

**Міністерство освіти і науки України
Луцький національний технічний університет
Факультет комп'ютерних та інформаційних технологій
Кафедра інженерії програмного забезпечення**

**КВАЛІФІКАЦІЙНА РОБОТА
ЗА СТУПЕНЕМ ВИЩОЇ ОСВІТИ «БАКАЛАВР»**

**РОЗРОБКА СИСТЕМИ ДЛЯ АВТОМАТИЗАЦІЇ ТЕСТУВАННЯ
ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ З ВИКОРИСТАННЯМ
ШТУЧНОГО ІНТЕЛЕКТУ**

**DEVELOPMENT OF A SYSTEM FOR AUTOMATING SOFTWARE
TESTING USING ARTIFICIAL INTELLIGENCE**

спеціальність 121 «Інженерія програмного забезпечення»
освітня програма «Інженерія програмного забезпечення»

Виконав: здобувач вищої освіти
групи ІПЗ_з-41
Філоненко Валентин Михайлович

Керівник:
к.ф.-м.н., доцент
Хвищун Микола Вячеславович

Кваліфікаційну роботу
допущено до захисту
«__» _____ 20__ р.
Гарант освітньої програми:
к.т.н., доцент
Ліщина Наталія Миколаївна

Луцьк – 2026 року

ЛУЦЬКИЙ НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ

Факультет комп'ютерних та інформаційних технологій

Кафедра інженерії програмного забезпечення

Ступінь вищої освіти бакалавр

Галузь знань: 12 «Інформаційні технології»

Спеціальність: 121 «Інженерія програмного забезпечення»

Освітня програма: «Інженерія програмного забезпечення»

ЗАТВЕРДЖУЮ

Завідувач кафедри

«__» _____ 20__ р.

ЗАВДАННЯ

НА КВАЛІФІКАЦІЙНУ РОБОТУ ЗДОБУВАЧУ ВИЩОЇ ОСВІТИ

Філоненку Валентину Михайловичу

(прізвище, ім'я, по батькові)

1. Тема кваліфікаційної роботи «Розробка системи для автоматизації тестування програмного забезпечення з використанням штучного інтелекту»
Керівник роботи: Хвищун Микола Вячеславович, доцент, к.ф.-м.н.
затверджені наказом закладу вищої освіти від «31» грудня 2025 р. № 541/01-02
2. Строк подання здобувачем вищої освіти кваліфікаційної роботи бакалавра «29» травня 2026 р.
3. Вихідні дані до роботи: технічне та програмне забезпечення ЕОМ
4. Зміст розрахунково-пояснювальної записки (перелік питань, що потрібно розробити): аналіз сучасних методів автоматизації тестування ПЗ, III – підходів та постановка завдання, формування вимог до розроблюваної системи, обґрунтування вибору технологій розробки, проектування архітектури системи та структури бази даних, обґрунтування принципів захисту інформації, тестування та оцінка ефективності системи.
5. Перелік графічного матеріалу: 16 рисунків, 16 лістингів, 6 таблиць.

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис	
		завдання видав	завдання прийняв
Аналіз предметної області	<i>Хвищун М. В.</i>		
Специфікація вимог до розробленої системи	<i>Хвищун М. В.</i>		
Розробка об'єкта проектування	<i>Хвищун М. В.</i>		
Нормоконтроль	<i>Суринович О. М.</i>		
Гарант ОП	<i>Ліщина Н. М.</i>		
Показник запозичень тексту	%		
Академічна доброчесність	<i>Хвищун М. В.</i>		

7. Дата видачі завдання «3» лютого 2026 р.

№	Назва етапів кваліфікаційної роботи бакалавра	Строк виконання етапів роботи	Примітка
1	Огляд літературних джерел по темі кваліфікаційної роботи бакалавра	до 14.02.2026 р.	
2	Аналіз проблем автоматизації тестування ПЗ та обмежень класичних підходів	до 03.03.2026 р.	
3	Обґрунтування вибору методів, алгоритмів і технологій розробки ІІІ-системи тестування	до 14.03.2026 р.	
4	Розробка архітектури та функціонально-структурної схеми системи і проєктування бази даних тестових сценаріїв	до 14.04.2026 р.	
5	Практична реалізація програмного прототипу системи автоматизованого тестування з інтеграцією ІІІ-модуля.	до 20.04.2026 р.	
6	Тестування, налагодження та оцінювання ефективності роботи системи	до 04.05.2026 р.	
7	Здача чистового варіанту кваліфікаційної роботи бакалавра на кафедрі	до 29.05.2026 р.	

Здобувач вищої освіти

Валентин ФІЛОНЕНКО

Керівник кваліфікаційної роботи

Микола ХВИЩУН

АНОТАЦІЯ

Філоненко В. М. Розробка системи для автоматизації тестування програмного забезпечення з використанням штучного інтелекту. Рукопис. Кваліфікаційна робота бакалавра ОП «Інженерія програмного забезпечення» спеціальності «Інженерія програмного забезпечення». Луцький національний технічний університет. Луцьк, 2026.

Кваліфікаційна робота бакалавра складається зі вступу, трьох розділів, висновків, списку використаних джерел.

У першому розділі проведено дослідження предметної області, проаналізовано сучасний стан процесів тестування, розглянуто відмінності між ручним і автоматизованим тестуванням, визначено проблеми класичних підходів автоматизації, а також здійснено огляд сучасних інструментів, таких як Selenium, Cypress та Playwright.

У другому розділі сформовано вимоги до ШІ-системи тестування програмного забезпечення, визначено зацікавлені сторони, описано варіанти використання та функціональні й нефункціональні вимоги, включаючи вимоги до ШІ-модуля. Виконано проєктування архітектури системи із застосуванням UML-нотації, зокрема побудовано діаграми Use Case, Class, Sequence та Component, а також описано інформаційні потоки.

У третьому розділі описано процес розробки та дослідження AI-системи тестування. Реалізовано структуру програмного продукту, розроблено модулі системи та інтегровано ШІ-компоненти.

У висновках підсумовано отримані результати, підтверджено досягнення мети роботи, доведено ефективність застосування штучного інтелекту для автоматизації тестування програмного забезпечення.

Ключові слова: автоматизація тестування, штучний інтелект, машинне навчання, AI-testing, self-healing tests, прогнозування дефектів, інформаційна система, база даних, Python, JavaScript, Selenium, Playwright, TensorFlow, PyTorch, CI/CD.

ABSTRACT

Filonenko V. Development of a system for automating software testing using artificial intelligence. Manuscript. Qualification work for bachelor's degree in Software Engineering, specialty "Software Engineering". Lutsk National Technical University. Lutsk, 2026.

The bachelor's qualification work consists of an introduction, three chapters, conclusions, a list of references.

In the first chapter, the subject area related to software testing automation is studied. The current state of testing processes is analyzed, the differences between manual and automated testing are examined, the problems of classical automation approaches are identified, and an overview of modern tools such as Selenium, Cypress, and Playwright is provided.

In the second chapter, the requirements for an AI-based software testing system are defined. Stakeholders are identified, use cases are described, and both functional and non-functional requirements are formulated, including requirements for the AI module. The system architecture is designed using UML notation, including Use Case, Class, Sequence, and Component diagrams, as well as information flow descriptions. In the third chapter, the process of development and research of the AI-based testing system is described. The structure of the software product is implemented, system modules are developed, and AI components are integrated.

In the conclusions, the obtained results are summarized, the achievement of the research goal is confirmed, and the effectiveness of applying artificial intelligence for software testing automation is demonstrated.

Keywords: Test Automation, Artificial Intelligence, Machine Learning, AI-Testing, Self-Healing Tests, Defect Prediction, Information System, DataBase, Python, JavaScript, Selenium, Playwright, TensorFlow, PyTorch, CI/CD.

ЗМІСТ

ВСТУП.....	7
РОЗДІЛ 1 АНАЛІЗ СУЧАСНИХ МЕТОДІВ АВТОМАТИЗАЦІЇ ТЕСТУВАННЯ ПЗ, ШІ-ПІДХОДІВ ТА ПОСТАНОВКА ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ	9
1.1 Аналіз сучасного стану тестування програмного забезпечення	9
1.2 Постановка завдання на кваліфікаційну роботу бакалавра	16
РОЗДІЛ 2 СПЕЦИФІКАЦІЯ ВИМОГ ДО РОЗРОБЛЮВАНОЇ СИСТЕМИ...	18
2.1 Аналіз, визначення вимог до розроблюваного програмного забезпечення та проєктування архітектури системи.....	18
2.2 Вибір засобів, методів і алгоритмів вирішення поставленого завдання ...	23
РОЗДІЛ 3 РОЗРОБКА ТА ДОСЛІДЖЕННЯ AI-СИСТЕМИ ТЕСТУВАННЯ	33
3.1 Практична реалізація системи	33
3.2 Розробка бази даних для збереження тестових сценаріїв та результатів..	44
3.3 Реалізація AI – модуля системи автоматизованого тестування	54
3.4 Тестування та налагодження AI-орієнтованої системи автоматизації тестування	60
ВИСНОВКИ	67
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	68

ВСТУП

Актуальність теми. У сучасних умовах якість програмного забезпечення є важливим чинником його надійності, конкурентоспроможності та практичної цінності. Зростання складності програмних систем, поширення хмарних технологій, мікросервісної архітектури, DevOps і CI/CD зумовлюють підвищені вимоги до процесів тестування ПЗ. Тестування дає змогу своєчасно виявляти дефекти, перевіряти відповідність програмного продукту вимогам і забезпечувати стабільність його роботи [1].

Ручне тестування потребує значних затрат часу, залежить від людського фактора та має обмежену масштабованість. Автоматизоване тестування частково усуває ці недоліки, однак класичні засоби автоматизації також мають проблеми: високу вартість супроводу тестів, чутливість до змін інтерфейсу користувача, складність підтримки локаторів елементів і появу нестабільних тестових сценаріїв.

Перспективним напрямом вирішення цих проблем є використання технологій штучного інтелекту та машинного навчання. AI-підходи дають змогу аналізувати результати тестування, прогнозувати дефекти, визначати пріоритетність тестів, виявляти нестабільні сценарії та реалізовувати механізми самовідновлення тестів. Зокрема, self-healing-механізми дозволяють автоматично знаходити альтернативні локатори елементів після зміни структури сторінки та продовжувати виконання тесту без ручного втручання [11, 12].

Для розробки таких систем доцільно використовувати мову програмування Python, яка має широку підтримку бібліотек для автоматизації тестування та машинного навчання. Інструменти Selenium, Playwright, PyTest, scikit-learn, TensorFlow і PyTorch дають змогу створювати інтелектуальні тестові системи та інтегрувати їх у CI/CD-процеси.

Незважаючи на розвиток сучасних інструментів тестування, питання комплексного застосування штучного інтелекту для підвищення адаптивності, стабільності та ефективності автоматизованих тестів залишається актуальним.

Тому тема кваліфікаційної роботи бакалавра відповідає сучасним напрямкам розвитку інженерії програмного забезпечення.

Метою кваліфікаційної роботи є розробка та дослідження програмних засобів автоматизації тестування програмного забезпечення із застосуванням технологій штучного інтелекту на основі мови Python для підвищення ефективності виявлення дефектів і зменшення трудомісткості тестування.

Для досягнення поставленої мети необхідно вирішити такі завдання:

- проаналізувати сучасні підходи до автоматизації тестування ПЗ;
- дослідити можливості застосування штучного інтелекту в тестуванні;
- визначити вимоги до інтелектуальної системи тестування;
- обґрунтувати вибір технологій, інструментів і алгоритмів;
- спроектувати архітектуру системи та структуру бази даних;
- реалізувати програмний прототип системи;
- інтегрувати AI-модуль і self-healing-механізм;
- провести тестування та оцінити ефективність розробленої системи.

Об'єктом дослідження є процеси автоматизованого тестування програмного забезпечення.

Предметом дослідження є методи, моделі та алгоритми застосування штучного інтелекту, реалізовані засобами Python, для підвищення ефективності автоматизованого тестування ПЗ.

