

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ

Сумський державний університет

Центр заочної, дистанційної та вечірньої форм навчання

Кафедра комп'ютерних наук

«До захисту допущено»

В.о. завідувача кафедри

Ігор ШЕЛЕХОВ

_____ (підпис)

_____ грудня 2023 р.

КВАЛІФІКАЦІЙНА РОБОТА

на здобуття освітнього ступеня магістр

зі спеціальності 122 - Комп'ютерних наук,

освітньо-професійної програми «Інформатика»

на тему: «Інтелектуальна технологія детектування дефектів деталей, що обробляються на верстатах токарної групи»

здобувачки групи ІН.мз-22с Мікуліна Дмитрія Олеговича

Кваліфікаційна робота містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

_____ Дмитрій МІКУЛІН

(підпис)

Керівник,

в.о. завідувача кафедри,

кандидат технічних наук, доцент

Ігор ШЕЛЕХОВ

_____ (підпис)

Суми – 2024

Сумський державний університет
Центр заочної, дистанційної та вечірньої форм навчання
Кафедра комп'ютерних наук

«Затверджую»

В.о. завідувача кафедри

Ігор ШЕЛЕХОВ

(підпис)

ІНДИВІДУАЛЬНЕ ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

на здобуття освітнього ступеня магістра

зі спеціальності 122 - Комп'ютерних наук, освітньо-професійної програми «Інформатика»
здобувача групи ІН.мз-22с Мікуліна Дмитра Олеговича

1. Тема роботи: «Інтелектуальна технологія детектування дефектів деталей, що обробляються на верстатах токарної групи»

затверджую наказом по СумДУ від «20» листопада 2023 року № 1307-VI

2. Термін здачі здобувачем кваліфікаційної роботи до 23 січня 2024 року

3. Вхідні дані до кваліфікаційної роботи _____

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

1) Аналіз проблеми предметної області, постановка й формування завдань дослідження.

2) Інформаційно-екстремальна інтелектуальна технологія. 3) Розробка інформаційного та програмного забезпечення. 4) Аналіз результатів.

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

6. Консультанти до проекту (роботи), із значенням розділів проекту, що стосується їх

| Розділ | Консультант | Підпис, дата | |
|--------|-------------|----------------|------------------|
| | | Завдання видав | Завдання прийняв |
| | | | |

7. Дата видачі завдання « » _____ 20 р.

Завдання прийняв до виконання _____

(підпис)

Керівник _____

(підпис)

КАЛЕНДАРНИЙ ПЛАН

| № п/п | Назва етапів кваліфікаційної роботи | Термін виконання | Примітка |
|-------|----------------------------------------------------------------------------------------|------------------|----------|
| 1 | <i>Аналіз проблеми предметної області, постановка й формування завдань дослідження</i> | | |
| 2 | <i>Інформаційно-екстремальна інтелектуальна технологія</i> | | |
| 3 | <i>Розробка інформаційного та програмного забезпечення</i> | | |
| 4 | <i>Аналіз отриманих результатів</i> | | |
| 5 | <i>Оформлення пояснювальної записки до кваліфікаційної роботи</i> | | |

Здобувач вищої освіти _____

(підпис)

Керівник _____

(підпис)

АНОТАЦІЯ

Записка: 49 стр., 13 рис., 4 табл., 1 додаток, 20 використаних джерел.

Обґрунтування актуальності теми роботи – Напрямом цього дослідження є методи обробки зображень під час автоматизації візуального контролю поверхні деталей, що обробляються на верстатах токарної групи. Інспекція поверхні здійснюється на підприємствах виробників і споживачах таких деталей, зокрема під час вхідного контролю, в організаціях виробників парогенераторів. Вимоги до контролю зазначені в технічних умовах на відповідні деталі і не допускають наявності дефектів, таких як пліви, тріщини, задирки тощо. Оператор, який проводить візуальний огляд, схильний до фізичної та емоційної втоми, його робота залежить від досвіду, тому автоматизація візуального контролю, як засіб виключення суб'єктивності, є актуальним завданням.

Об'єкт дослідження — Процес візуального контролю поверхні деталей, що обробляються на верстатах токарної групи.

Мета роботи — Розробка математичних моделей, методів і засобів інтелектуальної технології детектування дефектів деталей, що обробляються на верстатах токарної групи.

Методи дослідження — методи інтелектуального аналізу зображень, методи машинного навчання, методи розпізнавання образів.

Результати — Розроблено комплекс моделей, методів і засобів інтелектуальної технології детектування дефектів деталей, що обробляються на верстатах токарної групи. Ефективність інтелектуальної технології перевірено при створенні системи розпізнавання трьох типів дефектів поверхні деталей.

ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУАЛЬНА ТЕХНОЛОГІЯ,
КРИТЕРІЙ ФУНКЦІОНАЛЬНОЇ ЕФЕКТИВНОСТІ, ВИРІШАЛЬНІ
ПРАВИЛА, ТОЧНІСНІ ХАРАКТЕРИСТИКИ

ЗМІСТ

| | |
|-----------------------------------------------------------------------------------------------------------|----|
| ВСТУП | 5 |
| 1 АНАЛІТИЧНИЙ ОГЛЯД І ПОСТАНОВКА ЗАДАЧІ | 6 |
| 1.1 Сучасний стан та тенденції розвитку предметної галузі | 6 |
| 1.2 Способи виявлення дефектів | 7 |
| 1.3 Методи розпізнавання образів в задачах виявлення дефектів | 11 |
| 1.4 Постановка задачі | 13 |
| 2 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУЛЬНА ТЕХНОЛОГІЯ | 14 |
| 2.1 Основні положення та ідеї інформаційно-екстремальної інтелектуальної технології | 14 |
| 2.2 Математична модель навчання системи підтримки прийняття рішень . | 20 |
| 2.3 Критерій функціональної ефективності | 23 |
| 3 ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ..... | 26 |
| 3.1 Формування вхідного математичного опису..... | 26 |
| 3.2 Базовий алгоритм навчання системи розпізнавання | 26 |
| 3.3 Алгоритм паралельно-послідовної оптимізації системи контрольних допусків на ознаки розпізнавання..... | 31 |
| 3.4 Алгоритм оцінки ефективності ієрархічного класифікатора | 33 |
| 3.5 Короткий опис програмної реалізації | 34 |
| 3.6 Результати фізичного моделювання | 35 |
| ВИСНОВКИ..... | 43 |
| СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ | 44 |
| ДОДАТОК | 46 |

ВСТУП

Обґрунтування актуальності теми роботи – Напрямом цього дослідження є методи обробки зображень під час автоматизації візуального контролю поверхні деталей, що обробляються на верстатах токарної групи. Інспекція поверхні здійснюється на підприємствах виробників і споживачах таких деталей, зокрема під час вхідного контролю, в організаціях виробників парогенераторів. Вимоги до контролю зазначені в технічних умовах на відповідні деталі і не допускають наявності дефектів, таких як пліви, тріщини, задирки тощо. Оператор, який проводить візуальний огляд, схильний до фізичної та емоційної втоми, його робота залежить від досвіду, тому автоматизація візуального контролю, як засіб виключення суб'єктивності, є актуальним завданням.

Об'єкт дослідження — Процес візуального контролю поверхні деталей, що обробляються на верстатах токарної групи.

Мета роботи — Розробка математичних моделей, методів і засобів інтелектуальної технології детектування дефектів деталей, що обробляються на верстатах токарної групи.

Методи дослідження — методи інтелектуального аналізу зображень, методи машинного навчання, методи розпізнавання образів.

Гіпотеза. Автоматизація візуального контролю дефектів деталей, що обробляються на верстатах токарної групи, призведе до підвищення оперативності та ефективності цього процесу.

Новизна. В роботі запропоновано виконати розробку моделей, методів і засобів інтелектуальної технології детектування дефектів деталей, що обробляються на верстатах токарної групи, в рамках інформаційно-екстремального інтелектуального (IEI) підходу до машинного навчання та розпізнавання образів.

Структура. Дана робота складається зі вступу, аналізу проблеми предметної області, постановки й формування завдань дослідження, опису IEI технології, опису інформаційного та програмного забезпечення, аналізу отриманих результатів, висновків, списку використаних джерел та додатків.

1 АНАЛІТИЧНИЙ ОГЛЯД І ПОСТАНОВКА ЗАДАЧІ

1.1 Сучасний стан та тенденції розвитку предметної галузі

В процесі обробки механічних деталей на їх поверхні утворюються тріщини та інші дефекти, що серйозно впливають на якість поверхні. Тому важливо стежити за якістю поверхні деталей машин. Традиційний метод моніторингу здійснюється шляхом ручного відбору проб в автономному режимі. Цей метод залежить від людського фактору – досвідченості персоналу, що виконує перевірку, і часто не може знаходити дефекти в режимі реального часу. Технологія виявлення дефектів може бути реалізована за допомогою інтелектуального аналізу зображень поверхні. В даний час для виявлення поверхневих дефектів механічних деталей на основі методу обробки зображень, відповідно для виявлення поверхневих дефектів механічних деталей для різців, смуг, шестерень, підшипників та інших пропонуються методи виявлення просторової області (метод виявлення краю, метод нульового середнього) та алгоритм виявлення вейвлет-домену. Серед них метод нульового середнього побудований з нульовим середнім значенням, і розбиває область дефекту на порогові значення. і цей алгоритм простий, але має похибку виявлення дефектної області. Метод виявлення країв реалізований на виявленні дефектів за допомогою виявлення крайових дефектів, але цей метод може витягувати лише грубі крайові дефекти, не може виявити повну область дефекту. Алгоритм виявлення у вейвлет-області розкладається на інформацію про нормальну область та інформацію про область дефекту, розділену вейвлетом, який може виявити область дефекту. Однак сегментація області дефекту залежить від продуктивності вейвлет-фільтра, а як побудувати вейвлет-фільтр - складна проблема. Насправді, людська зорова система, спираючись на попередні знання, завжди в процесі пошуку співвідносить їх з попередніми знаннями про особливості виявлення цілей і надає перевагу цим цілям, це і є людський механізм виявлення. Якщо цей механізм запровадити для виявлення поверхневих дефектів механічних деталей, використовуючи характерні дефекти як умови виявлення дефектів механічних деталей, швидше за все, зосередити увагу на ділянці дефекту, щоб

уникнути впливу факторів навколишнього середовища на виявлення, досягти точної сегментації області дефекту. З цією метою виявлення цільової ознаки встановлює поріг сегментації, щоб досягти точної сегментації поверхневих дефектів механічних деталей.

Візуальний контроль із застосуванням оптичних приладів називають візуально-оптичним. Він призначений для виявлення різних поверхневих дефектів матеріалу деталей, прихованих дефектів агрегатів, контролю закритих конструкцій, важкодоступних місць механізмів і машин (за наявності каналів для доступу приладів до контрольованих об'єктів). Контроль проводиться шляхом спостереження деталей і виробів у видимому світлі. Під час контролю використовуються оптичні прилади, що створюють повне зображення зони, що перевіряється, її видиму картину.

