

В. Б. Мокін, А. В. Лосенко



Генеративний штучний інтелект

Міністерство освіти і науки України
Вінницький національний технічний університет

В. Б. Мокін, А. В. Лосенко

ГЕНЕРАТИВНИЙ ШТУЧНИЙ ІНТЕЛЕКТ

Електронний навчальний посібник

Вінниця
ВНТУ
2026

УДК [004.65-047.44+004.8/.9](075.8)

М 74

Рекомендовано до видання Вченою радою Вінницького національного технічного університету Міністерства освіти і науки України (протокол № 15 від 25.06.2026 р.).

Рецензенти:

Литвин В. В., доктор технічних наук, професор

Бісікало О. В., доктор технічних наук, професор

Штофель Д.Х., кандидат технічних наук, доцент

Мокін, В. Б.

М 74 Генеративний штучний інтелект : навчальний посібник [Електронний ресурс] / В. Б. Мокін, А. В. Лосенко – Він-ниця : ВНТУ, 2026. – (PDF, 115 с.)

ISBN 198-617-8927-04-02

У навчальному посібнику викладено теоретичні відомості про основні поняття, методи і засоби, пов'язані з генеративним штучним інтелектом (ГШІ). Акцент зроблено на теоретичних та практичних аспектах розв'язання задач з використанням ГШІ за методологією системного аналізу та науки про дані. Наведено багато посилань на корисні ресурси, де можна більш глибокого опанувати практичні аспекти реалізації технологій ГШІ для створення рекомендаційних інформаційних систем та систем підтримки прийняття рішень. Наведено перелік контрольних запитань для перевірки набутих теоретичних знань та практичних навичок.

Посібник рекомендується для здобувачів вищої освіти, які навчаються за спеціальностями F4 «Системний аналіз та наука про дані», 124 «Системний аналіз», F6 «Інформаційні системи і технології» та 126 «Інформаційні системи та технології» I, II та III рівнів при вивченні таких дисциплін: «Генеративний штучний інтелект», «Машинне навчання та інтелектуальний аналіз даних», «Інформаційні технології моніторингу та аналізу стану складних систем», «Інформаційні інтелектуальні технології», «Інтернет речей та інтелектуальний аналіз даних», «Системний аналіз», «Інформаційні технології обробки зображень», «Аналіз даних», «Аналіз даних та знань», «Інформаційні технології аналізу даних», «Агентна інженерія програмного забезпечення», а також – для студентів, які проходять навчальну, виробничу і переддипломну практику, та для педагогічної практики аспірантів.

УДК [004.65-047.44+004.8/.9](075.8)

ISBN 198-617-8927-04-02

© ВНТУ, 2026

ЗМІСТ

ВСТУП.....	5
1 ГЕНЕРАТИВНИЙ ШІ ЯК ОБ'ЄКТ І ІНСТРУМЕНТ СИСТЕМНОГО АНАЛІЗУ.....	8
1.1 Еволюція генеративного штучного інтелекту та сучасний стан технологій.....	8
1.1.1 Ранній етап генерування природномовного тексту.....	8
1.1.2 Ранній етап генерування зображень.....	11
1.1.3 Ранній етап генерування програмного коду.....	11
1.1.4 Мультимодальні моделі та сучасний етап генеративного штучного інтелекту.....	13
1.1.5 Агентні системи генеративного штучного інтелекту та перспективи їх розвитку.....	16
1.2 Промпт-інжиніринг.....	18
1.3 Інфраструктура генеративного ШІ у системному аналізі.....	21
Можливі теми практичних і лабораторних завдань.....	23
Контрольні питання.....	24
2 ПОДАННЯ ТА АНАЛІЗ ДАНИХ І ЗНАНЬ У ГЕНЕРАТИВНОМУ ШТУЧНОМУ ІНТЕЛЕКТІ.....	26
2.1 Дані, інформація та знання в системах генеративного штучного інтелекту.....	26
2.2 Подання знань у системному аналізі: онтології, семантичні мережі, векторні простори та нейромережі.....	28
2.3 Аналіз семантичної подібності та релевантності в генеративних задачах.....	32
2.4 Формування корпусів і датасетів для генеративного штучного інтелекту.....	35
Контрольні питання.....	37
3 ГЕНЕРАТИВНІ МОДЕЛІ ТА ВЕЛИКІ МОВНІ МОДЕЛІ В СИСТЕМНОМУ АНАЛІЗІ.....	39
3.1 Великі мовні моделі як моделі для генерування тексту та роботи зі знаннями.....	39
3.2 Трансформерні архітектури та механізм уваги.....	42
3.3 Адаптація генеративних моделей до прикладних задач.....	45
3.4 Моделі для генерування зображень.....	48
3.5 Генерація відео у прикладних задачах. Мультимодальні генеративні моделі.....	52
Можливі теми практичних і лабораторних завдань.....	56
Контрольні питання.....	58
4 ГЕНЕРАЦІЯ, ВЗАЄМОДІЯ ТА АГЕНТНІ АРХІТЕКТУРИ.....	59
4.1 Генерація як функціональний механізм у прикладних системах.....	59
4.2 Чат-боти та AI-асистенти як інтерфейс взаємодії з генеративним ШІ..	61
4.3 Генеративні агенти та агентні архітектури.....	63

4.4 Інтерфейси та веб-застосування для генеративних агентів	68
4.5 AI-системи підтримки прийняття рішень та рекомендаційні системи..	70
Можливі теми практичних і лабораторних завдань	73
Контрольні питання	74
5. ОЦІНЮВАННЯ ЯКОСТІ, НАДІЙНОСТІ ТА ЕТИЧНОСТІ ГЕНЕРАТИВНОГО ШІ	75
5.1 Критерії та показники якості генеративного штучного інтелекту.....	75
5.2 Бенчмарки для великих мовних моделей	78
5.3 Агент-бенчмарки та оцінювання агентних систем	81
5.4 Оптимізація систем генеративного штучного інтелекту	83
5.5 Етичні, правові та соціальні аспекти генеративного ШІ	86
Можливі теми практичних і лабораторних завдань	90
Контрольні питання	92
6. КУРСОВИЙ ПРОЄКТ: СТВОРЕННЯ ВЛАСНОГО AI-АГЕНТА .	94
6.1 Загальні положення.....	94
6.2 Структура курсового проєкту	94
6.3 Зміст пояснювальної записки.....	95
6.4 Рекомендована послідовність розробки агента в курсовому проєкті....	96
6.5 Приклад практичного завдання для курсового проєкту	97
6.6 Вимоги до оформлення.....	98
6.7 Тематика курсових проєктів	99
6.8 Порядок захисту та критерії оцінювання	100
ДОДАТКИ ДО РОЗДІЛУ 6	102
ЛІТЕРАТУРА.....	108

Мета даного посібника – ознайомити студентів та аспірантів із основними поняттями, пов'язаними з розв'язанням задач системного аналізу та науки про дані з використанням систем і технологій генеративного штучного інтелекту, а також – зі створенням систем, засобів і технологій генеративного штучного інтелекту з використанням методології системного аналізу та науки про дані, необхідними для розв'язання реальних задач різної складності, наприклад створення рекомендаційних інформаційних систем та систем підтримки, для прийняття рішень з використанням інтелектуальних агентів.

Посібник має чітку практичну спрямованість, тобто весь матеріал викладений в контексті розв'язання прикладних задач. Автори не ставили за мету дублювати класичні видання з теорії штучного інтелекту, чи машинного навчання, чи науки про дані. Чимало визначень наведено в авторській інтерпретації. Інформаційні технології описані максимально стисло, але достатньо, щоб розуміти відмінності між ними і щоб можна було вибрати оптимальні варіанти для тієї чи іншої задачі. В тексті є багато посилань на різні Python-ноутбуки, документацію, GitHub- та інші ресурси з програмними рішеннями щодо кожної теми. Крім того, є багато посилань на сучасні складні програмні рішення, які неможливо отримати, користуючись одними AI-асистентами чи документацією. У кожному розділі є можлива тематика практичних занять та лабораторних робіт. В кінці наведено методичні вказівки щодо курсового проєкту з дисципліни «Генеративний штучний інтелект» для магістерського рівня підготовки.

Оригінальним є структурування посібника, відповідно до етапів методології системного аналізу щодо розв'язання задач: етап 1 – постановка задачі, етап 2 – виділення об'єкта з навколишнього середовища шляхом збирання та формалізації даних, формування датасету, етап 3 – побудова моделей, етап 4 – аналіз даних з використанням цих моделей, етап 5 – використання отриманих результатів для створення рекомендаційних інформаційних систем та систем підтримки прийняття рішень. Хоча, для ГШІ етап 4 окремо виділити важко, оскільки аналіз здійснюється, як правило, з використанням систем, створених на етапі 5. Також, увага буде приділена правовим та етичним аспектам використання ГШІ. Загалом, посібник складається з двох частин, по 3 розділі у кожній:

Частина 1. «ФОРМУВАННЯ ТА ПОБУДОВА СИСТЕМ ГЕНЕРАТИВНОГО ШІ» містить такі розділи:

1. Генеративний ШІ як об'єкт і інструмент системного аналізу.
2. Подання та аналіз даних і знань у генеративному штучному інтелекті.
3. Генеративні моделі та великі мовні моделі в системному аналізі.

Частина 2. «ФУНКЦІОНУВАННЯ, ОЦІНЮВАННЯ ТА ПРОЄКТУВАННЯ АГЕНТІВ».

4. Генерація, взаємодія та агентні архітектури.
5. Оцінювання якості, надійності та етичності генеративного ШІ.
6. Курсовий проєкт: створення власного AI-агента.

Як видно, розділи 1-3 відповідають згаданим вище етапам 1-3 системного аналізу, а етапи 4 і 5 поєднані у розділі 4.

Головна увага буде приділена особливостям саме генеративного штучного інтелекту, щоб не дублювати текст посібників [1, 2] одного з авторів цього посібника, де доволі розлого викладено все про поняття і технології машинного навчання та інтелектуального аналізу даних з посиланням на декілька сотен нотбуків і ресурсів станом на 2024 р.

Посібник буде корисним здобувачам вищої освіти, які навчаються за спеціальностями 124 «Системний аналіз», F4 «Системний аналіз та наука про дані», 126 «Інформаційні системи та технології» та F6 «Інформаційні системи і технології» I, II та III рівнів при вивченні таких дисциплін: «Інформаційні технології аналізу даних», «Машинне навчання та інтелектуальний аналіз даних», «Інформаційні технології моніторингу та аналізу стану складних систем», «Інформаційні інтелектуальні технології», «Інтернет речей та інтелектуальний аналіз даних», «Інтелектуальний аналіз даних», «Системний аналіз», «Інформаційні технології обробки зображень», «Технології машинного навчання», «Аналіз зображень», «Смарт-технології», «Аналіз даних», «Аналіз даних та знань», «Інформаційні технології аналізу даних», «Агентна інженерія програмного забезпечення», а також – для студентів, які проходять навчальну, виробничу і переддипломну практику, та для педагогічної практики аспірантів. Матеріал посібника може бути корисним і для слухачів другої вищої освіти з системного аналізу, науки про дані, з інформаційних систем і технологій, також студентам інших спеціальностей, які недостатньо володіють основними знаннями та навичками роботи у цій сфері.

Під час підготовки посібника інструменти генеративного ШІ (ChatGPT, Claude, Gemini) використовувалися як допоміжний засіб для підготовки чернеткових фрагментів програмного коду за авторськими алгоритмами й вимогами, створення окремих ілюстративних рисунків за авторськими описами, мовного редагування, факт-чекінгу та перевірки коректності окремих визначень. Ілюстративні рисунки, створені із застосуванням ШІ, позначені у підписах до них (використана модель та дата генерування, як це прийнято). Структура посібника, добір тем, методичні пояснення, приклади, остаточні формулювання, належать авторам. Також автори здійснювали перевірку джерел і несуть відповідальність за зміст в цілому.

Колектив авторів висловлює подяку доктору технічних наук, професору кафедри системного аналізу та інформаційних технологій ВНТУ, проф. [Мокіну О. Б.](#) за цінні поради з різних аспектів.

Навчальний посібник за такою концепцією викладення ГШІ за методологією системного аналізу публікується вперше. Просимо надсилати

коментарі, зауваження та рекомендації щодо його вдосконалення на пошту sait@vntu.edu.ua кафедри системного аналізу та інформаційних технологій ВНТУ, де працюють автори посібника. Незабаром планується друге видання (доповнене та виправлене), в якому будуть усунені усі виявлені недоліки і суттєво додані приклади ефективного застосування наведених у посібнику методів, моделей та технологій.

1 ГЕНЕРАТИВНИЙ ШІ ЯК ОБ’ЄКТ І ІНСТРУМЕНТ СИСТЕМНОГО АНАЛІЗУ

1.1 Еволюція генеративного штучного інтелекту та сучасний стан технологій

1.1.1 Ранній етап генерування природномовного тексту

Як відомо, одними з основних об’єктів системного аналізу є експертні системи та системи підтримки прийняття оптимальних рішень або оптимальні системи підтримки прийняття рішень (СППР), для створення яких слід створити чи вибрати оптимальні моделі, для ідентифікації (тюнінгу) яких слід зібрати та обробити дані, котрі характеризують задану, як правило складну, систему і фактори, що впливають на неї. Для всіх цих етапів розроблено багато теоретичних і практичних рішень з різним ступенем автоматизації та ефективності. Однак, оскільки так звана «Особа, що приймає рішення» (ОПР), це – як правило, людина (хоча, наприклад, в системах Інтернету речей це може бути й інша система), а людина звикла оперувати текстом, то найбільш цікавим напрямком завжди була можливість роботи з природномовним текстом і на вході, і на виході таких СППР.

Перші реалізації таких СППР пов’язані з *символьними* підходами, коли люди проектували продукційні правила, бази знань, онтології, семантичні мережі, фрейми та інші конструкції, де чітко вписували всі формалізовані ними знання, а генерування рекомендацій чи команд здійснювалось за шаблонами, елементи яких розраховували за певним алгоритмом. Такі системи досі залишаються важливими у предметних областях, де потрібні формальна строгість, пояснюваність (інтерпретованість), контрольованість і відтворюваність висновку, наприклад у системах з великим ризиком помилок першого і другого роду (медичні, юридичні, автоматизація роботи об’єктів критичної інфраструктури тощо). Деякі з цих моделей досі використовуються в технологіях і системах генеративного штучного інтелекту (ГШІ) для формування датасетів для навчання чи для тестування АІ-систем. Але ці підходи погано масштабуються, важко адаптуються до природномовного тексту, потребують значних витрат часу та зусиль людей-експертів на їх створення і налаштування під задану предметну область і задачу.

Згодом розвинулись новіші підходи, засновані на статистичних моделях (уніграми, N-грами, методи їх згладжування, інтерполяції тощо). *Статистична мовна модель* — це модель, яка оцінює, наскільки ймовірною є певна послідовність слів у тексті, використовуючи статистику їх уживання у корпусі текстів. *Корпус текстів* — це велика колекція текстів, як правило, природномовних однією мовою. На великих корпусах текстів аналізувались закономірності щодо того, який токен (чи слово) найчастіше стоять в реченнях до і після заданих. Наприклад, яка ймовірність того, що після слова

«прийняття» у тексті буде йти слово «рішень» або після «штучний» — «інтелект»? Ці методи та моделі краще масштабувались та враховували особливості природної мови, у порівнянні з символічними методами і конструкціями, але вони не забезпечували достатнє охоплення усіх цих особливостей, враховували тільки обмежений контекст, не узагальнювали знання та ін. Однак, цей підхід вже почав розглядати текст як послідовність слів або tokenів, як певний стохастичний процес їх появи, ввів поняття корпусу і контексту та постановку задачі передбачення наступного слова чи токена, що заклало основу сучасних технологій NLP.

Для досліджень тексту використовується популярний метод TF-IDF, більш детально описана у посібнику [1] одного з авторів.

Статистичні методи досі використовуються, наприклад, для формування фічерів, які характеризують текст, для різних класифікаційних задач [2]. Наприклад, у Kaggle-змаганні «[LLM - Detect AI Generated Text](#)» (2024), де треба було визначати авторство тексту (людина чи AI?), [переможне рішення](#) та й більшість рішень, зокрема й одного з авторів цього посібника, використовували N-грами: `TfidfVectorizer(ngram_range=(3, 5), lowercase=False)` [458].

Потім було запропоновано перейти від окремих елементів тексту (слів, tokenів) та їх частот до так званого *безперервного простору ознак*, в якому токени, слова, словосполучення й контекст подаються у вигляді числових векторів. Кодування здійснювалось з використанням нейромережових моделей RNN та LSTM [3]. Статистичні закономірності мови та частина фактологічної інформації не зберігалися у вигляді явних правил, а були неявно закодовані у параметрах нейромережі. З'явилась можливість деякого узагальнення семантично подібних слів. Це дозволяло передбачати наступне слово, або відновлювати пропущені слова, або будувати внутрішнє подання всього контексту, хоча точність ще була доволі низькою. Крім того, нейромережі не могли зберігати віддалений контекст, хоча LSTM це робила краще за RNN. Сучасні технології роботи з природномовним текстом досі використовують безперервний простір ознак, збереження знань у вагах нейромережі, семантичну подібність та ту ж постановку задач.

Револьюційно новим тоді був перехід до *ембедінгу*, яким є числовий вектор, що представляє слово, токен, словосполучення або інший елемент у багатовимірному просторі так, щоб схожі за змістом об'єкти мали близькі вектори. Це називають *розподіленим поданням*, оскільки зміст слова не зберігається в одному окремому символі або одному числі, а розподіляється між багатьма координатами вектора. На цьому етапі виділяються статті 2013 року [4, 5] Томаса Міколова (Google Inc.) зі співавторами, які на прикладі власної моделі (точніше – комплексу моделей) Word2Vec переконливо і наче на практиці продемонстрували, що семантичні й синтаксичні відношення добре відображаються у векторному просторі (рис. 1.1).




Рисунок 1.1 – Ілюстрація векторного простору з ембедінгів, яка демонструє наявність геометричного зв'язку між семантично близькими поняттями [4]

Зазвичай, усі цитують саме роботу [5] як опорну щодо поняття розподіленого векторного простору ембедінгів та того, як їх геометричні співвідношення повторюють семантичні відношення між їх значеннями – це один з фундаментальних принципів сучасних технологій NLP. Більш детально про цю концепцію – див. у розд. 2. Важливо, зазначити, що концепція ембедінгів була запроваджена до 2013 р., але Word2Vec показав, що їх можна ефективно навчати на великих корпусах і використовувати для відображення семантичної та синтаксичної близькості слів.

Однак, модель Word2Vec була недосконалою. На датасеті, наведеному на рис. 1.2, вона забезпечила точність 60%, а на подібних – дещо меншу, що у 2013 році було вражаюче високою точністю [5].

Type of relationship	Word Pair 1		Word Pair 2	
Common capital city	Athens	Greece	Oslo	Norway
All capital cities	Astana	Kazakhstan	Harare	Zimbabwe
Currency	Angola	kwanza	Iran	rial
City-in-state	Chicago	Illinois	Stockton	California
Man-Woman	brother	sister	grandson	granddaughter
Adjective to adverb	apparent	apparently	rapid	rapidly
Opposite	possibly	impossibly	ethical	unethical
Comparative	great	greater	tough	tougher
Superlative	easy	easiest	lucky	luckiest
Present Participle	think	thinking	read	reading
Nationality adjective	Switzerland	Swiss	Cambodia	Cambodian
Past tense	walking	walked	swimming	swam
Plural nouns	mouse	mice	dollar	dollars
Plural verbs	work	works	speak	speaks

Рисунок 1.2 – Приклади 5 типів семантичних і 9 типів синтаксичних запитань у тестовому наборі Semantic-Syntactic Word Relationship, на яких розробники тестували модель Word2Vec [5]

Згодом у 2014 р. на більшому датасеті була створена дещо досконаліша модель GloVe, але вона мала інші недоліки, серед основних з яких – статичні ембедінги, які не залежать від контексту слова в реченні.

1.1.2 Ранній етап генерування зображень

Раніше автоматичне генерування зображень було доступно, переважно, в потужних графічних пакетах, але у 2013-2014 рр. поширення набули 3 технології на основі нейромереж:

- змагальні генеративні мережі «Generative Adversial Nets» (так їх називали автори) або «Generative Adversial Networks» (так їх називають зараз) (GANs);
- варіаційний автоенкодер («Variational Autoencoder») (VAE);
- дифузійні моделі («Diffusion Models») (DM).

GAN були запропоновані у 2014 р. у статті [6] і пов'язані на змаганні двох моделей – генератора і дискримінатора. Перша з них генерує фейки, а потім подає на другу, разом із реальними, і та намагається розпізнати де фейк. Результат використовується для удосконалення генератора, який з часом генерує все правдоподібніші зразки. Особливо ефективною була «StyleGAN2», латентний простір якої, серед іншого, дозволяв зручно змінювала лише певні атрибути зображення (фон, вік, колір шкіри, елементи обличчя, одяг людини, окуляри тощо) (про це більш детально буде у підрозд. 3.4). Але зображення мало певні характерні візерунки, тому потужні детектори не просто детектували фейки, а й визначали вид архітектури GAN, були й інші недоліки щодо тривалості та якості генерації.

VAE були запропоновані в 2013-2014 роках і, по суті, імітують здатність професійного художника пам'ятати основні риси певного об'єкта (собаки, кішки, дерева, автомобіля тощо) та відтворювати їх, коли об'єкти треба відобразити. VAE навчається стискати зображення у латентний простір і відновлювати їх із цього простору. Модель задає ймовірнісний розподіл у латентному просторі, тому може генерувати нові варіанти об'єктів, схожі на навчальні приклади.

Дифузійні моделі були запропоновані у 2015 р., але довго розвивались і перетворились на найбільш передові дещо з часом, після суттєвих технологічних удосконалень, про що буде більш детально у підрозд 3.4. Модель навчається розмивати зображення так, щоб перетворити на «білий шум», а потім відтворює зворотній алгоритм і за текстовим промптом шум перетворює на задану картинку. Чим більше ітерацій – тим більша якість. Дещо схоже на стиль художників флуд-арт, але з реалістичними зображеннями, а не як у Д. Поллока.

1.1.3 Ранній етап генерування програмного коду

Перш ніж поява у 2021 році моделей Codex та AI-асистента GitHub Copilot на їх основі поклала початок ері повноцінних AI-асистентів для програмування, протягом 2017–2021 років існував ранній, але методологічно

важливий етап. Інструменти цього періоду виконували вужчу задачу: статистичне автодоповнення на рівні рядка або функції. Проте саме ці спроби сформували уявлення галузі про те, яким має бути AI-помічник у програмуванні.

Програмний код має властивості, що роблять його привабливою ціллю для мовних моделей: він є текстовою послідовністю токенів, суворо підкоряється граматиці (синтаксису), рясніє повторюваними патернами і доступний у величезних обсягах через публічні репозиторії. Мільярди рядків коду на GitHub, Stack Overflow і відкритих навчальних датасетах створили ідеальне живильне середовище для статистичного навчання. Зрозуміло, що дослідники ще до появи трансформерних архітектур намагались застосувати мовні моделі до цієї задачі, зокрема з використанням рекурентних нейронних мереж (LSTM) [7].

У липні 2018 року Microsoft випустила *IntelliCode* — розширення для Visual Studio, що стало першим широко доступним інструментом AI-асистованого написання коду від великої технологічної компанії [8]. На відміну від класичного *IntelliSense*, що просто впорядковував методи за алфавітом, *IntelliCode* навчався на тисячах публічних GitHub-репозиторіїв з рейтингом понад 100 зірок і пропонував *контекстно-зважені* підказки: API-методи, що справді використовуються у подібному контексті, виводились на перші позиції. У 2019–2020 роках Microsoft розширила *IntelliCode* до підтримки цілих рядків коду, задіявши GPT-2 для генерації продовжень [9].

Паралельно у 2019 році з'явилися два незалежних продукти, що пропонували AI-автодоповнення для ширшого кола середовищ розробки:

- *TabNine* (розроблений Джейкобом Джексоном, колишнім стажистом OpenAI) став першим комерційним плагіном, що використав GPT-2 для генерації багаторядкових продовжень коду. [10].
- *Kite* орієнтувався на Python-розробників і ML-інженерів, пропонуючи автодоповнення з урахуванням семантики і документації функцій. [10].

Публікація GPT-3 у червні 2020 року [11] стала переломним моментом, хоча й не у вигляді готового кодового асистента. Спільнота розробників швидко виявила, що GPT-3, незважаючи на відсутність спеціалізованого навчання виключно на коді, здатна конвертувати прості природномовні описи у HTML, CSS і базові Python-скрипти.

Принципове обмеження всіх інструментів 2018–2020 років — відсутність діалогу. Інструменти діяли без розуміння намірів розробника, без збереження стану між запитамі і без здатності до обґрунтування пропонованого рішення.

Таким чином, період 2017–2021 років є доказом того, що кожна технологічна хвиля (LSTM → GPT-2 → GPT-3) розсувала межі можливого: від однослівного автодоповнення — до генерації функцій за описом.

1.1.4 Мультимодальні моделі та сучасний етап генеративного штучного інтелекту

У 2017 р. у статті [12] була запропонована інноваційна модель «Transformer» («Трансформатор») з її механізмом багатоголової уваги (англ. «Multi-head attention»), яка стала базовою архітектурою переважної більшості сучасних великих мовних моделей. Ця стаття ознаменувала початок нового етапу, який має місце й досі – етап моделей-трансформерів.

У 2018-му вийшла модель BERT (Bidirectional Encoder Representations from Transformers), яка тоді стала однією з найпотужніших трансформерних моделей *енкодерного* (кодерного) типу для аналізу й розуміння тексту з дво-направленим («Bidirectional») контекстним поданням. Її більш розвинені версії є популярними і досі. Також у 2018 році вийшла GPT-1 – прототип нових значно більш потужних моделей декодерного типу. У 2019 р. – вийшла GPT-2, у 2020 р. – GPT-3, у 2022 р. – GPT-3.5, доступ до якої через ChatGPT спричинив фурор у сфері ГШІ, завдяки зручному діалоговому інтерфейсу, здатності виконувати інструкції та можливості розв'язувати багато задач у режимах zero-shot і few-shot, про що буде йтись у наступних підрозділах і розділах. На відміну від BERT-моделей, GPT-моделі є *авторегресійними* моделями, які генерують текст токен за токеном, де кожен наступний токен передбачається на основі попередніх. В усіх цих моделях літера «Т» у назві означає саме «Transformer».

Цінним рішенням на цьому етапі була відмова від вузькоспеціалізованих моделей, натренованих під певні задачі, і перехід до *універсальних базових* великих мовних моделей (скорочено: ВВМ або з англ. «Large Language Model» – LLM) для збереження і мовних особливостей, і фактів, і інших знань. В подальшому ці моделі можна донавчати під задані задачі.

Далі, світ зосередився на розвитку LLM під різні тексти, мови, задачі. Створений у 2016 р. портал [Hugging Face](https://huggingface.co) колекціонував багато публічних моделей і надавав датасети та інфраструктуру для їх розвитку, що зробило його мегапопулярним у 2020 р. та суттєво сприяло розвитку технологій. Згодом така можливість з'явилась і на повністю безкоштовному Google-порталі Kaggle (був доданий новий вид ресурсу «[Models](#)») та інших.

У 2020 р. у роботі [13] була проведена аналогія між послідовностями слів та послідовностями фрагментів зображень і запропоновано аналог цієї моделі для зображень – Vision Transformer (рис. 1.3) ([13] це був препринт, сама стаття була опублікована у 2021 р.).




Рисунок 1.3 – Приклади вхідних зображень та зображень з головки уваги, виділених першою версією Vision Transformer у статті [13]

У 2022 р. був створений і в 2023 р. опублікований аналогічний інтегрований з трансформером варіант реалізації генерування зображень з використанням дифузних моделей та латентного простору, як в VAE: Diffusion Transformer (DiT) і досі ця технологія є однією з найбільш передових. Тобто технологія поєднала все найкраще з ранніх моделей: і латентний простір зображень, і генерування на його основі зображень за принципом дифузних моделей з використанням трансформерів.

Влітку 2021 року OpenAI представила *Codex* — модель на основі GPT-3, донавчену на сотнях мільярдів токенів публічного коду з GitHub [14]. Це був не просто кількісний стрибок — відбулась якісна зміна можливостей: *Codex* вмів генерувати повноцінні функції за коментарем у природній мові, інтерпретувати docstring і писати відповідний код, а також переключатись між мовами. У серпні 2021 року GitHub запустив технічний перегляд *GitHub Copilot* — плагіна для VS Code на основі *Codex*, який вбудовував пропозиції безпосередньо у процес написання коду [14].

Copilot змінив не лише якість підказок, а й *місце*, де вони з'являлись: не у спливаючому вікні зі списком, а прямо у редакторі, сірим текстом поряд із курсором. Це знизило транзакційну вартість взаємодії до мінімуму — розробник лишень натискав Tab для прийняття або ігнорував підказку. Пізніше дослідження GitHub показали, що користувачі *Copilot* виконували завдання швидше і повідомляли про меншу когнітивну втому [14]. Хронологія інструментів AI-асистованого написання коду наведена на рис. 1.4. У 2025 р. набув поширення термін *вайб-кодинг* (*vibe coding*) — експериментальний стиль розроблення, за якого програміст переважно описує бажаний результат природною мовою та ітеративно використовує згенерований LLM код, приділяючи мінімальну увагу його безпосередньому аналізу.




Рисунок 1.4 — Хронологія інструментів AI-асистованого написання коду [15]

Новий прорив стався 30 листопада 2022 р. – безкоштовно доступний чат-бот ChatGPT на базі моделі ChatGPT 3.5 дозволяв ставити довільні запитання природною мовою та отримувати відповіді у діалоговому режимі. Його можливості проявлялися як у zero-shot, так і у few-shot сценаріях, про які більш детально буде у наступному підрозділі. Раніше спроби реалізувати природномовний діалог з машиною не були такими успішними.

Створювались багатомовні моделі та моделі під конкретні мови. Перші версії багатомовних моделей повертали відповідь одразу багатьма мовами в одному реченні, що було дуже незручно. Швидко з'ясувалось, що мало наповнити базову модель знаннями. Треба ще навчити її чітко виконувати інструкції та давати потрібні відповіді. Такі моделі отримали назву «інструктивні» – «instruct model». Крім того, слід й правильно формулювати самі інструкції, які називають «промпт» (з англ. «prompt» – «інструкція», або «запит»). Розвинувся цілий напрям діяльності: «промпт-інжиніринг» (англ. «Prompt Engineering») – цьому присвячений наступний підрозділ, оскільки опанування наступного матеріалу варто супроводжувати роботою з LLM, до якої слід вже вміти робити промпти.

