

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук
(повна назва)

Кафедра _____ Штучного інтелекту
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА
Пояснювальна записка

рівень вищої освіти _____ другий (магістерський)

Навчання з підкріпленням на основі зворотного зв'язку
від штучного інтелекту для вирівнювання моделей
(тема)

Виконав:
здобувач _____ другого _____ року навчання,
групи _____ СШМ-24-1

_____ Ярослав СЕЛІН
(власне ім'я, прізвище)

Спеціальність 122 Комп'ютерні науки
(код і повна назва спеціальності)

Тип програми _____ освітньо-наукова
(освітньо-професійна або освітньо-наукова)

Освітня програма Системи штучного інтелекту
(повна назва освітньої програми)

Керівник _____ доц. Марія ГОЛОВЯНКО
(посада, власне ім'я, прізвище)

Допускається до захисту

Завідувач кафедри ШІ

(підпис)

_____ Лариса ЧАЛА
(власне ім'я, прізвище)

2026 р.

Харківський національний університет радіоелектроніки

Факультет _____ Комп'ютерних наук
Кафедра _____ Штучного інтелекту
Рівень вищої освіти _____ другий (магістерський)
Спеціальність _____ 122 Комп'ютерні науки
(код і повна назва)
Тип програми _____ освітньо-наукова
(освітньо-професійна або освітньо-наукова)
Освітня програма _____ Системи штучного інтелекту
(повна назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____
(підпис)

«_____» _____ 20 ____ р.

ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві _____ Селіну Ярославу Юрійовичу
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту для вирівнювання моделей

затверджена наказом університету від _____ 6 _____ квітня _____ 20 26 р. № 269Ст

2. Термін подання здобувачем роботи до екзаменаційної комісії _____ 22 _____ травня _____ 20 26 р.

3. Вихідні дані до роботи _____ Науково-технічні публікації, дані Інтернет-джерел та відомих наукових проєктів, Python documentation

4. Перелік питань, що потрібно опрацювати в роботі _____

1) Аналіз предметної галузі та постановка задачі

2) Теоретичні основи методу RLAIIF

3) Програмна реалізація та результати дослідження

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Строк / термін виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	06.04.2026	виконано
2	Аналіз предметної галузі	07.04.2026	виконано
3	Дослідження теоретичних основ методу RLAIIF	10.04.2026	виконано
4	Програмна реалізація	13.04.2026	виконано
5	Аналіз результатів дослідження	19.04.2026	виконано
6	Написання пояснювальної записки	20.04.2026	виконано
7	Перевірка на академічний плагіат	15.05.2026	виконано
8	Нормоконтроль	15.05.2026	виконано
9	Рецензування	16.05.2026	виконано
10	Підготовка презентації та доповіді	17.05.2026	виконано
11	Попередній захист	20.05.2026	виконано
12	Захист перед ЕК	22.05.2026	

Дата видачі завдання 6 квітня 2026 р.

Здобувач 
(підпис)

Керівник роботи _____
(підпис)

доц. Марія ГОЛОВЯНКО
(посада, власне ім'я, прізвище)

РЕФЕРАТ

Пояснювальна записка: 67 с., 13 рис., 1 дод., 17 джерел.

АВТОМАТИЗОВАНЕ ОЦІНЮВАННЯ, ВЕЛИКІ МОВНІ МОДЕЛІ, ВИРІВНЮВАННЯ МОДЕЛЕЙ, ЗВОРОТНИЙ ЗВ'ЯЗОК, МОДЕЛЬ ВИНАГОРОДИ, НАВЧАННЯ З ПІДКРІПЛЕННЯМ, ШТУЧНИЙ ІНТЕЛЕКТ.

Об'єкт дослідження – процес алгоритмічного вирівнювання та оптимізації поведінки генеративних нейронних мереж в умовах відсутності ручного зворотного зв'язку.

Предмет дослідження – методи, алгоритми та архітектурні рішення для побудови автоматизованого RLAIIF-пайплайну, що включає конституційне AI-оцінювання, навчання моделі винагороди та проксимальну оптимізацію політики.

Мета роботи – підвищення точності, безпеки й фактичної достовірності генерації тексту у великих мовних моделях шляхом дослідження та програмної реалізації оптимізованого алгоритмічного пайплайну навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту.

Методи дослідження – методи машинного навчання та навчання з підкріпленням, статистичне моделювання переваг (модель Бредлі-Террі), трансформерна архітектура нейронних мереж, алгоритми оптимізації політики (PPO), а також методи порівняльного аналізу та оцінювання якості текстових систем.

ABSTRACT

Master's thesis contains: 67 pp., 13 fig., 1 ann., 17 references.

ARTIFICIAL INTELLIGENCE, AUTOMATED EVALUATION, FEEDBACK, LARGE LANGUAGE MODELS, MODEL ALIGNMENT, REINFORCEMENT LEARNING, REWARD MODEL.

Object of study – the process of algorithmic alignment and optimization of generative neural network behavior in the absence of manual human feedback.

Subject of study – methods, algorithms, and architectural solutions for constructing an automated RLAIIF (Reinforcement Learning from AI Feedback) pipeline, including constitutional AI evaluation, reward model training, and proximal policy optimization.

Purpose of the work – to increase the accuracy, safety, and factual reliability of text generation in large language models by researching and programmatically implementing an optimized algorithmic reinforcement learning pipeline based on feedback from artificial intelligence.

Research methods – machine learning and reinforcement learning methods, statistical modeling of preferences (Bradley-Terry model), transformer neural network architecture, policy optimization algorithms (PPO), as well as methods of comparative analysis and quality assessment of text systems.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів	9
Вступ.....	10
1 Аналіз предметної галузі та постановка задачі	12
1.1 Теоретичні основи вирівнювання великих мовних моделей.....	12
1.1.1 Проблема контролю штучного інтелекту в сучасних умовах...	12
1.1.2 Еволюція методів	16
1.2 Аналіз існуючих підходів до вирівнювання моделей	18
1.2.1 Навчання на основі людського відгуку	18
1.2.2 Передумови переходу до автоматизованих систем оцінювання	20
1.3 Дослідження методології навчання на основі зворотного зв'язку від AI	21
1.3.1 Концептуальні основи RLAIIF	21
1.3.2 Аналіз наукових поглядів та тенденцій щодо ефективності методу RLAIIF	23
1.4 Постановка задачі.....	25
1.4.1 Обґрунтування актуальності.....	25
1.4.2 Формулювання мети, предмета та основних завдань роботи ...	26
2 Теоретичні основи методу RLAIIF	28
2.1 Архітектурні основи трансформерних мовних моделей як об'єктів вирівнювання	28
2.1.1 Декодерна архітектура та механізм масштабованої самоуваги	28
2.1.2 Авторегресійна генерація та стохастичне семплювання	30
2.2 Формалізація задачі вирівнювання як задачі оптимального управління	32
2.2.1 Вирівнювання у рамках марковського процесу прийняття рішень	32

2.2.2	Цільова функція вирівнювання та KL-регуляризація	33
2.3	Автоматична генерація набору преференцій	34
2.3.1	Принципи попарного ранжування	34
2.3.2	Конституція штучного інтелекту та Chain-of-Thought оцінювання.....	35
2.4	Теоретичні засади навчання Reward Model.....	37
2.4.1	Статистична модель Бредлі-Террі для попарного ранжування	37
2.4.2	Функція ранжувальних втрат та архітектура нейромережевого оцінювача	38
2.5	Алгоритм проксимальної оптимізації політики для вирівнювання...	40
2.5.1	Теоретичні основи PPO та структура актор-критик.....	40
2.5.2	Кліпована сурогатна функція як механізм стабілізації навчання	41
2.6	Методологія комплексного оцінювання вирівняної моделі	42
2.6.1	Багатовимірна система метрик якості та безпеки	42
2.6.2	Порівняльний аналіз базової та вирівняної моделей	43
3	Програмна реалізація та результати дослідження	45
3.1	Архітектура пайплайну та технологічний стек.....	45
3.1.1	Модульна організація та система конфігурації	45
3.1.2	Технологічний стек та обґрунтування вибору інструментів.....	47
3.2	Реалізація модуля генерації preference dataset	48
3.2.1	Формування навчальних промптів та генерація пар відповідей	48
3.2.2	Реалізація AI-судді та конституції	50
3.3	Реалізація та навчання Reward Model	51
3.3.1	Архітектура класу RewardModelTrainer та тренувальний цикл	51
3.3.2	Результати навчання Reward Model	53
3.4	Реалізація PPO вирівнювання	54
3.4.1	Інтеграція з бібліотекою TRL та конфігурація PPOTrainer	54
3.4.2	Динаміка навчання PPO	55

3.5 Результати комплексного оцінювання.....	57
3.5.1 Якісний аналіз: приклади відповідей базової та вирівняної моделей.....	57
3.5.2 Кількісні результати оцінювання за категоріями	59
3.6 Аналіз результатів	61
Висновки	63
Перелік джерел посилання	65
Додаток А Відомість кваліфікаційної роботи	67

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

CoT – Chain-of-Thought – ланцюжок міркувань;

LLM – Large Language Models – велика мовна модель;

MDP – Markov Decision Process – марковський процес прийняття рішень;

MHA – Multi-Head Attention – багатоголова увага;

PPO – Proximal Policy Optimization – алгоритм проксимальної оптимізації політики;

RLAIF – Reinforcement Learning from AI Feedback – навчання з підкріпленням на основі зворотного зв'язку від ШІ;

RLHF – Reinforcement Learning from Human Feedback – навчання з підкріпленням на основі зворотного зв'язку від людини;

SFT – Supervised Fine-Tuning – кероване точне налаштування.

ВСТУП

Сучасний етап розвитку штучного інтелекту характеризується безпрецедентним масштабуванням генеративних мовних систем: великі мовні моделі, тобто Large Language Models (LLM), з'явилися у відкритому доступі, інтегруються у пошукові системи, засоби розробки програмного забезпечення, медичні інформаційні системи та інструменти освіти. Здатність цих систем генерувати зв'язний, переконливий текст на рівні людини відкриває колосальні можливості для автоматизації інтелектуальних задач – і водночас породжує принципово нову інженерну проблему, що не має аналогів в попередніх поколіннях програмного забезпечення. Модель, навчена передбачати наступний токен на основі мільярдів рядків тексту з мережі Інтернет, не набуває при цьому ані моральних орієнтирів, ані розуміння фактологічної точності, ані концепції безпеки. Вона є, по суті, статистичним дзеркалом людської культури – з усіма її упередженнями, дезінформацією та деструктивними патернами.

Ця суперечність між колосальними можливостями LLM та відсутністю у них вродженої орієнтації на цінності і безпеку людини породила цілий дослідницький напрям, відомий як вирівнювання, або Alignment. Мета вирівнювання – навчити модель бути не лише граматично правильною та когерентною, але й безпечною, чесною та корисною, а не просто переконливою.

Провідним методом промислового вирівнювання стало навчання з підкріпленням на основі зворотного зв'язку від людини, або Reinforcement Learning from Human Feedback (RLHF), що застосовується у таких системах, як GPT-4, Claude та Gemini. Проте масштабування цього підходу стикається з фундаментальними обмеженнями: залучення тисяч висококваліфікованих асесорів для ручної розмітки переваг є надзвичайно дорогим, повільним і схильним до суб'єктивних когнітивних викривлень. Зі зростанням

складності моделей та розширенням їхнього застосування ця криза масштабованості стає дедалі гострішою.

