

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Національний університет «Запорізька політехніка»

Факультет комп'ютерних наук і технологій

(повне найменування факультету)

Кафедра програмних засобів

(повне найменування кафедри)

Пояснювальна записка

до дипломного проекту (роботи)

бакалавр

(ступінь вищої освіти)

на тему РОЗРОБЛЕННЯ ТА ДОСЛІДЖЕННЯ ПРОГРАМНОГО
ЗАБЕЗПЕЧЕННЯ ДІАЛОВОЇ СИСТЕМИ
АВТОМАТИЗОВАНОГО КОНСУЛЬТУВАННЯ
КОРИСТУВАЧІВ ВЕБРЕСУРСУ
DEVELOPMENT AND RESEARCH OF SOFTWARE
FOR A DIALOGUE SYSTEM FOR AUTOMATED USER
CONSULTATION ON WEB RESOURCES

Виконав(ла): студент(ка) 4 курсу, групи КНТ-132

Спеціальності 121 Інженерія програмного

(код і найменування спеціальності)

забезпечення

Освітня програма (спеціалізація)

Інженерія програмного забезпечення

СЕВЕРИН М.А.

(ПРИЗВИЩЕ та ініціали)

Керівник ЛЕОЩЕНКО С.Д.

(ПРИЗВИЩЕ та ініціали)

Рецензент ПОЛЯКОВ М.О.

(ПРИЗВИЩЕ та ініціали)

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
Національний університет «Запорізька політехніка»
 (повне найменування закладу вищої освіти)

Факультет КНТ
 Кафедра програмних засобів
 Ступінь вищої освіти бакалавр
 Спеціальність 121 Інженерія програмного забезпечення
 (код і найменування)
 Освітня програма (спеціалізація) Інженерія програмного забезпечення
 (назва освітньої програми (спеціалізації))

ЗАТВЕРДЖУЮ

Завідувач кафедри ПЗ, д.т.н, проф.
Сергій СУББОТІН
 “ ” 2026 року

З А В Д А Н Н Я

НА ДИПЛОМНИЙ ПРОЄКТ (РОБОТУ) СТУДЕНТА(КИ)

СЕВЕРІНА Максима Андрійовича

(ПРИЗВИЩЕ, ім'я, по батькові)

1. Тема проєкту (роботи) Розроблення та дослідження програмного забезпечення діалогової системи автоматизованого консультування користувачів вебресурсу. Development and Research of Software for Dialogue System for Automated User Consultation on Web Resources.

керівник проєкту (роботи) д-р філософ., доцент, ЛЕОЩЕНКО Сергій Дмитрович

(науковий ступінь, вчене звання, ПРИЗВИЩЕ, ім'я, по батькові)

затверджені наказом закладу вищої освіти від “ 07 ” квітня 2026 року № 139

2. Строк подання студентом проєкту (роботи) 10 червня 2026 року

3. Вихідні дані до проєкту (роботи) рекомендована література, технічне завдання

4. Зміст розрахунково-пояснювальної записки (перелік питань, які потрібно розробити) 1. Аналіз проблеми та постановка завдань дослідження. 2. Матеріали і методи. 3. Опис програми. 4. Експлуатація, тестування та експериментальне дослідження програми.

5. Перелік графічного матеріалу (з з точним зазначенням обов'язкових креслень, кількість слайдів, плакатів)

Слайди презентації

6. Консультанти розділів проєкту (роботи)

Розділ	ПРИЗВИЩЕ, ініціали та посада консультанта	Підпис, дата	
		завдання видав	прийняв виконане завдання
1-4 Основна частина	ЛЕОЩЕНКО С.Д., доцент		
Нормоконтроль	КАЛІНІНА М.В., асистент		

7. Дата видачі завдання «20» квітня 2026 року.

КАЛЕНДАРНИЙ ПЛАН

№ з/п	Назва етапів дипломного проєкту (роботи)	Строк виконання етапів проєкту (роботи)	Примітка
1	Постановка завдання роботи.	1 тиждень	Завдання, ТЗ
2	Аналіз предметної області.	1 тиждень	Розділ 1
3	Вибір мови програмування та інших технологій розробки.	2 тиждень	Розділ 2
4	Розробка архітектури програми.	2 тиждень	Розділ 3
5	Розробка програми.	3-4 тижні	Розділ 3, 4
6	Тестування та експериментальне дослідження програмного забезпечення.	5 тиждень	Розділ 4
7	Оформлення пояснювальної записки та документів до неї.	6 тиждень	Додатки
8	Нормоконтроль та рецензування.	7 тиждень	
9	Захист роботи.	8 тиждень	

Студент(ка)

Максим СЕВЕРИН
(Ім'я ПРІЗВИЩЕ)

Керівник проєкту (роботи)

(підпис) Сергій ЛЕОЩЕНКО
(Ім'я ПРИЗВИЩЕ)

РЕФЕРАТ

Пояснювальна записка до дипломної кваліфікаційної роботи бакалавра: 98 с., 10 табл., 37 рис., 3 дод., 28 джерел.

ДІАЛогоВА СИСТЕМА, ГЕНЕРАЦІЯ З ДОПОВНЕНИМ ПОШУКОМ, ВЕЛИКІ МОВНІ МОДЕЛІ, АВТОМАТИЗОВАНЕ КОНСУЛЬТУВАННЯ, ГІБРИДНИЙ ПОШУК, ВЕБРЕСУРС.

Об'єкт дослідження – процес розроблення та програмної реалізації програмного забезпечення інтелектуальних діалогових систем для вебресурсів.

Предмет дослідження – методи та програмні засоби генерації з доповненим пошуком для обробки природномовних запитів.

Мета роботи – підвищення швидкості автоматизованого інформаційно-консультаційного обслуговування користувачів вебресурсів за рахунок створення автономної діалогової системи на базі локальних мовних моделей.

Матеріали, методи та технічні засоби: персональний комп'ютер, середовище розробки Visual Studio Code, мова програмування Python разом з набором пакетів для машинного навчання та обробки природної мови, асинхронний вебфреймворк FastAPI, векторна база даних ChromaDB, система локального запуску мовних моделей Ollama.

Результати. Розроблено програмне забезпечення серверної частини діалогової системи, що дозволяє автоматично збирати, індексувати та здійснювати пошук по вебсторінках і документах. Реалізовано архітектуру гібридного пошуку із застосуванням перехресного кодування та агрегації рангів. Забезпечено інтеграцію з локальними великими мовними моделями. Впроваджено багаторівневу систему безпеки для захисту від ін'єкцій у підказки та виток системних даних.

Висновки. Досягнуто підвищення швидкості та точності автоматизованого консультування користувачів завдяки впровадженню гібридного пошуку в механізм генерації з доповненим пошуком, що значно перевершує показники класичного семантичного пошуку. Розроблена система безпеки та ізоляції контексту успішно блокує спроби обходу інструкцій, що дозволяє безпечно розгортати систему в публічному середовищі, прискорюючи обробку запитів користувачів.

Галузь використання – інформаційно-довідкові системи закладів освіти, автоматизація роботи служб підтримки, корпоративні бази знань.

ABSTRACT

Explanatory note to the diploma qualifying work of the bachelor: 98 pages, 10 tables, 37 figures, 3 appendixes, 28 sources.

DIALOGUE SYSTEM, RETRIEVAL-AUGMENTED GENERATION, LARGE LANGUAGE MODELS, AUTOMATED CONSULTING, HYBRID SEARCH, WEB RESOURCE.

Object of research is the process of developing and implementing software for intelligent dialogue systems for web resources.

Subject of the study is methods and software tools for generating augmented search to process natural language queries.

The purpose of the work is to improve the speed of automated information and advisory services for users of web resources by creating a standalone dialogue system based on local language models.

Materials, methods and technical tools: a personal computer, the Visual Studio Code development environment, the Python programming language together with a set of packages for machine learning and natural language processing, the FastAPI asynchronous web framework, the ChromaDB vector database, the Ollama local language model execution system.

Results. Software for the server-side of the dialogue system has been developed, enabling the automatic collection, indexing and searching of web pages and documents. A hybrid search architecture has been implemented using cross-encoding and rank aggregation. Integration with local large language models has been ensured. A multi-level security system has been implemented to protect against prompt injection and system data leaks.

Conclusions. The speed and accuracy of automated user advice have been improved through the implementation of a hybrid search mechanism incorporating augmented search, which significantly outperforms traditional semantic search. The developed security and context isolation system successfully blocks attempts

to bypass instructions, allowing the system to be safely deployed in a public environment whilst accelerating the processing of user queries.

The field of use are information and reference systems for educational institutions, automation of support services, and corporate knowledge bases.

ЗМІСТ

	С.
Перелік скорочень та умовних позначок	11
Вступ.....	12
1 Аналіз проблеми та постановка завдань дослідження	13
1.1 Огляд предметної області	13
1.2 Актуальність проблеми	13
1.3 Огляд аналогів	14
1.3.1 Google Dialogflow.....	14
1.3.2 Chatbase	15
1.3.3 SiteGPT	16
1.3.4 Загальне порівняння аналогів	17
1.4 Висновки за розділом	18
2 Матеріали і методи.....	20
2.1 Аналіз мов програмування	20
2.1.1 Мова програмування Python	20
2.1.2 Мова програмування Go.....	20
2.1.3 Мова програмування Java	21
2.1.4 Загальне порівняння мов програмування	21
2.1.5 Обґрунтування вибору мови програмування.....	22
2.2 Аналіз серверних вебфреймворків.....	23
2.2.1 Вебфреймворк FastAPI	23
2.2.2 Вебфреймворк Flask.....	24
2.2.3 Вебфреймворк Django.....	24
2.2.4 Загальне порівняння вебфреймворків.....	25
2.2.5 Обґрунтування вибору вебфреймворку.....	25
2.3 Аналіз систем керування базами даних	26
2.3.1 Векторна база даних ChromaDB.....	26
2.3.2 Хмарний сервіс Pinecone	27

2.3.3 База даних Milvus.....	27
2.3.4 Загальне порівняння векторних баз даних	27
2.3.5 Обґрунтування вибору бази даних.....	28
2.4 Аналіз великих мовних моделей та систем їх розгортання	29
2.4.1 Хмарні мовні моделі	29
2.4.2 Локальне розгортання через Hugging Face.....	30
2.4.3 Локальний сервер інференсу Ollama.....	30
2.4.4 Порівняльний аналіз систем розгортання мовних моделей	31
2.4.5 Обґрунтування вибору системи розгортання.....	31
2.5 Вибір технологій розробки клієнтської частини.....	32
2.5.1 Відокремлений вебзастосунок.....	32
2.5.2 Вбудований JavaScript-модуль	33
2.5.3 Нативний плагін для системи керування контентом	33
2.5.4 Загальне порівняння технологій клієнтської частини.....	34
2.5.5 Обґрунтування вибору технології.....	34
2.6 Висновки за розділом	35
3 Опис програми	37
3.1 Опис архітектури системи	37
3.1.1 Клієнт-серверна архітектура системи	37
3.2 Проєктування серверної частини.....	39
3.2.1 Алгоритм підготовки та індексації даних.....	39
3.2.2 Алгоритм гібридного пошуку та генерації відповіді	41
3.2.3 Алгоритм семантичного кешування запитів	43
3.2.4 Забезпечення безпеки та фільтрація запитів	44
3.3 Проєктування бази даних	45
3.3.1 Проєктування векторного сховища ChromaDB	46
3.3.2 Проєктування сховища швидкого доступу Redis	47
3.4 Об'єктно-орієнтоване проєктування системи	47
3.5 Проєктування клієнтської частини	48
3.5.1 Проєктування інтерфейсу користувацького віджета.....	48

	10
3.5.2 Проєктування інтерфейсу панелі керування адміністратора	49
3.6 Можливості масштабування системи.....	50
3.7 Висновки за розділом	51
4 Експлуатація, тестування та експериментальне дослідження програми.....	52
4.1 Призначення та умови застосування програми.....	52
4.2 Системні вимоги та умови експлуатації	53
4.2.1 Апаратні та програмні вимоги	53
4.2.2 Умови експлуатації	54
4.3 Інтерфейс клієнтської частини.....	54
4.3.1 Інтеграція віджета та стартовий стан	54
4.3.2 Вікно діалогу та основні елементи керування	55
4.3.3 Режим очікування та результат генерації	56
4.3.4 Адаптивність для мобільних пристроїв	58
4.4 Інтерфейс панелі адміністрування	59
4.4.1 Дашборд та моніторинг інфраструктури	59
4.4.2 Інструменти синхронізації бази знань	60
4.5 Тестування та обробка виняткових ситуацій.....	61
4.5.1 Функціональне тестування користувацького інтерфейсу.....	62
4.5.2 Тестування бекенду та RAG-конвеєра	63
4.5.3 Навантажувальне тестування та робота системи кешування	64
4.5.4 Тестування безпеки та обробки нестандартних запитів	65
4.6 Висновки за розділом.....	66
Висновки	68
Перелік джерел посилання	70
Додаток А Технічне завдання	73
Додаток Б Текст програми	78
Додаток В Слайди презентації.....	89

ПЕРЕЛІК СКОРОЧЕНЬ ТА УМОВНИХ ПОЗНАК

API	– Application Programming Interface;
CMS	– Content Management System;
FIFO	– First In, First Out;
GPU	– Graphics Processing Unit;
HTML	– HyperText Markup Language;
HTTP	– HyperText Transfer Protocol;
JS	– JavaScript;
LLM	– Large Language Model;
LRU	– Least Recently Used;
MD5	– Message Digest 5;
ORM	– Object-Relational Mapping;
RAG	– Retrieval-Augmented Generation;
RAM	– Random Access Memory;
REST	– Representational State Transfer;
SSE	– Server-Sent Events;
UI	– User Interface;
VRAM	– Video Random Access Memory;
БД	– база даних;
ОС	– операційна система;
ПЗ	– програмне забезпечення;
ПК	– персональний комп'ютер;
ШІ	– штучний інтелект.

ВСТУП

Сьогодні корпоративні та освітні вебресурси стикаються зі стрімким зростанням обсягів інформації. Впровадження інтелектуальних діалогових систем допомагає автоматизувати консультування та обробку запитів, підвищуючи загальну ефективність роботи вебпорталів.

В умовах постійного збільшення кількості документів та нормативних баз користувачі потребують зручних інструментів для швидкого та точного пошуку релевантної інформації, оскільки традиційні системи пошуку за ключовими словами не завжди враховують контекст запиту.

У цій дипломній кваліфікаційній роботі розглядається процес розроблення діалогової системи, яка дозволяє автоматично збирати, індексувати та здійснювати інтелектуальний пошук по вебсторінках і документах для надання точних відповідей. Система реалізована із застосуванням мови програмування Python, асинхронного фреймворку FastAPI, векторної бази даних ChromaDB, системи локального запуску великої мовної моделі (англ. Large Language Model, LLM) Ollama та сучасних алгоритмів гібридного пошуку.

Актуальність даного дослідження зумовлена високою потребою організацій в автоматизації інформаційно-консультаційних процесів, підвищенні швидкості обробки запитів користувачів відповідно до наповнення ресурсу.

Метою роботи є дослідження програмного забезпечення інтелектуальної діалогової системи для підвищення інформованості, швидкості та точності автоматизованого консультування користувачів вебресурсів.

Для досягнення цієї мети у роботі розглядаються сучасні методи обробки природної мови, аналізуються алгоритми гібридного пошуку, впроваджується багаторівнева система безпеки для захисту від вразливостей та створюється відповідне автономне серверне рішення.

1 АНАЛІЗ ПРОБЛЕМИ ТА ПОСТАНОВКА ЗАВДАНЬ ДОСЛІДЖЕННЯ

1.1 Огляд предметної області

Вебресурси закладів освіти та корпоративного сектору є важливими елементами для забезпечення доступу до актуальної інформації та послуг. Основними функціями таких порталів є надання довідкових даних, нормативних документів та підтримка відвідувачів. Зі стрімким розвитком цифрового простору та збільшенням кількості електронних публікацій, обсяг даних, з якими стикаються користувачі, постійно зростає. Це спричиняє необхідність оптимізації процесів пошуку інформації, навігації по сторінках та надання швидких консультацій.

Забезпечити якісне обслуговування користувачів неможливе без використання автоматизованих рішень. Тому важливим напрямом розвитку є цифровізація та створення спеціалізованих діалогових систем на базі технології генерації, доповненої пошуком (англ. Retrieval-Augmented Generation, RAG), які допомагають ефективно обробляти природномовні запити, здійснювати точний гібридний пошук по локальній базі знань та забезпечувати користувачів достовірною інформацією [1].