Візуально-оптичний контроль, так само як і візуальний огляд, - найбільш доступний і простий метод виявлення поверхневих дефектів деталей. Оптичні засоби контролю використовують на різних стадіях виготовлення виробів, у процесі регламентних робіт та оглядів, що проводяться під час експлуатації техніки, а також під час її ремонту.

Візуально-оптичний контроль застосовують у таких випадках:

- для пошуку поверхневих дефектів (тріщин, корозійних і ерозійних ушкоджень, вибоїн, виразок, відкритих раковин, пір тощо) під час візуально-оптичного контролю деталей, доступних для безпосереднього огляду;
- для виявлення великих тріщин, місць руйнування елементів конструкцій, залишкової деформації прихованих або видалених елементів конструкцій, протікання, забруднень, а також різних сторонніх предметів усередині закритих конструкцій;
- для аналізу характеру і визначення типу поверхневих дефектів, виявлених під час контролю деталей будь-яким методом дефектоскопії: ультразвуковим, кольоровим та ін.)

1.2 Способи виявлення дефектів

Розглянемо основні способи виявлення дефектів:

- візуальний - сукупність зорових прийомів виявлення, зокрема із застосуванням оптичних або фотографічних засобів, видимого індикаторного сліду несучільності, виявленої люмінесцентним, кольоровим, люмінесцентно-кольоровим або яскравим методами;
- фотоелектричний - сукупність фотоелектричних прийомів виявлення і перетворення із застосуванням різних засобів непрямой індикації та реєстрації сигналу видимого індикаторного сліду несучільності, виявленої люмінесцентним, кольоровим, люмінесцентно-кольоровим і яскравим методами. У разі фотоелектричного виявлення виріб бракують на підставі вимірювання світлового потоку, що сприймається фотоелементом. Для цього, наприклад, виріб поміщають у затемнену камеру, освітлюють ультрафіолетовим світлом, а фотоелемент реєструє світіння у видимій ділянці;
- телевізійний - сукупність телевізійних прийомів виявлення, перетворення в аналогову або дискретну форму з відповідним представленням на екран, дисплей, магнітну плівку сигналу від видимого індикаторного сліду несучільності. Основна перевага телевізійного виявлення - можливість регулювання контрасту і яскравості зображення дефекту. За рахунок цього можуть бути підвищені чутливість і достовірність контролю і поліпшені умови роботи контролера. Крім того, виведене на екран зображення дефекту дає змогу за допомогою ЕОМ здійснити кількісну оцінку дефекту й отримати дані про ступінь його небезпеки;
- інструментальний - сукупність непрямих прийомів виявлення сигналу від невидимого оком індикаторного сліду несучільності або сигналу від індикаторного пенетранта, що знаходиться всередині порожнини несучільності. У разі інструментального виявлення сигнал про наявність дефекту отримують шляхом реєстрації за допомогою спеціальних приладів, що враховують випромінювання, яке випромінюється з індикаторною речовиною, що знаходиться в порожнині дефекту. Це можуть бути, наприклад, випромінювання радіоактивного газу криптону

в газосорбційному контролі або акустичні імпульси, що генеруються крихкою плівкою, яка утворилася в результаті полімеризації спеціального пенетранта в порожнині дефектів. До інструментальних способів виявлення належить також виявлення дефектів у виробках із непровідних матеріалів за допомогою струмо струмового приладу за умови просочення дефектів електропровідним пенетрантом.

Сліди дефектів можуть бути у вигляді суцільних або переривчастих ліній різної конфігурації, скупчення окремих коротких ліній, сітки, плям, розмитих смуг, точок або зірочок.

Дефекти першої групи відповідають шліфувальним, втомним або загартовувальним тріщинам, волосинам, неспаям та іншим подібним дефектам; другої групи - корозійному розтріскуванню матеріалів; третьої групи - порам, піттинговій корозії або осередкам міжкристалітної корозії, вифарбовуванню або ерозії металу. Виявлений індикаторний малюнок аналізують, як правило, із застосуванням оптичних засобів.

Слід враховувати, що індикаторні малюнки на поверхні виробів можуть бути утворені не тільки дефектами, а й різними забрудненнями або допустимими пошкодженнями поверхні. Тому в результаті аналізу контролер має встановити наявність дійсного дефекту, його характер і розміри.

Розрізняють обмежений і повний аналіз індикаторних малюнків дефектів. Під час обмеженого аналізу вивчають тільки геометрію і розміри малюнка. Вироби бракують, якщо кількість і розміри виявлених штрихів, ліній і точок перевищують допустимі технічні умови. Такий аналіз забезпечує високу продуктивність контролю, дає змогу використовувати фахівців із невисокою кваліфікацією, але може призвести до необґрунтованого вибракування виробів зі складною поверхнею або невисокою чистотою обробки.

Повний аналіз малюнка передбачає вивчення місця його розташування, напрямку, кольору, яскравості та інших ознак. При такому аналізі необхідний ретельний огляд виробів, який виконують висококваліфіковані контролери.

Спеціаліст повинен вміти розрізняти дійсні та помилкові дефекти. До несправжніх дефектів відносять різні допустимі технічними умовами зміни якості матеріалу виробу, їхньої мікрогеометрії, незначні ушкодження та забруднення поверхні, що спричиняють утворення індикаторних малюнків, схожих на малюнки дійсних дефектів. Хибні дефекти проявляються в разі неповного видалення пенетранта з поверхні, особливо тієї, що містить залишки забруднень і корозії.

Тому аналіз дефектів виконують із використанням додаткових ознак:

- місце розташування малюнка;
- напрямок ліній малюнків щодо осі симетрії виробу і діючих навантажень;
- колір, яскравість і насиченість кольору малюнка;
- швидкість утворення малюнка і характер його зміни з плином часу;
- конфігурація малюнка, наявність зламів і розгалужень;
- чіткість і ступінь подібності контурів ліній малюнка;
- мікрорельєф проявника в зоні малюнка;
- наявність подібного малюнка в сусідніх зонах виробу.

Іноді буває достатньо розглянути дві-три додаткові ознаки. У складних випадках проводять аналіз за всіма додатковими ознаками або вдаються до додаткового контролю виробу іншими методами. За повного аналізу досягається найбільша достовірність контролю, знижуються втрати від необґрунтованого вибракування виробів, створюється можливість контролю виробів зі складною поверхнею, а також тих, що були в експлуатації. Іноді аналіз дефектів виконують шляхом порівняння отриманих дефектограм з еталонними.

Для виявлення слідів дефектів на контрольованій поверхні слід створити необхідну освітленість, а оператор має бути оснащений необхідним обладнанням. У разі використання фарбувальних пенетрантів випробовувана поверхня має бути освітлена денним або штучним світлом. У разі використання індикаторних речовин, що люмінесціюють, кімната, де проводиться перевірка, має бути затемнена.

Після виявлення дефектів проявник, як правило, видаляють із поверхні виробу. Виявлені сліди дефектів реєструються дефектоскопістом-оператором шляхом фотографування і замальовування індикаторних слідів з метою фіксації місця розташування дефектів на контрольованому виробі. Ці результати заносяться до спеціальних документів, аналізуються фахівцем, який бере до уваги сукупність основних і непрямих ознак індикації допустимих і неприпустимих дефектів, кінетику прояву сліду.

У результаті видається висновок спеціальної в кожній галузі форми щодо можливості експлуатації контрольованої деталі, або в неоднозначних для оцінки випадках деталь направляється на повторний контроль. Огляд треба починати через 5-6 хвилин у будь-якому разі. Характер першого малюнка індикації і потім його динаміка несуть корисну для дефектоскопіста інформацію про дефект.

1.3 Методи розпізнавання образів в задачах виявлення дефектів

Слід зауважити, що під розпізнаванням дефектів зазвичай розуміють три головні методи.

- Порівняння із заздалегідь підготовленим шаблоном;
- Розпізнавання з використанням критеріїв, розпізнаваного об'єкта;
- Розпізнавання за допомогою самонавчальних алгоритмів, зокрема за допомогою нейронних мереж.

Розпізнаванням образів називаються задачі побудови і застосування формальних операцій над числовими або символічними відображеннями об'єктів реального або ідеального світу, результати розв'язання яких відображають відносини еквівалентності між цими об'єктами. Відносини еквівалентності виражають приналежність оцінюваних об'єктів до якихось класів, що розглядаються як самостійні семантичні одиниці.

Під час побудови алгоритмів розпізнавання класи еквівалентності може задавати дослідник, який користується власними змістовними уявленнями або використовує зовнішню додаткову інформацію про схожість і відмінність об'єктів у контексті розв'язуваної задачі. Тоді говорять про «розпізнавання з учителем». В іншому разі, тобто коли автоматизована система розв'язує задачу

класифікації без залучення зовнішньої навчальної інформації, говорять про автоматичну класифікацію або «розпізнавання без учителя». Більшість алгоритмів розпізнавання образів вимагає залучення вельми значних обчислювальних потужностей, які можуть бути забезпечені тільки високопродуктивною комп'ютерною технікою.

Існує різну типологію методів розпізнавання образів. Одні автори розрізняють параметричні, непараметричні та евристичні методи, інші - виокремлюють групи методів, виходячи з шкіл і напрямів, які історично склалися, у цій галузі. Зокрема використовується така типологія методів розпізнавання образів:

- методи, засновані на принципі поділу;
- статистичні методи;
- методи, побудовані на основі "потенційних функцій";
- методи обчислення оцінок (голосування);
- методи, засновані на обчисленні висловлювань, зокрема на апараті алгебри логіки.

Подібна типологія методів розпізнавання з тим чи іншим ступенем деталізації трапляється в багатьох роботах із розпізнавання. Водночас відомі типології не враховують одну дуже суттєву характеристику, яка відображає специфіку способу представлення знань про предметну галузь за допомогою якогось формального алгоритму розпізнавання образів, що виокремлює два основні способи подання знань:

- Інтенціональне подання - у вигляді схеми зв'язків між атрибутами (ознаками).
- Екстенціональне подання - за допомогою конкретних фактів (об'єкти, приклади).

Інтенціональне представлення фіксують закономірності та зв'язки, якими пояснюється структура даних. Стосовно діагностичних завдань така фіксація полягає у визначенні операцій над атрибутами (ознаками) об'єктів, що призводять до необхідного діагностичного результату. Інтенціональні

уявлення реалізуються за допомогою операцій над значеннями атрибутів і не передбачають здійснення операцій над конкретними інформаційними фактами (об'єктами).

Своєю чергою, екстенсивні уявлення знань пов'язані з описом і фіксацією конкретних об'єктів із предметної області та реалізуються в операціях, елементами яких слугують об'єкти як цілісні системи.

Наведемо класифікацію методів розпізнавання образів, що використовуються при виявленні дефектів.

- 1) Інтенціональні методи розпізнавання;
- 2) Методи розпізнавання на основі оцінок щільності розподілу ознак;
- 3) Методи розпізнавання, що базуються на припущеннях про клас розв'язуючих функцій
- 4) Логічні методи розпізнавання
- 5) Структурні методи розпізнавання
- 6) Нейромережеві методи розпізнавання.