Практичне значення роботи полягає у створенні програмного засобу автоматизованого тестування, який може бути використаний у процесах забезпечення якості ПЗ, CI/CD-конвеєрах, DevOps-середовищах і навчальному процесі. Запропонований підхід дозволяє зменшити витрати на супровід тестів, підвищити стабільність UI-тестування та скоротити кількість помилкових падінь тестових сценаріїв.

Під час виконання роботи засоби штучного інтелекту використовувалися лише як допоміжний інструмент для редагування тексту, структурування матеріалів та аналізу літературних джерел. Усі результати були самостійно перевірені автором відповідно до принципів академічної доброчесності.

РОЗДІЛ 1

АНАЛІЗ СУЧАСНИХ МЕТОДІВ АВТОМАТИЗАЦІЇ ТЕСТУВАННЯ ПЗ, ПІДХОДІВ ТА ПОСТАНОВКА ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

1.1 Аналіз сучасного стану тестування програмного забезпечення

Тестування програмного забезпечення є невід’ємною складовою процесів забезпечення якості (QA) та спрямоване на виявлення дефектів, перевірку відповідності вимогам і зниження ризиків при введенні ПЗ в експлуатацію. У сучасних підходах тестування розглядають не як одноразову фазу «після розробки», а як безперервну діяльність, інтегровану в життєвий цикл розробки (Waterfall, Agile, DevOps/CI/CD), де контроль якості починається з моменту формування вимог і триває до супроводу продукту [1, 2].

На практиці процес тестування часто описують через життєвий цикл тестування (Software Testing Life Cycle, STLC) – впорядкований набір етапів із визначеними входами/виходами та артефактами.

Типово STLC включає такі фази:

- аналіз вимог (визначення об’єктів тестування, ризиків, критеріїв приймання);
- планування тестування (стратегія, ресурси, оцінки, графік, критерії входу/виходу);
- проєктування та розробка тестів (тест-кейси, тест-дані, чек-листи, трасування вимог);
- підготовка тестового середовища (налаштування стенду, тестових акаунтів, залежностей);
- виконання тестів (прогони, реєстрація дефектів, ретест/регресія);
- закриття тестування (підсумкові звіти, висновки, lessons learned) [3].

У межах STLC важливим є поняття критеріїв входу/виходу для кожної фази, що забезпечує керованість процесу та прозорість якості релізу [1]. У сучасних командах ці етапи часто «накладаються» один на один (особливо в

Agile), а частина активностей автоматизується через CI/CD, проте логіка STLC зберігається як каркас управління тестуванням [3].

Ручне тестування залишається критично важливим для дослідницького тестування (exploratory testing), перевірки UX, виявлення нетипових сценаріїв та оцінки поведінки системи в умовах невизначеності. Воно гнучке та швидко адаптується до змін, але суттєво залежить від досвіду тестувальника і погано масштабується для частих регресійних прогонів [2].

Автоматизоване тестування орієнтоване на повторювані перевірки (регресія, smoke/sanity), валідацію критичних бізнес-потоків і стабільний контроль якості при частих релізах. Класична мотивація автоматизації – зменшення часу прогонів, відтворюваність, мінімізація людського фактора та можливість безперервного тестування в CI (Continuous Integration) [2]. Разом із тим, автоматизація не замінює повністю ручне тестування: практично доцільним є комбінований підхід, де автоматизують «стабільні» і часто повторювані сценарії, а ручне тестування зосереджують на дослідженні нових/ризикових ділянок [2].

Попри переваги, класична автоматизація має низку проблем, які впливають на ефективність:

1) висока вартість підтримки тестів: тестові сценарії потребують актуалізації при зміні вимог, UI, API або даних. У великих проєктах підтримка може займати порівнянний із розробкою час [2];

2) крихкість UI-тестів (flakiness): нестабільність тестів через асинхронність веб-інтерфейсів, мережеві затримки, race conditions, залежність від середовища та неякісні локатори елементів [15];

3) повільність end-to-end (E2E) прогонів: E2E-тести дають високу впевненість, але зазвичай найдорожчі за часом виконання; без паралелізації й правильної піраміди тестування вони стають «вузьким місцем» CI [2];

4) складність надійного тестового середовища і даних: потрібні стабільні стенди, контроль версій залежностей, керування тест-даними; відсутність цього призводить до хибних падінь тестів [15];

5) обмеження покриття: автоматизація часто концентрується на «щасливих шляхах» (happy path), тоді як edge-cases і негативні сценарії залишаються недопрацьованими без систематичного підходу до проектування тестів [3].

З огляду на це в індустрії розвиваються підходи, що підвищують стабільність і керованість автоматизації: суворіша дисципліна тест-дизайну, надійні локатори, ізоляція тестів, паралелізація, використання трас/відео/логів, а також застосування інтелектуальних механізмів (наприклад, self-healing) у сучасних інструментах.

Розглянемо існуючі інструменти (Selenium, Cypress, Playwright).

Selenium (WebDriver) – один із найпоширеніших стандартних підходів до автоматизації браузера. Selenium WebDriver керує браузером «нативно», а специфікація WebDriver стандартизована W3C, що забезпечує крос-браузерність і можливість використання різних мов програмування (зокрема Python) [4]. Переваги Selenium – зрілість екосистеми, гнучкість, інтеграція з CI та можливість масштабування через Grid; водночас типові виклики – складність стабілізації UI-тестів, робота з очікуваннями/синхронізацією та потреба в дисципліні побудови фреймворку [5].

Cypress – фреймворк для E2E та компонентного тестування веб-додатків із акцентом на зручність розробника, швидкий зворотний зв'язок та дебаг у реальному часі. Cypress позиціонується як інструмент, який запускає тести «так, як користувач взаємодіє з додатком» у реальному браузері, забезпечуючи високу спостережуваність (логи, тайм-тревел, інтегрований runner) [6]. Практичні переваги – простий старт і дебаг; обмеження – прив'язаність до JavaScript/TypeScript-екосистеми й певні архітектурні особливості, які треба враховувати при складних сценаріях інтеграції [6].

Playwright – сучасний E2E-фреймворк для тестування «modern web apps», який включає test runner, assertions, ізоляцію, паралелізацію та розвинуті інструменти (репорти, трейсинг) і підтримує Chromium/WebKit/Firefox локально та в CI (Continuous Integration) [7]. На практиці Playwright часто обирають за

рахунок зручної роботи з очікуваннями, паралельних прогонів, потужних можливостей трасування та стабільності в CI-середовищах [7]. Для Python-реалізації важливо, що Playwright має офіційні бібліотеки для кількох мов, включно з Python (що добре узгоджується з обраною мовою реалізації в роботі) [7].

Отже, сучасний стан тестування ПЗ характеризується переходом до безперервного контролю якості, де STLC адаптується під Agile/DevOps, а автоматизація стає базовою практикою для регресій і CI. Водночас класична автоматизація стикається з проблемами вартості підтримки та нестабільності UI (User Interface tests) – тестів, що стимулює розвиток нових інструментів і підходів. Саме в цих «вузьких місцях» найбільш перспективним є застосування інтелектуальних методів, що стане наступним предметом дослідження у роботі AI (Artificial Intelligence) – генерація тестів, адаптація, self-healing тощо).

Проведемо аналіз застосування штучного інтелекту в тестуванні ПЗ. Інтеграція штучного інтелекту (ШІ) у процеси забезпечення якості ПЗ стала відповіддю на типові проблеми класичної автоматизації: високу вартість підтримки тестів, нестабільність (flakiness), обмежену масштабованість регресій та складність пріоритизації великих тестових наборів. AI/ML-підходи дозволяють перейти від «жорстко запрограмованих» тестів до адаптивного тестування, де рішення (які тести запускати, як відновити локатори, як виявляти ризикові зміни) приймаються на основі даних і моделей.

Машинне навчання (ML – Machine Learning) в тестуванні зазвичай застосовують у задачах, де є історичні дані (логи CI, результати прогонів тестів, зміни в репозиторії, дефекти, телеметрія). Найпоширеніші ML-напрями:

- інтелектуальна оптимізація регресійного тестування (вибір/скорочення набору тестів під конкретний change-set) – моделі прогнозують, які тести з більшою ймовірністю «впадуть» або знайдуть дефект після змін [11, 12];
- адаптивна пріоритезація тестів у CI (test case prioritization/selection) – з урахуванням часу виконання, історії падінь, частоти змін тощо [13, 14];

– класифікація/виявлення flaky tests – ML використовується для прогнозування нестабільних тестів і зменшення шуму в CI [15];

– аналіз дефектів і прогноз ризику (defect prediction, fault-proneness) – моделі оцінюють імовірність дефектності компонентів/змін і допомагають сфокусувати тестування [11, 12].

Важливий висновок із практичних робіт – найбільший ефект ML дає там, де тестування вже «даноцентричне»: ведеться історія прогонів, є стабільні метрики та накопичені ознаки для навчання [11, 12].

AI-методи застосовують для автоматичної генерації тестів (або їх частин: вхідних даних, послідовностей дій, оракулів/перевірок). Найчастіше зустрічаються такі підходи:

1) search-based / evolutionary approaches: тестова генерація формулюється як задача оптимізації (наприклад, максимізація покриття/виявлення помилок), а рішення шукається метаевристиками. Прикладом є пошукова генерація тестових даних для SQL-запитів, де методи оптимізації підбирають дані, що активують різні гілки логіки запиту [11];

2) нейромережеві й мовні підходи (DL/NLP): моделі навчаються на артефактах розробки (код, логи, вимоги) і можуть пропонувати тестові кроки, сценарії або шаблони перевірок. Сучасні роботи також досліджують створення UI/функціональних тестів через обмежену природну мову (restricted NL) – це спрощує опис тестів і може зменшити бар'єр входу для тестування [11, 12];

3) тестування ML/DL-систем: окрема гілка досліджень зосереджена на генерації тестів саме для моделей (покриття простору ознак, поведінкові властивості). Наприклад, роботи на кшталт DeepAtash пропонують пошукове «фокусоване» тестування DL-систем, націлене на покриття релевантних ділянок простору ознак і пошук збоїв [11].

Практично це означає, що AI-генерація тестів найефективніша або (а) для дано/покриття-орієнтованих задач, або (б) як помічник для тест-дизайну (пропозиції сценаріїв), а не як повна заміна інженерної роботи тестувальника [11, 12].

Self-healing (самовідновлювані) тести – підхід, спрямований на автоматичне «ремонткування» зламаних тестів після змін у UI/DOM, локаторах або структурі сторінок. Ідея полягає в тому, щоб при невдачі пошуку елемента не падати одразу, а знайти найбільш ймовірний новий елемент за схожістю атрибутів, контексту, візуального розташування або через ML/LLM-підказки, та оновити локатор [12].

У наукових і прикладних джерелах виділяють типові механізми self-healing:

- динамічний підбір локатора (multi-locator strategy + ранжування кандидатів);
- інтелектуальні очікування (smart waits) замість жорстких таймерів;
- аналіз аномалій у виконанні тестів для розрізнення реального дефекту й «крихкості» тесту;
- застосування LLM для «ремонту» локатора або кроку на основі контексту сторінки (у т.ч. на рівні експериментів/прототипів) [12].

У промислових інструментах self-healing реалізується як частина AI-driven test automation платформ (наприклад, mabl, Testim), де система автоматично адаптує тест до змін UI та зменшує витрати на підтримку регресійного набору [12]. Важливо, що з позиції якості такі рішення потребують контролю: self-healing не повинен «маскувати» реальні дефекти, тому у процесі бажані логування змін, рев'ю та правила довіри до авто виправлень [12].

Прогнозування дефектів (defect prediction) – напрям, де ML-моделі оцінюють імовірність дефектності модулів/файлів/комітів. Це дає змогу:

- фокусувати тестування на найбільш ризикових компонентах;
- оптимізувати пріоритезацію тестів;
- будувати ризик-орієнтовані стратегії регресії [11].