1.2 Актуальність проблеми

Великі інформаційні системи, зокрема корпоративні та освітні портали, накопичують величезну кількість інформації. Через постійне зростання обсягу документів користувачам стає дедалі складніше знаходити потрібні дані. Звичайний пошук за ключовими словами часто не дає результату, оскільки не розуміють контексту запиту, змушуючи людину вручну переглядати десятки сторінок у пошуках однієї відповіді. Вирішенням цієї проблеми є впровадження інтелектуальної діалогової системи на базі RAG. Вона дозволяє автоматизувати пошук, генеруючи відповіді виключно на основі завантаженої бази знань (що виключає

галюцинації мовної моделі). Поєднання гібридного пошуку та локальних нейромереж забезпечує користувача швидкою і точною інформацією, зберігаючи при цьому повну конфіденційність даних.

1.3 Огляд аналогів

Сучасний ринок програмного забезпечення пропонує широкий вибір інформаційно-консультаційних платформ для вебпорталів. Далі розглянуто три найпоширеніші підходи до автоматизації взаємодії з користувачами. Зважаючи на специфіку кожної архітектури, доцільно провести детальний аналіз їхніх сильних і слабких сторін.

1.3.1 Google Dialogflow

Google Dialogflow – хмарна платформа від компанії Google для створення розмовних інтерфейсів та чат-ботів на основі алгоритмів розпізнавання намірів. Вона широко використовується для інтеграції віртуальних асистентів у вебресурси для базового автоматизованого консультування.

Перевагами є:

- висока стабільність роботи та жорсткий контроль логіки діалогу;
- широкі можливості інтеграції з популярними месенджерами та вебсайтами;
- наявність зручного візуального інтерфейсу для проєктування гілок розмови.

Недоліки:

- базується на сценарному підході, що вимагає від адміністраторів ручного прописування всіх можливих варіантів запитань та відповідей;
- система не здатна автоматично індексувати та генерувати відповіді на основі багатосторінкових неструктурованих документів;

— неможливість прямого використання наявних баз документів без попередньої ручної розмітки даних [2].

Інтерфейс платформи Google Dialogflow зображено на рис. 1.1 [3].




Рисунок 1.1 – Інтерфейс Google Dialogflow [3]

1.3.2 Chatbase

Chatbase — хмарна платформа для створення користувацьких діалогових систем на основі LLM, яка дозволяє навчати систему на власних даних. Вона орієнтована на швидку інтеграцію інтелектуального чат-бота в існуючі сайти.

Перевагами є:

- автоматичний збір контенту з вказаних вебпосилань та документів для швидкого формування бази знань;
- швидка інтеграція на сайт без необхідності написання програмного коду;
- наявність вбудованої панелі для перегляду історії діалогів.

Недоліки:

- повна залежність від сторонніх хмарних систем, що створює ризики витоку інформації та порушує конфіденційність;

- відсутність доступу до вихідного коду, що унеможливлює налаштування алгоритмів гібридного пошуку під специфіку бази даних;
- висока вартість підписки, яка зростає пропорційно кількості запитів та обсягу завантажених документів [4].

Інтерфейс платформи Chatbase зображено на рис. 1.2 [5].




Рисунок 1.2 – Інтерфейс Chatbase [5]

1.3.3 SiteGPT

SiteGPT – хмарний сервіс для швидкого створення інтелектуальних чат-ботів на основі контенту вебсайтів. Він автоматично сканує всі сторінки за вказаним посиланням, формує базу знань та надає відповіді відвідувачам ресурсу у форматі діалогу.

Перевагами є:

- миттєве розгортання через вказування посилання на сайт;
- зручний віджет для інтеграції на будь-яку вебсторінку за допомогою додавання одного рядка коду;
- регулярне автоматичне пересканування сайту для підтримки актуальності інформації.

Недоліки:

- повна залежність від зовнішньої хмарної інфраструктури (використовується програмний інтерфейс застосунку (англ. Application Programming Interface, API) популярних моделей), що робить неможливою локальну роботу;
- обмежені можливості змін алгоритмів пошуку та відсутність доступу до вихідного коду для налаштування особистих фільтрів безпеки;
- ціна базується на кількості повідомлень, що призводить до значних фінансових витрат при високій відвідуваності ресурсу [6].

Інтерфейс платформи SiteGPT зображено на рис. 1.3 [7].




Рисунок 1.3 – Інтерфейс SiteGPT [7]

1.3.4 Загальне порівняння аналогів

Для об'єктивного оцінювання та вибору оптимального рішення необхідно зіставити їхні базові параметри. Порівняльний аналіз ключових характеристик та функціональних можливостей розглянутих платформ наведено в таблиці 1.1.

Таблиця 1.1 – Порівняння аналогів

Критерій	Google Dialogflow	Chatbase	SiteGPT
Архітектурний підхід	Сценарний	Генеративний	Генеративний
Вартість	Динамічна	від \$19 на місяць	від \$49 на місяць
Метод наповнення бази знань	Ручний	Напівавтоматичний	Автоматичний
Гнучкість алгоритмів пошуку	Висока	Низька	Низька
Тип розгортання	Хмарний	Хмарний	Хмарний
Легкість впровадження	Середня	Висока	Висока
Рівень конфіденційності даних	Низький	Низький	Низький

1.4 Висновки за розділом

Аналіз предметної області показав головну проблему існуючих платформ, яка полягає у пошуку постійного компромісу між зручністю та безпекою. Google Dialogflow ефективний для жорстких сценарних ботів, але вимагає ручного прописування кожного кроку. Chatbase та SiteGPT вирішують проблему роботи з масивами документів завдяки генеративному підходу, проте мають критичний недолік для корпоративного сектору – низький рівень конфіденційності. Оскільки ці платформи є хмарними, усі

внутрішні дані передаються на сторонні сервери. До того ж вони прив'язують організацію до постійних витрат на підписку або оплату за токени.

Архітектура розробленої системи побудована інакше. Обробка природномовних запитів та пошук по документах відбуваються виключно на базі локальних LLM, що дозволяє корпоративній інформації залишатися в межах локальної мережі. Також відсутня прив'язка до платних хмарних API. Таке рішення дає змогу безкоштовно масштабувати систему та вільно змінювати її логіку під специфіку конкретної організації.

2 МАТЕРІАЛИ І МЕТОДИ

2.1 Аналіз мов програмування

Для програмної реалізації серверної частини необхідно обрати мову програмування, яка забезпечуватиме високу швидкість розробки, нативну підтримку концепції RAG та легку інтеграцію з локальними LLM. З огляду на сучасні індустріальні стандарти розробки серверного ПЗ (програмного забезпечення) у сфері штучного інтелекту (ШІ), у якості основних альтернатив було розглянуто мови Python, Go та Java.

2.1.1 Мова програмування Python

Python – це потужна високорівнева інтерпретована мова програмування загального призначення, яка забезпечує легку інтеграцію з низькорівневими бібліотеками, що зробило її провідним вибором для наукових обчислень та систем ШІ [8].

Основними перевагами є:

- найбагатша екосистема для розробки алгоритмів машинного навчання за рахунок наявності спеціалізованих фреймворків [9];
- нативна підтримка векторних баз даних;
- висока швидкість створення програмного коду;
- підтримка асинхронності для ефективної потокової генерації відповідей LLM без блокування системи [10].

2.1.2 Мова програмування Go

Go – це статично типізована компільована мова програмування, розроблена компанією Google, що алгоритмічно орієнтована на створення високонавантажених та масштабованих мікросервісів [11].

Основними перевагами є:

- надзвичайно висока продуктивність завдяки компіляції безпосередньо в машинний код та відсутності проміжних віртуальних машин;
- обробка тисяч паралельних з'єднань із мінімальним споживанням оперативної пам'яті (англ. Random Access Memory, RAM);
- зручність розгортання через компіляцію програми в єдиний виконуваний файл без зовнішніх залежностей;
- надійність інфраструктури, що підтверджується її використанням у ядрі популярного ШІ-сервера Ollama [12].

2.1.3 Мова програмування Java

Java – це суворо типізована об'єктно-орієнтована мова програмування, яка традиційно вважається галузевим стандартом для розробки надійних систем корпоративного рівня [13].

Основними перевагами є:

- стабільна швидкість виконання, що забезпечується багаторічною оптимізацією віртуальної машини Java;
- масштабованість та надійність архітектури;
- наявність корпоративних інструментів ШІ, що активно розвиваються та дозволяють інтегрувати LLM в існуючі бізнес-процеси [14];
- повна апаратна незалежність, яка гарантує легке перенесення серверної частини між різними операційними системами (ОС) без необхідності перекомпіляції вихідного коду.

2.1.4 Загальне порівняння мов програмування

Кожне із зазначених рішень має свої інструментальні переваги та обмеження. В таблиці 2.1 наведено порівняння розглянутих мов програмування для власної розробки.

Таблиця 2.1 – Порівняння мов програмування

Критерій	Python	Go	Java
Поріг входу	Низький	Середній	Високий
Зрілість екосистеми для ІІІ	Висока	Низька	Середня
Продуктивність	Середня	Висока	Висока
Робота з багатопотоковістю	Обмежена	Висока	Висока
Підтримка векторних баз даних	Повна	Часткова	Повна
Якість документації	Висока	Середня	Висока
Спільнота	Дуже велика	Велика, але менш активна	Середня

2.1.5 Обґрунтування вибору мови програмування

За результатами порівняльного аналізу для розробки серверної частини обрано Python. Головний аргумент – найвища зрілість екосистеми ІІІ. Як індустріальний стандарт, Python надає готові абстракції для RAG-

архітектури, а велика спільнота та якісна документація суттєво пришвидшують розробку та інтеграцію з векторними базами даних.

Хоча у продуктивності та багатопотоковості Python поступається компільованим мовам, цей недолік повністю нівелюється. У системі Python відіграє роль координатора логіки, тоді як ресурсомісткі завдання делегуються оптимізованим низькорівневим бібліотекам і локальному ШІ-серверу. Такий розподіл забезпечує високу швидкодію системи за максимальної швидкості написання коду.

2.2 Аналіз серверних вебфреймворків

Для розробки серверного API потрібен фреймворк, здатний ефективно працювати з векторною базою, потоковою генерацією тексту та високим мережевим навантаженням. Для реалізації серверної частини системи як основні альтернативи розглянуто фреймворки FastAPI, Flask та Django.

2.2.1 Вебфреймворк FastAPI

FastAPI – це сучасний високопродуктивний вебфреймворк для створення програмних інтерфейсів, який від самого початку проєктувався на базі стандартів асинхронного програмування та підказок типів Python [15].

Основними перевагами є:

- нативна підтримка асинхронного програмування для паралельної обробки запитів і потокової генерації відповідей LLM;
- автогенерація інтерактивної документації, що значно спрощує тестування API та його інтеграцію з фронтендом;
- висока швидкість обробки запитів завдяки ядру Starlette, яка наближається до показників компільованих мов;
- надійна валідація вхідних даних за допомогою бібліотеки Pydantic.

2.2.2 Вебфреймворк Flask

Flask – це класичний мікрофреймворк із мінімалістичним ядром та вільною структурою проєкту [16].

Основними перевагами є:

- абсолютна гнучкість архітектури, що дозволяє підключати лише необхідні інструменти без зайвого функціоналу;
- низький поріг входження та простота створення прототипів;
- велика екосистема сторонніх розширень для додавання інструментів маршрутизації, безпеки чи інтеграції з базами даних (БД);
- мінімальне споживання RAM у базовій комплектації;
- наявність вичерпної документації та великої спільноти розробників, що значно прискорює пошук рішень для типових задач.

2.2.3 Вебфреймворк Django

Django – це високорівневий вебфреймворк з монолітною архітектурою, який дотримується принципу включення всіх необхідних інструментів у базову конфігурацію [17].

Основними перевагами є:

- автоматично згенерована панель адміністратора для зручного керування контентом;
- потужна вбудована система об'єктно-реляційного відображення (англ. Object-Relational Mapping, ORM) для безпечної роботи з реляційними БД;
- високий базовий рівень безпеки із вбудованим захистом від поширених вебуразливостей;
- строга структура проєкту, яка ідеально підходить для розробки складних корпоративних порталів.

– наявність повноцінного вбудованого інструментарію для вирішення типових завдань без підключення сторонніх бібліотек;

2.2.4 Загальне порівняння вебфреймворків

В таблиці 2.2 наведено порівняння розглянутих вебфреймворків.

Таблиця 2.2 – Порівняння серверних вебфреймворків

Критерій	FastAPI	Flask	Django
Архітектурний підхід	Мікросервісний	Мікросервісний	Монолітний
Підтримка асинхронності	Повна нативна	Часткова	Часткова
Продуктивність обробки	Дуже висока	Середня	Середня
Складність освоєння	Середня	Низька	Висока
Наявність вбудованої ORM	Відсутня	Відсутня	Вбудована

2.2.5 Обґрунтування вибору вебфреймворку

На основі результатів порівняльного аналізу, наведених у таблиці 2.2, для реалізації програмного інтерфейсу серверної частини інтелектуальної діалогової системи було обрано вебфреймворк FastAPI.

Головним аргументом на користь цього вибору є нативна підтримка асинхронного програмування. Специфіка роботи технології RAG вимагає постійної взаємодії з LLM, генерація відповідей яких може займати певний час. Вбудована асинхронність FastAPI дозволяє серверу не простоювати в очікуванні відповіді від нейромережі, а паралельно обробляти запити інших

користувачів, що неможливо ефективно реалізувати у синхронних фреймворках на кшталт Flask або Django.

2.3 Аналіз систем керування базами даних

Для повноцінного функціонування механізму RAG класичні реляційні або документо-орієнтовані БД є неефективними. Система потребує зберігання інформації у вигляді векторних вкладень, що дозволяє обчислювати семантичну відстань між запитом користувача та документами. Для вирішення цього завдання було проведено аналіз сучасних векторних баз даних, серед яких найбільш релевантними є ChromaDB, Pinecone та Milvus.

2.3.1 Векторна база даних ChromaDB

ChromaDB – це спеціалізована векторна БД з відкритим вихідним кодом, яка розроблена спеціально для створення застосунків на LLM [18].

Основними перевагами є:

- автономне локальне розгортання, що гарантує повну конфіденційність корпоративних даних;
- нативна інтеграція з Python та сучасними фреймворками для швидкого підключення до бекенду;
- гнучкість зберігання даних, що дозволяє працювати як у режимі RAM для швидкого тестування, так і зберігати дані на локальному накопичувачі;
- відсутність складного налаштування інфраструктури, що оптимально для розробки мікросервісів;
- вбудована підтримка різноманітних моделей векторного представлення тексту, що дозволяє автоматизувати векторизацію тексту безпосередньо під час запису в БД.

2.3.2 Хмарний сервіс Pinecone

Pinecone – це популярне рішення для векторного пошуку, що надається виключно за моделлю програмного забезпечення як послуги [19].

Основними перевагами є:

- висока швидкість пошуку завдяки оптимізованій хмарній інфраструктурі;
- автоматичне масштабування для обробки мільйонів векторів без адміністрування;
- зручна графічна панель керування індексами та моніторингу БД;
- нульове навантаження на локальний сервер (всі обчислення відбуваються у хмарі).

2.3.3 База даних Milvus

Milvus – це високопродуктивна векторна база даних корпоративного рівня з відкритим вихідним кодом [20].

Основними перевагами є:

- стабільна обробка мільярдів записів;
- підтримка гібридного пошуку (семантичний пошук та класична фільтрація за метаданими);
- висока відмовостійкість завдяки мікросервісній архітектурі;
- наявність розширених індексних алгоритмів для оптимізації швидкості пошуку в надвеликих масивах даних.

2.3.4 Загальне порівняння векторних баз даних

Для обґрунтування вибору оптимального інструменту індексації великих даних необхідно систематизувати їхні параметри. В таблиці 2.3 наведено порівняння розглянутих систем керування векторними базами.

Таблиця 2.3 – Порівняння векторних баз даних

Критерій	ChromaDB	Pinecone	Milvus
Тип розгортання	Локальне	Хмарне	Локальне
Рівень конфіденційності даних	Високий	Низький	Високий
Складність налаштування	Низька	Низька	Висока
Вимоги до апаратних ресурсів	Низькі	Відсутні	Високі
Масштабованість	Вертикальна	Горизонтальна	Горизонтальна
Захист даних	Повний контроль	Дані на серверах провайдера	Повний контроль
Вартість використання	Безкоштовно	від \$50 на місяць	Безкоштовно (але високі витрати на сервери)

2.3.5 Обґрунтування вибору бази даних

На основі результатів порівняльного аналізу, наведених у таблиці 2.3, для зберігання інформації та забезпечення механізму семантичного пошуку було обрано векторну базу даних ChromaDB.