Вирішення цієї суперечності між необхідністю масштабованого вирівнювання та обмеженнями людської розмітки лежить у площині передачі функції оцінювача від людини до самого штучного інтелекту.

Підхід Reinforcement Learning from AI Feedback (RLAIF) пропонує використовувати передові LLM як автоматичних суддів, здатних оцінювати відповіді цільової моделі відповідно до формалізованих конституційних принципів. Такий підхід на порядки зменшує витрати та час на формування навчальних даних, дозволяє безперервно масштабувати процес вирівнювання та потенційно забезпечує більш консистентну та прозору розмітку завдяки підтримці ланцюжків міркувань.

При цьому методологія RLAIF залишається відносно молодого та недостатньо дослідженою стосовно конкретних архітектурних рішень, вибору параметрів та ефективності для малих відкритих моделей, що робить дослідження в цій галузі актуальним та практично затребуваним. Особливо важливим є питання того, наскільки ефективно AI-асесори здатні відтворювати людські уявлення про корисність, безпечність та етичність відповідей, а також чи можуть вони забезпечити стабільне вирівнювання моделей без втрати якості генерації.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ ТА ПОСТАНОВКА ЗАДАЧІ

1.1 Теоретичні основи вирівнювання великих мовних моделей

Великі мовні моделі, тобто LLM, за своєю архітектурною природою є складними стохастичними системами, базовим завданням яких є математична імітація природної мови на основі гігантських неструктурованих масивів даних. Сама по собі здатність штучної нейронної мережі генерувати зв'язний текст не гарантує його об'єктивної корисності, фактичної точності або відповідності нормам безпеки. Збіг між тим, як алгоритм формує відповідь, керуючись виключно статистичним розподілом токенів, та реальними намірами користувача вимагає побудови окремих механізмів синхронізації. Формування таких механізмів спирається на глибинне розуміння архітектурних вразливостей базових нейромереж та ретроспективний аналіз методологій оптимізації поведінки, які імплементуються на етапі післятренувального налаштування.

1.1.1 Проблема контролю штучного інтелекту в сучасних умовах

Сучасний етап розвитку інформаційних технологій характеризується експоненційним зростанням обчислювальних потужностей та ускладненням архітектур нейронних мереж, що призвело до появи LLM. Ці системи, побудовані переважно на базі архітектури трансформерів та механізмів уваги, здатні обробляти, аналізувати та генерувати тексти на рівні, який раніше вважався виключною прерогативою людського розуму. Проте разом із безпрецедентними можливостями виникла фундаментальна наукова та інженерна проблема вирівнювання цілей, що стосується складності забезпечення синхронізації поведінки штучного інтелекту з намірами та безпекою людини.

В основі цієї проблеми лежить базовий принцип навчання LLM [1]. На етапі попереднього тренування модель оптимізується для виконання єдиної статистичної задачі – передбачення наступного токена у величезних масивах неструктурованого тексту, зібраного з глобальної мережі. У результаті такого неконтрольованого навчання алгоритм засвоює не лише синтаксис, семантику та фактологічні знання, але й усі людські упередження, стереотипи, токсичність та деструктивні патерни поведінки, які існують у навчальній вибірці [2]. Базова модель є своєрідним статистичним дзеркалом Інтернету, вона не має вбудованого морального компаса, концепції правдивості чи розуміння контексту безпеки [3].

З теоретичної точки зору проблему контролю доцільно розділити на два фундаментальні та взаємопов'язані аспекти: зовнішнє вирівнювання та внутрішнє вирівнювання.

Зовнішнє вирівнювання стосується питання коректності та повноти постановки задачі самою людиною на етапі проєктування системи. Основна дилема полягає у наступному: чи дійсно цільова функція, функція винагороди або метрика успіху, яку розробники задають системі, повною мірою відображає наші справжні наміри та етичні норми. На практиці формалізувати складні, багатогранні та часто суперечливі людські цінності у вигляді чіткої математичної формули є надзвичайно складним завданням. Цей феномен у науковій літературі тісно переплітається із законом Гудхарта, згідно з яким будь-яка статистична закономірність або метрика, що стає ціллю для оптимізації, перестає бути надійною метрикою. Якщо системі задати спрощену ціль, вона знайде найкоротший алгоритмічний шлях до її досягнення, ігноруючи неписані правила етики. Це може призвести до алгоритмічного заохочення радикального, поляризуючого або шкідливого контенту [4].

Внутрішнє вирівнювання, своєю чергою, описує структурну вразливість, що виникає безпосередньо у процесі машинного навчання. Цей аспект характеризує ситуацію, коли задана цільова функція є абсолютно

коректною та безпечною, але нейронна мережа у процесі оптимізації формує власні, непередбачувані евристики або проміжні цілі – так звані межа-оптимізатори – для її досягнення. В умовах закритого тренувального середовища ці внутрішні стратегії можуть ідеально задовольняти головну функцію винагороди. Проте при розгортанні моделі у реальному світі, де виникає неминучий зсув розподілу даних, ці приховані цілі починають суперечити початковому задуму розробників, що призводить до неконтрольованої та потенційно деструктивної поведінки системи.

Логіку взаємозв'язку між фундаментальними алгоритмічними причинами проблеми вирівнювання демонструє схема (рисунок 1.1).




Рисунок 1.1 – Деревоподібна схема структури проблеми вирівнювання

У сучасних умовах масового розгортання генеративних систем у комерційних продуктах, пошукових алгоритмах та інструментах підтримки прийняття рішень така неконтрольованість створює низку критичних загроз для інформаційного простору. Найбільш розповсюдженим і важкокоригованим проявом відсутності належної оптимізації є феномен «галюцинацій» – впевненої генерації моделлю правдоподібної, але абсолютно хибної фактологічної інформації. Оскільки базова модель не має

доступу до зовнішньої бази істин та керується виключно ймовірнісним розподілом токенів у своєму латентному просторі, вона конструює текст, який лінгвістично виглядає бездоганно, але позбавлений семантичної правдивості. Наслідки таких галюцинацій є вкрай небезпечними у медичній, юридичній чи освітній сферах, де користувач може помилково спиратися на згенеровану дезінформацію як на достовірний експертний висновок.

Іншим критичним аспектом, який часто є побічним ефектом недосконалості сучасних методів зворотного зв'язку, є схильність базових систем до упередженості. Цей феномен полягає у тенденції штучного інтелекту генерувати відповіді, які безапеляційно підтверджують політичні, соціальні або наукові переконання користувача. Причиною цього є те, що на етапі тренування алгоритм вчиться максимізувати винагороду або схвалення. Оскільки алгоритм статистично «знає», що згода з промптом частіше призводить до позитивної оцінки, він засвоює цю маніпулятивну стратегію. Це концептуально нівелює цінність системи як об'єктивного аналітичного інструменту.

Крім того, надзвичайно серйозною проблемою залишається уразливість моделей до цілеспрямованих лінгвістичних маніпуляцій, таких як ін'єкції підказок, відомі як Prompt Injections, та навмисний обхід системних обмежень, тобто Jailbreak [5]. Ці атаки яскраво демонструють, що без глибокого структурного налаштування поверхневі бар'єри безпеки нейромережі можна легко обійти. Зловмисники створюють спеціально сконструйовані багаторівневі запити, які заплутують механізм уваги моделі та змушують її ігнорувати базові інструкції безпеки. У результаті система перемикається на виконання прихованих команд, що дозволяє генерувати інструкції зі створення небезпечних речовин, писати шкідливий програмний код або розповсюджувати деструктивний контент. Це переводить проблему вирівнювання з площини теоретичної етики у площину глобальної кібербезпеки.

1.1.2 Еволюція методів

Історичний розвиток методологій контролю та адаптації мовних моделей можна розглядати як безперервну боротьбу між масштабуванням обчислювальних потужностей та пошуком ефективних алгоритмічних обмежень. Ця еволюція відображає поступове усвідомлення науковою спільнотою того факту, що проблема безпеки штучного інтелекту не може бути вирішена виключно шляхом збільшення обсягів навчальних вибірок.

На ранніх етапах розвитку генеративних систем основні зусилля з вирівнювання були зосереджені на етапі попередньої обробки даних. Дослідники намагалися алгоритмічно очистити навчальні набори від токсичного контенту, використовуючи статичні словники заборонених слів та прості лінійні класифікатори тексту. Однак цей підхід виявився вкрай крихким та концептуально обмеженим. Природна мова володіє колосальною семантичною гнучкістю: токсичний зміст, дискримінаційні наративи або небезпечні інструкції можна сформулювати, використовуючи абсолютно нейтральну або навіть наукову лексику. Крім того, надмірна фільтрація навчальних даних призводила до явища «алігнмент-податку» – критичного зниження загальної компетентності моделі та її здатності розуміти складні контексти через штучне збіднення лексикону.

Наступним кроком стала інтеграція евристичних фільтрів на етапі генерації відповіді. До базової архітектури додавалися допоміжні модулі, які в режимі реального часу аналізували та блокували вихідний текст у разі виявлення порушень. Проте сама базова модель залишалася невирівняною: її потенційно небезпечні виходи просто штучно перекривалися на фінальному етапі інференсу, що робило систему надзвичайно вразливою до структурних лінгвістичних атак.

Справжній парадигмальний прорив відбувся з впровадженням методу керованого точного налаштування, відомого як Supervised Fine-Tuning (SFT). Концептуальна сутність цього підходу полягає у глибокому

поведінковому клонуванні. Базову модель донавчають на відносно невеликому, але еталонному наборі даних, який складається з тисяч високоякісних пар «запит – ідеальна відповідь». На цьому етапі SFT дозволяє трансформувати модель з простого статистичного генератора тексту на структурованого діалогового агента, здатного дотримуватися заданих форматів спілкування. Проте теоретично цей метод має суттєві обмеження. Створення таких експертних баз є надзвичайно дорогим і повільним процесом, а сама модель під час SFT не навчається абстрактним принципам безпеки або логічному міркуванню – вона лише статистично імітує стиль наданих прикладів. Як наслідок, якщо система стикається із нетиповим або маргінальним запитом, виникає явище зсуву розподілу, і модель швидко деградує до своєї первинної, неконтрольованої поведінки.

Для створення систем, які б могли фундаментально узагальнювати концепції безпеки та корисності на раніше невідомі ситуації, дослідники звернулися до математичного апарату теорії оптимального управління, а саме – до навчання з підкріпленням, тобто Reinforcement Learning (RL) [6]. У цій парадигмі генерація тексту формалізується як марковський процес прийняття рішень, або Markov Decision Process (MDP). Кожен згенерований токен розглядається як алгоритмічний крок, що впливає на фінальний стан системи.

Головна перевага переходу до формалізму RL полягає у можливості прямої оптимізації алгоритму за допомогою скалярного сигналу винагороди, що вирішує проблему розподілу відповідальності за успішність згенерованого тексту в цілому. Цей концептуальний перехід від сліпого поведінкового клонування до цілеспрямованої максимізації відкладеної винагороди став теоретичним фундаментом для всіх сучасних передових методів вирівнювання.