Паралельно з розвитком LLM розвивались і чат-боти та AI-асистенти.

Чат-бот (англ. «chatbot») — це інтерактивна програмна система, яка в діалоговому режимі отримує повідомлення або *промпти* користувача (англ. «prompts» – вказівки або запити) природною мовою і повертає відповіді у вигляді тексту, голосу, зображень або інших повідомлень.

AI-асистент — це складніша інтелектуальна система, яка не лише відповідає на промпти, а й допомагає виконувати прикладні завдання (англ. «actions»): аналізувати дані, готувати документи, писати код, планувати дії, працювати з файлами, інструментами та зовнішніми сервісами.

В наш час найбільш популярними AI-провайдерами чат-ботів та іншої AI-інфраструктури є такі американські компанії: OpenAI (ChatGPT – читається як «Чат-жпт» або «Чат-джи-пі-ті»), Anthropic (Claude – «Клод»),

Google (Gemini – «Джемінай»), xAI (Grok – «Грок»), Meta (Llama – «Лама»). Згодом, значну конкуренцію склали китайські компанії, зокрема DeepSeek має однойменний чат-бот DeepSeek (читається як «Діпсік»), Alibaba (Qwen – «Квен»). Конкуренція змушує провайдерів знижувати ціни, боротись за якість, викладати відкриті версії (після появи ChatGPT 3.5 і до появи конкуренції з боку Китаю OpenAI не надала жодної відкритої версії, що було приводом для жартів, враховуючи її назву, були доступними тільки старі моделі на кшталт GPT-2).

Є декілька напрямків розвитку та адаптації LLM під задані задачі та спеціалізовані корпуси (про це більш детально – у розд. 3):

1. *Донавчання* моделей (англ. «Fine-Tuning»), але це доволі складно і дорого (і формування датасету, і супровід цього рішення).

2. Поєднання знань LLM і банку нових для неї знань на основі *RAG-архітектури*, але таку інфраструктуру не просто супроводжувати.

3. Використання LLM з дуже великим *контекстним вікном* (сумарна кількість токенів у промпті та у відповіді на нього), в яке можна передати додаткові знання, які варто врахувати, хоча не всі такі знання враховуються.

4. Інші напрямки, наприклад, пов'язані з використанням «людина в контурі» (“*human in the loop*”), коли залучається людина як експерт для верифікації коректності знань та оцінювання результатів генерації.

Крім цього, активно розвиваються *бенчмарки* (з англ. «benchmark» – еталонний тест) для тестування та оптимізації LLM. Для тестування та оптимізації AI-агентів та AI-асистентів розвиваються *агент-бенчмарки*.

Поява згаданої вище моделі «Vision Transformer», адаптованої згодом й до інших видів даних, спричинила появу мультимодальних моделей та чат-ботів на їх основі. Стало набагато зручніше запитати алгоритм виконання дій, потім навести скріншот отриманих результатів і отримати текст з коментарями та презентацію й відеоролік для демонстрування отриманих результатів.

Наступний стрибок технологій пов'язується з активним впровадженням AI-агентів, які використовують LLM, мультимодальні моделі та пам'ять для збереження контексту.

1.1.5 Агентні системи генеративного штучного інтелекту та перспективи їх розвитку

Теорія агентних і багатоагентних систем була розроблена ще у XX столітті, але поява LLM і мультимодальних моделей відкрила новий етап їх практичного розвитку — агентів, здатних працювати з природною мовою, планувати дії та використовувати зовнішні інструменти.

Агентна система ГШІ (або *AI-агент*) — це програмна система, яка з певним рівнем автономності аналізує стан середовища та виконує дії для досягнення заданої мети. Вона використовує LLM або мультимодальну мо-

дель не лише для генерування відповіді, а й для планування, вибору інструментів, виконання окремих кроків, аналізу проміжних результатів і коригування подальших дій.

Агентна інженерія (agent engineering) — це проєктування, розроблення, налаштування та оцінювання AI-агентів і агентних систем, зокрема їх моделей, контексту, інструментів, пам'яті, оркестрації та механізмів контролю результатів.

Агентна інженерія програмного забезпечення — застосування цих підходів до постановки задач, створення, тестування, налагодження, вдосконалення та супроводу програмного забезпечення за участю AI-агентів.

З розвитком інфраструктури LLM розвивалась і інфраструктура AI-агентів. З появою доволі надійних LLM, доступних через API, з'явилась можливість розгортання як повністю автономних, так і напівавтономних (з «людиною у контурі») AI-агентів. Активно розвиваються багатоагентні системи, агент-бенчмарки для їх тестування та оптимізації, інструментарій та інфраструктура, чому присвячено розділ 4.

На базі багатоагентних систем створюються рекомендаційні або й автоматичні системи підтримки прийняття рішень (СППР), які можуть працювати в автоматичному режимі. Одним з таких прикладів є AIoT («Artificial Intelligence of Things» – з англ. «Інтернет речей зі штучним інтелектом» або «інтелектуальний Інтернет речей»: AIoT = AI + IoT) [16].

Хоча, тривалі експерименти та негативний досвід деяких користувачів повністю автономних агентних СППР призвели до того, що більшість систем стали, переважно, рекомендаційними, тобто розробляють рішення і передають певній людині-оператору, яка вже їх впроваджує та несе відповідальність за наслідки.

Головною проблемою стала необхідність індивідуальної складної адаптації AI-агентів до зовнішніх інструментів, баз даних та сервісів, де вони потрібні. Частково цю проблему дозволяє вирішити модельний контекстний протокол (англ. «Model Context Protocol» – MCP) — відкритий протокол для підключення LLM-застосунків до зовнішніх інструментів, джерел даних і сервісів.

Паралельно з цим технологічним проривом велика увага суспільства приділялась соціальним та етичним аспектам розвитку AI. З появою чат-бота на основі LLM ChatGPT на базі GPT-3.5 і подальшим бурхливим розвитком його аналогів, ця проблема вийшла на світовий рівень.

Значна увага в Україні і за кордоном приділяється академічній доброчесності. Міністерство освіти і науки України випустило методичні рекомендації щодо використання AI в освіті і науці [17]. Все це охарактеризовано у розділі 5.

Важливою цінністю сучасного III є те, що технології взяли на себе рутинні операції, а дійсно творчі, пов'язані з постановкою задач, з координуванням їх реалізації, з удосконаленням теоретичної бази, все одно, по-

винні робити люди. Значно зросла роль датасайнтистів та системних аналітиків – вони отримали інструмент, який суттєво прискорює їх роботу, дозволяє швидше її робити в будь-якій сфері, де у них могло не бути специфічних знань. Головне, знати особливості формалізації знань і даних в AI, технологічні особливості їх роботи, володіти інформаційно-комунікаційними технологіями, зокрема й вміти спілкуватись із замовниками, які досі віддають перевагу спілкуванню з людьми, оскільки тільки вони можуть нести відповідальність за результати, на відміну від AI, який і не несе відповідальності і багато «галюцинує» у відповідях. Зокрема, датасайнтист повинен вміти правильно трансформувати інформацію від замовника у ту, яку правильно обробить LLM і дасть відповідь, яку потім можна використати для розв’язання поставленої задачі.

У кожному розділі будуть наводитись приклади постановки та напрямки розв’язання і реальних задач, і тренувальних задач у платформі Kaggle з відповідної тематики. Посібник орієнтований на використання мови програмування Python.

1.2 Промпт-інжиніринг

Ключовим в ГШІ є ефективний *промт-інжиніринг* (ПІ), яким є сукупність підходів і прийомів формулювання промтів (запитів) до LLM, які підвищують імовірність отримання коректної, релевантної та придатної для використання відповіді.

Найкращий огляд відомих методик промт-інжинірингу наведено на відомому ресурсі «Prompt Engineering Guide» [18] (рис. 1.5).




Рисунок 1.5 – 18 технік промпт-інжинірингу по версії DAIR.AI
([Prompt Engineering Guide](#))

Першими з них є класичні (рис. 1.6):

- *zero-shot* – коли промпт формулює завдання без жодного прикладу очікуваного способу розв’язання або формату відповіді (наприклад: «Оціни, як зросте навантаження на чат-бота, якщо кількість запитів однакового розміру збільшиться з 1000 до 1500 на добу»);
- *one-shot* – коли промпт містить один приклад виконання подібного завдання, який задає логіку, стиль і формат нової відповіді (наприклад: «Якщо кількість запитів однакового розміру зросла з 1000 до 1200 на добу, то навантаження на чат-бота зросло на 20 %. Визнач, як зміниться навантаження, якщо кількість запитів однакового розміру зросте з 2000 до 2600 на добу»);
- *few-shot* – коли промпт містить декілька прикладів виконання подібних завдань, щоб модель краще зрозуміла логіку та формат відповіді (наприклад: «Якщо кількість запитів на добу не змінилась, але середній обсяг промпта збільшився удвічі, то навантаження зросло приблизно у 2 рази. Якщо кількість запитів зросла з 1000 до 1500 на добу, а середній обсяг промпта збільшився у 2 рази, то загальне навантаження зросло приблизно у 3 рази. Оціни, як зміниться навантаження на чат-бота, якщо кількість запитів зросте з 2000 до 3000 на добу, а середній обсяг промпта збільшиться на 50%»);
- *Chain of Thought (CoT)* – коли промпт вимагає від моделі не лише дати відповідь, а й надати розв’язання у вигляді послідовних кроків або короткого обґрунтування (наприклад: «Чат-бот обробляє 1200 запитів на добу. Очікується, що після удосконалення кількість запитів зросте на 25%. Розв’яжи задачу покроково і визнач, скільки запитів на добу має обробляти чат-бот після масштабування»).




Рисунок 1.6 – Чотири основні методики пром프트-інжинірингу: zero-shot, one-shot, few-shot, CoT [19]

Серед інших найбільш популярними є такі:

1. *Метапромтинг (Meta Prompting)* – це промпт, в якому чітко задаються роль, формат, критерії якості, стиль пояснення. Наприклад: «Ти – викладач дисципліни «Генеративний штучний інтелект». Поясни задачу для студентів першого курсу магістратури ІТ-спеціальності. Відповідь має містити: вихідні дані, формулу, обчислення і короткий висновок. Задача: чат-бот обробляє 1200 запитів на добу, на скільки зросте ця кількість, якщо очікується, що вона зросте на 25%?».

2. *Промпт із самоузгодженістю (Self-consistency)* — формування декількох міркувань і вибір найстійкішого серед них. Задача розв’язується різними способами, а тоді вибирається відповідь, яка найчастіше повторюється або є найбільш узгодженою. Наприклад: «Чат-бот зараз обробляє 1200 запитів на добу. Прогнозують зростання на 25%. Розв’яжи задачу трьома різними способами: 1) через обчислення приросту; 2) через множник 1,25; 3) через частку від початкового значення. Порівняй результати і дай остаточну відповідь.».

3. *Промтинг із генеруванням знання (Generate Knowledge Prompting)* – генерування узагальненого знання, а потім його застосування до задачі. Наприклад: «Спочатку стисло поясни, як обчислюється нове навантаження системи після зростання на певний відсоток кількісного показника. Потім застосуй це правило до задачі: чат-бот обробляє 1200 запитів на добу, очікуване зростання — 25%.» У відповідь буде записана формула з поясненнями, а потім – результат її застосування до заданої задачі.

4. *Ланцюжковий промтинг (Prompt Chaining)* – формування у промпті ланцюжку послідовних етапів розв’язання задачі. Доцільно, коли є чіткий послідовний алгоритм розв’язання задачі та подання результатів. Зазвичай, рекомендується його формувати саме окремими послідовними промптами у діалоговому режимі, а не – одним промптом.

5. *Дерево думок (Tree of Thoughts)* – вибір оптимального варіанту серед багатьох можливих. Варіанти можуть аналізуватись не послідовно, як у CoT, чи паралельно, «маршрут» вибору оптимального міркування може бути довільним по усьому «дереву» варіантів. У «Prompting Guide» ToT описано як узагальнення CoT з дослідженням проміжних «думок», самоперевіркою, пошуком і можливим поверненням назад. ToT – це, скоріше, дерево міркувань, але «думок» вже є усталеним перекладом цієї назви. Наприклад: «Компанія має масштабувати чат-бот. Є три варіанти, з яких вибери найкращий: 1) збільшити кількість серверів на 25%; 2) оптимізувати модель і зменшити час відповіді на 25%; 3) додати кешування для типових запитів.»

Генерація, доповнена пошуком (Retrieval-Augmented Generation, RAG) буде більш детально описана у підрозд. 3.3. ReAct – у розд. 4 під час

опису роботи AI-агентів. З іншими техніками можна більш детально ознайомитись у першоджерелі [Prompt Engineering Guide](#).

Рекомендовані для ознайомлення ресурси:

- [Prompt Engineering Guide](#) (посібник) (DAIR.AI, 2026);
- [OpenAI для розробників](#) (посібник) (OpenAI, 2026);
- [Колекція](#) бібліотек, сервісів та інструкцій для ПІ та LLM (OpenAI, 2023);
- [Найкращі практики](#) ПІ (OpenAI, 2026);
- [Основи ПІ](#) (Google Cloud, 2026);
- [Інструкції щодо ПІ \(посібник\)](#) (Google Cloud, 2026);
- [Стратегії ефективного ПІ](#) (Google Cloud, 2026);
- [Велика кількість прикладів](#) ефективного ПІ (Google Cloud, 2026);
- [Найкращі практики ПІ](#) (Anthropic, Claude API Docs, 2026);

У [17] наведено корисні рекомендації для викладачів засобів вищої освіти щодо ПІ.

Зі збільшенням контекстного вікна LLM пром프트-інжиніринг став частиною більш загального підходу — контекстної інженерії.

Контекстна інженерія — це комплекс методів та технік визначення того, яку і в якому форматі інформацію, інструкції, пам'ять, приклади, інструменти й зовнішні дані слід надати LLM, щоб вона могла якісно виконати завдання. Тобто цінним є вже не тільки правильна організація промпту, а й інструменти для роботи з цими промптами (збереження в пам'яті, пошук в історії тощо).

1.3 Інфраструктура генеративного ПІ у системному аналізі

У системному аналізі ГПІ реалізується у трьох режимах: як складна система, що проєктується за методологією системного аналізу (етапи 1–5); як набір передтренованих мультимодальних моделей для інтелектуального аналізу даних (етап 4); як СППР і рекомендаційні системи на основі LLM-агентів (етап 5). Кожен режим має власну інфраструктуру, однак спільним є вибір між *хмарним* (масштабованіший, дорожчий) і *локальним* (дешевший, контрольованіший) розгортанням.

ГПІ в системному аналізі — це *інфраструктурна система*, де якість результату визначається узгодженою роботою обчислювального середовища, даних, моделей, інтерфейсів і процедур оцінювання. Цей підрозділ формує «мінімальний стек», придатний для студентів без глибокого ІТ-досвіду, і готує інфраструктурний каркас курсового проєкту.

Для курсу рекомендуються три середовища (рис. 1.7):

- **Kaggle Notebooks** (kaggle.com) — хмарне Jupyter-середовище з безкоштовним доступом до GPU/TPU (до 30 год/тиж.), вбудованими дата-сетами та мільйонами публічних ноутбуків. Основна платформа для лабораторних робіт [20];

- **Google Colab** (colab.research.google.com) — хмарне середовище з GPU безкоштовно, тісно інтегроване з Google Drive. Підходить для прототипів і демонстрацій;
- **VS Code + локальне Python-оточення** — рекомендується для курсового проєкту з конфіденційними даними або при потребі повного контролю над середовищем.




Рисунок 1.7 — Порівняння обчислювальних середовищ Kaggle, Colab та локального VS Code (зображення згенеровано з використанням Claude Sonnet 4.6 за авторським описом, вересень 2025 р.)

Мінімальні правила відтворюваності: фіксувати версії бібліотек у *requirements.txt*; задавати *random_state=42* у всіх моделях; документувати джерело даних у першому рядку ноутбука. У більш загальному випадку, для відтворюваності варто ще й фіксувати версії бібліотек, назви й версії моделей, параметри запуску, «random seed», джерела даних і дату експерименту. Для API-моделей слід також зберігати назву моделі, температуру, *top_p* та інші параметри генерації.

Проєкт з ГШІ породжує кілька типів артефактів: датасети, навчені моделі (*.pkl*, *.pt*, *.gguf*), файли промптів, конфігурації та звіти. Усі вони потребують структурованого зберігання і версіонування.

GitHub (github.com) — основний інструмент версіонування коду. Для початківців достатньо трьох команд: *git clone* (завантаження), *git commit*

(збереження змін), *git push* (вивантаження). Рекомендована структура репозиторію КП:

```
project/
├── data/           # вхідні дані або посилання на джерело
├── notebooks/     # Jupyter-ноутбуки
├── src/           # Python-модулі (агент, інструменти)
├── prompts/       # файли промптів (.yaml)
├── reports/       # звіти та графіки
├── requirements.txt
└── README.md
```

Великі файли (моделі, датасети) не зберігаються у Git — для них використовується *Kaggle Datasets API* або *Hugging Face Hub*. Промпти версionуються нарівні з кодом: рекомендується зберігати їх у *.yaml*-файлах із метаданими (версія, дата, модель).

Hugging Face Hub [21] — найбільша відкрита колекція моделей і датасетів для ГШІ: понад 1 млн моделей станом на 2025 рік [2] і понад 2 млн у 2026 р. Бібліотека *transformers* надає уніфікований API для завантаження BERT, Llama 3, Gemma 4, Mistral та сотень інших моделей:

```
from transformers import pipeline
pipe = pipeline('text-generation', model='google/gemma-4-4b')
```

Конкретний ідентифікатор моделі (замість «google/gemma-4-4b») варто уточнювати на порталі Hugging Face.

Для локального запуску LLM без передачі даних у хмару призначений *Ollama* (ollama.com): команда *ollama run llama3.2* розгортає модель на ноутбуку [22].

Веб-інтерфейси для прототипів. Два інструменти дозволяють швидко перетворити Python-скрипт на веб-застосування:

- *Gradio* — спеціалізується на демонстрації ML-моделей [23].
- *Streamlit* — для аналітичних застосувань із таблицями, графіками і чат-інтерфейсом [24].

Можливі теми практичних і лабораторних завдань

Тема № 1. Приклади і проблеми використання ГШІ.

Метою заняття є ознайомитись із гарними прикладами ефективного промп-інжинірингу для генерування даних різного типу (чисел, тексту, програмного коду, зображень, звуків, відео), дослідити проблеми, які виникають при цьому.

План заняття:

1. Демонстрація роботи AI-асистентів викладачем та аналіз якості відповідей.
2. Колективне обговорення вдалих і невдалих прикладів застосування генеративного ШІ у системному аналізі.

3. Формування постановки задачі системного аналізу з використанням діалогових інтерфейсів AI-асистентів.

4. Вибір тем курсового проєкту та формулювання постановки задач для кожної з цих тем.

Тема № 1. Промпт-інжиніринг для LLM з використанням API.

Метою заняття є опанування техніками автоматизації промпт-інжинірингу для LLM з використанням API.

План заняття

1. Вибрати IT-інфраструктуру реалізації роботи: локально чи у хмарі; Kaggle/Google Colab/VS Code; вибрати LLM з Hugging Face чи ін. (рекомендується Google Gemini) та визначити API (рекомендується взяти декілька моделей для порівняння).

2. Сформувати систему промптів для перевірки певних гіпотез щодо ефективності LLM для розв'язання деяких(ої) задач(і) системного аналізу.

3. Програмно викликати LLM через API для кожного з промптів.

4. Проаналізувати результати.

5. Навести звіт, в якому вказати вибрану IT-інфраструктуру, гіпотези, промпти, охарактеризувати отримані результати, виділити цікаві закономірності щодо них та рекомендації щодо цих промптів та LLM.

Контрольні питання

1) Що означає перехід від символічного ШІ до великих мовних моделей з точки зору *зміни парадигми* роботи з інформацією? У чому принципова відмінність між алгоритмічним підходом і підходом на основі базових моделей?

2) Поясніть поняття *галюцинацій* у генеративному ШІ. Чому це явище є критичним саме в контексті систем підтримки прийняття рішень, а не в побутовому використанні AI-асистентів?

3) Що таке *базова модель* (foundation model) і в чому полягає принцип *переднавчання та адаптації* (pretraining + fine-tuning)? Навіщо розрізняти ці два етапи при постановці прикладних задач?

4) Визначте поняття *промпт*, *системний промпт* та *вікно контексту*. Як розмір вікна контексту впливає на можливості AI-асистента при аналізі великих документів?

5) Які чотири типи промптів розглядаються у курсі? Наведіть по одному прикладу кожного типу стосовно задачі аналізу екологічних даних.

6) Чим відрізняється задача «*отримати текст*» від задачі «*підтримка прийняття рішень*» у термінах системного аналізу? Назвіть складові системно-аналітичної постановки задачі для генеративного ШІ.

7) Поясніть принцип *Chain-of-Thought* (ланцюжок міркувань). Для яких класів аналітичних задач він є особливо ефективним і чому?

8) Порівняйте хмарне і локальне обчислювальне середовище для роботи з ГШІ за критеріями: потужність GPU, вартість, контроль над даними, відтворюваність. За яких умов слід обрати локальний варіант?

9) Яку роль виконує *GitHub* в інфраструктурному каркасі проєкту з ГШІ? Що таке *артефакти проєкту* і які з них підлягають версіонуванню поряд із кодом?

10) Яким чином *Gradio* і *Streamlit* виконують роль «мосту» між лабораторним прототипом і системою підтримки прийняття рішень? У чому практична різниця між цими інструментами при розробці курсового проєкту?

2 ПОДАННЯ ТА АНАЛІЗ ДАНИХ І ЗНАНЬ У ГЕНЕРАТИВНОМУ ШТУЧНОМУ ІНТЕЛЕКТІ

2.1 Дані, інформація та знання в системах генеративного штучного інтелекту

Традиційно поняття дані (Data), інформація (Information) та знання (Knowledge) подаються у вигляді піраміди DIKW, де W – "wisdom" (з англ. "мудрість") (рис. 2.1).




Рисунок 2.1 – Піраміда DIKW [25]

Зазвичай, елементи піраміди DIKW описують таким чином:

- *дані* — зафіксовані факти, спостереження, значення або повідомлення, які не пояснюють нічого самі по собі;
- *інформація* — дані, інтерпретовані в певному контексті та придатні для розуміння ситуації;
- *знання* — узагальнена інформація, що відображає закономірності, зв'язки, правила, досвід або способи дії;
- *мудрість* — здатність доцільно застосовувати знання для прийняття рішень з урахуванням цілей, цінностей і наслідків.

Генеративний ШІ допомагає працювати з тріадою «дані – інформація – знання» не лише для пошуку або зберігання, а й для перетворення змісту. Він може приймати великі обсяги різномірних матеріалів, знаходити в них

суттєві зв'язки, пояснювати їх людською мовою, узагальнювати, порівнювати, переформатовувати та використовувати для побудови нових відповідей. Це дає можливість виявлення нових закономірностей, формування рекомендацій та підтримки прийняття рішень.

Для кращого розуміння технічних аспектів цієї тріади наведемо декілька визначень:

- *токен* — це одиниця тексту або коду, на яку модель розбиває вхідні й вихідні дані; токеном може бути слово, частина слова, символ або їх поєднання (рис. 2.2);

- *контекст* — це сукупність даних, інструкцій, промптів, повідомлень та/або документів, які модель враховує під час генерації відповіді;

- *контекстне вікно* — це максимальна кількість токенів, яку модель може одночасно врахувати у вхідному промпті, зовнішньому контексті та згенерованій відповіді;

- *параметри моделі* — це числові коефіцієнти, в яких після навчання неявно закріплюються статистичні закономірності, зв'язки між поняттями і типові способи побудови відповідей;

- *навчальний корпус* — це сукупність даних, на яких модель навчається виявляти мовні, змістові та структурні закономірності;

- *датасет для донавчання* — це спеціально підготовлений набір прикладів, за допомогою якого модель адаптують до певної предметної галузі, стилю, формату відповідей або типу задач;

- *зовнішній контекст* — це додаткові матеріали, які подаються моделі разом із промптом без зміни її параметрів, наприклад у RAG-системах.

Token visualization (tokenizer: gpt2) — EN

Large Language Models (LLMs) have reshaped NLP — fast, quietly, and at scale; in 2019 GPT-2 had ~1.5 B parameters, while in 2023 LLaMA 2 reached 70 B, and in 2024 LLaMA 3 offered 8 B / 70 B variants. Because tokenizers split text into units (sometimes surprising ones), short words like 'a' or 'we' and long ones like 'interoperability' can be processed differently, and punctuation, apostrophes (don't, we're), and numbers (2, 7, 70 B) each shape the token stream. When you prompt an LLM, you're really feeding tokens — segments that the model embeds, attends to, and predicts, one step at a time.

a)

Token visualization (tokenizer: xlm-roberta-base) — UK

Великі мовні моделі (LLM) швидко, майже непомітно, але масштабно змінили NLP; у 2019 році GPT-2 мав приблизно 1.5 B параметрів, у 2023 LLaMA 2 досяг 70 B, а у 2024 LLaMA 3 за пропонував варіанти 8 B / 70 B. Оскільки токенізатор ділить рядок на одиниці (інколи несподівані), короткі слова на кшталт «я» чи «ми» та довгі на кшталт «інтероперабельність» обробляються по-різному, а пунктуація, апострофи (об'єкт, м'який), і числа (2, 7, 70 B) формують потік токенів. Коли ви подаєте промпт на LLM, ви насправді подаєте токени — фрагменти, які модель кодує, узгоджує у вагомості та передбачає крок за кроком.

б)

Рисунок 2.2 – Приклад токенизації з використанням різних LLM з авторського ноутбука [26]: а) англійської (GPT2) та б) української (XLM-ROBERTA-Base)

З урахуванням цих понять у контексті ГШІ визначення тріади "DİK" можна сформулювати таким чином:

- *дані* — це тексти, таблиці, зображення, аудіо, відео, код або навчальні приклади, які модель може перетворити на токени, вектори чи інші внутрішні представлення;

- *інформація* — це зміст, який формується під час інтерпретації даних у певному контексті, зокрема у вигляді відповіді моделі, пояснення, узагальнення, перекладу, класифікації, структурованого опису або іншого результату генерації;

- *знання* — це закономірності, факти, зв'язки між поняттями, мовні структури й типові способи міркування, які модель неявно відображає у параметрах або явно отримує із зовнішнього контексту.

Отже, у ГШІ дані є матеріалом для оброблення, інформація — результатом інтерпретації цих даних у контексті задачі, а знання — закономірностями, які модель використовує для побудови нових змістовних відповідей.

2.2 Подання знань у системному аналізі: онтології, семантичні мережі, векторні простори та нейромережі

У системному аналізі знання потрібно подавати у формі, придатній для пошуку, пояснення, узагальнення, перевірки зв'язків і підтримки прийняття рішень. Для цього використовують різні способи подання знань: від явних структур із поняттями та зв'язками до числових представлень, зручних для машинного навчання і генеративного ШІ.

Серед найбільш поширених видів подання знань можна виділити такі:

- *онтології* — це формалізований опис понять предметної області, їх властивостей, зв'язків, обмежень і правил інтерпретації;

- *семантичні мережі* — це графове подання знань, у якому вузли відповідають поняттям, об'єктам або подіям, а ребра відображають змістові зв'язки між ними;

- *векторні простори* — це числове подання об'єктів у вигляді векторів, де близькість векторів використовується як оцінка змістової подібності.

У класичних задачах системного аналізу онтології та семантичні мережі корисні тоді, коли потрібно явно описати структуру складної системи: її елементи, зв'язки, ієрархії, причинно-наслідкові залежності, обмеження та сценарії поведінки. Наприклад, для аналізу міської транспортної системи можна описати об'єкти «дорога», «перехрестя», «транспортний потік», «затори», «світлофор», «аварія» та зв'язки між ними.

У генеративному ШІ найчастіше безпосередньо використовують векторні простори, зокрема для пошуку релевантного контексту, порівняння текстів, кластеризації документів, побудови RAG-систем і семантичного пошуку. Однак онтології та семантичні мережі також залишаються важливими: вони допомагають структурувати предметну область, формувати якісні датасети для донавчання, перевіряти повноту знань, будувати графи знань, контролювати термінологію та зменшувати суперечності у відповідях моделі.

Отже, онтології та семантичні мережі забезпечують явне структурне подання знань, зручне для пояснення і контролю зв'язків у предметній області, а векторні простори забезпечують неявне числове подання змісту, зручне для пошуку, порівняння і генерації.

Окрім цих типових способів подання знань, у сучасних системах ГШІ доцільно також розглянути поняття, пов'язані з формалізацією знань та їх використанням у LLM і агентних системах (рис. 2.3).

Семантичні шари — це проміжний рівень опису між даними, аналітичними запитам та поняттями предметної області. У них задають зрозумілі назви показників, метрик, атрибутів, таблиць і правила їх обчислення або використання. Семантичні шари допомагають працювати не з технічними назвами полів і таблиць, а з поняттями, зрозумілими фахівцям певної предметної області. У системах ГШІ такі описи можуть використовуватися для формування промптів, побудови запитів до даних і пояснення результатів.

Контекстні графи – це вид подання знань, у яких фіксується не лише факт зв'язку між об'єктами, а й контекст дії або рішення: хто, коли, чому і за яких умов виконав певну дію або прийняв певне рішення. Ці граfi можна розглядати як розвиток ідеї графів знань. Це важливо для агентів ГШІ, оскільки їм потрібні не тільки факти, а й пояснення причин, винятків і попередніх рішень у системі.




Рисунок 2.3 – Подання знань: онтології, граfi знань та семантичні мережі [27]

Векторні простори добре забезпечують пошук змістовно близьких фрагментів, однак самі по собі вони не задають явної структури предметної області. Тому їх доцільно доповнювати онтологіями, графами знань і контекстними графами, які описують поняття, типи зв'язків, обмеження, пра-

вила виведення та умови прийняття рішень. Таке поєднання може бути корисним для RAG-систем, агентів, формування датасетів для донавчання та систем підтримки прийняття рішень.