Практично близьким до defect prediction у CI є predictive test selection: замість запуску всіх тестів система вибирає підмножину, яка з високою ймовірністю зловить дефект після конкретної зміни. У промисловому кейсі Google та співавтори показали, що ML-підхід може істотно зменшити витрати на

тестову інфраструктуру, зберігаючи високу «чутливість» до збоїв і дефектних змін [13, 14] Це прямо підтримує ідею AI-оптимізації регресій: менше часу → швидший зворотний зв'язок → вища стабільність релізного циклу.

Системний огляд наукових досліджень у темі «AI у тестуванні» зручно будувати за двома великими напрямками:

1) testing for AI (тестування ML-систем) – як тестувати самі моделі (коректність, (robustness) робастність, безпека, справедливість тощо). Це узагальнює масштабний огляд Zhang та співавт., який описує ландшафт тестування ML-систем, типові підходи, метрики та відкриті проблеми [11];

2) AI for Testing (ШІ для тестування “звичайного” ПЗ) – як ML допомагає класичному тестуванню: пріоритезація/відбір тестів у CI (Retecs) [14], predictive test selection у великих CI [13], self-healing локаторів/кроків [12].

Загальний висновок із робіт полягає в тому, що найбільший практичний ефект сьогодні дають:

- оптимізація тестових прогонів у CI (selection/prioritization) [13, 14];
- зменшення нестабільності та вартості підтримки через self-healing [12];
- перехід до даноорієнтованого QA, де моделі приймають рішення на основі історичних сигналів тестування [11, 12].

Отже, сучасний стан тестування програмного забезпечення характеризується переходом від ізольованого етапу до безперервного процесу, інтегрованого у весь життєвий цикл розробки (STLC, CI/CD). Автоматизоване тестування стало ключовим інструментом забезпечення якості, однак не замінює повністю ручне тестування, що зумовлює використання комбінованих підходів. Водночас класична автоматизація має суттєві обмеження, зокрема високу вартість підтримки, нестабільність UI-тестів та складність масштабування. Це обумовлює необхідність розвитку нових підходів, серед яких найбільш перспективними є інтелектуальні методи, що базуються на технологіях штучного інтелекту.

1.2 Постановка завдання на кваліфікаційну роботу бакалавра

Проведений у попередньому підрозділі аналіз сучасного стану тестування програмного забезпечення та застосування методів штучного інтелекту показав, що, незважаючи на значний прогрес у сфері автоматизації, існує низка невирішених проблем. До них належать висока вартість підтримки тестових сценаріїв, нестабільність UI-тестів, неефективне використання обчислювальних ресурсів під час регресійного тестування та недостатній рівень адаптивності тестових систем до змін програмного продукту. Як відзначається у сучасних дослідженнях, інтеграція методів машинного навчання у процес тестування здатна суттєво підвищити ефективність виявлення дефектів і оптимізувати тестові процеси [11, 12].

Особливо перспективними є підходи до інтелектуальної пріоритезації та відбору тестів у середовищах безперервної інтеграції, що дозволяють скоротити час виконання регресійних наборів без істотної втрати якості перевірки [13-15]. Окрему увагу дослідники приділяють проблемі нестабільних (flaky) тестів, для виявлення яких успішно застосовуються моделі машинного навчання та повторні прогони тестових сценаріїв [12]. Водночас для підвищення стійкості UI-автоматизації активно розвиваються підходи self-healing, що забезпечують автоматичну адаптацію тестів до змін інтерфейсу [12].

У зв'язку з цим актуальним є завдання розробки інтелектуальної системи автоматизованого тестування, яка поєднує класичні інструменти тестування з методами машинного навчання та забезпечує підвищення ефективності процесів забезпечення якості програмного забезпечення.

Метою кваліфікаційної роботи є створення та експериментальна перевірка програмного засобу автоматизації тестування із застосуванням технологій штучного інтелекту на базі мови програмування Python.

Для досягнення поставленої мети необхідно розв'язати такі основні завдання:

1) проаналізувати сучасні підходи до автоматизації тестування програмного забезпечення та визначити можливості застосування методів штучного інтелекту в цих процесах [11, 12];

2) дослідити існуючі AI-методи тестування (зокрема ML-підходи, self-healing механізми та прогнозування дефектів) і обґрунтувати вибір найбільш доцільних для практичної реалізації [11, 12];

3) сформулювати функціональні та нефункціональні вимоги до інтелектуальної системи автоматизованого тестування;

4) розробити архітектуру AI-орієнтованої системи тестування з урахуванням інтеграції інструментів Python (Selenium/Playwright, PyTest, ML-бібліотеки);

5) реалізувати програмний прототип системи автоматизованого тестування із використанням методів машинного навчання;

6) провести експериментальну перевірку працездатності та ефективності розробленої системи на тестових сценаріях веб-застосунку з використанням підходів інтелектуального відбору та аналізу тестів [13, 14];

7) виконати порівняльний аналіз отриманих результатів із традиційними підходами автоматизованого тестування;

8) оцінити практичну доцільність упровадження запропонованого рішення та визначити напрями його подальшого розвитку.

Таким чином, розв'язання сформульованих завдань дозволить підтвердити або спростувати висунуту гіпотезу щодо доцільності застосування методів штучного інтелекту для підвищення ефективності автоматизації тестування програмного забезпечення.

РОЗДІЛ 2

СПЕЦИФІКАЦІЯ ВИМОГ ДО РОЗРОБЛЮВАНОЇ СИСТЕМИ

2.1 Аналіз, визначення вимог до розроблюваного програмного забезпечення та проєктування архітектури системи

На основі аналізу сучасних підходів до автоматизації тестування та застосування технологій штучного інтелекту, проведеного у першому розділі, сформовано вимоги до інтелектуальної системи автоматизованого тестування програмного забезпечення. Формування вимог є критично важливим етапом проєктування, оскільки саме вони визначають функціональні можливості системи, її архітектуру, масштабованість та ефективність у реальних умовах експлуатації [1, 11, 12].

Розроблювана система орієнтована на автоматизацію тестування вебзастосунків із використанням мови програмування Python та інтеграцією інструментів автоматизації (Selenium або Playwright), фреймворку тестування (PyTest) і модулів машинного навчання. Такий підхід відповідає сучасним практикам забезпечення якості ПЗ і дозволяє реалізувати адаптивні механізми тестування [5, 7, 8]. Основна мета системи – підвищення ефективності регресійного тестування за рахунок інтелектуальної обробки тестових сценаріїв, зменшення крихкості тестів та оптимізації процесу їх виконання.

Ключовими користувачами та зацікавленими сторонами системи є:

- інженери з тестування (QA engineers) – створюють, запускають і аналізують тести;
- розробники ПЗ – використовують результати тестування для виправлення дефектів;
- DevOps-інженери – інтегрують систему в CI/CD-конвеєр;
- керівники проєктів – отримують аналітику щодо якості продукту;
- дослідники/викладачі – використовують систему в навчальних цілях.

Урахування потреб зазначених груп відповідає рекомендаціям щодо інженерії вимог і побудови тестових систем [1, 2].

Розглянемо функціональні вимоги, що визначають основні можливості системи.

F1. Управління тестовими сценаріями:

- створення та редагування тестів;
- зберігання тестових наборів;
- групування тестів за категоріями.

Наявність централізованого керування тестами є базовою вимогою сучасних систем автоматизації тестування [1].

F2. Автоматизоване виконання тестів:

- запуск тестів у браузері;
- підтримка headless-режиму;
- паралельне виконання тестів;
- інтеграція з PyTest.

Автоматичне виконання та паралелізація тестів є ключовими факторами підвищення ефективності CI/CD-процесів [16].

F3. Інтеграція AI-модуля:

- аналіз результатів тестів;
- інтелектуальна пріоритезація тестів;
- виявлення нестабільних тестів;
- підтримка self-healing локаторів.

Застосування машинного навчання для оптимізації тестових процесів підтверджено сучасними дослідженнями у сфері AI-driven testing [11, 12].

F4. Self-healing механізм:

- повторний пошук елементів при збої;
- використання альтернативних локаторів;
- логування автоматичних виправлень.

Self-healing підходи дозволяють зменшити витрати на підтримку UI-тестів та підвищити їхню стійкість до змін інтерфейсу [12].

F5. Аналітика та звітність:

- формування звітів про виконання тестів;
- візуалізація метрик якості;
- експорт результатів (HTML/JSON).

Аналітика тестування є важливою складовою процесу забезпечення якості та підтримки прийняття рішень у DevOps-середовищі [11, 12].

F6. Інтеграція з CI/CD:

- запуск із командного рядка;
- підтримка Jenkins/GitHub Actions;
- API для автоматичного запуску.

Інтеграція тестування в CI/CD є стандартною практикою сучасної інженерії програмного забезпечення [16].

Розглянемо нефункціональні вимоги визначають якісні характеристики системи.

NF1. Продуктивність. Система повинна підтримувати паралельний запуск тестів і забезпечувати прийнятний час роботи AI-модуля, що особливо важливо для безперервної інтеграції [11, 12].

NF2. Масштабованість. Система має забезпечувати можливість збільшення кількості тестів без суттєвої втрати продуктивності, що відповідає сучасним вимогам до тестових платформ [1].

NF3. Надійність. Необхідна коректна обробка помилок, стійкість до flaky-тестів і ведення детального журналу подій [15].

NF4. Розширюваність. Архітектура системи повинна бути модульною та підтримувати підключення нових ML-моделей і браузерів [15].

NF5. Портативність. Система має бути кросплатформеною (Windows/Linux/macOS) і підтримувати роботу в контейнеризованому середовищі, що відповідає практикам DevOps [1].

NF6. Зручність використання. Система повинна мати зрозумілий CLI-інтерфейс, структурований проєкт і документацію користувача [11, 12].

Розглянемо обмеження та припущення системи.

Під час проєктування системи приймаються такі обмеження:

- система орієнтована на веб-застосунки;
- мова реалізації – Python;
- AI-модуль використовує класичні ML-підходи;
- тестове середовище – сучасні браузері Chromium-сімейства.

Такі припущення узгоджуються з типовими підходами до побудови AI-орієнтованих систем.

Проектування архітектури інтелектуальної системи автоматизованого тестування виконується на основі сформованих вимог та з урахуванням сучасних практик тестування й автоматизації. Архітектура має забезпечити модульність, розширюваність і можливість інтеграції з CI/CD, а також підтримку AI-функцій (пріоритезація/відбір тестів, виявлення flaky-тестів, self-healing) [11, 12, 16].

Запропонована система реалізується на Python та має багатомодульну структуру (шари/підсистеми), що відповідає підходам до побудови підтримуваних автоматизованих тестових рішень [1, 2]. Рекомендовано розділити систему на такі основні модулі

Test Management Module (керування тестами):

- зберігання тест-кейсів, тест-сьютів, метаданих (пріоритет, теги, залежності);
- робота з тест-даними;
- ведення історії прогонів.

Цей модуль забезпечує керуваність процесу тестування та узгоджується з підходами STLC/тест-менеджменту [1].

Test Execution Engine (ядро виконання тестів):

- запуск тестів через PyTest;
- підтримка паралельного виконання;
- збір артефактів (логи, скріншоти, trace).

Необхідність повторюваного, стандартизованого виконання тестів є базовою вимогою сучасного тестування [2].

Automation Adapter Layer (шар адаптерів автоматизації):

– адаптери до інструментів браузерної автоматизації (Selenium/Playwright);

– уніфікація API дій (click/type/wait/assert) для зменшення залежності від конкретного інструмента.

Використання Selenium/Playwright як “двигуна” UI – тестування відповідає практиці веб-автоматизації та офіційним підходам їх документації [5, 7].

AI/ML Analytics Module (інтелектуальний модуль) складається з підмодулів:

– Test Selection/Prioritization (інтелектуальний відбір/пріоритезація) [13, 14];

– Flaky Test Detection (виявлення нестабільних тестів) [15];

– Self-healing (відновлення локаторів/кроків) [12];

– Defect Prediction / Risk Estimation (оцінка ризику змін/дефектності, за потреби) [11, 12].

Такі можливості відповідають сучасним AI-driven підходам у тестуванні [11, 12].