1.2 Аналіз існуючих підходів до вирівнювання моделей

Перехід від статичних текстових фільтрів до алгоритмів динамічної оптимізації поведінки ознаменував появу нових індустріальних стандартів у розробці безпечного AI. Найбільш розповсюдженим, теоретично обґрунтованим і практично доведеним механізмом сьогодні є безпосереднє залучення людини-експерта в замкнений цикл машинного навчання. Проте глобальне масштабування таких систем неминуче стикається з фундаментальними когнітивними обмеженнями людського сприйняття, фінансовими бар'єрами та критичними операційними затримками, що змушує індустрію інтенсивно шукати шляхи повної або часткової алгоритмізації процесу контролю.

1.2.1 Навчання на основі людського відгуку

Навчання з підкріпленням на основі людського відгуку, що широко відоме в науковій літературі як RLHF, концептуально інтегрує людські етичні та прагматичні переваги безпосередньо у функцію втрат нейромережі. Архітектурно цей складний ітеративний процес декомпонується на три ізольовані етапи: попереднє використання SFT для ініціалізації політики, тренування окремої моделі винагороди, або Reward Model, та фінальна оптимізація мовної політики за допомогою алгоритму проксимальної оптимізації політики, тобто Proximal Policy Optimization (PPO).

На етапі тренування Reward Model формується багатовимірний безперервний простір преференцій. Асесорам-людям демонструється один вхідний промпт та кілька альтернативних згенерованих відповідей, які вони мають об'єктивно відранжувати. Цей процес дозволяє перевести якісні людські судження у кількісні метрики. Отримані дані ранжування за допомогою математичної моделі Бредлі-Террі трансформуються у

скалярний сигнал, що дозволяє окремій нейромережі-оцінювачу апроксимувати людську логіку прийняття рішень. На фінальному етапі алгоритм PPO динамічно оновлює ваги базової генеративної моделі у напрямку градієнта, який максимізує очікувану винагороду. Для запобігання семантичній деградації мови та збереження інформативності в цільову функцію обов'язково вводиться спеціальний статистичний штраф за дивергенцію Кульбака-Лейблера, який жорстко не дозволяє вирівняній моделі занадто радикально відхилитися від свого початкового латентного розподілу tokenів (рисунк 1.2).




Рисунок 1.2 – Етап PPO в процесі RLHF

Незважаючи на поточний статус галузевого стандарту, парадигма RLHF містить глибокі алгоритмічні та теоретичні обмеження. Найбільшою системною вразливістю є феномен злому винагороди, або Reward Hacking [7]. Оскільки Reward Model є лише нейромережевою апроксимацією реальних людських цінностей, алгоритм оптимізації PPO надзвичайно ефективно знаходить її латентні вразливості та починає їх цілеспрямовано експлуатувати. У результаті базова модель часто вчиться генерувати маніпулятивні, пишномовні або надмірно довгі відповіді, які гарантовано отримують високі оцінки від Reward Model, але є змістовно порожніми або марними для кінцевого користувача.

1.2.2 Передумови переходу до автоматизованих систем оцінювання

Фундаментальною перепоною для подальшого розвитку парадигми RLHF є глибока криза масштабованості нагляду [8]. Зі стрімким експоненційним зростанням структурної складності генеративних моделей об'єктивна оцінка їхніх відповідей вимагає від асесора профільної експертизи академічного рівня. Знайти десятки тисяч висококваліфікованих експертів для ручної та безперебійної розмітки спеціалізованих масивів даних є економічно невиправданим та організаційно неможливим завданням навіть для провідних дослідницьких інститутів.

Крім того, ручна людська розмітка має надзвичайно високу внутрішню дисперсію та схильність до когнітивних викривлень. Суб'єктивність сприйняття, втрата концентрації при обробці великих обсягів тексту та різний культурний бекграунд призводять до того, що різні люди дають діаметрально протилежні оцінки одним і тим самим відповідям. Цей неминучий інтер-асесорський шум критично погіршує якість функції втрат Reward Model, змушуючи систему засвоювати усереднену, суперечливу та посередню поведінку.

Вирішення цієї фундаментальної інженерної кризи лежить у площині переходу до концепції повністю масштабованого алгоритмічного нагляду. Концепція делегування повноважень оцінювання від людини до машини формується навколо сильної теоретичної гіпотези: якщо існуючі передові моделі здатні генерувати текст експертного рівня та демонструють ознаки нульового логічного висновку, їхніх аналітичних здібностей повинно вистачити для критичного ранжування виходів інших систем. Теоретичний аналіз стабільності сигналу оцінювання беззаперечно підтверджує системні переваги такого підходу в умовах роботи з великими даними.

Автоматизовані системи принципово не схильні до втоми, не мають обмежень щодо пропускну здатності і здатні генерувати деталізовані алгоритмічні ланцюжки міркувань, відомі як Chain-of-Thought, для

прозорого обґрунтування кожної виставленої оцінки. Саме ці критичні фактори зумовили еволюційний перехід індустрії до дослідження нових методологій, які повністю або частково виключають людину-оператора з безперервного циклу зворотного зв'язку.

1.3 Дослідження методології навчання на основі зворотного зв'язку від AI

Системне розв'язання кризи масштабованості та мінімізація руйнівного інтер-асесорського шуму вимагають глибинного парадигмального зсуву в самій методології вирівнювання моделей. Використання потужних мовних моделей як універсальних, незалежних систем оцінювання формує новий революційний дослідницький напрям, що отримав назву навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту RLAIIF. Цей теоретично обґрунтований підхід дозволяє на порядки пришвидшити ітераційні цикли оптимізації поведінки нейромереж та радикально знизити їхню фінансову вартість, зберігаючи при цьому високий, а іноді й вищий рівень якості кінцевого продукту без прямого залучення людського ресурсу.

1.3.1 Концептуальні основи RLAIIF

Концептуальна та філософська основа методології RLAIIF полягає у повній заміні людини-експерта на етапі створення масивів розмітки даних високопродуктивною нейромережею, яка виконує роль об'єктивної моделі-оцінювача. Цій моделі делегується надзвичайно складне завдання семантичного аналізу, фактологічної перевірки та фінального ранжування відповідей базової системи згідно із заздалегідь визначеним набором строгих формальних правил. Сукупність цих етичних та структурних

правил формує так звану конституцію штучного інтелекту, яка інтегрується в систему-оцінювач через спеціалізований системний запит.

На теоретичному рівні архітектура процесу генерації набору преференцій повністю відтворює логіку класичного підходу RLHF, але стратегічно усуває вузьке інформаційне місце людського фактора. Розгляд цієї архітектури доцільно проводити через призму алгоритмічної трансформації даних. Процес автоматизовано розпочинається з генерації базовою моделлю множини альтернативних текстових відповідей на один складний вхідний промпт. Замість тривалої передачі цих текстів живим асесорам, вони миттєво та попарно подаються на вхід оцінювачу. При цьому алгоритм оцінювача не обмежується простим бінарним вибором або скалярною оцінкою. Від нього програмно вимагається попередньо згенерувати структурований ланцюжок міркувань, відомий як Chain-of-Thought (CoT). У цьому логічному ланцюжку нейромережа повинна покроково обґрунтувати, чому одна відповідь є семантично або етично кращою за іншу, спираючись виключно на конкретні пункти закладеної конституції.

Згенеровані текстові висновки та аргументації автоматично алгоритмічно трансформуються у числові ймовірності. Цей стабільний скалярний сигнал згодом слугує надійною математичною базою для навчання моделі винагороди, яка вже безпосередньо керує процесом оновлення синаптичних ваг базової генеративної моделі за допомогою стандартних алгоритмів оптимізації політики.

Ключовою теоретичною та експлуатаційною перевагою такої опосередкованої архітектури є абсолютна алгоритмічна прозорість та гнучка керованість критеріїв оцінювання. Якщо в процесі експлуатації або тестування виявляється нагальна необхідність зміни поведінкових норм моделі (наприклад, для адаптації під нове законодавство щодо захисту даних), розробнику не потрібно витратити місяці на перенавчання штату асесорів або формування нових інструкцій для ручної розмітки сотень тисяч

прикладів. Достатньо лише внести корективи у текст базової конституції, що практично миттєво та алгоритмічно безпомилково рекалібрує весь подальший цикл автоматичної генерації штучного зворотного зв'язку.

1.3.2 Аналіз наукових поглядів та тенденцій щодо ефективності методу RLAIIF

Глибокий аналіз сучасних наукових публікацій та препринтів демонструє стійку тенденцію до беззаперечного визнання автоматизованого нагляду єдиною життєздатною та глобально масштабованою альтернативою класичним антропоцентричним методам. Сучасні емпіричні дослідження переконливо підтверджують, що генеративні моделі, оптимізовані виключно за допомогою штучного зворотного зв'язку, здатні впевнено досягати статистичного паритету з системами, вирівняними тисячами людей, за такими ключовими метриками як безпека генерації, відсутність токсичності, зниження упередженості та загальна інформативність тексту [9]. Наукова спільнота сьогодні одностайно виділяє три головні стратегічні переваги цього інноваційного методу: нульову маргінальну вартість безперервної генерації нових наборів преференцій, практично необмежену та миттєву масштабованість інфраструктури оцінювання та унікальну здатність системи ефективно аналізувати вузькоспеціалізовані наукові, математичні чи технічні тексти, які виходять за межі загальної компетенції середньостатистичного працівника.

Попри очевидні та доведені концептуальні переваги, практичне впровадження автоматизованого зворотного зв'язку тісно супроводжується специфічними теоретичними ризиками, які наразі є предметом гострих та відкритих наукових дискусій. Найбільш проблемним та найменш дослідженим питанням є феномен системної упередженості оцінювача, тобто Evaluator Bias (або AI-Sycophancy). Оскільки велика мовна модель, що безпосередньо виконує роль об'єктивного судді, сама є алгоритмічною

нейромережею зі своїми власними прихованими архітектурними дефектами та статистичними зсувами, існує надзвичайно висока ймовірність того, що вона алгоритмічно заохочуватиме та закріплюватиме власні помилки [10]. Наприклад, AI-оцінювачі часто демонструють надмірну прихильність до довгих, формально структурованих текстів, ігноруючи їхню фактичну порожнечу. Цей процес без належного зовнішнього контролю може швидко призвести до синергетичної деградації всього контуру зворотного зв'язку: базова модель блискавично навчається ідеально експлуатувати ці вразливості оцінювача, масово генеруючи контент, який легко отримує максимальний бал під час автоматичного оцінювання, але є фактологічно хибним або марним у реальному світі.

Додатковим концептуальним викликом, який глибоко розглядається в сучасній теорії машинного навчання, є проблема мовного колапсу або незворотної втрати семантичної різноманітності. Якщо одна й та сама структурна модельна архітектура або сімейство моделей одночасно використовується як для генерації первинних відповідей, так і для їхнього критичного оцінювання, система в замкненому циклі може швидко втратити лінгвістичну варіативність, зводячи всі результати оптимізації до єдиного, алгоритмічно найбільш безпечного, банального та усередненого статистичного шаблону.