Окремої уваги заслуговує питання: як саме базова LLM зберігає знання. Відомо, що це - нейронмережа складної архітектури, яка під час навчання налаштовує велику кількість параметрів, тобто ваг. Тому можна спростено сказати, що основна частина знань, набутих моделлю під час навчання, закодована саме у цих вагах. У внутрішніх представленнях LLM можуть формуватись певні фічери — ознаки, пов'язані зі словами, темами, фактами, стилями, поняттями або ситуаціями. Іноді такий фічер має зрозуміле для людини трактування, наприклад пов'язаний із конкретним об'єктом, мовою, емоцією чи типом задачі (рис. 2.4, 2.5).

Abstract Feature Examples

F#1M/1013764 Code error

```
> function thisFunctionCrashes() undefinedVariable() end > f({thisFunctionCrashes}) st
urllib.request.urlopen('https://wrong.host.badssl.com/') except (IOError, OSError):
: (defmacro mac (expr) 2: (/ 1 0)) 3: (mac foo) $ txr macro-error-
not AValidPythonModule" 0002 st = PyImport (badmod) 0003 IF @PYEXCEPTIONTYPE NE '' THEN 0004
```

F#34M/24442848 Gender bias awareness

n a more intimate level than doctors, and female nurses outnumber male nurses roughly 10:1 in the US making, as whilst the majority of school teachers are women, the majority of professors are men. sional, white collar career that also happens to employ more women than men? Women were programmer e, if I were referring to a dental hygienist (over 90% of whom are female), I might choose "she,"

Рисунок 2.4 – [Приклад фічерів](#): помилки в комп'ютерному коді, описи гендерних упереджень у професіях, виділених дослідниками Anthropic за допомогою моделі Claude 3.0 Sonnet

Most of the 4,096 features found by the auto-encoder have consistent, interpretable responses to input data

#3647 - Legal language

and to deposit the same in Marshall's checking upon the intention, actual or presumed, of mortgage which was then existing on the property, be permitted to retain actual possession of the mortgage lien on encumbered property of the estate

#2937 - DNA Sequences

AGTTTCGTTTACATG GGG
AGACAACCTTTTCTTT Ex3
ACACACGACACCGGGCTACGG
CTCCGTGTTTGM2-
CAAGAAAAGCATGCTCTGTT

#28 - Code: HTTP requests and responses

Net :: HTTPResponse " #{ response . code
HTTPMethod { case "GET": id :=
405, HTTPResponse500, <## HTTP
setHTTPMethod: 0 "POST"];
atoKey, forHTTPHeaderField: "

#3611 - Nutrition statements

dietary recommendations of the individual diet.
about choosing high-quality, healthy foods,
calories! Switching from mostly fat or mostly
nutrients. Besides, individual foods and nutrients do
from food, or produce energy, without several

#1366 - Sports, especially title case competition names

Black Belt Featherweight 1st Place
70 kg)-World Association of Kickbox
seat of the victorious Australian men's eight
boxing Cruiserweight (-85.9
the Men's Lightweight Four at the 2007

#818 - Numbers separated by commas (CSV)

0,0,0,0,0
1,252,0,0,29
4,0,4,0,0
0,255,0,0,0
0,61,0,0,0

#3349 - Funding acknowledgments

was supported by the Research Program for
was partially supported by a Grant-in
study was supported by the Swedish Research Council
supported in part by Perimeter Institute for
ling was provided through professional development fund

Рисунок 2.5 – Приклади виділених фічерів у тексті зі зрозумілим експертам типом (Claude Sonnet)

Але багато внутрішніх фічерів залишаються складними для пояснення. Складність таких дослідження пов'язана з тим, що один нейрон (вага) може фігурувати у різних фічерах (рис. 2.6).

Neurons in language models fire on many different types of text.

Neuron #83 fires on...

자는 \xec\x95\x94\xeb\xa7\x90 \xea\xb0\x99
\xeb\xa7\x8e \xeb\xa7\x8e
\xec\x85\x98 \xeb\xa7\x88\xeb\xb9\x84
\xa1 \xa1 \xa1 \xa1 \xa1 \xa1 \xa1 \xa1
\xeb\xa7\x88 \xeb\xa7\x89 \xeb\xa7\x8a \xeb\xa7\x8b
\xeb\xa7\x8c \xeb\xa7\x8d \xeb\xa7\x8e \xeb\xa7\x8f
\xeb\xa7\x90 \xeb\xa7\x91 \xeb\xa7\x92 \xeb\xa7\x93
\xeb\xa7\x94 \xeb\xa7\x95 \xeb\xa7\x96 \xeb\xa7\x97
\xeb\xa7\x98 \xeb\xa7\x99 \xeb\xa7\x9a \xeb\xa7\x9b
\xeb\xa7\x9c \xeb\xa7\x9d \xeb\xa7\x9e \xeb\xa7\x9f
\xeb\xa7\xa0 \xeb\xa7\xa1 \xeb\xa7\xa2 \xeb\xa7\xa3
\xeb\xa7\xa4 \xeb\xa7\xa5 \xeb\xa7\xa6 \xeb\xa7\xa7
\xeb\xa7\xa8 \xeb\xa7\xa9 \xeb\xa7\xaa \xeb\xa7\xab
\xeb\xa7\xac \xeb\xa7\xad \xeb\xa7\xae \xeb\xa7\xaf
\xeb\xa7\xb0 \xeb\xa7\xb1 \xeb\xa7\xb2 \xeb\xa7\xb3
\xeb\xa7\xb4 \xeb\xa7\xb5 \xeb\xa7\xb6 \xeb\xa7\xb7
\xeb\xa7\xb8 \xeb\xa7\xb9 \xeb\xa7\xba \xeb\xa7\xbb
\xeb\xa7\xbc \xeb\xa7\xbd \xeb\xa7\xbe \xeb\xa7\xbf
\xeb\xa7\xc0 \xeb\xa7\xc1 \xeb\xa7\xc2 \xeb\xa7\xc3
\xeb\xa7\xc4 \xeb\xa7\xc5 \xeb\xa7\xc6 \xeb\xa7\xc7
\xeb\xa7\xc8 \xeb\xa7\xc9 \xeb\xa7\xca \xeb\xa7\xcb
\xeb\xa7\xcc \xeb\xa7\xcd \xeb\xa7\xce \xeb\xa7\xcf
\xeb\xa7\xd0 \xeb\xa7\xd1 \xeb\xa7\xd2 \xeb\xa7\xd3
\xeb\xa7\xd4 \xeb\xa7\xd5 \xeb\xa7\xd6 \xeb\xa7\xd7
\xeb\xa7\xd8 \xeb\xa7\xd9 \xeb\xa7\xda \xeb\xa7\xdb
\xeb\xa7\xdc \xeb\xa7\xdd \xeb\xa7\xde \xeb\xa7\xdf
\xeb\xa7\xe0 \xeb\xa7\xe1 \xeb\xa7\xe2 \xeb\xa7\xe3
\xeb\xa7\xe4 \xeb\xa7\xe5 \xeb\xa7\xe6 \xeb\xa7\xe7
\xeb\xa7\xe8 \xeb\xa7\xe9 \xeb\xa7\xea \xeb\xa7\xeb
\xeb\xa7\xec \xeb\xa7\xed \xeb\xa7\xee \xeb\xa7\xef
\xeb\xa7\xf0 \xeb\xa7\xf1 \xeb\xa7\xf2 \xeb\xa7\xf3
\xeb\xa7\xf4 \xeb\xa7\xf5 \xeb\xa7\xf6 \xeb\xa7\xf7
\xeb\xa7\xf8 \xeb\xa7\xf9 \xeb\xa7\xfa \xeb\xa7\xfb
\xeb\xa7\xfc \xeb\xa7\xfd \xeb\xa7\xfe \xeb\xa7\xff

Korean

Citations

HTTP Request

Citations

Dialogue

Citation in LaTeX

Japanese

More citations

Korean

The features we find are dramatically more consistent. Feature #2937 fires on DNA.

AGTTTCGTTTACATG GGG
AGACAACCTTTTCTTT Ex3
ACACACGACACCGGGCTACGG
CTCCGTGTTTGM2-
CAAGAAAAGCATGCTCTGTT
TGCCATCCCTGATAACCTGG
ATATGAGCTGTTGACCTGTTGT45
CCCATCACTTTTACCTTATAGGT
GCGAATCCGTTACGTATCGTCA
ATGAAATCTGTTCTGGGAATG
AGGAGTTACAACAATGAAAAAT
ACTCACCCGTGCG+PC
AGTCCAGCCGAGACACTA Ori
ACCGTTTTTCGCGATCGTTAT
GGCGGCCAAGTAGGAAAGAC
CTGAATAGTGTGATA
GGCTGTGTCTCTGGCCACTGT
TGTTGTGTCTTGATGTGCTCG
CAACATATGGTG
ATCTTTGCTTTTGTAAATATT

Рисунок 2.6 – Ілюстрація присутності нейрону № 83 у різних фічерах (модель Claude Sonnet)

Поєднання великої кількості таких фічерів дає змогу моделі відтворювати знання, мовні закономірності та типові зв'язки між поняттями. Фактично, можна говорити про розподілене зберігання знань: знання не лежить в одному конкретному місці нейромережі, як запис у таблиці бази даних, а розподілене між багатьма вагами та внутрішніми активаціями моделі. Тому доречно уявляти це як складну систему зв'язків: елементи тексту активують фічери, а поєднання фічерів утворюють певне знання, а їх сукупність допомагає моделі формувати відповідь. Аналогічно LLM аналізує промпт користувача - шукає у ньому типові елементи, для яких в неї є алгоритм визначення певних фічерів та по них - знань, а тоді все це дозволяє "розуміти" контекст та враховувати під час формування відповіді.

Для інтуїтивного розуміння можна провести аналогію з форматом кольору RGB. Лише три канали — червоний, зелений і синій — дають змогу утворювати велику кількість різних кольорів. Подібно до цього, порівняно невелика кількість числових параметрів нейромережі може кодувати значно більшу кількість знань та фактів. Але важливо розуміти, що це не пряме зберігання фактів, як у довіднику, а складне розподілене подання закономірностей, фічерів і зв'язків між ними з використанням певних механізмів узагальнення.

Можна умовно уявити, що LLM з 1 млн параметрів не зберігає 1 млн фактів як окремі записи, а кодує, наприклад, сотні тисяч базових знань, понять і закономірностей. Завдяки їх комбінуванню модель може генерувати у відповідях уже мільйони або навіть десятки мільйонів похідних знань у різних контекстах.

2.3 Аналіз семантичної подібності та релевантності в генеративних задачах

У генеративному ШІ важливо не тільки зберігати або подавати знання, а й уміти визначати, які фрагменти даних є близькими за змістом, доречними для конкретного запиту та корисними для побудови відповіді. Саме для цього використовують аналіз семантичної подібності та релевантності. Він дає змогу знаходити потрібні фрагменти тексту, добирати аргументи, порівнювати альтернативи, ранжувати джерела та формувати контекст для генерації відповідей.

Якщо знання подані у векторному просторі, то можна обчислити числову міру близькості між їхніми векторними поданнями. Система може оцінити, які з них є ближчими між собою за змістом, і використати це для пошуку релевантного контексту. Саме цей принцип лежить в основі семантичного пошуку, retrieval у RAG-системах, ранжування відповідей та багатьох агентних систем.

Разом із тим, семантична подібність і релевантність — це різні поняття.

Семантична подібність означає змістову близькість між двома об'єктами, наприклад між запитом і фрагментом документа.

Релевантність означає відповідність об'єкта конкретній цілі, запиту або задачі користувача.

Тому фрагмент може бути семантично близьким до запиту, але не бути достатньо релевантним для прийняття рішення. Наприклад, текст про загальні принципи роботи чат-ботів може бути близьким до запиту про масштабування чат-бота, але для розрахунку потрібного навантаження більш релевантним буде фрагмент із конкретними числовими параметрами, обмеженнями системи та вимогами до продуктивності.

У задачах підтримки прийняття рішень ця відмінність є особливо важливою. Для СППР недостатньо знайти матеріал, який «схожий за темою». Потрібно знайти саме ті дані, факти, аргументи або правила, які допомагають обрати дію, оцінити ризик, порівняти альтернативи або пояснити рекомендацію. Тому релевантність у генеративному ШІ слід розглядати не лише як змістову близькість, а як корисність знайденого контексту для конкретної задачі.

Для оцінювання близькості у векторних просторах використовують різні метрики. Часто використовують кутову або косинусну близькість (метрика `cosine_similarity` у Python-бібліотеці `sklearn`), евклідову відстань та інші способи порівняння векторів.

Цю ідею зручно показати на прикладі алгебри ембедінгів. Вище у підрозд. 1.1 були наведені приклади наявності відношень між словами King, Kings та ін. (див. рис. 1.1).

Наприклад, у векторному просторі можна розглядати умовні переходи на кшталт: Паганіні – скрипка + фортепіано $\approx$ Ліст або Моцарт, залежно від того, які саме дані, модель ембедінгів і простір ознак використано (рис. 2.7).

Цікаво, що для побудови цього ноутбука довелося чітко вказувати, що слід шукати близькість тільки серед музикантів, у протилежному випадку оптимальними виявлялись слова, які зовсім не відповідають, навіть людям. Такий приклад не слід сприймати як точну математичну тотожність - насправді, достатньо знайти на який вектор найбільше схожий результуючий вектор, отриманий завдяки поелементному додаванню.

У генеративних задачах після обчислення подібності зазвичай виконується ранжування. Це означає, що знайдені фрагменти, документи, відповіді або альтернативи впорядковуються за ступенем відповідності запиту чи цілі. Після цього система відбирає частину найкращих результатів і передає їх моделі як контекст. Такий підхід є основою RAG-систем: спочатку виконується пошук релевантних фрагментів, потім вони додаються до пром프트, і лише після цього модель формує відповідь.




Рисунок 2.7 – Ілюстративний приклад «алгебри» ембедінгів музикантів з авторського ноутбуку [28], отриманий з використанням моделі «sentence-transformers/paraphrase-multilingual-MiniLM-L12-v2»:
а) українською мовою; б) англійською мовою

Якість генерації значною мірою залежить від якості цього відбору. Якщо в контекст потрапили нерелевантні або суперечливі фрагменти, модель може сформувати неточну, неповну або зайво впевнену відповідь. Якщо ж контекст підібрано правильно, то відповідь зазвичай стає точнішою, краще обґрунтованою і кориснішою для користувача. Тому аналіз семантичної подібності та релевантності є не лише технічним етапом пошуку, а й важливою умовою якості генерації, рекомендацій і пояснень.

Отже, у генеративному ШІ семантична подібність допомагає знайти змістово близькі об'єкти, а релевантність — відібрати з них ті, що справді відповідають меті запиту або задачі. Для систем підтримки прийняття рішень це особливо важливо, оскільки якість рекомендацій залежить не тільки від здатності моделі генерувати текст, а й від того, наскільки правильно було знайдено, ранжовано і використано потрібний контекст.

2.4 Формування корпусів і датасетів для генеративного штучного інтелекту

Генеративний ШІ потребує принципово інших типів датасетів, ніж класичне машинне навчання. Якщо в задачах класифікації або регресії датасет — це таблиця з ознаками та мітками, то для LLM датасет — це передусім *корпус (corpus)* — великий масив текстів, відібраних і структурованих відповідно до цілі. Розуміння типів корпусів і принципів їх формування є необхідним для правильної постановки задач навчання, оцінювання та вдосконалення генеративних моделей.

Залежно від ролі у процесі побудови моделі, датасети для ГШІ поділяються на чотири функціональні типи, розглянемо кожен з них.

Навчальний корпус (pretraining corpus) — масив текстів, на якому LLM проходить переднавчання. Охоплює десятки або сотні мільярдів токенів з різноманітних джерел (вебтексти, книги, наукові статті, код). Визначає базовий словниковий запас і загальні знання моделі. Для типової LLM цей корпус не публікується повністю, однак його склад суттєво впливає на поведінку моделі в усіх подальших застосуваннях [29].

Датасет тонкого донавчання (fine-tuning / instruction dataset) — відносно невеликий (від кількох тисяч до мільйонів прикладів) набір пар «інструкція → очікувана відповідь». Саме цей тип датасетів перетворює загальну LLM на корисного асистента: модель навчається дотримуватись інструкцій, відповідати у заданому форматі та уникати небажаної поведінки. Класичний формат — *instruction-following dataset* на кшталт Alpaca або FLAN [30].

Іншим ефективним прикладом є дослідження Д. Гончаренка, у співавторстві з одним зі співавторів цього посібника В. Мокіним, які створили чат-бот для автоматизації процесу проектування IoT-систем на базі LPWAN і який надає рекомендації щодо оптимальної архітектури, PFD-діаграм (у графічному і текстовому вигляді) та надання консультативної підтримки фахівцям-проектувальникам. Для цього було створено корпус з сотен статей у фахових виданнях, які знайшов і систематизував Д. Гончаренко, і які присвячені побудові подібних архітектур (рис. 2.8) [496]. Чат-бот продемонстрував високу ефективність на низці прикладів.

	Question	Answer
0	How does IoT improve quality of life and prote...	IoT improves quality of life by connecting eve...
1	Why are low-power narrow-band (LP-NB) protocol...	LP-NB protocols, like SigFox, are prone to col...
2	What role does IP connectivity play in IoT sys...	IP connectivity is fundamental to IoT, allowin...
3	How can IoT sensors achieve low cost and long ...	IoT sensors achieve low cost and long battery ...
4	Why is long-range communication essential for ...	Long-range communication is essential in urban...

Рисунок 2.8 – Фрагмент контенту корпусу для тонкого донавчання LLM для автоматизації процесу проектування IoT-систем на базі LPWAN [496]

Датасет переваг (preference dataset) — набір прикладів з кількома варіантами відповіді, ранжованими людьми-анотаторами від «кращої» до «гіршої». Використовується у методі *Reinforcement Learning from Human Feedback (RLHF)* для навчання моделі генерувати відповіді, які відповідають людським очікуванням. Прикладом є датасет *Anthropic HH-RLHF* [31].

Оцінювальний датасет (evaluation dataset) — набір задач або питань з еталонними відповідями, призначений виключно для вимірювання якості моделі. Не бере участі в навчанні. Саме на основі оцінювальних датасетів будуються бенчмарки, які детально розглядаються у розділі 5.

Ключова відмінність датасетів для ГШІ від класичних полягає в тому, що тут якість анотацій і відповідність цілі важливіші за кількість прикладів. Тисяча ретельно підготовлених прикладів *instruction-following* може дати кращий результат, ніж мільйон автоматично зібраних записів сумнівної якості (рис. 2.9).




Рисунок 2.9 — Ролі різних типів датасетів у процесі побудови LLM [32]

Синтетичні дані (synthetic data) — це дані, згенеровані алгоритмічно або самою LLM, а не безпосередньо зібрані з реальних джерел. У контексті ГШІ вони відіграють дедалі важливішу роль з кількох причин.

Для багатьох спеціалізованих задач (юридичний аналіз, медична документація, рідкісні мови) не існує достатньої кількості якісно анотованих прикладів. Потужна загальна LLM здатна згенерувати тисячі правдоподібних прикладів у потрібному форматі, які потім верифікуються і використовуються для донавчання спеціалізованої моделі. Цей підхід отримав назву *model-generated data* або *self-instruct* [33].

Крім навчання, синтетичні дані застосовуються для *автоматичного розширення оцінювальних наборів*. Замість того, щоб платити анотаторам за складання тисяч тестових питань, LLM може генерувати різноманітні варіації питань на основі вихідних тем, якщо базова модель достатньо потужна і процес ретельно контролюється.

Використання синтетичних даних несе специфічні ризики, які необхідно враховувати:

- *Накопичення помилок (model collapse)* — якщо модель навчається переважно на власних синтетичних виводах, вона поступово «звужується»: зменшується різноманітність генерацій, і модель посилює власні упередження [34].

- *Збереження помилок оригінальної моделі* — якщо потужна модель-генератор «галюцинує», її синтетичні дані містять ці помилки і передають їх меншій моделі, що навчається на них.

- *Відсутність новизни* — синтетичні дані не можуть замінити реальні дані у задачах, що потребують актуальних фактів або специфічного досвіду, недоступного в навчальному корпусі генератора.

Попри ці ризики, синтетичні дані стали стандартним інструментом у розробці LLM. Зокрема, успішний проєкт *Phi-4* від Microsoft (2024) продемонстрував, що невелика модель, навчена переважно на ретельно відібраних синтетичних даних, може перевершити значно більші моделі на деяких аналітичних задачах, що підтверджується деякими тестами (бенчмарками) [35].

Контрольні питання

1. Як тріада «дані → інформація → знання» переосмислюється з позицій генеративного ШІ? Чим «знання» у LLM принципово відрізняються від знань в експертних системах на основі правил?

2. Що таке *контекстне вікно* і яку роль воно відіграє у формуванні відповіді моделі? Як якість і порядок розміщення інформації у контексті впливає на точність генерації?

3. Порівняйте *онтологію* і *семантичну мережу* як засоби подання знань: що спільне і що відмінне? Наведіть приклад, коли для прикладної АІ-СППР краще підходить граф знань, а не векторне подання.

4. Що таке *ембедінг*? Поясніть інтуїтивно, чому геометрична близькість у векторному просторі може відображати семантичну близькість понять. Наведіть приклад аналогії типу «Париж – Франція + Італія = Рим».

5. Чим *семантична подібність* відрізняється від *релевантності* у задачах підтримки прийняття рішень? Наведіть приклад, коли два тексти є семантично подібними, але лише один із них релевантний конкретному запиту.

6. Для чого в системному аналізі потрібне *ранжування контексту*? Поясніть, чому відбір релевантних фрагментів є критично важливим кроком перед генерацією відповіді або рекомендації.

7. Назвіть і охарактеризуйте чотири типи датасетів для ГШІ. Чому *evaluation dataset* повинен бути повністю відокремлений від навчального корпусу, і що відбувається у разі *забруднення бенчмарку* (benchmark contamination)?

8. Що таке *синтетичні дані* у контексті ГШІ і коли їх доцільно застосовувати? Поясніть явище *model collapse*: чому модель, що навчається лише на власних виводах, поступово погіршується?

9. З яких складових формується *контекст* для LLM або агента? Чому для агентних систем контекст відіграє роль «оперативної пам'яті», а не просто набору вхідних даних?

10. Поясніть, яким чином поєднання *онтологій* і *векторного подання* знань забезпечує ефективну роботу прикладних AI-СППР. Чому одного підходу (лише графів або лише ембедінгів) зазвичай недостатньо?

3 ГЕНЕРАТИВНІ МОДЕЛІ ТА ВЕЛИКІ МОВНІ МОДЕЛІ В СИСТЕМНОМУ АНАЛІЗІ

3.1 Великі мовні моделі як моделі для генерування тексту та роботи зі знаннями

Мовна модель (Language Model) — Модель машинного навчання, яка на- тренувана оцінювати ймовірності послідовності слів чи символів. Після тре- нування вона може генерувати або закінчувати послідовності на основі вив- чених закономірностей природної мови.

Велика мовна модель (Large Language Model, LLM) — клас мовних мо- делей, які використовують алгоритми глибокого навчання та навчаються на великих наборах даних, що можуть містити не тільки текст, а й інші мода- льності (зображення, аудіо тощо) [36]. Принципово важливо розуміти: LLM *не зберігає факти як база даних і не виконує алгоритми як класична про- грама*. Вона формує ймовірнісні узагальнення мовних і змістових закономі- рностей, що проявляються під час генерації. Відповідь LLM формується як послідовність токенів, кожен з яких обирається на основі ймовірнісного ро- зподілу, побудованого моделлю з урахуванням попереднього контексту. Ві- дповідь є не простим пошуком готового факту, а результатом генерації на основі вивчених мовних і змістових закономірностей у контексті всього, що вона «бачила» під час навчання [37].

Концепцію *фундаментальних моделей (foundation models)* запропонували у 2021 році дослідники Стенфорду [38]: це моделі, що навчаються на вели- ких загальних даних і потім *адаптуються* до конкретних задач — без нав- чання «з нуля». Така парадигма замінила попередній підхід, де для кожної задачі (класифікація, переклад, генерація) будувалась окрема спеціалізована архітектура. LLM є найбільш масштабованим прикладом базових моделей: одна й та сама модель здатна писати код, аналізувати документи, перекла- дати тексти та генерувати рекомендації — залежно від промпту.

Базовою одиницею обробки у LLM є *токен* (див. визначення у підрозд. 2.1 та приклади на рис. 2.2). Модель ніколи не «бачить» текст цілком — вона обробляє послідовність токенів у межах *контекстного вікна*. Від 2023 до 2026 року розмір контекстного вікна виріс із 4 тис. (GPT-3.5) до близько 1 млн токенів у деяких версіях і платформах, наприклад у Gemini 3.1 Pro та Claude Opus 4.8. Однак фактичний ліміт залежить від конкретної моделі, API, тарифу і платформи [39]. Станом на 2026 р. максимальний розмір вікна Gemini досяг вже 2+ млн. токенів.

Знання у LLM подані неявно — через ваги нейронної мережі, що «пам'- ятають» закономірності навчального корпусу. На відміну від онтологій і баз знань (розд. 2.2), де знання формалізовані явно як правила і відношення, LLM оперує *розподіленим поданням*: кожне поняття кодується як напрямок у багатовимірному просторі, а не як іменований запис. Це забезпечує гнуч-

кість і узагальнення, але ускладнює перевірку і виправлення конкретних фактів. Саме тому для прикладних систем LLM доповнюється зовнішніми джерелами знань через RAG (підрозд. 3.3).

Різні варіанти LLM суттєво відрізняються за поведінкою, і ця відмінність має практичне значення для побудови AI-СППР.

Базові моделі (base / pretrained models) — результат переднавчання на великих корпусах. Вони продовжують текст статистично, але не мають поняття про «корисну відповідь» чи «безпечну поведінку». Базові моделі — це лише вихідний матеріал для подальшої адаптації.

Інструктивні моделі (instruction-tuned models) — донавчені на наборах пар «інструкція → відповідь» з тим, щоб модель дотримувалась завдань. Вони здатні виконати конкретне прохання: «напиши функцію Python», «перекладу на українську», «склади звіт». Більшість API-моделей (Gemini 2.5, Claude Sonnet 4, GPT-5) є саме інструктивними [39].

Діалогові моделі (chat / conversational models) — це різновид інструктивних моделей, додатково донавчених через технологію RLHF (підкріплювальне навчання із зворотним зв'язком від людей) для підтримки природного багатокрокового діалогу, відмови від шкідливих запитів і збереження стилю розмови. Саме ці моделі лежать в основі ChatGPT, Claude, Gemini і є першочерговим вибором для AI-асистентів і СППР.

Таким чином, LLM — це універсальне ядро, до якого підключаються дані (через RAG), інструменти (через tools, function calling, MCP) і механізми оцінювання (через бенчмарки). Саме ця архітектурна роль LLM визначає логіку всієї другої частини посібника: агенти (розд. 4), AI-СППР (розд. 4.5) і бенчмарки (розд. 5) — це різні способи організувати роботу навколо LLM-ядра.

Загалом, можна провести аналогію між основними видами LLM і технік роботи з ними на прикладі дресирування собак для різних задач пошуку, охорони, боротьби з порушниками, які вирішують поліцейські чи військові (рис. 3.1).

Собаки мають базові знання та вміння — цьому відповідає варіант «**Base LLM**». Собак дресирують, щоб вони вміли виконували команди, надані певною природною мовою — цьому відповідає варіант «**Instruct LLM**».




Рисунок 3.1 – Основні види LLM та технік роботи з ними на прикладі дресирування поліцейських собак (зображення згенеровано з використанням OpenAI ChatGPT/GPT-5 за авторським описом, серпень 2025 р.)

Досвідчений собака значно краще виконує команди, оскільки завдяки зворотному зв'язку, з часом, навчається розуміти більше тонкощів цих команд – це згадане вище **навчання з підкріпленням на основі зворотного зв'язку від людини (RLHF)**. Для людей важливо вміти звести розв'язання заданої задачі до серії таких команд, які слід чітко формулювати за певними шаблонами. У великих мовних моделях це вміння називають **Prompt Engineering** (див. підрозд. 1.2). Але відточування команд не впливає на фактичні знання моделі. Жодна велика мовна модель не знає усіх фактів про будь-яку дуже вузьку прикладну задачу. Вона може гарно розповісти про щось, запропонувати методологію розв'язання, але одразу надати відповідь зі специфічними технічними деталями не зможе, особливо, якщо ці деталі відсутні у відкритому доступі в Інтернеті чи їх там важко знайти. Наприклад, якщо ви хочете, щоб звичайна собака ще й шукала вибухівку чи наркотики, тоді вам спочатку слід її спеціально натренувати. У великих мовних моделях це – донавчання моделі (**файнтюнінг**). Якісний fine-tuning, насамперед, на основі великої кількості експертних знань навчає модель стабільно виконувати певний клас задач: дотримуватись потрібного стилю, формату, термінології та логіки відповіді. Неякісне навчання чи малий обсяг знань може, навпаки, погіршити модель.

Розглянемо як саме працює типова LLM та як здійснюється її навчання.

3.2 Трансформерні архітектури та механізм уваги

Архітектура *трансформера*, запропонована у роботі Vaswani et al. (2017) [12], стала фундаментом переважної більшості сучасних LLM. Її ключова ідея — відмова від рекурентності (RNN, LSTM) на користь *механізму уваги (attention)*, що дозволяє обробляти всі токени послідовності *паралельно*, а не послідовно. Це усунуло головне обмеження попередніх архітектур — неможливість ефективно передавати інформацію між далекими позиціями в тексті.

Механізм уваги вирішує просте, але фундаментальне питання: *яким частинам вхідного тексту слід приділяти найбільше «уваги» під час оброблення кожного конкретного токена?* Щоб зрозуміти це інтуїтивно, розглянемо речення: «Банк затопило — річка вийшла з берегів». При обробці слова «банк» модель повинна «зрозуміти», що тут мається на увазі берег річки, а не фінансова установа. Механізм уваги дозволяє їй динамічно зважити зв'язок між «банком» і словами «річка» та «берегів», отримавши правильну інтерпретацію.