Головним аргументом на користь цього вибору є можливість повністю автономного локального розгортання БД. Збереження конфіденційності даних клієнтів та внутрішньої документації є критичним пріоритетом. Використання хмарних рішень (на зразок Pinecone) вимагає передачі даних на сторонні сервери, що створює безпекові ризики та додаткові фінансові витрати на підписку. Водночас розгортання корпоративної системи Milvus вимагає значних апаратних потужностей та складної оркестрації, що є економічно та технічно недоцільним для проєкту такого масштабу. Спільне

розгортання ChromaDB та бекенду на FastAPI в єдиному локальному середовищі гарантує безпечний і швидкий семантичний пошук без залучення сторонніх сервісів.

2.4 Аналіз великих мовних моделей та систем їх розгортання

Основою технології генерації з доповненим пошуком є LLM, яка відповідає за обробку наданого контексту та формування зв'язної природномовної відповіді. Для реалізації цього компонента необхідно не лише обрати саму модель, але й визначити архітектурний підхід до її розгортання. У якості основних альтернатив було розглянуто хмарні API (наприкладі OpenAI), класичне локальне розгортання через екосистему Hugging Face та спеціалізований локальний сервер Ollama.

2.4.1 Хмарні мовні моделі

Використання комерційних закритих моделей через API, таких як GPT-3.5 або GPT-4 від компанії OpenAI, є найпопулярнішим підходом у прототипуванні [21].

Основними перевагами є:

- найвища якість генерації тексту та розуміння складного контексту без необхідності самостійного налаштування моделі;
- нульові вимоги до апаратного забезпечення сервера розробника, оскільки всі обчислення відбуваються у хмарі провайдера;
- висока швидкість інтеграції завдяки стабільному та добре задокументованому API.

Серед головних недоліків: залежність від стороннього сервісу, оплата за токени (що фінансово невигідно при великих навантаженнях) та ризики витоку даних.

2.4.2 Локальне розгортання через Hugging Face

Hugging Face – це провідна платформа та найбільший у світі хаб відкритих LLM, який надає розробникам можливість завантажувати ваги моделей (наприклад, Llama 3 від Meta [22]) та запускати їх безпосередньо у Python-кодi.

Основними перевагами є:

- повний контроль над процесом інференсу моделі та параметрами генерації;
- високий рівень безпеки даних, оскільки система працює повністю автономно без підключення до мережі Інтернет.

Проте цей підхід має суттєві недоліки: необхідність писати низькорівневий код для управління RAM та критично високі вимоги до VRAM через відсутність базової оптимізації моделей.

2.4.3 Локальний сервер інференсу Ollama

Ollama – це сучасний інструмент з відкритим вихідним кодом, який дозволяє швидко розгортати та запускати LLM локально у вигляді окремого фонового сервісу [23].

Основними перевагами є:

- використання технології квантування (зменшення розрядності ваг моделі), що дозволяє запускати потужні моделі на споживчому обладнанні з обмеженим обсягом RAM та VRAM;
- надання готового API на базі архітектури передачі репрезентативного стану (англ. Representational State Transfer, REST), яке повністю сумісне з форматом запитів OpenAI, що дозволяє використовувати стандартні бібліотеки без переписування коду;
- максимальна простота розгортання. Завантаження та запуск моделі виконується однією консольною командою;

– повна конфіденційність даних клієнтів за рахунок ізольованої роботи на локальному сервері.

2.4.4 Порівняльний аналіз систем розгортання мовних моделей

Вибір конкретного методу зв’язування ШІ-компонентів із вебплатформою визначає загальну швидкість відгуку та масштабованість проєкту. У таблиці 2.4 наведено порівняння розглянутих інструментів та підходів до інтеграції мовних.

Таблиця 2.4 – Порівняння систем розгортання LLM

Критерій	OpenAI API	Hugging Face	Ollama
Тип розгортання	Хмарне	Локальне	Локальне
Конфіденційність даних	Низька	Висока	Висока
Вартість експлуатації	Плата за кожен запит	Безкоштовно	Безкоштовно
Вимоги до обладнання	Відсутні	Надвисокі	Середні
Складність інтеграції	Низька	Висока	Низька

2.4.5 Обґрунтування вибору системи розгортання

На основі результатів порівняльного аналізу, наведених у таблиці 2.4, для реалізації інтелектуального ядра діалогової системи було обрано локальний сервер інференсу Ollama у зв'язці з відкритою мовною моделлю (наприклад, Llama 3).

Головним аргументом на користь цього вибору є поєднання високої безпеки даних та нульової вартості експлуатації при збереженні простоти розробки. Класичний запуск моделей через Hugging Face потребує дорогого

обладнання. Ollama ефективно вирішує обидві проблеми: завдяки алгоритмам квантування вона запускає потужні моделі на стандартному апаратному забезпеченні, а її уніфікований API безшовно інтегрується з сервером на FastAPI.

2.5 Вибір технологій розробки клієнтської частини

Для взаємодії користувача з інтелектуальною діалоговою системою необхідна розробка клієнтської частини, яка прийматиме запити та відображатиме згенеровані мовною моделлю відповіді. Інтерфейс користувача (англ. User Interface, UI) розроблюваного ПЗ має бути інтегрований у вже існуючу вебінфраструктуру підприємства. Для вирішення цього завдання було розглянуто три архітектурні підходи: створення відокремленого вебзастосунку, інтеграція через вбудовуваний модуль JavaScript (JS) та розробка нативного плагіна для системи керування контентом (англ. Content Management System, CMS).

2.5.1 Відокремлений вебзастосунок

Цей підхід передбачає розробку клієнтського застосунку з використанням сучасних JS-фреймворків (наприклад, React, Vue або Angular), який розгортається незалежно від основного корпоративного ресурсу [24].

Основними перевагами цього підходу є:

- максимальна гнучкість у розробці UI;
- висока швидкість роботи завдяки використанню механізмів віртуальної об'єктної моделі документа (англ. Document Object Model, DOM);
- незалежність компіляції та розгортання від основної інфраструктури вебпорталу.

2.5.2 Вбудований JavaScript-модуль

Цей архітектурний підхід передбачає розробку ізольованого клієнтського скрипта, який підключається до вихідного коду сторінок існуючого сайту за допомогою тегу мови гіпертекстової розмітки (англ. HyperText Markup Language, HTML), а саме тегу `<script>`. Інтерфейс діалогового вікна рендериться динамічно на стороні клієнта з використанням технології Web Components та тіньового дерева для надійної інкапсуляції стилів [25].

Основними перевагами є абсолютна кросплатформність та централізоване оновлення логіки на сервері. Проте метод має суттєві недоліки в контексті розгортання продукту для малого бізнесу. Він вимагає ручного втручання адміністратора у вихідні шаблони сайту, налаштування політик міждомених запитів та підтримки розробником окремої інфраструктури для роздачі статичних файлів віджета.

2.5.3 Нативний плагін для системи керування контентом

Цей архітектурний підхід передбачає створення модуля (плагіна), який встановлюється безпосередньо в CMS існуючого сайту та виводить віджет за допомогою базових вебтехнологій безпосередньо в DOM-дерево сторінки. У якості бази для розробки плагіну було обрано WordPress [26].

Основними перевагами є:

- простота розгортання без залучення програмістів;
- можливість прямого доступу до внутрішнього API та БД користувачів сайту для подальшої персоналізації системи;
- відсутність вимог до сторонньої інфраструктури, оскільки клієнтський код зберігається та виконується на існуючому сервері;
- централізоване керування, завдяки якому всі параметри системи можна здійснювати через адміністративну панель CMS.

2.5.4 Загальне порівняння технологій клієнтської частини

У таблиці 2.5 наведено порівняння розглянутих підходів до інтеграції UI.

Таблиця 2.5 – Порівняння технологій інтеграції клієнтської частини

Критерій	Окремий застосунок	JS-модуль	Нативний плагін
Зусилля на розгортання замовником	Високі	Середні	Низькі
Рівень універсальності рішення	Середній	Максимальний	Обмежений
Додаткова інфраструктура	Окремий хостинг	Зовнішній файловий сервер	Не потребує
Можливості інтеграції з сесією користувача	Обмежені	Середні	Повні
Вимоги до технічних навичок адміністрування	Високі	Середні	Низькі

2.5.5 Обґрунтування вибору технології

На основі результатів порівняльного аналізу для реалізації клієнтської частини інтелектуальної діалогової системи було обрано архітектуру нативного плагіна для системи керування контентом.

Головним аргументом є зручність розгортання та адміністрування для кінцевого замовника. Оскільки значна частина корпоративних вебресурсів працює на базі готових CMS, створення нативного плагіна дозволяє встановити клієнтський віджет без втручання у вихідний код і залучення сторонніх розробників. Хоча ізольовані JS-модулі є більш універсальними, вони створюють зайву системну складність, оскільки вимагають додаткової інфраструктури для хостингу файлів. Натомість плагін глибоко інтегрується з внутрішньою екосистемою сайту (що в перспективі дозволяє реалізувати авторизацію користувачів) та використовує стандартні асинхронні запити для зв'язку з бекендом на FastAPI. Для корпоративних систем це найбільш економічно та технічно виправдане архітектурне рішення.

2.6 Висновки за розділом

У цьому розділі було проведено комплексний аналіз технологій та обґрунтовано вибір інструментарію для розробки інтелектуальної діалогової системи для станції технічного обслуговування. Основним архітектурним підходом обрано RAG, що вирішує критичну проблему фактологічної неточності LLM і дозволяє системі формувати відповіді виключно на основі актуальної закритої документації клієнта без необхідності дороговартісного перенавчання нейромережі.

Для апаратно-програмної реалізації серверної частини в якості основи для розробки програмного інтерфейсу використано високопродуктивний асинхронний вебфреймворк FastAPI, який гарантує неблокувальну обробку запитів під час тривалої генерації відповідей мовними моделями. Збереження індексованих документів та швидкий семантичний пошук реалізовано за допомогою векторної БД ChromaDB, яка забезпечує повністю автономне локальне розгортання.

Інтелектуальне ядро системи побудовано на базі локального сервера інференсу Ollama, що усуває залежність від платних хмарних API та дозволяє

безкоштовно використовувати потужні відкриті нейромережі. Для програмної оркестрації всіх компонентів, управління пам'яттю діалогу та зв'язування векторної бази з мовною моделлю інтегровано спеціалізований фреймворк LangChain.

Для взаємодії з кінцевим користувачем обрано архітектуру нативного плагіна для CMS. Це дозволяє безшовно, швидко та без залучення програмістів розгорнути діалоговий віджет на існуючому корпоративному сайті замовника. Таке поєднання технологій робить систему автономною та економічно вигідною. Це дозволяє реалізувати надійний захист інформації та спростити подальше адміністрування платформи.

3 ОПИС ПРОГРАМИ

3.1 Опис архітектури системи

Система працює на багаторівневій клієнт-серверній архітектурі, яка є одним із найпоширеніших типів багаторівневих архітектур, що використовуються сучасними вебзастосунками. Клієнтська частина системи розроблена як плагін для CMS WordPress.

Сервер побудовано з використанням асинхронного фреймворку FastAPI та має логіку обробки всіх даних. Сервер отримує запити клієнтів через API, шукає в ChromaDB відповідну інформацію, яка повертається до локально розгорнутої LLM Ollama для створення відповіді. На рисунку 3.1 зображено компонентну діаграму системи.




Рисунок 3.1 – Компонентна діаграма системи

3.1.1 Клієнт-серверна архітектура системи

Клієнт-серверна архітектура – це модель розподіленої системи, де обробка завдань розділена між постачальниками послуг (серверами) та тими, хто ці послуги запитує (клієнтами). У такій структурі кожен учасник має

свою чітку роль: клієнт відповідає за взаємодію з людиною, збір вхідних даних та відображення результату (презентаційний рівень), а сервер бере на себе основну роботу по зберіганню великих масивів інформації, виконання складної бізнес-логіки та контролю безпеки [27].

Спілкування між частинами системи відбувається через комп'ютерну мережу за циклом «запит-відповідь». Клієнт завжди виступає ініціатором – він формує та надсилає запит, тоді як сервер постійно перебуває в режимі очікування. Отримавши сигнал, сервер проводить його валідацію, виконує необхідні обчислення або звертається до БД і повертає результат у строго визначеному форматі [27]. Це дозволяє зосередити всю критичну логіку в одному центрі, що значно спрощує підтримку системи: будь-які зміни на сервері відразу стають доступними для всіх користувачів без необхідності оновлення клієнтського ПЗ.

Обираючи таку модель, система реально отримує кілька важливих переваг. Даними управляти простіше – все зберігається в одному місці. Також ця архітектура дає змогу збільшувати потужності сервера незалежно від клієнтів, що дуже зручно для систем з великим навантаженням [27].

Схему клієнт-серверної архітектури наведено на рисунку 3.2.




Рисунок 3.2 – Діаграма клієнт-серверної архітектури

3.2 Проєктування серверної частини

Серверна частина використовує асинхронний програмний інтерфейс, який діє як зв'язок між базою знань та кінцевим користувачем. Архітектура повністю автоматизує роботу з даними: система самостійно перевіряє кеш, шукає інформацію в базі знань та генерує фінальну відповідь.

3.2.1 Алгоритм підготовки та індексації даних

Інтелектуальна система пошуку використовує для виконання асинхронний конвеєр обробки даних. Збір інформації реалізовано у вигляді двох процесів, що працюють паралельно. У першому процесі вебсторінки сайту завантажуються за допомогою інструменту Playwright. Він витягує з них лише потенційно корисний текст, відкидаючи зайвий HTML-код, меню навігації та скрипти. У другому процесі система напряму читає завантажені документи за допомогою спеціальних бібліотек для парсингу. Щоб ці задачі не гальмували роботу основного сервера, вони відправляються у фонову чергу. Алгоритм підготовки та індексації даних наведено на блок-схемі на рисунку 3.3.

Наступним етапом є векторизація підготовлених фрагментів тексту. Через використання синонімів чи помилок у словах, класичний пошук за точними збігами слів є неефективним, тому для складних користувацьких запитів у системі реалізовано механізм семантичного пошуку. Для цього кожен текстовий фрагмент передається до локальної моделі, яка перетворює текст на багатовимірні числові вектори (зокрема, `nomis-embed-text`). Цей вектор математично описує сенс фрагмента, що дозволяє системі знаходити відповіді за контекстом.

Після успішної генерації векторних представлень система формує пакет даних, який включає сам вектор, оригінальний текстовий фрагмент та

набір базових метаданих (джерело, категорія контенту), і передає його для збереження до векторної бази.




Рисунок 3.3 – Алгоритм підготовки бази даних

Наступним етапом є векторизація підготовлених фрагментів тексту. Через використання синонімів чи помилок у словах, класичний пошук за точними збігами слів є неефективним, тому для складних користувацьких запитів у системі реалізовано механізм семантичного пошуку. Для цього кожен текстовий фрагмент передається до локальної моделі, яка перетворює текст на багатовимірні числові вектори (зокрема, `nomis-embed-text`). Цей вектор математично описує сенс фрагмента, що дозволяє системі знаходити відповіді за контекстом.

Після успішної генерації векторних представлень система формує пакет даних, який включає сам вектор, оригінальний текстовий фрагмент та набір базових метаданих (джерело, категорія контенту), і передає його для збереження до векторної бази.

3.2.2 Алгоритм гібридного пошуку та генерації відповіді

Основою ядра розробки є архітектура RAG, яка дозволяє мовній моделі формувати відповіді спираючись виключно на локальну базу знань підприємства. У даній роботі було розглянуто сайт університету у якості бази знань. Процес обслуговування користувачького запиту починається з його отримання через UI чат-віджету.

Для забезпечення максимальної релевантності знайденої інформації в системі реалізовано алгоритм гібридного пошуку. Після надходження запиту пошук виконується паралельно за двома напрямками.

Семантичний пошук. Запит векторизується і порівнюється з документами за смисловим значенням, дозволяючи знаходити відповіді навіть коли користувач використовує синоніми.

Лексичний пошук. Класичний пошук за точним збігом ключових слів. Цей метод критично важливий для специфічної термінології, прізвищ викладачів, номерів кабінетів та університетських аббревіатур, які векторна модель може розпізнати некоректно.

