алгоритм інформаційно-екстремального машинного навчання інформаційно-аналітичної системи оцінки якості навчального контенту випускової кафедри до вимог ринку праці, що полягає в ітераційній процедурі максимізації інформаційної спроможності системи шляхом введення додаткових інформаційних обмежень. Як критерій функціональної ефективності навчання системи розглядається модифікація логарифмічної інформаційної міри за К. Шеноном, представлена у вигляді функціоналу від точнісних характеристик рішень, що приймаються в робочому режимі системи.

ВСТУП

Оцінка якості навчального контенту випускової кафедри є важливою складовою інтегрального показника якості освіти вищого навчального закладу (ВНЗ) [1,2]. Саме якість навчального контенту безпосередньо впливає на такі важливі показники, як відсоток працевлаштованих випускників кафедри та їх конкурентноспроможність на ринку праці. Тому у ВНЗ України накопичено багаторічний досвід встановлення зворотнього зв'язку з роботодавцями з метою аналізу працевлаштування випускників і вимог ринку праці. Але суттєвим недоліком існуючої системи оцінки якості вищої освіти є відсутність автоматизованої інформаційно-аналітичної системи адаптації навчального контенту випускової кафедри до вимог ринку праці, яка функціонує в режимі моніторингу і видає викладацькому складу кафедри рекомендації по удосконаленню контенту навчальних дисциплін. Основна причина такого стану полягає в ускладненнях науково-методологічного характеру, обумовлених необхідністю надання системі властивості адаптивності за умов апріорної невизначеності. Одним із

перспективних шляхів вирішення цієї проблеми є застосування ідей і методів інформаційно-екстремальної інтелектуальної технології (ІЕІ-технології) аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи в процесі її навчання [3,4].

У статті в рамках ІЕІ-технології розглядається алгоритм навчання інформаційно-аналітичної системи адаптації навчального контенту випускової кафедри до вимог ринку праці.

ОСНОВНА ЧАСТИНА

Ідея машинного навчання у рамках ІЕІ-технології полягає в трансформації шляхом ітераційної оптимізації параметрів функціонування СППР апріорно нечіткого розбиття простору ознак на класи розпізнавання у чітке розбиття. Тобто процес навчання можна розглядати як процедуру дефазифікації, задачею якої є побудова чітких вирішальних правил. При цьому в процесі навчання здійснюється цілеспрямований пошук глобального максимуму багатоекстремальної функції статистичного інформаційного критерію в робочій (допустимій) області її визначення і одночасного відбувається відновлення в радіальному базисі бінарного простору ознак розпізнавання оптимальних роздільних гіперповерхонь.

Згідно з принципом відкладених рішень Івахненка О.Г. побудова в процесі оптимізації параметрів машинного навчання безпомилкових за навчальною матрицею вирішальних правил в рамках ІЕІ-технології здійснюється за багатоциклічною ітераційною процедурою пошуку максимального граничного значення КФЕ навчання у вигляді

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

де $E_m^{(k)}$ – інформаційний КФЕ навчання системи розпізнавати реалізації класу x_m^0 , обчислений на k -му кроці навчання; G_{ξ} – допустима область значень ξ -ї

ознаки розпізнавання; G_E – допустима область визначення функції інформаційного КФЕ навчання; $\{k\}$ – множина кроків навчання.

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

- обчислення інформаційного КФЕ навчання системи в робочій допустимій області визначення його функції;
- пошук глобального максимуму інформаційного КФЕ;
- визначення оптимальних в інформаційному розумінні геометричних параметрів контейнерів класів розпізнавання, які забезпечують максимальне значення інформаційного КФЕ.

Категорійну модель навчання системи за базовим алгоритмом представимо у вигляді діаграми відображення множин, що задіяні в процесі машинного навчання (рис.4.15).




Рисунок 4.15– Структурна діаграма відображень множин у процесі навчання

На рис. 4.15 універсум випробувань w характеризується декартовим добутком $w = G \times T \times \Omega \times Z$, де G – простір вхідних сигналів (факторів), які діють на систему; T – множина моментів часу зняття інформації; Ω – простір ознак розпізнавання; Z – простір можливих станів системи.

Оператор $\Phi: G \times T \times \Omega \times Z \rightarrow Y$ формує вхідну навчальну матрицю Y , а оператор $\theta: Y \rightarrow \tilde{\mathfrak{R}}^{|M|}$ буде в загальному випадку нечітке розбиття $\tilde{\mathfrak{R}}^{|M|}$

простору ознак на класи розпізнавання. Оператор класифікації $\psi: \mathfrak{R}^{|\mathcal{M}|} \rightarrow I^{|\mathcal{I}|}$, де $|\mathcal{I}|$ – кількість статистичних гіпотез, перевіряє основну статистичну гіпотезу про належність реалізацій $\{x_m^{(j)} | j = \overline{1, n}\}$ нечіткому класу розпізнавання x_m^o . Оператор $\gamma: I^{|\mathcal{I}|} \rightarrow \mathfrak{Z}^{|\mathcal{Q}|}$ шляхом оцінки статистичних гіпотез формує множину точнісних характеристик $\mathfrak{Z}^{|\mathcal{Q}|}$, де $q = |\mathcal{Q}|$ – кількість точнісних характеристик. Оператор $\phi: \mathfrak{Z}^{|\mathcal{Q}|} \rightarrow E$ обчислює множину значень інформаційного КФЕ, який є функціоналом точнісних характеристик. Контур оптимізації геометричних параметрів нечіткого розбиття $\mathfrak{R}^{|\mathcal{M}|}$ шляхом пошуку максимуму КФЕ навчання розпізнаванню реалізацій класу x_m^o замикається оператором $r: E \rightarrow \mathfrak{R}^{|\mathcal{M}|}$.

В лівий контур операторів введено множину v типів радіально-базисних вирішальних правил, які вибираються оператором v за умови недосягнення в процесі навчання за максимального граничного значення інформаційного критерію E . Правий контур операторів оптимізує геометричні параметри розбиття $\mathfrak{R}^{|\mathcal{M}|}$ шляхом ітераційного пошуку глобального максимуму інформаційного КФЕ навчання. Оператор $u: v \rightarrow G \times T \times \Omega \times Z$ регламентує процес навчання.

Вхідною інформацією для навчання за базовим алгоритмом є дійсний в загальному випадку масив реалізацій образу $\{y_m^{(j)} | m = \overline{1, M}; j = \overline{1, n}\}$; система полів контрольних допусків $\{\delta_{k,i}\}$ на ознаки розпізнавання і рівні селекції $\{\rho_m\}$ координат еталонних векторів-реалізацій, які за замовчуванням дорівнюють 0,5 для всіх класів розпізнавання.

Розглянемо основні етапи реалізації базового алгоритму для навчання СППР з гіперсферичним класифікатором.

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

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

2. Формування масиву еталонних двійкових векторів-реалізацій $\{x_{m,i}\}$, елементи яких визначаються за правилом

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

де ρ_m – рівень селекції координат двійкового еталонного вектора $x_m \in X_m^0$, який за замовчуванням дорівнює 0,5.

3. Розбиття множини еталонних векторів на пари найближчих “сусідів”:
 $\mathfrak{R}_m^{[2]} = \langle x_m, x_1 \rangle$, де x_1 – еталонний вектор сусіднього класу X_1^0 , за такою схемою:

а) структурується множина еталонних векторів, починаючи з вектора x_1 базового класу X_1^0 , який характеризує найбільшу функціональну ефективність СППР;

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

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

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

4. Оптимізація кодової відстані d_m відбувається за ітераційною процедурою пошуку глобального максимуму інформаційного КФЕ в робочій області визначення його функції:

$$d_m^* = \arg \max_{G_E \cap G_d} E_m, \quad (1)$$

де G_E – робоча (допустима) область визначення інформаційного критерію E_m ; G_d – допустима область значень радіусів контейнерів класів розпізнавання, які відновлюються в процесі навчання в радіальному базисі простору ознак.

5. Процедура закінчується при знаходженні максимуму КФЕ в робочій (допустимій) області визначення його функції:

$$E_m^* = \max_{\{d\}} E_m,$$

де $\{d\} \in [0; d(x_m \oplus x_1) - 1]$ – множина радіусів концентрованих гіперсфер, центр яких визначається вершиною еталонного вектора $x_m \in X_m^0$.

Таким чином, параметрами навчання СППР за базовим алгоритмом є оптимальні кодові відстані $\{d_m^*\}$ і оптимальні еталонні вектори-реалізації $\{x_m^*\}$ для заданого алфавіту $\{X_m^0\}$, які дозволяють побудувати в просторі ознак розпізнавання вирішальні правила для прийняття рішень при функціонуванні системи в режимі екзамену, тобто безпосередньо в робочому режимі моніторингу відповідності навчального контенту вимогам ринку праці.

Базовий алгоритм (1) навчання СППР інформаційно-аналітичної системи було реалізовано для трьох класів розпізнавання, які характеризували різні функціональні стани навчального контенту:

- клас x_1^0 – навчальний контент відповідає сучасним вимогам ринку праці;
- клас x_2^0 – навчальний контент потребує незначної корекції окремих змістовних модулів навчальних дисциплін;
- клас x_3^0 – навчальний контент потребує значної корекції змістовних модулів навчальних дисциплін і перегляду варіативної частини навчального плану.