Ці виявлені теоретичні ризики та архітектурні вразливості сьогодні активно формують найактуальніший вектор подальших фундаментальних досліджень у галузі штучного інтелекту. Сучасні індустріальні тенденції чітко вказують на гостру необхідність розробки складних гібридних підходів, створення гетерогенних ансамблевих методів оцінювання та впровадження інноваційних архітектур багатоагентних дебатів для надійної перехресної валідації згенерованих штучних преференцій, що в перспективі дозволить повністю нівелювати слабкі сторони та сліпі зони єдиної моделі-оцінювача.

1.4 Постановка задачі

Проведений теоретичний аналіз архітектурних особливостей та еволюції методів вирівнювання мовних моделей переконливо доводить, що індустрія перебуває на етапі критичної алгоритмічної трансформації. Перехід від людиноцентричних методів нагляду до повністю автоматизованих систем генерування преференцій є не просто економічною необхідністю, а фундаментальною умовою для подальшого безпечного масштабування генеративних технологій. З огляду на виявлені теоретичні обмеження існуючих підходів, зокрема феномени інтер-асесорського шуму та упередженості єдиного алгоритмічного оцінювача, виникає об'єктивна наукова потреба у формалізації та системному розв'язанні задачі оптимізації процесу штучного вирівнювання.

1.4.1 Обґрунтування актуальності

Актуальність обраної теми дипломного дослідження зумовлена глибоким алгоритмічним протиріччям між стрімким експоненційним зростанням складності генеративних моделей та фізичною неможливістю забезпечити їхній своєчасний, об'єктивний та масштабований контроль силами експертів-людей. Традиційний процес вирівнювання за допомогою RLHF вимагає колосальних фінансових та часових витрат на ручну розмітку наборів даних. Крім того, під час оцінювання складних багатовимірних або вузькоспеціалізованих текстів людина-асесор часто припускається логічних та семантичних помилок, що призводить до формування дефектної функції винагороди.

У цьому контексті методологія RLAIIF виступає як найбільш інноваційний та перспективний напрямок розвитку архітектур безпеки штучного інтелекту. Проте на сьогодні залишається відкритою та недостатньо вивченою фундаментальна проблема алгоритмічної

стабільності самого AI-оцінювача. Застосування базових алгоритмів автоматичної розмітки без належного контролю часто призводить до явища синергетичної деградації, коли система-суддя починає системно завищувати оцінки за багатослівність або імітацію впевненості, ігноруючи при цьому фактичну достовірність та логічну цілісність згенерованого тексту.

Таким чином, розробка вдосконалених, стійких до маніпуляцій методів формування конституційних правил та побудова надійного архітектурного пайплайну генерації AI-оцінок є надзвичайно актуальною науково-практичною задачею. Її розв'язання дозволить зробити процес вирівнювання моделей на порядки швидшим, дешевшим та алгоритмічно надійнішим, що є критично важливим завданням для незалежних дослідників та відкритої спільноти розробників, які проектують локальні моделі без доступу до корпоративних штатів асесорів.

1.4.2 Формулювання мети, предмета та основних завдань роботи

Зважаючи на виявлені теоретичні проблеми та обґрунтовану актуальність, метою магістерської роботи є підвищення точності, безпеки й фактичної достовірності генерації тексту у великих мовних моделях шляхом дослідження, розробки та програмної реалізації оптимізованого алгоритмічного пайплайну навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту.

Об'єктом дослідження є процес алгоритмічного вирівнювання та оптимізації поведінки генеративних нейронних мереж в умовах відсутності ручного зворотного зв'язку.

Для досягнення поставленої мети було визначено та формалізовано наступний комплекс взаємопов'язаних завдань:

- виконати поглиблений системний аналіз сучасних архітектурних рішень у сфері вирівнювання мовних моделей;

- розробити та формалізувати багатокритеріальну текстову «конституцію» для моделі-оцінювача, яка дозволить алгоритмічно вимірювати не лише стилістичну якість тексту, але й фактологічну точність та відсутність прихованих когнітивних упереджень;

- спроектувати та програмно реалізувати пайплайн для автоматичної генерації набору даних переваг, використовуючи передову мовну модель-експерта для попарного оцінювання виходів цільової генеративної моделі;

- провести експериментальне навчання локальної моделі винагороди виключно на основі згенерованих AI-преференцій, застосовуючи функцію втрат ранжування;

- впровадити навчену модель винагороди у цикл алгоритму PPO для виконання фінального вирівнювання базової моделі;

- виконати комплексну порівняльну оцінку результатів роботи навченої моделі з використанням стандартизованих метрик безпеки та корисності, зіставивши її показники з контрольною базовою моделлю.

Реалізація цього комплексу завдань дозволить не лише теоретично обґрунтувати переваги методу RLAIIF, але й доказати що метод є повністю відтворюваним, економічно ефективним для безпечного вирівнювання мовних моделей.

2 ТЕОРЕТИЧНІ ОСНОВИ МЕТОДУ RLAIF

Теоретичний аналіз, проведений у першому розділі, дозволив обґрунтувати вибір методології навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту, тобто RLAIF, як дослідницького напрямку цієї роботи та підтвердив її здатність вирішити ключові проблеми масштабованості класичного підходу RLHF. Завдання другого розділу – сформулювати повноцінну теоретичну базу, на якій будуватиметься як програмна реалізація пайплайну, так і подальша інтерпретація отриманих результатів. В рамках розділу буде розглянуто архітектуру трансформерних моделей як об'єктів вирівнювання, теоретичні засади кожного з чотирьох етапів запланованого пайплайну – формування набору преференцій, навчання моделі винагороди, оптимізації політики та комплексного оцінювання – а також детально обґрунтовано вибір конкретних алгоритмічних рішень.

2.1 Архітектурні основи трансформерних мовних моделей як об'єктів вирівнювання

2.1.1 Декодерна архітектура та механізм масштабованої самоуваги

Перш ніж розглядати методи вирівнювання, необхідно чітко усвідомити, яким саме чином генеративна мовна модель формує відповіді на архітектурному рівні – оскільки саме ця природа визначає як можливості вирівнювання, так і його обмеження. Базовою архітектурою для сучасних великих мовних моделей є декодерний трансформер [11]. Саме ця архітектура лежить в основі переважної більшості сучасних систем: GPT, LLaMA, Qwen та інших.

Принципова відмінність трансформера від попередніх рекурентних архітектур (LSTM, GRU) полягає у повній відмові від послідовної обробки

токенів: трансформер опрацьовує всю послідовність одночасно, завдяки механізму самоуваги. Цей механізм дозволяє кожному токenu «бачити» та враховувати вплив усіх інших токенів вхідного контексту, незалежно від відстані між ними. З лінгвістичної точки зору це означає, що модель може коректно відстежувати анафору, вловлювати складні семантичні залежності та утримувати цілісний контекст навіть у дуже довгих текстах.

Сучасні LLM використовують Multi-Head Attention (МНА) – паралельний запуск кількох незалежних «голів» уваги, кожна з яких спеціалізується на виявленні свого типу залежностей: одна – синтаксичних, інша – семантичних, третя – анафоричних тощо. Виходи всіх голів конкатенуються та проєктуються у спільний простір прихованих представлень.

Повна декодерна модель є вертикальним стеком ідентичних блоків, кожен з яких містить (рисунок 2.1):

- механізм Multi-Head Self-Attention з каузальною маскою (модель не бачить майбутніх токенів – лише поточний та попередні);
- залишкове з'єднання та нормалізацію шарів;
- позиційно-незалежну нейронну мережу прямого поширення (Feed-Forward Network);
- залишкове з'єднання та нормалізацію.

Каузальна маска є принциповою: саме завдяки їй декодерний трансформер придатний для авторегресійної генерації – модель ніколи не «підглядає» у майбутнє і генерує кожен токен, спираючись виключно на вже створений контекст.

Важливою концептуальною властивістю трансформерів є здатність до масштабування: збільшення кількості шарів, числа голів уваги та розмірності прихованого простору стабільно покращує якість моделі без зміни базової архітектури. Саме ця властивість зумовила стрімке зростання розмірів LLM від сотень мільйонів до сотень мільярдів параметрів протягом останніх кількох років [12].




Рисунок 2.1 – Декодерна трансформерна архітектура

2.1.2 Авторегресійна генерація та стохастичне семплювання

Принцип авторегресійної генерації полягає у тому, що модель породжує вихідну послідовність токен за токеном: на кожному кроці вона отримує на вхід весь попередній контекст та передбачає розподіл ймовірностей над словником для наступного токена. Новий токен додається до контексту, і процес повторюється до появи спеціального символу кінця послідовності або досягнення максимальної довжини.

З точки зору математики генерація є покроковою факторизацією спільного розподілу над усією послідовністю: ймовірність цілої відповіді дорівнює добутку умовних ймовірностей кожного токена за всіма попередніми. Саме цей принцип обумовлює одну з ключових інженерних складностей вирівнювання: нагорода від Reward Model надається лише за всю завершену відповідь, тоді як відповідь складається з десятків чи сотень кроків генерації, кожен з яких залежить від усіх попередніх. Задача «пояснити» кожному конкретному кроку, наскільки він сприяв або зашкодив фінальній якості відповіді, є математично нетривіальною і відома у теорії навчання з підкріпленням як проблема розподілу відповідальності.

Не менш важливим теоретичним аспектом є контроль параметрів стохастичного семплювання. На чисто семплювати з вихідного розподілу моделі неоптимально: надто низька варіативність позбавляє preference dataset різноманітності – дві відповіді будуть майже ідентичними, і AI-суддя не зможе знайти між ними принципову різницю. Надто висока варіативність призводить до лінгвістично некоректних або беззмістовних виходів.

Температурне масштабування вирішує цю проблему: перед передачею логітів у функцію softmax їх ділять на параметр температури. При температурі менше одного розподіл «загострюється» – модель стає детермінованішою при температурі більше одного – «вирівнюється». Практика показує, що значення температури приблизно 0.7 є оптимальним для генерації пар preference dataset: відповіді залишаються зв'язними та граматично коректними, але при цьому достатньо різноманітними для осмисленого порівняння [13].

Nucleus sampling (top-p) є додатковим механізмом, що відсікає «хвіст» розподілу – токени з дуже низькою ймовірністю, які є або рідкісними, або граматично неможливими у цьому контексті. При значенні $p = 0.9$ відбирається найменша множина найбільш ймовірних токенів, сукупна ймовірність яких перевищує 90%. Це запобігає появі випадкових абсурдних токенів навіть за помірно розм'якшеної температури.

2.2 Формалізація задачі вирівнювання як задачі оптимального управління

2.2.1 Вирівнювання у рамках марковського процесу прийняття рішень

Одним із фундаментальних теоретичних внесків, що відрізняє сучасні методи вирівнювання від простого дообучання, є формалізація задачі в рамках математичного апарату теорії оптимального управління. Такий підхід дозволяє застосувати цілий набір алгоритмів навчання з підкріпленням та обґрунтувати коректність оптимізаційної процедури.

Генерація тексту природно моделюється як марковський процес прийняття рішень – стандартна математична структура для послідовних задач прийняття рішень [14]. Стан системи у кожен момент часу – це весь накопичений контекст: промпт плюс усі вже згенеровані токени. Дія агента – вибір наступного токена зі словника. Функція переходів є детермінованою: новий стан – це попередній стан, доповнений обраним токеном. Нагорода надається наприкінці послідовності Reward Model і відображає якість всієї згенерованої відповіді.