Гібридний пошук також повертатиме більше тексту, ніж звичайний пошук. Їх пряме об'єднання може перевищити ліміти контекстного вікна LLM або створити інформаційний шум. З цієї причини застосовується проміжний етап ранжування. Для цього використовується CrossEncoder (спеціалізована модель) для порівняння початкового запиту з кожним із отриманих фрагментів окремо, щоб визначити оцінку їхньої взаємної релевантності. Алгоритм просто відхиляє фрагменти, оцінка яких нижча за поріг, залишаючи найбільш правильний контекст.

На останньому кроці відфільтровані фрагменти об'єднуються у один структурований запит (промпт) до нейромережі разом із фактичним запитанням користувача та системними інструкціями щодо форматування. Сформований контекст разом із питанням користувача передається до LLM Llama 3, розгорнутої за допомогою сервера інференсу Ollama. Саме ця модель відповідає за фінальний етап архітектури RAG – генерацію грамотної та фактологічно точної відповіді на основі наданих фрагментів знань, після чого модель генерує відповідь на основі наданих фактів та повертає результат користувачу у потоковому режимі, що дозволяє відображати текст у віджеті частинами по мірі генерації, візуально зменшуючи час очікування.

Діаграма уніфікованої мови моделювання (англ. Unified Modeling Language, UML) для відображення взаємодії компонентів під час генерації відповідей зображена на рисунку 3.4.




Рисунок 3.4 – UML-діаграма послідовності обробки пошукового запиту

3.2.3 Алгоритм семантичного кешування запитів

Генерація тексту за допомогою LLM є найбільш ресурсомісткою та тривалою операцією в усьому конвеєрі обробки. Для оптимізації навантаження на апаратну частину сервера, зменшення використання VRAM та мінімізації часу очікування користувача, у системі розроблено дворівневу підсистему семантичного кешування.

На відміну від класичних механізмів кешування (наприклад, Redis Cache), які вимагають абсолютного посимвольного збігу рядків, розроблений семантичний кеш здатний ідентифікувати зміст запиту. Процес перевірки наявності готової відповіді складається з двох етапів:

- етап точного збігу. Система генерує хеш-значення вхідного текстового запиту з використанням криптографічного алгоритму (англ. Message Digest 5, MD5). Якщо ідентичний запит уже оброблявся раніше, хеші збігаються, і алгоритм миттєво повертає готову відповідь та список джерел;
- етап семантичної подібності. Якщо точного збігу не знайдено, вхідний запит перетворюється на числовий вектор. Далі алгоритм обчислює косинусну подібність між вектором поточного запиту та векторами всіх збережених раніше запитів.

Було розглянуто політики витіснення кешу, зокрема алгоритми «першим прийшов — першим вийшов» (англ. First In, First Out, FIFO) та «найменш недавно використаний» (англ. Least Recently Used, LRU). Якщо розраховане значення подібності перевищує встановлений системний поріг, запити вважаються ідентичними за змістом. Система розуміє, що користувач питає вже раніше задане запитання, навіть якщо використовувалися інші слова. У такому випадку система повертає закешовану відповідь без активації нейромережі.

Для запобігання переповненню RAM сервера, кеш використовує політику витіснення, яка автоматично видаляє найстаріші записи при досягненні ліміту.

Технічні параметри роботи підсистеми наведено в таблиці 3.1.

Таблиця 3.1 - Конфігурація алгоритму семантичного кешування

Параметр	Значення	Опис
CACHE_MAX_SIZE	2000	Ліміт пар «запит-відповідь» для балансу між споживанням RAM і швидкодією.
CACHE_SIMILARITY_THRESHOLD	0.82	Поріг семантичної подібності (0–1). Гарантує точний збіг за змістом і відсікає хибні спрацьовування.
Політика витіснення	FIFO / LRU	Автоматичне видалення найстаріших записів (за принципом FIFO) завдяки структурі OrderedDict.
Алгоритм хешування	MD5	Швидка генерація ключів для перевірки точних збігів із мінімальним навантаженням на процесор.

3.2.4 Забезпечення безпеки та фільтрація запитів

Впровадження LLM у публічні вебресурси створює специфічні вектори кібератак, найнебезпечнішим з яких є ін'єкція у інструкції та спроби зламу. Зловмисник може сформулювати запит таким чином, щоб змусити нейромережу проігнорувати системні інструкції, розкрити внутрішню архітектуру або згенерувати шкідливий програмний код.

Для захисту розробленої діалогової системи на серверному рівні реалізовано багаторівневий механізм безпеки та ізоляції контексту:

- жорстке розмежування ролей. Системні інструкції програмно відокремлені від користувацького вводу на рівні API оркестратора LangChain. Користувач не має прямого доступу до формування системного контексту, що мінімізує ризик зміни базової поведінки бота;

- лексична фільтрація. Перед ініціалізацією RAG-конвеєра вхідний текст проходить через систему регулярних виразів та тригерів безпеки. Алгоритм автоматично блокує запити, що містять спроби маніпуляції (наприклад, «ігноруй попередні інструкції», «напиши програмний код», «уяви, що ти адміністратор»), перериваючи обробку ще до запуску ресурсомістких обчислень нейромережі;
- інкапсуляція бази знань. Нейромережі надано сувору системну інструкцію формувати відповіді виключно на основі знайдених релевантних фрагментів із векторної бази ChromaDB. Якщо відповіді на запит користувача немає у відфільтрованому контексті, система примусово повертає стандартне повідомлення про відсутність інформації, повністю блокуючи генерацію тексту на сторонні теми.

3.3 Проєктування бази даних

Ефективність функціонування інтелектуальної системи консультування безпосередньо залежить від якості проєктування її інформаційного забезпечення. На відміну від традиційних інформаційних систем, де перевага надається реляційним структурам, архітектура RAG потребує спеціалізованих методів зберігання. Проєктування БД спрямоване на створення гібридного середовища, яке поєднує довгострокове зберігання векторних представлень знань у ChromaDB та високошвидкісний доступ до закешованих відповідей у Redis.

Логічну схему структур даних наведено на рисунку 3.5.




Рисунок 3.5 – Логічна схема структур даних

3.3.1 Проєктування векторного сховища ChromaDB

Отримані дані записуються до векторної бази. Щоб фінальна відповідь бота була достовірною, кожен фрагмент у базі жорстко пов'язується з набором метаданих. Ці дані зберігають інформацію про походження фрагмента, що дає змогу бекенду генерувати точні посилання на оригінальні документи у фінальній відповіді. специфікацію цих атрибутів наведено в таблиці 3.2.

Таблиця 3.2 - Специфікація метаданих документів у векторній базі

Поле метаданих	Тип даних	Опис та призначення
source	String	Посилання на сторінку або назва файлу для посилань на джерела у віджеті.
chunk_index	Integer	Порядковий номер фрагмента. Дозволяє об'єднувати сусідні блоки тексту для розширення контексту.
category	String	Тематичний тег контенту (наприклад, "news"). Слугує попереднім фільтром для прискорення пошуку.
timestamp	Float	Час індексації. Потрібен для видалення застарілих записів під час оновлення.

3.3.2 Проєктування сховища швидкого доступу Redis

Підсистема швидкого доступу на базі Redis проєктується за принципом «ключ-значення». Для забезпечення цілісності кешування ключі формуються на основі MD5-хешування запитів. Це гарантує унікальність записів та дозволяє уникати повторних обчислень мовної моделі при семантично схожих зверненнях користувачів. Структура запису в Redis включає серіалізований об'єкт відповіді, перелік джерел інформації та часову мітку для автоматичного звільнення RAM на сервері.

3.4 Об'єктно-орієнтоване проєктування системи

Для забезпечення масштабованості та легкості підтримки програмного забезпечення, архітектуру бекенд-частини системи розроблено з використанням принципів об'єктно-орієнтованого проєктування. Основна логіка розподілена між незалежними класами-сервісами, що взаємодіють через чітко визначені інтерфейси. Це дозволяє в майбутньому замінювати окремі модулі (наприклад, змінити векторну базу або модель LLM) без переписування всієї системи.

Структуру основних класів системи, їхні методи та зв'язки візуалізовано на UML-діаграмі класів (рисунок 3.6).




Рисунок 3.6 - UML-діаграма класів серверної частини системи

3.5 Проєктування клієнтської частини

Архітектура розробленої системи передбачає наявність двох відокремлених клієнтських застосунків, які взаємодіють з єдиним API бекенду. Перший застосунок – це інтегрований вебвіджет, призначений для кінцевих користувачів. Другий застосунок – це ізольована панель керування, призначена для адміністраторів системи та контент-менеджерів. Розділення клієнтської частини на два незалежні модулі підвищує рівень безпеки та дозволяє оптимізувати інтерфейси під конкретні сценарії використання.

3.5.1 Проєктування інтерфейсу користувацького віджета

Головною метою під час створення інтерфейсу користувача було забезпечення швидкого відображення відповіді. Оскільки обробка запиту займає кілька секунд, перш ніж LLM відповість на нього, використання синхронних запитів протоколу передачі гіпертексту (англ. HyperText Transfer Protocol, HTTP) викликало б візуальне зависання інтерфейсу. Для вирішення

цієї проблеми використано технологію потокової передачі даних на базі подій, надісланих сервером (англ. Server-Sent Events, SSE) [28]. На відміну від ресурсомістких WebSockets, SSE створює легкий односторонній канал зв'язку, дозволяючи серверу надсилати текстові токени в браузер по мірі їх генерації. Це дає ефект «живого введення»: фронтенд не чекає на фінальний результат, а користувач бачить перші слова майже миттєво. Після завершення генерації віджет автоматично підвантажує клікабельні посилання на першоджерела.

Візуальна частина застосунку розроблена за принципами мінімалізму. UI складається з чотирьох ключових компонентів:

- кнопка ініціалізації. Плаваючий елемент для швидкого відкриття та закриття вікна чату;
- область діалогу. Контейнер з історією сеансу, у якому запити користувача вирівняні праворуч, відповіді системи відображаються ліворуч;
- блок джерел. Динамічні інтерактивні елементи, що генеруються під відповіддю бота і дозволяють перейти до оригінального тексту;
- панель вводу. Поле для багаторядкового тексту з кнопкою відправлення. На час генерації відповіді сервером поле автоматично блокується для запобігання дублюванню запитів або відправки нових.

3.5.2 Проєктування інтерфейсу панелі керування адміністратора

Для управління базою знань, моніторингу стану системи та виконання адміністративних задач розроблено окремий вебінтерфейс на базі фреймворку Streamlit. Інтерфейс адміністратора має строгую структуру і складається з бічної панелі навігації та основної робочої області.

Клієнтська частина панелі керування розділена на логічні екрани:

- екран завантаження даних. Містить зону для зручного завантаження локальних документів та текстові поля для вводу посилань на сайт;

- екран моніторингу та аналітики. Відображає ключові метрики роботи системи у вигляді числових карток. Адміністратор може переглядати загальну кількість проіндексованих текстових фрагментів у базі ChromaDB, розмір кешу та статистику його ефективності;
- екран управління системою. Містить панель інструментів із кнопками критичних дій, таких як примусове очищення векторної БД, скидання семантичного кешу або видалення конкретних застарілих документів за їхнім ідентифікатором.

Всі критичні дії захищені модальними вікнами підтвердження для уникнення випадкового видалення бази знань.

3.6 Можливості масштабування системи

Архітектура розробленої системи від самого початку проєктувалася з урахуванням можливостей горизонтального та вертикального масштабування. Оскільки клієнтська частина та сервер є повністю відокремленими модулями, зростання трафіку на основному вебсайті не впливає на продуктивність обчислювального ядра. Завдяки асинхронній природі FastAPI, сервер здатен обробляти велику кількість паралельних запитів, а використання протоколу SSE для потокової передачі даних мінімізує витрати RAM на утримання активних з'єднань. У разі подальшого збільшення навантаження бекенд-застосунок готовий до контейнеризації та розгортання на кількох вузлах із балансувальником навантаження.

Найбільш ресурсомістким компонентом RAG-системи є генерація тексту LLM. Для оптимізації та масштабування цього процесу реалізовано два архітектурні важелі. По-перше, розгорнута підсистема семантичного кешування на базі Redis діє як амортизатор, відсікаючи типові запити та експоненційно знижуючи навантаження на GPU сервера. По-друге, об'єктно-орієнтована структура коду ізолює логіку роботи з LLM в окремий сервісний клас. Це дозволяє за необхідності швидко перевести систему з локальної

моделі Ollama на потужні хмарні кластери (наприклад, API від OpenAI) без переписування алгоритмів гібридного пошуку та обробки векторів бази ChromaDB.

3.7 Висновки за розділом

У третьому розділі було описано проєктування ПЗ інтелектуальної системи консультування. Для організації взаємодії компонентів обрано багаторівневу клієнт-серверну архітектуру. Такий підхід дозволив відокремити UI від бекенд-процесів, і забезпечувати належну роботу системи.

Клієнтський рівень реалізовано як плагін для CMS WordPress. Завдяки такому рішенню, вбудуванню віджета чату в існуючу екосистему сайту, без необхідності розробки окремого фронтенд-додатка з нуля. В результаті інтерфейс є адаптивним, не перевантажує платформу та залишається інтуїтивно зрозумілим для кінцевого користувача.

Серверну частину побудовано на базі асинхронного фреймворку FastAPI. Тут виконуються усі складні обчислення, такі як векторизація тексту, функціонування RAG-конвеєра, обмін даними з локальним LLM. Винесення цієї логіки на окремий бекенд забезпечує швидкодію та захищає базу знань від прямого доступу ззовні.

Для зберігання даних було створено гібридне рішення. Семантичний пошук релевантного контексту здійснюється за допомогою векторної бази даних ChromaDB. Типові діалоги кешуються через систему Redis. Було розроблено специфікацію метаданих для фільтрації інформації та забезпечення того, щоб основні вихідні документи в відповідях правильно цитувалися.

Таким чином, балансування навантаження та розширена обробка даних є основою системи. Запропоновані рішення відповідають усім вимогам проєкту та сприяють подальшому масштабуванню системи.

4 ЕКСПЛУАТАЦІЯ, ТЕСТУВАННЯ ТА ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ПРОГРАМИ

4.1 Призначення та умови застосування програми

Інтелектуальна система призначена для надання користувачам вебсайту швидких та точних відповідей на запитання у форматі інтерактивного чату. Програма автоматизує процес пошуку інформації, використовуючи тільки завантажену в неї інформацію, що дозволяє користувачеві не шукати інформацію самостійно. Застосунок легко вбудовується у WordPress сайти і виконує роль віртуального консультанта. Він розуміє запити природною мовою, шукає підходящу інформацію та дає корисні відповіді, посилаючись на першоджерела.

На практиці взаємодія з віртуальним консультантом відбувається так: користувач відкриває сторінку сайту з інтегрованим віджетом, і викликає вікно діалогу. Вводить своє запитання та відправляє його системі. Під час обробки запиту відображається індикатор завантаження, а згодом система починає плавно виводити згенеровану текстову відповідь. Знайдена інформація підкріплюється посиланнями на документи-першоджерела, що дозволяє користувачеві при необхідності одразу перейти до оригінального тексту для ознайомлення. Також користувач має можливість продовжувати діалог, ставлячи уточнюючі запитання.

Основні функції системи:

- обробка природномовних запитів. Прийом та розуміння текстових питань від користувача через вебінтерфейс;
- семантичний пошук. Розуміння системою суть питання, а не просто пошук точних збігів слів;
- потокова генерація відповідей. Поступова поява тексту на екрані;
- атрибуція джерел. Автоматичне додавання посилань на першоджерела, з яких було взято інформацію для формування;

– кешування типових запитів. Миттєва відповідь системи на поширені питання.

Отже, призначення застосунку полягає у забезпеченні користувачів швидким, зручним та надійним інструментом для отримання точних консультацій на основі бази знань сайту.

4.2 Системні вимоги та умови експлуатації

Для стабільної роботи та оптимальної взаємодії з інтелектуальною системою консультування необхідно дотримуватися деяких системних вимог і умов експлуатації. Оскільки застосунок розроблено з використанням багаторівневої клієнт-серверної архітектури, де векторна БД та мовна модель розміщені на виділеному сервері, вимоги до апаратного забезпечення чітко розділені.

4.2.1 Апаратні та програмні вимоги

Стабільна продуктивність системи та ефективна реакція сервера вимагають, щоб як апаратні, так і програмні компоненти системи були обрані з урахування загальних критеріїв.

Основні критерії, які варто враховувати для клієнта:

- сучасний персональний комп'ютер або мобільний пристрій;
- браузер, що підтримує JS та SSE в останньому оновленні.

Для серверу слід врахувати наступне:

- операційну систему сімейства Linux;
- обсяг RAM від 16 ГБ;
- наявність GPU з обсягом VRAM від 8 ГБ.