Мінімальна репрезентативна кількість векторів-реалізацій кожного образу дорівнювала 40 і визначалася за методикою, наведеною в праці. Тобто при формуванні навчальної матриці для цих трьох класів розпізнавання було задіяно відповіді 120 респондентів, які оцінювали за стобальною шкалою відповідність сучасним вимогам 50 змістовних модулів 10 навчальних дисциплін із нормативних і варіативних розділів навчального плану рівня бакалавра з напрямку «Інформатика», які мають безпосереднє відношення до підготовки програмістів.

Як критерій оптимізації параметрів навчання розглядався нормований ентропійний критерій Шенона, модифікація якого має вигляд [4]

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

де $\alpha_m^{(k)}(d)$ – помилка першого роду прийняття рішення на k -му кроці навчання; $\beta_m^{(k)}(d)$ – помилка другого роду; $D_{1,m}^{(k)}(d)$ – перша достовірність; $D_{2,m}^{(k)}(d)$ – друга достовірність; d – дистанційна міра, яка визначає радіуси гіперсферичних контейнерів, побудованих в радіальному базисі простору Хеммінга.

На рис. 4.16 – 4.18 показано графіки залежності КФЕ (2) від радіусів контейнерів класів розпізнавання, одержані у процесі реалізації базового алгоритму навчання (1). На цих рисунках заштриховані ділянки графіків позначають робочі (допустимі) області визначення функції ентропійного критерію (2), в яких перша та друга достовірності перебільшують відповідно помилки першого та другого роду.




Рисунок 4.16– Графік залежності критерію від радіуса контейнера класу x_1^0




Рисунок 4.17– Графік залежності критерію Шенона від радіуса контейнера класу x_2^0




Рисунок 4.18 –Графік залежності критерію Шеннона від радіуса контейнера класу x_3^0

Аналіз рис. 4.16-4.18 показує, що оптимальні радіуси контейнерів у кодових одиницях Хеммінга дорівнюють відповідно $d_1^* = 13$, $d_2^* = 19$ і $d_3^* = 33$ при усередненому за алфавітом класів розпізнавання значенні КФЕ $\bar{E}^* = 0,37$. Недостатньо високе значення КФЕ навчання СППР пояснюється неоптимальною системою контрольних допусків на ознаки розпізнавання, яка застосовувалася при формуванні бінарної навчальної матриці. Тому згідно з принципом відкладених рішень Івахненка О. Г.

ВИСНОВКИ

1. Реалізація у рамках ІЕІ-технології алгоритму навчання інформаційно-аналітичної системи оцінки якості навчального контенту випускової кафедри, що функціонує в режимі моніторингу, дозволяє будувати вирішальні правила шляхом цілеспрямованого пошуку глобального максимуму інформаційного критерію в робочій (допустимій) області визначення його функції.

2. Для підвищення функціональної ефективності навчання інформаційної системи оцінювати поточний стан навчального контенту кафедри необхідно оптимізувати інші параметри функціонування, наприклад, систему контрольних допусків на ознаки розпізнавання.

4.6 АВТОМАТИЗАЦІЯ ПОБУДОВИ ПРЕДМЕТНОЇ ГАЛУЗІ КУРСІВ У РАМКАХ СИСТЕМИ ДИСТАНЦІЙНОГО НАВЧАННЯ

Одним з ключових компонентів моделі адаптивної системи дистанційного навчання (аСДН) є модель предметної галузі. Структура моделі та якість наповнення цього компоненту є важливими при побудові аСДН на основі СДН, що не має таких властивостей, бо обумовлюють перелік підходів до адаптації, які можуть бути застосовані. Тому в рамках вирішення задачі побудови аСДН на основі СДН СумДУ була розроблена модель предметної галузі навчальних курсів та реалізовано сервіс імпорту нових та адаптації існуючих матеріалів.

В рамках дослідження модель предметної області представлена множиною типізованих понять. Поняття курсу поділяються на загальнонаукові та предметно-орієнтовані. Між поняттями можуть встановлюватись відношення синонімії. Інші типи зв'язків не передбачені.

Контент у СДН СумДУ представлено набором пов'язаних гіпертекстових об'єктів. Для зв'язування понять та окремих навчальних об'єктів запроваджено спеціалізований сервіс. Вважається, що один об'єкт може бути проіндексований кількома поняттями. Виходячи з гіпотези про логічність впорядкованості навчальних матеріалів курсу сервіс дозволяє спрогнозувати роль поняття в об'єкті: об'єкт потребує попереднього ознайомлення з поняттям чи поняття вводиться у ньому вперше. При підготовці до використання в аСДН під час завантаження навчальних об'єктів проводиться їх аналіз. Алгоритм роботи сервісу «Аналіз документів» представлений на рис.4.19. Для аналізу використовуються документи у форматі html. Якщо документ представлений в інших форматах (odt, doc), попередньо застосовується сервіс перетворення документів.

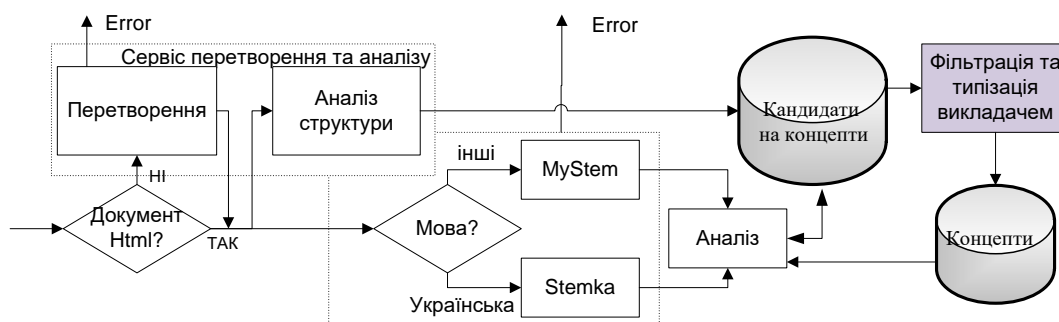


Рисунок 4.19– Структурна схема сервісу аналізу документів

Аналіз документа проводиться у два етапи. По-перше, на основі структурних особливостей документа сервіс аналізу структури намагається виділити в документі визначення або ключові слова [1]. Оптимальним у цьому випадку є варіант, коли документ доповнено метаінформацією щодо ключових слів. Такі ключові слова позначаються як вихідні поняття. На другому етапі проводиться аналіз документа на основі морфологічного розбору та виділення кандидатів на ключові слова, використовуючи базу відомих

понять. При цьому використовуються модулі сторонніх розробників MyStem [2] та Stemka [3]. Поняття, виділені через перелік ключових слів та на основі аналізу документа, заносяться в таблицю кандидатів. Аналізуючи таблицю кандидатів, автор навчального об'єкта може уточнити тип поняття (предметно-орієнтоване чи загальнонаукове) та його роль (поняття є базовим чи результуючим для тексту, що аналізується).

Поняття, його тип та зв'язки із документом зберігаються у глобальному сховищі. Схема частини бази даних, що відповідає за збереження понять, представлена на рис.4.20. Урахування синонімії понять реалізовано через зв'язок `parent_id`→`term_id` у таблиці `Terms.Term`. Сховище кандидатів реалізовано виділенням частки таблиці (partition) `Terms.TermUsage` за критерієм (`is_visible = false`).




Рисунок 4.20– Схема таблиць БД, пов'язаних із збереженням понять

Первинне наповнення глобального сховища понять було виконано за допомогою розбору глосаріїв курсів. Це гарантувало, що терміни, які були заздалегідь виділені автором, обов'язково потраплять до онтології понять дисципліни, що обробляється. Після розбору окремих документів проводиться формальна перевірка повноти курсу із застосуванням авторського підходу [4].

Запроваджений сервіс використовується при розробці навчальних курсів у СДН СумДУ та є органічним доповненням нового модуля розробки навчальних курсів, у якому провідну роль відведено самим авторам курсів. Подальшими напрямками роботи є підвищення точності виділення понять та розширення переліку форматів, що підтримуються.

ВИСНОВКИ

При виконанні НДР розв'язано важливі науково-практичні задачі підвищення функціональної ефективності систем підтримки прийняття рішень в різних галузях промисловості та освіти. Головні наукові та практичні результати роботи полягають у такому:

1. Проаналізовано сучасний стан розвитку систем підтримки прийняття рішень, які функціонують за умов апріорної невизначеності даних, і встановлено, що основною тенденцією їх подальшого розвитку є створення і застосування інтелектуальних інформаційних технологій на основі машинного навчання та розпізнавання образів.

2. Отримала подальший розвиток так звана інформаційно-екстремальної інтелектуальної технології аналізу даних, яка ґрунтується на максимізації інформаційної спроможності системи підтримки прийняття рішень в процесі машинного навчання.

3. Вперше розроблено модель і метод машинного навчання системи радіонуклідного діагностування патологій за кількісними та категорійними вхідними ознаками на базі ієрархічної структури контейнерів класів розпізнавання і багатоінтервальної системи контрольних допусків на різнотипні вхідні дані, що дозволило в процесі машинного навчання за вибірковими даними з довільною конфігурацією нечіткої компактності образів побудувати високодостовірні вирішальні правила.