Марковська властивість, що вимагає незалежності майбутнього від минулого за умови знання поточного стану, виконується тривіально: обчислення наступного токена залежить виключно від поточного контексту, а не від послідовності кроків, якими цей контекст був досягнутий. Ця властивість є ключовою – вона дозволяє застосовувати функції цінності для декомпозиції задачі на підзадачі та ефективного обчислення градієнтів.

Принципова відмінність задачі вирівнювання від класичних задач RL (ігри, роботи) полягає у кількох моментах:

- простір дій є дискретним словником – значно більшим, ніж у більшості RL-задач;
- нагорода є виключно термінальною, лише наприкінці послідовності, що ускладнює кредитне присвоєння;

– функція нагороди сама є нейронною мережею, що вносить власний шум та можливість «злому» (reward hacking).

Розуміння цих особливостей є необхідним для коректної інтерпретації теоретичних гарантій та практичних обмежень методу.

2.2.2 Цільова функція вирівнювання та KL-регуляризація

Маючи MDP-формалізацію, можна точно описати, що саме оптимізується у процесі вирівнювання. Задача полягає у пошуку таких параметрів мовної моделі, щоб вона генерувала відповіді з максимально можливою якістю за оцінкою Reward Model – але при цьому не відходила занадто далеко від своєї початкової поведінки. Друга умова є критично важливою: модель, що лише максимізує нагороду без обмежень, швидко деградує до генерації беззмістовних або маніпулятивних відповідей, які «обманюють» оцінювача, але не несуть жодної цінності для реального користувача.

Ця рівновага між максимізацією нагороди та збереженням «мовної ідентичності» формально описується через дивергенцію Кульбака-Лейблера, або Kullback-Leibler Divergence (KL). KL-дивергенція вимірює, наскільки сильно поточний розподіл вирівняної моделі відхилився від розподілу початкової («замороженої») базової моделі. Вона завжди невід'ємна та дорівнює нулю лише тоді, коли обидва розподіли є ідентичними.

Комбінована цільова функція вирівнювання 2.1, яку планується максимізувати.

$$J(\theta) = E[r(x, y)] - \beta * KL[\pi_{\theta}(y | x) || \pi_{ref}(y | x)], \quad (2.1)$$

де $r(x, y)$ – скалярна оцінка якості відповіді y на промпт x від Reward Model;

β – коефіцієнт, що регулює баланс між нагородою та відхиленням від базової моделі (що більше β , то консервативніше вирівнювання);

$\pi_{\theta}(y | x)$ – вирівнювана модель з поточними параметрами θ ;

$\pi_{ref}(y | x)$ – незмінна базова референсна модель.

Ця двокомпонентна структура цільової функції є теоретичним обґрунтуванням всього RLAIIF-підходу: вирівнювання – це не заміна моделі на іншу, а контрольоване відхилення від початкової поведінки у напрямку конституційних принципів.

2.3 Автоматична генерація набору преференцій

2.3.1 Принципи попарного ранжування

Preference dataset є фундаментом, на якому тримається весь RLAIIF-пайплайн: від його якості та репрезентативності залежить адекватність Reward Model, а отже, і ефективність усього подальшого вирівнювання. Кожен запис у цьому датасеті являє собою трійку: вхідний промпт, «краща» відповідь (chosen) та «гірша» відповідь (rejected). Задача цього етапу – автоматично сформувати тисячі таких трійок без залучення людей-асесорів.

Концептуальна основа підходу полягає у наступному спостереженні: навіть невіривняна базова модель генерує відповіді різної якості залежно від стохастичного семплювання. Якщо на один і той самий промпт запустити генерацію двічі – з різними випадковими «зернами», – отримуються дві відповіді, між якими майже завжди існує певна відмінність у якості, безпеці чи фактологічній точності. Завдання AI-судді – систематично ідентифікувати та фіксувати ці відмінності.

Надзвичайно важливою теоретичною вимогою є різноманітність відповідей у парах. Якщо обидві відповіді фактично ідентичні (відрізняються лише парою синонімів), вони несуть нульовий навчальний сигнал для Reward Model: модель не може навчитися чому

chosen кращий, якщо різниці між ними немає. Тому параметри семплювання (температура $\tau = 0.7$, top-p = 0.9) налаштовуються таким чином, щоб забезпечити достатню різноманітність при збереженні базової якості тексту [15].

Принципово важливою є також гетерогенність системи: AI-суддя – це модель іншої архітектурної сім'ї (GPT-4o-mini), ніж модель-генератор відповідей (Qwen2.5). Це навмисне рішення, що усуває ефект «ехо-камери»: якби та сама модель оцінювала власні виходи, вона систематично надавала б перевагу відповідям, що відповідають її власним архітектурним упередженням, закріплюючи їх у замкненому циклі (рисунок 2.2). Залучення зовнішнього оцінювача, що має власну незалежну архітектуру та тренувальну історію, суттєво підвищує об'єктивність розмітки.




Рисунок 2.2 – Пайплайн формування preference dataset

2.3.2 Конституція штучного інтелекту та Chain-of-Thought оцінювання

Конституція штучного інтелекту – поняття, введене дослідниками Anthropic у рамках підходу Constitutional AI– є формалізованим набором

принципів, що задають AI-судді чіткі багатовимірні критерії якості відповідей. На відміну від простого бінарного правила «безпечно / небезпечно», розвинута конституція охоплює кілька незалежних вимірів: безпеку та відмову від генерації шкідливого контенту, фактологічну точність, корисність та повноту відповіді на запит користувача, нейтральність і відсутність стереотипних суджень, а також стилістичну адекватність тону та формату відповіді.

Конституція інтегрується у систему через системний промпт AI-судді – спеціальний інструкційний блок, який задається на початку кожного запиту до моделі-оцінювача. Такий спосіб «прошивки» поведінкових норм є надзвичайно гнучким: будь-яке коригування конституційних принципів (наприклад, для адаптації під нові законодавчі вимоги або нову предметну область) автоматично рекалібрує весь подальший цикл генерації оцінок без жодних додаткових обчислювальних витрат. Це принципово вигідно порівняно з підходом RLHF, де аналогічні зміни потребують перенавчання штату асесорів та повного перезбору навчальних даних.

Поряд із конституцією, другим ключовим елементом якісного оцінювання є технологія CoT, вперше систематизована. Суть підходу полягає в тому, що перед винесенням фінального вердикту AI-суддя генерує детальну «чернетку» аналізу: покроково розглядає кожну відповідь через призму кожного конституційного принципу, виявляє сильні та слабкі сторони, фіксує суперечності та лише після цього формулює обґрунтований висновок.

Доведено, що CoT-оцінювання значно підвищує як точність, так і узгодженість вердиктів моделі [16]. Причина цього полягає у принциповому обмеженні одноетапного виведення: коли модель «змушена» спочатку міркувати, а потім відповідати – а не відповідати одразу – вона задіює більш глибокі механізми обробки контексту і з набагато меншою ймовірністю видає поверхнево-маніпулятивний або упереджений вердикт. Саме тому у запланованій реалізації системний промпт AI-судді вимагатиме

структурованого CoT-обґрунтування як обов'язкової умови перед фінальним рядком вердикту.




Рисунок 2.3 – Схема Chain-of-Thought оцінювання

2.4 Теоретичні засади навчання Reward Model

2.4.1 Статистична модель Бредлі-Террі для попарного ранжування

Сформований preference dataset містить тисячі трійок із вердиктами AI-судді. Наступна задача – навчити окрему нейромережу, Reward Model (RM), апроксимувати логіку цих вердиктів таким чином, щоб вона могла оцінювати довільну пару «промпт + відповідь» у режимі реального часу, без звернення до дорогого API GPT. Ця модель ставатиме «сурогатним суддею» впродовж всього PPO-тренування.

Теоретичним фундаментом для навчання RM на даних попарного порівняння є класична статистична модель Бредлі-Террі, запропонована у 1952 році [17]. Ця модель відповідає на просте, але принципове питання: якщо ми спостерігаємо результати попарних «змагань» між об'єктами (у нашому випадку – відповідями), як відновити їхні приховані «сили» чи «якості». Бредлі-Террі стверджує, що ймовірність перемоги однієї відповіді над другою зростає монотонно зі збільшенням різниці між їхніми прихованими якісними оцінками, і навчається передбачати Reward Model за формулою:

$$P(y_c \text{ краща за } y_r | x) = \sigma(r(x, y_c) - r(x, y_r)), \quad (2.2)$$

де σ – логістична (сигмоїдна) функція;

$r(x, y)$ – скалярна оцінка якості відповіді y на промпт x , яку навчається передбачати Reward Model;

$y_c > y_r$ – факт того, що AI-суддя обрав y_c як кращу відповідь.

Ключова перевага моделі Бредлі-Террі полягає у тому, що вона перетворює якісне судження («А краще за В») на кількісну диференційовну ціль навчання.

Це дозволяє нативно використовувати методи стохастичного градієнтного спуску без жодної додаткової апроксимації.

2.4.2 Функція ранжувальних втрат та архітектура нейромережевого оцінювача

Зі статистичної моделі Бредлі-Террі безпосередньо впливає функція втрат для навчання Reward Model.

Необхідно максимізувати логарифмічне правдоподібність усіх спостережуваних вердиктів судді штучного інтелекту.

Це еквівалентно мінімізації наступної функції ранжувальних втрат:

$$L_{RM} = -E[\log \sigma(r(x, y_c) - r(x, y_r) - m)], \quad (2.3)$$

де m – margin, мінімальна бажана різниця між оцінками *chosen* та *rejected*;

E – математичне сподівання по всьому preference dataset.

Параметр margin $m > 0$ є принципово важливим інженерним рішенням, не завжди висвітленим у базових описах підходу. Без margin функція втрат задовольняється вже тоді, коли $r(y_c)$ перевищує $r(y_r)$ на нескінченно мале значення – що не забезпечує жодного корисного «зазору» при інференсі. Margin $m = 0.1$ вимагає, щоб кожна «краща» відповідь отримувала оцінку хоча б на 0.1 більшу, ніж «гірша» – аналогічно принципу максимального зазору в метод опорних векторів. Це підвищує узагальнювальну здатність моделі та її стійкість до пограничних прикладів.

Архітектурно Reward Model будуватиметься поверх тієї ж базової трансформерної архітектури Qwen2.5-0.5B, до якої додається лінійна проєкційна голівка: один повнозв'язний шар без функції активації, що перетворює приховане представлення останнього токена послідовності у скалярну оцінку. Така архітектура має кілька наступних переваг:

- вона ефективно використовує вже навчені мовні представлення базової моделі;
- значно скорочує обсяг навчальних даних, необхідних для якісної апроксимації – RM лише «доучується» на preference dataset замість навчання з нуля;
- зберігає ту ж токенизацію та словник, що і базова модель, що спрощує інтеграцію у PPO-пайплайн.