1.4 Постановка задачі

У роботі необхідно розробити інтелектуальну систему діагностування дефектів деталей, що обробляються на верстатах токарної групи за зображенням, що здатна навчатися в рамках сучасної інформаційно екстремальної інтелектуальної технології (ІЕІ-технології). Таким чином, метою роботи є

- 1) формування вхідного математичного опису інтелектуальної системи,
- 2) розробка математичних моделей функціонування системи в режимі навчання,
- 3) розробка та програмна реалізація алгоритмів оптимізації функціональних параметрів системи,
- 4) оцінка ефективності системи на практичній задачі автоматичного розпізнавання трьох класів дефектів.

2 ІНФОРМАЦІЙНО-ЕКСТРЕМАЛЬНА ІНТЕЛЕКТУЛЬНА ТЕХНОЛОГІЯ

2.1 Основні положення та ідеї інформаційно-екстремальної інтелектуальної технології

Базовим методом ІЕІ-технології є метод функціонально-статистичних випробувань (МФСВ) [6-8] – непараметричний інформаційно-екстремальний метод аналізу та синтезу здатної навчатися системи підтримки прийняття рішень, який ґрунтується на прямій оцінці інформаційної здатності системи за умов нечіткої компактності реалізацій образу, та обмеження навчальної вибірки, яка є прийнятною для задач контролю і управління. Метод призначено для розв’язання практичних задач контролю та управління слабо формалізованими системами і процесами шляхом автоматичної класифікації їх функціональних станів за умови невизначеності.

МФСВ окрім системних та специфічних принципів ґрунтується також на 2-х дистанційних принципах:

максимально-дистанційному, який вимагає максимальної міжцентрової відстані між класами;

мінімально-дистанційному, вимагає мінімальної середньої відстані реалізацій від центру свого класу.

Класом розпізнавання (образом) X_m^0 називається відбиття властивостей m -го функціонального стану СК і відношень між елементами системи. Клас розпізнавання – топологічна категорія, яка задається в просторі ознак розпізнавання (ОР) областю $X_m^0 \subset \Omega_B$.

Детерміновано-статистичний підхід до моделювання систем вимагає завдання систем нормованих (експлуатаційних) і контрольних допусків на ОР. Нехай X_m^0 – базовий клас, який характеризує максимальну функціональну ефективність, тобто є найбільш бажаним для розробника інформаційного забезпечення системи. Нормованим називається поле допусків $\{\delta_{H,i} \mid i = \overline{1, N}\}$, в якому значення i –ї ОР знаходиться з імовірністю $p_i = 1$ або $p_i = 0$, за умови,

що функціональний стан відноситься до класу X_1^0 . Контрольним називається поле допусків $\{\delta_{K,i} \mid i = \overline{1, N}\}$, в якому значення i -ї ОР знаходиться з імовірністю $0 < p_i < 1$ за умови, що функціональний стан відноситься до класу X_1^0 .

В МФСВ система контрольних допусків вводиться з метою рандомізації процесу прийняття рішень, оскільки для повного дослідження ОКУ необхідно використовувати як детерміновані, так і статистичні характеристики. Зрозуміло, що $|\delta_{K,i}| \leq |\delta_{H,i}|$ і базова (відносно класу X_1^0) СКД є сталою для всієї абетки класів розпізнавання.

Реалізацією образу $x_m^{(j)} \in X_m^0$ називається випадковий структурований бінарний вектор $x_m^{(j)} = \langle x_{m,1}^{(j)}, \dots, x_{m,i}^{(j)}, \dots, x_{m,N}^{(j)} \rangle$, $j = \overline{1, n_{\min}}$, де $x_{m,i}^{(j)}$ – i -та координата вектора, яка приймає одиничне значення, якщо значення i -ї ОР знаходиться в полі допусків $\delta_{K,i}$, і нульове значення, якщо не знаходиться; n_{\min} – мінімальна кількість випробувань, яка забезпечує репрезентативність реалізацій образу.

При обґрунтуванні гіпотези компактності (чіткої, або нечіткої) реалізацій образу за геометричний центр класу X_m^0 приймається вершина бінарного еталонного вектору x_m .

Еталонний вектор (ЕВ) x_m – це математичне сподівання реалізацій класу X_m^0 .

Він подається у вигляді детермінованого структурованого бінарного вектора $x_m = \langle x_{m,1}, \dots, x_{m,i}, \dots, x_{m,N} \rangle$, $m = \overline{1, M}$, де $x_{m,i}$ – i -та координата вектора, яка приймає одиничне значення, якщо значення i -ї ОР знаходиться в нормованому полі допусків $\delta_{H,i}$, і нульове значення, якщо не знаходиться.

Основною задачею етапу навчання за МФСВ є розбиття простору ОР за поданою навчальною матрицею на області класів розпізнавання деяким оптимальним в інформаційному сенсі способом, який забезпечує на етапі

екзамену прийняття рішень з достовірністю, наближеною до максимальної асимптотичної достовірності.

Параметром функціонування називається характеристика інформаційного забезпечення, яка прямо або непрямо впливає на функціональну ефективність системи. Такими параметрами можуть бути параметри навчання, перетворення образу, впливу середовища та інші, які безпосередньо впливають на асимптотичну достовірність.

Як критерій оптимізації процесу навчання системи прийняттю рішень в рамках МФСВ застосовується статистичний інформаційний КФЕ, який є природною мірою різноманітності (або схожості) класів розпізнавання і одночасно функціоналом асимптотичних точнісних характеристик. При цьому важливо, щоб параметри навчання були оптимальними в інформаційному розумінні, тобто забезпечували максимальну функціональну ефективність системи, яка визначається достовірністю прийняття рішень на екзамені.

Достовірність класифікатора залежить від геометричних параметрів роздільних гіперповерхонь класів розпізнавання.

У загальному випадку, коли класи розпізнавання перетинаються, розглянемо відносний коефіцієнт нечіткої компактності реалізації образу для класу

$$X_m^0 : l_{m,d} = d_m^* / d(x_m \oplus x^{(j)}) \quad (2. 1)$$

Процес навчання полягає в мінімізації цього виразу.

В МФСВ, який ґрунтується на допущенні гіпотези компактності (чіткої або нечіткої) реалізацій образу, як наближення "точної" роздільної гіперповерхні для класу X_m^0 розглядається гіперсфера, центром якої є еталонний вектор $x_m \in X_m^0$, а радіусом d_m – кодова відстань, яка у просторі Хеммінга визначається як

$$d_m = \sum_{i=1}^N (x_{m,i} \oplus \lambda_{m,i}) \quad (2. 2)$$

де d_m – і-та координата вектора $x_m \in X_m^0$; $\lambda_{m,i}$ – і-та координата деякого вектора λ_m , вершина якого знаходиться на роздільній гіперповерхні класу X_m^0 ;
 \oplus – операція складання за модулем два.

Оптимальною кодовою відстанню (радіусом) між вектором x_m і контейнером K_m^0 називається екстремальне значення d_m^* , яке визначає максимум інформаційного КФЕ $E_m^* = \max_{\{d\}} E_m$, де $\{d\}$ – послідовність збільшень радіуса контейнера K_m^0 .

У загальному випадку при прийнятті гіпотези нечіткої компактності реалізацій образу покриття $L^{|M|} = \{X_m^o\}$ не є чіткою фактор-множиною $\mathfrak{R}^{|M|} = \Omega / \dot{Y}$, де \dot{Y} – відношення еквівалентності. Якщо для нечіткого простору ознак $\tilde{\Omega}$ існує нечітке покриття $\tilde{L} \subset \tilde{\Omega}$ і визначено міру $\mu(\tilde{X})$ як відношення діаметрів нечітких множин $\tilde{X}_m^o \subset \tilde{L}$, $m = \overline{1, M}$, і \tilde{L} , то покриття $\tilde{L} \subset \tilde{\Omega}$ є нечітким розбиттям $\tilde{\mathfrak{R}}^{|M|}$, яке відповідає умовам:

$$\begin{aligned}
 & 1) (\forall X_m^o \in \tilde{\mathfrak{R}}^{|M|}) [X_m^o \neq \emptyset]; \\
 & 2) (\exists X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\exists X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow X_k^o \cap X_l^o \neq \emptyset]; \\
 & 3) (\forall X_k^o \in \tilde{\mathfrak{R}}^{|M|}) (\forall X_l^o \in \tilde{\mathfrak{R}}^{|M|}) [X_k^o \neq X_l^o \rightarrow \text{Ker} X_k^o \cap \text{Ker} X_l^o = \emptyset]; \\
 & 4) \bigcup_{X_m^o \in \tilde{\mathfrak{R}}} X_m^o \subseteq \Omega_A; k \neq l; k, l, m = \overline{1, M}
 \end{aligned} \tag{2.3}$$

Побудова оптимальної в інформаційному сенсі роздільної гіперповерхні (РГП) у вигляді гіперсфери за МФСВ зводиться до оптимізації радіуса роздільної гіперсфери d_m , яка відбувається за ітераційним алгоритмом

$$d_m(k) = d_m(k-1) + \begin{cases} h, \text{if } E_m[d(k)] \geq E_m[d(k-1)]; \\ 0, \text{if else} \end{cases} \tag{2.4}$$

де k – змінна числа збільшень радіуса РГП; h – крок збільшення.

Процедура закінчується при знаходженні екстремального значення критерію $E_m^* = \max_{\{d\}} E_m$, де $\{d\} = \{0, 1, \dots, d(x_m \oplus x_{m+1})\}$ – множина радіусів

концентрованих гіперсфер, центр яких визначається вершиною еталонного вектора $x_m \in X_m^0$, x_{m+1} – еталонний вектор найближчого (до X_m^0) класу X_{m+1}^0 .

Нехай класи X_k^0 і X_l^0 є “найближчими сусідами”, тобто мають серед усіх класів найменшу міжцентрову відстань $d(x_k \oplus x_l)$, де x_k, x_l – еталонні вектори відповідних класів. Тоді за МФСВ з метою запобігання “поглинання” одним класом ядра іншого класу умови (2. 1.3) доповнюються таким предикатним виразом:

$$\begin{aligned} & (\forall X_k^0 \in \tilde{\mathfrak{R}}^{|M|}) (\forall X_l^0 \in \tilde{\mathfrak{R}}^{|M|}) [X_k^0 \neq X_l^0 \rightarrow (d_k^* < d(x_k \oplus x_l)) \& \\ & \& (d_l^* < d(x_k \oplus x_l))], \end{aligned} \quad (2.5)$$

де d_k^*, d_l^* – оптимальні радіуси контейнерів K_k^0 і K_l^0 відповідно.

Алгоритм навчання за МФСВ полягає в реалізації багатоциклічної ітераційної процедури оптимізації структурованих просторово-часових параметрів функціонування СПР шляхом пошуку глобального максимуму усередненого за алфавітом $\{X_m^0\}$ значення КФЕ навчання.

Нехай вектор параметрів функціонування СПР у загальному випадку має таку структуру:

$$g = \langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}, f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle, \quad \Xi_1 + \Xi_2 = \Xi, \quad (2.6)$$

де $\langle g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1} \rangle$ – генотипні параметри функціонування СПР, які впливають на параметри розподілу реалізацій образу; $\langle f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2} \rangle$ – фенотипні параметри функціонування СПР, які прямо впливають на геометрію контейнера класу розпізнавання.