4. Вперше розроблено новий інформаційно-екстремальний метод аналізу і синтезу здатної самонавчатися СППР на базі контейнерів циліндроїдної форми та трьохальтернативної системи оцінки прийняття рішень, що включає комплекс категорійних моделей, критеріїв оцінки функціональної ефективності і алгоритмів оптимізації параметрів функціонування, використання якого дозволило надати системі властивість

адаптивності при її функціонуванні через відсутність поточного вхідного контролю сировини та матеріалів, інформаційних та ресурсних обмежень.

5. Вперше розроблено модель і метод машинного навчання системи діагностування інфекційних патологій з оптимізацією коефіцієнта надлишковості в інформаційному розумінні бінарної навчальної матриці, що дозволило в процесі машинного навчання за розріженими векторами-реалізаціями класів розпізнавання, що має місце в практичних задачах діагностування функціонального стану патологічного процесу, побудувати високодостовірні вирішальні правила.

6. В рамках інформаційно-екстремальної технології синтезовано вирішальні правила з багаторівневою системою вкладених контрольних допусків на значення ознак розпізнавання. При цьому для обробки різнотипних ознак розпізнавання запропоновано використовувати частотне перекодування категоріальних ознак. За результатами фізичного моделювання з використанням даних сцинтиграфії міокарда та контекстних даних, що характеризують симптоми, наявність хронічних хвороб та шкідливих звичок підтверджено можливість побудови безпомилкових за навчальною вибіркою вирішальних правил.

7. Запропоновано в рамках ІЕІ-технології аналізу даних метод глибокого машинного навчання СППР для керування енергоблоком теплоелектроцентралі. При цьому в процесі машинного навчання здійснювалася оптимізація системи контрольних допусків на ознаки розпізнавання і рівнів селекції координат усереднених векторів-реалізацій класів розпізнавання, що дозволило побудувати безпомилкові за навчальною матрицею вирішальні правила.

8. Запропоновано алгоритм побудови вектора ознак розпізнавання, заснований на використанні вейвлетів Габора і не зв'язаний з конкретним типом розпізнаваних об'єктів.

9. Розроблено новий метод ієрархічного інформаційно-екстремального машинного навчання системи функціонального діагностування ШПМ з

ієрархічною структурою даних, який дозволяє підвищити достовірність діагностування та зменшити чутливість системи до збільшення потужності алфавіту класів розпізнавання. У рамках розробленого методу запропоновано категорійну модель інформаційно-екстремального машинного навчання з ієрархічною структурою даних, яка є композицією контурів оптимізації параметрів навчання за інформаційним критерієм. Згідно з категорійною моделлю розроблено алгоритм інформаційно-екстремального ієрархічного машинного навчання, який полягає в ітераційному наближенні усередненого за алфавітом класів розпізнавання значення інформаційного критерію оптимізації параметрів навчання до максимального граничного.

10. У рамках ІЕІ-технології розроблено інформаційне, алгоритмічне та програмне забезпечення інформаційно-аналітичної системи оцінки якості навчального контенту за трьохалтернативною системою оцінок: «Відмінно», «Задовільно» і «Незадовільно» на базі інформаційно-екстремального класифікатора з вкладеними контейнерами. Розроблена інформаційно-аналітична система дозволяє автоматизувати інформування осіб, відповідальних за супроводження навчальних матеріалів, про необхідність оновлення, стиснення, ліквідації чи реорганізації відповідного контенту.

ПЕРЕЛІК ПОСИЛАНЬ

Розділ 1.1

1. Авраменко В.В. Характеристики непропорциональности числовых функций и их применение. Деп. В ГНТБ Украины 19.01.98, N59- Ук98.
2. Авраменко В.В., Характеристики непропорциональности числовых функций и их применения при решении задач диагностики. // Вісник СумДУ, 2000, N16
3. Авраменко В.В., Карпенко А.П., Распознавание фрагментов заданных эталонов в анализируемом сигнале с помощью функций непропорциональностей. // Вісник СумДУ, 2002, N1 (34)ʹ.
4. Мелентьев П.В., Приближенные вычисления. – М.: Государственное издательство физико-технической литературы, 1962ю – 388 с.

Розділ 1.2

1. Lawrence S., Giles C. L., Tsoi A. C. and Back A. D. Face Recognition: A Convolutional Neural Network Approach. IEEE Transactions on Neural Networks, Special Issue on Neural Networks and Pattern Recognition, pp. 1-24.
2. В. Кепенекци. Face Recognition Using Gabor Wavelet Transform. A thesis submitted to the graduate school of natural sciens of the Middle East Technical University, September 2001.
3. L. Wiskott, J. M. Fellous, N. Kruger, C. Malsburg, Face Recognition by Elastic Bunch Graph Matching, IEEE Trans. on. PAMI, 19(7): pp.775-779, 1997.
4. The ORL Database of Faces
http://www.cl.cam.ac.uk/Research/DTG/attarchive:pub/data/att_faces.tar.Z.

Розділ 1.3

1. Cios K. J. A novel algorithm for classification of spect images of a human heart [Text] / K. J. Cios, L. S. Goodenday, K. K. Shah, G. Serpen // Proceedings Ninth IEEE Symposium on Computer-Based Medical Systems, 17 Jun 1996-18 Jun 1996. – Ann Arbor, MI : IEEE Press. – 1996. – P. 1-5.

2. Ohlsson M. WeAidU—a decision support system for myocardial perfusion images using artificial neural networks [Text] / M. Ohlsson // *Artificial Intelligence in Medicine*. – Tecklenburg, Germany: Burgverlag. – 2004. – Vol. 30, I. 1. – P. 49-60, doi:10.1016/s0933-3657(03)00050-2.

3. Šajin L. Image processing and machine learning for fully automated probabilistic evaluation of medical images [Text] / L. Šajin, M. Kukar // *Journal Computer Methods and Programs in Biomedicine*. – New York, NY, USA : Elsevier North-Holland Inc. – 2011. – Vol. 104, I. 3. – P. e75-e86, doi:10.1016/j.cmpb.2010.06. 021.

4. Synefia S. 3D images quantitative perfusion analysis and myocardium polar index for cardiac scintigraphy improvement [Text] / S. Synefia, M. Sotiro-poulos, M. Argyrou, M. Bella, I. Floros, A. Valasi, M. Lyra // *e-Journal of Science & Technology*. – Athens, Greece : e-JST. – 2014. – No 3(9). – P. 35-41.

5. Wadhonkar B. M. A data mining approach for classification of heart disease dataset using neural network [Text] / B. M. Wadhonkar, P. A. Tijare, S. N. Sawalkar // *International Journal of Application or Innovation in Engineering & Management (IJAIEM)*. – New Delhi, India : IJAIEM. – 2015. – Vol. 4, I. 5. – P. 426-433.

6. Arsanjani R. Prediction of revascularization after myocardial perfusion SPECT by machine learning in a large population [Text] / R. Arsanjani, D. Dey, T. Khacha-tryan, A. Shalev, S. W. Hayes [et al]. // *Journal of Nuclear Cardiology*. – 2015. – Vol. 22, I. 5. – New York : Springer. – P. 877-884. doi: 10.1007/s12350-014-0027-x.

7. Moskalenko V.V. Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes [Text] / A. S. Dovbysh, N.N. Budnyk, V.V. Moskalenko // *Journal of automation and information sciences*. – New York : Begell House Inc. – 2012. – V.44, I.10. – P. 35-44. doi:10. 1615/jautomatinfscien.v44.i10.30.

8. Dovbysh A. S. Intelligent Decision Support System for Medical Radioisotope Diagnostics with Gamma-camera [Text] / A. S. Dovbysh,

V. V. Moskalenko, A. S. Rizhova, O. V. Dyomin // Journal of Nano- and Electronic Physics. – Sumy, Ukraine : Sumy State University. – 2015. – Vol.7, No 4. – P. 04036-1-04036-7.

9. Rizhova A.S. Information Extreme Method for Classification of observations with categorical attributes [Text] / A. S. Rizhova, V. V. Moskalenko, A. S. Dov-bysh. // Cybernetics and Systems Analysis. – Berlin-Heidelberg : Springer-Verlag. – 2016. – V.52, №2. – p. 35-42.

Розділ 1.4

1. Ивахненко А.Г. О принципах построения обучающихся систем управления сложными процессами [Текст] / А.Г. Ивахненко. – М.: Наука, 1970. – 252 с.

2. Цыпкин Я.З. Основы информационной теории идентификации [Текст] / Я.З. Цыпкин. – М.: Наука, 1984.– 320 с.

3. Васильев В. И. Распознающие системы. Справочник. 2-е изд., перераб. и доп. [Текст] / В.И. Васильев. – Киев: Наукова думка, 1983.– 422 с.

4. *Путятин Е.П., Аверин С.И.* Обработка изображений в робототехнике [Текст] / Е.П. Путятин, С.И. Аверин. – М: Машиностроение, 1990. – 320 с.

5. Краснополюсовський А.С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань [Текст] / А.С. Краснополюсовський – Суми: Видавництво СумДУ, 2004. – 261 с.