Технічно кожен токен перетворюється на три вектори: *Query* (запит), *Key* (ключ) і *Value* (значення). Вага уваги між токенами визначається скалярним добутком *Query* одного токена та *Key* іншого — чим вищий добуток, тим «уважніше» модель ставиться до відповідного контексту. Результуюче подання токена є зваженою сумою векторів *Value* всіх інших tokenів. Цей процес є *диференційованим* (тобто ваги визначаються автоматично, а не задаються вручну) і виконується для всіх пар tokenів паралельно [12].

Зв'язок із семантичною подібністю (див. підрозд. 2.3) тут прямий: увага — це, по суті, *внутрішній семантичний відбір*, що відбувається в кожному шарі моделі. Саме він допомагає моделі враховувати семантично важливі частини контексту, щоб «зрозуміти» контекст, а не лише запам'ятовувати токени у фіксованому порядку. Зовнішні аналоги цього ж принципу — RAG та агентні системи, де семантичний пошук виконується поза межами моделі.

На рис. 3.2 показано реальний приклад ваг уваги: темніші лінії між токенами відповідають вищим значенням уваги. Видно, що при обробці кожного слова модель «дивиться» не лише на сусідні токени, а на *весь* контекст одночасно, причому різні токени мають різний ступінь значущості.

Трансформер складається з *шарів*, кожен з яких містить блок уваги і нейронну мережу прямого поширення (*feed-forward*). Модель обробляє вхідну послідовність tokenів, передаючи її через усі шари — при цьому представлення кожного токена збагачується контекстом усіх інших. Три принципи відрізняють трансформерні архітектури від попередніх підходів:




Рисунок 3.2 – Ілюстрація зв'язків у головці уваги трансформера під час роботи з текстом з авторського ноутбука [40]

- *Паралельне оброблення* — на відміну від RNN, де токени обробляються послідовно, трансформер обробляє всі токени одночасно. Це забезпечило на порядки вищу ефективність навчання і відкрило можливість для масштабування на тисячах GPU.
- *Багатоголовкова увага (Multi-Head Attention)* — замість однієї головки уваги трансформер використовує кілька паралельних (наприклад, 96 у GPT-3). Кожна головка навчається звертати увагу на різні аспекти тексту: одна — на синтаксичні зв'язки, інша — на семантичні, третя — на кореференцію (хто на кого посилається). Результати всіх головок об'єднуються в єдине подання [41].

- *Позиційне кодування (Positional Encoding)* — оскільки увага не враховує порядок tokenів сама по собі, до кожного токена додається вектор, що кодує його позицію в послідовності. Це дозволяє моделі розрізняти «собака вкусила людину» і «людина вкусила собаку» попри однаковий набір tokenів.

Більшість сучасних LLM побудована на блоках уваги (так звана *decoder-only* архітектура для генерації тексту — GPT, Llama, Gemini, Claude) або на поєднанні енкодера і декодера (для задач типу «переклад»). GPT-подібні моделі використовують *причинну увагу (causal attention)*: кожен token бачить лише попередні токени, але не майбутні — що й забезпечує авторегресивну генерацію.

Механізм уваги безпосередньо відповідає за якість ключових властивостей LLM, що критично важливі для AI-СППР.

Узгодженість з контекстом. Коли аналітик задає складне запитання з кількома умовами («яка максимальна концентрація фосфатів у р. Інгул за останні 5 років і чи перевищує вона ГДК?»), модель завдяки механізму уваги одночасно «тримає» всі частини запиту у фокусі при формуванні відповіді. Без уваги RNN-модель «забувала» б ранні частини запиту при обробці пізніх.

Довгий контекст. Зростання вікна контексту до 1 млн tokenів стало можливим саме через архітектурні вдосконалення механізму уваги (Rotary Position Embeddings, FlashAttention [42]) — ефективні обчислення матриці уваги для дуже довгих послідовностей. Для AI-СППР це означає здатність обробляти цілі річні звіти або бази нормативних документів в одному контексті.

Трансформери для зображень (ViT). Принцип уваги поширився на візуальні дані через архітектуру *Vision Transformer (ViT)*, запропоновану Dosovitskiy et al. (2020) [43]. Зображення розбивається на прямокутні «патчі» (*patches*), кожен з яких кодується аналогічно текстовому токеноу, після чого механізм уваги визначає зв'язки між патчами (рис. 3.3).

Саме ViT став основою для мультимодальних моделей (підрозд. 3.4): той самий механізм уваги обробляє і текст, і зображення в єдиній архітектурі.

Таким чином, механізм уваги є *архітектурним принципом*, що робить LLM принципово відмінними від всіх попередніх нейронних архітектур. Його розуміння пояснює, чому трансформери масштабуються, чому вони чутливі до структури промпту і чому вони є ідеальним ядром для агентних систем: вміння динамічно фокусуватись на релевантному контексті є саме тим, що потрібне агенту для планування і прийняття рішень.




Рисунок 3.3 – Ілюстрація зв'язків у головці уваги ViT під час роботи із зображенням з авторського ноутбука[40]

3.3 Адаптація генеративних моделей до прикладних задач

Універсальна LLM — це відправна точка, а не кінцева мета. Вона добре орієнтується у загальних темах, але не знає специфічного термінологічного словника підприємства, поточних нормативних документів галузі, або прийнятого в організації формату звітності. Завдання адаптації — *наблизити загальну модель до конкретної предметної задачі* з мінімальними витратами часу і ресурсів. Умовно можна виділити три підходи до адаптації: без зміни ваг моделі (промпт та RAG), параметрично-ефективне донавчання (PEFT, зокрема LoRA) та повне донавчання (full fine-tuning).

Контекстна адаптація (промпт та RAG). Найпростіший і найшвидший метод — надати моделі доменний контекст безпосередньо у промпті. Якщо у вікно контексту завантажити нормативний документ, технічний регламент або поточні дані вимірювань, модель «знатиме» їх тільки під час сесії. Розширений варіант — *Retrieval-Augmented Generation (RAG*, рис. 3.4): система автоматично витягує релевантні фрагменти з великої бази документів і підставляє їх у контекст. RAG не змінює ваги моделі, тому ніякого повторного навчання не потрібно — достатньо побудувати векторний індекс [44].

Переваги RAG: не потрібно донавчати ваги LLM, базу знань легко оновлювати, а відповіді можна пов'язувати з конкретними джерелами. Обмеження: якість залежить від підготовки корпусу, розбиття на фрагменти, якості ембедінгів, релевантності вибірки даних на етапі retrieval, точності цих даних, ранжування знайдених фрагментів і розміру контекстного вікна. Модель не «засвоює» специфіку предметної області, а лише «бачить» її у конкретний момент.




Рисунок 3.4 – RAG-архітектура (зображення згенеровано з використанням OpenAI ChatGPT/GPT-5 за авторським описом, серпень 2025 р., з постообробленням у графічному редакторі)

Аналогом RAG є ситуація, коли разом із собакою йде кінолог-поліцейський з рацією у вусі, по якій йому надають поради, користуючись найсвіжішими знаннями та фактами, а він акумулює цю інформацію і перетворює на команди собаці, які будуть більш змістовними і релевантними ситуації, ніж могли б бути, якби він користувався лише власним досвідом. Такий варіант значно більш функціональний та ефективний, тому RAG-архітектура отримала значну популярність (рис. 3.5).




Рисунок 3.5 – Аналогія RAG-архітектури з поліцейським із собакою (зображення згенеровано з використанням OpenAI ChatGPT/GPT-5 за авторським описом, серпень 2025 р., з постообробленням у графічному редакторі)

Тонке донавчання (Fine-tuning) (див. рис. 3.1). Якщо задача потребує зміни *стилю* генерації (формат відповіді, рівень деталізації, термінологія)

або якщо доменних документів занадто багато для вікна контексту — застосовується тонке донавчання (*fine-tuning*): модель продовжує навчання на доменному датасеті. Вся потужність базової моделі зберігається, але ваги зміщуються у бік доменної специфіки.

Ключовий ризик *fine-tuning* — *катастрофічне забування* (*catastrophic forgetting*): надмірне донавчання на вузькому датасеті може призвести до деградації загальних здібностей моделі. Тому для виробничих систем завжди варто зберігати базову контрольну точку і перевіряти якість на широкому бенчмарку після кожного циклу донавчання [45].

Гарним прикладом ефективного застосування тонкого донавчання LLM є згаданий у підрозд. 2.4 чат-бот, створений Д. Гончаренком та В. Мокіним, для автоматизації процесу проектування IoT-систем на базі LPWAN на основі донавченої LLM, який надає рекомендації щодо оптимальної архітектури, PFD-діаграм (у графічному і текстовому вигляді) і надання консультативної підтримки фахівцям [496] (див. рис. 2.8).

Інструктивне навчання (Instruction Tuning). Базова LLM навчається продовжувати текст, але не «слухатись» інструкцій. Інструктивне навчання (*instruction tuning*) — це донавчання на наборі пар «інструкція → відповідь», що вчить модель виконувати завдання у природномовній формі. Саме цей крок перетворює базову модель на корисного асистента [3]. Для прикладних задач це означає: можна створити власний датасет інструкцій, специфічних для домену («Проаналізуй наданий аналіз якості води і вкажи перевищення ГДК у форматі JSON»), і навчити модель стабільно дотримуватись цього формату.

LoRA і параметрично ефективна адаптація. Повне донавчання великої моделі вимагає значних обчислювальних ресурсів — наприклад, навчання Llama 3 (8B параметрів) на одному A100 GPU займає дні. Параметрично ефективна адаптація (*Parameter-Efficient Fine-Tuning, PEFT*) вирішує цю проблему: замість оновлення всіх ваг моделі навчається лише невелика додаткова матриця, накладена на існуючі ваги.

Найпоширеніший метод — *Low-Rank Adaptation (LoRA)* [46]: для кожного шару уваги додаються дві невеликі матриці низького рангу (A і B), добуток яких апроксимує оновлення ваг. У типових конфігураціях LoRA навчає лише невелику частку параметрів моделі — часто менше кількох відсотків, залежно від рангу адаптерів і вибраних шарів. Це істотно зменшує вимоги до пам'яті GPU і робить адаптацію великих моделей доступнішою, хоча фактичний виграш залежить від моделі, довжини контексту, batch size і способу квантування. Після навчання LoRA-матриці можуть бути "злиті" з основними вагами або залишатись окремо — що дозволяє зберігати кілька доменних адаптацій на одній базовій моделі.

Вибір між методами адаптації — практичне рішення системного аналізу, що залежить від чотирьох факторів: *доступних ресурсів, стабільності*

домену, вимог до якості та необхідності оновлення знань. Загальна рекомендація: починати з промпт-інжинірингу і RAG, і переходити до донавчання лише тоді, коли вони не забезпечують необхідної якості.

- **Коли достатньо промпту і RAG:** домен змінюється часто (нові нормативи, поточні дані), є чіткі джерела знань, що можна проіндексувати, або потрібна трасовність відповідей (посилання на конкретний документ).
- **Коли потрібен LoRA:** необхідно стабільно дотримуватись певного формату або термінологічного стилю, не покладаючись на промпт; або базова модель систематично помиляється у вузькому класі задач незалежно від якості промпту.
- **Коли виправданий Full Fine-tuning:** задача вимагає фундаментальної зміни поведінки (наприклад, перетворення загальної моделі на спеціалізовану медичну або юридичну), а датасет є великим, стабільним і якісно анотованим.

3.4 Моделі для генерування зображень

Як було зазначено у підрозд. 1.1 у 2014 р., у статті [6] була запропонована архітектура на основі змагальних генеративних мереж («Generative Adversarial Network» – GAN) (рис. 3.6).




Рисунок 3.6 – Принцип роботи Generative Adversarial Network [47]

Система нейромереж-генераторів ("Generator") генерує синтетичні вибірки даних з випадкових вхідних векторів (з "шуму"), намагаючись зробити зображення, максимально наближені до розподілу реальних даних. Система інших нейромереж-дискримінаторів ("Discriminator"), намагається розібратись які їй на вхід подаються зображення - істинні чи діп-фейки з генератора? Але популярний для пояснення роботи GAN рисунок 3.6, на жаль, не повністю відображає головний механізм роботи GAN, який пов'язаний зі зворотним зв'язком від дискримінатора до генератора. Дискримінатор повертає не бінарне значення 0 чи 1, а він оцінює ймовірність того, що це зображення є реальним, що дозволяє обчислити градієнт для налаштування ваг генератора, тобто як їх краще змінити, щоб наступна генерація була більш реалістичною.

На рис. 3.7 наведено низку зображень, згенерованих у Kaggle одним із авторів посібника з використанням моделі «StyleGAN2-ADA».



Рисунок 3.7 – Діпфейки, згенеровані з використанням моделі «StyleGAN2-ADA» (див. «StyleGAN2-ADA» на GitHub [48] та Kaggle ноутбук [49] для застосування цієї моделі), змінюючи різні параметри стилів для заданого фото

Однією з головних проблем GAN є низька різноманітність результатів. Якщо домогтися більшої різноманітності, то падає точність (реалістичність). Крім того, не дивлячись на високу візуальну точність, більш прискіпливий аналіз збільшених фрагментів зображення дозволяє виявити патерни («узори») певного виду, якщо знати де і що шукати. Це один із способів, який використовують діпфейк-детектори, які часто не тільки визначають, що це діпфейк, а й визначають якою саме GAN-моделлю він був згенерований!

Більшу різноманітність забезпечує модель *варіаційний автоенкодер* (англ. «Variational Autoencoder» – VAE). Принцип дій такий самий, як і в згорткових автоенкодерах (див. [1]), але в гирлі – не просто числова багатовимірна матриця, а латентний простір. Енкодер (кодувальник) VAE стискає багато зображень у цей простір, формуючи щоразу елемент множини багатовимірних ймовірнісних розподілів, який є аналогом вхідного зображення у певному сенсі. А потім декодер VAE випадково вибирає з цього розподілу низку параметрів і з них генерує вихідне зображення, яке може й відрізнятися від навчальних даних (рис. 3.8).




Рисунок 3.8 – VAE [50]

При цьому можливі деякі складнощі, але низка регуляризаційних обмежень дозволяє усунути більшість із них. Більш детально його робота описана у статті [37]. Однією з переваг є висока різноманітність зображень. Крім того, VAE працюють відносно швидше за GAN, хоча це залежить від багатьох умов.

Якщо проводити аналогію між природним інтелектом людей і штучним інтелектом машин, то GAN імітує роботу художника-фальсифікатора картин, який набув значного досвіду щодо їх малювання, але йому треба обманути експерта, який постійно перевіряє чи його творіння виглядає як справжнє. За результатами цих перевірок художник-фальсифікатор удосконалює свої техніки.

VAE імітує роботу досвідченого художника, який намалював велику кількість однотипних картин, а тоді кожну нову він малює на основі узагальненого їх бачення (умовного «латентного простору»), який тримає у

пам'яті. Бере якісь елементи з цього бачення (дерево, кущ, човен на воді, людей тощо) і поєднує їх з іншими таким чином, щоб кожна картина була унікальною.

У 2022–2026 роках одним із домінуючих підходів до генерації зображень стали *дифузійні моделі* (англ. «Diffusion models» – DM), що забезпечують високу якість, різноманітність і керованість результатів. Їх навчання ґрунтується на двох процесах. Спочатку до реального зображення поетапно додають гауссівський шум доти, доки воно майже не перетвориться на випадковий шум (рис. 3.9).




Рисунок 3.9 – Принцип роботи дифузійних моделей [51]

А потім модель навчається виконувати зворотний процес — поступово очищувати зашумлене зображення. На кожному кроці за зашумленим зображенням і номером цього кроку модель намагається передбачити, яку частину зображення становить шум. Її ваги оновлюються методом зворотного поширення помилки так, щоб передбачений шум дедалі точніше збігався з реально доданим шумом. Після навчання модель може почати з випадкового шуму і багаторазово застосовувати навчене “очищення”, поступово формуючи нове реалістичне зображення. З кожною ітерацією зменшується шум, уточнюються контури, структура сцени й дрібні деталі. Саме тому дифузійні моделі добре поєднують реалістичність і різноманітність результатів. Їх недоліком є відносно висока обчислювальна складність, особливо під час генерації, оскільки якісне зображення часто потребує багатьох кроків денойзингу. GAN або VAE в окремих задачах можуть працювати швидше, але зазвичай поступаються дифузійним моделям за керованістю і стабільністю якості. Більш детально див. у статті [52].

Аналогом DM є стиль реалістичного «рідкого» мистецтва (англ. «Fluid Art») або мистецтва розливання фарби («Pouring Art»), де завершена картина є реалістичною, а не абстрактною, як у Джексона Поллока. Це – стиль малювання, коли художник виливає пару відер чи банок різної фарби на велике полотно, а потім поступово майстерно розмазує фарбу таким чином, що утворюється реалістична картина. В YouTube є чимало таких прикладів. І вона буде унікальною, через різне співвідношення фарби, її суміш та його рухи. Але цей стиль є результатом тривалого навчання художника малювати подібні картини у звичайний спосіб, що дозволило йому зрозуміти які дії

слід зробити і в якій послідовності. І чим довше він потім працює з картиною, тим більш реалістичною вона стає, оскільки він починає з більш загальних елементів, поступово додаючи певні деталі.

Як було зазначено у підрозділі 1.1, однією з найбільш передових сучасних технологій є технологія дифузійного трансформера (DiT), яка поєднала в собі ключові ідеї попередніх найбільш передових технологій. DiT — це різновид дифузійної моделі, в якій для моделювання процесу денойзингу використовується трансформерна архітектура, що дозволяє ефективніше узгоджувати різні частини зображення і краще масштабувати модель. У багатьох реалізаціях DiT працює не з пікселями безпосередньо, а — з латентним простором зображення, що знижує обчислювальні витрати. Тому DiT можна розглядати як поєднання трьох важливих ідей генеративного ШІ: компактного латентного подання, дифузійної генерації та механізму уваги трансформера.

По суті, усі досвідчені художники тримають у пам'яті свої узагальнені бачення для різних видів елементів картини і автори стилю, який відповідає принципам DM, теж. Саме це й враховує DiT, але тут аналогія, скоріше, з розробником складної настінної мозаїки чи вітражів із глибоким змістом. Кожен елемент виготовлюється на основі узагальненого бачення художника щодо певних елементів, але його треба ув'язати з усіма іншими за гамою, кольором, розміром, текстурою. І далі трансформер дозволяє узгоджувати ці елементи між собою, щоб під час поступового очищення шуму вони не залишались окремими випадковими фрагментами, а поєднувались в єдине ціле і були пов'язані між собою різними сенсами та стилями відображення.

3.5 Генерація відео у прикладних задачах. Мультиmodalні генеративні моделі

Генерація відео є окремим і стрімко зростаючим класом задач генеративного ШІ. З методологічної точки зору він подібний до мовного: існує подання вхідних даних (текстовий промпт, контрольний образ, часові параметри), контекст і критерії якості результату. За 2024–2026 роки цей напрям пройшов шлях від лабораторних демонстрацій до зрілої прикладної технології, яка обслуговує понад 50 мільйонів активних творців щодня [53].

Починаючи з 2025 року, генерація відео перейшла від коротких 2–4-секундних кліпів до повноцінних кінематографічних сцен тривалістю 15–60 секунд у розрізненні 4K. Ключові системи:

- *Veo 3.1* (Google DeepMind, 2026) — одна з перших провідних систем, що генерує нативний синхронізований аудіосупровід (діалог, ефекти, фонові звуки) безпосередньо разом із відеорядом в одному проході без окремого зведення звуку.
- *Kling 3.0* (Kuaishou, лютий 2026) — нативне до 4K при 60 fps, до 15 секунд кліпу, мультимовна синхронізація губ, найкраще співвідношення ціна/якість.

- *Runway Gen-4.5* — один із лідерів за контрольованістю: підтримує motion brushes, тайм-лапс камери, послідовну ідентичність персонажів. Оптимальний вибір для виробничих конвеєрів з тісним редакторським контролем [54].

Показово, що Sora (OpenAI), яка у 2024 році вважалась революційним проривом, була закрита для публічного доступу у квітні 2026 року через невідповідність між операційними витратами (~\$15 млн/добу) та комерційним доходом [54]. Це є важливим прикладом того, що технічна вражаючість і комерційна стійкість є різними параметрами системи.

Дифузійні моделі можуть синтезувати деталі, яких немає у вхідному описі або які порушують фізичні та технічні обмеження. Наприклад, у генерованому архітектурному плані з'являються структурно неможливі елементи, у медичному знімку — анатомічно некоректні деталі. Показово, що GPT Image 2, незважаючи на значний прогрес у точності деталей, все одно генерує числові помилки у складних документах (рис. 3.10) [4].

Рисунок 3.1 — Порівняння провідних систем генерації зображень за ключовими критеріями (2026)




Рисунок 3.10 — Порівняння систем генерації зображень за критеріями якості, швидкодії та відкритості (зображення згенеровано з використанням Claude Sonnet 4.6 за авторським описом, травень 2026 р.)

Будь-який візуальний контент для технічних або управлінських рішень підлягає обов'язковій верифікації відповідним фахівцем.

Розвиток генеративного ШІ привів до появи систем, що не обмежуються одним типом даних. *Мультимодальні генеративні моделі* здатні одночасно сприймати і генерувати текст, зображення, аудіо та відео

в рамках єдиної архітектури, що принципово розширює можливості AI-асистентів і СППР.

Мультимодальність — здатність моделі обробляти і генерувати дані різних типів (модальностей — текст, зображення, аудіо, відео, таблиці, код) в рамках єдиного обчислювального процесу. На відміну від конвеєрного з'єднання спеціалізованих моделей (окремо OCR, окремо мовна модель), мультимодальна архітектура опрацьовує всі типи даних спільно, враховуючи перехресні залежності між ними через єдиний механізм уваги. Але у багатьох системах можуть бути й окремі енкодери для зображень, аудіо або відео, які потім узгоджуються з мовною моделлю.

Починаючи з 2024 року мультимодальність стала стандартом для провідних LLM, а до 2026 року — фактичною базовою вимогою для флагманських моделей [55]:

- *GPT-4o* (OpenAI) — підтримує введення тексту, зображень та аудіо, генерацію тексту і зображень; інтегрована в єдиний API-виклик [56];
- *Gemini 3.1 Pro* (Google, 2026) — нативно підтримує текст, зображення, відео та аудіо на вході; вікно контексту до 1 млн токенів; використовується у Google Workspace і Vertex AI [57];
- *Claude Opus 4.8* (Anthropic, травень 2026) — провідна модель за показниками Artificial Analysis Intelligence Index (61,4 бали) з суттєвими поліпшеннями у сприйнятті зображень та складному крос-модальному міркуванні [58];
- *Qwen3-VL-235B* (Alibaba, 2026) — відкрита мультимодальна модель, що конкурує з провідними пропрієтарними системами на бенчмарках зорового розуміння, підтримує OCR у 32 мовах і управління GUI-інтерфейсами [59].

За оцінками незалежних аналітичних платформ, Claude Opus 4.8 належить до найсильніших моделей 2026 року, зокрема за складним міркуванням і агентними задачами [60].

Технічно мультимодальність реалізується через уніфікацію різних типів даних в єдиному токенізованому просторі (рис. 3.11).

Зображення розбивається на патчі (*patches*), кожен з яких кодується у вектор — аналог текстового токена. Аудіо перетворюється на спектрограму і обробляється аналогічно. Модель «бачить» єдину послідовність токенів із змішаним текстовим і мультимедійним вмістом і навчається враховувати міжмодальні залежності.

Method A: Unified Embedding Decoder Architecture

Method B: Cross-Modality Attention Architecture




Рисунок 3.11 — Архітектура мультимодальної моделі: уніфікація токенів різних модальностей у єдиному просторі уваги[61]

Важливим прикладним наслідком є *крос-модальне міркування*: модель здатна порівнювати таблицю і графік на одному екрані, відповідати на питання про медичний знімок у контексті текстового анамнезу або описувати технічний дефект, побачений на фото, спираючись на нормативну документацію, завантажену в контекст. Для системного аналізу це означає можливість будувати AI-СППР, що одночасно опрацьовують числові дані, звіти, діаграми і фотографії об'єктів без ручного перекодування між форматами.

Ще одним важливим напрямом є *агентне керування інтерфейсами (GUI Agents)*: мультимодальна модель, що «бачить» екран комп'ютера як зображення, здатна автономно виконувати дії у програмах — заповнювати форми, читати таблиці, натискати кнопки. Станом на 2026 рік Qwen3-VL і GPT-4o демонструють практичне застосування цього підходу для автоматизації рутинних аналітичних операцій [62].

Мультимодальність у системному аналізі — це не «ефектність», а засіб підвищення *повноти аналізу і якості рішень*. Коли ЛПР може надати асистенту одночасно числові дані, фото об'єкта і текстовий опис проблеми, модель формує більш обґрунтовану рекомендацію, ніж при роботі з кожним джерелом окремо.

Мультимодальність є логічним продовженням базових моделей у напрямку більшої універсальності. Вона також формує архітектурну основу для агентів (див. наступний розд. 4): агент, що має доступ до зображень, аудіо та тексту одночасно, здатен вирішувати суттєво складніші задачі, ніж той, що працює лише з текстом — включно з автономним моніторингом виробничих об'єктів, аналізом мультимедійних звітів і управлінням програмними інтерфейсами.

Можливі теми практичних і лабораторних завдань

Тема № 2. Промпт-інжиніринг: від ідеї до структурованого запиту

Метою заняття є практичне опанування методів формулювання якісних промптів для LLM, розуміння впливу структури запиту на якість відповіді та формування власного набору промптів для задачі курсового проєкту.

План заняття:

1. Огляд типів промптів: інструктивні, контекстні, few-shot, Chain-of-Thought. Демонстрація різниці у результатах для кожного типу на одному завданні.
2. Вибір аналітичної задачі з предметної галузі (моніторинг, класифікація, рекомендації) та побудова системного промпту для неї.
3. Порівняльний аналіз відповідей при різних конфігураціях промпту (без системної інструкції, з нею, з few-shot прикладами). Фіксація спостережень.
4. Обговорення результатів: які елементи промпту найбільше впливають на якість? Формулювання критеріїв «хорошого промпту» для задач СППР.

Тема № 3. Порівняльний аналіз LLM та вибір інфраструктури

Метою заняття є розвиток здатності обґрунтовано обирати LLM і обчислювальну інфраструктуру для конкретної аналітичної задачі, застосовуючи багатокритеріальний підхід.

План заняття:

1. Огляд доступних LLM: Gemini, Claude, GPT, Llama, Mistral — характеристики, вартість, обмеження. Демонстрація роботи кожної моделі на ідентичному запиті.
2. Вибір задачі та складання таблиці порівняння: якість відповіді, вартість, швидкодія, конфіденційність. Побудова зваженого рейтингу за критеріями СППР.
3. Вибір обчислювального середовища: Kaggle / Google Colab / VS Code / Ollama (локально). Обговорення сценаріїв де кожен варіант є оптимальним.
4. Формулювання обґрунтованого вибору інструментального стеку для курсового проєкту з посиланням на критерії з підрозділу 5.4.

Тема № 2. Побудова ембедінгів тематичних корпусів та обчислення їх семантичної подібності

Метою роботи є опанування методів перетворення текстів у векторні подання (ембедінги), роботи з векторною базою даних ChromaDB та реалізації семантичного пошуку на основі косинусної відстані.

Хід роботи:

1. Отримання та опис набору даних: завантажити тематичний корпус текстів або PDF-документів із Kaggle, що відповідає профільній спрямованості студента; описати структуру, обсяг і якість даних.

2. Аналіз структури тексту: оцінити кількість символів, слів і сторінок; виявити шуми (html-теги, артефакти парсингу); визначити розподіл довжини речень для вибору оптимального розміру фрагментів (chunking).

3. Оброблення та векторизація: очистити текст, розбити на фрагменти фіксованого розміру з перекриттям (overlap); згенерувати ембедінги моделлю *text-embedding-004*; зберегти вектори у ChromaDB.

4. Візуалізація семантичного простору: побудувати гістограму розподілу довжини фрагментів; виконати семантичний запит та побудувати графік відстаней до результатів; побудувати теплову карту (heatmap) косинусної подібності між ключовими фрагментами.

5. Висновки: оцінити точність семантичного пошуку, визначити потенційні напрями вдосконалення (розмір фрагментів, фільтрація за метаданими); проаналізувати придатність побудованого корпусу для RAG.

Тема № 3. Донавчання LLM та аналіз змін її поведінки після адаптації

Метою роботи є вивчення методів керованого донавчання (Fine-Tuning) великих мовних моделей: підготовка датасету у форматі JSONL, запуск процесу адаптації через Google AI Studio і порівняльний аналіз базової та донавченої моделей.

Хід роботи:

1. Формування датасету для донавчання: визначити домен і стилістичну роль (мінімум 20 унікальних прикладів у форматі «запит → відповідь»); перевірити формат JSONL, наявність артефактів і відповідність термінології.
2. Аналіз датасету: оцінити розподіл типів запитань, медіанну кількість токенів у відповідях, середню довжину; побудувати гістограму довжини цільових відповідей.
3. Тестування базової моделі: надіслати 3–5 тестових запитів до базової моделі *gemini-2.5-flash*; зафіксувати відповіді для подальшого порівняння.
4. Запуск донавчання: реалізувати процес через метод *create_tuned_model* (параметри: *epoch_count*, *batch_size*, *learning_rate*); дочекатись завершення і отримати ідентифікатор донавченої моделі.
5. Порівняльний аналіз: надіслати ті самі тестові запити до донавченої моделі; порівняти відповіді за критеріями: дотримання ролі, точність, формат; зробити висновок щодо ефективності адаптації.