При цьому відомі обмеження на відповідні параметри функціонування:

$$R_{\xi_1}(g_1, \dots, g_{\xi_1}, \dots, g_{\Xi_1}) \leq 0; \quad R_{\xi_2}(f_1, \dots, f_{\xi_2}, \dots, f_{\Xi_2}) \leq 0 \quad (2.7).$$

За методологією об’єктно-орієнтованого проектування подамо тестовий алгоритм навчання в рамках МФСВ для загального випадку ($M > 2$) як

ієрархічну ітераційну процедуру оптимізації структурованих просторово-часових параметрів (2.6) функціонування СПР:

$$g_{\xi_1}^* = \arg < [\max_{G_{\xi_1}} \dots [\max_{G_1} [\max_{F_{\xi_2}} [\dots [\max_{F_1} \overline{E}] \dots]] \dots]] > \quad (2.8)$$

де G_{ξ_1}, \dots, G_1 – області допустимих значень відповідних генотипних параметрів навчання; $\overline{E} = \frac{1}{M} \sum_{m=1}^M E_m$ – усереднене значення КФЕ навчання СПР; G_E – область значень функції інформаційного КФЕ навчання СПР; $g_{\xi_1}^*$ – оптимальне значення параметра навчання, яке визначається у зовнішньому циклі ітераційної процедури оптимізації; F_{ξ_2}, \dots, F_1 – області допустимих значень відповідних фенотипних параметрів навчання. Тут E_m – інформаційний КФЕ навчання СК розпізнавати реалізації класу X_m^o .

2.2 Математична модель навчання системи підтримки прийняття рішень

Розглянемо математичну модель СППР, яка реалізує класичну задачу розпізнавання образів за МФСВ. Математична модель повинна включати як обов'язкову складову частину вхідний математичний опис, який подамо на рівні системного аналізу у вигляді теоретико-множинної структури $\Delta_B = \langle G, T, \Omega, Z, Y, P, \Phi \rangle$, де G – простір вхідних сигналів (факторів); T – множина моментів часу зняття інформації; Ω – простір ознак розпізнавання; Z – простір можливих станів; Y – множина сигналів після первинної обробки інформації; $P: G \times T \times \Omega \rightarrow Z$ – оператор переходів, що відбиває механізм зміни станів під дією внутрішніх і зовнішніх збурень; $\Phi: G \times T \times \Omega \times Z \rightarrow Y$ – оператор оброблення зображення (формування вибіркової множини Y на вході СППР), який є реакцією на внутрішні і зовнішні збурення. Як універсум випробувань W розглядається декартовий добуток: $W = G \times T \times \Omega \times Z$.

Для чіткого детермінованого розбиття $R^{|M|}$ потужності M , оператор побудови розбиття η задає відображення $\eta: Y \mapsto R^{|M|}$. Апріорно оператором $\nu: Y \rightarrow L^{|M|}$ будується покриття $L^{|M|} = \{X_m^0\}$, яке визначає абетку класів розпізнавання і на якому на відміну від розбиття відношення еквівалентності відсутнє. Оператор $\alpha: R^{|M|} \rightarrow L^{|M|}$ переводить апостеріорно розбиття $R^{|M|}$ в покриття $L^{|M|}$ і замикає комутативне кільце. Перевірка гіпотези про належність реалізацій образу здійснюється оператором класифікації $\psi: R^{|M|} \rightarrow I^{|M+1|}$, де $I^{|M+1|} = \{\gamma_1, \gamma_2, \dots, \gamma_M, \gamma_{M+1}\}$ – множина допустимих гіпотез (рішень). При цьому гіпотеза γ_{M+1} означає відмову від класифікації. У загальному випадку математичну модель будь-якої системи керування, яка розв'язує задачу класифікаційного аналізу, подамо у вигляді діаграми відображень відповідних множин (рис. 2.1):




Рисунок 2.1 – Математична модель системи керування

Оператор зворотного зв'язку ξ коригує геометричні параметри розбиття $\tilde{\mathfrak{R}}^{|M|}$ з метою поліпшення точнісних характеристик. Саме спосіб реалізації оператора ξ породжує різні методи та підходи до розв'язання проблеми адаптивного навчання системи керування.

При обґрунтуванні гіпотези нечіткої компактності має місце нечітке розбиття $\tilde{\mathfrak{R}}^{|M|} \subset \Omega$.

Тоді замість оператора η застосуємо оператор θ нечіткої факторизації простору ознак: $\theta: Y \rightarrow \tilde{\mathfrak{R}}^{|M|}$. Нехай оператор класифікації $\psi: \tilde{\mathfrak{R}}^{|M|} \rightarrow I^{|l|}$ визначає перевірку основної статистичної гіпотези про належність реалізацій $\{x_m^{(j)} \mid j = \overline{1, n}\}$ класу X_m^0 , де l – кількість статистичних гіпотез. Принциповою відмінністю МФСВ від відомих методів автоматичної класифікації є ітераційна оптимізація процесу навчання за інформаційним КФЕ.

Для обчислення КФЕ оператор $\gamma: I^{|l|} \rightarrow \mathfrak{S}^{|q|}$ шляхом оцінки прийнятих гіпотез γ_l формує множину ТХ $\mathfrak{S}^{|q|}$, де $q=|2$ – кількість точнісних характеристик (ТХ), а оператор $\varphi: \mathfrak{S}^{|q|} \rightarrow E$ обчислює множину значень інформаційного КФЕ, який є функціоналом від ТХ. Ітераційний процес оптимізації геометричних параметрів розбиття $\tilde{\mathfrak{R}}^{|M|}$ реалізується оператором $\tau: E \rightarrow \tilde{\mathfrak{R}}^{|M|}$ шляхом пошуку максимуму КФЕ $E_m^* = \max_{\{d\}} E_m$, де $\{d\}$ – множина кроків навчання

розпізнаванню реалізацій класу X_m^0 . Структурна діаграма процесу навчання за МФСВ для випадку нечіткого розбиття має вигляд:




Рисунок 2.2 – Процес навчання за МФСВ у випадку нечіткого розбиття

Таким чином, на діаграмі (див. рис. 2.2) контур операторів $\psi \rightarrow \gamma \rightarrow \phi \rightarrow r$ безпосередньо оптимізує геометричні параметри розбиття $\tilde{\mathfrak{R}}^{|M|}$. Оператор $U: E \rightarrow G \times T \times \Omega \times Z$ регламентує процес навчання. Оскільки в цьому контурі також застосовано процедуру обчислення інформаційного критерію, то він дозволяє розв'язувати задачу оптимізації параметрів плану навчання, які визначають, наприклад, обсяг і тривалість випробовувань, потужність словника ОР, черговість подання для навчання класів розпізнавання та інше.

За алгоритмом (2.8) кожен параметр навчання повинен мати в діаграмі відображень множин свій контур оптимізації при виконанні умови повної композиції: множина E є загальною для всіх контурів оптимізації. Розглянемо побудову такого контура оптимізації СКД. Нехай контур оптимізації СКД, яка утворює множину D , замикається послідовно оператором $\delta_1: E \mapsto D$ і оператором $\delta_2: D \rightarrow Y$, який змінює реалізації образу в процесі максимізації критерію $E_m \in E$.

Тоді діаграма відображення множин з урахуванням додаткових контурів оптимізації набуде вигляду, як показано на рис. 2.3.




Рисунок 2.3 – Процес навчання за МФСВ з оптимізацією СКД

У діаграмі у порівнянні з базовою діаграмою (див. рис. 2.2) з'явився новий контур оптимізації (рис 2.4), який відповідає за оптимізацію СКД на ознаки розпізнавання.




Рисунок 2.4 – Контур оптимізації СКД на ОР

Таким чином, базова математична модель може бути легко модифікована для вирішення задачі оптимізації різноманітних параметрів навчання.

2.3 Критерій функціональної ефективності

Для оцінки функціональної ефективності СПР широко використовуються ентропійні інформаційні критерії. Наприклад, за Шенноном такий нормований критерій має вигляд

$$E = \frac{H_0 - H(\gamma)}{H_0}, \quad (2.9)$$

де H_0 – апіорна (безумовна) ентропія:

$$H_0 = -\sum_{l=1}^M p(\gamma_l) \log_2 p(\gamma_l); \quad (2.10)$$

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

$$H(\gamma) = -\sum_{l=1}^M p(\gamma_l) \sum_{m=1}^M p(\mu_m / \gamma_l) \log_2 p(\mu_m / \gamma_l), \quad (2.11)$$

де $p(\gamma_l)$ – апріорна ймовірність прийняття гіпотези γ_l ; $p(\mu_m / \gamma_l)$ – апостеріорна ймовірність появи події μ_m за умови прийняття гіпотези γ_l ; M – число альтернативних гіпотез.

На практиці при оцінюванні функціональної ефективності СК, що навчається, можуть мати місце такі допущення:

- рішення є двоальтернативним ($M=2$);
- оскільки здатна навчатися СК слабо формалізованим процесом функціонує за умови невизначеності, то за принципом Бернуллі-Лапласа виправдано прийняття рівноймовірних гіпотез $p(\gamma_1) = p(\gamma_2) = 0,5$.

Тоді критерій з урахуванням виразів (2.10) і (2.11) набирає такий частинний вигляд:

$$E = 1 + \frac{1}{2} \sum_{l=1}^2 \sum_{m=1}^2 p(\mu_m / \gamma_l) \log_2 p(\mu_m / \gamma_l). \quad (2.12)$$

При двоальтернативному рішенні ($M=2$) за основну беремо гіпотезу γ_1 про знаходження значення ознаки розпізнавання, що контролюється, в полі допусків δ і як альтернативну їй – гіпотезу γ_2 . При цьому мають місце чотири можливих результати оцінки виміру ознаки (рис. 2.5), які характеризуються наступними ймовірностями – точнісними характеристиками: помилка першого роду $-\alpha = \rho(x \notin \delta / z \in \delta)$ (рис. 2.5а); помилка другого роду $-\beta = \rho(x \in \delta / z \notin \delta)$ (рис. 2.5б); перша достовірність $-D_1 = \rho(x \in \delta / z \in \delta)$ (рис. 2.5в) і

друга достовірність— $D_2 = p(x \notin \delta / z \notin \delta)$ (рис. 2.5г), де x, z — вимірне та дійсне значення ознаки розпізнавання відповідно.




Рисунок 2.5 – Можливі результати оцінки виміру ознак розпізнавання при $M=2$

Розіб'ємо множину значень ознак на області μ_1 та μ_2 . Область μ_1 включає значення, що знаходяться в допуску δ , а μ_2 — не в допуску. Тоді можна записати $\alpha = p(\gamma_2 / \mu_1)$; $\beta = p(\gamma_1 / \mu_2)$; $D_1 = p(\gamma_1 / \mu_1)$; $D_2 = p(\gamma_2 / \mu_2)$.