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

7. Довбиш А.С. Оптимізація параметрів навчання СППР для діагностування онкопатологій [Текст] / А.С. Довбиш., М.С. Руденко // Вісник СумДУ. Серія: Технічні науки. – 2010. – №2. – С. 48-55.

Розділ 1.5

1. Шелехов І.В. Оптимізація параметрів навчання комп'ютеризованої системи діагностування емоційно-психічного стану людини / І.В. Шелехов,

Д.В. Прилепа // Радиоелектронні і комп'ютерні системи. – 2014. – №1(65). – С. 161-167.

2. Ануашвили А.Н. Объективная психология на основе волновой модели мозга / А.Н. Ануашвили - Москва: Экон-Информ, 2008. – 292 с.

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

4. Люггер, Дж.Ф. Искусственный интеллект. Стратегии и методы решения сложных проблем / Дж.Ф. Люггер. – Москва, Санкт-Петербург, Киев: Издательство «Вильямс», 2003. – 864 с.

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

6. Довбиш А.С. Інтелектуальні інформаційні технології в електронному навчанні / А.С. Довбиш, А.В. Васильєв, В.О. Любчак. – Суми: Видавництво СумДУ. – 2014. – 172 с.

7. Комп'ютеризована системи діагностування емоційно-психічного стану людини за фрагментами зображення обличчя: матеріали третьої міжнародної науково-практичної конференції (Суми, 14-16 травня 2014 р.) / І.В. Шелехов, Д.В. Прилепа // Advanced information systems and technologies, AIST. – 2014. – С. 118-119.

Розділ 1.6

1. Ануашвили А.Н. Объективная психология на основе волновой модели мозга. [Текст] / А.Н. Ануашвили // Экон-Информ. – Москва, 2008. – 292 с.

2. Анисимов Б. В. Распознавание и цифровая обработка изображений [Текст] / Б. В. Анисимов, В. Д. Курганов, В. К. Злобин.– М.: Высшая школа. – 1983. – 256 с.

3. Загоруйко Н.Г. Алгоритмы обнаружения эмпирических закономерностей [Текст] / Н.Г. Загоруйко, В.Н. Елкина, Г.С. Лбов // Наука. – Новосибирск, 1985. – 110 с.

4. Джордж Ф. Люггер. Искусственный интеллект. Стратегии и методы

решения сложных проблем [Текст] / Ф. Люггер Джордж. – Москва, Санкт-Петербург, Киев: Издательство «Вильямс» – Москва, Санкт-Петербург, Киев. – 2003. – 864 с.

5. Краснополюсовський А.С. Інформаційний синтез інтелектуальних систем керування: Підхід, що ґрунтується на методі функціонально-статистичних випробувань [Текст] / А.С. Краснополюсовський // Видавництво СумДУ. – Суми, 2004. – 261 с.

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

7. Дмитриев А. К. Основы теории построения и контроля сложных систем [Текст] / А. К. Дмитриев, П. А. Мальцев. – Л.: Энергоатомиздат. Ленингр. отд-ние. – 1988. – 192 с.

Розділ 1.7

1. Попов Ю. В. Проблемы повышения эффективности шахтных многоканатных подъемных установок с наземным расположением подъемных машин [Текст] / Ю. В. Попов, С. А. Тимухин, Е. Л. Садыков // Известия УГГУ. – 2010. – №24 – С. 59 – 67.

2. Озорнин С. П. Совершенствование организации мониторинга изменений технического состояния машин в эксплуатации [Текст] / С. П. Озорнин, И. Е. Бердников // Вестник ЗабГУ. – 2014. – №8. – С. 64 – 69.

3. Сидельников Л.Г. Обзор методов контроля технического состояния асинхронных двигателей в процессе эксплуатации [Текст] / Л. Г. Сидельников, Д.О. Афанасьев // Вестник ПНИПУ. Геология. Нефтегазовое и горное дело. – 2013. – №7. – С.127 – 137.

4. Bhowmik, P. S., Pradhan, S., Prakash, M. Faultdiagnostic and monitoring methods of induction motor: a review [Text]. International Journal of Applied Control, Electrical and Electronics. – 2013. – Vol. 1, pp. 1 – 18.

5. Andrzej O., Zygmunt S. Modern Methods Control and Diagnostics of Hoisting-Machines with Application of Artificial Intelligence Methods [Text].

Archives of Mining Sciences. – 2010, vol. 55, no. 1, pp. 217-231.

6. Сидоренко В. Н., Мониторинг мощных электроприводов на основе технологии data mining / В. Н. Сидоренко, А. П. Черный // Электротехнические и компьютерные системы. – 2011. – №3.– С. 414–416.

7. Szymański, Z. Intelligent, Energy Saving Power Supply and Control System of Hoisting Mine Machine with Compact and Hybrid Drive System / Szymański, Z., Układy Zasilania I Sterowania Górniczych Maszyn Wyciągowych Z Napędem Zintegrowanym Lub Hybrydowym [Text] // Archives of Mining Sciences, 2017. – V.60(1), pp. 239-251. DOI:10.1515/amsc-2015-0016

8. Ching-Lien Huang, Tsung-Shin Hsu, Chih-Ming Liu. The Mahalanobis-Taguchi system - Neural network algorithm for data-mining in dynamic environments [Text]. Expert Systems with Applications: An International Journal. – 2009. – Vol. 36, issue 3. pp. 5475-5480. DOI 10.1016/j.eswa.2008.06.120

9. Subbotin S. The neuro-fuzzy network synthesis and simplification on precedents in problems of diagnosis and pattern recognition [Text]/ S. Subbotin // Optical Memory and Neural Networks (Information Optics). – 2013. – Vol. 22, № 2. – P. 97 – 103. DOI:: 10.3103/s1060992x13020082

10. Hasan A. Yousef, Manal Wahba A. Adaptive fuzzy mimo control of induction motors [Text]. Expert Systems with Applications: An International Journal. – 2009. – vol. 36, issue 3, pp. 4171 – 4175. DOI 10.1016/j.eswa.2008.04.004

11. Dovbysh, A.S., . Budnyk, M. M., Moskalenko, V. V. Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes [Text]. Journal of automation and information sciences. – New York: Begell House Inc., 2012, v. 44, i.10, pp. 35-44. DOI: 10.1615/JAutomatInfScien.v44.i10.30

12. Dovbysh, A.S., Martynenko, S. S., Kovalenko, A. S., Budnyk, M. M. Information-extreme algorithm for recognizing current distribution maps in magnetocardiography [Text]. Journal of Automation and Information Sciences , 2011.– V. 43.– № 2.– pp. 63-70. DOI: 10.1615/JAutomatInfScien.v43.i2.60.

13. Moskalenko, V. V., Pimonenko, S. V. Optimizing the parameters of functioning of the system of management of data center IT infrastructure [Text]. Eastern-European Journal of Enterprise Technologies., 2016. – Vol. 5, No. 3 (83), pp. 21–29. DOI: 10.15587/1729-4061.2016.79231.

14. Довбиш А.С. Інформаційно-екстремальний алгоритм навчання системи функціонального контролю електроприводу шахтної підйомної машини [Текст] /А. С, Довбиш, В. І. Зимовець, З. С. Козлов // Радиоэлектроника и информатика, 2017. – №4. – С. 58 – 63.

Розділ 1.8

1. A. S. Khashandarag, M. Mirnia, and A. Sakhavati, "A New method for medical image clustering using genetic algorithm," IJCSI International journal of computer science issues, vol. 10, i 1, no. 1, pp. 381-393, 2013.

2. A. S. Silva, F. M. Q Severgnini, M. P Oliveira, V. M. S. Mendes, Z. M. A. Peixoto, "Object Tracking by Color and Active Models Segmentation", IEEE Latin America Transactions, no 14(3), pp. 1488 – 1493, 2016.

3. S. Subbotin, "The neuro-fuzzy network synthesis and simplification on precedents in problems of diagnosis and pattern recognition", Optical Memory and Neural Networks (Information Optics), vol. 22, no 2, pp. 97–103, 2013. DOI: 10.3103/s1060992x13020082

4. A. S. Dovbysh, V. V. Moskalenko, A. S. Rizhova, "Information-Extreme Method for Classification of Observations with Categorical Attributes", Cybernetics and Systems Analysis, vol. 52 (2), pp. 224-231, 2016. DOI: 10.1007/s10559-016-9818-1

5. A. S. Dovbysh, S. S. Martynenko, A. S. Kovalenko, N. N. Budnyk, "Information-extreme algorithm for recognizing current distribution maps in magnetocardiography", Journal of Automation and Information Sciences, vol.43, issue 2, pp.. 63-70. DOI: 10.1615/JAutomatInfScien.v43.i2.60

6. O. S. Kuzenko, L. B. Kascheev, M. I. Mironenko, "Geo-informational system of identification the frames for area reconstruction", Bulletin of NTU "KhPI". Series:

System analysis, control and information technology. – Kharkiv : NTU "KhPI", no. 46, pp. 2017.

Розділ 1.10

1. Еремин Е. Л. Адаптивное и робастное управление объектами теплоэнергетики / Е. Л. Еремин, Д. П. Темченко. – Благовещенск : Амурский гос. ун-т, 2009. – 228 с.