Для уникнення перебоїв під час отримання відповідей потрібне стабільне і високошвидкісне інтернет-з'єднання.

4.2.2 Умови експлуатації

Для стабільної роботи застосунку, потрібно дотримуватися певних умов використання та обслуговування. Основні рекомендації для покращення роботи системи:

- оновлення БД. Оскільки контент і вебсторінки, і документів можуть змінюватися, необхідно регулярне оновлення векторних індексів БД;
- стеження за ресурсами системи. Мовні моделі часто використовують велику кількість обчислювальних ресурсів під час генерації відповідей, тому бажано стежити за навантаженням на систему;
- мережеві умови. Для оптимальної роботи необхідно встановити стабільне HTTP-з'єднання між сервером WordPress і API-шлюзом на FastAPI.

Система не вимоглива до користувацьких пристроїв. Але, для забезпечення високої продуктивності і надійності застосунку, необхідно дотримуватися вищенаведених вимог до серверної частини.

4.3 Інтерфейс клієнтської частини

UI клієнтської частини створено згідно з концепцією мінімалізму та ненав'язливості. Оскільки розроблений продукт є плагіном для CMS WordPress, його головне завдання – органічно доповнювати існуючий дизайн вебсайту, не перекриваючи основний контент і не перевантажуючи сторінку. Для забезпечення максимального комфорту взаємодії інтерфейс розбито на кілька логічних станів.

4.3.1 Інтеграція віджета та стартовий стан

За замовчуванням система знаходиться у режимі очікування. Користувач бачить лише компактну плаваючу кнопку, яка фіксується у лівому нижньому куті екрана (рисунок 4.1).

При наведенні курсора на іконку, кнопка може злегка змінювати колір або тінь, сигналізуючи про свою інтерактивність.




Рисунок 4.1 – Відображення закритого віджета на сторінці вебсайту

4.3.2 Вікно діалогу та основні елементи керування

Після кліку на іконку виклику плавно розгортається головне вікно чату (рисунок 4.2). Його структуру поділено на три основні функціональні зони:

- шапка. Містить назву віртуального консультанта (або логотип компанії) та кнопку для згортання віджета;
- робоча область. Зона, де відображається історія листування, при першому відкритті тут виводиться стандартне привітальне повідомлення від системи, яке запрошує користувача поставити своє запитання;
- панель вводу. Текстове поле для введення запиту природною мовою та кнопка відправлення повідомлення.

Поле вводу підтримує багаторядковий текст і автоматично масштабується по висоті при введенні довгих запитань.




Рисунок 4.2 – Головне вікно віртуального помічника у початковому стані

4.3.3 Режим очікування та результат генерації

Коли користувач відправляє повідомлення, його текст миттєво з'являється у робочій області чату. Після цього система переходить у стан обробки запиту.

Оскільки семантичний пошук у ChromaDB та ініціалізація LLM на бекенді займають певний час (від кількох мілісекунд при кешуванні до кількох секунд при повній генерації), інтерфейс повинен інформувати користувача про статус роботи. Для цього під повідомленням користувача з'являється індикатор завантаження (рисунок 4.3). Цей зворотний зв'язок запобігає повторному відправленню запитів і знижує відчуття затримки.




Рисунок 4.3 – Індикація процесу пошуку та векторизації на сервері

Як тільки бекенд починає генерувати відповідь, інтерфейс переходить у режим потокового виведення. Текст з'являється на екрані плавно, по мірі надходження токенів від мовної моделі. Ключовим елементом цього екрана є блок метаданих. Після завершення генерації повідомлення, під текстом відповіді автоматично виводиться плашка з джерелами (рисунок 4.4). Вона містить назви документів або посилання на конкретні сторінки сайту, які RAG-система використала як контекст. На ці посилання можна натиснути.




Рисунок 4.4 – Згенерована відповідь із виведенням першоджерел

4.3.4 Адаптивність для мобільних пристроїв

Інтерфейс віджета від початку створювався адаптивним. Окремої мобільної версії не розроблялося, оскільки завдяки гнучкій верстці елементи чату автоматично підлаштовуються під розміри екранів смартфонів та планшетів (рисунок 4.5).

Вікно діалогу не виходить за межі екрана і не ламає дизайн сайту. Кнопки зручно натискати сенсорно, а поле вводу достатньо велике для використання віртуальної клавіатури. Завдяки цьому плагіном комфортно користуватися на будь-якому пристрої без додаткових доробок коду.




Рисунок 4.5 – Відображення інтерфейсу на мобільному пристрої

4.4 Інтерфейс панелі адміністрування

Для керування RAG-конвеєром розроблено відокремлену панель адміністрування. Вона працює як незалежний вебінтерфейс і доступна за окремим захищеним посиланням. Таке архітектурне рішення ізолює логіку управління інтелектуальною системою від основної CMS WordPress, що значно підвищує безпеку та відмовостійкість інфраструктури. Доступ до панелі здійснюється через екран авторизації, де адміністратор повинен ввести валідний ключ для отримання доступу до налаштувань (рисунок 4.6).




Рисунок 4.6 - Екран авторизації в панелі адміністрування

4.4.1 Дашборд та моніторинг інфраструктури

Після успішного входу користувач потрапляє на головний дашборд з боковим меню. На екрані з системною аналітикою є візуальний моніторинг системи. В інтерфейсі реалізовано інформаційні блоки, які в режимі реального часу відображають статуси ключових вузлів: активність ядра, кількість фрагментів у базі та статистику in-memory сховища Redis (рисунок 4.7).




Рисунок 4.7 - Індикатори стану системи

4.4.2 Інструменти синхронізації бази знань

Оскільки векторна база знань зберігається на сервері ізольовано від основного сайту, ключовим інструментом панелі є розділ індексації та векторизації. Цей модуль відповідає за те, щоб віртуальний консультант «вивчив» необхідну інформацію та міг використовувати її в діалогах. Процес наповнення «мізків» системи розділено на два напрямки: роботу зі сторінками сайту та обробку окремих завантажених документів.

Перший інструмент призначений для синхронізації з основним сайтом. Одним натисканням кнопки можна запустити процес автоматичного збору тексту з усіх або лише з вибраних сторінок сайту (рисунок 4.8).




Рисунок 4.8 – Інтерфейс індексації сторінок сайту

Другий інструмент дозволяє завантажувати власні зовнішні файли (рисунок 4.9). В цьому розділі реалізовано просту форму для вибору файлів із пристрою. Після завантаження система автоматично розбиває документ на дрібні фрагменти та проводить їх векторизацію. Адміністратор може бачити список усіх доданих документів, їх обсяг та статус обробки.




Рисунок 4.9 – Розділ керування завантаженими документами

4.5 Тестування та обробка виняткових ситуацій

Для підтвердження надійності, безпеки та відмовостійкості розробленої інтелектуальної системи було проведено комплексне тестування.

Оскільки архітектура застосунку складається з двох ізольованих середовищ тестування було розділено на кілька етапів: перевірка UI, тестування бекенду, аналіз стійкості до навантажень та перевірка алгоритмів обробки помилок.

4.5.1 Функціональне тестування користувацького інтерфейсу

На цьому етапі перевірялася коректність роботи візуальних елементів віджета на різних пристроях та реакція системи на базові дії користувача. Головною метою було переконатися, що взаємодія із системою залишається стабільною, передбачуваною та комфортною для кінцевого користувача. Результати перевірки наведено в таблиці 4.1.

Таблиця 4.1 - Результати тестування клієнтського інтерфейсу

Сценарій тестування	Очікуваний результат	Фактичний результат	Статус
1	2	3	4
Ініціалізація віджета на сторінці	Віджет завантажується асинхронно, не блокуючи завантаження основного контенту сайту	DOM-дерево формується без затримок, віджет відображається коректно	Успішно
Адаптивність	При ширині екрана менше 768px вікно чату розгортається на весь екран	Інтерфейс адаптується, віртуальна клавіатура не перекриває поле вводу	Успішно
Валідація пустого вводу	Блокування відправки повідомлення, якщо поле вводу порожнє або містить лише пробіли	Кнопка відправки залишається неактивною, запит на сервер не формується	Успішно

Продовження таблиці 4.1

1	2	3	4
Обробка довгого тексту	Поле вводу автоматично масштабується по висоті під час набору об'ємного запиту	Текстове поле збільшується до заданого ліміту, після чого з'являється скрол	Успішно
Рендеринг потокових даних	Згенерований LLM текст виводиться на екран плавно, імітуючи живий друк.	Текст з'являється без ривків, розривів з'єднання під час генерації не зафіксовано.	Успішно

4.5.2 Тестування бекенду та RAG-конвеєра

Другий етап тестування був зосереджений на серверній частині: перевірці якості семантичного пошуку, формуванні контексту та роботі БД ChromaDB. Результати наведено в таблиці 4.2.

Таблиця 4.2 - Результати тестування серверного ядра

Сценарій тестування	Очікуваний результат	Фактичний результат	Статус
1	2	3	4
Точність семантичного пошуку	Запит із синонімами успішно знаходить релевантний фрагмент у базі	Векторна база повертає правильні документи	Успішно

Продовження таблиці 4.2

1	2	3	4
Атрибуція першоджерел	Система додає клікабельні посилання на джерела, які були використані як контекст	Блок метаданих формується коректно, посилання ведуть на цільові сторінки	Успішно
Синхронізація бази знань	Примусовий запуск індексації з адмін-панелі оновлює вектори в БД	Старі записи замінюються новими, процес відображається в логах сервера	Успішно

4.5.3 Навантажувальне тестування та робота системи кешування

Оскільки генерація тексту за допомогою LLM є ресурсомістким процесом, критично важливою була перевірка роботи in-memory сховища Redis. Під час тестування імітувалося надсилання серії ідентичних запитів. Перший запит оброблявся системою за стандартним сценарієм (пошук у ChromaDB + генерація LLM), що займало в середньому 3-5 секунд. Наступні ідентичні запити перехоплювалися системою кешування Redis на рівні FastAPI API-шлюзу. Час відповіді на кешовані запити складав близько 40-50 мілісекунд, що підтвердило високу ефективність обраної архітектури для зниження навантаження на обчислювальне ядро.

4.5.4 Тестування безпеки та обробки нестандартних запитів

Системи на базі ШІ вимагають специфічних підходів до безпеки. Для забезпечення стабільної роботи було реалізовано та протестовано алгоритми обробки нестандартних ситуацій.

Запити поза контекстом: коли користувач ставить питання, яке не стосується тематики завантаженої бази знань (наприклад, прогноз погоди або кулінарні рецепти), семантичний пошук повертає низький показник релевантності. У цьому випадку спрацьовує запобіжник: система не генерує хибні твердження, а виводить заздалегідь підготовлене повідомлення про відсутність інформації (рисунок 4.10).




Рисунок 4.10 - Реакція системи на запит поза межами бази знань

Відсутність зв'язку з сервером: у випадку падіння сервера FastAPI або обриву мережі, клієнтський плагін перехоплює помилку тайм-ауту. Замість нескінченної анімації очікування, інтерфейс миттєво перериває сесію та повідомляє користувача про технічні неполадки, запобігаючи зависанню сторінки (рисунок 4.11).




Рисунок 4.11 - Повідомлення помилки втрати з'єднання з бекендом

Захист від промпт-ін'єкцій: тестування включало спроби змусити модель проігнорувати системні інструкції (рисунок 4.12). Завдяки жорсткому шаблонуванню запитів на стороні бекенда, модель ігнорує подібні маніпуляції та залишається в межах заданої ролі консультанта.




Рисунок 4.12 - Реакція системи на запит зі спробою зміни ролі

4.6 Висновки за розділом

У цьому розділі підведено підсумки розробки, експлуатації та тестування інтелектуальної системи віртуального консультанта. Доведено, що створена клієнт-серверна архітектура, яка поєднує віджет для CMS WordPress та бекенд, успішно вирішує завдання автоматизації підтримки відвідувачів вебсайту на основі завантаженої бази знань.

Демонстрація розроблених екранних рішень засвідчила, що клієнтський інтерфейс відповідає принципам мінімалізму та інтуїтивної зрозумілості, органічно інтегруючись у загальний дизайн сторінок. Водночас створена панель адміністрування надає власникам необхідний інструментарій для зручного моніторингу стану інфраструктури та безперешкодного оновлення векторних даних.

Результати тестування серверної частини підтвердили високу швидкість і точність семантичного пошуку. Встановлено, що впровадження кешування суттєво оптимізує навантаження на обчислювальне ядро під час обробки типових запитів, а налаштовані алгоритми обробки виняткових ситуацій надійно блокують спроби генерації відповідей поза тематикою сайту.

Загалом, результати розділу свідчать про те, що створений застосунок є сучасним, масштабованим і стабільним. Поєднання ефективного інтелектуального пошуку з продуманим UI робить розробленого консультанта повністю готовим до інтеграції та практичної експлуатації.

ВИСНОВКИ

У результаті виконання дипломної бакалаврської роботи вдалося досягти поставлену мету роботи, яка полягала у підвищенні швидкості автоматизованого інформаційно-консультаційного обслуговування користувачів вебресурсів. Для цього було спроектовано та розроблено автономного віртуального консультанта, побудованого на базі LLM та архітектури генерації RAG.

Було проведено аналіз існуючих хмарних рішень, який виявив їхні вразливості щодо конфіденційності даних та залежності від платних API. На основі цього було вирішено створити власну автономну систему. Створено багаторівневу клієнт-серверну архітектуру, яка відділяє складні обчислення від UI.

Практична реалізація серверної частини виконана мовою Python з використанням високопродуктивного асинхронного фреймворку FastAPI. Інтелектуальне ядро системи побудовано навколо локального сервера інференсу Ollama, завдяки чому відсутня залежність від зовнішніх ШІ-сервісів. Зберігання даних та алгоритми гібридного пошуку релевантного контексту реалізовано на базі векторної БД ChromaDB. У системі також реалізовано семантичне кешування запитів за допомогою Redis, що значно зменшило навантаження на сервер при активному використанні чат-боту.

Взаємодію з кінцевим користувачем реалізовано у вигляді нативного адаптивного плагіна для CMS WordPress. Інтерфейс віджета використовує протокол SSE, завдяки чому текст з'являється поступово, завдяки чому створюється ефект живого спілкування. Для зручного управління базою знань та перегляду стану системи створено панель адміністрування.

Проведене комплексне тестування підтвердило стабільність, швидкодію та безпеку системи. Впроваджені алгоритми фільтрації та гібридного пошуку успішно утримують контекст розмови, блокують запити поза межами бази знань та відхиляють спроби зміни системних інструкцій.

Крім того, кожна згенерована відповідь автоматично підкріплюється активними посиланнями на першоджерела, що запобігає вигадуванню фактів III.

Отже, створений програмний продукт є завершеним, безпечним і масштабованим рішенням. Розроблена діалогова система відповідає всім вимогам технічного завдання і є повністю готовою до впровадження у реальні вебресурси для автоматизації консультування користувачів.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Що таке RAG і як його можна використовувати на практиці?: Стаття з блогу IT-школи Hillel. Корисні матеріали: Статті та новини IT-індустрії | Комп'ютерна школа Hillel. URL: <https://blog.ithillel.ua/articles/what-is-rag> (дата звернення: 06.04.2026).
2. Dialogflow CX | Google Cloud Documentation. Google Cloud Documentation. URL: <https://docs.cloud.google.com/dialogflow/docs> (date of access: 19.04.2026).
3. Dialogflow. Dialogflow. URL: <https://dialogflow.cloud.google.com/> (date of access: 06.04.2026).
4. Developer overview - Chatbase. Chatbase: The Leading AI Customer Service Platform. URL: <https://www.chatbase.co/docs/developer-guides/overview> (date of access: 06.04.2026).
5. Chatbase: the leading AI customer service platform. Chatbase: The Leading AI Customer Service Platform. URL: <https://www.chatbase.co/> (date of access: 06.04.2026).
6. Changelog - SiteGPT Docs. SiteGPT - Make AI your expert customer support agent. URL: <https://sitegpt.ai/docs/changelog/overview> (date of access: 06.04.2026).
7. SiteGPT - Make AI your expert customer support agent. SiteGPT. URL: <https://sitegpt.ai/> (date of access: 06.04.2026).
8. What is Python? Executive Summary. Python.org. URL: <https://www.python.org/doc/essays/blurb/> (date of access: 06.04.2026).
9. LangChain overview - Docs by LangChain. Home - Docs by LangChain. URL: <https://docs.langchain.com/oss/python/langchain/overview> (date of access: 07.04.2026).
10. asyncio – Asynchronous I/O. Python documentation. URL: <https://docs.python.org/3/library/asyncio.html> (date of access: 07.04.2026).