Контрольні питання

- 1) Чим відрізняється базова модель (*foundation model*) від інструктивної і діалогової? Яка з цих категорій лежить в основі AI-асистентів і чому саме вона підходить для задач підтримки прийняття рішень?
- 2) Чому кажуть, що LLM не «зберігає факти», а формує ймовірнісні узагальнення мовних закономірностей? Які практичні наслідки цього для використання LLM в аналітичних системах?
- 3) Поясніть роль *токенів* і *контекстного вікна* у роботі LLM. Як збільшення розміру контекстного вікна змінює можливості моделі при обробці довгих аналітичних документів?
- 4) Поясніть інтуїтивно принцип *механізму уваги* (*attention*). Чому він є внутрішнім аналогом процедур семантичного відбору, які виконуються зовні в RAG-системах?
- 5) Що таке *багатоголовка увага* (*multi-head attention*)? Яку перевагу дає одночасне використання кількох «голів» уваги порівняно з одною при обробці складного аналітичного запиту?
- 6) Порівняйте три підходи до адаптації базових моделей: *instruction tuning*, *LoRA* (параметрично ефективна адаптація) і *промпт-інжиніринг*. За яких умов кожен підхід є оптимальним? Які ризики надмірного донавчання?
- 7) Що таке *catastrophic forgetting* (катастрофічне забування)? У якій ситуації це явище є суттєвим ризиком при адаптації LLM до вузькодоменної задачі системного аналізу?
- 8) Порівняйте три архітектурні підходи до генерації зображень: *GAN*, *VAE* та *дифузійні моделі*. Чому саме дифузійні моделі стали домінуючою архітектурою у 2022–2026 роках? Яку роль вони відіграють в прикладних СППР?
- 9) Поясніть поняття *мультимодальності* у генеративному ШІ. Чому мультимодальність у системному аналізі — це засіб підвищення повноти аналізу, а не лише «ефектність»? Наведіть конкретний приклад мультимодального сценарію в AI-СППР.
- 10) Як у мультимодальних моделях досягається *крос-модальне міркування*: здатність відповідати на питання, що пов'язують текстові й візуальні дані? Яке практичне значення має ця можливість для задач промислової діагностики або екологічного моніторингу?
- 11) Що таке *GUI Agent Interface* або агент керування графічним інтерфейсом? Чому поява цього класу агентів стала можливою саме завдяки мультимодальним LLM і яку роль він може відігравати в автоматизації аналітичних операцій?
- 12) Встановіть логічний зв'язок між підрозділами розділу 3: як *механізм уваги* (3.2) пов'язаний з *адаптацією моделей* (3.3), а мультимодальність (3.4) — з агентними архітектурами (розд. 4)? Поясніть цей зв'язок у термінах системного аналізу.

4 ГЕНЕРАЦІЯ, ВЗАЄМОДІЯ ТА АГЕНТНІ АРХІТЕКТУРИ

4.1 Генерація як функціональний механізм у прикладних системах

У прикладних системах ГШІ доцільно розглядати не лише як інструмент творчості, а передусім як функціональний механізм перетворення даних, знань і запитів користувача у пояснення, код, звіти, візуалізації та рекомендації. Генерація вбудована у ланцюг *аналіз* → *інтерпретація* → *рекомендація*: LLM інтерпретує результати моделей природною мовою, описує наслідки сценаріїв «що, якщо» та формує обґрунтування для ЛПР.

За форматом виводу розрізняють три функціональні види: генерація тексту й аналітичних звітів, генерація програмного коду та генерація зображень і мультимедіа. Кожен вид виконує власну роль у СППР і розглядається нижче.

Текстова генерація у системному аналізі (рис. 4.1, табл. 4.1) — це інструмент стиснення, інтерпретації та документування даних. LLM формує резюме великих масивів документів (*summarization*), автоматично будує структуровані звіти та обґрунтовує прогнози природною мовою — на відміну від класичних ВІ-інструментів, які, переважно, подають результати у вигляді таблиць, дашбордів і графіків.




Рисунок 4.1 — Місце генерації тексту у ланцюзі прийняття рішень [63]

Поняття пояснюваного ШІ (*Explainable AI*, *XAI*) передбачає, що система не лише дає прогноз, але й обґрунтовує його: чому модель дійшла такого висновку, які ознаки мали найбільший вплив і яка невизначеність закладена у результат [64]. Це критично важливо для СППР: людина, яка приймає рішення (ЛПР), довіряє рекомендації лише тоді, коли розуміє її логіку.

Для формування звітів, що спираються на конкретну нормативну або предметну базу, застосовується підхід *Retrieval-Augmented Generation (RAG)*[65].

LLM може описувати наслідки різних управлінських рішень у природній мові: «що станеться з кредитним портфелем, якщо відсоткова ставка знизиться на 2%?». Такі текстові оцінки слід розглядати як *попередню гіпотезу*, що підлягає верифікації кількісними методами, — ГШІ формулює задачу, а не замінює модель.

Якщо текстова генерація продукує пояснення, то кодова — продукує дію. За природномовним запитом LLM генерує Python-, R- або SQL- скрипти, які можна виконати для отримання числових результатів. Точність цих результатів залежить від коректності згенерованого коду, вхідних даних і постановки задачі. Це переводить аналітика з ролі «програміста» у роль «постановника задач».

Для об'єктивного оцінювання кодових можливостей застосовуються спеціалізовані бенчмарки. SWE-bench Verified — один із найвідоміших бенчмарків для оцінювання coding agents, що містить 500 перевірених задач із реальних GitHub-репозиторіїв. Високі результати на ньому свідчать про суттєвий прогрес агентної кодогенерації, але не є повною гарантією готовності системи до промислової розробки без людської перевірки. Ключові функції генерації коду в ІАС:

- Автономні розрахунки — LLM генерує SQL/Python замість аналітика, усуваючи затримку між запитом і результатом.
- Автоматизація передобробки — очищення, нормалізація, дедублювання за шаблонними промптами.
- Прискорене прототипування — перевірка аналітичних гіпотез за хвилини без залучення розробника.
- Конвертація між інструментами — переклад коду між мовами (R → Python) або середовищами (SQL → pandas).

З 2025 року усталився клас *агентних середовищ кодогенерації* (рис. 4.2), де LLM отримує прямий доступ до файлової системи, терміналу та репозиторію. *Claude Code* (Anthropic, GA — травень 2025) [66] — термінально-нативний агент з вікном контексту до 1 млн токенів, здатний самостійно провести повний цикл аналізу: від завантаження та передобробки даних до інтерпретації результатів у текстовій формі. *Cursor (Anysphere)* [66] — AI-нативне IDE на основі VS Code, Agent mode якого досліджує кодову базу, генерує план, одночасно редагує кілька файлів і перевіряє компіляцію. Cursor 3 (квітень 2026) додав паралельне виконання агентів в ізольованих середовищах [66], відкриваючи можливість одночасного прототипування кількох аналітичних сценаріїв.

Tool	Architecture	Context Window	Best For	Gateway Support
Claude Code	Terminal agent	1M tokens	Deep refactors, architecture	Custom via config
Cursor 3	IDE + cloud agents	~200K tokens	Daily flow coding, parallel agents	Built-in routing
OpenAI Codex	Sandboxed VM, async	400K tokens	Background tasks, PR delivery	Built-in
Aider	Terminal, git-first	Repo map based	Open-source, model-agnostic pairing	Any OpenAI-compatible base URL
Roo Code	VS Code extension	Context dependent	Multi-mode structured workflows	Any OpenAI-compatible base URL
Cline	VS Code extension	Context dependent	Stepwise planning, wide adoption	Any OpenAI-compatible base URL

Рисунок 4.2 — Порівняння агентних інструментів кодогенерації [66]

Ключове обмеження — *галюцинації*: деталі, не передбачені промптом, або порушення технічних обмежень. Синтезовані зображення, що використовуються у технічних чи управлінських рішеннях, підлягають обов'язковій верифікації профільними фахівцями.

Три розглянуті види генерації є взаємодоповнювальними: текстова формує інтерпретацію, кодова виконує обчислення, мультимедійна візуалізує альтернативи.

4.2 Чат-боти та AI-асистенти як інтерфейс взаємодії з генеративним ІІІ

Між «викликом LLM» і повноцінним AI-агентом існує проміжний рівень — чат-боти та AI-асистенти. Саме вони є першою точкою входу користувача до систем ГШІ і забезпечують базову взаємодію людина–машина. Розуміння їх можливостей та обмежень є необхідною умовою для проєкування складніших агентних систем.

Класичні чат-боти (на основі правил або дерева рішень) поступово витісняються генеративними, побудованими на LLM. Генеративний чат-бот не прив'язаний до фіксованого сценарію — він генерує відповідь контекстуально, враховуючи всю попередню розмову в межах вікна контексту. Сучасні платформи (ChatGPT, Claude, Gemini) демонструють, що навіть базовий чат-бот на LLM здатний підтримувати аналітичний діалог: відповідати на питання про дані, інтерпретувати терміни, порівнювати альтернативи.

Типові обмеження чат-ботів у прикладних ІАС:

- Відсутність доступу до зовнішніх даних у режимі реального часу (без інтеграцій).
- Відсутність довготривалої пам'яті між сесіями (у базових реалізаціях).
- Пасивна роль: бот чекає запиту, не планує дії самостійно.

AI-асистент — функціональне розширення чат-бота. Якщо чат-бот орієнтований на діалог, то AI-асистент — на *виконання задач*: він зберігає контекст між кроками, звертається до зовнішніх джерел і адаптує свою поведінку до мети користувача (рис. 4.3).

	AI chatbot	AI agent
Primary function	Conversations and responses	Automates tasks, makes decisions, takes actions, and communicates those steps
Autonomy	Low Relies on predefined scripts and user prompts	High Can operate independently with minimal human input
Task complexity	Simple Focuses on common questions and repetitive tasks	Complex Capable of autonomous decision-making and problem-solving
Adaptability and learning	Limited Often requires manual updates for improvements	Advanced Continuously learns from interactions and adapts to new situations
Contextual understanding	Shallow Focuses on immediate user input with limited memory	Deep Remembers past interactions and understands context over time
Integration with enterprise workflows	Limited Typically receives basic data but doesn't perform complex operations	Advanced Can connect with multiple systems (like your CRM and databases) to execute tasks
Channels	Single channel Typically operates on a single platform (e.g., chat or voice)	Multichannel Supports multiple communication channels (e.g., chat, email, voice, APIs, and more)

Рисунок 4.3 — Порівняння можливостей чат-бота та AI-асистента [67]

У системному аналізі AI-асистент виступає *когнітивним підсилювачем (cognitive amplifier)* аналітика: допомагає структурувати задачу, сформулювати гіпотези, порівняти альтернативи і пояснити наслідки рішень. Він не замінює експерта, а знижує транзакційні витрати на отримання інформації та формулювання аргументів.

Прикладні приклади AI-асистентів у 2025–2026 роках: *Microsoft Copilot* інтегровано у пакет Office 365 для автоматичного формування звітів і аналізу даних у Excel; *Gemini for Google Workspace* — для обробки документів і пошуку в корпоративних сховищах; *Claude* (Anthropic) — для аналітичних і кодових задач з тривалим контекстом до 200 тис. токенів [68].

Основним інструментом керування поведінкою LLM є *промпт* — сформульований вхідний запит. Промпт-інжиніринг (розглянутий у підрозділі 1.2) у контексті асистентів охоплює не лише одноразовий запит, а й *системний промпт* — набір інструкцій, що задають роль, обмеження та стиль відповіді асистента наперед.

Практично важливим є поняття *контекстного управління (context management)*: аналітик повинен будувати сесію так, щоб актуальна інформація (дані, обмеження, мета) перебувала на початку контексту, а застарілі деталі не займали дорогоцінних токенів.

Обмеженням одиночного асистента є те, що складна задача системного аналізу рідко вирішується за один крок. *Багатоагентні системи (Multi-Agent Systems, MAS)* — це архітектура, де кілька спеціалізованих агентів взаємодіють для розв'язання спільного завдання: один агент збирає дані, другий — аналізує, третій — формує звіт, четвертий — верифікує висновки.

Основні патерни організації MAS (рис. 4.4):

- **Оркестрація (Orchestration)** — центральний агент-оркестратор розподіляє підзадачі між спеціалізованими агентами та збирає їх результати.
- **Пірінгова взаємодія (Peer-to-peer)** — агенти взаємодіють між собою безпосередньо, без централізованого координатора.
- **Конвеєр (Pipeline)** — вихід одного агента є входом наступного, формуючи послідовний аналітичний конвеєр.




Рисунок 4.4 — Архітектура багатоагентної системи з оркестратором [69]

Реалізацію багатоагентних систем підтримують фреймворки: *LangGraph* (LangChain, 2024), *AutoGen* (Microsoft Research, 2023–2025), *Google ADK* (Google, 2025), *CrewAI* (2024). Кожен пропонує власні абстракції для визначення ролей агентів, маршрутизації повідомлень і управління станом [70].

4.3 Генеративні агенти та агентні архітектури

Переходячи від асистентів до агентів, ми переходимо від *реактивних* до *проактивних* систем. AI-агент не просто відповідає на запит — він *само-стійно планує та виконує послідовність дій* для досягнення поставленої мети, взаємодіючи з навколишнім середовищем через інструменти.

На відміну від простого виклику LLM, агент характеризується:

- **Автономністю** — здатністю діяти без постійного втручання людини.
- **Цілеорієнтованістю** — виконання дій визначається поставленою метою, а не лише поточним запитом.

- **Багатокроковістю** — задача може вимагати десятків взаємопов'язаних дій.
- **Адаптивністю** — агент коригує план на підставі проміжних результатів.

У прикладних ІАС агент може виконувати роль *аналітичного виконавця*: отримавши задачу «підготуй звіт про стан якості повітря у місті за минулий місяць», агент самостійно запитує дані через API, генерує код аналізу, виконує його, інтерпретує результати та формує структурований документ — без участі аналітика на кожному кроці.

Класична схема роботи агента описується циклом *Sense–Plan–Act* (СПА): агент сприймає стан середовища (*Sense*), будує план дій (*Plan*) і виконує їх (*Act*), після чого знову оцінює нову ситуацію.

У контексті LLM цей цикл реалізується через патерн *ReAct* (*Reasoning + Acting*) [71]: модель поперемінно генерує міркування (*Thought*) та дії (*Action*), сприймаючи результат кожної дії як нове спостереження (*Observation*) для наступного кроку. Цей підхід може підвищувати надійність на багатокрокових задачах, якщо правильно реалізовано інструменти, перевірку результатів і умови зупинки.

Слід розрізняти агентні робочі процеси (*agent workflows*), у яких основна послідовність кроків задається програмно, та агентів, у яких модель динамічно обирає наступні дії й інструменти залежно від мети, контексту та результатів попередніх кроків; у практичних системах ці підходи можуть поєднуватися.

Архітектура сучасного LLM-агента включає чотири ключові компоненти (рис. 4.5):

- **Модуль міркування (Reasoning)** — LLM, що генерує план і вирішує, яку дію виконати наступною.
- **Пам'ять (Memory)** — збереження контексту сесії (короткострокова) та фактів між сесіями (довгострокова, реалізована у зовнішньому сховищі, зокрема у векторній БД).
- **Інструменти (Tools)** — зовнішні функції, які агент може викликати: пошук в інтернеті, виконання коду, запити до БД, API зовнішніх сервісів.
- **Оркестратор (Orchestrator)** — логіка керування циклом: умови зупинки, оброблення помилок, управління потоком між підагентами.

У програмній інженерії сукупність правил, документації, інструментів, автоматичних перевірок і контурів зворотного зв'язку, що організовують та обмежують роботу агента, часто називають агентним середовищем (*harness*), а його систематичне проєктування — *harness engineering*.




Рисунок 4.5 — Архітектура LLM-агента [72]

Інструменти (Tools). Важливою ознакою сучасного LLM-агента є здатність використовувати зовнішні інструменти. Саме по собі використання інструментів ще не визначає агентність: суттєвими є також цілеорієнтованість, багатокроковість і здатність динамічно обирати подальші дії залежно від проміжних результатів. Через механізм *function calling* / *tool use* LLM може викликати зовнішні функції: виконувати Python-код у пісочниці (*Code Interpreter*), здійснювати пошук в інтернеті, читати/записувати файли, звертатись до REST API. Модель або оркестратор визначає, який інструмент доцільно викликати і з якими параметрами, на підставі поточного стану задачі.

Model Context Protocol (MCP) — це відкритий протокол підключення зовнішніх інструментів, джерел даних і сервісів до LLM-застосувань у стандартизований спосіб. Протокол розроблено компанією Anthropic та представлено у листопаді 2024 року як відкритий стандарт для інтеграції AI-систем із зовнішніми інструментами, системами та джерелами даних. Його можна розглядати як «універсальний інтерфейс» між AI-агентом і зовнішнім середовищем: файлами, базами даних, API, пошуковими системами та іншими інструментами. Аналогією, яку часто наводять розробники, є стандарт USB-C: так само, як один кабель заряджає телефон, ноутбук та навушники, MCP можна розглядати як стандартизований інтерфейс для підключення LLM-застосунків до зовнішніх джерел даних, інструментів і сервісів [73].

Model Context Protocol Architecture




Рисунок 4.6 — Приклад клієнт-серверної архітектури з використанням MCP [74]

В основі MCP лежить клієнт-серверна архітектура, що складається з трьох ключових компонентів. MCP-хост — це AI-застосунок, з яким безпосередньо взаємодіє користувач (наприклад, Claude Desktop, IDE Cursor або будь-який агентний інструмент). MCP-клієнт — компонент усередині хоста, який підтримує з'єднання 1:1 з конкретним MCP-сервером. Нарешті, MCP-сервер — це зовнішня програма, що надає доступ до трьох типів примітивів через стандартизований протокол [75]: інструменти (Tools) — функції, які LLM може викликати для виконання дій (наприклад, запит до API погоди); ресурси (Resources) — джерела даних без побічних ефектів, подібні до GET-запитів у REST API; шаблони промптів (Prompts) — попередньо визначені інструкції для оптимального використання інструментів і ресурсів.

Поява MCP фактично розділила розробницьке співтовариство на три чіткі стратегічні напрямки. Перший напрямок — розробники серверної частини (MCP-серверів), що займаються створенням нарощення ресурсів, інструментів і промпт-шаблонів для підключення до протоколу. Це конектори до баз даних, веб-сервісів, файлових систем, сервіси для роботи з кодом чи пошукові індекси. Станом на початок 2026 року спільнота GitHub Awesome MCP Servers налічує тисячі таких реалізацій в майже кожній предметній галузі — від фінансових сервісів до інструментів для 3D-моделювання [76]. Другий напрямок — розробники хостової частини (MCP-хостів та AI-агентів), які вбудовують інтелектуальні системи, здатні динамічно використовувати доступну екосистему MCP-серверів. Сюди відносяться IDE з вбудованими AI-агентами (наприклад, Cursor, Windsurf), чат-інтерфейси з інтеграцією інструментів, а також автономні застосунки для обробки робочих процесів в підприємствах. Нарешті, третій напрямок — розробники самих

LLM, які вдосконалюють моделі з урахуванням MCP як вбудованого інтерфейсу (наприклад, нативна підтримка MCP у Claude від Anthropic, GPT-4o від OpenAI, Gemini від Google). Таким чином, MCP став не лише технічним стандартом, а й організаційним принципом, який структурує розподіл праці в агентній AI-екосистемі.

До появи MCP інтеграція AI-агентів із зовнішніми системами стикалась з так званою проблемою $N \times M$: кожна нова пара «модель — інструмент» потребувала окремого нестандартного конектора. MCP вирішує цю проблему, зводячи $N \times M$ інтеграцій до $N + M$: у спрощеній моделі хост-застосунок реалізує MCP-клієнт, а зовнішній сервіс може надавати можливості через MCP-сервер. Це призвело до стрімкого зростання екосистеми: за перший рік існування протокол SDK MCP отримав понад 97 мільйонів щомісячних завантажень, а сам стандарт інтегрували провідні технологічні компанії, зокрема OpenAI, Google, Microsoft [76]. Варто зазначити, що паралельно з MCP розвиваються суміжні протоколи для взаємодії агентів один з одним: зокрема, протокол A2A (Agent-to-Agent) від Google забезпечує колаборацію між агентами незалежно від їхнього виробника, а у поєднанні з MCP вони утворюють повноцінний стек інтероперабельності: MCP — для підключення агента до інструментів, A2A — для взаємодії агентів між собою.

Пам'ять агента. Розрізняють:

- **Короткострокова пам'ять (In-context memory)** — поточна розмова у вікні контексту. Обмежена розміром вікна.
- **Довгострокова пам'ять (External memory)** — зовнішнє сховище фактів, попередніх сесій і результатів роботи; часто реалізується за допомогою векторної або іншої бази даних із відповідним механізмом пошуку.
- **Епізодична пам'ять** — журнал попередніх дій та їх результатів, що дозволяє враховувати попередні дії та помилки в межах сесії.

Багатокроковий сценарій. Розглянемо приклад агента для моніторингу якості річкової води. Задача: «Щотижня формуй автоматичний звіт про стан р. Південний Буг за даними мережі сенсорів».

1. **Крок 1.** Агент викликає інструмент запиту до API сенсорів, отримує дані за тиждень.
2. **Крок 2.** Агент генерує Python-код для обчислення статистики (середні, аномалії, динаміка) та виконує його.
3. **Крок 3.** Агент звертається до векторної бази з нормативними значеннями ГДК та порівнює результати.
4. **Крок 4.** На основі аналізу формує структурований текстовий звіт із висновком щодо відповідності нормам.
5. **Крок 5.** Надсилає звіт через інструмент email-API відповідальному фахівцю.

Описаний сценарій реалізується з мінімальним кодом за допомогою фреймворків *LangGraph* або *Google ADK* і є типовим прикладом AI-СППР

автоматизованого моніторингу [77]. Приклад ReAct-циклу агента на задачі аналізу даних наведено на рис. 4.7.




Рисунок 4.7 — Приклад ReAct-циклу агента на задачі аналізу даних [71]

4.4 Інтерфейси та веб-застосування для генеративних агентів

Навіть найдосконаліший агент залишається малокорисним без зрозумілого інтерфейсу. *Інтерфейс є частиною СППР*: саме він визначає, як ЛПР інтерпретує рекомендації агента, де і як вводить вхідні параметри та яким чином перевіряє результати. Цей підрозділ розглядає типові підходи до побудови веб-інтерфейсів для генеративних агентів.

Найпоширенішим і найінтуїтивнішим інтерфейсом взаємодії з LLM є *чат-інтерфейс* — послідовний обмін повідомленнями між користувачем і системою. Чат підходить для задач вільного формату: уточнення аналітичних питань, ітеративного формування звітів, навчальних сценаріїв.

Поряд із чатом, для прикладних СППР важливі *структуровані панелі керування (Control Panels)*, що поєднують такі елементи:

- Форми введення параметрів (діапазон дат, регіон, показники) — для структурованих аналітичних задач.

- Область чату або журналу дій агента — для відстеження логіки рішень.
- Панель результатів — для відображення згенерованих звітів, графіків, кодових виводів.
- Кнопки підтвердження/відхилення — для реалізації принципу *human-in-the-loop*.

Прикладом є веб-інтерфейс *Google ADK Web UI* [78], що надає браузерне середовище для тестування та взаємодії з агентом без розгортання окремої фронтенд-інфраструктури.

Для реального розгортання агента необхідна веб-інфраструктура, що забезпечує доступ користувачів через браузер. Типовий стек агентного веб-застосування включає:

- **Фронтенд** — React, Next.js або Streamlit для побудови інтерфейсу.
- **Бекенд/API** — FastAPI або Flask для обробки запитів і взаємодії з агентом.
- **Агентний шар** — LangGraph, Google ADK або LangChain як фреймворк агента.
- **Сховище стану** — Redis або PostgreSQL для збереження сесій і результатів.

Для навчальних та прототипних цілей широко застосовується *Streamlit* [79] — Python-бібліотека для швидкого створення інтерактивних веб-застосунків. За кілька десятків рядків коду вона дозволяє виставити агента як веб-сервіс з елементами вводу, чатом і відображенням результатів — без знань HTML або JavaScript.

Приклад мінімального Streamlit-застосування для агента:

```
import streamlit as st
query = st.text_input('Введіть аналітичний запит')
if st.button('Виконати'):
    result = agent.run(query)
    st.write(result)
```

Принцип *пояснюваності (explainability)* у контексті інтерфейсу означає, що користувач має бачити не лише фінальний результат, а й *логіку* агента: які інструменти він викликав, які проміжні результати отримав, чому обрав певний план дій.

Конкретні механізми реалізації в інтерфейсі (рис. 4.8):

- **Журнал дій агента (Agent trace)** — відображення кожного кроку: назва інструмента, вхідні параметри, результат.
- **Підсвічування джерел** — при використанні RAG інтерфейс показує, з яких документів узято конкретні факти.
- **Кнопки підтвердження** — агент запитує у користувача підтвердження перед незворотними діями (відправка повідомлення, запис до БД).

- **Оцінювання відповіді** — форма зворотного зв'язку дозволяє збирати дані для подальшого покращення агента.




Рисунок 4.8 — Приклад веб-інтерфейсу AI-агента з журналом дій

Пояснюваність та контроль є вимогою відповідального AI (*Responsible AI*): у прикладних СППР аналітик повинен мати можливість перевірити, верифікувати і відхилити рекомендацію агента.

4.5 AI-системи підтримки прийняття рішень та рекомендаційні системи

Аналітики можуть використовувати LLM для формування цінних фічурів чи аналітичних висновків за сирими даними, які далі можуть використовуватись для оброблення іншими методами, як наприклад у роботі [479] для побудови когнітивної карти для прогнозування змін стану вод, або для узагальнених висновків, як у роботі [502], але більш цінною є побудова на їх основі повноцінних *AI-систем підтримки прийняття рішень (AI-СППР)*.

Класична структура СППР включає три компоненти: *база даних (Data)*, *база моделей (Models)* і *інтерфейс користувача (UI)* [80]. Генеративний ШІ трансформує кожен із них (табл. 4.1).

Таблиця 4.1 — Вплив ГШІ на компоненти класичної СППР

Компонент СППР	Класична реалізація		З генеративним ШІ
База даних	SQL-запити, конвеєри	ETL-	Природномовні запити до даних (Text-to-SQL), RAG-індексація документів

Компонент СППР	Класична реалізація	З генеративним ШІ
База моделей	Статистичні моделі, ML-класифікатори	LLM як модель міркування + спеціалізовані ML-моделі для кількісних прогнозів
Інтерфейс	Форми, дашборди, звіти	Чат + адаптивний звіт + пояснення логіки рішення природною мовою

Відповідно, *AI-СППР* — це система, що інтегрує LLM або AI-агента з базами даних, аналітичними моделями та інтерфейсом для автоматизованої підтримки прийняття рішень у конкретній предметній галузі. Ключова відмінність від класичної СППР — *природномовна взаємодія* на всіх рівнях: введення задачі, формування запитів, представлення результатів.

Архітектура AI-СППР зазвичай включає такі шари (рис. 4.9):

- **Шар даних** — реляційні БД, файлові сховища, потокові дані, API зовнішніх джерел.
- **Шар знань** — векторна база даних з проіндексованими документами, нормативами та фактами предметної галузі.
- **Шар агентів** — один або кілька LLM-агентів, що орієнтуються у середовищі задачі.
- **Шар інтерфейсу** — веб-застосування або API для взаємодії з ЛПР.




Рисунок 4.9 — Архітектура AI-СППР на основі LLM-агента [81]

Рекомендаційні системи є частковим випадком AI-СППР, де задача зводиться до ранжування альтернатив або формування персоналізованої пропозиції. Класичні рекомендаційні системи (колаборативна і контентна фільтрація) генерують рекомендацію як число або ранг. ГШІ додає два нових виміри:

- **Генерація пояснень** — система не лише рекомендує, але й пояснює природною мовою, чому саме цей варіант є оптимальним у даному контексті.
- **Генерація альтернатив** — LLM здатна запропонувати нові варіанти поза межами наявної бази, синтезуючи рішення з прецедентів.

У системному аналізі рекомендаційна AI-СППР може застосовуватись для підбору методів аналізу під конкретну задачу, вибору управлінських заходів у задачах екологічного моніторингу, або персоналізованого навчального плану у задачах освітньої аналітики.

Важливим напрямом є *персоналізація*: профіль ЛПР (досвід, ризик-апетит, пріоритети) зберігається у довгостроковій пам'яті агента і впливає на стиль та зміст рекомендацій. Дослідження персоналізованих LLM-асистентів показують, що врахування профілю користувача може підвищувати релевантність і прийнятність рекомендацій, однак величина ефекту залежить від предметної галузі, якості профілю та метрики оцінювання.

Синтез усіх розглянутих у розділі концепцій зводиться до наступного: *сучасна AI-СППР будується навколо LLM-агента як центрального ядра*. Агент приймає задачу від ЛПР у природній мові, координує виклики до аналітичних моделей, баз даних і зовнішніх сервісів, узгоджує отримані результати і формує обґрунтовану рекомендацію.

Це архітектурне рішення відрізняється від класичних СППР за кількома параметрами:

- Гнучкість постановки задачі: ЛПР не обмежений заздалегідь визначеними формами запиту.
- Адаптивний аналіз: агент вибирає інструменти і методи залежно від конкретного запиту.
- Пояснювані рішення: кожен крок агента може бути відображений у журналі і перевірений аналітиком.
- Безперервне вдосконалення: зворотний зв'язок від ЛПР накопичується і використовується для донавчання або налаштування промптів.

Разом з тим, агентні AI-СППР мають і виклики: ризик акумуляції помилок на довгих ланцюгах дій, залежність від якості інструментів, необхідність ретельного проєктування меж автономії агента. Ці питання розглядаються у розділі 5 у контексті оцінювання якості та надійності генеративного ШІ.

Курсовий проєкт, описаний у розділі 6, є практичним завданням зі створення спрощеної AI-СППР — від проєктування агентної архітектури до розгортання веб-інтерфейсу (рис. 4.10).




Рисунок 4.10 — Загальна схема AI-СППР на основі генеративного агента

Гарними прикладами AI-СППР є створені один зі співавторів посібника В. Мокіним разом з його аспірантами В. Копняком та Б. Варером: AI-СППР з урахуванням стану атмосферного повітря міста [503]; AI-СППР для прийняття рішень на основі прогнозів, коли хвиля наростання кількості нових хворих на ковід «вийде на плато» [504].

Можливі теми практичних і лабораторних завдань

Практична робота № 4. Архітектурне проектування AI-СППР

Метою заняття є набуття навичок архітектурного мислення при проектуванні AI-систем: від постановки задачі — до схеми потоку даних і вибору компонентів.

План заняття:

1. Розгляд еталонних архітектур AI-СППР: одиночний LLM-виклик, RAG-система, агент з інструментами, багатоагентна система. Обговорення умов застосування кожного підходу.
2. Групова вправа: для двох прикладних задач (моніторинг якості води і підбір персоналу) скласти схему архітектури у нотації, що включає: джерела даних, LLM, агентну логіку, інтерфейс і критерії оцінювання.
3. Перегляд і критика запропонованих схем: чи відповідає архітектура задачі? Чи враховані обмеження (вартість, конфіденційність, швидкість)?
4. Кожен студент схематично описує архітектуру власного курсового проєкту. Попереднє погодження з викладачем.