2. Dorf R.C. Modern Control Systems / R.C. Dorf, R. H. Bishop // Prentice Hall, 2011. – 1082 p.

3. Han J. Data mining: concepts and techniques. – 3rd ed. / J. Han, M. Kamber, J. Pei. – Morgan Kaufmann / Elsevier, 2012. – 744 p.

4. Субботин С. А. Интеллектуальные информационные технологии проектирования автоматизированных систем диагностирования и распознавания образов: Монография / С. А. Субботин, Ан. А. Олейник, Е. А. Гофман, С. А. Зайцев, Ал. А. Олейник; под ред. С. А. Субботина. – Харьков: Компания СМІТ. – 2012. – 318 с.

5. Campbell C. Learning with Support Vector Machines / C. Campbell, Y. Ying. – Morgan and Claypool, 2011. – 95 p.

6. Satish Kumar A Survey on Artificial Intelligence Techniques in Power Station / Kumar Satish, Cherukuri Ravali // International Journal of Innovative Research in Science, Engineering and Technology, 2017. – Vol. 6, Issue 1. – P. 852–861.

7. Sai T.K. Fuzzy applications in a power station / T.K Sai and K.A. Reddy // International Journal on Soft Computing (IJSC), 2015.– Vol.6, No. 2. – P. 1–16.

8. Довбиш, А. С. Основи проектування інтелектуальних систем: навчальний посібник [Текст] / А. С. Довбиш // Вид-во СумДУ. - 2009. – 171 с.

9. Довбиш, А. С. Інтелектуальні інформаційні технології в електронному навчанні [Текст] / А. С. Довбиш, А. В. Васильєв, В. О. Любчак // Суми: Видавництво СумДУ. - 2014. – 172 с.

10. Довбиш А. С. Оптимізація параметрів навчання системи керування енергоблоком теплоелектроцентралі / А. С. Довбиш, М. В. Бібик, А. С. Рудий

// Компрессорное и энергетическое машиностроение, 2015. – №3(41). – С. 37 – 40.

11. Куценко О. С. Геоінформаційна система ідентифікації кадрів при реконструюванні місцевості / О. С. Куценко, Б. Л. Кащєєв. М. І. Мироненко // Вісник НТУ «ХПІ». Серія : Системний аналіз, управління та інформаційні технології. – Харків: НТУ «ХПІ», 2017. –№ 46(1218). – С. 53 – 61.

Розділ 2.1

1. Авраменко В.В. Характеристики непропорциональности числовых функций и их применение. Деп. В ГНТБ Украины 19.01.98, N59- Ук98.

2. Авраменко В.В., Характеристики непропорциональности числовых функций и их применения при решении задач диагностики. // Вісник СумДУ, 2000, N16

3. Авраменко В.В., Карпенко А.П., Распознавание фрагментов заданных эталонов в анализируемом сигнале с помощью функций непропорциональностей. // Вісник СумДУ, 2002, N1 (34)ʹ.

4. Мелентьев П.В., Приближенные вычисления. – М.: Государственное издательство физико-технической литературы, 1962ю – 388 с.

Розділ 2.2

9. VPN Protocols [Electronic resource] // VPN Consortium. – 1999 – 2014. – Mode of access: <http://www.vpnc.org/vpn-standards.html#Key>.

10.От ARPAnet до INTERnet (краткая история Интернета) [Электронный ресурс] / А. Прохоров // Интернет-издание «КомпьютерПресс». – 2014. – Режим доступа: <http://compress.ru/article.aspx?id=9708>.

11.Криптографические алгоритмы [Электронный ресурс] /Б. Ключевский // Электронная библиотека InfoCity. – 2009. - Режим доступа: <http://infocity.kiev.ua/hack/content/hack021.phtml>.

12.Шифрование в компьютерной сети [Электронный ресурс] / DesCrypto - статьи о защите данных и криптографии. – 2008. - Режим доступа: <http://www.des-crypto.ru/cryptography/shifrovanie/>.

13. Системы шифрования в компьютерных сетях (Последняя линия обороны администраторов и пользователей от злоумышленника) [Электронный ресурс] // Кафедра ОПДС СПб ГУТ. – 2012. Режим доступа: www.opds.sut.ru/old/electronic_manuals/it_emd/tema_6/sist_shifr.doc.
14. Котухов М.М. Информационная безопасность: учебное пособие / М.М. Котухов, А.Н. Кубанков, А.О. Калашников. – 2009. – 195 с.
15. VPN Technologies: Definitions and Requirements [Electronic resource] // VPN Consortium. – 2008. - Mode of access: <http://www.vpn-c.org/vpn-technologies.html>.
16. Запечников С.В. Основы построения виртуальных частных сетей: учебное пособие / С.В. Запечников, Н.Г. Милославская, А.И. Толстой. - Горячая линия – Телеком, 2003. – 249 с.
17. Браун С. Виртуальные частные сети VPN / С. Браун. – 2001. – 504 с.
18. What is GNS3 ? [Electronic resource] // GNS3: Graphical Network Simulator. – 2007. Mode of access: <http://www.gns3.net/>.
19. GNS3 - Графический Сетевой Симулятор [Электронный ресурс] // CiscoLab.RU » Лаборатория CiscoLAB. – 2014. – Режим доступа: <http://www.ciscolab.ru/labs/40-gns3-graficheskiy-setevoy-simulyator.html>.
20. IPSEC как протокол защиты сетевого трафика [Электронный ресурс] // CiscoLab.RU » Лаборатория CiscoLAB. – 2013. - Режим доступа: <http://www.ciscolab.ru/security/15-ipsec-kak-protokol-zaschity-setevogo-trafika.html>.
21. Защита на сетевом уровне (Протокол IPSEC) [Электронный ресурс] // Your Private Network - Лаборатория Сетевой Безопасности. – 2014. - Режим доступа: <http://ypn.ru/category/internetworking-security/networking-layer-securing-ipsec/>.
22. Biryukov A. Related-key Cryptanalysis of the Full AES-192 and AES-256 / A. Biryukov, D. Khovratovich // Advances in Cryptology – ASIACRYPT. - 2009.
23. Daemen J. AES Proposal: Rijndael / J. Daemen, V. Rijmen // AES Algorithm Submission. - 1999.

24. Nechvatal J. Report on the Development of the Advanced Encryption Standard (AES) / J. Nechvatal // National Institute of Standards and Technology. - 2000.
25. Настройка GRE туннеля между маршрутизаторами Cisco (cisco tunnel gre) [Электронный ресурс] / А. Нижегороденко // Opennet.ru. – 2007. Режим доступа: http://www.opennet.ru/base/cisco/gre_cisco_tun.txt.html.
26. Generic Routing Encapsulation, создание GRE туннелей [Электронный ресурс] // Удаленное администрирование серверов. Настройка, оптимизация, поддержка. – 2013. Режим доступа: <http://vds-admin.ru/networks/gre-generic-routing-encapsulation-sozdanie-tunnelei>.
27. Wireshark — приручение акулы [Электронный ресурс] // Блог компании PentestIT, Сетевые технологии*, Информационная безопасность*. – 2013. Режим доступа: <http://habrahabr.ru/company/pentestit/blog/204274/>.
28. WireShark [Электронный ресурс] / М.Максимова // База знаний кафедры ИКТ. – 2011. Режим доступа: <http://wiki.auditory.ru/%D0%A3%D1%87%D0%B0%D1%81%D1%82%D0%BD%D0%B8%D0%BA:Marina.Maximova/%D0%97%D0%98/Wireshark>.
29. Жидецький В.Ц. Охорона праці користувачів комп'ютерів. – Львів: Афіша, 2001. – 176 с.
30. Трахтенберг І.М., Коршун М.М., Чебанова О.В. Гігієна праці та виробнича санітарія. – К., 1997.
31. Бедрій Я.І. Охорона праці: Навчальний посібник. – К.: ЦУЛ, 2002. -322 с.

Розділ 2.4

1. Zander S. Automated Traffic Classification and Application Identification using Machine Learning / S. Zander, T. Nguyen, G. Armitage // Proceedings of the IEEE Conference on Local Computer Networks 30th Anniversary. – 2005. – Sydney : IEEE Press. –P. 250-257.
2. Pedro M. Santiago del Rio. Internet Traffic Classification for High-Performance and Off-The-Shelf Systems / Pedro Maria Santiago del Rio // Ph.D. Thesis.–2013. –Madrid, Spain : Technical University of Madrid. –217 p.
3. Raman Singh. Issue related to sampling techniques for network traffic

dataset / Raman Sigh, Harish Kumar, R.K. Singla // *International Journal of Mobile Network Communications & Telematics*. – 2013. – Sydney, Australia : WSP. – Vol.3., No.4. – P. 75-85.

4. Iacovazzi A. Network Communication Privacy: Traffic Masking against Traffic Analysis / Alfonso Iacovazzi // Ph.D. Thesis. – 2013. – Rome, Italy: Sapienza University of Rome. – 119 p.

5. Bujlow T. Volunteer-Based System for classification of traffic in computer networks / T. Bujlow, K. Balachandran, M.T. Riaz, J.M. Pedersen // In Proceedings of 19th Telecommunications Forum TELFOR 2011'. – 2011. – Sydney : IEEE Press. – P. 210-213.