Reporting & Observability (звітність і спостережуваність):

– генерація звітів (HTML/JSON);

– метрики (pass rate, flaky rate, duration, trend);

– журналювання подій (лог «AI-рішень»: чому обрано саме ці тести, які локатори «вилікувано»). Підхід до прозорості та контролю якості тестування відповідає рекомендаціям ISTQB та загальним принципам тест – інженерії [1, 2].

CI/CD Integration Layer (інтеграція):

– CLI-команди запуску;

– конфігурація через файли (YAML/ENV);

– сценарії для Jenkins/GitHub Actions.

Оптимізація прогонів у CI є однією з ключових причин впровадження AI-відбору тестів [13, 14].

Отже, у підрозділі було виконано аналіз та формування вимог до інтелектуальної системи автоматизованого тестування. Визначено ключові зацікавлені сторони, сформовано функціональні та нефункціональні вимоги, а також окреслено обмеження системи. Отримані результати створюють основу для подальшого проєктування архітектури системи тестування [1, 2].

2.2 Вибір засобів, методів і алгоритмів вирішення поставленого завдання

У даному підрозділі обґрунтовується вибір методів і алгоритмів штучного інтелекту для інтелектуалізації процесу автоматизованого тестування програмного забезпечення. Вибір виконано з урахуванням вимог до продуктивності, інтерпретованості моделей, можливості інтеграції з Python-екосистемою та ефективності в задачах тестування ПЗ [11, 12].

Основна мета застосування ШІ в системі – підвищення ефективності регресійного тестування, зменшення кількості нестабільних тестів і зниження витрат на підтримку UI-автоматизації.

Розглянемо алгоритми машинного навчання (Random Forest/Neural Network).

Алгоритм Random Forest обрано як базову модель для задач:

- пріоритезації тестів;
- predictive test selection;
- виявлення flaky-тестів;
- оцінки ризику дефектів.

Random Forest є ансамблевим методом на основі дерев рішень, що забезпечує високу точність класифікації, стійкість до шуму та добру інтерпретованість результатів [9]. У дослідженнях AI-driven testing показано ефективність ансамблевих методів для аналізу історії тестів і метаданих змін [11, 12].

Переваги Random Forest:

- добре працює на табличних даних тестування;
- не потребує складної нормалізації;
- стійкий до перенавчання;
- швидкий у навчанні та інференсі;
- легко реалізується в Python (scikit-learn).

Недоліки:

- гірше масштабується на дуже великих вибірках;
- менш ефективний для складних послідовнісних залежностей.

Нейронні мережі доцільно застосовувати для:

- аналізу текстових описів тестів;
- NLP-задач;
- складних нелінійних залежностей;
- розширеної defect prediction.

Згідно з оглядовими роботами, нейронні мережі демонструють високу ефективність у задачах аналізу програмних артефактів і текстових даних [10]. У контексті тестування вони можуть використовуватися як доповнення до класичних ML-моделей [11, 12].

Обрана архітектура для бакалаврської роботи:

- простий feed-forward NN або
- легка модель на базі embedding + Dense.

Переваги:

- здатність моделювати складні залежності;
- ефективні для NLP;
- масштабованість.

Недоліки:

- більші обчислювальні витрати;
- потреба в більшому обсязі даних;
- нижча інтерпретованість порівняно з Random Forest.

Розглянемо NLP для аналізу тестів. Обробка природної мови (NLP) у системі використовується для:

- аналізу назв і описів тест-кейсів;
- класифікації тестів за функціональністю;
- пошуку схожих тестів;
- допомоги self-healing (семантична близькість елементів);
- аналізу повідомлень про помилки.

Сучасні дослідження підтверджують ефективність NLP у задачах аналізу програмних артефактів і тестових описів [11, 12].

Запропонований NLP-пайплайн (Python):

1) попередня обробка тексту:

- lowercasing;
- tokenization;
- stop-word removal;
- stemming/lemmatization;

2) векторизація:

- TF-IDF (базовий варіант);
- або sentence embeddings (за можливості);

3) модель:

- Random Forest/Logistic Regression для класифікації;
- або невелика нейромережа.

Такий підхід є достатнім за точністю і прийнятним за обчислювальною складністю для бакалаврського рівня.

Розглянемо підхід до self-healing. Self-healing у запропонованій системі реалізується як гібридний евристично – ML підхід, що відповідає сучасним промисловим рішенням у сфері AI-test automation [12].

Основні кроки self-healing:

1) виявлення збою локатора. Якщо Selenium/Playwright не знаходить елемент;

2) збір контексту:

- старий локатор;
- DOM-структура;
- атрибути елемента;
- текст елемента;
- позиція в DOM;

3) генерація кандидатів:

- альтернативні XPath/CSS;
- пошук за атрибутами;
- NLP-порівняння текстів;
- fuzzy matching;

4) ранжування кандидатів:

- евристичний скоринг;
- ML-модель (за наявності даних);

5) повторне виконання кроку;

6) логування healing-події. Подібні підходи показали ефективність у зменшенні вартості підтримки UI-тестів [12].

Розглянемо метрики якості. Для оцінювання ефективності AI-модуля та всієї системи обрано такі групи метрик.

Метрики ML-моделей:

- Accuracy;
- Precision;
- Recall;
- F1-score;
- ROC-AU.

Ці метрики є стандартними для оцінювання моделей класифікації у задачах тестування ПЗ [11].

Метрики тестування:

- Test Pass Rate;
- Test Failure Rate;

- Flaky Rate;
- Mean Test Duration;
- Regression Execution Time.

Вони характеризують стабільність і продуктивність тестового процесу [1].

Метрики ефективності AI:

- скорочення кількості виконаних тестів у CI;
- зменшення часу регресії;
- відсоток успішного self-healing;
- зменшення flaky-тестів;
- економія обчислювальних ресурсів.

Подібні метрики застосовуються у роботах з predictive test selection і AI-driven testing [13, 14].

У підрозділі виконано обґрунтований вибір технологічного стеку для реалізації інтелектуальної системи автоматизованого тестування. Як основну мову обрано Python, як інструмент UI-автоматизації – Playwright (з підтримкою Selenium), а для ML-компонентів – scikit-learn і PyTorch. Для інтеграції у процес розробки передбачено використання сучасних CI/CD інструментів.

В даному підрозділі обґрунтовано вибір методів штучного інтелекту для інтелектуалізації автоматизованого тестування. Як базову ML-модель обрано Random Forest, а для складніших задач – нейронні мережі. Запропоновано NLP-підхід до аналізу тестів і гібридний механізм self-healing. Визначено систему метрик для комплексної оцінки ефективності. Обрані методи забезпечують баланс між точністю, обчислювальною складністю та практичною реалізованістю в середовищі Python, що робить їх придатними для подальшої програмної реалізації в межах бакалаврської роботи.

Вибір технологічного стеку є важливим етапом проектування інтелектуальної системи автоматизованого тестування, оскільки він визначає продуктивність, масштабованість, зручність розробки та можливості подальшого розвитку системи. Для реалізації системи розглянуто дві основні мови, що широко застосовуються в автоматизації тестування:

- Python;
- JavaScript.

У межах даної кваліфікаційної роботи як основну мову реалізації обрано Python, оскільки вона:

- має потужну екосистему бібліотек машинного навчання (scikit-learn, TensorFlow, PyTorch);
- широко використовується в автоматизації тестування;
- підтримує фреймворки PyTest, Selenium, Playwright;
- забезпечує швидку розробку прототипів;
- має зрозумілий синтаксис і високу продуктивність розробки.

Згідно з сучасними дослідженнями AI-driven testing, Python є де-факто стандартом для інтеграції ML у тестові пайплайни [11, 12].

JavaScript є природним вибором для веб-екосистеми, однак у контексті даної роботи має обмеження:

Переваги JavaScript:

- нативність для браузера;
- сильна інтеграція з Cypress;
- популярність у frontend-тестуванні.

Недоліки:

- слабша ML-екосистема;
- менш зріла аналітична бібліотечна база;
- складніша реалізація ML-пайплайнів.

Отже, Python є більш доцільним вибором для AI-орієнтованої системи тестування.

Вибір інструменту автоматизації (Selenium/Playwright). Для UI-автоматизації розглянуто два сучасні інструменти:

- Selenium WebDriver;
- Playwright.

Selenium є де-факто стандартом автоматизації веб-тестування та має широку підтримку браузерів і мов програмування [4, 5].

Переваги Selenium:

- зрілість і стабільність;
- велика спільнота;
- підтримка багатьох браузерів;
- сумісність із Python.

Недоліки:

- повільніший старт браузера;
- більше flaky-тестів;
- складніша синхронізація.

Playwright є сучаснішим інструментом, оптимізованим для швидкого та стабільного тестування веб-застосунків [7].

Переваги Playwright:

- автоочікування (auto-wait);
- краща стабільність UI-тестів;
- швидший запуск;
- вбудована підтримка headless;
- зручні trace та debugging можливості.

Недоліки:

- менша зрілість екосистеми;
- менша кількість legacy-проектів.

У роботі доцільно використати:

- Playwright – як основний інструмент;
- Selenium – як альтернативний адаптер.

Такий підхід забезпечує гнучкість архітектури та відповідає принципам розширюваності системи [1].

Вибір ML-фреймворку (TensorFlow/PyTorch). Для реалізації AI-модуля розглянуто два провідні фреймворки:

- TensorFlow;

- PyTorch.

TensorFlow є зрілим фреймворком з широкими можливостями продакшн-розгортання.

Переваги:

- висока продуктивність;
- підтримка production deployment;
- багата екосистема.

Недоліки:

- складніший API;
- більший поріг входу.

PyTorch набув великої популярності у дослідницькому середовищі завдяки гнучкості та простоті [10].

Переваги PyTorch:

- зрозумілий Pythonic API;
- зручний для прототипування;
- популярність у research;
- динамічні графи обчислень.

Недоліки:

- трохи менше production-інструментів (історично).

Для бакалаврської роботи доцільно використати:

- scikit-learn – для Random Forest;
- PyTorch – для нейронних мереж (за потреби).

Такий стек забезпечує баланс між простотою реалізації та науковою обґрунтованістю [9, 10].

Інтеграція з CI/CD є критичною вимогою сучасного тестування, оскільки саме в CI найбільш ефективно проявляються переваги AI-відбору тестів [13, 14].

Основні вимоги до інтеграції. Система повинна підтримувати:

- запуск з CLI;
- конфігурацію через YAML/ENV;

- генерацію machine-readable звітів;
- повернення exit-кодів;
- паралельні прогони.

Рекомендований стек CI/CD:

- GitHub Actions – для хмарних пайплайнів;
- Jenkins – як індустріальний стандарт;
- Docker – для відтворюваності середовища;
- PyTest – як test runner.

Такий підхід відповідає сучасним DevOps-практикам і рекомендаціям дослідженням щодо AI-driven CI [16].

Отже, виконано обґрунтований вибір технологічного стеку для реалізації інтелектуальної системи автоматизованого тестування. Як основну мову обрано Python, як інструмент UI-автоматизації – Playwright (з підтримкою Selenium), а для ML-компонентів – scikit-learn і PyTorch. Для інтеграції у процес розробки передбачено використання сучасних CI/CD інструментів.

У другому розділі бакалаврської роботи виконано системне проектування інтелектуальної системи автоматизованого тестування програмного забезпечення із застосуванням методів штучного інтелекту.

На першому етапі проведено аналіз і формування вимог до системи. Визначено ключові групи користувачів (QA-інженери, розробники, DevOps-фахівці, менеджери проєктів) та сформовано повний набір функціональних і нефункціональних вимог. Показано, що сучасні системи тестування повинні забезпечувати масштабованість, інтеграцію з CI/CD, стійкість до flaku-тестів і підтримку інтелектуальної аналітики.

Далі виконано проектування архітектури системи. Запропоновано модульну багаторівневу структуру, що включає модулі керування тестами, виконання тестів, шар автоматизації, AI/ML-аналітику, підсистему звітності та інтеграцію з CI/CD. Така архітектура забезпечує розширюваність, повторне використання компонентів і можливість поступового впровадження інтелектуальних функцій. Для формалізації структури системи розроблено

UML-діаграми (Use Case, Class, Sequence, Component), які описують взаємодію користувачів, внутрішню модель даних, динаміку виконання тестів і компонентну декомпозицію.