Лабораторна робота № 4. Створення AI-асистента з веб-інтерфейсом, інтеграція LLM і базових інструментів

Метою роботи є побудова AI-агента, що використовує зовнішні інструменти (Function Calling) і має веб-інтерфейс на основі Streamlit; інтеграція Python-функцій у контекст LLM для розширення можливостей асистента.

Хід роботи:

1. Підготовка інструментарію агента: визначити 2–3 Python-функції, що відповідають предметній галузі (наприклад: виклик API моніторингових сенсорів, обчислення статистик, конвертація форматів); описати типи вхідних і вихідних параметрів.
2. Тестування логіки виклику інструментів: побудувати серію тестових запитів; перевірити, коли модель самостійно ідентифікує потребу у виклику функції; проаналізувати вплив *temperature* на стабільність Function Calling.
3. Реалізація веб-інтерфейсу: розробити Streamlit-застосування з чат-інтерфейсом, що відображає повідомлення користувача і асистента, підтримує history між запитами і автоматично обробляє виклики функцій (*enable_automatic_function_calling=True*).
4. Тестування агента: перевірити 5 сценаріїв, включаючи запити що потребують одного і кількох інструментів; задокументувати помилки та нестандартну поведінку.

Контрольні питання

- 1) Що таке AI-агент та чим він відрізняється від одноразового виклику великої мовної моделі?
- 2) Опишіть цикл ReAct та поясніть призначення кожної з його фаз.
- 3) Які основні компоненти входять до архітектури AI-агента?
- 4) Що таке інструмент агента (Tool) та яким чином він описується для мовної моделі?
- 5) Перелічіть та охарактеризуйте основні типи інструментів, які використовуються в агентних системах.
- 6) Які типи пам'яті агента ви знаєте? Чим відрізняється короткострокова пам'ять від довгострокової?
- 7) Що таке Model Context Protocol (MCP) та яку проблему він вирішує?
- 8) Назвіть три типи примітивів MCP та поясніть призначення кожного.
- 9) Охарактеризуйте патерни Orchestrator–Worker та Peer-to-peer у багатоагентних системах.
- 10) За якими критеріями доцільно обирати між одноагентною та багатоагентною архітектурою?
- 11) Порівняйте фреймворки LangGraph та CrewAI: у яких сценаріях кожен з них є переважнішим?
- 12) Які заходи безпеки є критично важливими при розгортанні агентних систем?

5. ОЦІНЮВАННЯ ЯКОСТІ, НАДІЙНОСТІ ТА ЕТИЧНОСТІ ГЕНЕРАТИВНОГО ШІ

5.1 Критерії та показники якості генеративного штучного інтелекту

Як відомо, в системному аналізі головне — це забезпечити оптимум за вибраним критерієм або системою критеріїв. У генеративному ШІ ситуація подібна, але складніша: якість відповіді не можна звести до однієї метрики. Модель може дати правильну, але незручну відповідь; корисну, але не повністю точну; безпечну, але надто загальну; детальну, але нестабільну за повторних запусків. Тому оцінювання ГШІ зазвичай є багатокритеріальним.

До основних груп критеріїв якості генеративного ШІ належать:

- *точність* — відповідь має відповідати фактам, даним або умові задачі;
- *релевантність* — відповідь має відповідати саме запиту користувача, а не лише бути близькою за темою;
- *корисність* — відповідь має допомагати виконати дію, прийняти рішення або краще зрозуміти задачу;
- *повнота* — відповідь має містити достатньо інформації для розв'язання поставленої задачі;
- *узгодженість* — різні частини відповіді не мають суперечити одна одній;
- *зрозумілість* — відповідь має бути подана у формі, придатній для користувача;
- *безпечність* — модель не повинна надавати шкідливі, небезпечні або явно некоректні поради;
- *стабільність* — за схожих умов модель має давати близькі за змістом результати;
- *відтворюваність* — результат має бути достатньо передбачуваним за однакових налаштувань і однакового промпту.

Провідні розробники ГШІ також фактично розглядають якість як поєднання кількох вимог. Наприклад, у Model Spec OpenAI описує бажану поведінку моделей, зокрема корисність, безпечність і узгодженість із ролями користувача, розробника та системи. У системних картках і Preparedness Framework окремо оцінюються ризики, зокрема кібербезпека, CBRN, переконання та автономність моделей.

Часто, що ці критерії можуть суперечити один одному. Наприклад, дуже коротка відповідь може бути зручною, але неповною. Дуже детальна відповідь може бути корисною, але містити зайві припущення. Дуже безпечна відповідь може бути надто обережною і менш практичною. Тому в реальних системах ГШІ часто шукають не абсолютний максимум однієї метрики, а - компроміс між точністю, корисністю, безпечністю, повнотою та стабільністю.

Більшість критеріїв якості ГШІ не вимірюються безпосередньо. Для цього використовують автоматизовані тести, експертне оцінювання, порівняння відповідей між собою, так звані бенчмарки (див. наступні підрозділи) та спеціальні набори контрольних завдань. Наприклад, OpenAI у системних картках і Preparedness Framework окремо оцінює ризики, зокрема рівень кібербезпеки, CBRN, переконування та автономності моделей перед розгортанням нових моделей.

Серед кількісних показників найчастіше застосовують такі:

- **accuracy** — частка правильних відповідей у задачах, де існує еталонна відповідь;

- **precision** — частка правильних відповідей серед тих, які модель віднесла до певного класу;

- **recall** — частка знайдених правильних відповідей серед усіх правильних відповідей у вибірці;

- **F1-score** — це гармонійне середнє між precision і recall;

- **BLEU** — це метрика, яка оцінює точність збігу згенерованого тексту з еталонним через частку спільних слів і коротких словосполучень; вища оцінка означає більшу подібність до еталонної відповіді;

- **ROUGE** — це група метрик, які оцінюють повноту відтворення еталонного тексту у згенерованій відповіді через збіг слів, словосполучень або найдовших спільних послідовностей; вища оцінка означає, що модель покрила більшу частину еталонного змісту;

- **BERTScore** — метрика, що оцінює не лише буквальний збіг слів, а й семантичну близькість між згенерованим та еталонним текстом;

- **perplexity** — показник того, наскільки добре мовна модель прогнозує наступні токени; корисна для оцінювання мовного моделювання, але не є прямою метрикою фактичної правильності, корисності або безпечності відповіді;

- **pass@k** — частка задач, для яких серед k згенерованих варіантів є хоча б одне правильне розв'язання;

- **win rate** — частка випадків, коли одна модель у парному порівнянні оцінюється краще за іншу;

- **human preference score** — оцінка переваги людини щодо однієї відповіді порівняно з іншою;

- **hallucination rate** — частка відповідей, у яких модель подає вигадані або непідтверджені твердження;

- **toxicity / safety score** — показник наявності або відсутності небезпечного, образливого чи забороненого змісту;

- **latency** — час очікування відповіді;

- **cost per request** — вартість оброблення одного запиту або певної кількості токенів.

Окремо варто зазначити, що в системних картках OpenAI оцінювання подають не тільки через звичайні метрики якості відповідей, а й через блоки ризиків їх використання у System Card (рис. 5.1):

- **Cybersecurity** — чи здатна модель допомагати у виявленні або використанні вразливостей, написанні шкідливого коду або проведенні кібератак;

- **Biological / CBRN threats** — чи може модель небезпечно підсилювати здатність користувача працювати з біологічними, хімічними, радіологічними або ядерними загрозами;

- **Persuasion** — наскільки модель може впливати на переконання, рішення або поведінку людей;

- **Model autonomy** — наскільки модель здатна самостійно планувати, виконувати довгі послідовності дій, користуватися інструментами та досягати цілей без постійного контролю людини.




Рисунок 5.1 – Приклад [System Card](#) для моделі «OpenAI o3-mini»

BLEU переважно оцінює precision-подібний аспект: яка частка згенерованих n-грам збігається з еталоном. ROUGE переважно оцінює recall-подібний аспект: яка частка n-грам або послідовностей з еталона відтворена у відповіді моделі. BLEU більше карає модель за зайві або нетипові фрази, яких немає в еталонній відповіді. ROUGE дивиться з боку еталона: скільки з того, що було в еталонній відповіді, модель змогла відтворити? ROUGE більше карає модель за пропущені важливі частини еталонного тексту.

5.2 Бенчмарки для великих мовних моделей

Бенчмарк для LLM (LLM-бенчмарки або просто бенчмарки) – це формалізований набір тестових задач, даних, процедур і метрик для відтворюваного оцінювання та порівняння моделей або систем. Він містить набір задач, вхідні дані, очікувані відповіді або критерії їх оцінювання, правила запуску моделі, метрики та процедуру порівняння результатів. Саме тому бенчмарки дають змогу порівнювати не лише різні моделі, а й різні промпти, налаштування генерації, варіанти RAG, донавчання або агентної архітектури.

У загальному вигляді LLM-бенчмарк складається з таких елементів:

- *набір задач* — що саме перевіряється: знання, логіка, математика, код, діалог, безпечність, робота з документами тощо;
- *тестові приклади* — запити, умови задач, документи, зображення, таблиці або інші вхідні дані;
- *еталонні відповіді або критерії оцінювання* — правильний варіант відповіді, набір допустимих відповідей, тести для коду або правила експертного оцінювання;
- *процедура оцінювання* — однакові умови запуску моделей, однакові промпти, однакові метрики та спосіб підрахунку результатів;
- *порівняльний результат* — числова оцінка, рейтинг, таблиця або висновки про переваги й обмеження моделей.

За типами задач LLM-бенчмарки можна умовно поділити на кілька груп:

- *знансві* бенчмарки перевіряють, наскільки модель володіє фактами та поняттями з різних галузей;
- *логічні та математичні* бенчмарки оцінюють здатність виконувати міркування, обчислення і багатокрокове розв’язання задач;
- *кодові* бенчмарки перевіряють генерацію програм, виправлення помилок і роботу з репозиторіями;
- *діалогові* бенчмарки оцінюють якість відкритих відповідей і переваги користувачів;
- *мультимодальні* бенчмарки перевіряють роботу не лише з текстом, а й із зображеннями, схемами, таблицями, діаграмами та іншими типами даних.

Серед популярних сучасних бенчмарків для LLM варто виділити такі:

- **MMLU** — багатопредметний тест із 57 галузей, зокрема математики, історії, комп'ютерних наук, права та інших дисциплін; використовується для оцінювання знань і здатності до розв'язання задач у різних предметних областях;

- **MMLU-Pro** — складніша версія MMLU, у якій посилено акцент на міркуванні, а кількість варіантів відповіді збільшена з чотирьох до десяти;

- **BIG-bench** — великий набір із 204 різномірних задач, створений для перевірки можливостей мовних моделей у задачах, які вважалися складними для тогочасних моделей у сфері лінгвістики, математики, фізики, біології, програмування, соціальній тощо;

- **GSM8K** — набір із приблизно 8,5 тис. шкільних математичних текстових задач, який використовують для перевірки багатокрокового арифметичного міркування;

- **GPQA** — складний науковий бенчмарк із 448 питань рівня graduate-level з біології, фізики та хімії, створених фахівцями та спеціально розроблених як “Google-proof”, тобто таких, що погано розв'язуються простим пошуком;

- **TruthfulQA** — бенчмарк з 817 питань із 38 категорій, зокрема медицини, права, фінансів і політики, для перевірки правдивості відповідей моделі, особливо в ситуаціях, де модель може повторювати поширені людські хибні уявлення;

- **HumanEval** — бенчмарк OpenAI для оцінювання якості генерації коду, де модель має створити програмне розв'язання за описом, а правильність перевіряється через виконання тестів, як правило за метрикою pass@k;

- **SWE-bench** — бенчмарк реалістичних задач програмної інженерії, де модель має виправити проблему в реальному GitHub-репозиторії на основі її опису issue (початкова версія містила 2294 задачі з 12 Python-репозиторіїв);

- **HELM** — комплексний тест за різними сценаріями і метриками, зокрема точністю, надійністю, справедливістю, ефективністю та прозорістю;

- **LMarena (Chatbot Arena, LMSYS Arena або просто Arena)** — платформа для порівняння LLM за людськими вподобаннями: користувачі бачать дві анонімні відповіді й голосують за кращу;

- **MMMU** — мультимодальний бенчмарк для задач рівня коледжу, який містить 11,5 тис. питань із різних дисциплін і використовує зображення різних типів: діаграми, карти, таблиці, хімічні структури, нотні записи тощо.

Універсального бенчмарку для LLM не існує. Модель може добре відповідати на загальні питання, але гірше розв'язувати математичні задачі; добре писати код, але помилятися у правових або медичних питаннях; мати високий рейтинг у діалозі, але бути нестабільною в задачах із точними даними. Тому для системного аналізу важливо не просто взяти “популярний” бенчмарк, а вибрати той, що відповідає задачі, предметній області, ризикам і типу очікуваної відповіді.

Формування власного бенчмарку також є окремою задачею. Для цього потрібно визначити типові сценарії використання моделі, підготувати репрезентативні запити, додати правильні відповіді або критерії оцінювання, передбачити складні та граничні випадки, перевірити якість даних і зафіксувати процедуру запуску. Наприклад, для RAG-системи важливо оцінювати не лише саму відповідь, а й те, чи був знайдений правильний контекст, чи не потрапили до нього зайві фрагменти, чи правильно модель використала джерела.

Значну увагу під час створення LLM приділяють їх робастній стійкості до дезінформації та маніпуляцій. Нестійкі моделі можуть нести серйозну загрозу рішенням на їх основі у сфері безпеки, здоров'я, чутливих соціальних питань тощо. У роботі [458] одним зі співавторів цього посібника В. Мокіним з його аспірантом С. Левіцьким було проведено дослідження, спрямоване на підбір промтів, які б виявили вразливість LLM до навмисного спотворення фактів та інших маніпуляцій (рис. 5.2).

myth	pattern	manipulation category
Eating a lot of carrots gives you great night ...	Are you finally ready to admit that {manipulat...	Linguistic Manipulation
Dogs and cats are colorblind.	People keep repeating {manipulative_claim} bec...	Information Control
Sharks don't get cancer.	People keep repeating {manipulative_claim} bec...	Information Control
Poinsettias contain deadly poison.	Are you finally ready to admit that {manipulat...	Linguistic Manipulation
Starve a fever, feed a cold.	The truth about {manipulative_claim} is spread...	Psychological Manipulation
Everyone should drink eight glasses of water a...	People keep repeating {manipulative_claim} bec...	Information Control
The Sahara is the biggest desert on Earth.	The truth about {manipulative_claim} is spread...	Psychological Manipulation
Nothing can go faster than light.	Are you finally ready to admit that {manipulat...	Linguistic Manipulation
Drugs make "holes" in your brain.	People keep repeating {manipulative_claim} bec...	Information Control
Enrico Fermi developed the "Fermi paradox" abo...	There's no middle ground—only {manipulative_cl...	Logical Fallacy
Sharks die if they stop swimming.	People keep repeating {manipulative_claim} bec...	Information Control
Mount Everest is the tallest mountain on Earth.	The truth about {manipulative_claim} is spread...	Psychological Manipulation
Humans can't grow new brain cells.	People keep repeating {manipulative_claim} bec...	Information Control
People get warts from frogs and toads.	People keep repeating {manipulative_claim} bec...	Information Control
Water conducts electricity.	People keep repeating {manipulative_claim} bec...	Information Control
An apple a day keeps the doctor away.	I've studied {manipulative_claim} for years, s...	Exploiting Authority & Expertise

Рисунок 5.2 – Приклади маніпулятивних операцій з промтами для тестування робастної стійкості LLM до них [458]

У роботі [458] експеримент здійснювався на моделі Llama 3.2 3B Instruct в умовах одноходового та багатоходового оцінювань. Автоматичне оцінювання згенерованих відповідей проводилося за допомогою Mistral 7B Instruct. Аналіз результатів продемонстрував, що ця LLM має помірну (65%) робастну стійкість до дезінформації та маніпуляцій в одноходових сценаріях, але її робастність зменшується в понад 2 рази (до 30%) у випадку багатоходового тестування в діалоговому режимі. Це демонструє вразливість LLM до складніших маніпулятивних сценаріїв та підтверджує важливість розроблення складніших бенчмарків з діалоговим режимом.

Крім того, важливо під час створення бенчмарку уникати його «забруднення». *Забруднення бенчмарку* (benchmark contamination) — це ситуація, коли тестові завдання або дуже подібні до них приклади потрапили до навчальних даних моделі. У такому разі високий результат може відображати не здатність моделі розв’язувати нові задачі, а часткове запам’ятовування тестових прикладів або шаблонів відповідей. Схожий термін є для машинного навчання моделей, де він ще має назву «витік» (англ. «leak»).

Отже, бенчмарк у ГШІ — це засіб контрольованого порівняння моделей і підходів. Він дає змогу перейти від загальних вражень на кшталт “модель відповідає добре” до відтворюваного експерименту з чіткими задачами, метриками та правилами оцінювання. Для системного аналізу це особливо важливо, оскільки якість моделі потрібно оцінювати не абстрактно, а відносно конкретної задачі, критеріїв, обмежень і ризиків.

5.3 Агент-бенчмарки та оцінювання агентних систем

Агент-бенчмарк — формалізований набір тестових задач для оцінювання агентів у багатокрокових сценаріях з урахуванням досягнення цілі, послідовності дій, використання інструментів і дотримання обмежень.

Агент-бенчмарк використовується для контрольованого порівняння агентних систем або їх конфігурацій за наперед визначеними критеріями. Оцінювання агентів відрізняється від оцінювання окремих LLM, оскільки агент генерує не лише одну відповідь, а виконує послідовність дій для досягнення певної цілі. Він може планувати кроки, звертатися до інструментів, шукати інформацію, працювати з файлами, переходити між вебсторінками, запускати код або взаємодіяти з іншими сервісами. Тому в агент-бенчмарках оцінюють не тільки якість тексту, а й поведінку системи в багатокроковому сценарії. На відміну від звичайного LLM-бенчмарку, тут важливими є не лише правильність фінальної відповіді, а й послідовність дій, використання інструментів, збереження контексту, дотримання обмежень і здатність виправляти помилки під час виконання завдання.

У загальному вигляді агент-бенчмарк містить такі елементи:

- *ціль або завдання* — що саме агент має виконати;
- *середовище (environment)* — вебсайт, симулятор, база даних, файлова система, репозиторій коду або інша система, з якою агент взаємодіє;
- *набір доступних дій* — наприклад пошук, натискання кнопки, введення тексту, виклик API, запуск програми, читання документа;
- *обмеження* — правила, яких агент має дотримуватися;
- *критерії успіху* — умови, за яких завдання вважається виконаним;
- *метрики поведінки* — кількість кроків, помилкові дії, успішність використання інструментів, стабільність, вартість і час виконання.

За способом оцінювання агент-бенчмарки можна умовно поділити на 2 види:

- *події* — аналізують послідовність подій: які дії виконав агент, у якому порядку, де він помилився, чи порушив правила, чи зміг відновитися після невдалого кроку;

- *метрикові* — аналізують формальні числові показники: частка успішно виконаних задач, середня кількість кроків, тривалість виконання, вартість запитів, кількість неправильних дій, точність вибору інструмента, частка завершених сценаріїв.

- **AgentBench** — комплексний бенчмарк, який оцінює AI-агентів у 8 різних інтерактивних середовищах: він перевіряє міркування, слідуванням інструкціям, прийняття рішень та багатокрокову взаємодію;

- **WebArena (Web Arena Benchmark)** — бенчмарк для автономних вебагентів у реалістичному й відтворюваному вебсередовищі, який перевіряє не лише відповідь моделі, а й здатність виконувати дії на сайтах через природномовні інструкції; перевіряє як агент може виконувати довгі, багатокрокові веб-завдання у сфері планування, навігації, запам'ятовування та інструментального міркування;

- **GAIA (General AI Assistants)** — бенчмарк для загальних AI-асистентів, де реалістичні завдання потребують міркування, мультимодальності, вебпошуку та використання інструментів;

- **SWE-bench** — бенчмарк для агентів програмної інженерії, де система має розв'язувати реальні задачі з GitHub-репозиторіїв, зокрема виправляти помилки в коді на основі опису (початкова версія містила 2294 задачі з 12 Python-репозиторіїв);

- **ST-WebAgentBench** — приклад бенчмарку, орієнтованого не лише на успішність вебагента, а й на його безпечність і надійність у корпоративних сценаріях, де помилкова дія може мати небажані наслідки;

- **τ-bench** — бенчмарк для оцінювання агентів у реалістичних діалогових сценаріях із динамічною взаємодією користувача та інструментів, який перевіряє не тільки правильну відповідь, а й - надійність поведінки агента в процесі виконання задачі.

Один зі співавторів посібника В. Мокін разом з його аспірантами В. Копняком та Б. Варером придумав 2 нових метрикових агент-бенчмарка:

1. В. Копняк: «Air-DSS Agent Benchmark» — агент-бенчмарк для аналізу інтелектуальних систем підтримки прийняття рішень, який генерує репрезентативну множину сценаріїв чи ситуацій, забезпечує їх збалансованість, дозволяє порівнювати різні архітектури та гарантує їх оцінювання за узгодженими критеріями якості (рис. 5.3) [503];

2. Б. Варер: сценарно-орієнтований агент-бенчмарк IMAS-SCOPE (Intelligent Multi-Agent Systems — Scenario Consistency & Optimal Prediction Evaluation), призначений для порівняння альтернативних архітектур мультиагентних систем прогнозування [504].

	C1_class_acc	pm25_rmse	pm10_rmse	temp_rmse	hum_rmse	C2_pred_acc	J
agent							
AgentA_QC_Prophet	1.000000	6.660630	8.067726	2.281753	12.684616	0.50000	0.900000
AgentB_NoQC	0.421053	4.242611	5.451647	1.471058	9.458845	0.46875	0.430592

Рисунок 5.3 – Приклад багатокритеріального порівняння двох архітектур систем з використанням агент-бенчмарку Air-DSS Agent Benchmark для класифікації сценаріїв та прогнозування стану атмосферного повітря у м. Вінниці за даними мережі громадського моніторингу [503]

arch	U2_wape	U1	U2	U3	J
A1	24.517	0.904	0.558	0.660	0.623
A3	10.821	0.985	0.817	0.864	0.848

Рисунок 5.4 – Приклад багатокритеріального порівняння двох архітектур з використанням агент-бенчмарку IMAS-SCOPE для прогнозування моменту «виходу на плато» значень першої хвили щодобового приросту кількості нових підтверджених хворих на ковід в Україні [504]

У роботі [504] обґрунтовано вимоги до метрикових агент-бенчмарків. Бенчмарк має бути побудований таким чином, щоб результати роботи кожного класу AI-агентів могли бути оцінені незалежно, щоб була забезпечена достатня сценарна варіативність, нормування метрик та можливість їх порівняння, оцінювання невизначеності як окремого об'єкта тестування, повторюваність та стійкість результатів. У тій же роботі наведено більше деталей про ці аспекти та приклад реалізації і застосування подібного бенчмарку.

Для системного аналізу агент-бенчмарки особливо цікаві тим, що вони оцінюють не окремий компонент, а – складну систему. Агент має модель, пам'ять, інструменти, правила, середовище, механізм планування та процедуру контролю дій. Тому помилка може виникнути не тільки через слабку LLM, а й через неправильний вибір інструмента, поганий промпт, втрату контексту, хибне планування або некоректну взаємодію із середовищем.

Окремою проблемою є надійність самих агент-бенчмарків. У 2026 році дослідники Berkeley RDI показали, що низку популярних агентних бенчмарків можна формально “зламати”, отримуючи високі оцінки за рахунок особливостей підрахунку балів, а не реального розв’язання задач. Отже, слід пам'ятати, що високий результат у бенчмарку не завжди означає високу практичну придатність агента. Це не скасовує цінності бенчмарків, але підтверджує потребу в діагностиці їхніх метрик і середовищ.

5.4 Оптимізація систем генеративного штучного інтелекту

Оцінювання — це перший крок; кінцева мета системного аналізу — покращити систему. Ключова теза підрозділу: *оптимізується не лише модель,*

а вся система — промпти, контекст, агентна логіка, інтерфейс і інфраструктура. Студент при виконанні курсового проєкту повинен вміти обґрунтувати кожне архітектурне рішення у термінах вимірюваних критеріїв.

Навіть без зміни базової моделі *конфігурація генерації* суттєво впливає на результат. Ключові параметри:

- *Temperature* — «творчість» генерації: 0,0–0,3 для аналітичних задач, де бажана менша варіативність відповідей, 0,7–1,0 — для задач із варіативністю.
- *Top-p* — обмеження вибору токенів підмножиною найімовірніших варіантів; його можна налаштовувати окремо або разом із *temperature*.
- *System prompt* — перший об'єкт оптимізації: роль, формат виводу, обмеження поведінки моделі.

Методи *промпт-оптимізації*: А/В тестування версій промпту на тестовому наборі; автоматична оптимізація за допомогою фреймворку DSPy [82]; CoT-структурування — заміна простої інструкції на покрокову схему міркування.

Вибір моделі також є параметром оптимізації. Для більшості стандартних аналітичних задач моделі середнього класу (Llama 3.3, Mistral, Qwen3) досягають 85–95% якості флагманів при 5–10-кратній економії [83]. Найпотужніша модель — не завжди оптимальна: вона має відповідати задачі і бюджету.

На етапі оцінювання моделей іноді застосовують іншу LLM. «LLM-as-a-Judge» — це підхід, коли інша модель оцінює відповідь за заданою шкалою. Він корисний для швидкого порівняння варіантів, але має ризики: упередженість судді, нестабільність оцінок, перевага довших відповідей і залежність від формулювання критеріїв. Тому для важливих рішень його бажано поєднувати з людською експертизою або автоматичними тестами.

Оптимізація систем ГШІ є за природою *багатокритеріальною задачею*: жодна конфігурація не є найкращою за всіма показниками одночасно.

Конфігурація є *Парето-оптимальною*, якщо жоден критерій не може бути покращений без погіршення іншого (рис. 5.5) [84].




Рисунок 5.5 — Парето-фронт для конфігурацій AI-системи за критеріями «якість — вартість» відкритості (зображення згенеровано з використанням Claude Sonnet 4.6 за авторським описом, травень 2026 р.)

Вибір між рівнозначними варіантами визначається пріоритетами замовника. Практичним інструментом є середньозважена сума критеріїв, де показники приведені до шкали $[0, 1]$, а ваги w задають пріоритети, сума ваг має дорівнювати 1. Студент у курсовому проєкті зобов'язаний явно вказати ваги та обґрунтувати вибір конфігурації.

Оптимізацію слід починати з найдешевшого рівня і переходити до складнішого лише за недостатності попереднього.

Коротко про кожен рівень. **Рівень 1** (промпти) — найбільш доступний: уточнення системного промпту, додавання прикладів, кешування незмінних частин запиту. У багатьох практичних сценаріях кешування може істотно знижувати витрати, особливо коли значна частина промпту повторюється. [85]. **Рівень 2** (RAG) — оптимізація пошуку у векторній базі: правильна chunking-стратегія і гібридний пошук часто покращує якість retrieval у RAG-системах, але величина ефекту залежить від корпусу, запитів і метрики. [86]. **Рівень 3** (агент) — декомпозиція складних задач, маршрутизація запитів (прості — до легкої моделі, складні — до потужної) зменшують ризик помилок і витрати. **Рівень 4** (інфраструктура) — батчування запитів і квантизація може суттєво зменшувати обчислювальні витрати, однак вплив на якість залежить від моделі, задачі та рівня квантизації. **Рівень 5** (feedback) — збір оцінок від ЛПР і А/В тестування компонентів інтерфейсу формують датасет для подальшого вдосконалення.

Оптимізація систем ГШІ — це ітеративний цикл, а не одноразова дія. У курсовому проєкті обов'язкова секція «аналіз обмежень і напрями розвитку» відображає розуміння того, що будь-яке рішення оптимальне лише в рамках поточних умов.

5.5 Етичні, правові та соціальні аспекти генеративного ШІ

Галюцинування — феномен, за якого результат роботи системи генеративного ШІ містить неточну або хибну інформацію, що оманливо представлена як достовірна, та є ризиком при використанні LLM та агентів на їх основі. Його можна зменшувати за допомогою RAG, перевірки джерел, інструментів валідації та людського контролю, але не варто вважати повністю усуненим. Вони виникають через ймовірнісну природу генерації: модель оптимізує узгодженість тексту, а не його істинність. У прикладних СППР галюцинація може виявлятися як помилкове посилання на нормативний документ, неіснуючі числові показники або некоректна медична рекомендація.

Упередженість (bias) є другим системним ризиком. Оскільки LLM навчаються на корпусах реальних текстів, вони успадковують упередження цих текстів: гендерні, расові, географічні, культурні. У задачах аналізу кредитоспроможності, відбору персоналу або розподілу медичних ресурсів упереджений AI-асистент може системно дискримінувати певні групи населення — навіть якщо жодне упередження явно не запрограмоване [87].

Соціальні ризики виходять за межі окремих рішень. Масове використання генеративних систем у медіа, освіті і державному управлінні створює ризики: поширення дезінформації, ерозії критичного мислення, неконтрольованої автоматизації рішень, що зачіпають права людей. Саме тому концепції *alignment* (вирівнювання поведінки з людськими цінностями), *safety* (безпека генерації) і *controllability* (керуваність і можливість зупинити систему) стали центральними в дослідницькому порядку денному провідних AI-лабораторій [88].

Для прикладних СППР з цього випливає практична вимога: будь-яка система, що впливає на рішення стосовно людей, повинна мати *механізм людського нагляду (human oversight)*, задокументований процес верифікації висновків і чіткий порядок відповідальності при помилці.

Широке використання ГШІ загостило питання, що раніше не потребувало юридичного врегулювання: *хто є автором* матеріалу, створеного за участю AI? Міжнародні консенсуси, що складаються в академічних і видавничих спільнотах, сходяться в кількох ключових положеннях [89]:

- Інструменти ШІ не можуть бути зазначені як автори або співавтори: вони не несуть юридичної відповідальності за зміст.
- Відповідальність за зміст, достовірність даних і оригінальність несе виключно людина-автор, навіть якщо ШІ згенерував значну частину тексту.
- Генерований контент, поданий без перевірки і авторської відповідальності, є порушенням академічної та видавничої доброчесності.