11. Documentation - The Go Programming Language. The Go Programming Language. URL: <https://go.dev/doc/> (date of access: 07.04.2026).
12. GitHub - ollama/ollama: Get up and running with Kimi-K2.5, GLM-5, MiniMax, DeepSeek, gpt-oss, Qwen, Gemma and other models. GitHub. URL: <https://github.com/ollama/ollama> (date of access: 07.04.2026).
13. Java SE Specifications. URL: <https://docs.oracle.com/javase/specs/> (date of access: 07.04.2026).
14. GitHub - langchain4j/langchain4j: LangChain4j is an idiomatic, open-source Java library for building LLM-powered applications on the JVM. GitHub. URL: <https://github.com/langchain4j/langchain4j> (date of access: 07.04.2026).
15. Features - FastAPI. FastAPI. URL: <https://fastapi.tiangolo.com/features/> (date of access: 08.04.2026).
16. Welcome to Flask – Flask Documentation (3.1.x). Welcome to Flask – Flask Documentation (3.1.x). URL: <https://flask.palletsprojects.com/en/stable/> (date of access: 08.04.2026).
17. Django overview. Django Project. URL: <https://www.djangoproject.com/start/overview/> (date of access: 08.04.2026).
18. Introduction - Chroma Docs. Introduction - Chroma Docs. URL: <https://docs.trychroma.com/docs/overview/introduction> (date of access: 09.04.2026).
19. The vector database to build knowledgeable AI | Pinecone. The vector database to build knowledgeable AI | Pinecone. URL: <https://www.pinecone.io/> (date of access: 09.04.2026).
20. Milvus vector database documentation. Milvus | High-Performance Vector Database Built for Scale. URL: <https://milvus.io/docs> (date of access: 09.04.2026).
21. API Overview. OpenAI API Reference. URL: <https://developers.openai.com/api/reference/overview> (date of access: 10.04.2026).

22. Introducing Meta Llama 3: The most capable openly available LLM to date. AI at Meta: Meta AI Products, Models and Research | AI at Meta. URL: <https://ai.meta.com/blog/meta-llama-3/> (date of access: 10.04.2026).
23. Ollama. Ollama. URL: <https://ollama.com/> (date of access: 10.04.2026).
24. Quick Start – React. React. URL: <https://react.dev/learn> (date of access: 19.04.2026).
25. Web Components - Web APIs | MDN. MDN Web Docs. URL: https://developer.mozilla.org/en-US/docs/Web/API/Web_components (date of access: 19.04.2026).
26. Plugin Handbook | Developer.WordPress.org. WordPress Developer Resources. URL: <https://developer.wordpress.org/plugins/> (date of access: 19.04.2026).
27. What Is Client-Server Architecture?. Coursera. URL: <https://www.coursera.org/articles/client-server-architecture> (date of access: 26.04.2026).
28. Choose Between SSE and WebSockets | Railway Guides. Choose Between SSE and WebSockets | Railway Guides. URL: <https://docs.railway.com/guides/sse-vs-websockets> (date of access: 26.04.2026).

ДОДАТОК А
Технічне завдання

Вступ

Цей документ є технічним завданням на розробку програмного забезпечення – інтелектуальної діалогової системи на базі технології RAG. Основна мета створення даного застосунку полягає в автоматизації процесів консультування користувачів, обробці природномовних запитів та забезпеченні швидкого пошуку інформації серед великих масивів неструктурованих нормативних документів та сторінок вебресурсу. Система повинна мати зручний, інтуїтивно зрозумілий інтерфейс, гарантувати абсолютну безпеку даних завдяки локальному розгортанню та забезпечувати стабільну роботу. Програмне забезпечення розробляється з урахуванням сучасних стандартів створення інтелектуальних вебзастосунків і реалізується як модульне клієнт-серверне рішення.

A.1 Підстава для розробки

Підставою для розробки є завдання на дипломну кваліфікаційну роботу на тему «Розроблення та дослідження програмного забезпечення діалогової системи автоматизованого консультування користувачів вебресурсу», затверджене відповідним наказом Національного університету «Запорізька політехніка» № 139 від 07 квітня 2026 р.

A.2 Основні вимоги до програми, що розроблюється

Для гарантування коректного, стабільного й безпечного функціонування програмного забезпечення важливо чітко окреслити основні вимоги, яким повинна відповідати система протягом усього життєвого циклу. Ці вимоги охоплюють як функціональні характеристики (роботу алгоритмів пошуку та генерації), так і вимоги до дизайну інтерфейсу, надійності архітектури, а також специфічні технічні умови серверного розгортання

локальних нейромереж. Їх формування базується на реальних потребах освітніх порталів та сучасних підходах до захисту інформації. У цьому розділі представлені основні вимоги до розроблюваного програмного продукту, виходячи з його головної мети – автоматизації інформаційної підтримки. Для зручності подальшої реалізації та тестування системи, вимоги класифіковано за логічними групами.

A.2.1 Вимоги до функціональних характеристик

Програмне забезпечення повинно забезпечувати реалізацію наступного функціоналу:

- завантаження, індексування та збереження текстових масивів (документів, вебсторінок) у векторній базі даних;
- виконання гібридного пошуку (поєднання векторного та лексичного алгоритмів) для знаходження найбільш релевантного контексту;
- генерацію відповідей природною мовою виключно на основі знайденого контексту за допомогою локальних великих мовних моделей;
- обов'язкове формування посилань на першоджерела у кожній згенерованій відповіді;
- фільтрацію вхідних запитів для захисту від prompt-ін'єкцій та інших спроб обходу системних інструкцій;
- перевірку згенерованого тексту перед відображенням користувачу;
- збереження історії діалогів та метрик використання для панелі адміністратора.

A.2.2 Вимоги до інтерфейсу програми

Користувацький інтерфейс має бути функціональним, візуально строгим і повністю адаптованим для роботи на мобільних і десктопних

пристроях. Дизайн панелі управління та вікна чату повинен бути виконаний у темному строгому стилі із жорсткою геометрією, що виключає використання заокруглених кутів. Зона діалогу, поле вводу запиту та блок відображення джерел мають бути логічно розділені та контрастно виділені для максимальної концентрації користувача на контенті.

A.2.3 Вимоги до надійності

Програмне забезпечення повинно гарантувати повну ізоляцію даних: жоден запит чи фрагмент документа не повинен передаватися на сторонні хмарні сервери. Усі векторні представлення текстів мають зберігатися у локальній базі даних ChromaDB. Архітектура застосунку має бути розділена на незалежні мікросервіси (сервер бази даних, сервер обробки API та сервер мовної моделі). Це забезпечить можливість гарячої заміни LLM чи оновлення бази знань без переривання доступу користувачів до чату.

A.2.4 Вимоги до складу та параметрів технічних засобів

Для ефективного використання програми на клієнтському боці користувачеві достатньо мати комп'ютер або смартфон із мінімальними технічними характеристиками:

- процесор: не нижче Intel Core i3 або аналогічний ARM;
- оперативна пам'ять (RAM): 4 Гб;
- сучасний веббраузер із підтримкою актуальних вебстандартів;
- стабільне підключення до Інтернету.

Оскільки система базується на локальному виконанні важких мовних моделей та алгоритмів векторизації, до серверної висуваються жорсткі апаратні вимоги:

- процесор: багатоядерний серверний процесор (не менше 16 потоків);

- оперативна пам'ять (RAM): мінімум 32 ГБ (рекомендується 64 ГБ) для розміщення бази даних та індексів у пам'яті;
- графічний прискорювач (GPU): наявність відеокарти з обсягом VRAM від 16 ГБ для завантаження ваг мовної моделі та забезпечення швидкої генерації токенів;
- накопичувач: NVMe SSD для швидкого доступу до бази векторів під час гібридного пошуку.

ДОДАТОК Б
Текст програми

Б.1 Фрагмент файла main.py

```

app = FastAPI(title="University RAG Assistant", version="1.0.0",
lifespan=lifespan, docs_url=None if ENVIRONMENT == "production" else "/docs",
redoc_url=None if ENVIRONMENT == "production" else "/redoc")
app.add_middleware(CORSMiddleware, allow_origins=ALLOWED_ORIGINS,
allow_credentials=True, allow_methods=["*"], allow_headers=["*"])
def get_client_identifier(request: Request): return
request.headers.get("X-Forwarded-For", "").split(",")[0].strip() or
get_remote_address(request)
limiter = Limiter(key_func=get_client_identifier)
app.state.limiter = limiter
app.add_exception_handler(RateLimitExceeded,
_rate_limit_exceeded_handler)
class Message(BaseModel): role: Literal["user", "assistant"]; content:
str
class ChatRequest(BaseModel):
    messages: List[Message] = Field(..., max_length=10); mode:
Literal["site", "docs"] = "site"; use_history: bool = False
    @property
    def last_question(self) -> str: return self.messages[-1].content
if self.messages and self.messages[-1].role == "user" else ""
    @property
    def history(self) -> List[dict]: return [{"role": m.role,
"content": m.content.strip()[:500]} for m in self.messages[:-1][-
MAX_HISTORY_MESSAGES:]] if self.use_history else []
    class UpdateRequest(BaseModel): urls: List[str]
    class SitemapRequest(BaseModel): url: str
    async def verify_admin(x_api_key: str = Depends(APIKeyHeader(name="X-
API-Key"))):
        if x_api_key != ADMIN_API_KEY: raise
        HTTPException(status_code=403, detail="Forbidden")
    @app.post("/api/chat/stream")
    @limiter.limit(RATE_LIMIT_CHAT)
    async def chat_endpoint(req: ChatRequest, request: Request):
        q = "".join(ch for ch in re.sub(r'(\.|\{|\}', r'\1\1\1\1',
req.last_question.strip()) if ch.isprintable() or ch in ['\n', '\r', '\t'])
        if not q or len(q) < 2 or len(q) > MAX_QUERY_LENGTH or not
any(c.isalnum() for c in q): raise HTTPException(status_code=400,
detail="Invalid request")
        if request_counter.is_overloaded():
            async def _overload(): yield sse_pack("Сервер
перевантажено."); yield "data: [DONE]\n\n"
            return StreamingResponse(_overload(), media_type="text/event-
stream", headers={"Cache-Control": "no-cache", "Connection": "keep-alive",
"X-Accel-Buffering": "no"})
        gen = doc_chat_generator(q, request=request) if req.mode == "docs"
else site_chat_generator(q, req.history, request=request)
        return StreamingResponse(gen, media_type="text/event-stream",
headers={"Cache-Control": "no-cache", "Connection": "keep-alive", "X-Accel-
Buffering": "no"})
    @app.post("/api/upload", dependencies=[Depends(verify_admin)])
    async def upload_document(file: UploadFile = File(...)):
        if file.content_type not in ALLOWED_UPLOAD_TYPES: raise
        HTTPException(status_code=400, detail="Unsupported type")
        content = await file.read()
        if len(content) > UPLOAD_MAX_BYTES: raise
        HTTPException(status_code=413, detail="File too large")
        filename = re.sub(r'^\w\.-|_|_', file.filename or "upload")
        file_path =
os.path.realpath(os.path.join(os.path.realpath(DOCS_UPLOAD_DIR), filename))
        with open(file_path, "wb") as b: b.write(content)

```

```

        if await ingest_document(file_path, filename): return {"status":
"success", "filename": filename}
        raise HTTPException(status_code=500, detail="Process failed")
    @app.post("/api/update-knowledge",
dependencies=[Depends(verify_admin)])
    async def update(req: UpdateRequest, bg: BackgroundTasks):
bg.add_task(run_update_pipeline, req.urls); return {"status": "started"}
    @app.post("/api/crawl-sitemap", dependencies=[Depends(verify_admin)])
    async def crawl_sitemap_endpoint(req: SitemapRequest, bg:
BackgroundTasks): bg.add_task(run_sitemap_pipeline, req.url); return
{"status": "started"}
    @app.get("/api/health")
    async def health_check(): return {"status": "ok", "total_chunks":
get_document_stats().get("total_chunks", 0) +
(doc_vectorstore._collection.count() if 'doc_vectorstore' in globals() else
0)}

    @app.get("/api/docs/list")
    async def list_documents(): return {"documents": [{"name": f, "size":
os.path.getsize(os.path.join(DOCS_UPLOAD_DIR, f))} for f in
os.listdir(DOCS_UPLOAD_DIR) if not f.startswith('.')]} if
os.path.exists(DOCS_UPLOAD_DIR) else {"documents": []}
    @app.get("/api/docs/view/{filename}")
    async def view_document(filename: str): return
FileResponse(os.path.join(DOCS_UPLOAD_DIR, os.path.basename(filename)))
    @app.delete("/api/docs/{filename}",
dependencies=[Depends(verify_admin)])
    async def delete_document(filename: str):
        file_path = os.path.join(DOCS_UPLOAD_DIR,
os.path.basename(filename))
        if os.path.exists(file_path): os.remove(file_path)
        data = doc_vectorstore.get(where={"source":
os.path.basename(filename)})
        if data and data.get("ids"):
doc_vectorstore.delete(ids=data["ids"])
        return {"status": "success"}

```

Б.2 Фрагмент файлу core.py

```

llm = ChatOllama(model=LLM_MODEL, base_url=OLLAMA_BASE_URL,
temperature=LLM_TEMPERATURE, top_p=LLM_TOP_P, repeat_penalty=1.0,
num_ctx=LLM_CONTEXT_WINDOW, num_predict=2000, keep_alive=-1)
fast_llm = ChatOllama(model=FAST_LLM_MODEL, base_url=OLLAMA_BASE_URL,
temperature=0.0, num_ctx=1024, num_predict=100, keep_alive=-1)
embeddings = OllamaEmbeddings(model=EMBEDDING_MODEL,
base_url=OLLAMA_BASE_URL)
ranker = CrossEncoder(RERANKER_MODEL, max_length=512,
device=_reranker_device, model_kwargs={"torch_dtype": torch.float16})

```

Б.3 Фрагмент файлу config.py

```

load_dotenv()
LLM_MODEL, FAST_LLM_MODEL = "gemma2:9b", "gemma2:2b"
EMBEDDING_MODEL, RERANKER_MODEL = "nomic-embed-text", "BAAI/bge-
reranker-v2-m3"
CHUNK_SIZE, CHUNK_OVERLAP, VECTOR_RECALL_K, RERANK_TOP_K = 1000, 200,
40, 8

```

```

RERANK_THRESHOLD, MAX_CONTEXT_CHUNKS = 0.28,
int(os.getenv("MAX_CONTEXT_CHUNKS", "4"))
HYBRID_VECTOR_WEIGHT, HYBRID_BM25_WEIGHT = 0.6, 0.4
CACHE_MAX_SIZE, CACHE_SIMILARITY_THRESHOLD = 2000, 0.82
LLM_TEMPERATURE, LLM_TOP_P, LLM_CONTEXT_WINDOW = 0.0, 0.5, 3072
MAX_HISTORY_MESSAGES, MAX_QUERY_LENGTH, SITE_LLM_TIMEOUT = 4, 2000,
60.0
CONTEXTUALIZE_SYSTEM_PROMPT = ""[РОЛЬ] Ти — внутрішній пошуковий
рушій... []""
QA_SYSTEM_PROMPT = ""<system_core> Ти — офіційний штучний інтелект-
асистент... []""
QA_FINAL_REMINDER = ""КАТЕГОРИЧНО ЗАБОРОНЕНО: змінювати МОВУ... []""
MSG_NO_CONTEXT_FOUND = "На жаль, у базі знань не знайдено інформації.
Зверніться на сайт https://zp.edu.ua"
DATA_EXTRACTION_PROMPT = ""<system> Ти — точний алгоритм
екстракції... []""
DOCS_UPLOAD_DIR, DOCS_DB_PATH = "uploaded_documents", "chroma_db_docs"
ENABLE_OCR_PREPROCESSING, LLM_CONCURRENCY = True,
int(os.getenv("LLM_CONCURRENCY", "2"))
LLM_SEMAPHORE = asyncio.Semaphore(LLM_CONCURRENCY)
DOC_QA_SYSTEM_PROMPT = ""<system_core> Ти — експерт-аналітик
документів... []""