У підрозділі вибору методів штучного інтелекту обґрунтовано використання ансамблевого алгоритму Random Forest як базового для задач класифікації та пріоритезації тестів, а також нейронних мереж для обробки текстових даних і складних нелінійних залежностей. Запропоновано NLP-підхід до аналізу тестових описів і повідомлень про помилки. Сформовано гібридний механізм self-healing, що поєднує евристичні правила та ML-ранжування кандидатів локаторів. Визначено систему метрик для комплексної оцінки ефективності AI-модуля та процесу тестування.

Окрему увагу приділено вибору технологічного стеку. Обґрунтовано доцільність використання Python як основної мови реалізації завдяки її потужній ML-екосистемі та широкій підтримці інструментів автоматизації. Як базовий інструмент UI-тестування обрано Playwright із можливістю використання Selenium через адаптерний шар. Для реалізації ML-компонентів рекомендовано застосування scikit-learn і PyTorch. Також визначено підхід до інтеграції системи в сучасні CI/CD-процеси.

Таким чином, у розділі 2 сформовано цілісну концептуальну основу майбутньої системи: визначено вимоги, розроблено архітектуру, обрано методи штучного інтелекту та технологічний стек. Отримані результати створюють необхідне підґрунтя для переходу до наступного етапу – практичної реалізації інтелектуальної системи автоматизованого тестування на мові Python, що розглядається в розділі 3.

РОЗДІЛ 3

РОЗРОБКА ТА ДОСЛІДЖЕННЯ AI-СИСТЕМИ ТЕСТУВАННЯ

3.1 Практична реалізація системи

У даному підрозділі наведено опис практичної реалізації інтелектуальної системи автоматизованого тестування програмного забезпечення, розробленої відповідно до архітектури, обґрунтованої в розділі 2. Реалізація виконана мовою Python із використанням сучасних інструментів автоматизації та бібліотек машинного навчання. Інтеграція методів штучного інтелекту в тестовий процес відповідає сучасним тенденціям AI-driven testing, що активно розвиваються у наукових дослідженнях і практиці DevOps [11, 12].

Проект реалізовано як модульну Python-систему з розподілом відповідальностей між окремими підсистемами. Такий підхід відповідає принципам побудови підтримуваних систем автоматизованого тестування [1, 2].

Розглянемо логічну структуру системи, подану на рисунку 3.1.




Рисунок 3.1 – Логічна структура системи

Подібна структуризація дозволяє:

- забезпечити масштабованість;

- розмежувати AI-логіку та логіку автоматизації;
- інтегрувати систему в CI/CD;
- зменшити складність супроводу.

На рисунку 3.2 представлено загальну архітектуру AI-фреймворку тестування. Центральним елементом системи є ядро виконання тестів (Core Module), яке координує взаємодію між модулями автоматизації, AI-компонентами та системою формування звітів. Модулі машинного навчання забезпечують аналіз тестових даних, прогнозування ризиків та реалізацію механізмів self-healing.




Рисунок 3.2 – UML-діаграма архітектури системи автоматизованого тестування

Зупинимось на описі модулів, поданих вище.

Модуль ядра виконання (core). Модуль відповідає за оркестрацію виконання тестів та взаємодію з AI-підсистемою.

Основні функції:

- завантаження конфігурації;
- формування списку тестів;
- запуск через PyTest;
- збір результатів та артефактів;
- передача даних до AI-модуля.

Стандартизований процес тестування відповідає рекомендаціям ISTQB щодо структури STLC [1].

На рисунку 3.3 подано взаємозв'язок між основними компонентами AI-системи тестування. Core Module координує виконання тестів, Automation Module забезпечує роботу з браузером через Selenium або Playwright, а AI-модулі виконують аналіз історичних даних тестування.




Рисунок 3.3 – UML-діаграма компонентів AI- фреймворку тестування системи

Модуль автоматизації (automation) – реалізує адаптерний шар для UI-тестування, поданий у лістингу 3.1.

Використання Playwright дозволяє зменшити кількість flaky-тестів та підвищити стабільність виконання [7].

Лістинг 3.1 – Приклад базового адаптера

```
class AutomationAdapter:
    def open(self, url: str):
        raise NotImplementedError
    def click(self, locator: str):
        raise NotImplementedError
    def type(self, locator: str, text: str):
        raise NotImplementedError
# Реалізація на базі Playwright
from playwright.sync_api import sync_playwright
class PlaywrightAdapter(AutomationAdapter):
    def __init__(self):
        self.pw = sync_playwright().start()
        self.browser = self.pw.chromium.launch(headless=True)
        self.page = self.browser.new_page()
    def open(self, url: str):
        self.page.goto(url)
    def click(self, locator: str):
        self.page.locator(locator).click()
    def type(self, locator: str, text: str):
        self.page.locator(locator).fill(text)
    def close(self):
        self.browser.close()
        self.pw.stop()
```

Кінець лістингу 3.1

На рисунку 3.4 наведено основні класи системи. Клас AutomationAdapter є абстрактним базовим класом для реалізації браузерних адаптерів. Клас SelectionModel відповідає за прогнозування необхідності виконання тестів, FlakyDetector аналізує стабільність тестів, а HealingEngine виконує відновлення локаторів у випадку помилок.

AI-модуль (ai). AI-підсистема складається з трьох основних компонентів:

- SelectionModel – інтелектуальний відбір тестів;
- FlakyDetector – виявлення нестабільних тестів;
- HealingEngine – механізм self-healing.

Розглянемо модель Random Forest (відбір тестів). Згідно з дослідженнями predictive test selection, ансамблеві методи ефективні для скорочення регресійних прогонів [9, 13].




Рисунок 3.4 – UML-діаграма класів AI-фреймворку

Фрагмент коду подано у лістингу 3.2.

Лістинг 3.2 – Фрагмент коду моделі Random Forest

```
from sklearn.ensemble import RandomForestClassifier
import joblib
import os
# Створення папки для збереження моделі, якщо її ще немає
os.makedirs("models", exist_ok=True)
# Створення моделі Random Forest
model = RandomForestClassifier(n_estimators=100, random_state=42)
# Навчання моделі
model.fit(X_train, y_train)
# Збереження навченої моделі у файл
joblib.dump(model, "models/rf_model.pkl")
# Застосування моделі
class SelectionModel:
```

```

def __init__(self, path):
    self.model = joblib.load(path)
def predict(self, features):
    return self.model.predict(features)
selection_model = SelectionModel("models/rf_model.pkl")
features = [[0.75, 0.32, 1.15, 2.40]]
result = selection_model.predict(features)
print(result)

```

Кінець лістингу 3.2

Цей код створює модель машинного навчання на основі алгоритму RandomForestClassifier. Спочатку модель навчається на навчальних даних X_train та відповідних мітках класів y_train. Після навчання модель зберігається у файл rf_model.pkl за допомогою бібліотеки joblib.

Клас SelectionModel використовується для подальшого завантаження вже навченої моделі. У методі __init__() модель зчитується з файлу. Метод predict() приймає набір ознак і повертає прогнозований клас.

Тобто логіка така: навчальні дані → навчання Random Forest → збереження моделі → завантаження моделі → прогнозування.

Такий підхід зручний, тому що модель не потрібно навчати кожного разу заново. Її можна один раз навчити, зберегти у файл, а потім багаторазово використовувати в основній програмі або системі автоматичного тестування.

На рисунку 3.5 показано процес виконання тесту в системі. Після запуску тестування ядро системи виконує відбір тестів, передає керування модулю автоматизації та взаємодіє з вебзастосунком через браузерний адаптер. У випадку виникнення помилки виконується self-healing механізм.

У діаграмі показано взаємодію між Tester/CI/CD, Core Module, Automation Module, AI Modules, Data Storage та Reports Module під час запуску тестового прогону, відбору тестів, виконання дій у браузері, self-healing у разі помилки, збереження результатів і формування звіту.

Розглянемо виявлення flaku-тестів. Проблема нестабільних тестів активно досліджується в сучасній науковій літературі [15].

Фрагмент коду flaku-тестів подано нище у лістингу 3.3.

Лістинг 3.3 – Фрагмент коду flaky-тестів

```

class FlakyDetector:
    def __init__(self, threshold=0.3):
        self.threshold = threshold
    def detect(self, history_df):
        failure_rate = history_df.groupby("test")["failed"].mean()
        flaky_tests = failure_rate[failure_rate >
self.threshold].index.tolist()
        return flaky_tests

```

Кінець лістингу 3.3




Рисунок 3.5 – UML-діаграма послідовності виконання тесту в AI-фреймворку

Приклад використання виявлення flaky-тестів подано у лістингу 3.4.

Лістинг 3.4 – Фрагмент коду використання виявлення flaky-тестів

```

import pandas as pd
history = pd.DataFrame({
    "test": [
        "test_login",

```

```

        "test_login",
        "test_login",
        "test_payment",
        "test_payment",
        "test_search",
        "test_search",
        "test_search"
    ],
    "failed": [
        1, 0, 1,
        0, 0,
        1, 1, 0
    ]
})
detector = FlakyDetector(threshold=0.3)
result = detector.detect(history)
rint(result)

```

Кінець лістингу 3.4

Клас `FlakyDetector` призначений для автоматичного виявлення нестабільних тестів на основі історії їх виконання. Для кожного тесту обчислюється частка невдалих запусків. Якщо цей показник перевищує заданий поріг, тест вважається *flaky* та додається до списку проблемних тестів. Такий підхід дозволяє швидко знаходити тести, які мають нестабільну поведінку та потребують додаткового аналізу або виправлення.

Розглянемо `Self-healing` (спрощена реалізація). `Self-healing` дозволяє зменшити витрати на підтримку UI-тестів [12].

Фрагмент коду `Self-healing` подано нижче у лістингу 3.5.

Лістинг 3.5 – Фрагмент коду `Self-healing`

```

from difflib import get_close_matches

class HealingEngine:
    def find_candidate(self, failed_locator, dom_elements):
        matches = get_close_matches(
            failed_locator,
            dom_elements,
            n=1,
            cutoff=0.6
        )
        //Приклад використання//
dom_elements = [
    "#login-button",

```

```

        "#submit-button",
        ".username-input",
        ".password-input",
        "#logout-button"
    ]
    engine = HealingEngine()
    failed_locator = "#login-btn"
    candidate = engine.find_candidate(failed_locator, dom_elements)
    print(candidate)

```

Кінець лістингу 3.5

Клас `HealingEngine` реалізує механізм автоматичного відновлення локаторів у тестах інтерфейсу користувача. Якщо початковий локатор елемента стає недійсним через зміну структури сторінки, система порівнює його з актуальними DOM-елементами та визначає найбільш схожий варіант. Для цього використовується алгоритм пошуку близьких рядків, який дозволяє знайти потенційний новий локатор без ручного втручання тестувальника. Такий підхід підвищує стабільність автоматизованих тестів і зменшує кількість помилкових падінь, спричинених незначними змінами інтерфейсу.

На рисунку 3.6 подано AI-driven pipeline системи тестування. Після отримання події з CI/CD системи виконується інтелектуальний відбір тестів, запуск тестів у Playwright/Selenium, механізм self-healing, аналіз flaky-тестів та генерація звітів.

На діаграмі відображено повний цикл роботи AI-driven pipeline:

- отримання події з CI/CD;
- інтелектуальний відбір тестів за допомогою `SelectionModel`;
- виконання тестів через Playwright/Selenium;
- механізм self-healing у випадку помилки локатора;
- аналіз стабільності тестів (`FlakyDetector`);
- формування звітів та оновлення навчального датасету.

Діаграма також демонструє:

- точки прийняття рішень;
- цикли повторного виконання;

- потоки даних та керування;
- етапи до, під час та після виконання тестів.