Виразимо апостеріорні ймовірності $p(\mu_m / \gamma_l)$ через апіорні за формулою Байєса:

$$p(\mu_m / \gamma_l) = \frac{p(\mu_m) p(\gamma_l / \mu_m)}{p(\mu_1) p(\gamma_l / \mu_1) + p(\mu_2) p(\gamma_l / \mu_2)}$$

та, прийнявши $p(\mu_1) = p(\mu_2) = 0,5$, отримаємо:

$$p(\mu_1 / \gamma_1) = \frac{D_1}{D_1 + \beta}; \quad p(\mu_2 / \gamma_1) = \frac{\beta}{D_1 + \beta}; \quad p(\mu_1 / \gamma_2) = \frac{\alpha}{\alpha + D_2}; \quad p(\mu_2 / \gamma_2) = \frac{p_2 D_2}{p_1 \alpha + p_2 D_2}. \quad (2.13)$$

Після підстановки (2.12) в (2.13) отримаємо формулу для обчислення КФЕ за Шенноном:

$$E = 1 + \frac{1}{2} \left(\frac{\alpha}{\alpha + D_2} \log_2 \frac{\alpha}{\alpha + D_2} + \frac{D_1}{D_1 + \beta} \log_2 \frac{D_1}{D_1 + \beta} + \frac{\beta}{D_1 + \beta} \log_2 \frac{\beta}{D_1 + \beta} + \frac{D_2}{\alpha + D_2} \log_2 \frac{D_2}{\alpha + D_2} \right). \quad (2.14)$$

3 ІНФОРМАЦІЙНЕ ТА ПРОГРАМНЕ ЗАБЕЗПЕЧЕННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ

3.1 Формування вхідного математичного опису

В роботі розглядаються зображення робочих поверхонь деталей, що використовуються при діагностуванні та визначенні причин їх пошкодження. При формуванні вхідного математичного опису розглядалися три класи пошкоджень, зображення яких наведено на рис 3.1.



Рисунок 3.1 – Графічне відображення навчальних матриць

Навчальні матриці формуються безпосередньо з зображення, при цьому зчитується яскравість кожного пікселя, що змінюється від 0 - чорний колір до 255 - білий колір, проміжні значення є градаціями сірого. Враховуючи стаціонарність зображень, (тобто те, що невеличкий елемент зображення містить достатньо інформації для відновлення зображення в цілому) будемо вважати кожний рядок пікселів зображення реалізацією класу, при цьому кількість ознак буде співпадати з кількістю елементів такого рядка. В роботі розглядалися зображення 100x100 пікселів. Таким чином, навчальні матриці для кожного класу склалися з $N=100$ ознак розпізнавання та $n=100$ реалізацій.

3.2 Базовий алгоритм навчання системи розпізнавання

Призначенням базового алгоритму навчання LEARNING [8] є оптимізація геометричних параметрів контейнерів класів розпізнавання, які відновлюються на кожному кроці навчання в радіальному базисі. Вхідною інформацією для навчання за базовим алгоритмом у загальному випадку є дійсний масив реалізацій образу $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$; система полів контрольних допусків $\{\delta_{k,i}\}$ і рівні селекції $\{\rho_m\}$ координат двійкових еталонних векторів-реалізацій образу, які за замовчанням дорівнюють 0,5 для всіх класів розпізнавання.

Розглянемо етапи реалізації алгоритму LEARNING:

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

$$x_{m,i}^{(j)} = \begin{cases} 1, & \text{if } y_{m,i}^{(j)} \in \delta_{K,i}, \\ 0, & \text{if } y_{m,i}^{(j)} \notin \delta_{K,i}. \end{cases} \quad (3.1)$$

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

$$x_{m,i} = \begin{cases} 1, & \text{if } \frac{1}{n} \sum_{j=1}^n x_{m,i}^{(j)} > \rho_m, \\ 0, & \text{if } \textit{else}, \end{cases} \quad (3.2)$$

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

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

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

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

в) для кожного рядка матриці кодових відстаней знаходиться мінімальний елемент, який належить стовпчику вектора, найближчого до вектора, що визначає строку. За наявності декількох однакових мінімальних елементів вибирається з них будь-який, оскільки вони є рівноправними;

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 рекурентною процедурою (2.3). 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 $\{d\} = \{0, 1, \dots, d < d(x_m \oplus x_l)\}$ – множина радіусів концентрованих гіперсфер, центр яких визначається вершиною $x_m \in X_m^o$.

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

$$d_m^* = \arg \max_{\{d\}} E_m^*.$$

На рис. 3.2 наведено структурну схему базового алгоритму навчання LEARNING.

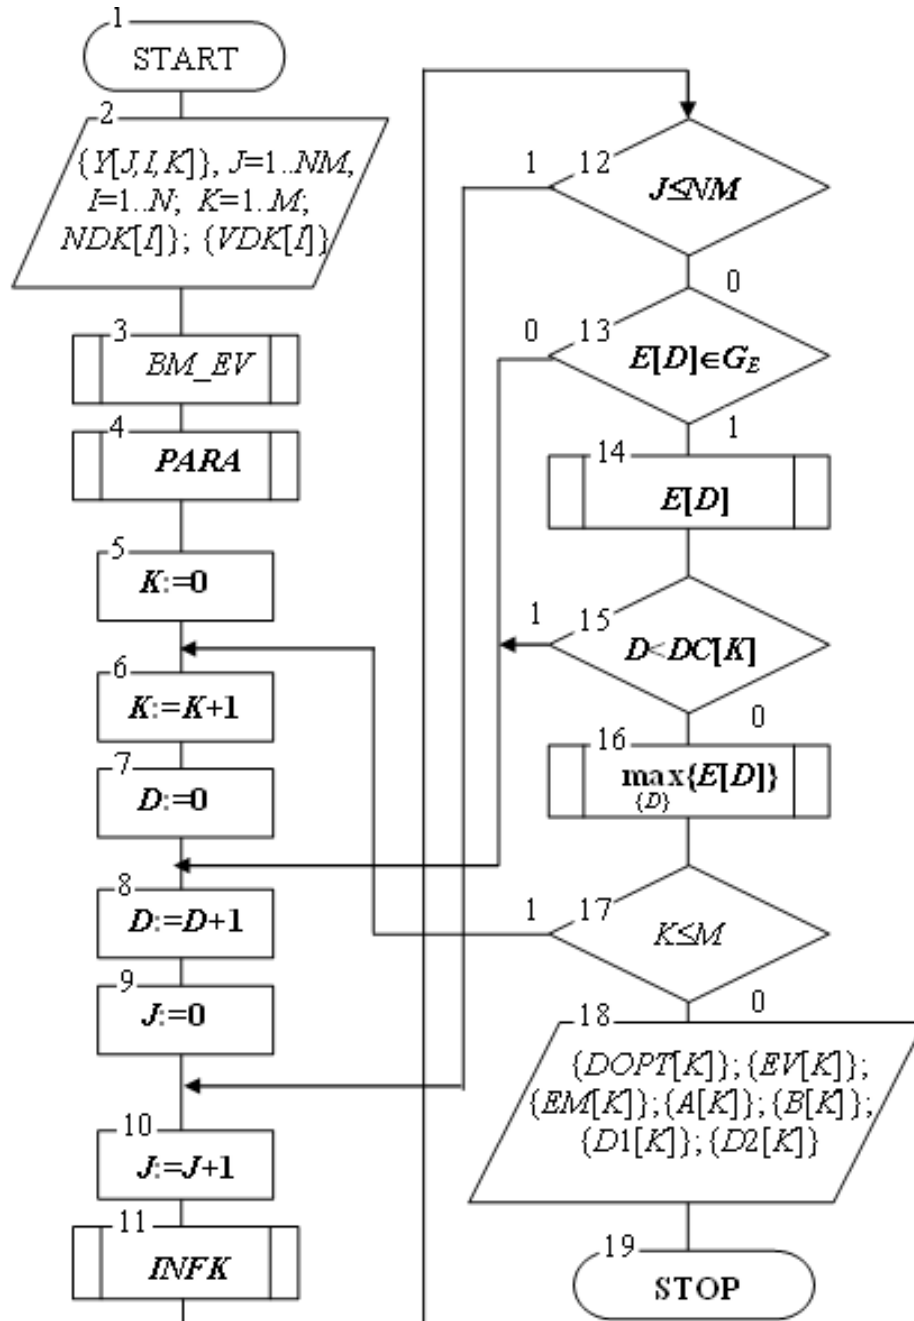


Рисунок 3.2 – Структурна схема базового алгоритму навчання

Тут показано такі входні дані: $\{Y[J,I,K]\}$ – масив навчальних вибірок, $J = \overline{1, NM}$ – змінна кількості випробувань, де NM – мінімальний обсяг репрезентативної навчальної вибірки, $I = \overline{1, N}$ – змінна кількості ознак розпізнавання, $K = \overline{1, M}$ – змінна кількості класів розпізнавання; $\{NDK[I]\}$, $\{VDK[I]\}$ – масиви нижніх і верхніх контрольних допусків на ознаки відповідно. Результатом реалізації алгоритму є: $\{DOPT[K]\}$ – цілий масив оптимальних значень радіусів контейнерів класів розпізнавання у кодовій відстані Хеммінга; $\{EV[K]\}$ – масив еталонних двійкових векторів класів

розпізнавання; $\{EM[K]\}$ – дійсний масив максимальних значень інформаційного КФЕ процесу навчання; $\{D1[K]\}$, $\{A[K]\}$, $\{B[K]\}$, $\{D2[K]\}$ – дійсні масиви оцінок екстремальних значень точнісних характеристик процесу навчання для відповідних класів розпізнавання: перша достовірність, помилки першого та другого роду і друга достовірність відповідно. Змінна D є робочою змінною кроків навчання, на яких послідовно збільшується значення радіуса контейнера.

У структурній схемі алгоритму (рис. 3.2) блок 3 формує масив навчальних двійкових вибірок $\{X[J,I,K]\}$ шляхом порівняння значень елементів масиву $\{Y[J,I,K]\}$ з відповідними контрольними допусками за правилом (1) і формує масив еталонних двійкових векторів $\{EV[K]\}$ шляхом статистичного усереднення стовпців масиву $\{X[J,I,K]\}$ за правилом (2) при відповідному рівні селекції, який за замовчуванням дорівнює $\rho_m = 0,5$. Блок 4 здійснює розбиття множини еталонних векторів на пари “найближчих сусідів”. Блок 11 обчислює на кожному кроці навчання значення інформаційного КФЕ. При невиконанні умови блока порівняння 12 блок 13 оцінює належність поточного значення критерію $E[D]$ робочій області G_E визначення його функції і при позитивному рішенні блока 13 це значення запам’ятовується блоком 14. При негативному рішенні блока порівняння 15, в якому величина $DC[K]$ дорівнює кодовій відстані між парою сусідніх еталонних векторів, блок 16 здійснює у робочій області G_E пошук глобального максимуму КФЕ – $EM[K]$ і визначає для нього екстремальне значення радіуса гіперсфери – $DOPT[K]$. Аналогічно будуються оптимальні контейнери для інших класів. Якщо параметри навчання $\{DOPT[K]\}$ і $\{EV[K]\}$ є вхідними даними для екзамену, то значення КФЕ та екстремальних оцінок точнісних характеристик використовуються для аналізу ефективності процесу навчання.