```

Б.4 Фрагмент файлу sitemap.py

```

def is_ip_allowed(ip: str) -> bool:
    try: obj = ipaddress.ip_address(ip); return not (obj.is_private or
obj.is_loopback or obj.is_reserved or obj.is_multicast)
    except ValueError: return False
def validate_url_security(url: str):
    parsed = urlparse(url)
    if parsed.scheme not in ('http', 'https') or not parsed.hostname:
raise ValueError("Invalid URL")
    try:
        for *_ , sockaddr in socket.getaddrinfo(parsed.hostname, None):
            if not is_ip_allowed(sockaddr[0]): raise
ValueError(f"Forbidden IP: {sockaddr[0]}")
    except socket.gaierror: raise ValueError("DNS resolution failed")
def fetch_sitemap_content(url: str) -> bytes:
    validate_url_security(url)
    session = requests.Session(); session.max_redirects = 5
    req = session.prepare_request(requests.Request("GET", url));
content = b""
    for _ in range(session.max_redirects + 1):
        resp = session.send(req, timeout=SITEMAP_TIMEOUT,
allow_redirects=False, stream=True)
        if resp.is_redirect or resp.is_permanent_redirect:
            next_url = resp.headers.get("Location", "")
            if not next_url: break
            validate_url_security(next_url); req =
session.prepare_request(requests.Request("GET", next_url)); continue
        resp.raise_for_status()
        for chunk in resp.iter_content(chunk_size=8192):
            content += chunk
            if len(content) > SITEMAP_MAX_SIZE: raise
ValueError("Sitemap too large")
        break
    return content
def get_sitemap_urls(sitemap_url: str, depth: int = 0) -> list[dict]:
    if depth > SITEMAP_MAX_RECURSION: return []

```

```

        match = re.search(r'([a-zA-Z0-9_-]+)-sitemap', sitemap_url); cat =
match.group(1) if match else "general"; urls = []
    try:
        root = ET.fromstring(fetch_sitemap_content(sitemap_url)); ns =
{'ns': 'http://www.sitemaps.org/schemas/sitemap/0.9'}
        for s in root.findall('ns:sitemap', ns):
            loc = s.find('ns:loc', ns)
            if loc and loc.text:
                urls.extend(get_sitemap_urls(loc.text.strip(), depth + 1))
        for u in root.findall('ns:url', ns):
            loc = u.find('ns:loc', ns)
            if loc and loc.text and not any(p in loc.text.strip() for
p in SITEMAP_IGNORED_PATHS):
                urls.append({"url": loc.text.strip(),
"category": cat})
    except Exception: pass
    return urls

```

Б.5 Фрагмент файла crawler.py

```

def is_ip_allowed(ip: str) -> bool:
    try: addr = ipaddress.ip_address(ip); return not (addr.is_loopback
or addr.is_private or addr.is_reserved or addr.is_multicast)
    except ValueError: return False
def resolve_and_validate(hostname: str) -> bool:
    try: return all(is_ip_allowed(sockaddr[0]) for _, _, _, _
sockaddr in socket.getaddrinfo(hostname, None))
    except socket.gaierror: return False
def validate_url(url: str):
    p = urlparse(url)
    if p.scheme not in ('http', 'https') or not p.hostname or not
resolve_and_validate(p.hostname): raise ValueError("Invalid URL")
def clean_text(text: str) -> str:
    text = re.sub(r'\n{3,}', '\n\n', re.sub(r' +', ' ',
re.sub(r'\[([^\]]+)\]\[([^\]]+)\]', r'\1', text)))
    text = '\n'.join([line.strip() for line in
text.splitlines()]).strip()
    return text[:CRAWLER_MAX_TEXT_LENGTH] + "\n\n[Truncated]" if
len(text) > CRAWLER_MAX_TEXT_LENGTH else text
async def intercept_route(route: Route):
    req = route.request; url = req.url; p = urlparse(url)
    if req.resource_type in BLOCKED_RESOURCE_TYPES or any(pat in url
for pat in BLOCKED_URL_PATTERNS) or (p.hostname and not
resolve_and_validate(p.hostname)): await route.abort()
    else: await route.continue_()
async def url_to_markdown(browser: Browser, url: str, category: str =
"general") -> str | None:
    try: validate_url(url)
    except ValueError: return None
    if "/en/" in url: return None
    raw_name = urlparse(url).path.strip('/') or "index"
    filename = re.sub(r'^\w[-.]', '_', raw_name) + ('' if
raw_name.endswith('.md') else '.md')
    output_path = os.path.join(UPLOAD_DIR, category, filename)
    if not
os.path.abspath(output_path).startswith(os.path.abspath(os.path.join(UPLOAD_D
IR, category))): return None
    try:
        ctx = await browser.new_context(viewport=BROWSER_VIEWPORT,
user_agent=USER_AGENT, permissions=[],
ignore_https_errors=IGNORE_HTTPS_ERRORS, service_workers="block")

```

```

        await ctx.route("**/*", intercept_route); page = await
ctx.new_page()
        res = await page.goto(url, wait_until="domcontentloaded",
timeout=CRAWLER_TIMEOUT)
        if not res or ("text/html" not in res.headers.get("content-
type", "") and "text/plain" not in res.headers.get("content-type", "")):
return None
        await page.wait_for_timeout(CRAWLER_WAIT_AFTER_LOAD)
        await page.evaluate("() => {
document.querySelectorAll('.accordion-button.collapsed,
.nav-link,
.tab').forEach(el => el.click()); }")
        title = (await page.evaluate("() =>
document.querySelector('h1') ? document.querySelector('h1').innerText : ''")
or await page.title()).strip() or "Untitled"
        html = await page.evaluate("(sel) => { sel.forEach(s =>
document.querySelector(s).forEach(e => e.remove())); return
(document.querySelector('main') || document.body).innerHTML; }",
JUNK_SELECTORS)
        content = clean_text(md(html, heading_style="ATX",
strip=MARKDOWN_STRIP_TAGS, bullets='•', autolinks=False))
        new_content = f"URL: {url}\nTitle: {title}\nCategory:
{category}\n\n{content}"
        new_hash = hashlib.sha256(new_content.encode('utf-
8')).hexdigest()
        if os.path.exists(output_path):
            with open(output_path, "r", encoding="utf-8") as f:
                if hashlib.sha256(f.read().encode('utf-
8')).hexdigest() == new_hash: return None
            os.makedirs(os.path.dirname(output_path), exist_ok=True)
            with open(output_path, "w", encoding="utf-8") as f:
f.write(new_content)
            return output_path
        finally:
            if 'page' in locals() and page: await page.close()
            if 'ctx' in locals() and ctx: await ctx.close()

```

Б.6 Фрагмент файла indexer.py

```

vectorstore = Chroma(persist_directory=DB_PATH,
embedding_function=embeddings, collection_metadata={"hnsw:space": "cosine"})
extraction_chain =
PromptTemplate.from_template(DATA_EXTRACTION_PROMPT) | llm
def parse_metadata_from_file(content: str) -> dict[str, str]:
    meta = {"url": "unknown", "title": "Unknown page", "category":
"general"}
    for line in content.split('\n')[:20]:
        if line.startswith("URL:"): meta["url"] = line.replace("URL:",
"").strip()
        elif line.startswith("Title:"): meta["title"] =
line.replace("Title:", "").strip()
        elif line.startswith("Category:"): meta["category"] =
line.replace("Category:", "").strip()
    return meta
def clean_content_lines(content: str) -> str:
    lines = [l for l in content.split('\n') if not any(l.startswith(p)
for p in ["URL:", "Title:", "Category:", "Університет:"])]
    content = re.sub(r'\n{3,}', '\n\n',
re.sub(r'\[[^\]]+\]\[([^\]]+)\]', lambda m: f'{m.group(1)} ({m.group(2)})'
if 'http' in m.group(2) else m.group(1), re.sub(r'\{*{1,2}([^\n]+)\{*{1,2}',
r'\1', re.sub(r'\((.)', r'\1', "\n".join(lines)))))

```

```

        table_lines, new_lines, in_table, headers = content.split('\n'),
[], False, []
        for line in table_lines:
            if line.strip().startswith('|') and
line.strip().endswith('|'):
                cols = [c.strip() for c in
line.strip().strip('|').split('|')]
                if not in_table: headers, in_table = cols, True; continue
                if set(line.replace('|', ' ').replace('-', ' ').replace(' ',
'')) == set(): continue
                if headers and len(cols) == len(headers):
new_lines.append("• " + " ".join([f"{headers[i]}: {cols[i]};" for i in
range(len(cols)) if cols[i] and cols[i] != '-']))
                else: new_lines.append(line)
                else: in_table = False; new_lines.append(line)
        return "\n".join(new_lines).strip()

    def is_quality_chunk(text: str) -> bool: return len(text.strip()) >=
30 and len(text.split()) >= 4 and len(re.findall(r'[|\•▶▪←]', text)) /
max(len(text), 1) <= 0.15 and len(re.findall(r'[a-æïïera-z]', text,
re.IGNORECASE)) / max(len(text), 1) >= 0.30

    def create_enhanced_chunks(content: str, metadata: dict) ->
list[Document]:
        md_splits = MarkdownHeaderTextSplitter(headers_to_split_on=[("#",
"h1"), ("##", "h2"), ("###", "h3")], strip_headers=False).split_text(content)
        text_splitter, final_docs, chunk_counter =
RecursiveCharacterTextSplitter(chunk_size=CHUNK_SIZE,
chunk_overlap=CHUNK_OVERLAP), [], 0
        for doc in md_splits:
            section_path = " > ".join([doc.metadata[k] for k in ["h1",
"h2", "h3"] if doc.metadata.get(k)])
            base_meta = {**metadata, "section_path": section_path}
            for chunk_text in text_splitter.split_text(doc.page_content):
                clean_chunk = chunk_text.strip()
                if not is_quality_chunk(clean_chunk): continue
                chunk_counter += 1
                enriched = f"[Сторінка: {metadata.get('title')} | HV
«Запорізька політехніка»]\n{section_path}\n{clean_chunk}" if section_path
else f"[Сторінка: {metadata.get('title')} | HV «Запорізька
політехніка»]\n{clean_chunk}"
                doc_id =
hashlib.md5(f"{metadata['url']}_{chunk_counter}_{clean_chunk[:50]}".encode()).
.hexdigest()
                final_docs.append(Document(page_content=enriched,
metadata={**base_meta, "chunk_type": "enriched_text", "chunk_id": doc_id,
"chunk_index": chunk_counter}))
        return final_docs

    def process_file_indexing(file_path: str):
        with open(file_path, "r", encoding="utf-8") as f: content =
f.read()
        metadata = parse_metadata_from_file(content); metadata["source"] =
os.path.basename(file_path)
        final_docs = create_enhanced_chunks(clean_content_lines(content),
metadata)
        if final_docs: existing = vectorstore.get(where={"url":
metadata["url"]})
            if existing and existing.get("ids"):
vectorstore.delete(ids=existing["ids"])
            vectorstore.add_documents(documents=final_docs,
ids=[d.metadata["chunk_id"] for d in final_docs])

```

Б.7 Фрагмент файлу rag.py

```

vectorstore = Chroma(persist_directory=DB_PATH,
embedding_function=embeddings, collection_metadata={"hnsw:space": "cosine"})
morph = pymorphy3.MorphAnalyzer(lang='uk')
history_chain = ChatPromptTemplate.from_messages([("system",
CONTEXTUALIZE_SYSTEM_PROMPT), ("human", "{history_text}\n{input}")]) |
fast_llm.bind(num_predict=40, stop=["\n", "?", "!"]) | StrOutputParser()
qa_chain = ChatPromptTemplate.from_messages([("system",
QA_SYSTEM_PROMPT + "\n\n" + QA_FINAL_REMINDER), ("human",
"{history_text}\n<context>{context}</context>\n{start_tag}{question}{end_tag}
")]) | llm | StrOutputParser()
def is_malicious_intent(query: str) -> bool: return any(re.search(p,
query.lower()) for p in [r"(?i)\b(?:уяви|забудь|відповідай на|напиши код)\b",
r"(?i)(?:/system|<instruction>)"])
def check_dlp_violation(text: str) -> bool: return any(re.search(p,
text) for p in [r"(?i)(/var/www/|/etc/)", r"(?i)(api_key|sk-[a-zA-Z0-9]{20,})" , r"\b(?:10\.|192\.168\.)"])
def format_history_text(history: list[dict]) -> str: return
"\n".join([f"'Користувач' if m['role'] == 'user' else 'Асистент':
{m['content'].replace('\n', ' ').strip()[:495]}" for m in history]) if
history else "Немає."
def format_docs(docs: list[Document]) -> str: return "\n\n---
\n\n".join([f"[Джерело {i}: {d.metadata.get('title')} |
{d.metadata.get('section_path')}]]\nURL:
{d.metadata.get('url', '')}\n{d.page_content}" for i, d in enumerate(docs,
1)])
def sse_pack(text: str) -> str: return f"data: {json.dumps({'t':
text}, ensure_ascii=False)}\n\n"
def expand_acronyms(text: str) -> str:
for acr, full in UNIVERSITY_ACRONYMS.items(): text =
re.sub(rf"(?i)\b{re.escape(acr)}\b", full, text)
return text
def lemmatize_query(query: str) -> str:
words = re.findall(r"(?u)[\w']+", query.lower()); lemmas =
set(morph.parse(w)[0].normal_form for w in words) - set(words)
return f"{query} {' '.join(lemmas)}" if lemmas else query
async def contextualize_question(input_text: str, history_text: str) -
> str:
if history_text == "Немає.": return input_text
try:
await asyncio.wait_for(LLM_SEMAPHORE.acquire(),
timeout=SITE_LLM_TIMEOUT)
try: return (await history_chain.ainvoke({"history_text":
history_text, "input": input_text})).strip() or input_text
finally: LLM_SEMAPHORE.release()
except Exception: return input_text
class BM25Index:
def __init__(self): self._docs = []; self._index = None;
self._built = False
def build(self, docs): self._docs = docs; self._index =
BM25Okapi([re.findall(r"(?u)[\w']+", d.page_content.lower()) for d in docs]);
self._built = True
def search(self, query, k): return [(self._docs[i], float(s)) for
i, s in sorted(enumerate(self._index.get_scores(re.findall(r"(?u)[\w']+",
query.lower()))), key=lambda x: x[1], reverse=True)[:k] if s > 0] if
self._built else []
_bm25_index, _bm25_loaded = BM25Index(), False
def _build_bm25_sync():
raw = vectorstore.get()

```

```

        if raw and raw.get("documents"):
            _bm25_index.build([Document(page_content=t, metadata=m) for t, m in
zip(raw["documents"], raw["metadatas"])]])
            async def _ensure_bm25():
                global _bm25_loaded
                if not _bm25_loaded:
                    await
                    asyncio.get_running_loop().run_in_executor(None, _build_bm25_sync);
                    _bm25_loaded = True
            def reciprocal_rank_fusion(v_res, b_res, k=60):
                scores, dmap = {}, {}
                for r, d in enumerate(v_res): scores[d.metadata.get("chunk_id") or
d.page_content[:80]] = scores.get(d.metadata.get("chunk_id") or
d.page_content[:80], 0) + HYBRID_VECTOR_WEIGHT * (1 / (k + r + 1));
dmap[d.metadata.get("chunk_id") or d.page_content[:80]] = d
                for r, (d, _) in enumerate(b_res):
                    scores[d.metadata.get("chunk_id") or d.page_content[:80]] =
                    scores.get(d.metadata.get("chunk_id") or d.page_content[:80], 0) +
                    HYBRID_BM25_WEIGHT * (1 / (k + r + 1)); dmap[d.metadata.get("chunk_id") or
                    d.page_content[:80]] = d
                return [dmap[u] for u in sorted(scores, key=scores.__getitem__,
reverse=True)]
            async def get_relevant_docs(question: str):
                q_emb = await asyncio.get_running_loop().run_in_executor(None,
embeddings.embed_query, question)
                try:
                    if cached := query_cache.get_similar(q_emb): return cached
                except Exception: pass
                await _ensure_bm25(); loop = asyncio.get_running_loop()
                v_docs, b_res = await
                asyncio.gather(vectorstore.as_retriever(search_kwargs={"k":
VECTOR_RECALL_K}).ainvoke(question), loop.run_in_executor(None, lambda:
_bm25_index.search(question, k=VECTOR_RECALL_K)))
                unique_docs = {d.metadata.get("chunk_id") or d.page_content[:80]:
d for d in reciprocal_rank_fusion(v_docs, b_res)}.values()
                if not unique_docs: return [], []
                scores = await loop.run_in_executor(None, lambda:
ranker.predict([[question, d.page_content] for d in unique_docs],
batch_size=4))
                res = sorted([{"idx": i, "score": float(s)} for i, s in
enumerate(scores)], key=lambda x: x["score"], reverse=True)
                f_docs = [list(unique_docs)[r["idx"]] for r in
res[:MAX_CONTEXT_CHUNKS] if r["score"] >= RERANK_THRESHOLD] or
[list(unique_docs)[r["idx"]] for r in res[:min(3, len(res))]]
                o_urls = list(dict.fromkeys([d.metadata.get("url") for d in f_docs
if "http" in d.metadata.get("url", "")]))
                try: query_cache.set(question, f_docs, o_urls, q_emb)
                except Exception: pass
                return f_docs, o_urls
            async def chat_stream_generator(question: str, history: list[dict] =
[], request: Optional[Request] = None):
                c_inp = re.sub(r'(?i)(system|user|assistant):', '',
re.sub(r'<[^>*>|[[^\\]]*\\|\\{[^\\]}*\\}', '', question).strip())
                token = secrets.token_hex(4).upper(); tag = f"USER_BLOCK_{token}"
                h_text = format_history_text(history)
                s_query = lemmatize_query(expand_acronyms(c_inp) if
request_counter.size >= 5 else await contextualize_question(c_inp,
h_text)).strip()
                if not s_query: yield sse_pack("Будь ласка, сформулируйте запитання
чіткіше."); yield "data: [DONE]\n\n"; return
                docs, o_urls = await get_relevant_docs(s_query)
                if not docs: yield sse_pack(MSG_NO_CONTEXT_FOUND); yield "data:
[DONE]\n\n"; return
                try:
                    request_counter.increment()