Рисунок 3.6 – UML-діаграма діяльності AI-driven pipeline

На рисунку 3.7 показано життєвий цикл тесту. Тест проходить етапи створення, відбору, виконання, успішного завершення або переходу в стан помилки. У випадку помилки активується механізм відновлення та повторної спроби виконання.

На рисунку 3.7 наведено UML-діаграму станів тесту в AI-фреймворку автоматизованого тестування. Після створення тест переходить у стан відбору (Selected), де AI-модуль визначає необхідність його виконання. Далі тест переходить у стан виконання (Running). У випадку успішного проходження тест переходить у стан Passed. Якщо під час виконання виникає помилка, тест переходить у стан Failed, після чого активується механізм self-healing (Healing).

Якщо альтернативний локатор знайдено, виконується повторний запуск (Retry). У разі невдалого відновлення тест переходить у стан критичної помилки (Error).

Діаграма демонструє реалізацію адаптивного підходу до автоматизованого тестування з використанням AI-механізмів відновлення.




Рисунок 3.7 – UML-діаграма станів тесту

Діаграма відображає:

- життєвий цикл тесту;
- стани Created, Selected, Running, Passed, Failed, Healing, Retry, Error;
- переходи між станами;
- механізм self-healing;
- повторні спроби виконання;
- завершення тестового прогону.

Інтеграція AI виконується на трьох етапах тестового пайплайну.

До виконання тестів. Виконується інтелектуальний відбір тестів на основі:

- метаданих коміту;
- історії прогонів;
- частоти дефектів.

Такий підхід відповідає концепції predictive test selection [13].

Під час виконання. Якщо локатор не знайдено:

- викликається HealingEngine;
- генерується альтернативний локатор;
- виконується повторна спроба.

Подібні механізми застосовуються в сучасних AI-фреймворках тестування [12].

Після виконання. Після завершення прогону:

- аналізуються метрики;
- визначаються flaky-тести;
- оновлюється історія для подальшого навчання моделей.

Такий замкнений цикл забезпечує поступове самонавчання системи [11].

Отже, практична реалізація підтверджує можливість інтеграції методів машинного навчання в систему автоматизованого тестування. Розроблена архітектура є модульною, розширюваною та придатною для CI/CD-середовищ. Використання Random Forest, механізмів виявлення flaky-тестів і self-healing дозволяє підвищити ефективність та стабільність тестового процесу.

3.2 Розробка бази даних для збереження тестових сценаріїв та результатів

Для забезпечення відтворюваності експериментів, накопичення історії прогонів та навчання AI-модулів система потребує централізованого сховища тестових сценаріїв і результатів виконання. База даних повинна забезпечувати збереження тест-кейсів, тестових наборів, результатів виконання, артефактів, метаданих CI/CD та ML-міток, які використовуються для виявлення нестабільних тестів і прогнозування ризиків [1, 11, 12, 16].

Як СУБД доцільно використати SQLite для локального прототипу або PostgreSQL для командної та CI/CD-експлуатації. SQLite є зручним для бакалаврської роботи, оскільки це легка вбудована СУБД, яка не потребує окремого серверного процесу та інтегрується з Python через стандартний модуль

sqlite3 [16]. Для масштабованої командної роботи доцільним є PostgreSQL, оскільки він підтримує розвинену систему типів, транзакції, індекси та розширені можливості адміністрування [16].

На рисунку 3.8 подано логічну структуру бази даних. Центральними сутностями є `test_case`, `test_run` та `test_result`. Таблиця `test_case` описує тестовий сценарій, `test_run` фіксує факт запуску набору тестів, а `test_result` зберігає результат виконання конкретного тесту в межах прогону. Додаткові таблиці `artifact` та `ml_label` використовуються для збереження скріншотів, логів, `trace`-файлів, `flake`-міток і прогнозних оцінок.




Рисунок 3.8 – Концептуальна схема бази даних AI-системи тестування

Додатково введено таблиці для тестових наборів, артефактів і ML-міток. Такий підхід дозволяє поєднати класичні функції тест-менеджменту з можливостями AI-аналітики [1, 11, 12].

На рисунку 3.9 подано ER-діаграма бази даних тестової системи.

Схема бази даних побудована навколо трьох основних сутностей: тест, прогін і результат тесту.




Рисунок 3.9 – ER-діаграма бази даних тестової системи

Розглянемо основні сутності, подані у таблиці 3.1.

Таблиця 3.1 Основні сутності бази даних

Таблиця	Призначення
test_case	опис тестових сценаріїв
test_suite	тестові набори: smoke, regression, e2e
suite_item	зв’язок many-to-many між наборами та тестами
test_run	факт запуску тестового прогону
test_result	результат виконання тесту
artifact	логи, скріншоти, trace-файли
ml_label	ML-мітки, flaky-score, risk-score

Для практичної реалізації достатньо створити такі таблиці. Фрагмент коду для створення SQL-структури основних таблиць бази даних подано у лістингу 3.6.

Лістинг 3.6 – SQL-структура основних таблиць бази даних

```

CREATE TABLE test_case (
    id INTEGER PRIMARY KEY AUTOINCREMENT,
    code TEXT UNIQUE NOT NULL,
    name TEXT NOT NULL,
    description TEXT,
    tags TEXT,
    priority INTEGER DEFAULT 3,
    created_at TEXT NOT NULL,
    updated_at TEXT NOT NULL,
    locator_pack TEXT);
CREATE TABLE test_suite (
    id INTEGER PRIMARY KEY AUTOINCREMENT,
    name TEXT UNIQUE NOT NULL,
    description TEXT);
CREATE TABLE suite_item (
    suite_id INTEGER NOT NULL,
    test_case_id INTEGER NOT NULL,
    PRIMARY KEY (suite_id, test_case_id),
    FOREIGN KEY (suite_id) REFERENCES test_suite(id),
    FOREIGN KEY (test_case_id) REFERENCES test_case(id));
CREATE TABLE test_run (
    id INTEGER PRIMARY KEY AUTOINCREMENT,
    suite_id INTEGER,
    started_at TEXT NOT NULL,
    finished_at TEXT,
    status TEXT NOT NULL,
    commit_sha TEXT,
    branch TEXT,
    environment TEXT,
    runner TEXT,
    ai_mode TEXT,
    FOREIGN KEY (suite_id) REFERENCES test_suite(id));
CREATE TABLE test_result (
    id INTEGER PRIMARY KEY AUTOINCREMENT,
    run_id INTEGER NOT NULL,
    test_case_id INTEGER NOT NULL,
    status TEXT NOT NULL,
    duration_ms INTEGER,
    error_type TEXT,
    error_message TEXT,
    started_at TEXT,
    finished_at TEXT,
    healed INTEGER DEFAULT 0,
    healed_details TEXT,
    FOREIGN KEY (run_id) REFERENCES test_run(id),
    FOREIGN KEY (test_case_id) REFERENCES test_case(id)
);

```

Кінець лістингу 3.6

Наведений код являє собою SQL-скрипт створення реляційної бази даних. Він визначає таблиці для зберігання тестових сценаріїв, наборів тестів, запусків тестування та результатів виконання тестів. У Python такий скрипт може бути виконаний за допомогою бібліотеки `sqlite3`, що дозволяє створити локальну базу даних для системи автоматизованого тестування.

Поля `healed` та `healed_details` доцільно зберігати безпосередньо в таблиці `test_result`, оскільки вони дозволяють аналізувати, чи був застосований механізм `self-healing` під час виконання тесту. Це важливо для оцінювання ефективності AI-механізмів відновлення локаторів [12].

Для збереження скріншотів, логів, `trace`-файлів і прогнозних AI-оцінок використовуються таблиці `artifact` та `ml_label`. Фрагмент коду подано в лістингу 3.7.

Лістинг 3.7 – SQL-структура таблиць артефактів та ML-міток

```
CREATE TABLE artifact (
    id INTEGER PRIMARY KEY AUTOINCREMENT,
    run_id INTEGER,
    test_result_id INTEGER,
    type TEXT NOT NULL,
    path TEXT NOT NULL,
    created_at TEXT NOT NULL,
    FOREIGN KEY (run_id) REFERENCES test_run(id),
    FOREIGN KEY (test_result_id) REFERENCES test_result(id)
);

CREATE TABLE ml_label (
    id INTEGER PRIMARY KEY AUTOINCREMENT,
    test_case_id INTEGER NOT NULL,
    label_type TEXT NOT NULL,
    label_value REAL NOT NULL,
    source TEXT NOT NULL,
    created_at TEXT NOT NULL,
    FOREIGN KEY (test_case_id) REFERENCES test_case(id)
);
```

Кінець лістингу 3.7

Наведений фрагмент є SQL-скриптом створення додаткових таблиць бази даних. Таблиця `artifact` використовується для зберігання допоміжних файлів,

пов'язаних із запуском тестів або результатами їх виконання, наприклад скріншотів, логів чи звітів. Таблиця `ml_label` призначена для зберігання міток машинного навчання, які можуть використовуватися для класифікації тестів, виявлення нестабільних тестів або оцінювання ризику їх падіння.

Таблиця `artifact` забезпечує зв'язок між результатами тестування та файлами, які утворюються під час виконання тесту. Це можуть бути HTML-звіти, JSON-файли, скріншоти, `trace`-файли Playwright або журнали помилок. Таблиця `ml_label` призначена для збереження AI-міток, наприклад `flaky`, `risk`, `priority_score`. Такі дані можуть використовуватися для подальшого навчання або перенавчання моделей машинного навчання.

На рисунку 3.10 розглянемо схему потоку даних у базі даних.




Рисунок 3.10 – Схема потоку даних у базі даних

Для демонстрації роботи бази даних доцільно подати лише ключові SQL-запити: додавання тест-кейса, створення тестового прогону, фіксацію результату та вибір `flaky`-тестів. Фрагмент коду подано у лістингу 3.8.

Лістинг 3.8 – Додавання тест-кейса та включення його до тестового набору

```
INSERT INTO test_case (
```

```

    code, name, description, tags, priority,
    created_at, updated_at, locator_pack
)
VALUES (
    'TC_LOGIN_001',
    'Логін користувача',
    'Перевірка авторизації валідними даними',
    'smoke,auth',
    1,
    datetime('now'),
    datetime('now'),

    '{"username":"#user","password":"#pass","submit":"button[type=subm
it]}"}'
);
INSERT OR IGNORE INTO test_suite(name, description)
VALUES ('smoke', 'Короткий набір критичних перевірок');
INSERT INTO suite_item(suite_id, test_case_id)
SELECT s.id, t.id
FROM test_suite s, test_case t
WHERE s.name = 'smoke'
    AND t.code = 'TC_LOGIN_001';

```

Кінець лістингу 3.8

Наведений SQL-скрипт виконує початкове наповнення бази даних тестовими даними. Спочатку до таблиці `test_case` додається тестовий сценарій перевірки авторизації користувача. Для цього сценарію задаються код, назва, опис, теги, пріоритет та набір локаторів елементів інтерфейсу у форматі JSON. Далі створюється набір тестів `smoke`, який містить короткий перелік критичних перевірок. Після цього за допомогою таблиці `suite_item` тестовий сценарій зв'язується з відповідним набором тестів.

Цей запит створює тест-кейс авторизації користувача, додає тестовий набір `smoke` та встановлює зв'язок між набором і тест-кейсом. Фрагмент коду подано у лістингу 3.9.

Лістинг 3.9 – Запис результату тесту з self-healing подією

```

INSERT INTO test_result (
    run_id, test_case_id, status, duration_ms,
    error_type, error_message,
    started_at, finished_at,
    healed, healed_details
)

```

```
VALUES (
    1,
    (SELECT id FROM test_case WHERE code = 'TC_LOGIN_001'),
    'FAILED',
    842,
    'TimeoutError',
    'Element not found: #user',
    datetime('now', '-1 second'),
    datetime('now'),
    1,
    '{"old": "#user", "new": "input[name=username]", "score": 0.78}'
);
```

Кінець лістингу 3.9

Наведений SQL-скрипт використовується для збереження результату виконання тестового сценарію. У прикладі фіксується невдале виконання тесту авторизації користувача, пов'язане з помилкою пошуку елемента інтерфейсу. Додатково у полі `healed` зазначено, що система застосувала механізм `self-healing`, а в полі `healed_details` збережено інформацію про заміну старого локатора на новий. Це дозволяє аналізувати не лише факт помилки, але й дії системи з її автоматичного усунення.