Таким чином, основною процедурою базового алгоритму навчання за МФСВ є обчислення на кожному кроці навчання інформаційного КФЕ і організація пошуку його глобального максимуму в робочій області визначення функції критерію.

3.3 Алгоритм паралельно-послідовної оптимізації системи контрольних допусків на ознаки розпізнавання

На ефективність навчання СППР значно впливає використання контуру оптимізації СКД. Алгоритм оптимізації контрольних допусків за МФСВ полягає у наближенні глобального максимуму інформаційного критерію оптимізації до найбільшого його значення в області значень функції.

Розглянемо схему алгоритму LEARNING-2, призначеного для паралельної оптимізації контрольних допусків на ознаки розпізнавання. Вхідні дані: масив реалізацій образу $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$; стартова СКД $\{\delta_{K,i}\}$ і система нормованих допусків (СНД) $\{\delta_{H,i}\}$, яка визначає область значень відповідних контрольних допусків. За область визначення параметра δ приймається інтервал $[1; \delta_H / 2]$, де δ_H – ширина нормованого поля допусків. Стартовий параметр δ_i поля контрольних допусків може дорівнювати половині відповідного симетричного поля нормованих допусків для i -ї ознаки за умови випадковості її значень. Попередньо для кожної ознаки визначається ціна градації Δ_i , на яку змінюється i -та ознака.

Розглянемо кроки реалізації цього алгоритму:

1. Обнулюється лічильник кроків зміни параметра δ : $l := 0$.
2. Запускається лічильник: $l := l + 1$ і обчислюються нижні та верхні контрольні допуски для всіх ознак: $\{A_{HK,i}[l] := y_{m,i} - \delta[l]\}$ і $\{A_{BK,i}[l] := y_{m,i} + \delta[l]\}$, $i = \overline{1, N}$, відповідно.
3. Реалізується базовий алгоритм навчання.
4. Якщо $E_1^*[l] \geq E_1^*[l - 1]$, то виконується пункт 5, інакше пункт 6.
5. Якщо $\delta \leq \delta_H / 2$, то виконується пункт 2, інакше пункт 6.
6. $\{A_{HK,i}^* := A_{HK,i}[l - 1]\}; \{A_{BK,i}^* := A_{BK,i}[l - 1]\}$, $i = \overline{1, N}$;
 $E_1^* := E_1^*[l - 1]$ і “ЗУПИН”.

Розглянемо схему алгоритму LEARNING-1, призначеного для послідовної оптимізації контрольних допусків на ознаки розпізнавання. Вхідні

дані: масив реалізацій образу $\{y_m^{(j)} \mid m = \overline{1, M}; j = \overline{1, n}\}$; стартова СКД $\{\delta_{K,i}\}$ і система нормованих допусків (СНД) $\{\delta_{H,i}\}$, яка визначає область значень відповідних контрольних допусків. Стартовий параметр δ_i поля контрольних допусків може дорівнювати половині відповідного симетричного поля нормованих допусків для i -ї ознаки за умови випадковості її значень. Попередньо для кожної ознаки визначається ціна градації Δ_i , на яку змінюється i -та ознака.

Схема алгоритму послідовної оптимізації контрольних допусків така:

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

2. Для стартової системи допусків обчислюється за базовим алгоритмом навчання LEARNING значення функції $E_{\max,1}^{(l)}$.

3. Формування лічильника прогонів: $l: l+1$.

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

5. Формування лічильника ознак розпізнавання: $i: i+1$.

6. Визначення екстремального значення параметра $\hat{\delta}_{K,i}^{(l)}$ за процедурою, в якій внутрішній цикл оптимізації реалізує алгоритм LEARNING.

$$7. \hat{\delta}_{K,i}^{(l)} := \mathbf{max}_{\delta_{K,i} \in \delta_{H,i}} \delta_{K,i}^{(l)}.$$

8. Якщо $i \leq N$, то виконується пункт 5, інакше пункт 9.

9. Якщо $\left| \overline{E_{\max}^{(l-1)}} - \overline{E_{\max}^{(l)}} \right| \leq \varepsilon$, де ε – будь-яке мале позитивне число, то виконується пункт 10, інакше пункт 3.

10. $\{\delta_{K,i}^*\} := \{\hat{\delta}_{K,i}^{(l)}\}$ і “ЗУПИН”.

В роботі запропоновано поєднати алгоритми паралельної та послідовної оптимізації параметрів системи контрольних допусків на ознаки розпізнавання. На першій ітерації нового алгоритму використовується паралельна оптимізація системи контрольних допусків, результати роботи якої подаються на вхід алгоритму послідовної оптимізації СКД. Таке поєднання алгоритмів характеризується більшою ефективністю ніж кожний з її складових окремо.

3.4 Алгоритм оцінки ефективності ієрархічного класифікатора

- 1) Формуємо множину ієрархічних класифікаторів $Q: Q_l = (V_1^{(l)}, V_2^{(l)}, \dots, V_t^{(l)}, \dots, V_{T_l}^{(l)})$, де l – номер ієрархічного класифікатора ($l=1 \dots |Q|$), $V_t^{(l)}$ – множина класів, вирішальні правила яких формуються на t – тому рівні ієрархічного класифікатора Q_l ; T_l – максимальна кількість рівнів ієрархій Q_l класифікатора.
- 2) Ініціюємо лічильник ієрархічних класифікаторів $l:=1$.
- 3) Оптимізуємо параметри Q_l – ієрархічного класифікатора з використанням паралельного алгоритму оптимізації системи контрольних допусків на ознаки розпізнавання $\{\delta_t^{(l)}\}$ і базового алгоритму оптимізації геометричних параметрів контейнерів класів розпізнавання $\{R_t^{|V_t^{(l)}}|\}$. При визначенні найближчих (сусідніх) класів для класів $V_t^{(l)}$ враховуємо лише класи тих рівнів ієрархії, що є не вищими за поточний рівень t , тобто $\{V_t^{(l)}, V_{t+1}^{(l)}, \dots, V_{T_l}^{(l)}\}$.
- 4) Визначаємо усереднене максимальне значення КФЕ по всім класам ієрархії Q_l

$$\bar{E}_l^* = \frac{\sum_{t=1}^{T_l} \left(\sum_{k=1}^{|V_t^{(l)}|} E_{t,k}^* \right)}{\left| \bigcup_{t=1}^{T_l} V_t^{(l)} \right|},$$

де $E_{t,k}^*$ – максимальне значення КФЕ в робочій області його визначення, що було отримане в процесі оптимізації параметрів функціонування інтелектуальної системи для k -того класу на t -тому рівні.

- 5) $l:=l+1/$
- 6) Якщо $l \leq |Q|$, то переходимо до наступного варіанту ієрархічного класифікатора (перехід до етапу 3), інакше перехід до етапу 7.
- 7) Визначаємо оптимальний в інформаційному розумінні ієрархічний класифікатор Q_{opt} для якого виконується умова

$$\bar{E}_{opt}^* = \max_l \bar{E}_l^*$$

8) Останов.

3.5 Короткий опис програмної реалізації

Програмна реалізація була виконана за допомогою пакету Matlab. Були використані наступні константи та змінні (табл. 3.1):

Таблиця 3.1 Основні константи та змінні програми

| Ім'я константи або змінної | Короткий опис |
|---------------------------------------|---------------------------------------------------------------------------------------------------------------------------------|
| class1, class2, class3 | Масиви вхідних даних |
| E_opt1_alg1, E_opt2_alg1, E_opt3_alg1 | Оптимальні значення КФЕ для алгоритму корекції генотипних параметрів для першого, другого та третього базового класу відповідно |
| average | Середнє значення для першого класу |
| delta | Значення, що впливає на формування контрольних допусків |
| up_fringe, under_fringe | Верхній та нижній контрольний допуск відповідно |
| Bin1, Bin2, Bin3 | Бінарні матриці |
| ev1, ev2, ev3 | Масиви еталонних векторів |
| MR | Міжцентрова відстань |
| SKR1, SKR2 | Система контрольних допусків на ознаки розпізнавання |
| K1, K2, K3, K4, D1, D2, alpha, beta | Точнісні характеристики |
| E1, E2 | Критерій функціональної ефективності |
| r1, r2 | Оптимальні радіуси контейнерів класів навчання |
| work_space1, work_space2 | Робочі області для класів розпізнавання |
| delta_opt | Оптимальна δ |

Крім того було розроблено наступні процедури та функції (Табл. 3.2):

Таблиця 3.2 Основні процедури та функції програми


| Ім'я функції | Короткий опис |
|--------------|------------------------------------------------------------------------|
| check | Функція перевірки під логарифмічного виразу у формулі критерію Шеннона |
| ev | Функція розрахунку еталонних векторів |
| examen | Функція екзамену |
| optim | Алгоритм паралельної оптимізації |
| work_space | Функція розрахунку робочої області та оптимального радіусу |

Програмний код наведено в Додатку.

3.6 Результати фізичного моделювання

У результаті роботи програми було оптимізовано контрольні допуски на ознаки розпізнавання. Для оптимізації було використано паралельну оптимізацію. Як критерій оптимізації параметрів функціонування використовувалася інформаційна міра Шеннона.

На першому етапі розглядалася задача відтворення вирішальних правил для розпізнавання двох класів дефектів за зображення дефектів (рис. 3.3 а-б). За базовий клас було обрано клас X_1^o - дефект №1. Спочатку δ було обране фіксованого значення – 15.



а)




Рисунок 3.3 - Графік зміни критерію функціональної ефективності для
а) класу X_1^o , б) класу X_2^o

Значення геометричних параметрів класу для X_1^o $r_1=43$, класу X_2^o $r_2=30$. Значення міжцентрової відстані між класами склало 55. Тобто контейнери класів перетинаються, що підтверджують максимальні значення КФЕ системи: для класу X_1^o $E^*_1 = 0.47013$ ($D1 = 0.50$; $\beta = 0.01$), для X_2^o – $E^*_2 = 0.68325$ ($D1 = 0,81$; $\beta = 0$).

Таким чином, відтворений класифікатор не є безпомилковим і для підвищення його ефективності необхідно застосувати паралельну оптимізацію СКД. Результати оптимізації даного параметру за паралельним алгоритмом наведені на рис. 3.4:





Рисунок 3.4 – Процес паралельної оптимізації кроку δ СКД

Аналіз рисунку вказує на те, що оптимальним в інформаційному розумінні значення параметра $\delta^* = 14$. Оскільки йому відповідає максимальне усередненого значення КФЕ $\bar{E}^* = 0.67083$. На рисунку 3.5 показано процес оптимізації радіусів контейнерів класів розпізнавання.



а)




Рисунок 3.5 – Графік зміни критерію функціональної ефективності при паралельній оптимізації для а) класу X_1^o , б) класу X_2^o

Аналіз результатів оптимізації показує, що оптимальними параметрами контейнера класу для X_1^o $r_1=53$, класу X_2^o $r_2=31$. Значення міжцентрової відстані між класами склало 67. Цим параметрам контейнерів відповідають такі значення КФЕ і точнісних характеристик системи керування: для класу $X_1^o \in E_{\max}^{(1)} = 0.67455$ ($D1 = 0,98$; $\beta = 0,12$), для класу $X_2^o \in E_{\max}^{(2)} = 0.66712$ ($D1 = 0,79$; $\beta = 0$).