6. Москаленко В.В. Ієрархічний інформаційно-екстремальний класифікатор / В.В. Москаленко, С.А.С.М. Джулгам // *Радіоелектронні і комп'ютерні системи*. – Харків : НАКУ «ХАІ». – 2012. – №3(55). – С. 86-93.

7. Moskalenko V.V. Information-Extreme Algorithm for Optimizing Parameters of Hyperellipsoidal Containers of Recognition Classes / A.S. Dovbysh, N.N. Budnyk, V.V. Moskalenko // *Journal of automation and information sciences*. – New York : Begell House Inc. – 2012. – V.44, I.10. – P. 35-44.

8. Довбиш А.С. Основи проектування інтелектуальних систем / А.С. Довбиш. – Суми : СумДУ. – 2009. – 171 с.

9. Markowsky G. Who's Knocking at Your Cybercastle's Gate? / G. Markowsky, L. Markowsky // In Proceedings of International Conference on Security and Management. – 2012. – Las Vegas Nevada, USA : DCSREA Press. – P. 206-212

Розділ 2.5

1. Cao, Z. Dynamic VM consolidation for energy-aware and SLA violation reduction in cloud computing [Text] / Z. Cao, S. Dong // Proceedings of the 13th International Conference on Parallel and Distributed Computing, Applications and Technologies. – Beijing, China : Higher Education Press, 2012. – P. 363–369.

2. Sharma, B. Applications of Data Mining in the Management of Performance and Power in Data Centers / B. Sharma // Technical Report, Department of Computer Science and Engineering. The Pennsylvania State University. – 2009. – P. 1–5.
3. Caglar, F. Towards a performance interference-aware virtual machine placement strategy for supporting soft real-time applications in the cloud [Text] / F. Caglar, S. Shekhar, A. Gokhale // Proceedings of the 3rd International Workshop on Real-time and Distributed Computing in Emerging Applications. – NY, USA : ACM, 2014. – P. 15-20.
4. Delimitrou, C. Paragon: QoS-aware scheduling for heterogeneous datacenters [Text] / C. Delimitrou, C. Kozyrakis // Proceedings of the 18th international conference on Architectural support for programming languages and operating systems. – NY, USA : ACM, 2013. – Vol. 41. – P. 77–88. DOI:10.1145/2499368.2451125.
5. Hayashi, T. Performance Degradation Detection of Virtual Machines via Passive Measurement and Machine Learning [Text] / T. Hayashi, S. Ohta // International Journal of Adaptive, Resilient and Autonomic Systems. – 2014. – Vol. 5(2). – P. 40–56.
6. Bodik, P. Fingerprinting the Datacenter: Automated Classification of Performance Crises [Text] / P. Bodik, M. Goldszmidt, A. Fox, D. B. Woodard [et al.] // Proceedings of the 5th European conference on Computer systems. – NY, USA : ACM, 2010. – P. 111–124.
7. Nanduri, R. Job Aware Scheduling Algorithm for MapReduce Framework [Text] / R. Nanduri, N. Maheshwari, R. Raja, V. Varma // 3rd IEEE International Conference on Cloud Computing Technology and Science. – Institute of Electrical and Electronics Engineers (IEEE), 2011. – P. 724-729.
8. Kandalintsev, A. Profiling Cloud Applications with Hardware Performance Counters [Text] / A. Kandalintsev, R. L. Cigno, D. Kliazovich, P. Bouvry // The International Conference on Information Networking. – 2014. – P. 52–57.

9. Dovbysh, A. S. Information-Extreme Method for Classification of Observations with Categorical Attributes [Text] / A. S. Dovbysh, V. V. Moskalenko, A. S. Rizhova // Cybernetics and Systems Analysis. – 2016. – Vol. 52, Issue 2. – P. 224–231. DOI: 10.1007/s10559-016-9818-1.
10. Dovbysh, A. S. Learning decision making support system for control of nonstationary technological process [Text] / A. S. Dovbysh, V. V. Moskalenko, A. S. Rizhova // Journal of automation and information sciences. – 2016. – Vol. 48, Issue 6. – P. 39–48. DOI: 10.1615/JAutomatInfScien.v48.i6.40.
11. Chen, L. MTAD: A Multitarget Heuristic Algorithm for Virtual Machine Placement [Text] / L. Chen, J. Zhang, L. Cai, R. Li, T. He, T. Meng // International Journal of Distributed Sensor Networks. – 2015. – V. 2015. – P. 14. DOI:10.1155/2015/679170.
12. Salmasnia, A. A new desirability function-based method for correlated multiple response optimization [Text] / A. Salmasnia, M. Bashiri // The International Journal of Advanced Manufacturing Technology. – 2015. – V. 76, I. 5. – P. 1047–1062.
13. Altinoz, O. T. A multiobjective optimization approach via systematical modification of the desirability function shapes [Text] / O. T. Altinoz, A. E. Yilmaz, G. Ciuprina // 8th International symposium on advanced topics in electrical engineering. – Institute of Electrical and Electronics Engineers (IEEE), 2013. – P. 1–6.
14. Sanginova, O. Comparative analysis of some computational schemes for obtaining a compromise solution [Text] / O. Sanginova // Eastern-European Journal of Enterprise Technologies. – 2015. – Vol. 1/4 (73). – P. 10–18. DOI: 10.15587/1729-4061.2015.35607
15. Shengnan, Z. Multi-response robust design based on improved desirability function [Text] / Z. Shengnan, W. Jianjun // International Conference on Grey Systems and Intelligent Services. – Institute of Electrical and Electronics Engineers (IEEE), 2015. – P. 515–520. DOI: 10.1109/GSIS.2015.7301911.

16. Kushwaha, S. A Modified Desirability Function Approach for Mean-Variance Optimization of Multiple Responses [Text] / S. Kushwaha, S. Sikdar, I. Mukherjee, P. K. Ray // International Journal of Software Science and Computational Intelligence. – 2013. – Vol. 5, Issue 3. – P. 7–21. DOI: 10.4018/ijssci.2013070101.
17. Yoo, D. G. Rehabilitation Priority Determination of Water Pipes Based on Hydraulic Importance [Text] / D. G. Yoo, D. Kang, H. Jun, J. H. Kim // Water. – 2014. – No 6. – P. 3864–3887. DOI:10.3390/w6123864.
18. Parpinelli, R. Theory and New Applications of Swarm Intelligence [Text] / R. Parpinelli. – InTech, 2012. – 204 p. DOI: 10.5772/1405.
19. Jain, S. A Comparative Study for Cloud Computing Platform on Open Source Software [Text] / S. Jain, R. Kumar, Anamika, S. K. Jangir // An International Journal of Engineering & Technolog. – 2014. – Vol. 1, No. 2. – P. 28–34.
20. Kaur, A. Energy optimized VM placement in cloud environment [Text] / A. Kaur, M. Kalra // 6th International Conference – Cloud System and Big Data Engineering (Confluence). – Institute of Electrical and Electronics Engineers (IEEE), 2016. – P. 141–145. DOI:10.1109/CONFLUENCE.2016.7508103.

Розділ 2.6

1. Kachikian S. A Review of detector descriptors' on Object Tracking / S. Kachikian, M. Emadi // International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering. – 2016. – Vol. 5, Issue 7. DOI: 10.15662/IJAREEIE.2016.0507002.
2. Comaschi F RASW: A run-time adaptive sliding window to improve Viola-Jones object detection / F. Comaschi, S. Stuijk, T. Basten, H. Corporaal // Seventh International Conference on Distributed Smart Cameras, Palm Springs, California, USA, October 29. – November 1. 2013: proceedings. – IEEE Washington DC, USA, 2013. DOI: 10.1109/ICDSC.2013.6778224.
3. Senjian A. Efficient algorithms for subwindow search in object detection and localization / A. Senjian, P. Peursum, L. Wanquan, S. Venkatesh // IEEE

Computer Society Conference on Computer Vision and Pattern Recognition, Miami, Florida, USA, June 20-25, 2009: proceeding, IEEE, Washington, D. C, USA, pp. 264-271. DOI: 10.1109/CVPR.2009.5206822

4. Zhiqiang W. A review of object detection based on convolutional neural network / W. Zhiqiang, L. Jun // IEEE 2017 36th Chinese Control Conference (CCC), Dalian, China, July 26-28, 2017: proceeding, IEEE, Washington, D. C, USA, pp. 11104 – 11109. DOI: 10.23919/ChiCC.2017.8029130

5. Moskalenko V.V. Intelligent Decision Support System for Medical Radioisotope Diagnostics with Gamma-camera / A.S. Dovbysh, V.V. Moskalenko, A.S. Rizhova, O.V. Dyomin // Journal of Nano- and Electronic physics. – Vol. 7, No. 4. – Sumy : Sumy State University, 2015. – P. 04036-1–04036-7.

6. Labusch K. Sparse coding neural gas: learning of overcomplete data representations / Labusch K., E. Barth, T. Martinetz // Neurocomputing. – Vol. 72, No. 7–9, 2009, pp. 1547–1555. DOI:10.1016/j.neucom.2008.11.027.