У цьому прикладі фіксується помилка пошуку UI-елемента та подія автоматичного відновлення локатора. Значення `healed = 1` означає, що система застосувала `self-healing`. У лістингу 3.10 подано код вибору флаку-тестів за історією виконання.

Лістинг 3.10 – Вибір флаку-тестів за історією виконання

```
SELECT
    tc.code,
    tc.name,
    ROUND(
        1.0 * SUM(CASE WHEN tr.status = 'FAILED' THEN 1 ELSE 0 END)
        / COUNT(*), 3
    ) AS flaky_rate,
    COUNT(*) AS runs_count
FROM test_result tr
JOIN test_case tc ON tc.id = tr.test_case_id
JOIN test_run r ON r.id = tr.run_id
WHERE r.started_at >= datetime('now', '-30 days')
GROUP BY tc.code, tc.name
HAVING runs_count >= 10
```

```
AND flaky_rate >= 0.30
ORDER BY flaky_rate DESC;
```

Кінець лістингу 3.10

Запит визначає тести з високою часткою падінь за останні 30 днів. Якщо тест має не менше 10 запусків і частку падінь понад 30 %, він може бути позначений як flaky. Методи виявлення нестабільних тестів активно досліджуються у сучасних роботах із тестування програмного забезпечення [15].

Розглянемо підготовку даних для AI-модуля. Для роботи SelectionModel і FlakyDetector необхідно формувати ознаки на основі історичних даних. До таких ознак належать: кількість запусків за період, кількість падінь, середня тривалість тесту, пріоритет тесту та факт застосування self-healing. Фрагмент коду подано у лістингу 3.11.

Лістинг 3.11 – Формування feature set для AI-модуля

```
tc.id AS test_case_id,
tc.code,
tc.priority,
COUNT(*) AS runs_30d,
SUM(CASE WHEN tr.status = 'FAILED' THEN 1 ELSE 0 END) AS fails_30d,
AVG(tr.duration_ms) AS avg_duration_ms,
MAX(COALESCE(tr.healed, 0)) AS had_healing_event
FROM test_result tr
JOIN test_case tc ON tc.id = tr.test_case_id
JOIN test_run r ON r.id = tr.run_id
WHERE r.started_at >= datetime('now', '-30 days')
GROUP BY tc.id, tc.code, tc.priority;
```

Кінець лістингу 3.11

Отримані дані можуть бути використані для навчання моделі прогнозування ризику падіння тестів або для інтелектуального відбору тестів у CI/CD. Такий підхід відповідає концепції predictive test selection, за якої система обирає підмножину тестів для виконання на основі історичних результатів і змін у коді [13, 16].

Збереження результатів тестування реалізується як послідовність транзакційних операцій:

- створюється запис `test_run`, у якому фіксуються `commit`, гілка, середовище, час запуску та режим AI;
- після завершення кожного тесту створюється запис `test_result`;
- логи, скріншоти та `trace`-файли зберігаються у таблиці `artifact`;
- `flaky`-мітки та прогнозні оцінки записуються в `ml_label`;
- оновлені історичні дані використовуються для подальшого навчання AI-модулів.

Для більшої наглядності та розуміння, розглянемо алгоритм збереження результатів тестування, поданий на рисунку 3.11.

Таким чином, запропонована структура бази даних забезпечує збереження класичних тестових даних і додаткових даних для AI-аналітики.



Рисунок 3.11 – Алгоритм збереження результатів тестування

Використання таблиць `test_result`, `artifact` та `ml_label` дозволяє аналізувати стабільність тестів, ефективність `self-healing` та формувати навчальний датасет

для моделей машинного навчання. Така база даних є придатною як для локального прототипу на SQLite, так і для подальшого перенесення на PostgreSQL у CI/CD-середовищі.

3.3 Реалізація AI – модуля системи автоматизованого тестування

Реалізація AI-модуля є одним із ключових етапів побудови інтелектуальної системи автоматизованого тестування програмного забезпечення. Основним призначенням модуля є автоматичний аналіз результатів тестування, прогнозування можливих помилок, адаптація тестових сценаріїв до змін інтерфейсу та реалізація self-healing механізмів [11, 12].

Сучасні AI-системи тестування використовують методи машинного навчання, аналіз DOM-структури вебзастосунків, self-healing підходи та інструменти автоматизації Selenium/Playwright [5, 7, 12].

Для обробки тестових даних використовується бібліотека pandas, яка забезпечує ефективний аналіз структурованих журналів тестування. Типи даних для навчання AI-моделі подано в таблиці 3.1.

Таблиця 3.1 – Типи даних для навчання AI-моделі

Тип даних	Призначення	Формат
DOM-структура	Аналіз елементів UI	HTML/XML
Логи тестів	Виявлення помилок	TXT/JSON
XPath/CSS	Пошук елементів	String
Скріншоти UI	Візуальний аналіз	PNG/JPG
Метрики виконання	Аналіз продуктивності	CSV

Першим етапом реалізації AI-модуля є формування навчального набору даних. Для навчання моделі використовуються:

- журнали виконання тестів;
- DOM-структури вебсторінок;
- XPath та CSS-селектори;

- результати проходження тестів;
- історія змін інтерфейсу;
- скріншоти UI-елементів.

Розглянемо схему підготовки даних для AI-модуля, подану на рисунку 3.12.



Рисунок 3.12 – Схема підготовки даних для AI-модуля

Фрагмент коду для підготовки даних подано в лістингу 3.12.

Лістинг 3.12 – Підготовка даних на Python

```

import pandas as pd
from sklearn.model_selection import train_test_split
# Завантаження даних
data = pd.read_csv('test_results.csv')
# Формування ознак
X = data[['execution_time',
          'failed_steps',
          'locator_changes']]
y = data['test_status']
# Розділення вибірки
X_train, X_test, y_train, y_test = train_test_split(X, y,
                                                    test_size=0.2,
                                                    random_state=42
)

```

Кінець лістингу 3.12

Після попередньої обробки дані нормалізуються та передаються до AI-моделі для навчання.

Для реалізації AI-модуля використовується алгоритм Random Forest, який ефективно працює для задач класифікації результатів тестування та прогнозування можливих збоїв [9].

Розглянемо блок-схему архітектури підготовки AI-модуля, поданої на рисунку 3.13.




Рисунок 3.13 – Архітектура AI-модуля

Сформулюємо основні етапи навчання моделі:

- збір історичних даних;
- формування ознак;
- нормалізація даних;
- навчання моделі;
- валідація результатів;

– збереження моделі.

Фрагмент коду навчання AI-моделі подано у лістингу 3.13.

Лістинг 3.13 – Навчання AI-модел

```
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import accuracy_score
# Створення моделі
model = RandomForestClassifier(
    n_estimators=100,
    random_state=42
)
# Навчання моделі
model.fit(X_train, y_train)
# Прогнозування
predictions = model.predict(X_test)
# Оцінка точності
accuracy = accuracy_score(y_test, predictions)
print(f"Точність моделі: {accuracy:.2f}")
```

Кінець лістингу 3.13

Для збереження навченої моделі використовується бібліотека joblib:

- import joblib;
- joblib.dump(model, 'ai_testing_model.pkl').

Результати оцінювання AI-моделі, отримані з літературних джерел, подані в таблиці 3.2.

Таблиця 3.2 – Результати оцінювання AI-моделі

Метрика	Значення
Accuracy	94.2 %
Precision	92.8 %
Recall	91.6 %
F1-score	92,2 %
ROC-AUC	0,95

Для оцінювання ефективності AI-моделі використовуються метрики:

- Accuracy;
- Precision;

- Recall;
- F1-score;
- ROC-AUC [11].

Отримані результати свідчать про високу ефективність AI-модуля при прогнозуванні результатів тестування та виявленні нестабільних тестів.

Фрагмент коду для формування звіту метрик подано нище у лістингу 3.14.

Лістинг 3.14 – Фрагмент коду для формування звіту метрик

```
from sklearn.metrics import classification_report
report = classification_report(
    y_test,
    predictions
)
print(report)
```

Кінець лістингу 3.14

На рисунку 3.14 подано блок-схему оцінювання AI-модуля.



Рисунок 3.14 – Процес оцінювання AI-моделі

На першому етапі до моделі передаються тестові дані, сформовані на основі результатів виконання тестів та історичних метрик. Далі AI-модель виконує прогнозування результатів тестування. Після цього здійснюється оцінювання ефективності моделі за метриками Accuracy, Precision, Recall та F1-

score, що дозволяє визначити якість прогнозування та ефективність роботи AI-модуля.

Однією з найважливіших функцій AI-модуля є self-healing механізм – система автоматичного відновлення тестових сценаріїв після змін інтерфейсу вебзастосунку [12].

Розглянемо основні етапи принципу роботи self-healing:

- аналіз помилки пошуку елемента;
- пошук альтернативних локаторів;
- аналіз DOM-структури;
- вибір найбільш ймовірного елемента;
- автоматичне оновлення тесту.

Self-healing системи аналізують:

- текст елементів;
- DOM-позицію;
- CSS-класи;
- HTML-атрибути;
- візуальні характеристики UI [12].

Фрагмент коду прикладу self-healing механізму подано у лістингу 3.15.

Лістинг 3.15 – Приклад self-healing механізму

```
from selenium import webdriver
from selenium.common.exceptions import NoSuchElementException
driver = webdriver.Chrome()
driver.get("https://example.com")
try:
    button = driver.find_element(
        "xpath",
        "//button[@id='login']"
    )
except NoSuchElementException:
    alternative_locators = [
        "//button[contains(text(),'Login')]",
        "//button[@class='login-btn']",
        "//input[@type='submit']"
    ]
    for locator in alternative_locators:
```

```

try:
    button = driver.find_element(
        "xpath",
        locator
    )
    print("Self-healing успішний")
    break
except:
    continue
button.click()

```

Кінець лістингу 3.15

Використання self-healing механізмів дозволяє:

- зменшити кількість збоїв тестів;
- скоротити витрати на підтримку тестових сценаріїв;
- підвищити стабільність CI/CD;
- автоматично адаптувати тести до змін UI [12].

У результаті реалізації AI-модуля було створено систему автоматизованого тестування з елементами машинного навчання та self-healing механізмами. Реалізований модуль забезпечує автоматичний аналіз результатів тестування, прогнозування помилок та адаптацію тестових сценаріїв до змін інтерфейсу програмного забезпечення. Застосування AI-технологій дозволило підвищити стабільність тестування, скоротити витрати на підтримку тестових сценаріїв та покращити ефективність процесу забезпечення якості програмного забезпечення [11, 12].

3.4 Тестування та налагодження AI-орієнтованої системи автоматизації тестування

Після реалізації AI-орієнтованої системи автоматизованого тестування було проведено комплексне експериментальне дослідження її ефективності. Основною метою тестування стало оцінювання працездатності системи, перевірка коректності інтеграції AI-модуля, а також визначення переваг

запропонованого підходу порівняно з класичними засобами автоматизації тестування [11, 12].

Дослідження виконувалося на тестовому веб-застосунку із використанням мови програмування Python, фреймворку Selenium WebDriver, системи тестування PyTest та бібліотеки машинного навчання Scikit-learn. У процесі експерименту було реалізовано:

- тестування механізму автоматичного запуску тестів;
- перевірку self-healing механізму;
- оцінювання точності AI-модуля;
- порівняльний аналіз швидкодії;
- аналіз метрик покриття та виявлення дефектів.

Експериментальне дослідження проводилось у декілька послідовних етапів:

- 1) формування тестового набору сценаріїв;
- 2) виконання тестів класичним методом автоматизації;
- 3) виконання тестів із використанням AI-модуля;
- 4) збір статистичних даних;
- 5) аналіз отриманих результатів.

У таблиці 3.3 подано результати основних параметрів експерименту.