Порівнявши результати роботи системи до та після паралельної оптимізації, приходимо до висновку, що паралельна оптимізація дала змогу підвищити точність розпізнавання реалізацій. При цьому ймовірність прийняття системою невірної рішення не перевищує 12% для першого класу та 21% - для другого.

Таким чином, відтворений класифікатор не є безпомилковим і для підвищення його ефективності необхідно застосувати послідовну оптимізацію СКД. Результати оптимізації даного параметру за послідовним алгоритмом наведені на рис. 3.6:

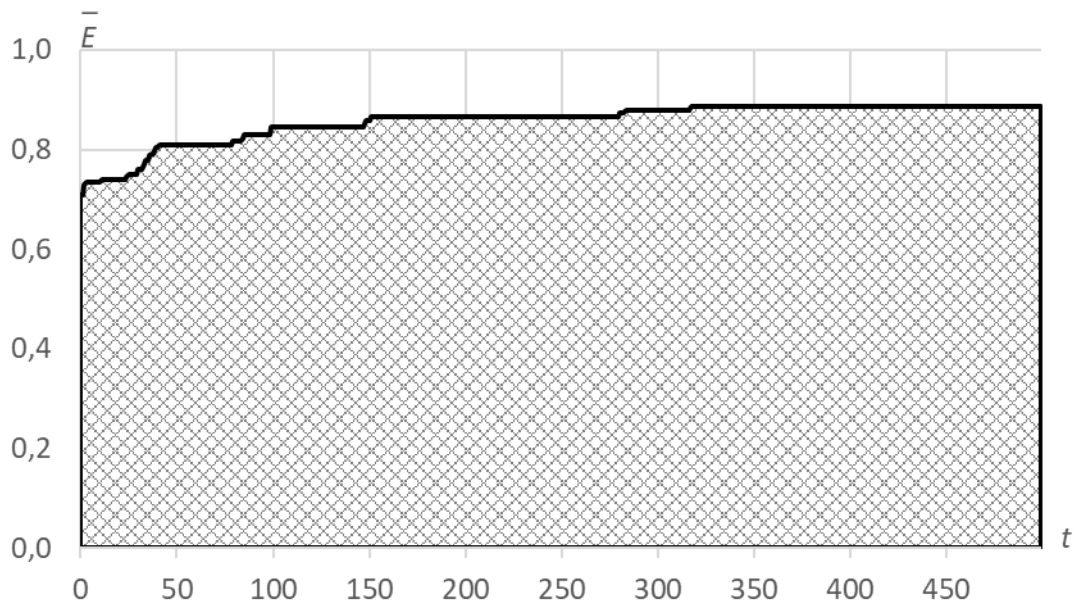



Рисунок 3.6 – Процес послідовної оптимізації кроку δ СКД

Аналіз рисунку вказує на те, що оптимальному в інформаційному розумінні значення параметра системи контрольних допусків відповідає максимальне усередненого значення КФЕ $\bar{E}^* = 0,88674$. На рисунку 3.7 показано процес оптимізації радіусів контейнерів класів розпізнавання.



а)




Рисунок 3.7 – Графік зміни критерію функціональної ефективності при паралельній оптимізації для а) класу X_1^o , б) класу X_2^o

Аналіз результатів оптимізації показує, що оптимальними параметрами контейнера класу для X_1^o $r_1=26$, класу X_2^o $r_2=27$. Значення міжцентрової відстані між класами склало 42. Цим параметрам контейнерів відповідають такі значення КФЕ і точнісних характеристик системи керування: для класу $X_1^o \in E_{\max}^{(1)} = 0.93038$ ($D1 = 1$; $\beta = 0,02$), для класу $X_2^o \in E_{\max}^{(2)} = 0.84309$ ($D1 = 0,94$; $\beta = 0$).

Порівнявши результати роботи системи до та після послідовної оптимізації, приходимо до висновку, що послідовна оптимізація дала змогу підвищити точність розпізнавання реалізацій. При цьому ймовірність прийняття системою невірної рішення не перевищує 2% для першого класу та 6% - для другого.

При збільшенні потужності алфавіту класів розпізнавання до трьох можливе застосування ієрархічного класифікатора. В роботі проводилася оцінка ефективності чотирьох варіантів ієрархічного класифікатора. Графічне відображення цих варіантів наведено на рис. 3.8.

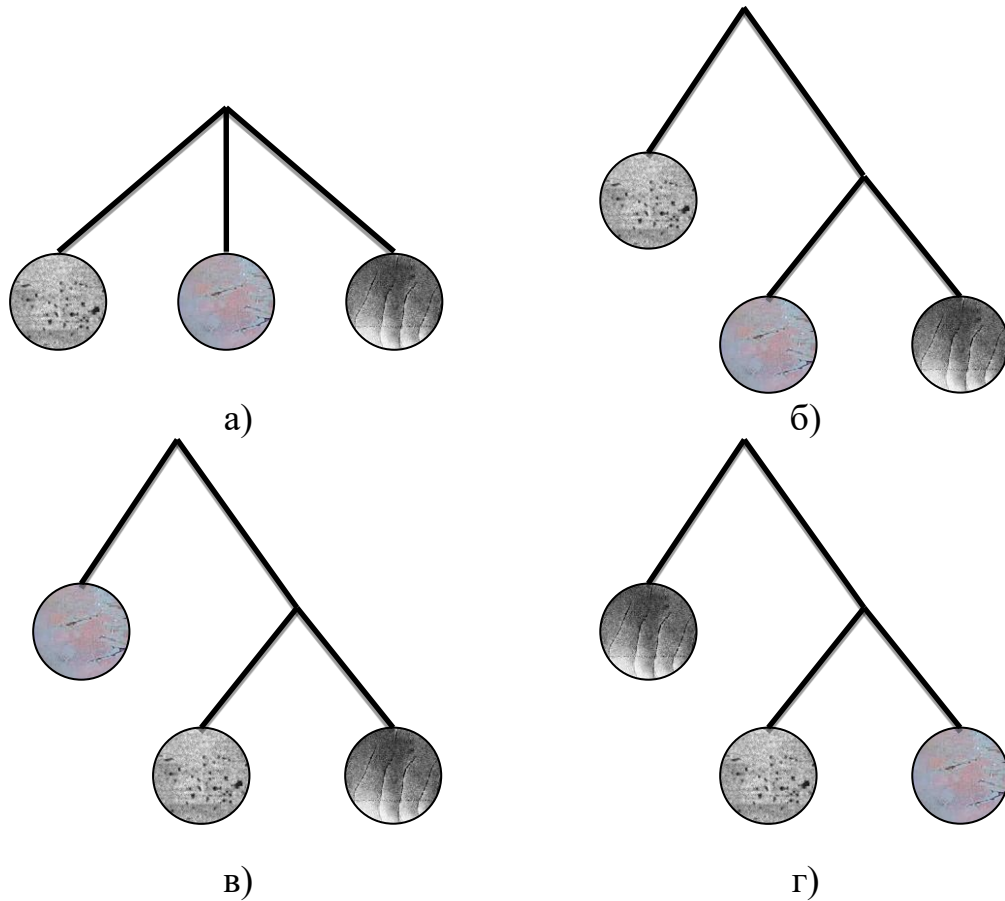


Рисунок 3.8 - Варіанти ієрархічних класифікаторів ефективність, яких оцінювалася: а) однорівневий класифікатор, б-г) дворівневі класифікатори

При оптимізації функціональних параметрів однорівневого класифікатора (рис. 3.8 а)) значення кроку СКД δ , оптимізувалося автоматично. Як критерій оптимізації параметрів функціонування використовувався ентропійний критерій Шеннона.

Таблиці 3.3-3.4 відображає оптимальні параметри класів розпізнавання, отриманих в процесі навчання СППР з паралельною та послідовною оптимізацією СКД.

Таблиця 3.3 - Оптимальні параметри класів розпізнавання після паралельної оптимізації СКД

| Клас розпізнавання | Оптимальне КФЕ | Оптимальний радіус | Точнісні характеристики | |
|--------------------|----------------|--------------------|-------------------------|---------|
| | | | D1 | β |
| X_1^0 | 0.10486 | 44 | 0,52 | 0,19 |
| X_2^0 | 0.68325 | 27 | 0.81 | 0 |
| X_3^0 | 0.65960 | 22 | 0.78 | 0 |

Таблиця 3.4 - Оптимальні параметри класів розпізнавання після послідовної оптимізації СКД

| Клас розпізнавання | Оптимальне КФЕ | Оптимальний радіус | Точнісні характеристики | |
|--------------------|----------------|--------------------|-------------------------|---------|
| | | | D1 | β |
| X_1^0 | 0.78025 | 42 | 0,90 | 0 |
| X_2^0 | 0.73523 | 36 | 0.90 | 0,01 |
| X_3^0 | 0.74984 | 28 | 0.91 | 0,01 |

Аналогічно проводилася оцінка ефективності інших дворівневих варіантів ієрархічних класифікаторів (рис. 3.5 б-г)). Результати такої оцінки наведено в таблиці 3.4.

Таблиця 3.4. –Результати оцінки ефективності ієрархічних класифікаторів

| Рівень ієрархії | Клас розпізнавання | Оптимальне КФЕ | Оптимальний радіус | Точнісні характеристики | |
|----------------------------------------------|--------------------|----------------|--------------------|-------------------------|---------|
| | | | | D1 | β |
| Ієрархічний класифікатор Q_1 (рис. 3.5 а)) | | | | | |
| 1 рівень | X_1^0 | 0.78025 | 42 | 0,90 | 0 |
| | X_2^0 | 0.73523 | 36 | 0.90 | 0,01 |
| | X_3^0 | 0.74984 | 28 | 0.91 | 0,01 |
| Усереднене КФЕ \bar{E}_1^* | | 0.75510 | | | |
| Ієрархічний класифікатор Q_2 (рис. 3.5 б)) | | | | | |
| 1 рівень | X_1^0 | 0.78025 | 42 | 0,90 | 0 |
| 2 рівень | X_2^0 | 1 | 20 | 1 | 0 |
| | X_3^0 | 1 | 6 | 1 | 0 |
| Усереднене КФЕ \bar{E}_2^* | | 0.92675 | | | |
| Ієрархічний класифікатор Q_3 (рис. 3.5 в)) | | | | | |
| 1 рівень | X_2^0 | 0.73523 | 36 | 0.90 | 0,01 |
| 2 рівень | X_1^0 | 1 | 19 | 1 | 0 |
| | X_3^0 | 1 | 13 | 1 | 0 |
| Усереднене КФЕ \bar{E}_3^* | | 0.91174 | | | |
| Ієрархічний класифікатор Q_4 (рис. 3.5 г)) | | | | | |
| 1 рівень | X_3^0 | 0.74984 | 28 | 0.91 | 0,01 |
| 2 рівень | X_1^0 | 0.93038 | 26 | 1 | 0.02 |
| | X_2^0 | 0.84309 | 27 | 0.94 | 0 |
| Усереднене КФЕ \bar{E}_4^* | | 0.84110 | | | |

Аналіз табл. 3.4 вказує на те, що максимальне усереднене значення КФЕ $\bar{E}_{opt}^* = \bar{E}_2^* = 0,92675$ було отримано для ієрархічного класифікатора Q_2 . Таким чином, ієрархічний класифікатор Q_2 , графічне відображення якого подано на рис. 3.5 б), є оптимальним в інформаційному розумінні.