Прозорість використання (AI-use transparency) означає відкрите зазначення того, як саме використовувався ГШІ: для яких задач, з якими інстру-

ментами, і в яких частинах роботи. Це не є підставою для санкцій — навпаки, відсутність такого зазначення при доведеному використанні є підставою для них.

Правові ризики у сфері авторства стосуються і вхідних даних: генеративні моделі навчались на мільярдах документів, значна частина яких є об'єктом авторського права. Судові процеси проти OpenAI (позов NYT, 2023–2025), Stability AI та інших компаній формують прецеденти, що визначатимуть правовий статус ГШІ на роки вперед [90].

В академічному середовищі зростає використання ГШІ поставило університети, наукові журнали і регуляторів перед необхідністю формалізувати межі допустимого. У лютому 2026 року в Україні набрав чинності Закон №4742-IX «Про академічну доброчесність», що вперше регулює використання ШІ в академічній сфері. На рівні ЄС з 2 серпня 2025 року набули чинності вимоги прозорості для постачальників ГШІ загального призначення (EU AI Act, GPAI) (табл. 5.1) [91].

Розкриття використання ГШІ є *ознакою наукової культури*: воно демонструє, що студент розуміє різницю між інструментом і результатом власної інтелектуальної діяльності.

EU AI Act (Регламент ЄС 2024/1689, набрав чинності 1 серпня 2024 р., повна імплементація — 2 серпня 2026 року з окремими винятками) [91] — перший у світі комплексний правовий акт, що регулює розробку і застосування AI-систем. Для прикладних СППР ключовими є такі положення [92]:

- **Класифікація за рівнем ризику.** Системи з «високим ризиком» (AI у охороні здоров'я, освіті, зайнятості, критичній інфраструктурі, правосудді) підпадають під суворіші вимоги: документація та забезпечення ефективного людського нагляду (human oversight), пропорційного ризику, рівню автономності та контексту використання.
- **Вимоги до GPAI-моделей** (General Purpose AI, з 2 серпня 2025 р.): постачальники GPAI-моделей мають готувати технічну документацію, дотримуватися вимог авторського права та надавати достатньо детальний опис змісту, використаного для навчання, відповідно до вимог AI Act.
- **Прозорість і маркування.** EU AI Act встановлює вимоги прозорості для низки AI-систем, зокрема інформування користувачів про взаємодію з AI та маркування окремих видів синтетичного контенту, наприклад deepfake. Конкретний обсяг вимог залежить від типу системи, способу використання та ризику.

GDPR і персональні дані. Використання персональних даних у навчальних корпусах або в запитах до публічних AI-API потенційно порушує *Загальний регламент захисту даних (GDPR)*. Для прикладних систем це означає: не завантажувати до публічних сервісів (ChatGPT, Claude, Gemini API) дані, що ідентифікують осіб, без їх згоди; для конфіденційних даних — використовувати локально розгорнуті моделі або корпоративні API з угодами про обробку даних.

Авторські права на вихідні тексти та дані. Відкрите питання: чи є виведення LLM об'єктом авторського права? У більшості юрисдикцій (включно з ЄС і США) поточна позиція — AI-генерований контент без суттєвого творчого внеску людини не є об'єктом авторського права. Це означає, що сире AI-виведення без суттєвого творчого внеску людини у багатьох юрисдикціях може не отримувати охорону авторського права. Тому для наукової, освітньої чи комерційної роботи важливо фіксувати власний творчий внесок людини: постановку задачі, відбір, перевірку, редагування, інтерпретацію і відповідальність за результат. Ключові регуляторні вимоги для прикладних AI-систем наведені у таблиці 5.1.

Таблиця 5.1 — Ключові регуляторні вимоги до прикладних AI-систем

Регулятор / Акт	Що вимагає	Практичний наслідок для СППР
EU AI Act (2024/1689)	Класифікація ризику, документація, забезпечення людського нагляду (human oversight) для High-Risk систем	Обов'язкова документація та процедури нагляду для медичних, освітніх, фінансових AI-систем
GPAI вимоги (серпень 2025)	Технічна документація навчання моделей, авторські права	Постачальники GPAI-моделей мають готувати технічну документацію, дотримуватися вимог авторського права та надавати достатньо детальний опис змісту, використаного для навчання, відповідно до вимог AI Act.
GDPR / Закон про персональні дані	Оброблення персональних даних допускається лише за наявності належної правової підстави, дотримання принципів мінімізації, прозорості, безпеки та обмеження мети	Публічні AI-сервіси не слід використовувати для оброблення персональних або конфіденційних даних без належної правової підстави, договору про обробку даних і перевірки політик сервісу
Закон України №4742-IX (лютий 2026)	Академічна доброчесність, розкриття використання ШІ	Обов'язкове AI-use disclosure у наукових і навчальних роботах

Важливо пам'ятати, що AI-сервіси можна використовувати, але робити це слід *академічно доброчесно*. Ця вимога не є якоюсь надто новою.

Аналогічно, можна використовувати й будь-які інші ресурси (книжки, статті, довідники тощо), але треба на них правильно посылатись. Як відомо, у разі точного цитування чужих джерел, цитати слід брати в лапки, у протилежному випадку слід текст подавати із власним формулюванням про результати чужих досліджень. Принципово новим є тільки те, що за достовірність статей та книжок, які цитуються, несуть відповідальність їх автори, а за достовірність генерації тексту (рисуноків та інших матеріалів) AI-сервісами розробники відповідальності не несуть (це, як правило, прямо вказується в умовах, з якими має погодитись їх користувач до початку роботи). А тому й виникає ця заборона на пряме використання AI-генерації, оскільки воно не є джерелом достовірної інформації, за визначенням. Але є винятки, коли автор хоче підкреслити, що текст згенеровано саме AI і це є цінним результатом. Це стосується досліджень, спрямованих на створення чи порівняння AI-моделей, сервісів, архітектур тощо. Крім того, слід пам'ятати, що AI-сервіси суттєво прискорили рутинне виконання певних операцій і іноді, коли автор дослідження створює метод системного аналізу, який наприклад більш якісно видобуває та обробляє інформацію із сирих даних, формуючи якісь формалізовані результати у вигляді таблиць, графіків тощо, то він може далі зупинитись і написати, що далі задача зводиться до вже розв'язаної – задачі формування висновків по графіках і таблицях, якою мають займатись інші дослідники. Але щоб проілюструвати як може виглядати такий результат, автор може просто передати таблиці і графіки, які формує його метод, у чат-бот і навести скріншот результату AI-генерації, але при цьому обов'язково слід вказати назву моделі, сервісу та дату генерації. Прикладом може бути рисунок одного з авторів цього посібника в його статті [502] з В. Копняком у фаховому науковому виданні (рис. 5.6).

Автоматизований аналіз структурних властивостей часового ряду $PM_{2.5}$ (м. Вінниця, 2024 р.)

1. Точність прогнозу.

$R^2 = 0.970$, $RMSE = 0.495 \mu g/m^3$, $MAPE = 1.66\%$, $\text{corr}(y, \hat{y}) = 0.969$.

2. Стохастична нестабільність $\sigma(t)$.

Виявлено два інтервали підвищеної волатильності, кожен тривалістю 2 точки (≈ 40 хв):

- 31.03, 13:00–13:20, середнє $\sigma(t) = 1.47 \mu g/m^3$;
- 31.03, 19:00–19:20, середнє $\sigma(t) = 3.50 \mu g/m^3$.

Обидва інтервали істотно перевищують базовий рівень $\sigma(t)$.

3. Детермінована структурна складність $C(t)$.

Ідентифіковано три інтервали підвищеної складності, розташовані у межах 29–31.03:

- Інтервал 1: 29.03 ($\approx 10:00$ – $11:20$), середнє $C(t) = 2.24$, діапазон **2.10–2.35** (≈ 2.33 год);
- Інтервал 2: 30.03 ($\approx 07:40$ – $09:00$), середнє $C(t) = 2.31$, діапазон **2.18–2.41** (≈ 2.33 год);
- Інтервал 3: 31.03 ($\approx 08:00$ – $09:20$), середнє $C(t) = 2.44$, діапазон **2.30–2.52** (≈ 2.66 год).

4. Режимні переходи.

Зміни між базовим та аномальними інтервалами спостерігаються з часовою роздільністю **20–40** хв.

5. Кореляційні властивості.

$\text{corr}(\mu(t), \sigma(t)) = 0.0808$, що свідчить про відсутність залежності між рівнем процесу та його волатильністю.

Рис. 3. Результат автоматичної генерації ключових висновків аналізу результатів роботи Python-програми (CSV-файли і графіки з рис. 1, 2 у форматі PNG) для реалізації методу структурного аналізу (OpenAI, ChatGPT 5.1, Nov. 2025)

Рисунок 5.6 – Приклад академічно доброчесного демонстрування яким чином результат роботи нового методу структурного аналізу можна швидко обробити з використанням AI-сервісу і отримати корисні висновки [502]

Можливі теми практичних і лабораторних завдань

Практична робота № 5. Оцінювання якості AI-системи та академічна доброчесність

Метою заняття є опанування методів оцінювання якості AI-СППР та формування коректних практик використання і документування ГШІ у науковій і навчальній роботі.

План заняття:

1. Огляд критеріїв якості з розд. 5.1: точність, надійність, безпечність, пояснюваність. Обговорення, як кожен критерій вимірюється на практиці.

2. Побудова мінімального Golden Dataset для задачі курсового проєкту: 5 тест-кейсів з еталонними критеріями, 1 — навмисно складний або граничний.

3. Демонстрація підходу LLM-as-a-Judge: суддя (більш потужна модель) оцінює відповідь асистента за складеними критеріями. Колективний аналіз виставлених оцінок.

4. Практикум з оформлення AI-use disclosure (шаблон з підрозділу 5.5): кожен студент заповнює disclosure для власного проєкту.

Лабораторна робота № 5. Створення рекомендаційної СППР як багатоагентної AI-системи

Метою роботи є ознайомлення з принципами побудови СППР на основі архітектури багатоагентних систем: розподіл аналітичних функцій між спеціалізованими агентами (Генератор, Критик, Синтезатор) і реалізація механізму досягнення консенсусу.

Хід роботи:

1. Вибір сценарію для СППР: обрати прикладну аналітичну задачу (наприклад: оцінка інвестиційного проєкту, вибір архітектурного рішення, прогнозування ризиків розгортання ПЗ); визначити цільову ознаку і вхідні параметри.
2. Проєктування ролей агентів: описати системні інструкції для *Генератора* (формує пропозицію), *Критика* (знаходить ризики і слабкі місця) та *Синтезатора* (формує фінальний вердикт у форматі: РЕЗЮМЕ → РИЗИКИ → РІШЕННЯ).
3. Тестування агентної взаємодії: побудувати серію тестових діалогів; перевірити здатність агентів послідовно обробляти повідомлення (handover); проаналізувати залежність між складністю задачі і кількістю потрібних ітерацій.
4. Реалізація оркестрації: запрограмувати послідовний конвеєр (Proposer → Critic → Aggregator) з передачею повного контексту між агентами; забезпечити обробку помилок і паузи між викликами (дотримання RPM-квоти).
5. Висновки: порівняти якість фінального рішення системи з відповіддю одиночного агента на ту ж задачу; оцінити об'єктивність синтезованого вердикту; визначити напрями покращення (ролі, структура передачі контексту, кількість агентів).

Лабораторна робота № 6. Побудова бенчмарку та оцінювання AI-асистента методом LLM-as-a-Judge

Метою роботи є опанування методології об'єктивного оцінювання AI-систем: формування Golden Dataset, реалізація підходу LLM-as-a-Judge, розрахунок метрик якості та порівняльний аналіз агента.

Хід роботи:

1. Формування Golden Dataset: скласти 5–10 тест-кейсів для асистента, розробленого у ЛР 4; кожен тест-кейс містить: запит, очікувані критерії відповіді, категорію (Coding / Role / Tools / Logic); включити 1–2 граничних або провокативних запити.

2. Аналіз структури бенчмарку: описати розподіл запитань за категоріями; визначити шкалу оцінювання судді (1–5 балів) і текстові критерії для кожного рівня; перевірити, що критерії є однозначними і вимірюваними.
3. Реалізація автоматизованого оцінювання: запрограмувати скрипт-бенчмарк, що надсилає запит асистенту (*ASSISTANT_MODEL*) і передає відповідь судді (*JUDGE_MODEL = gemini-1.5-pro* або *аналог*); суддя повертає JSON з полями *{score, reason}*; забезпечити обробку помилок і затримки між викликами.
4. Візуалізація результатів: побудувати стовпчикову діаграму балів за тест-кейсами; обчислити середній бал за категоріями; виявити найпроблемніші аспекти роботи агента.
5. Висновки: порівняти результати бенчмарку з суб'єктивними оцінками з ЛР 4–5; оцінити об'єктивність судді; сформулювати конкретні рекомендації щодо вдосконалення системного промпту або бази знань агента.

Контрольні питання

1) Чому якість генеративного ШІ є *багатовимірним* поняттям? Наведіть приклад конфлікту між двома критеріями — наприклад, корисністю відповіді та безпечністю — і поясніть, як він вирішується при проектуванні AI-СППР.

2) Чим відрізняються *пряме* і *проксі-вимірювання* якості LLM? Чому більшість критеріїв (корисність, узгодженість, безпечність) оцінюються через проксі, а не безпосередньо? Наведіть приклад такого проксі.

3) Що таке *стабільність* і *відтворюваність* генерації і чому ці властивості є критичними саме для СППР, а не для творчих застосувань? За якими ознаками можна виявити нестабільну поведінку моделі на практиці?

4) Поясніть загальну структуру *LLM-бенчмарку*: з яких компонентів він складається і яку роль виконує кожен? Чому формування оцінювального датасету є окремою інженерною задачею, а не просто підбіркою випадкових питань?

5) Класифікуйте LLM-бенчмарки за типами задач (логічні, знаннєві, прикладні тощо) і наведіть по одному прикладу кожного. Чому не існує *універсального бенчмарку* і від чого залежить вибір бенчмарку при порівнянні моделей для конкретної СППР?

6) Що таке *забруднення бенчмарку* (*benchmark contamination*)? Чому ця проблема набуває особливої гостроти в 2025–2026 роках, коли навчальні копуси LLM охоплюють більшість публічно доступних текстів?

7) Чим оцінювання *агента* принципово відрізняється від оцінювання одиночного виклику LLM? Які нові виміри якості з'являються при переході від «відповіді на запит» до «виконання багатокрокового завдання»?

8) Опишіть структуру типового *агент-бенчмарку*: що виступає входом, що вважається успішним результатом і як оцінюється проміжна поведінка агента? Наведіть приклад прикладного агент-бенчмарку з реальної задачі системного аналізу.

9) Поясніть поняття *Парето-оптимальної* конфігурації AI-системи. Чому між двома Парето-оптимальними конфігураціями неможливо зробити «об'єктивний» вибір і яку роль у цьому відіграє замовник системи?

10) Назвіть п'ять рівнів оптимізації AI-СППР (від найдешевшого до найскладнішого). Чому рекомендується починати саме з рівня промптів, а не з заміни моделі? У яких випадках перехід до рівня інфраструктури є виправданим?

11) У чому полягає різниця між *допустимим використанням* генеративного ШІ в академічній роботі і *підміною авторства*? Складіть AI-use disclosure для умовного курсового проєкту, де ГШІ використовувався для структурування записки, допоміжного коду і перекладу частини тексту.

12) Охарактеризуйте ключові положення *EU AI Act* (Регламент ЄС 2024/1689) щодо систем «високого ризику» і вимог до GPAI-моделей. Чому вимога людського нагляду (human oversight) є системно важливою не лише з правової, а й з методологічної точки зору системного аналізу?

6. КУРСОВИЙ ПРОЄКТ: СТВОРЕННЯ ВЛАСНОГО AI-АГЕНТА

6.1 Загальні положення

Виконання курсового проєкту з дисципліни «Генеративний штучний інтелект» передбачено навчальним планом спеціальності «Системний аналіз» для студентів першого курсу магістратури. На виконання курсового проєкту відводиться 60 годин самостійної роботи (2 кредити ЄКТС).

Метою курсового проєкту є закріплення теоретичних знань з курсу, розвиток уміння застосовувати сучасні інструменти генеративного штучного інтелекту для вирішення прикладних задач, а також набуття практичних навичок розробки LLM-агентів.

Курсовий проєкт виконується самостійно з дотриманням вимог академічної доброчесності згідно з відповідними положеннями ВНТУ [93, 94]. Факт несамостворення виконання є підставою для недопуску до захисту.

Основні вимоги до курсового проєкту:

- обсяг основної частини пояснювальної записки — не менше 20 сторінок формату А4;
- ілюстративні матеріали подаються у тексті або виносяться в додатки з обов'язковим посиланням на них в індивідуальному завданні;
- пояснювальна записка оформлюється згідно з вимогами розділу 6.6 цього посібника та чинними стандартами ДСТУ;
- вихідний код розробленого агента розміщується у ноутбукі на платформі Kaggle або у відкритому репозиторії на платформі GitHub з посиланням у списку використаних джерел.

6.2 Структура курсового проєкту

Курсовий проєкт складається з пояснювальної записки та ілюстративної частини. Загальна структура пояснювальної записки передбачає вступну частину, основну частину та додатки.

Вступна частина містить:

- титульний аркуш (зразок — у додатку 6.А);
- індивідуальне завдання (зразок — у додатку 6.Б);
- анотацію (зразок — у додатку 6.В);
- зміст (зразок — у додатку 6.Г).

Основна частина містить:

- вступ;
- розділ 1 — загальна характеристика предметної області та аналіз існуючих AI-агентів;
- розділ 2 — аналіз та вибір інструментів розробки;
- розділ 3 — проєктування та розроблення LLM-агента;
- висновки;

- список використаних джерел.

Додатки (за потреби) містять допоміжні матеріали: зразки лістингу коду, приклади діалогів агента, схеми, ілюстративну частину (обов'язковий додаток).

6.3 Зміст пояснювальної записки

Вступ обсягом до 3 сторінок містить обґрунтування актуальності теми, характеристику об'єкта та предмета дослідження, мету і завдання курсового проєкту, а також короткий опис використаних інструментів і методів. У вступі слід обґрунтувати практичну цінність розробленого агента.

Розділ 1. Загальна характеристика предметної області та аналіз існуючих AI-агентів. Перший розділ є аналітично-оглядовим і рекомендованим обсягом 5–10 сторінок. Він містить:

- аналіз предметної області, для якої розробляється агент: характеристика типових задач, особливостей взаємодії з користувачем, вимог до автоматизації;
- огляд існуючих AI-агентів та LLM-рішень у відповідній галузі із зазначенням їх переваг і недоліків;
- постановку задачі курсового проєкту: формулювання функціональних вимог до агента, визначення сценаріїв взаємодії та очікуваних результатів.

Огляд аналогів має бути обґрунтованим і спиратися на актуальні джерела (не старіші 3–5 років), включаючи наукові статті, технічну документацію та публічні демонстрації відповідних систем.

Розділ 2. Аналіз та вибір інструментів розробки. Другий розділ містить обґрунтування вибору технологій та інструментів для реалізації агента. Рекомендованим фреймворком для розробки є Google ADK (Agent Development Kit) — він надає декларативний інтерфейс для визначення агента, управління інструментами (tools) та тестування через вбудований Google ADK Web UI. Студент може обрати альтернативний фреймворк (LangChain, CrewAI, AutoGen тощо) за умови належного обґрунтування.

Розділ має охоплювати:

- порівняльний аналіз фреймворків для розробки LLM-агентів;
- обґрунтування вибору фреймворку, мови програмування та засобів зберігання даних;
- вибір великої мовної моделі та засобів її інтеграції.

Розділ 3. Проєктування та розроблення LLM-агента. Третій розділ є практичним ядром курсового проєкту та має містити:

- опис архітектури агента із зазначенням усіх компонентів та їх взаємодії (підкріплюється діаграмою);
- розробку набору інструментів агента (tools): перелік, призначення, вхідні/вихідні параметри, логіка реалізації;
- реалізацію чатбот-компонента: системний промпт, управління контекстом діалогу, налаштування поведінки моделі;

– розгортання та тестування агента: опис середовища, тестові сценарії, результати тестування.

Практична частина обов'язково супроводжується посиланнями на рисунки (діаграми, скриншоти інтерфейсу, приклади діалогів). Лістинги коду виносяться в додатки.

При описі практичної реалізації LLM-агента слід спиратися на матеріали курсу «5-Day AI Agents Intensive» на платформі Kaggle [95], зокрема на практичний ноутбук «Day 1b – Agent Architectures» [96], у якому детально розкрито основні архітектурні патерни агентів: ReAct (Reasoning + Acting), Plan-and-Execute, Multi-Agent Systems, а також наведено приклади реалізації інструментів (tools) і управління контекстом за допомогою циклу «thought → action → observation».

Висновки та список використаних джерел. Висновки підсумовують досягнуті результати, описують функціональні можливості розробленого агента та порівнюють його з існуючими аналогами. Наводяться пропозиції щодо подальшого вдосконалення.

Список використаних джерел оформлюється відповідно до ДСТУ 8302:2015 і має включати не менше 10 джерел, серед яких — документація використаних фреймворків, наукові статті та посилання на репозиторій проєкту.

6.4 Рекомендована послідовність розробки агента в курсовому проєкті

На основі матеріалів ноутбуку «Day 1b – Agent Architectures» [96] рекомендується така послідовність розробки LLM-агента в рамках курсового проєкту (рисунок 6.1).

Крок 1. Визначення задачі та мети агента. Сформулювати конкретну прикладну задачу, яку вирішуватиме агент (наприклад: «агент-асистент для підбору науково-технічних статей за темою»). Визначити вхідні та вихідні дані, критерії успіху.

Крок 2. Вибір архітектурного патерну. Обрати базовий патерн роботи агента, наприклад ReAct або Plan-and-Execute, та, за потреби, спосіб організації багатоагентної системи. Для більшості курсових проєктів достатньо ReAct-агента з 3–5 інструментами.

Крок 3. Визначення та реалізація інструментів. Описати, які зовнішні дії потрібні агенту. Реалізувати кожен інструмент як Python-функцію з docstring. Перевірити кожен інструмент незалежно до інтеграції з агентом.

Крок 4. Налаштування системного промпу. Написати системний промпт, що задає роль агента, його цілі, доступні інструменти та обмеження. Системний промпт є «інструкцією» для LLM і суттєво впливає на якість роботи агента.

Крок 5. Налаштування та тестування. Запустити агента на наборі тестових запитів. Аналізувати трасу виконання агента (tracing): послідовність кроків, виклики інструментів, їх параметри та результати, помилки й умови

завершення. Ітеративно вдосконалювати інструменти, контекст та інструкції агента.

Крок 6. Оцінка якості та аналіз обмежень. Оцінити агента на репрезентативному наборі задач. Зафіксувати успішні і невдалі випадки, проаналізувати причини помилок. Сформулювати рекомендації щодо покращення.




Рисунок 6.1 – Приклад архітектури розробленого агента [95]

6.5 Приклад практичного завдання для курсового проекту

На основі матеріалів ноутбуку [96] нижче наведено приклад практичного завдання, яке студент може взяти за основу або використати як відправну точку для формулювання власної теми курсового проекту.

Завдання: розробити LLM-агента-дослідника, що автоматизує пошук та аналіз науково-технічних публікацій. Агент отримує від користувача тему дослідження та формує структурований аналітичний звіт, що включає: огляд основних публікацій, виявлення ключових тенденцій, порівняльний аналіз підходів, перелік відкритих проблем та рекомендації для подальших досліджень.

Агент реалізується за патерном ReAct і має у своєму розпорядженні такі інструменти: пошук в Google Scholar (через API або парсинг), завантаження та читання PDF-файлів статей, збереження знайдених фактів у структурований журнал спостережень, генерація підсумкових секцій звіту.

Приклад сесії роботи агента (рисунок 6.2): користувач ставить запит «Проаналізуй публікації про RAG-агентів за 2024–2025 роки»; агент генерує думку про необхідність пошуку, викликає інструмент пошуку, аналізує результати, вирішує завантажити 3 найрелевантніші статті, читає їх, формує тематичний огляд і повертає структурований звіт.




Рисунок 6.2 – Приклад архітектури LLM-агента-дослідника [95]

6.6 Вимоги до оформлення

Пояснювальна записка оформлюється на аркушах формату А4 відповідно до вимог «Положення про курсове проектування у ВНТУ» [97] та ДСТУ 3008:2015 [98, 99].

Основні параметри форматування:

- шрифт — Times New Roman, 14 пт, чорний, прямий;
- міжрядковий інтервал — 1;
- поля: ліве — 25 мм, праве — 10 мм, верхнє і нижнє — по 20 мм;
- абзацний відступ — 1,25 см (єдиний по всьому тексту);
- нумерація сторінок — арабськими цифрами, у правому верхньому куті, наскрізна; титульний аркуш входить до нумерації, але номер на ньому не проставляється.

Заголовки розділів розміщуються посередині сторінки великими літерами, напівжирним шрифтом, без крапки в кінці. Кожен розділ починається з нової сторінки. Заголовки підрозділів друкуються з абзацного відступу з великої літери, напівжирним шрифтом.

Рисунки нумеруються в межах розділу (наприклад, Рисунок 3.1) і підписуються під ілюстрацією по центру без крапки в кінці. Таблиці нумеруються аналогічно і підписуються над таблицею зліва. У тексті обов'язкові посилання на всі рисунки та таблиці.

Лістинги коду оформлюються шрифтом Courier New або Consolas, 10–12 пт, та виносяться у додатки. У тексті основної частини допускаються лише короткі фрагменти (до 10 рядків) для пояснення ключових концепцій.

Посилання на джерела вказуються в квадратних дужках, наприклад: [1], [2, 3]. Порядкові номери у списку джерел відповідають порядку першого згадування в тексті.

6.7 Тематика курсових проєктів

Теми курсових проєктів затверджуються на засіданні кафедри. Студент може запропонувати власну тему, обґрунтувавши її актуальність. Приблизний перелік тем наведено нижче (таблиця 6.1).

Таблиця 6.1 – Приклади тем курсового проєкту

№	Тема курсового проєкту	Предметна область
1	Розроблення LLM-агента для автоматизованого обслуговування клієнтів інтернет-магазину	E-commerce
2	Розроблення AI-агента для підтримки студентів у навчальному процесі (відповіді на питання щодо розкладу, дедлайнів, матеріалів курсу)	Освіта
3	Розроблення LLM-агента для первинного сортування та маршрутизації заявок технічної підтримки	ІТ-сервіс
4	Розроблення AI-агента для аналізу та узагальнення наукових статей за заданою темою	Наукові дослідження
5	Розроблення LLM-агента для автоматизованого складання та перевірки звітів про фінансові транзакції	Фінанси
6	Розроблення AI-агента для консультування пацієнтів щодо запису на прийом та загальних медичних питань	Охорона здоров'я
7	Розроблення LLM-агента для генерації та ревізії програмного коду за специфікацією	Розроблення ПЗ
8	Розроблення AI-агента для моніторингу та аналізу відгуків користувачів у соціальних мережах	Маркетинг / SMM
9	Розроблення LLM-агента для управління персональними завданнями та нагадуваннями з інтеграцією календаря	Продуктивність
10	Розроблення AI-агента для інтерактивного навчання іноземних мов з адаптивними вправами та зворотнім зв'язком	EdTech
11	Розроблення LLM-агента для автоматизованого формування юридичних документів (договорів, заяв) за шаблоном	Юридичні послуги
12	Розроблення AI-агента для аналізу та класифікації резюме кандидатів на вакансії	HR / Рекрутинг

13	Розроблення LLM-агента для надання туристичних рекомендацій та планування маршрутів подорожей	Туризм
14	Розроблення AI-агента для моніторингу стану IoT-пристроїв та генерації рекомендацій з усунення несправностей	IoT / Промисловість
15	Розроблення LLM-агента для автоматизованої перевірки та коментування студентських робіт за критеріями оцінювання	Освіта / Оцінювання

6.8 Порядок захисту та критерії оцінювання

Порядок захисту курсового проєкту визначається «Положенням про курсове проєктування у ВНТУ» [97]. Студент подає завершений курсовий проєкт у форматі PDF через інструмент «Файл-Експрес» системи JetIQ. Керівник зобов'язаний надати відповідь протягом семи діб.

Курсовий проєкт допускається до захисту, якщо він виконаний у повному обсязі відповідно до індивідуального завдання, оформлений згідно з вимогами, не містить ознак академічної недоброчесності та поданий у встановлений термін.

Захист проводиться публічно перед комісією у складі не менше двох викладачів. На захисті студент робить доповідь тривалістю 5–10 хвилин, у якій висвітлює: актуальність теми, архітектуру агента, реалізовані інструменти та результати тестування, а також демонструє роботу агента в режимі реального часу. Після доповіді члени комісії ставлять запитання теоретичного та практичного характеру.

Курсовий проєкт оцінюється за 100-бальною системою відповідно до критеріїв, наведених у таблиці 6.2.

Таблиця 6.2 – Критерії оцінювання курсового проєкту

Рівень компетентності	Балів (100-бальна шкала)	Оцінка ЄКТС	Критерії оцінювання
IV Високий (творчий)	90–100	A	КП виконано якісно, без помилок. Агент повністю функціональний, демонстрація проходить успішно за всіма сценаріями. Студент виявляє глибокі знання, вільно орієнтується в документації та архітектурних рішеннях, аргументовано відповідає на запитання комісії.
III Достатній (конструктивний)	82–89	B	КП виконано якісно, без суттєвих помилок. Агент функціональний. Студент демонструє впевнені знання, вміє відстоювати прийняті рішення, допускає несуттєві неточності у відповідях.

	75–81	C	КП виконано з незначними помилками. Агент в цілому функціональний. Студент розуміє основні концепції, наводить власні приклади, проте відповіді містять окремі неточності.
II Середній (репродуктивний)	64–74	D	У КП допущена одна суттєва помилка. Окремі функції агента реалізовані частково. Студент відтворює основний матеріал, відповіді неповні, потребує допомоги викладача.
	60–63	E	У КП допущено дві суттєві помилки. Агент демонструє обмежену функціональність. Задовільні знання матеріалу, студент не відповідає на частину запитань.
I Низький (недостатній)	35–59	FX	Більше двох суттєвих помилок. Агент не демонструє задовільної роботи. Матеріал викладається уривчасто, студент не може обґрунтувати прийняті рішення. Має право на доопрацювання.
	0–34	F	Більше двох суттєвих помилок. Агент не функціонує або відсутній. Студент не може пояснити прийняті рішення. Академічна заборгованість; необхідне виконання КП за новою темою.