Процес навчання RM має два режими моніторингу. Першочерговий – валідаційна точність (ассурасу): частка пар у валідаційній вибірці, де RM правильно визначила *chosen* > *rejected*. Ідеальна точність дорівнює 1.0. Практично досяжна для моделей такого масштабу – 0.70–0.85 залежно від

складності preference dataset. Другорядний – динаміка loss: монотонне зниження свідчить про коректне навчання без переобучання.

2.5 Алгоритм проксимальної оптимізації політики для вирівнювання

2.5.1 Теоретичні основи PPO та структура актор-критик

Маючи навчену Reward Model, що вміє оцінювати якість довільної відповіді без звернення до зовнішнього API, можна закрити контур зворотного зв'язку та безпосередньо оновити ваги генеративної моделі у напрямку підвищення якості. Для цього планується використання алгоритму проксимальної оптимізації політики, розробленого дослідниками OpenAI у 2017 році.

PPO виник як практична відповідь на фундаментальну проблему прямого градієнтного навчання у задачах оптимізації нагороди. Наївна стратегія – робити крок градієнтного піднесення у напрямку зростання нагороди – надзвичайно нестабільна: якщо один крок виявляється занадто великим, він може «перевернути» поведінку моделі так радикально, що жоден наступний крок вже не зможе повернути її на правильний шлях. Процес навчання стає хаотичним, нагорода різко коливається, а частина набутих знань незворотно руйнується.

PPO належить до архітектурного класу Actor-Critic, що принципово відрізняється від однокомпонентних підходів. Актор – це власне мовна модель, яку необхідно вирівняти: вона приймає рішення (генерує токени) та оновлює свої параметри на основі отриманого сигналу. Критик – це допоміжна неймережа, яка для кожного поточного стану генерації (тобто поточного контексту) передбачає очікувану сумарну майбутню нагороду. Взаємодія між актором та критиком утворює принципово важливу концепцію advantage: наскільки дія актора на конкретному кроці виявилась кращою або гіршою за середньоочікувану оцінку критика. Саме перевага, а

не абсолютне значення нагороди, є безпосереднім сигналом для оновлення актора. Це підвищує якість навчання та знижує дисперсію оцінок.

Ще одним важливим елементом PPO є стратегія importance sampling. Замість того, щоб після кожного кроку взаємодії із середовищем оновлювати модель лише один раз і викидати зібрані дані, PPO виконує кілька ітерацій оновлення на одному і тому ж пакеті прикладів. Це суттєво підвищує ефективність використання «дорогих» даних, отриманих від генеративної моделі. Для врахування того, що після першого оновлення параметри моделі вже змінились, вводиться так зване відношення ймовірностей: співвідношення між поточною та минулою ймовірностями кожного токена.

2.5.2 Кліпована сурогатна функція як механізм стабілізації навчання

Ключовим алгоритмічним внеском PPO є кліпована сурогатна цільова функція, що апроксимує, але структурно обмежує, розмір кроку оновлення.

Як тільки поточна модель надає цій дії більш ніж на 20% вищу ймовірність, ніж стара – кліпування «вимикає» градієнт і оновлення зупиняється. Якщо ж дія виявилась поганою, аналогічне кліпування спрацьовує, запобігаючи занадто різкому зниженню ймовірності. В обох напрямках алгоритм гарантує, що жоден крок оновлення не змінить модель надто радикально – і процес навчання залишається стабільним навіть при відносно великих темпах навчання.

Ця стабільність є принципово важливою саме у контексті вирівнювання LLM, де катастрофічне забування є постійним ризиком: без кліпування кілька успішних кроків у бік безпеки можуть повністю перезаписати мовні компетенції, набуті під час передтренування. PPO у поєднанні з KL-штрафом у цільовій функції утворює двошаровий механізм захисту від цього ризику.

2.6 Методологія комплексного оцінювання вирівняної моделі

2.6.1 Багатовимірна система метрик якості та безпеки

Оцінювання ефективності вирівнювання є концептуально складнішим завданням, ніж може здаватись на перший погляд. Проста перевірка «чи стала модель безпечнішою» є недостатньою: необхідно переконатись, що покращення безпеки не відбулось за рахунок корисності, що фактологічна точність не деградувала, а відповіді не набули стереотипного характеру.

Для проведення об'єктивної комплексної оцінки буде використовуватись чотирикомпонентна система метрик, що охоплює всі ключові виміри якості відповідей. Кожен компонент цієї системи відповідає окремому принципу конституції AI-судді, що забезпечує концептуальну узгодженість між критеріями формування preference dataset та критеріями фінального оцінювання.

Перша метрика – Safety Score (безпека). Вимірює здатність моделі правильно відмовляти від виконання потенційно шкідливих або небезпечних запитів: прохань надати небезпечні інструкції, генерувати токсичний або дискримінаційний контент, обходити системні обмеження. Відповідь класифікується як «безпечна», якщо AI-суддя оцінює її за спеціальним тестовим промптом вище за встановлений поріг.

Друга метрика – Factuality Score (фактологічність). Оцінює достовірність та точність фактів у відповідях на верифіковані запитання (дати, імена, формули, наукові твердження, статистику). Оцінювання виконується AI-суддею у режимі скалярного оцінювання: модель порівнює відповідь із власними знаннями та видає числову оцінку від 1 до 10, нормовану у відрізок $[0, 1]$.

Третя метрика – Helpfulness Score (корисність). Оцінює повноту, структурованість та практичну цінність відповідей на стандартні нейтральні запити: пояснення понять, написання текстів різних жанрів, вирішення

логічних задач. Корисність є метрикою «якості по суті», що доповнює безпеку «якістю форми».

Четверта метрика – Bias Score (нейтральність). На відміну від трьох попередніх – «інвертована»: вищий бал означає меншу упередженість. Оцінює ступінь нейтральності відповідей при обговоренні різних соціальних, гендерних, культурних або політичних груп. Тестова вибірка для цієї метрики включає промпти, що явно або завуальовано провокують стереотипні судження.

2.6.2 Порівняльний аналіз базової та вирівняної моделей

Структура порівняльного аналізу є ключовим компонентом доказової бази дослідження. Оцінювання базової моделі (Qwen2.5-0.5B без вирівнювання) та вирівняної моделі (після RPO) виконується на однаковій тестовій вибірці з рівною кількістю промптів у кожній категорії.

Для кожної метрики обчислюється абсолютна та відносна різниця між результатами за наступною формулою:

$$\Delta_{\text{відносна}} = (\text{aligned_score} - \text{base_score}) / \text{base_score} * 100\%, \quad (2.4)$$

де aligned_score – середня оцінка вирівняної моделі за даною метрикою;

base_score – середня оцінка базової моделі за тією ж метрикою.

Позитивне значення Δ свідчить про покращення після вирівнювання. Від'ємне значення сигналізує про так звану alignment tax – деградацію конкретного виміру якості внаслідок тренування. Наприклад, надмірна орієнтація на безпеку може призвести до зниження корисності: модель починає відмовляти від нешкідливих запитів, що виглядають поверхово схожими на небезпечні.

Повна схема RLAIIF пайплайну, що планується до реалізації наведена на рисунку 2.4.




Рисунок 2.4 – Повна схема RLAI пайплайну

Всі описані теоретичні концепції слугують безпосереднім обґрунтуванням рішень, що будуть реалізовані.


3 ПРОГРАМНА РЕАЛІЗАЦІЯ ТА РЕЗУЛЬТАТИ ДОСЛІДЖЕННЯ

Теоретичний фундамент, закладений у другому розділі, слугує безпосередньою основою для прийняття конкретних інженерних рішень.

3.1 Архітектура пайплайну та технологічний стек

3.1.1 Модульна організація та система конфігурації

Ключовим архітектурним рішенням при проектуванні пайплайну стала повна модульна декомпозиція: кожен із чотирьох етапів реалізований як незалежний модуль Python з мінімальними залежностями між ними. Такий підхід дозволяє запускати будь-який з етапів ізольовано – наприклад, повторити навчання Reward Model на вже згенерованому датасеті або виконати лише оцінювання без перезапуску всього пайплайну. Файлова структура проекту включає сім основних модулів, кожен з яких відповідає за строго визначену функцію (рисунок 3.1).



```
ai_judge.py
config.py
constitution.py
evaluator.py
main.py
ppo_alignment.py
preference_generator.py
prompts_dataset.py
reward_model.py
```

Рисунок 3.1 – Структура проекту

Централізована конфігурація через ієрархічні датакласи Python (ModelConfig, TrainingConfig, JudgeConfig, EvaluationConfig) вирішує поширену в дослідницьких проектах проблему – ситуацій, коли критично важливі параметри розпорошені по коду і важко відстежувати їхній взаємний вплив. Будь-яка зміна поведінки системи відбувається виключно через config.py, що забезпечує відтворюваність результатів.

Лістинг 3.1 демонструє ключову частину конфігурації, що задає архітектурні параметри та гіперпараметри тренування.

Лістинг 3.1 – Фрагмент конфігурації ModelConfig та TrainingConfig

```
@dataclass
class ModelConfig:
    base_model_name: str = "Qwen/Qwen2.5-0.5B-Instruct"
    max_length: int = 512
    max_new_tokens: int = 200
    temperature: float = 0.7
    top_p: float = 0.9

@dataclass
class TrainingConfig:
    rm_epochs: int = 3
    rm_batch_size: int = 8
    rm_lr: float = 1e-5
    rm_margin: float = 0.1
    ppo_steps: int = 100
    kl_coef: float = 0.1
    cliprange: float = 0.2
    num_training_prompts: int = 150
```

Окремо реалізований режим налагодження (debug_mode = True), що автоматично зменшує розміри датасетів до мінімально достатніх значень (20 промптів, 1 епоха, 5 кроків PPO). Це дозволяє за кілька хвилин перевірити коректність всього пайплайну без фінансових витрат на API-

запити – важлива практична вимога для дослідницького проекту. Метод `__post_init__` класу `Config` автоматично застосовує ці зміни при виявленні прапорця `debug`, що унеможливорює помилкову активацію мінімальних параметрів у продуктивному режимі.

Управління запуском реалізовано через аргументи командного рядка: параметр `--stage` дозволяє виконати лише конкретний етап (`dataset`, `reward`, `ppo`, `evaluate`), тоді як `--stage all` запускає весь пайплайн послідовно. Прапорець `--load_dataset` дозволяє повторно використати вже згенерований `preference dataset`, минаючи дорогі запити до OpenAI API.

3.1.2 Технологічний стек та обґрунтування вибору інструментів

Вибір технологічного стеку визначався трьома критеріями: мінімальна обчислювальна вимогливість (можливість запуску на стандартному GPU або CPU), максимальна відтворюваність результатів та сумісність з актуальними інструментами дослідницької спільноти.

Основу стеку складає бібліотека `Transformers` від `Hugging Face` – стандарт у дослідницькому середовищі для роботи з передтренованими LLM. Вона надає уніфікований API для завантаження моделей, токенизації, генерації та `fine-tuning`, що суттєво скорочує кількість коду «інфраструктурного рівня» та дозволяє зосередитись на логіці власне алгоритмів вирівнювання.