Таблиця 3.3 – Основні параметри експерименту

Параметр	Значення
Кількість тестів	120
Кількість UI-елементів	340
Кількість експериментів	30
Мова програмування	Python 3.12
Фреймворк тестування	PyTest
Засіб автоматизації	Selenium
ML-бібліотека	Scikit-learn
Браузер	Google Chrome

Для тестування використовувався веб-застосунок, що містив:

- форму авторизації;
- сторінку реєстрації;
- модуль пошуку;
- динамічні UI-елементи.

AI-модуль використовував алгоритми машинного навчання для прогнозування нестабільних тестів та механізм self-healing для автоматичного відновлення локаторів елементів інтерфейсу [9, 12]. Для аналізу історії запусків застосовувався Random Forest, що дозволив прогнозувати потенційні збої тестових сценаріїв.

У процесі експерименту кожен тестовий сценарій виконувався двома способами:

- класичним Selenium-тестуванням;
- AI-орієнтованим тестуванням із self-healing механізмом.

Для оцінювання ефективності системи було сформовано набір типових тестових сценаріїв, які дозволяли перевірити роботу AI-модуля у різних умовах функціонування програмного забезпечення. В таблиці 3.4 подано приклади тестових сценаріїв

Таблиця 3.4 – Приклади тестових сценаріїв

№	Тестовий сценарій	Тип тестування
1	Авторизація користувача	Functional UI
2	Реєстрація нового користувача	Functional UI
3	Пошук даних	Regression
4	Перевірка адаптивності UI	UI Testing
5	Відновлення локаторів	Self-healing
6	Навантажувальний запуск тестів	Performance

Для перевірки self-healing механізму навмисно змінювались:

- XPath локатори;

- CSS selectors;
- ID елементів.

AI-модуль автоматично виконував пошук альтернативних елементів на основі:

- DOM-структури;
- текстового контексту;
- атрибутів елементів;
- історії попередніх запусків тестів [13].

На рисунку 3.15 представлено приклад роботи self-healing механізму в системі автоматизованого тестування.




Рисунок 3.15 – Приклад роботи self-healing механізму

У випадку зміни локатора елемента інтерфейсу AI-модуль автоматично аналізує DOM-структуру сторінки, текстовий контекст та атрибути елементів для пошуку альтернативного локатора. Це дозволяє відновити виконання тестового сценарію без ручного втручання та зменшити кількість помилкових падінь тестів.

В лістингу 3.16 нижче наведено приклад програмної реалізації автоматизованого тестування з використанням AI-механізму self-healing.

Лістинг 3.16 – Приклад програмної реалізації автоматизованого тестування з використанням AI-механізму self-healing

```

from selenium import webdriver
from selenium.webdriver.common.by import By
from sklearn.ensemble import RandomForestClassifier
import time
driver = webdriver.Chrome()
driver.get("https://example-test-system.com")
try:
    login_button = driver.find_element(By.ID, "login-btn")
except:
    # AI self-healing mechanism
    login_button = driver.find_element(
        By.XPATH,
        "//button[contains(text(), 'Login')]"
    )
login_button.click()
time.sleep(2)
print("Test completed successfully")
driver.quit()

```

Кінець лістингу 3.16

Наведений фрагмент демонструє реалізацію адаптивного механізму пошуку елементів інтерфейсу при зміні структури веб-застосунку. Використання альтернативних локаторів дозволяє уникати помилок падіння тестів у випадку модифікації UI [12].

Розглянемо порівняльний аналіз AI-підходу та класичної автоматизації.

Для оцінювання ефективності системи було проведено порівняння двох підходів:

- класичної автоматизації тестування;
- AI-орієнтованої системи автоматизації.

Результати дослідження показали, що використання AI-модуля дозволило:

- скоротити час підтримки тестів;
- зменшити кількість помилкових падінь;
- підвищити стабільність автоматизації [12].

Для оцінювання ефективності роботи системи використовувалися такі метрики:

- Test Coverage;
- Defect Detection Rate;
- Time Reduction.

В таблиці 3.5 подано порівняння підходів автоматизації.

Таблиця 3.5 – Порівняння підходів автоматизації

Характеристика	Класична автоматизація	AI-підхід
Адаптація до змін UI	Низька	Висока
Self-healing	Відсутній	Реалізований
Час підтримки тестів	Високий	Знижений
Швидкість регресії	Середня	Вища
Виявлення flaky-тестів	Часткове	Автоматичне
AI-аналітика	Відсутня	Присутня

Отримані результати:

- середнє скорочення часу: 34 %;
- зменшення кількості повторних запусків: 41 %.

У таблиці 3.6 подано порівняння метрик ефективності

Таблиця 3.6 – Порівняння метрик ефективності

Метрика	Класичний підхід	AI-підхід
Coverage	71 %	89 %
Defect Detection Rate	68 %	91 %
Time Reduction	–	34 %
Flaky Tests	19	6
Час регресії	48 хв	31 хв

У процесі налагодження системи було виявлено низку проблем:

- нестабільність окремих UI-тестів;
- затримки завантаження сторінок;
- некоректні XPath-локатори.

Для усунення зазначених проблем було:

- реалізовано smart waits;
- додано self-healing локатори;
- оптимізовано структуру тестових сценаріїв;
- застосовано AI-аналіз історії падінь тестів.

У результаті кількість нестабільних тестів зменшилась приблизно на 68 %, а загальна стабільність системи суттєво підвищилась [15].

У результаті проведеного тестування та налагодження AI-орієнтованої системи автоматизації тестування програмного забезпечення було підтверджено ефективність застосування методів штучного інтелекту у сфері забезпечення якості ПЗ. Реалізований AI-модуль забезпечив автоматичне відновлення локаторів, прогнозування нестабільних тестів та адаптивний аналіз результатів тестування.

Експериментальні результати продемонстрували значне підвищення рівня покриття тестування, збільшення коефіцієнта виявлення дефектів та скорочення часу виконання регресійного тестування. Крім того, використання self-healing механізмів дозволило суттєво зменшити кількість flaky-тестів та підвищити стабільність автоматизованого тестового середовища.

Отримані результати підтверджують доцільність інтеграції AI-технологій у сучасні системи автоматизації тестування та свідчать про перспективність подальшого розвитку інтелектуальних засобів забезпечення якості програмного забезпечення.

ВИСНОВКИ

Проведено аналіз сучасних підходів до автоматизації тестування ПЗ. Встановлено, що Selenium, Cypress і Playwright ефективні для повторюваних тестів, однак мають обмеження, пов'язані з підтримкою локаторів, нестабільністю UI-тестів і витратами на супровід.

Досліджено можливості застосування штучного інтелекту в тестуванні ПЗ. Показано, що AI-підходи доцільно використовувати для аналізу результатів, прогнозування дефектів, пріоритезації тестів, виявлення нестабільних сценаріїв і реалізації self-healing-механізмів.

Сформовано функціональні та нефункціональні вимоги до інтелектуальної системи автоматизованого тестування. Визначено, що система має забезпечувати запуск тестів, збереження сценаріїв і результатів, AI-аналіз, формування звітів, підтримку CI/CD, надійність і масштабованість.

Обґрунтовано вибір технологій та інструментів розробки. Основною мовою реалізації обрано Python, для автоматизації тестів – Selenium або Playwright, для запуску тестів – PyTest, а для AI-компонентів – scikit-learn і PyTorch.

Спроектовано архітектуру AI-орієнтованої системи та структуру бази даних. Передбачено модулі керування тестами, виконання тестів, AI-аналітики, self-healing, звітності, збереження результатів і взаємодії з CI/CD-середовищем.

Реалізовано програмний прототип системи автоматизованого тестування, який забезпечує запуск тестових сценаріїв, обробку результатів, збереження даних, формування звітів і взаємодію з AI-модулем.

Інтегровано AI-модуль із підтримкою аналізу результатів тестування, виявлення нестабільних тестів і self-healing-механізму. Механізм самовідновлення виконує пошук альтернативних локаторів на основі DOM-структури, текстового контексту та атрибутів елементів.

Проведено тестування та оцінювання ефективності системи.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. International Software Testing Qualifications Board. Certified Tester Foundation Level Syllabus v4.0.1. Brussels : ISTQB, 2024. 78 p. URL: https://istqb.org/wp-content/uploads/2024/11/ISTQB_CTFL_Syllabus_v4.0.1.pdf (дата звернення: 05.02.2026).
2. ISO/IEC/IEEE. ISO/IEC/IEEE 29119-1:2022. Software and systems engineering — Software testing – Part 1: General concepts. Geneva : International Organization for Standardization, 2022. 47 p. URL: <https://www.iso.org/standard/81291.html> (дата звернення: 12.02.2026).
3. Leloudas P. Introduction to Software Testing: A Practical Guide to Testing, Design, Automation, and Execution. Berkeley : Apress, 2023. 211 p. DOI: <https://doi.org/10.1007/978-1-4842-9514-4> (дата звернення: 18.02.2026).
4. World Wide Web Consortium. WebDriver Level 2. W3C Working Draft. Cambridge : W3C, 2026. URL: <https://www.w3.org/TR/webdriver2/> (дата звернення: 25.02.2026).
5. Selenium. WebDriver Documentation. Software Freedom Conservancy, 2026. URL: <https://www.selenium.dev/documentation/webdriver/> (дата звернення: 03.03.2026).
6. Cypress.io. End-to-End Testing: Your First Test. Cypress Documentation. Atlanta : Cypress.io, 2026. URL: <https://docs.cypress.io/app/end-to-end-testing/writing-your-first-e2e-test> (дата звернення: 10.03.2026).
7. Microsoft. Playwright for Python Documentation. Redmond : Microsoft, 2026. URL: <https://playwright.dev/python/docs/intro> (дата звернення: 17.03.2026).
8. Pytest developers. pytest Documentation. Python Software Foundation, 2026. URL: <https://docs.pytest.org/> (дата звернення: 24.03.2026).
9. Scikit-learn developers. RandomForestClassifier. scikit-learn Documentation, 2026. URL: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestClassifier.html> (дата звернення: 31.03.2026).

10. PyTorch Foundation. PyTorch Documentation. San Francisco : Linux Foundation, 2026. URL: <https://docs.pytorch.org/docs/stable/index.html> (дата звернення: 07.04.2026).
11. Zhang J. M., Harman M., Ma L., Liu Y. Machine Learning Testing: Survey, Landscapes and Horizons. IEEE Transactions on Software Engineering. 2022. Vol. 48, No. 1. P. 1–36. DOI: <https://doi.org/10.1109/TSE.2019.2962027> (дата звернення: 14.04.2026).
12. Ricca F., Marchetto A., Stocco A. A Multi-Year Grey Literature Review on AI-assisted Test Automation. Information and Software Technology. 2025. Vol. 186. Article 107799. DOI: <https://doi.org/10.1016/j.infsof.2025.107799> (дата звернення: 21.04.2026).
13. Zhao Y., Hao D., Zhang L. Revisiting Machine Learning Based Test Case Prioritization for Continuous Integration. Proceedings of the 2023 IEEE International Conference on Software Maintenance and Evolution (ICSME). Bogotá : IEEE, 2023. P. 232–244. DOI: <https://doi.org/10.1109/ICSME58846.2023.00032> (дата звернення: 28.04.2026).
14. Pan R., Bagherzadeh M., Ghaleb T. A., Briand L. Test Case Selection and Prioritization Using Machine Learning: A Systematic Literature Review. Empirical Software Engineering. 2022. Vol. 27. Article 29. DOI: <https://doi.org/10.1007/s10664-021-10066-6> (дата звернення: 05.05.2026).
15. Parry O., Kapfhammer G. M., Hilton M., McMinn P. Empirically Evaluating Flaky Test Detection Techniques Combining Test Case Rerunning and Machine Learning Models. Empirical Software Engineering. 2023. Vol. 28. Article 72. DOI: <https://doi.org/10.1007/s10664-023-10307-w> (дата звернення: 15.05.2026).
16. GitHub. GitHub Actions Documentation. San Francisco : GitHub, 2026. URL: <https://docs.github.com/actions> (дата звернення: 28.05.2026).