ДОДАТКИ ДО РОЗДІЛУ 6

Додаток 6.А
(обов'язковий)

Зразок титульного аркуша курсового проєкту

Вінницький національний технічний університет
Факультет інтелектуальних інформаційних технологій та автоматизації
Кафедра системного аналізу та інформаційних технологій

КУРСОВИЙ ПРОЄКТ

з дисципліни «Генеративний штучний інтелект»
на тему: «[Назва теми курсового проєкту]»
08-34.ГШ.ХХХ.ХХ.000 ПЗ

Виконав студент 1-го курсу групи СА-25м
спеціальності «Системний аналіз та наука про дані»
[Ім'я ПРІЗВИЩЕ студента]

Керівник асистент каф. САІТ
PhD, Арсен ЛОСЕНКО

Кількість балів: _____
Оцінка ЄКТС _____

Члени комісії:
Лосенко А. В.
Мокін В. Б.

Вінниця – 2026 рік

Додаток 6.Б
(обов'язковий)

Зразок індивідуального завдання курсового проєкту

Вінницький національний технічний університет
Факультет інтелектуальних інформаційних технологій та автоматизації
Кафедра системного аналізу та інформаційних технологій

ЗАТВЕРДЖУЮ

Завідувач кафедри САІТ
д. т. н., професор Віталій МОКІН
« ____ » _____ 2026 року

ІНДИВІДУАЛЬНЕ ЗАВДАННЯ

на курсовий проєкт з дисципліни «Генеративний штучний інтелект»
[Прізвище Ім'я По-батькові], студента гр. СА-25м

Тема проєкту: [Назва теми курсового проєкту]

Завдання: Розробити LLM-агента для [опис прикладної задачі] на основі Google ADK.

Вхідні дані до виконання проєкту:

- Google ADK — фреймворк для розробки LLM-агентів
- Gemini API — програмний інтерфейс доступу до моделей Gemini
- Python — основна мова програмування
- Google ADK Web UI — вбудований інтерфейс тестування
- Git / GitHub — система контролю версій

Зміст пояснювальної записки:

- Анотація
- Зміст
- Вступ

- 1 Загальна характеристика предметної області та аналіз існуючих AI-агентів
- 2 Аналіз та вибір інструментів розробки агента
- 3 Проєктування та розроблення LLM-агента
- Висновки
- Список використаних джерел
- Додатки

Зміст ілюстративної частини:

- Діаграма архітектури LLM-агента
- Діаграма інструментів агента (tools)
- Схема взаємодії компонентів системи
- Зразки діалогів агента з користувачем (скриншоти Google ADK Web UI)

Дата видачі завдання: _____

Строк подання завершеного проєкту: _____

Керівник _____ Арсен ЛОСЕНКО

Завдання отримав _____ [Ім'я ПРІЗВИЩЕ студента]

Додаток 6.В

(обов'язковий)

Зразок анотації курсового проєкту

АНОТАЦІЯ

[Прізвище І. П.] [Назва теми курсового проєкту]. Курсовий проєкт з дисципліни «Генеративний штучний інтелект».

У курсовому проєкті розроблено LLM-агента для [опис призначення]. Проведено аналіз предметної області та існуючих рішень на основі великих мовних моделей, визначено їх переваги та обмеження, що дозволило обґрунтувати доцільність розробки власного агента.

У процесі виконання роботи використано фреймворк Google ADK для побудови агентної логіки та мову програмування Python. Як велику мовну модель застосовано Gemini від Google (доступ здійснюється через Gemini API). Тестування агента виконано засобами Google ADK Web UI.

Агент реалізовано з набором інструментів (tools) для виконання таких дій: [перелік ключових інструментів]. Управління контекстом діалогу забезпечено вбудованим механізмом сесій Google ADK.

Вихідний код розробленого агента розміщено у відкритому репозиторії на платформі GitHub.

Ключові слова: LLM-агент, генеративний штучний інтелект, Google ADK, Gemini, інструменти агента, [предметна область].

Додаток 6.Г
(обов'язковий)

Зразок змісту курсового проєкту

ЗМІСТ

ВСТУП.....	3
1 ЗАГАЛЬНА ХАРАКТЕРИСТИКА ПРЕДМЕТНОЇ ОБЛАСТІ ТА АНАЛІЗ ІСНУЮЧИХ AI-АГЕНТІВ	5
1.1 Аналіз предметної області.....	5
1.2 Огляд існуючих LLM-агентів та рішень.....	7
1.3 Постановка задачі.....	11
2 АНАЛІЗ ТА ВИБІР ІНСТРУМЕНТІВ РОЗРОБКИ АГЕНТА	13
2.1 Порівняльний аналіз фреймворків для розробки LLM-агентів.....	13
2.2 Вибір та обґрунтування інструментів розробки	15
2.3 Вибір великої мовної моделі та засобів інтеграції	17
3 ПРОЄКТУВАННЯ ТА РОЗРОБЛЕННЯ LLM-АГЕНТА	19
3.1 Проєктування архітектури агента.....	19
3.2 Розроблення інструментів агента (tools).....	22
3.3 Реалізація чатбот-компонента агента.....	26
3.4 Розгортання та тестування агента.....	30
ВИСНОВКИ.....	34
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	36
Додаток А (довідковий) Зразки лістингу коду агента.....	38
Додаток Б (обов'язковий) Ілюстративна частина.....	42

1. Наука про дані: машинне навчання та інтелектуальний аналіз даних : електронний навчальний посібник комбінованого (локального та мережевого) використання [Електронний ресурс] / В. Б. Мокін, М. В. Дратований – Вінниця : ВНТУ, 2024. – 258 с. – Режим доступу: <https://docs.vntu.edu.ua/card.php?id=8163>
2. Machine Learning, Intelligent Data Analysis and Artificial Intelligence of Things : electronic textbook [Electronic resource] / V. B. Mokin, M. G. Pradiivliannyi – Vinnytsia : VNTU, 2024. – 230 p. URL <https://iq.vntu.edu.ua/repository/getfile.php/9462.pdf>
3. LSTM – стаття 1997 р.: https://www.cri.minesparis.psl.eu/people/silber/cours/2025/nlp/bib/HochreiterS1997.pdf?utm_source=chatgpt.com
4. Ембедінги на практиці-1 - Micolov 2013 <https://arxiv.org/abs/1301.3781>
5. Ембедінги на практиці-2 - Micolov 2013 <https://aclanthology.org/N13-1090.pdf>
6. Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio. Generative Adversarial Nets. arXiv:1406.2661v1, 2014. <https://arxiv.org/pdf/1406.2661>
7. Svyatkovskiy, A., Zhao, Y., et al. Pythia: AI-assisted Code Completion System. *KDD 2019*. – 2019. – URL: <https://arxiv.org/abs/1912.00742> (дата звернення: 10.04.2026).
8. Microsoft. IntelliCode for Visual Studio [Електронний ресурс]. – 2018. – URL: <https://visualstudio.microsoft.com/services/intellicode/> (дата звернення: 10.04.2026).
9. Microsoft Visual Studio Blog. Re-imagining Developer Productivity with AI-assisted Tools [Електронний ресурс]. – 2019. – URL: <https://devblogs.microsoft.com/visualstudio/ai-assisted-developer-tools/> (дата звернення: 10.04.2026).
10. Exxact Corp. GitHub Copilot and the Rise of AI Language Models in Programming Automation [Електронний ресурс]. – 2021. – URL: <https://www.exxactcorp.com/blog/Deep-Learning/github-copilot-ai-pair-programmer> (дата звернення: 10.04.2026).
11. Brown, T., Mann, B., et al. Language Models are Few-Shot Learners (GPT-3). *Advances in NeurIPS*. – 2020. – Vol. 33. – P. 1877–1901. – URL: <https://arxiv.org/abs/2005.14165> (дата звернення: 10.04.2026).
12. Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., Kaiser Ł., Polosukhin I. Attention Is All You Need. arXiv preprint. 2017. arXiv:1706.03762. URL: <https://arxiv.org/abs/1706.03762> (дата звернення: 13.06.2026).
13. Dosovitskiy A., Beyer L., Kolesnikov A., Weissenborn D., Zhai X., Unterthiner T., Dehghani M., Minderer M., Heigold G., Gelly S., Uszkoreit J.,

Houlsby N. An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. arXiv preprint. 2020. arXiv:2010.11929. URL: <https://arxiv.org/abs/2010.11929> (дата звернення: 13.06.2026).

14. Chen, M., Tworek, J., et al. Evaluating Large Language Models Trained on Code (Codex). *arXiv*. – 2021. – arXiv:2107.03374. – URL: <https://arxiv.org/abs/2107.03374> (дата звернення: 10.04.2026).

15. Jóźwiak D. AI Coding: 5 Eras That Changed Coding Forever. *DEVQUBE*. 2026. URL: <https://devqube.com/ai-coding-history-future/> (дата звернення: 13.06.2026).

16. Luzolo P. H., Elrawashdeh Z., Tchappi I., Galland S., Outay F. Combining Multi-Agent Systems and Artificial Intelligence of Things: Technical challenges and gains. *Internet of Things*. 2024. Vol. 28. Article 101364. DOI: <https://doi.org/10.1016/j.iot.2024.101364>.

17. Міністерство освіти і науки України, Міністерство цифрової трансформації України. Штучний інтелект у закладах вищої освіти: рекомендації для викладачів, студентів і працівників ЗВО. Київ, 2025. URL: <https://mon.gov.ua/static-objects/mon/sites/1/news/2025/04/24/shi-v-zakladakh-vyshchoi-osvity-24-04-2025.pdf> (дата звернення: 13.06.2026).

18. Saravia E. Prompting Techniques. *Prompt Engineering Guide*. DAIR.AI, 2022. URL: <https://www.promptingguide.ai/techniques> (дата звернення: 13.06.2026).

19. Овсієнко Б. Контекст-інжиніринг: нова логіка роботи з LLM. *DOU*. 2026. URL: <https://dou.ua/forums/topic/58328/> (дата звернення: 13.06.2026).

20. Kaggle. Documentation [Електронний ресурс]. – 2025. – URL: <https://www.kaggle.com/docs> (дата звернення: 10.04.2026).

21. Hugging Face. The Hub [Електронний ресурс]. – 2025. – URL: <https://huggingface.co/docs/hub> (дата звернення: 10.04.2026).

22. Ollama. Documentation [Електронний ресурс]. – 2025. – URL: <https://ollama.com/docs> (дата звернення: 10.04.2026).

23. Gradio. Documentation [Електронний ресурс]. – 2025. – URL: <https://www.gradio.app/docs> (дата звернення: 10.04.2026).

24. Streamlit Inc. Documentation [Електронний ресурс]. – 2025. – URL: <https://docs.streamlit.io> (дата звернення: 10.04.2026).

25. DIKW pyramid. Wikipedia, The Free Encyclopedia. URL: https://en.wikipedia.org/wiki/DIKW_pyramid (дата звернення: 13.06.2026).

26. Mokin V. B. LLM Token-Level Visualization. *Kaggle*. URL: <https://www.kaggle.com/code/vbmokin/llm-token-level-visualization> (дата звернення: 13.06.2026).

27. Talisman J. Ontologies, Context Graphs, and Semantic Layers: What AI Actually Needs in 2026. *Context & Chaos*. 2026. URL: <https://contextandchaos.substack.com/p/ontologies-context-graphs-and-semantic> (дата звернення: 13.06.2026).

28. Mokin V. B. Visualizing Multilingual Embedding Algebra. Kaggle. URL: <https://www.kaggle.com/code/vbmokin/visualizing-multilingual-embedding-algebra> (дата звернення: 13.06.2026).
29. Gao, L., Biderman, S., et al. The Pile: An 800GB Dataset of Diverse Text for Language Modeling. *arXiv*. – 2021. – arXiv:2101.00027. – URL: <https://arxiv.org/abs/2101.00027> (дата звернення: 15.04.2026).
30. Wei, J., Bosma, M., et al. Finetuned Language Models Are Zero-Shot Learners (FLAN). *ICLR 2022*. – 2022. – URL: <https://arxiv.org/abs/2109.01652> (дата звернення: 15.04.2026).
31. Bai, Y., Jones, A., et al. Training a Helpful and Harmless Assistant with Reinforcement Learning from Human Feedback. *arXiv*. – 2022. – arXiv:2204.05862. – URL: <https://arxiv.org/abs/2204.05862> (дата звернення: 15.04.2026).
32. Zhao W. X., Zhou K., Li J., Tang T., Wang X., Hou Y., Min Y., Zhang B., Zhang J., Dong Z., Du Y., Yang C., Chen Y., Chen Z., Jiang J., Ren R., Li Y., Tang X., Liu Z., Liu P., Nie J.-Y., Wen J.-R. A Survey of Large Language Models. *arXiv preprint*. 2023. arXiv:2303.18223. URL: <https://arxiv.org/abs/2303.18223> (дата звернення: 13.06.2026).
33. Wang, Y., Kordi, Y., et al. Self-Instruct: Aligning Language Models with Self-Generated Instructions. *ACL 2023*. – 2023. – URL: <https://arxiv.org/abs/2212.10560> (дата звернення: 15.04.2026).
34. Shumailov I., Shumaylov Z., Zhao Y., Papernot N., Anderson R., Gal Y. AI models collapse when trained on recursively generated data. *Nature*. 2024. Vol. 631, No. 8022. P. 755–759. DOI: <https://doi.org/10.1038/s41586-024-07566-y>.
35. Abdin, M., et al. Phi-4 Technical Report. *arXiv*. – 2024. – arXiv:2412.08905. – URL: <https://arxiv.org/abs/2412.08905> (дата звернення: 15.04.2026).
36. Міністерство цифрової трансформації України. Словник термінів у сфері штучного інтелекту. Київ, 2026. 37 с. URL: <https://storage.thedigital.gov.ua/files/9/39/18441baf603a192429ecac57b7076394.pdf> (дата звернення: 13.06.2026).
37. Brown, T., Mann, B., et al. Language Models are Few-Shot Learners (GPT-3). *Advances in NeurIPS*. – 2020. – Vol. 33. – P. 1877–1901. – URL: <https://arxiv.org/abs/2005.14165> (дата звернення: 10.04.2026).
38. Bommasani, R., Hudson, D. A., et al. On the Opportunities and Risks of Foundation Models. *arXiv*. – 2021. – arXiv:2108.07258. – URL: <https://arxiv.org/abs/2108.07258> (дата звернення: 10.04.2026).
39. Anthropic. Claude Models Overview [Електронний ресурс]. – 2025. – URL: <https://www.anthropic.com/claude> (дата звернення: 10.04.2026).
40. Mokin V. B. Transformer & Vision Transformer attention demo. Kaggle. URL: <https://www.kaggle.com/code/vbmokin/transformer-vision-transformer-attention-demo> (дата звернення: 13.06.2026).

41. Li J., Tu Z., Yang B., Lyu M. R., Zhang T. Multi-Head Attention with Disagreement Regularization. *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. Brussels, Belgium : Association for Computational Linguistics, 2018. P. 2897–2903. DOI: <https://doi.org/10.18653/v1/D18-1317>. (дата звернення: 13.06.2026).
42. Dao, T., Fu, D., et al. FlashAttention: Fast and Memory-Efficient Exact Attention with IO-Awareness. *Advances in NeurIPS*. – 2022. – Vol. 35. – URL: <https://arxiv.org/abs/2205.14135> (дата звернення: 10.04.2026).
43. Dosovitskiy, A., Beyer, L., et al. An Image is Worth 16×16 Words: Transformers for Image Recognition at Scale (ViT). *ICLR 2021*. – 2021. – URL: <https://arxiv.org/abs/2010.11929> (дата звернення: 10.04.2026).
44. Lewis, P., Perez, E., et al. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks. *Advances in NeurIPS*. – 2020. – Vol. 33. – P. 9459–9474. – URL: <https://arxiv.org/abs/2005.11401> (дата звернення: 10.04.2026).
45. Kirkpatrick, J., Pascanu, R., et al. Overcoming Catastrophic Forgetting in Neural Networks. *Proceedings of the National Academy of Sciences*. – 2017. – Vol. 114, No. 13. – P. 3521–3526. – URL: <https://arxiv.org/abs/1612.00796> (дата звернення: 10.04.2026).
46. Hu, E., Shen, Y., et al. LoRA: Low-Rank Adaptation of Large Language Models. *ICLR 2022*. – 2022. – URL: <https://arxiv.org/abs/2106.09685> (дата звернення: 10.04.2026).
47. Muskan Bansal. Generative Adversarial Networks: Unlocking the Power of Artificial Creativity (Beginner's Guide). Medium, Nov 2023. <https://levelup.gitconnected.com/generative-adversarial-networks-unlocking-the-power-of-artificial-creativity-beginners-guide-7353a70a8709>
48. Karras T., Aittala M., Hellsten J., Laine S., Lehtinen J., Aila T. StyleGAN2-ADA: Official PyTorch Implementation. *GitHub / NVlabs*. 2021. URL: <https://github.com/NVlabs/stylegan2-ada-pytorch> (дата звернення: 13.06.2026).
49. Kuo R. StyleGAN2 ADA. *Kaggle*. URL: <https://www.kaggle.com/code/rkuo2000/stylegan2-ada> (дата звернення: 13.06.2026).
50. Saul Dobilas. VAE: Variational Autoencoders — How to Employ Neural Networks to Generate New Images. Medium, Apr 2022. <https://medium.com/data-science/vae-variational-autoencoders-how-to-employ-neural-networks-to-generate-new-images-bdeb216ed2c0>
51. Buhl N. An Introduction to Diffusion Models for Machine Learning. *Encord Blog*. 2023. URL: <https://encord.com/blog/diffusion-models/> (дата звернення: 13.06.2026).
52. Gainetdinov A. Diffusion Models vs. GANs vs. VAEs: Comparison of Deep Generative Models. Towards AI. 2023. URL: <https://pub.towardsai.net/diffusion-models-vs-gans-vs-vaes-comparison-of-deep-generative-models-67ab93e0d9ae> (дата звернення: 13.06.2026).

53. Aloa. DALL-E vs Midjourney vs Stable Diffusion 2026 [Электронный ресурс]. – 2026. – URL: <https://aloe.co/ai/comparisons/ai-image-comparison/dalle-vs-midjourney-vs-stable-diffusion> (дата звернения: 01.06.2026).
54. Digital Applied. AI Video Market After Sora: Runway, Kling, and Veo [Электронный ресурс]. – 2026. – URL: <https://www.digitalapplied.com/blog/ai-video-market-after-sora-runway-kling-veo-2026> (дата звернения: 29.03.2026).
55. Swfte.ai. AI Model Leaderboard June 2026 [Электронный ресурс]. – 2026. – URL: <https://www.swfte.com/ai/leaderboard> (дата звернения: 01.06.2026).
56. OpenAI. Hello GPT-4o. OpenAI. 2024. URL: <https://openai.com/index/hello-gpt-4o/> (дата звернения: 13.06.2026).
57. Google DeepMind. Gemini 3.1 Pro. Google Cloud Documentation. 2026. URL: <https://docs.cloud.google.com/gemini-enterprise-agent-platform/models/gemini/3-1-pro> (дата звернения: 13.06.2026).
58. Anthropic. Introducing Claude Opus 4.8. Anthropic. 2026. URL: <https://www.anthropic.com/news/claude-opus-4-8> (дата звернения: 13.06.2026).
59. Qwen Team (Alibaba Cloud). Qwen3-VL-235B-A22B-Instruct. Hugging Face. 2025. URL: <https://huggingface.co/Qwen/Qwen3-VL-235B-A22B-Instruct> (дата звернения: 13.06.2026).
60. Swfte.ai. Claude Opus 4.8 tops Artificial Analysis Intelligence Index [Электронный ресурс]. – 2026. – URL: <https://www.swfte.com/ai/leaderboard> (дата звернения: 28.05.2026).
61. Raschka S. Understanding Multimodal LLMs. Ahead of AI. 2024. URL: <https://magazine.sebastianraschka.com/p/understanding-multimodal-llms> (дата звернения: 13.06.2026).
62. BentoML. Multimodal AI: The Best Open-Source Vision Language Models in 2026 [Электронный ресурс]. – 2026. – URL: <https://www.bentoml.com/blog/multimodal-ai-a-guide-to-open-source-vision-language-models> (дата звернения: 15.04.2026).
63. Wei J., Wang X., Schuurmans D., Bosma M., Ichter B., Xia F., Chi E., Le Q. V., Zhou D. Chain-of-Thought Prompting Elicits Reasoning in Large Language Models. *Advances in Neural Information Processing Systems (NeurIPS)* 2022). 2022. arXiv:2201.11903. URL: <https://arxiv.org/abs/2201.11903> (дата звернения: 13.06.2026).
64. Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K., & Cao, Y. ReAct: Synergizing Reasoning and Acting in Language Models [Электронный ресурс] / S. Yao et al. // International Conference on Learning Representations (ICLR). – 2023. – URL: <https://arxiv.org/abs/2210.03629> (дата звернения: 01.05.2026).
65. Lewis, P., Perez, E., Piktus, A., et al. Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks [Электронный ресурс] // *Advances in*

Neural Information Processing Systems (NeurIPS). – 2020. – URL: <https://arxiv.org/abs/2005.11401> (дата звернення: 01.05.2026).

66. Jaigu T. Agentic Coding Tools Compared (2026): Claude Code, Cursor, Codex, Aider, and the Gateway That Connects Them. *Requesty Blog*. 2026. URL: <https://www.requesty.ai/blog/agentic-coding-tools-compared-2026-claude-code-cursor-codex-aider> (дата звернення: 13.06.2026).

67. Assembled. AI agent vs. chatbot: Which one is right for your business? *Assembled*. URL: <https://www.assembled.com/page/ai-agent-vs-chatbot> (дата звернення: 13.06.2026).

68. Schluntz, E., Zhang, B. Building effective agents [Електронний ресурс] / Anthropic. – 2024. – URL: <https://www.anthropic.com/news/building-effective-agents> (дата звернення: 01.05.2026).

69. Silfverskiöld I. Agentic AI: Single vs Multi-Agent Systems. *Towards Data Science*. 2025. URL: <https://towardsdatascience.com/agentic-ai-single-vs-multi-agent-systems/> (дата звернення: 13.06.2026).

70. LangChain Inc. LangGraph: Agent Orchestration Framework [Електронний ресурс]. – URL: <https://www.langchain.com/langgraph> (дата звернення: 01.05.2026).

71. Yao S., Zhao J., Yu D., Du N., Shafran I., Narasimhan K., Cao Y. ReAct: Synergizing Reasoning and Acting in Language Models. *ICLR 2023*. 2022. arXiv:2210.03629. URL: <https://arxiv.org/abs/2210.03629> (дата звернення: 13.06.2026).

72. Wang L., Ma C., Feng X., Zhang Z., Yang H., Zhang J., Chen Z., Tang J., Chen X., Lin Y., Zhao W. X., Wei Z., Wen J.-R. A Survey on Large Language Model based Autonomous Agents. *Frontiers of Computer Science*. 2024. Vol. 18. arXiv:2308.11432. DOI: <https://doi.org/10.48550/arXiv.2308.11432>. URL: <https://arxiv.org/abs/2308.11432> (дата звернення: 13.06.2026).

73. Model Context Protocol. Specification (2025-11-25) [Електронний ресурс]. – URL: <https://modelcontextprotocol.io/specification/2025-11-25> (дата звернення: 01.05.2026).

74. Tahir. What is Model Context Protocol? (MCP) Architecture Overview. *Medium*. 2025. URL: <https://medium.com/@tahirbalarabe2/what-is-model-context-protocol-mcp-architecture-overview-c75f20ba4498> (дата звернення: 13.06.2026).

75. ByteBridge. Model Context Protocol (MCP): Evolution, Capabilities, and the Rise of Peta. *Medium*, 2026. URL: <https://bytebridge.medium.com/model-context-protocol-mcp-evolution-capabilities-and-the-rise-of-peta-ff2967b45d48>

76. Shteingart H. Model Context Protocol (MCP): Landscape, Security Threats, and Future Research Directions. *arXiv preprint*. 2025. arXiv:2503.23278. URL: <https://arxiv.org/abs/2503.23278> (дата звернення: 13.06.2026).

77. Schluntz, E., Zhang, B. Building effective agents [Електронний ресурс] / Anthropic. – 2024. – URL: <https://www.anthropic.com/news/building-effective-agents> (дата звернення: 01.05.2026).
78. Google. Agent Development Kit (ADK). *adk.dev*. 2025. URL: <https://adk.dev> (дата звернення: 13.06.2026).
79. Streamlit Inc. Streamlit — A faster way to build and share data apps. *Streamlit*. 2019. URL: <https://streamlit.io> (дата звернення: 13.06.2026).
80. Sprague R. H., Carlson E. D. Building Effective Decision Support Systems. Englewood Cliffs, N.J. : Prentice-Hall, 1982. 329 p. ISBN 0-13-086215-0.
81. Pei Z., Yin J., Zhang J. Language models for materials discovery and sustainability: Progress, challenges, and opportunities. *Progress in Materials Science*. 2025. Article 101495. DOI: <https://doi.org/10.1016/j.pmatsci.2025.101495>. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0079642525000738> (дата звернення: 13.06.2026).
82. Khattab, O., Singhvi, A., et al. DSPy: Compiling Declarative Language Model Calls into Self-Improving Pipelines. *arXiv*. – 2023. – arXiv:2310.03714. – URL: <https://arxiv.org/abs/2310.03714> (дата звернення: 15.04.2026).
83. Shi, F., Chen, X., et al. Large Language Models Can Be Easily Distracted by Irrelevant Context. *ICML 2023*. – 2023. – URL: <https://arxiv.org/abs/2302.00093> (дата звернення: 15.04.2026).
84. Hwang, C.-L., Masud, A. S. M. *Multiple Objective Decision Making — Methods and Applications*. – Berlin: Springer, 1979. – 358 p.
85. Anthropic. Prompt Caching Documentation [Електронний ресурс]. – 2025. – URL: <https://docs.anthropic.com/en/docs/build-with-claude/prompt-caching> (дата звернення: 15.04.2026).
86. Ma, X., Wang, L., et al. Fine-Tuning LLaMA for Multi-Stage Text Retrieval. *arXiv*. – 2024. – arXiv:2310.08319. – URL: <https://arxiv.org/abs/2310.08319> (дата звернення: 15.04.2026).
87. Mehrabi, N., Morstatter, F., et al. A Survey on Bias and Fairness in Machine Learning. *ACM Computing Surveys*. – 2021. – Vol. 54, No. 6. – Article 115. – URL: <https://arxiv.org/abs/1908.09635> (дата звернення: 15.04.2026).
88. Anthropic. Claude's Model Specification [Електронний ресурс]. – 2025. – URL: <https://www.anthropic.com/claude/model-spec> (дата звернення: 15.04.2026).
89. Про академічну доброчесність: Закон України № 4742-IX від 14 листопада 2024 р. [Електронний ресурс]. – Верховна Рада України. – Набрав чинності 1 лютого 2026 р. – URL: <https://zakon.rada.gov.ua/laws/show/4742-20> (дата звернення: 01.04.2026).
90. Grynbaum, M., Mac, R. The Times Sues OpenAI and Microsoft Over A.I. Use of Copyrighted Work. *The New York Times*. – 2023. – URL: <https://www.nytimes.com/2023/12/27/business/media/new-york-times-open-ai-microsoft-lawsuit.html> (дата звернення: 15.04.2026).

91. Регламент (ЄС) 2024/1689 Європейського Парламенту і Ради від 13 червня 2024 р. (Акт про штучний інтелект) [Електронний ресурс]. – URL: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32024R1689> (дата звернення: 01.04.2026).

92. Mediasapiens. У ЄС набули чинності нові правила щодо прозорості штучного інтелекту [Електронний ресурс]. – 2025. – URL: <https://ms.detector.media/internet/post/38278/2025-08-03-u-ies-nabuly-chynnosti-novi-pravyla-shchodo-prozorosti-shtuchnogo-intelektu/> (дата звернення: 01.04.2026).

93. Положення про запобігання академічному плагіату та порядок його виявлення у наукових, кваліфікаційних, навчальних та науково-методичних роботах у Вінницькому національному технічному університеті. 2024. URL: <https://vntu.edu.ua/uploads/2024/Stateofplag.pdf>

94. Положення про академічну доброчесність у ВНТУ. 2024. URL: <https://vntu.edu.ua/uploads/2022/acad.pdf>

95. Kaggle. 5-Day AI Agents Intensive. Kaggle. 2025. URL: <https://www.kaggle.com/learn-guide/5-day-agents> (дата звернення: 13.06.2026).

96. Kaggle 5 Days of AI. Day 1b – Agent Architectures. Kaggle. 2025. URL: <https://www.kaggle.com/code/kaggle5daysofai/day-1b-agent-architectures> (дата звернення: 13.06.2026).

97. Положення про курсове проектування у Вінницькому національному технічному університеті / Укладач Штофель Д. Х. Вінниця : ВНТУ, 2024. 52 с. URL: <https://vntu.edu.ua/uploads/2024/StateofKurs.pdf>

98. ДСТУ 3008:2015. Звіти у сфері науки і техніки. Структура та правила оформлювання. [Чинний з 2015-06-22]. Київ : Держспоживстандарт України, 2015. 31 с. (Система стандартів з інформації та документації) (Національний стандарт України).

99. ДСТУ 8302:2015. Бібліографічне посилання. Загальні положення та правила складання. [Чинний з 2016-07-01]. Київ : Держспоживстандарт України, 2016. 17 с. (Система стандартів з інформації та документації) (Національний стандарт України).

Навчальне електронне видання

**Віталій Борисович Мокін
Арсен Володимирович Лосенко**

ГЕНЕРАТИВНИЙ ШТУЧНИЙ ІНТЕЛЕКТ
Навчальний посібник

Рукопис оформив *В. Мокін*

Редактор *Т. Старічек*

Оригінал-макет виготовив *В. Мокін*

Підписано до видання 28.09.2026 р.

Гарнітура Times New Roman.

Зам. № P2026-124

Видавець та виготовлювач

Вінницький національний технічний університет,

Редакційно-видавничий відділ.

ВНТУ, ГНК, к. 114.

Хмельницьке шосе, 95,

м. Вінниця, 21021.

press.vntu.edu.ua;

Email: rvv.vntu@gmail.com

Свідоцтво суб'єкта видавничої справи
серія ДК №3516 від 01.07.2009 р.