7. Rasdi Rere L.M.. Simulated Annealing Algorithm for Deep Learning / L.M. Rasdi Rere, Mohamad Ivan Fanany, Aniat Murni Arymurthy // Procedia Computer Science. – Vol. 72. – Elsevier B.V., 2015. – P.137–144. DOI: 10.1016/j.procs.2015.12.114

Розділ 3.1

1. Будник А. Ф. Разработка абразивостойкого трехкомпонентного композитного материала на основе политетрафторэтилена. Дисертация на соискание звания канд. техн. наук, Киев, 1993. – 132 с.

2. Сиренко Г. А. Антифрикционные карбопластики.- Киев: Техника, 1985. – 195 с.

3. Полимерные композиционные материалы: структура, свойства, технология/ М. Л. Кербер, В. М. Виноградов, Г. С. Головкин и др. – СПб.: Профессия, 2008. – 560 с.

4. Дудукаленко В. В., Шаповалов С. П. Об установившейся ползучести огнеупорных композитов// Прикладн. механика и техническ. физика, 1984, №4. – с. 142-145.
5. Дудукаленко В. В. Моделирование пластических свойств материала на основе параметров мезоструктуры // Вестник ЧГПУ им. И. Я. Яковлева. Серия: Механика предельного состояния, № 2 (10), 2011, Чебоксары. – с. 25-103.
6. Долгіх В. М., Долгіх Я. В., Шаповалов С. П. Міцність бетонів, хаотично армованих короткими волокнами// Вісник Сумського національного аграрного університету / СНАУ. - Суми, 2003. - Вип. 10. - С. 75-81.
7. Сіренко Г. О. , Базюк Л. В. , Будник А. Ф. , Шаповалов С. П. Оптимізація полімерного композиту, наповненого сферичними та еліпсоїдними частинками, за теоретичним критерієм узгодження пружних та пластичних властивостей // Фізика і хімія твердого тіла, т. 12, № 3, 2011, Прикарпатський національний університет, Івано-Франківськ. – с. 727 -747.
8. Фудзии Т., Дзако М. Механика разрушения композиционных материалов. – М.: Мир, 1982. – 232 с.
9. Новацкий В. Теория упругости. – М.: Мир, 1975. – 872 с.
10. Шаповалов С. П. Проектирование трехфазных композитов и исследование напряжений в элементах структуры. Диссертация на соискание звания канд. физ. – мат. наук, Куйбышев, 1988. – 172 с.
11. Материалы, армированные волокном /пер. с англ.– М.: Стройиздат, 1982.–180 с.
12. Кристенсен Р. Введение в механику композитов. – М.: Мир, 1982. – 334 с.
13. Дудукаленко В. В., Шаповалов С. П., Будник А. Ф. Выбор структуры трехфазного карбопластика для износостойких уплотнений // сборник науч. трудов «Химическое машиностроение: расчет, конструирование, технология», Киев, 1992. – с. 94-100.

14. Колесников В. И., Бардушкин В. В., Лапицкий А. В., Сычёв А. П., Яковлев В. Б. Эффективные упругие характеристики антифрикционных композитов на эпоксидной основе // Вестник южного научного центра РАН, том 6, №1, 2010, Ростов-на-Дону. – с. 5-10.

Розділ 3.2

1. S. Kasap, P. Capper, [*The Springer Handbook of Electronic and Photonic Materials*](#) (Berlin: Springer, 2007).
2. R. Scheer, H. Werner Schock, *Chalcogenide Photovoltaics. Physics, Technologies, and Thin Film Devices* (Weinheim: Wiley-VCH, 2011).
3. S. Adachi. Handbook on physical properties of semiconductors. V.3. II–VI compound Semiconductors / S. Adachi. – New York, Boston: Kluwer Academic publishers, 2004. – 1472 p.
4. М. Ламперт, П. Марк Инжекционные токи в твердых телах .- М.: Мир, 1973. –222 с.
5. К. Као, В. Хуанг Перенос электронов в твердых телах: В 2 т.-М.: Мир, 1984.-Т.1. –352 с.
6. A. Ashour, M.O. Abdel-Hamid, N.Z. El-Sayed. Conduction studies on evaporated cadmium sulphide thin films //Chalcogenide Letters Vol. 9, No. 9, 2012, p. 371 - 378
7. C. Viswanathan, V. Senthilkumar, R. Sriranjini at all. Effect of substrate temperature on the properties of vacuum evaporated indium selenide thin films // Cryst. Res. Technol. 40, No. 7, 658 – 664 (2005)
8. S. Darwish. DC electric and photoelectric measurements of CdTe thin films in Schottky-barrier cells// Physica B 349 (2004) 296–303.
9. A.S. Opanasyuk, N.N. Opanasyuk, N.V. Turkusova High-temperature injection spectroscopy of deep traps in CdTe polycrystalline films// Semiconductor physics, quantum electronics and optoelectronics», 2003, V.6, №4, P.444-449.
10. J.C. Pfister Note of interpretation of space-charge-limited currents with traps// Phys. Stat. Sol. -1974.- Vol.24, №1. - P.K15-K17.

11. S. Nespurek, J. Sworakowski. Spectroscopy of traps for current carriers in molecular materials// J. Mol. Electr.–1989.- Vol.5. - P.71-77.
12. В.О. Любчак, А.С. Опанасюк, Н.В. Тиркусова, В.І. Харченко. Метод інжекційної спектроскопії для вивчення глибоких центрів у плівках телуриду кадмію// УФЖ -1999.-Т.44, №6.-С. 741-747.
- 13 P. Smertenko, L. Fenenko, L. Brehmer, S. Schrader Differential approach to the study of integral characteristics in polymer films // Advances in Colloid and Interface Science, 2005, V. 116, №1-3, P.255-261.
- 14 R. Ciach, Yu.P. Dotsenko, V.V. Naumov, A.N. Shmyryeva, P.S. Smertenko. Injection Technique for Study of Solar Cells Test Structures // Solar Energy Materials & Solar Cells, 2003, V.76, №4, P. 613–624.
15. А.И. Зюганов, С.В. Свечников. Инжекционно-контактные явления в полупроводниках. - Киев: Наукова думка, 1981. –256 с.
16. V.V Kosyak, A.S. Opanasyuk, P.M. Bukivskij, Yu.P. Gnatenko. *J. Cryst. Growth*, 312, 1726 (2010).
17. А.С. Опанасюк, І.Ю. Проценко, Н.В. Тиркусова. Деякі особливості реконструкції розподілів глибоких станів методом інжекційної спектроскопії //Журнал фізичних досліджень. - 2000.- Т.4, №2. - С.208-215.
18. C. Manfredotti, C. de Blasi, S. Galassini at all. *Phys. Stat. Sol. (a)* 1976. - V.36, №2. - P.569-577.

Розділ 3.3

1. Box, G., and Jenkins, G. *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day, 1970. 575 p.
2. Hyndman, R. and Athanasopoulos, G. *Forecasting: principle and practice*. Available at <http://otexts.com/fpp/> (accessed 25 February 2017).
3. Bergmeir, C., Hyndman, R. J., and Benitez, J. M. Bagging exponential smoothing methods using STL decomposition and Box-Cox transformation. *International journal of forecasting*. 2016, no. 32, pp. 303–312.
4. Woodward, W. A., Gray, H. L., and Elliott, A. C. *Applied time series analysis*. NY: Taylor & Francis Group, 2012. 540 p.

5. Kalman, R. E. and Bucy, R. S. New results in linear filtering and prediction theory. *Journal of Basic Engineering*. 1961, no. 83, pp. 95–108.
6. Chen, Ch. and Liu ,L. Joint Estimation of Model Parameters and Outlier Effects in Time Series. *Journal of the American Statistical Association*, 1993, no. 88(421), pp. 284–297.
7. Moosa, I. A., and Bhatti, R. H. *The theory and empirics of exchange rates*. Singapore: World Scientific Publishing Co., 2009. 483 p.
8. Gupta, P., Batra, S., and Jayadeva. Sparse Short-Term Time Series Forecasting Models via Minimum Model Complexity. *Neurocomputing*, 2017, doi: 10.1016/j.neucom.2017.02.002.
9. Barhoumi, K., Darne, O., Ferrara, L. Dynamic factor models: a review of the literature. *OECD Journal: Journal of Business Cycle Measurement and Analysis*. 2014, vol. 2013/2, pp. 73-107.
10. Hyndman, R., O’Hara-Wild, M., Bergmeir, C., Razbash, S. et. al. *Forecasting Functions for Time Series and Linear Models*. – R package ‘forecast’ version 8.0, 2017. Available at <http://github.com/robjhyndman/forecast> (accessed 27 February 2017).
11. L’opez-de-Lacalle, J. *Structural Time Series Models (stsm)*. R package version 1.9, 2016. Available at <https://cran.r-project.org/web/packages/stsm/stsm.pdf> (accessed 17 February 2017).
12. L’opez-de-Lacalle, J. *Detection of Outliers in Time Series (tsoutliers)*. R package version 0.6-5, 2016. Available at <https://cran.r-project.org/web/packages/tsoutliers/tsoutliers.pdf> (accessed 15 February 2017).
13. National Bank of Ukraine (2000-2017). Statistical data. Available at <http://bank.gov.ua/>
14. Wickham, H., and Chang, W. *Elegant Data Visualisations Using the Grammar of Graphics*. R package ‘ggplot 2’ version 2.2.0, 2017. Available at <http://docs.ggplot2.org/current/> (accessed 13 February 2017).
15. Chambers, J. M., Cleveland, W. S., Kleiner, B., and Tukey, P. A. *Graphical Methods for Data Analysis*. Wadsworth & Brooks/Cole, 1983. 105 p.