```

```

        if request_counter.size > 1: yield sse_pack(f"\n⌚ Запит в
черпі ({request_counter.size - 1} перед вами)...\n\n")
        await asyncio.wait_for(LLM_SEMAPHORE.acquire(),
timeout=SITE_LLM_TIMEOUT)
        try:
            full = ""
            async for chunk in qa_chain.astream({"context":
format_docs(docs), "history_text": h_text, "question":
expand_acronyms(c_inp), "start_tag": f"<{tag}>", "end_tag": f"</{tag}>"}):
                if request and await request.is_disconnected(): break
                full += chunk
                if len(full) > 30 and check_dlp_violation(full): yield
sse_pack("\n\n[DLP Block]"); break
                yield sse_pack(chunk)
                if o_urls and not any(p in full.lower() for p in ["межі
мєї компетенції"]): yield sse_pack((" \n\n**Можливо, відповідь є тут:**\n" if
any(p in full.lower() for p in ["на жаль", "не знайшов"]) else
"\n\n**Джерела:**\n") + "\n".join([f"- {u}" for u in o_urls]))
            finally: LLM_SEMAPHORE.release()
        finally: request_counter.decrement(); yield "data: [DONE]\n\n"

```

Б.8 Фрагмент файлу doc_rag.py

```

doc_vectorstore = Chroma(persist_directory=DOCS_DB_PATH,
embedding_function=embeddings, collection_metadata={"hnsw:space": "cosine"})
async def ingest_document(file_path: str, filename: str):
    try: docs = PyPDFLoader(file_path).load() if
file_path.endswith(".pdf") and sum(len(d.page_content) for d in
PyPDFLoader(file_path).load()) >= 100 else ocr_file(file_path)
    except Exception: return False
    if not docs: return False
    splits = RecursiveCharacterTextSplitter(chunk_size=CHUNK_SIZE,
chunk_overlap=CHUNK_OVERLAP).split_documents(docs)
    for s in splits:
        s.metadata["source"] = filename
        if "page" in s.metadata and s.metadata.get("type") !=
"pdf_ocr": s.metadata["page"] = int(s.metadata["page"]) + 1
        await doc_vectorstore.aadd_documents(splits)
    global _doc_bm25_loaded; _doc_bm25_loaded = False;
    query_cache.clear(); return True
    class DocBM25Index:
        def __init__(self): self._docs = []; self._index = None;
self._built = False
        def build(self, docs): self._docs = docs; self._index =
BM25Okapi([re.findall(r"(?u)[\w']+", d.page_content.lower()) for d in
docs]); self._built = True
        def search(self, query, k): return [(self._docs[i], float(s)) for
i, s in sorted(enumerate(self._index.get_scores(re.findall(r"(?u)[\w']+",
query.lower()))), key=lambda x: x[1], reverse=True)[:k] if s > 0] if
self._built else []
        _doc_bm25_index, _doc_bm25_loaded = DocBM25Index(), False
        def _build_doc_bm25_sync():
            raw = doc_vectorstore.get()
            if raw and raw.get("documents"):
                _doc_bm25_index.build([Document(page_content=t, metadata=m) for t, m in
zip(raw["documents"], raw["metadatas"])])
        async def _ensure_doc_bm25():
            global _doc_bm25_loaded

```

```

        if not _doc_bm25_loaded:
            await
            asyncio.get_running_loop().run_in_executor(None, _build_doc_bm25_sync);
        _doc_bm25_loaded = True
        async def hybrid_doc_search(query: str, k: int = DOC_RERANK_TOP_K):
            await _ensure_doc_bm25(); loop = asyncio.get_running_loop()
            v_docs, b_res = await
            asyncio.gather(doc_vectorstore.as_retriever(search_kwargs={"k":
DOC_VECTOR_RECALL_K}).ainvoke(query), loop.run_in_executor(None, lambda:
_doc_bm25_index.search(query, k=DOC_VECTOR_RECALL_K)))
            fused = reciprocal_rank_fusion(v_docs, b_res)
            if not fused: return []
            scores = await loop.run_in_executor(None, lambda:
ranker.predict([[query, d.page_content] for d in
fused[:DOC_VECTOR_RECALL_K]], batch_size=4))
            res = sorted([{"idx": i, "score": float(s)} for i, s in
enumerate(scores)], key=lambda x: x["score"], reverse=True)
            return [fused[r['idx']] for r in res[:k] if r['score'] >
DOC_RERANK_THRESHOLD]
        doc_chain = ChatPromptTemplate.from_template(DOC_QA_SYSTEM_PROMPT) |
llm | StrOutputParser()
        def format_page_ranges(pages: list[int]) -> str:
            if not pages: return ""
            p, r, s = sorted(list(set(pages))), [],
sorted(list(set(pages))) [0]; prev = s
            for i in range(1, len(p)):
                if p[i] != prev + 1: r.append(str(s) if s == prev else f"{s}-
{prev}"); s = p[i]
                prev = p[i]
            r.append(str(s) if s == prev else f"{s}-{prev}"); return ",
".join(r)
        async def doc_chat_generator(question: str, request: Optional[Request]
= None) -> AsyncGenerator[str, None]:
            c_inp = re.sub(r'(?i)(system|user|assistant):', '',
re.sub(r'<[>]*|\\[[^\\]]*\\|\\{[^\\]}*\\}', '', question).strip())
            token = secrets.token_hex(4).upper(); tag = f"USER_BLOCK_{token}"
            docs = await hybrid_doc_search(c_inp)
            if not docs: yield sse_pack("Інформація відсутня у завантажених
файлах."); yield "data: [DONE]\n\n"; return
            ctx = "\n\n".join([f"--- ДЖЕРЕЛО: {d.metadata.get('source')} |
СТОПІНКА: {d.metadata.get('page', 0)} ---\n{d.page_content}\n" for d in
docs])
            try:
                request_counter.increment()
                if request_counter.size > 1: yield sse_pack(f"\n ⌚ Запит в
черзі ({request_counter.size - 1} перед вами)...\n\n")
                await
                asyncio.wait_for(LLM_SEMAPHORE.acquire(),
timeout=DOC_LLM_TIMEOUT)
                try:
                    full = ""
                    async for chunk in doc_chain.astream({"context": ctx,
"question": c_inp, "start_tag": f"<{tag}>", "end_tag": f"</{tag}>"}):
                        if request and await request.is_disconnected(): break
                        full += chunk
                        if len(full) > 30 and check_dlp_violation(full): yield
sse_pack("\n\n[DLP Block]"); break
                        yield sse_pack(chunk)
                    if not any(p in full.lower() for p in ["межі моєї
компетенції"]):
                        yield sse_pack("\n\n---\n**Можливо, відповідь є
тут:**\n" if any(p in full.lower() for p in ["на жаль"]) else "\n\n---
\n**Джерела:**\n")
                    s_map = {}

```

ДОДАТОК В
Слайди презентації

ДИПЛОМНА КВАЛІФІКАЦІЙНА РОБОТА БАКАЛАВРА НА ТЕМУ

Розроблення та дослідження програмного забезпечення діалогової системи консультування користувачів вебресурсу

Виконав: ст. групи КНТ-132

Максим СЕВЕРИН

Керівник: д-р філософ. доцент

Сергій ЛЕОЩЕНКО

2026

Рисунок В.1 – Слайд 1

Об'єкт, предмет та мета роботи

2

Об'єкт дослідження — процес розроблення та програмної реалізації програмного забезпечення інтелектуальних діалогових систем для вебресурсів.

Предмет дослідження — методи та програмні засоби генерації з доповненим пошуком для обробки природномовних запитів.

Метою роботи є підвищення швидкості автоматизованого інформаційно-консультаційного обслуговування користувачів вебресурсів за рахунок створення автономної діалогової системи на базі локальних мовних моделей.

Рисунок В.2 – Слайд 2

Постановка завдання

3

Завдання роботи:

- проаналізувати існуючі рішення для автоматизованого консультування користувачів вебресурсів;
- визначити вимоги до розробки;
- обґрунтувати вибір технологій для розробки складових системи;
- спроєктувати архітектуру системи та алгоритми;
- реалізувати інтерфейси користувача та адміністратора;
- провести тестування, дослідити точність гібридного пошуку та надійність захисту створеної платформи.

Рисунок В.3 – Слайд 3

Порівняння існуючих аналогів

4

Критерій порівняння	<u>Google Dialogflow</u>	<u>Chatbase</u>	<u>SiteGPT</u>
<u>Архітектурний підхід</u>	<u>Сценарний</u>	<u>Генеративний</u>	<u>Генеративний</u>
Вартість	<u>Динамічна</u>	від \$19 на місяць	від \$49 на місяць
Метод наповнення бази знань	<u>Ручний</u>	<u>Напівавтоматичний</u>	Автоматичний
Гнучкість алгоритмів пошуку	<u>Висока</u>	<u>Низька</u>	<u>Низька</u>
<u>Тип розгортання</u>	<u>Хмарний</u>	<u>Хмарний</u>	<u>Хмарний</u>
<u>Легкість впровадження</u>	<u>Середня</u>	<u>Висока</u>	<u>Висока</u>
Рівень конфіденційності даних	<u>Низький</u>	<u>Низький</u>	<u>Низький</u>

Рисунок В.4 – Слайд 4

Порівняння мов програмування

5

Критерій порівняння	Python	Go	Java
Поріг входу	<u>Низький</u>	<u>Середній</u>	<u>Високий</u>
Зрілість екосистеми для ШІ	<u>Висока</u>	<u>Низька</u>	<u>Середня</u>
Продуктивність	<u>Середня</u>	<u>Висока</u>	Висока
Робота з <u>багатопотоковістю</u>	<u>Обмежена</u>	<u>Висока</u>	<u>Висока</u>
<u>Підтримка векторних баз даних</u>	<u>Повна</u>	<u>Часткова</u>	<u>Повна</u>
Якість документації	Висока	<u>Середня</u>	Висока
Спільнота	Дуже велика	Велика, але менш активна	Середня

Рисунок В.5 – Слайд 5

Порівняння вебфреймворків

6

Критерій порівняння	FastAPI	Flask	Django
<u>Архітектурний підхід</u>	<u>Мікросервісний</u>	<u>Мікросервісний</u>	<u>Мікросервісний</u>
Підтримка асинхронності	<u>Повна нативна</u>	<u>Часткова</u>	<u>Часткова</u>
Продуктивність обробки	<u>Дуже висока</u>	<u>Середня</u>	Середня
Складність освоєння	<u>Середня</u>	<u>Низька</u>	<u>Висока</u>
Наявність вбудованої ORM	<u>Відсутня</u>	<u>Відсутня</u>	<u>Вбудована</u>

Рисунок В.6 – Слайд 6

7

Порівняння векторних баз даних

Критерій порівняння	ChromaDB	Pincode	Milvus
Тип розгортання	Локальне	Хмарне	Локальне
Рівень конфіденційності даних	Високий	Низький	Високий
Складність налаштування	Низька	Низька	Висока
Вимоги до апаратних ресурсів	Низькі	Відсутні	Високі
Масштабованість	Вертикальна	Горизонтальна	Горизонтальна
Захист даних	Повний контроль	Дані на серверах провайдера	Повний контроль
Вартість використання	Безкоштовно	від \$50 на місяць	Безкоштовно (але високі витрати на сервери)

Рисунок В.7 – Слайд 7

8

Порівняння систем розгортання мовних моделей

Критерій порівняння	OpenAI API	Hugging Face	Ollama
Тип розгортання	Хмарне	Локальне	Локальне
Конфіденційність даних	Низька	Висока	Висока
Вартість експлуатації	Плата за кожен запит	Безкоштовна	Безкоштовна
Вимоги до обладнання	Відсутні	Надвисокі	Середні
Складність інтеграції	Низька	Висока	Низька


Рисунок В.8 – Слайд 8

Порівняння технологій інтеграції клієнтської частини

Критерій порівняння	Відокремлений застосунок	JS-модуль	Нативний плагін (CMS)
Зусилля на розгортання замовником	<u>Високі</u>	<u>Середні</u>	Низькі
Рівень універсальності рішення	<u>Середній</u>	<u>Максимальний</u>	<u>Обмежений</u>
Додаткова інфраструктура	Окремий хостинг	Зовнішній файловий сервер	Не потребує
Можливості інтеграції з сесією користувача	<u>Обмежені</u>	<u>Середні</u>	<u>Повні</u>
Вимоги до технічних навичок адміністрування	Високі	Середні	Низькі

Рисунок В.9 – Слайд 9

Архітектура системи




Діаграма клієнт-серверної архітектури


Рисунок В.10 – Слайд 10

Фізичне проектування

11



Компонентна діаграма системи




Алгоритм підготовки бази даних


Рисунок В.11 – Слайд 11

Логічне проектування

12



UML-діаграма послідовності обробки пошукового запиту



Логічна схема структур даних

Рисунок В.12 – Слайд 12

Інтерфейс користувача віджету

13





Рисунок В.13 – Слайд 13

Обробка виняткових ситуацій

14





Рисунок В.14 – Слайд 14




Рисунок В.15 – Слайд 15

16

Функціональне тестування

Сценарій тестування	Очікуваний результат	Фактичний результат	Статус
Ініціалізація <u>віджета</u> на сторінці	<u>Віджет</u> завантажується асинхронно, не блокуючи завантаження основного контенту сайту	DOM-дерево формується без затримок, <u>віджет</u> відображається <u>коректно</u>	Успішно
Обробка довгого тексту	Поле вводу автоматично масштабується по висоті під час набору об'ємного запиту	Текстове поле збільшується до заданого ліміту, після чого з'являється <u>скрол</u>	Успішно
Точність семантичного пошуку	Запит із використанням синонімів успішно знаходить <u>релевантний</u> фрагмент у базі	<u>Векторна</u> база повертає <u>правильні</u> документи	Успішно
Атрибуція першоджерел	Система <u>додає</u> клікабельні <u>посилання</u> на <u>джерела</u> , які <u>були</u> використані як контекст	Блок метаданих формується <u>коректно</u> , посилання ведуть на цільові сторінки	<u>Успішно</u>
Синхронізація бази знань	Примусовий запуск індексації з <u>адмін</u> -панелі оновлює вектори в БД	Старі записи замінюються новими, процес відображається в <u>логах</u> сервера	Успішно

Рисунок В.16 – Слайд 16

Висновки

17

У результаті виконання дипломної кваліфікаційної роботи бакалавра мету щодо підвищення швидкості автоматизованого інформаційно-консультаційного обслуговування користувачів вебресурсів було досягнуто.

Для цього було виконано наступні завдання:

- проаналізовано існуючі рішення для автоматизованого консультування користувачів вебресурсів;
- визначено вимоги до розробки;
- обґрунтовано вибір технологій для розробки складових системи;
- спроектовано архітектуру системи та алгоритми;
- реалізовано інтерфейси користувача та адміністратора;
- проведено тестування, досліджено точність гібридного пошуку та надійність захисту створеної платформи.

Усі поставлені завдання дипломної кваліфікаційної роботи були виконані повністю.

Створений програмний продукт є завершеним, безпечним і масштабованим рішенням. Розроблена діалогова система відповідає всім вимогам технічного завдання і є повністю готовою до впровадження у реальні вебресурси.

Рисунок В.17 – Слайд 17