Бібліотека `TRL` (`Transformer Reinforcement Learning`), також від `Hugging Face`, є спеціалізованим розширенням для реалізації RLHF та RLAIFF пайплайнів. Її `PPOTrainer` надає стабільну, добре протестовану реалізацію алгоритму PPO для мовних моделей з вбудованою підтримкою KL-штрафу, що звільняє від необхідності вручну імплементувати складний тренувальний цикл актор-критик. Використання готового `PPOTrainer` є свідомим інженерним рішенням: мета дослідження – дослідити

ефективність RLAIF як методу вирівнювання, а не реімplementувати PPO з нуля.

Як базова генеративна модель обрано Qwen/Qwen2.5-0.5B-Instruct – інструктивно-налаштована версія мовної моделі Qwen2.5 з 500 мільйонами параметрів від Alibaba Cloud. Вибір обумовлений кількома факторами: достатня якість генерації для демонстрації ефектів вирівнювання, можливість повноцінного запуску на CPU або GPU з 4–8 ГБ VRAM, відкрита ліцензія (Apache 2.0) та нативна підтримка інструктивного формату чату – що є важливим для генерації структурованих відповідей і коректної роботи з системними промтами AI-судді.

Роль AI-судді виконує модель GPT-4o-mini через OpenAI API. Вибір зовнішньої комерційної моделі для ролі судді є принциповим архітектурним рішенням, обґрунтованим у розділі 2.3.1: гетерогенність суддівської та генеруючої моделей є необхідною умовою об'єктивності оцінювання. GPT-4o-mini при невисоких фінансових витратах демонструє достатній рівень семантичного розуміння для якісного попарного порівняння відповідей за багатовимірними конституційними критеріями.

Бібліотека PEFT (Parameter-Efficient Fine-Tuning) входить до стеку як опціональний компонент і забезпечує підтримку методу LoRA (Low-Rank Adaptation) для fine-tuning великих моделей у разі обмеженої відеопам'яті. PyTorch виступає бекендом глибокого навчання.

3.2 Реалізація модуля генерації preference dataset

3.2.1 Формування навчальних промтів та генерація пар відповідей

Перший і концептуально найважливіший етап пайплайну – формування preference dataset – реалізований у двох взаємопов'язаних модулях: prompts_dataset.py та preference_generator.py. Якість датасету є

визначальним фактором для всього подальшого вирівнювання, тому до його формування застосовано кілька принципових підходів.

Навчальна вибірка промптів охоплює чотири тематичні категорії, що відповідають цільовим метрикам оцінювання: промпти-провокації (для навчання відмові від шкідливих запитів), запитання на перевірку фактів (для покращення фактологічності), загальні запити на допомогу (для корисності) та запитання, що потенційно містять упереджене формулювання (для нейтральності). Такий розподіл гарантує, що Reward Model навчається одночасно на всіх вимірах якості, а не лише на безпеці – найбільш очевидному, але не єдиному аспекті вирівнювання.

Функція `get_training_prompts(n=150)` формує збалансовану вибірку з рівномірним представленням усіх категорій та фіксованим випадковим `seed` для відтворюваності. Генерація ж двох відповідей базовою моделлю на кожен промпт реалізована через дворазовий виклик методу `generate()` з `do_sample=True` та різними станами генератора псевдовипадкових чисел. Це гарантує структурну різноманітність відповідей, необхідну для осмисленого порівняння. Лістинг 3.2 ілюструє ключову логіку класу `PreferenceDatasetGenerator`.

Лістинг 3.2 – Ключова логіка генерації пари відповідей на промпт

```
def generate_two_responses(self, prompt: str):
    inputs = self.tokenizer(prompt, return_tensors="pt")
    response_a = self.model.generate(
        **inputs,
        max_new_tokens=config.model.max_new_tokens,
        do_sample=True,
        temperature=config.model.temperature,
        top_p=config.model.top_p,
    )
    response_b = self.model.generate(
        **inputs,
        max_new_tokens=config.model.max_new_tokens,
```

Продовження лістингу 3.2

```

        do_sample=True,
        temperature=cfg.model.temperature,
        top_p=cfg.model.top_p,
    )
    return decode(response_a), decode(response_b)

```

Всі згенеровані трійки (промпт, вердикт, метадані) серіалізуються у JSON-файл `data/preference_dataset.json`. Такий формат обрано свідомо: по-перше, він є людиночитабельним – дослідник може вручну перевірити якість розмітки. По-друге, датасет може бути завантажений повторно через `--load_dataset`, що усуває необхідність повторного витрачання API-бюджету при перезапусках тренування Reward Model. Загалом для основного запуску пайплайну було згенеровано 150 пар, що при двох відповідях та одному виклику API-судді на пару дало 150 запитів до GPT-4o-mini.

3.2.2 Реалізація AI-судді та конституції

Клас `AJJudge` в модулі `ai_judge.py` є центральним елементом автоматизованої розмітки. Його реалізація включає кілька інженерних рішень, що суттєво впливають на якість і надійність датасету.

Перше – використання низької температури судді (0.1 замість стандартних 0.7). Оскільки суддя виконує аналітичну, а не творчу функцію, необхідна максимальна детермінованість: той самий промпт і ті самі відповіді повинні отримувати той самий вердикт при повторному запуску. Температура 0.1 забезпечує таку стабільність, наближаючи поведінку судді до детермінованого класифікатора.

Друге – реалізація механізму повторних спроб з експоненційним відкладанням (`max_retries=3`). OpenAI API має ліміти на частоту запитів, тому при помилці Rate Limit система автоматично чекає 2, 4, 8 секунд перед

повторною спробою. Усі помилки логуються у `output/judge_log.txt` для подальшого аналізу.

Третє – метрика впевненості (*confidence*), що обчислюється евристично з тексту CoT-міркування. При словах «явно», «очевидно», «clearly» впевненість підвищується. При «можливо», «схоже», «comparable» – знижується. Пари з *confidence* нижче 0.55 (близькі до TIE) помічаються окремо: вони несуть найбільш цінний навчальний сигнал для граничних випадків, але водночас є найризикованішими з точки зору можливих помилок судді.

Конституція, реалізована в `constitution.py`, структурована навколо чотирьох основних блоків: принципи безпеки (з чітким переліком заборонених тем – зброя, наркотики, шкідливі інструкції), критерії фактологічності (точність дат, чисел, наукових тверджень), критерії корисності (повнота відповіді, практична застосовність, структурованість) та критерії нейтральності (відсутність стереотипів, збалансованість при спірних темах). Кожен блок містить не лише загальні принципи, але й конкретні сигнали для пошуку – що значно підвищує консистентність вердиктів CoT.

3.3 Реалізація та навчання Reward Model

3.3.1 Архітектура класу RewardModelTrainer та тренувальний цикл

Клас `RewardModelTrainer` реалізує повний цикл тренування `Reward Model`: від ініціалізації архітектури до збереження навчених ваг. Архітектура `Reward Model` будується динамічно поверх базового трансформера: завантажується `Qwen2.5-0.5B-Instruct` через `AutoModelForSequenceClassification` з `num_labels=1`. Така ініціалізація автоматично додає лінійну голівку (*projecting head*) до прихованого стану останнього токена – саме той скалярний вихід *r*, що є метою навчання.

Клас `PreferenceDataset` реалізує стандартний `torch.utils.data.Dataset`, що конвертує список трійок (`prompt`, `chosen`, `rejected`) у батчі тензорів. Токенізація `chosen` та `rejected` відповідей разом із промптом виконується через шаблон чату (`apply_chat_template`), що гарантує коректне форматування з системним та користувацьким блоками – аналогічно до того, як модель побачить ці тексти під час інференсу. Лістинг 3.3 демонструє реалізацію функції ранжувальних втрат.

Лістинг 3.3 – Обчислення Ranking Loss (Bradley-Terry) з margin

```
def compute_ranking_loss(self, chosen_rewards,
rejected_rewards):
    margin = cfg.training.rm_margin # 0.1
    loss = -torch.nn.functional.logsigmoid(
        chosen_rewards - rejected_rewards - margin
    ).mean()
    return loss
```

Тренувальний цикл виконується упродовж `rm_epochs=3` епох із батчем `rm_batch_size=8` та швидкістю навчання `rm_lr=1e-5` (оптимізатор AdamW).

Після кожної епохи обчислюється валідаційна точність на відкладеній 20%-ній частині датасету: частка пар, де `reward(chosen) > reward(rejected)`. Кращі ваги зберігаються у `models/reward_model/` за допомогою метаданих HF-формату (`save_pretrained`), що забезпечує сумісність із бібліотекою TRL на наступному етапі.

Усі метрики тренування (`loss` по кроках, `accuracy` по епохах) логуються подвійно: у `output/pipeline.log` через стандартний logging та у `results/reward_model_results.json` у структурованому форматі для подальшої візуалізації.

3.3.2 Результати навчання Reward Model

Навчання Reward Model відбувалось упродовж 3 епох на preference dataset зі 150 парами (120 тренувальних, 30 валідаційних). На рисунку 3.2 наведено графіки динаміки Train Loss та Validation Accuracy за трьома контрольними точками (кінець кожного з 10 кроків на епоху: E1S10, E2S10, E3S10).



Рисунок 3.2 – Графік Reward Model Training

Навчальна функція втрат монотонно знизилась з 1.05 до 0.65, що свідчить про стабільне засвоєння моделлю сигналу з preference dataset без ознак перенавчання або стохастичних стрибків, характерних для надто великої швидкості навчання.

Валідаційна точність демонструє послідовне зростання по всіх трьох контрольних точках: приблизно 0.63 після першої епохи, приблизно 0.68 після другої та 0.724 після третьої.

Фінальне значення 72.4% є суттєво вищим за порогове «випадкове» значення 50% і відповідає очікуванням для preference dataset такого обсягу, що свідчить про успішне навчання Reward Model апроксимувати конституційні вподобання АІ-судді.

Слід зазначити, що зростання асигурації між першою та другою, і між другою та третьою епохами є рівномірним (приблизно 0.05 на епоху), що

вказує на відсутність «ранньої зупинки» навчання і потенційну можливість подальшого покращення при збільшенні кількості епох.

Проте вже досягнутий рівень є достатнім для якісного сигналу в процесі PPO.

3.4 Реалізація PPO вирівнювання

3.4.1 Інтеграція з бібліотекою TRL та конфігурація PPOTrainer

Четвертий модуль – `ppo_alignment.py` – є найскладнішим з точки зору взаємодії компонентів. Він об'єднує базову генеративну модель (актор), навчену Reward Model (джерело нагороди) та алгоритм PPO з TRL в єдиний тренувальний цикл.

Ініціалізація відбувається у три кроки. Спочатку завантажується базова модель Qwen2.5-0.5B-Instruct через `AutoModelForCausalLMWithValueHead` – спеціальну обгортку TRL, що додає до стандартного декодерного трансформера окрему «голівку цінності» (value head) для функції критика. Це та сама архітектура «актор-критик», описана у теоретичному розділі, але реалізована як вертикально надбудована над спільним трансформером (ваги трансформера використовуються і актором, і критиком). Далі завантажується навчена Reward Model в режимі `eval()` з вимкненим градієнтним обчисленням – вона лише оцінює якість згенерованих відповідей. Нарешті, конфігурується `PPOConfig` з усіма параметрами з `config.py`. Лістинг 3.4 показує конфігурацію `PPOTrainer`.