ВИСНОВКИ

У роботі було розроблено інтелектуальну систему діагностування дефектів деталей, що обробляються на верстатах токарної групи за зображенням, що здатна навчатися в рамках сучасної інформаційно екстремальної інтелектуальної технології (ІЕІ-технології). При цьому виконано такі завдання:

- 1) сформовано вхідний математичний опис інтелектуальної системи,
- 2) розроблено математичні моделі функціонування системи в режимі навчання,
- 3) розроблено та програмно реалізовано алгоритми оптимізації функціональних параметрів системи,
- 4) виконано оцінку ефективності системи на практичній задачі автоматичного розпізнавання трьох класів дефектів.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Homes Bernard. Advanced Testing of Systems-of-Systems. Volume 1: Theoretical Aspects .- Wiley-ISTE, 2022. — 308 p.
2. Homes Bernard. Advanced Testing of Systems-of-Systems. Volume 2: Practical Aspects .- Wiley-ISTE, 2022. — 306 p.
3. Arnold W., Goebbels K., Kumar A. Non-destructive Materials Characterization and Evaluation . - Springer, 2023. — 333 p.
4. Bowler N. Eddy-Current Nondestructive Evaluation. - Springer, 2019. — 232 p.
5. Papaalias M., Marquez F., Karyotakis A. Non-Destructive Testing and Condition Monitoring Techniques for Renewable Energy Industrial Assets. - Butterworth-Heinemann, 2020. — 209 p.
6. Xu C. Robotic Nondestructive Testing Technology. - Boca Raton: CRC Press, 2022. — 517 p.
7. Abbasov Iftikhar B. (Ed.). Recognition and Perception of Images: Fundamentals and Applications. - Wiley, 2021. — 474 p.
8. Sevakula R.K., Verma N.K. Improving Classifier Generalization: Real-Time Machine Learning based Applications.- Springer, 2023. — 181 p
9. Rao L.K. et al. Image Pattern Recognition: Fundamentals and Applications. - CKC, 2022. - 203p.
10. Carlos Travieso-Gonzalez (ed.) Pattern Recognition Applications .- ITexLi, 2021. — 118 p.
11. Chaki J., Dey N. Image Color Feature Extraction Techniques: Fundamentals and Applications .- Springer, 2021. — 93 p
12. Wu J. Essentials of Pattern Recognition: An Accessible Approach .- Cambridge: Cambridge University Press, 2020. - 417 p.
13. Dovbysh, A., Shelechov, I., Khibovska, J., Matiash, O.
14. Information and Analytical System for Assessing the Compliance of Educational Content Specialties Cyber Security With Modern Requirements. - Radioelectronic and Computer Systems , 2021, (1), pp. 70–80.

15. Dovbysh, A., Piatachenko, V. Hierarchical clustering approach for information-extreme machine learning of hand brush prosthesis. - CEUR Workshop Proceedings , 2021, 2870, pp. 1706–1715
16. Dovbysh, A.S., Budnyk, M.M., Piatachenko, V.Y., Myronenko, M.I. Information-Extreme Machine Learning of On-Board Vehicle Recognition System. - Cybernetics and Systems Analysis , 2020, 56(4), pp. 534–543
17. Dovbysh, A., Naumenko, I., Myronenko, M., Savchenko, T. Information-extreme machine learning on-board recognition system of ground objects with the adaptation of the input mathematical description .- CEUR Workshop Proceedings , 2020, 2608, pp. 913–925
18. Dovbysh, A.S., Zimovets, V.I., Zuban, Y.A., Prihodchenko, A.S. Machine Training of the System of Functional Diagnostics of the Shaft Lifting Machine | Sistem de diagnosticare funcțională a mașinii de ridicare a minelor.- Problems of the Regional Energetics , 2019, (2), pp. 88–102
19. Dovbysh, A., Shelehov, I., Pylypenko, S., Berest, O. Estimation of informativeness of recognition signs at extreme information machine learning of knowledge control system. - CEUR Workshop Proceedings , 2019, 2362
20. Moskalenko, V., Dovbysh, A., Naumenko, I., Moskalenko, A., Korobov, A. Improving the effectiveness of training the on-board object detection system for a compact unmanned aerial vehicle. - Eastern-European Journal of Enterprise Technologies, 2018, 4(9), pp. 19–26

ДОДАТОК

Файл diplom1.m

```

% schityvaem izobrazheniya
class1=double(imread('1.bmp'));
class2=double(imread('2.bmp'));

% berem class1 kak bazovyy, vychislyаем srednee znachenie po
stolbtsam
average = mean(class1);
delta=15
% stroim verkhniy i nizhiy dopuski
up_fringe = average+delta;
under_fringe= average-delta;

% stroim binarnuyu matritsu
for i=1:100;
    Bin1(i,:)=(class1(i,:)>=under_fringe)           &
(class1(i,:)<=up_fringe);
    Bin2(i,:)=(class2(i,:)>=under_fringe)           &
(class2(i,:)<=up_fringe);
end

% stroim etalonnye vectora
ev1=ev(Bin1);
ev2=ev(Bin2);
% mezhcentrovое rastoyanie
MR=sum(abs(ev1-ev2));
% stroim sistemu kontrolnykh dopuskov
for i=1:100
    SKR1(i, 1)=sum(abs(ev1-Bin1(i, :)));
    SKR1(i, 2)=sum(abs(ev1-Bin2(i, :)));
    SKR2(i, 1)=sum(abs(ev2-Bin2(i, :)));
    SKR2(i, 2)=sum(abs(ev2-Bin1(i, :)));
end

% vychislyаем
[K1_1, K2_1, K3_1, K4_1, D1_1, D2_1, alpha1, beta1]=character(SKR1,
MR);
[K1_2, K2_2, K3_2, K4_2, D1_2, D2_2, alpha2, beta2]=character(SKR2,
MR);

E1=1+0.5*(check(alpha1, D2_1)+check(D1_1, beta1)+check(beta1,
D1_1)+check(D2_1, alpha1));
E2=1+0.5*(check(alpha2, D2_2)+check(D1_2, beta2)+check(beta2,
D1_2)+check(D2_2, alpha2));

% vydelenie rabochei oblasti i opt. radiusa dlya klassa 1
[work_space1, r1, Emax1]=work_space (D1_1, D2_1, E1);
% vydelenie rabochei oblasti i opt. radiusa dlya klassa 2
[work_space2, r2, Emax2]=work_space (D1_2, D2_2, E2);

area(E1, 'FaceColor', [0.3, 0.3, 0.3]);
hold on;
area(work_space1, E1(1), 'FaceColor', [0.9, 0.9, 0.9]);

```

```

hold off;

% area(E2, 'FaceColor', [0.3, 0.3, 0.3]);
% hold on;
% area(work_space2, E2(work_space2), 'FaceColor', [0.9, 0.9,
0.9]);
% hold off;

```

Файл optim.m

```

for delta = 1:64
    up_fr = average + delta;
    low_fr = average - delta;

    for i=1:100;
        Bin1(i,:)=(class1(i,:)>=low_fr) & (class1(i,:)<=up_fr);
        Bin2(i,:)=(class2(i,:)>=low_fr) & (class2(i,:)<=up_fr);
    end

    % stroim etalonnye vectora
    ev1=ev(Bin1);
    ev2=ev(Bin2);
    % mezhcentrovoe rastoyanie
    MR=sum(abs(ev1-ev2));
    % stroim sistemuy kontrolnykh dopuskov
    for i=1:100
        SKR1(i, 1)=sum(abs(ev1-Bin1(i, :)));
        SKR1(i, 2)=sum(abs(ev1-Bin2(i, :)));
        SKR2(i, 1)=sum(abs(ev2-Bin2(i, :)));
        SKR2(i, 2)=sum(abs(ev2-Bin1(i, :)));
    end

    % vychislyаем tochnosnye kharakteristiki
    [K1_1, K2_1, K3_1, K4_1, D1_1, D2_1, alpha1,
beta1]=charact(SKR1, MR);
    [K1_2, K2_2, K3_2, K4_2, D1_2, D2_2, alpha2,
beta2]=charact(SKR2, MR);

    E1=1+0.5*(check(alpha1, D2_1)+check(D1_1, beta1)+check(beta1,
D1_1)+check(D2_1, alpha1));
    E2=1+0.5*(check(alpha2, D2_2)+check(D1_2, beta2)+check(beta2,
D1_2)+check(D2_2, alpha2));

    % vydelenie rabochei oblasti i opt. radiusa dlya klassa 1
    [work_space1, r1, Emax1]=work_space (D1_1, D2_1, E1);
    % vydelenie rabochei oblasti i opt. radiusa dlya klassa 2
    [work_space2, r2, Emax2]=work_space (D1_2, D2_2, E2);

    E_av(delta)=(Emax1+Emax2)/2;
end

E_opt=max(E_av);

delta_opt=find(E_av == max(E_av));
if (length(delta_opt)>=2)

```

```

    delta_opt=delta_opt(1);
end;

```

Файл charact.m

```

function [K1, K2, K3, K4, D1, D2, alpha, beta] = charact(SKR,
MR)
    K1=zeros(MR, 1);
    K2=zeros(MR ,1);
    K3=zeros(MR, 1);
    K4=zeros(MR, 1);
    if (MR==0)
        MR=1;
    end
    for i=1:MR
        K1(i, 1)=sum(SKR(:, 1)<=i);
        K3(i, 1)=sum(SKR(:, 1)>i);
        K2(i, 1)=sum(SKR(:, 2)<=i);
        K4(i, 1)=sum(SKR(:, 2)>i);
    end

    D1=K1/100;
    D2=K4/100;
    alpha=K3/100;
    beta=K2/100;
end

```

Файл check.m

```

function tmp = check(a, b)

    for i=1:length(a)
        if ((a(i)+b(i)) == 0) | (a(i) == 0)
            tmp(i, 1)=0;
        else
            tmp(i, 1)=a(i)/(a(i)+b(i))*log2(a(i)/(a(i)+b(i)));
        end
    end
end

```

Файл ev.m

```

function ev=ev(A)
% po stolbtsam
for i=1:100
    summa(i)=sum(A(:, i));
    ev(i)=(summa(i)>=50);
end

```

Файл work_space.m

```

function [work_space, r, Emax] = work_space (D1, D2, E)
% vydelenie rabochei oblasti dlya klassa
work_space=find((D1 >= 0.5) & (D2 >= 0.5));
if (isempty(work_space))
    work_space=0;
end

```



```
%optimalnyi radius dlya klassa
if(work_space==0)
    Emax=0;
    r=0;
else
    Emax = max(E(work_space));
    if (length(Emax) >= 2)
        Emax=Emax(1);
    end
    r=work_space(min(find(E(work_space) == Emax)));
end
end
```