16. Cleveland, R. B., Cleveland, W. S., McRae, J., and Terpenning, I. STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*. 1990, no. 6(1), pp. 3–73.
17. Asteriou, D., and Hall, S. G. *Applied Econometrics (2nd Edition)*. NY: Palgrave Macmillan, 2011. 499 p.

Розділ 4.1

1. Основи нових інформаційних технологій навчання: Посібник для вчителів / Авт. кол.; За ред. Ю. І. Машбіца / Інститут психології ім. Г. С. Костюка АПН України. – К.: ІЗМН, 1997. – 167 с.
2. Khan B.H. Learning features in an open, flexible, and distributed environment // *AACE Journal*, 2005. - 13(2) – pp. 137-153.
3. Маклакова Г.Г., Маклаков Г.Ю., Карпаева О.В. Интеллектуальная система анализа и контроля качества дистанционного обучения // *Образование и виртуальность* – 2009. Сборник научных трудов 12-й Международной конференции УАДО – Харьков-Ялта:УАДО, 2009 - 105-109 сс.
4. Любчак В.О., Барило Р.Б. Оптимізація параметрів функціонування системи керування телекомунікаційним інформаційно-освітнім середовищем вищого навчального закладу // *Вісник Сумського державного університету. Серія Технічні науки.* — 2008. — №1. — С. 134-139.
5. Кривошеев А.О. Проблемы оценки качества программных средств учебного назначения // *Сборник докладов 1-го научно-практического семинара "Оценка качества программных средств учебного назначения".* – М. : Гуманитарий, 1995. – С. 5-12.
6. Smart-educaton [веб-портал] / Критерии выбора СДО/LMS/LCMS. URL: <http://www.smart-edu.com/issledovaniya-v-sfere-distantionnogo-obucheniya/kriterii-vybora-sdo/lms/lcms.html> (дата звернення: 07.09.2013).
7. EdX [веб-портал] / EdX: how it works. URL: <https://www.edx.org/how-it-works> (дата звернення: 07.09.2013).
8. Кузіков Б.О. Адаптивне керування навчальною діяльністю на основі прецедентів // *Вісник НТУ «ХПІ» Збірник наукових праць. Тематичний*

- випуск «Системний аналіз, управління та інформаційні технології». – Х. : НТУ "ХПІ", 2011. – №35 – С. 101-110.
9. Федорук П.И. Организация процесса индивидуализированного обучения на базе адаптивной системы дистанционного обучения и контроля знаний EduPro // Information models of knowledge – ITHEA, Kiev – Sofia, 2010. – С. 335-341.
 10. Федорук П.И. Використання інтелектуальних агентів для інтенсифікації процесу навчання // Штучний інтелект. Інтелектуальні і багатопроцесорні системи: матеріали міжнар. наук.-техн. конф. – Таганрог, Донецьк, 2004. – Т. 1. – С. 325–328.
 11. Федорук П.И. Адаптація процесу навчання в системах дистанційної освіти на основі оцінки швидкості сприйняття та засвоєння знань студентами // Математичні машини і системи. – 2006. – № 2. – С. 96–106.
 12. Бояшова С.А. Оценка эффективности моделей обучения в педагогической метрологии // Материалы XII Всероссийской научно-методической конференции: "Телематика 2005". – СПб.:Изд-во ГРОЦ, 2005. – Режим доступа: www.ict.edu.ru/vconf/files/9598.doc
 13. Мазурок Т.Л. Интеллектуальные средства автоматизации управления обучением // Образовательные технологии и общество (Educational Technology & Society), 2012. – Том 15, №:3. – С. 502–521.
 14. Lubchak V., Kupenko O., Kuzikov B. Approach to Dynamic Assembling of Individualized Learning Paths // Informatics in Education, 2012. – Vol. 11., № 2. – P. 213–225. Режим доступа: www.mii.lt/informatics_in_education/pdf/INFE207.pdf
 15. Курейчик В.М., Писаренко В.И., Кравченко Ю.А. Адаптивная модель организации малых учебных групп в интеллектуальных автоматизированных образовательных системах // Дистанционное и виртуальное обучение, 2008. – № 11. – С. 44-54.

Розділ 4.2

1. Богомоллов В. А. Обзор бесплатных систем управления обучением [Текст] / В. А. Богомоллов // Образовательные технологии и общество. –

2007. – Т. 10, № 3. – С. 439-460.

2. Довбиш А.С. Математичне моделювання при синтезі системи керування дистанційним навчанням / А.С. Довбиш, С.О. Петров // Математичне моделювання. Дніпродзержинський державний університет.– 2007. – №2(17). – С. 64-67.

3. Симанков В.С. Адаптивное управление сложными системами на основе теории распознавания образов / В.С. Симанков, Е.В. Луценко.– Краснодар: Техн. ун-т Кубан. гос. технол. ун-та. – 1999. – 318 с.

4. Довбиш А.С. Основи проектування інтелектуальних систем: Навчальний посібник / А.С. Довбиш. – Суми: Видавництво Сум ДУ. – 2009.– 171 с.

Розділ 4.3

1. Агапова, М. О. Про оптимізацію навчального матеріалу [Текст] / В. Г. Кремень // Теорія і практика управління соціальними системами. Науково-практичний журнал. – 2012. – № 1. – С. 34–39.

2. Xu, G. Applied Data Mining [Text] / G. Xu, Y. Zong, Z. Yang. – CRC Press, 2013. – 284 p.

3. Довбиш А. С. Інтелектуальні інформаційні технології в електронному навчанні [Текст] / А.С. Довбиш. – Суми: Видавництво Сумського державного університету, 2013. – 172 с.

4. Dovbysh A. S. Information-Extreme Method for Classification of Observations with Categorical Attributes [Text] / A. S. Dovbysh, V. V. Moskalenko, A. C. Rizhova // Cybernetica and Systems Analysis. – 2016. – V. 52. – №2. – P. 45-52

Розділ 4.4

1. Shelton, Kaye, Pedersen, Karen. Handbook of Research on Building, Growing, and Sustaining Quality E-Learning Programs // IGI Global, – 2016. – 412 с.

2. Краснопоясовський А.С. Інформаційний синтез інтелектуальних систем керування, що навчаються // Видавництво СумДУ Суми – 2003.

3. Гриценко В.И, Довбыш А.С., Любчак В.А. Информационный синтез адаптивной мультиагентной системы управления дистанционным обучением. – УсиМ.–2006.–№6 – С. 4-6,25

4. Довбиш А.С., Любчак В.О., Петров С.О. Машинна оцінка знань студентів у системах керування дистанційним навчанням // Вісник СумДУ. Серія «Техніка», №1, 2007.– С. 122-129.

5. Довбиш А.С. Основи проектування інтелектуальних систем: Навчальний посібник.– Суми: Видавництво Сум ДУ, 2009.– 171 с.

6. Краснопоясовський А. С. Інформаційний синтез системи підтримки прийняття рішень, що навчається // Труды Одес. политехн. ун-та, 2001. – Вып.4 (16). – С. 82-86.

Розділ 4.5

1. Чигасова Н.М. Місце інформаційних технологій у розвитку інформаційного суспільства в Україні.// Формування ринкових відносин в Україні: Збірник наукових праць. 2007. № 9. С. 110-114.

2. Боровик В.О., Осадчий А.С., Аналітично-інформаційна система для адаптації навчального контенту до запитів ринку праці. Международное научное издание. Сборник научных трудов SWorld.:Иваново, Маркова А. Д. 2013. 19-21 с.

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

4. Довбиш А.С, Васильєв А.В., Любчак В.О. Інтелектуальні інформаційні технології в електронному навчанні. Суми: Видавництво СумДУ, 2013. 191 с.

Розділ 4.6

1. Кузиков Б. О. Использование Libre Office в дистанционном обучении [Текст] / Б. О. Кузиков // Міжнародна науково-методична конференція «Якість вищої

освіти : методологічні та методичні підходи щодо впровадження дистанційних технологій навчання», 23-24 січ. 2013 р., м. Полтава. – Полтава, 2013. – Ч. 2. – С. 112-114.

2. Segalovich Іуа. A fast morphological algorithm with unknown word guessing induced by a dictionary for a web search engine [Електронний ресурс] / Segalovich

Іуа. - Режим доступу : <http://download.yandex.ru/company/iseg-las-vegas.pdf>

3. Коваленко А. Вероятностный морфологический анализатор русского и украинского языков [Електронний ресурс] / А. Коваленко // Системный администратор. - 2002. – № 1. - Режим доступу : <http://samag.ru/archive/article/47>

4. Kuzikov В. Using semantic web and covering context by test for course formal testing [Text] / V. Lubchack, В. Kuzikov, К. Kirichenko // 8th Int. Conference on Emerging eLearning Technologies and Applications, High Tatras, Slovakia. – 2010. – С. 135-140.