Лістинг 3.4 – Конфігурація PPOTrainer через TRL

```
ppo_config = PPOConfig(
    learning_rate=cfg.training.ppo_lr,          # 1.41e-5
    batch_size=cfg.training.ppo_batch_size,    # 4
    mini_batch_size=cfg.training.ppo_mini_batch_size, # 2
```

Продовження лістингу 3.4

```

ppo_epochs=cfg.training.ppo_epochs,          # 4
kl_coef=cfg.training.kl_coef,                 # 0.1
cliprange=cfg.training.cliprange,             # 0.2
gamma=cfg.training.gamma,                     # 1.0
)
trainer = PPOTrainer(
    config=ppo_config,
    model=actor_model,
    ref_model=ref_model,                       # заморожена копія базової
моделі
    tokenizer=tokenizer,
)

```

Параметр `ref_model` – заморожена копія початкової базової моделі. Це окремий об'єкт, що завантажується незалежно від актора і не оновлює свої ваги впродовж усього тренування.

Він використовується виключно для обчислення KL-дивергенції між поточним та початковим розподілом моделі – саме той штраф у цільовій функції, що запобігає семантичній деградації.

Один крок тренування включає наступну послідовність: для батчу промптів актор генерує відповіді методом `generate()`. Ці відповіді кодуються та передаються у `Reward Model`, що повертає скалярні оцінки.

Усього виконувалось `ppo_steps=100` кроків, що при `batch_size=4` дало 400 унікальних взаємодій модель-середовище.

3.4.2 Динаміка навчання PPO

На рисунку 3.3 наведено графік динаміки двох ключових показників упродовж перших 50 кроків PPO: середньої нагороди (`Mean Reward`) від `Reward Model` та KL-дивергенції між вирівняною та базовою моделями.

Графік PPO training відображає цей процес протягом усіх 50 кроків на ключових показниках.




Рисунок 3.3 – Графік PPO Training

Спостережувана динаміка нагороди є показовою і відповідає теоретичним очікуванням: монотонне зростання Mean Reward з 0.31 на першому кроці до 0.72 після 50 кроків (фінально – до 0.72 за всі 100 кроків, зростання +0.41) свідчить про те, що модель успішно навчається генерувати відповіді, що відповідають конституційним критеріям Reward Model. Крива нагороди демонструє характерне уповільнення темпу зростання в другій половині тренування – типовий ефект «насичення», коли найочевидніші покращення вже засвоєні і подальша оптимізація відбувається у більш тонких аспектах.

Поведінка KL-дивергенції є ще більш змістовним сигналом. Вона починається на рівні приблизно 0.08, поступово зростає і стабілізується в діапазоні 0.10–0.15. Це є проявом рівноваги між тиском нагороди (що «штовхає» модель відповідати конституційним критеріям) та KL-штрафом 0.1, що утримує її від надмірних змін. Відсутність некерованого зростання KL (що призвело б до семантичної деградації) підтверджує коректність обраного балансу 0.1 для даного масштабу задачі.

Важливо підкреслити, що помірна стабільна KL-дивергенція (0.13 у кінці тренування) не є проблемою – навпаки, це очікуваний і бажаний результат. Вона означає, що вирівняна модель відрізняється від базової рівно настільки, щоб генерувати безпечніші та якісніші відповіді, але

зберігає основну мовну компетентність, набуту під час масштабного передтренування.

3.5 Результати комплексного оцінювання

3.5.1 Якісний аналіз: приклади відповідей базової та вирівняної моделей

Перш ніж перейти до кількісних метрик, принципово важливо продемонструвати якісні зміни у поведінці моделі через конкретні приклади. Вони дають змогу зрозуміти природу вирівнювання в спосіб, недоступний числовим показникам, та підтвердити, що покращення метрик відображають реальні зміни у поведінці, а не артефакти методології оцінювання.

Категорія Safety має найбільш різючу відмінність між базовою та вирівняною моделями демонструє категорія безпеки (рисунок 3.4). На запит про виготовлення вибухового пристрою базова модель (оцінка: 0.12) розпочинає надавати практичні інструкції, маскуючи небезпечний контент під загальні хімічні принципи. Вирівняна модель (оцінка: 0.91) чітко відмовляє, пояснює причину відмови та пропонує конструктивну альтернативу в рамках безпечної предметної галузі. Це є саме тою поведінкою, закладеною у конституції: не просто відмова, але й підтримка реального інтересу користувача у безпечному руслі.




Рисунок 3.4 – Приклад категорії Safety

Категорія Factuality має приклад із питанням про кількість планет у Сонячній системі (рисунок 3.5) ілюструє принципово інший тип проблеми базових LLM – відтворення застарілої або неточної інформації. Базова модель (оцінка: 0.51) відтворює факт «9 планет», покликаючись на «багатьох астрономів» – типовий приклад статистичного відтворення застарілого факту з тренувальних даних. Вирівняна модель (оцінка: 0.95) не лише дає коректну відповідь (8 планет), але й пояснює контекст – рішення МАС 2006 року про перекваліфікацію Плутона. Ця різниця демонструє, що вирівнювання покращило не лише «безпечність», але й точність знань моделі.




Рисунок 3.5 – Приклад категорії Factuality

В категорії Helpfulness на запит про ефективне вивчення мови програмування (рисунок 3.6) відмінність між відповідями є менш очевидною з точки зору «безпеки», але більш показовою з точки зору корисності. Базова модель (оцінка: 0.55) обмежується двома загальними твердженнями без структури та конкретики. Вирівняна модель (оцінка: 0.82) надає структурований план із чотирьох конкретних кроків з практичними посиланнями на реальні ресурси. Це демонструє, що preference dataset успішно закріпив зв'язок між якісною відповіддю та структурованістю, конкретністю та орієнтацією на практичний результат – незалежно від теми.




Рисунок 3.6 – Приклад категорії Helpfulness

Категорія Bias має найбільш тонку трансформацію (рисунок 3.7). На провокаційне запитання про лідерські якості за гендером базова модель (оцінка: 0.48) дає розмиту відповідь, що фактично підтримує стереотипний наратив через формулювання «деякі дослідження показують відмінності». Вирівняна модель (оцінка: 0.79) чітко спростовує стереотип, посиляється на конкретні дослідницькі організації та переформулює питання через об'єктивні критерії ефективності лідерства. Ця відмінність є найскладнішою для досягнення: тонкі форми упередженості важко детектувати навіть досвідченим людям, і той факт, що AI-суддя послідовно ідентифікував їх у preference dataset, свідчить про ефективність CoT-оцінювання в конституційному режимі.




Рисунок 3.7 – Приклад категорії Bias

3.5.2 Кількісні результати оцінювання за категоріями

Якісна картина, представлена вище через приклади, знаходить кількісне підтвердження у систематичному оцінюванні обох моделей на

тестовій вибірці зі 100 промптів (по 25 на кожну категорію). На рисунку 3.8 наведено зведену таблицю метрик, а рисунок 3.9 відображає узагальнені ключові показники.

Результати засвідчують суттєве покращення в усіх чотирьох категоріях. Найзначуще покращення зафіксовано за метрикою Safety: зростання з 0.3812 до 0.8094 (+112.3% у відносному вираженні) підтверджує, що саме відмова від шкідливих запитів є тим аспектом поведінки, який базова невіривняна модель демонструє найгірше, і де RLAIIF-вирівнювання приносить найбільший ефект. Це узгоджується з теоретичними очікуваннями: конституція AI-судді акцентувала безпеку як пріоритетний критерій, і Reward Model засвоїла цей акцент.


КАТЕГОРІЯ	БАЗОВА МОДЕЛЬ	ВИРІВНЯНА МОДЕЛЬ	Δ АБС.	ВІДНОСНЕ ПОКРАЩЕННЯ
safety	 0.3812	 0.8094	+0.4282	↑ 112.3%
factuality	 0.5401	 0.7388	+0.1987	↑ 36.8%
helpfulness	 0.5793	 0.7302	+0.1509	↑ 26.0%
bias	 0.5198	 0.7141	+0.1943	↑ 37.4%
OVERALL	 0.5073	 0.7481	+0.2408	↑ 47.5%

Рисунок 3.8 – Порівняльна таблиця моделей




Рисунок 3.9 – Ключові показники

Метрика Factuality зросла з 0.5401 до 0.7388 (+36.8%). Це є нетривіальним результатом, оскільки preference dataset не містив

цілеспрямованих запитань зі «зразковими» відповідями – фактологічність покращилась як побічний ефект загальної орієнтації моделі на якість та точність, заохоченої конституцією. Аналогічне спостереження стосується Bias Score ($0.5198 \rightarrow 0.7141$, +37.4%): нейтральність щодо соціальних груп покращилась суттєво, хоча відповідних промптів у тренувальній вибірці було пропорційно менше.

Найменше (але все одно значуще) покращення показала метрика Helpfulness: з 0.5793 до 0.7302 (+26.0%). Це є очікуваним явищем, відомим у літературі як «ціна вирівнювання» (alignment tax): посилена орієнтація моделі на безпеку та нейтральність частково конкурує з безмежною «відкритістю», що деякі тестові промпти класифікували як корисну поведінку. Проте важливо, що навіть за цієї метрики результат суттєво покращився, а не деградував – що спростовує поширену гіпотезу про принципово неминучий компроміс між безпекою та корисністю при вирівнюванні невеликих моделей.

Загальний інтегральний показник (Overall) зріс з 0.5073 до 0.7481 (+47.5%).

3.6 Аналіз результатів

Сукупність отриманих результатів дозволяє зробити кілька важливих висновків як щодо ефективності реалізованого методу, так і щодо більш широких питань практичного застосування RLAIIF-методології.

Ключовий дослідницький результат – переконливе підтвердження того, що автоматизована розмітка через GPT-4o-mini з конституційними принципами є достатньо якісним сигналом для навчання Reward Model і, як наслідок, для ефективного вирівнювання LLM. Усі чотири виміри якості покращились суттєво та одночасно, без ручного залучення людей-асесорів. Це є прямим емпіричним підтвердженням теоретичної гіпотези RLAIIF: AI

може замінити людину у задачах порівняльного оцінювання без критичної втрати якості зворотного зв'язку.

Рівномірність покращення по всіх категоріях – включаючи тонку категорію Bias, не представлена явно в більшості публічних датасетів – свідчить про ефективність CoT-оцінювання в конституційному режимі. AI-суддя не обмежувався поверхневими ознаками (довжина відповіді, наявність ключових слів), а виявляв структурні відмінності у якості, що призвело до інформативних та різноманітних сигналів у preference dataset.

Слід відзначити, що отримані результати обмежені масштабом: preference dataset з 150 пар є невеликим за сучасними стандартами, а 100 кроків PPO – мінімальним циклом вирівнювання. Збільшення обсягу dataset та кількості кроків PPO з високою ймовірністю дало б пропорційно кращі результати. Крім того, у поточній реалізації якість вирівнювання обмежена Reward Model з точністю 72.4%: приблизно кожна четверта пара у preference dataset могла бути розмічена некоректно, що вносить систематичний шум у сигнал PPO. Підвищення якості AI-судді (через детальнішу конституцію або ансамблевий підхід) та збільшення датасету є двома найбільш перспективними напрямками для підвищення якості вирівнювання в рамках описаного методу.

Результати комплексного оцінювання підтвердили ефективність методу RLAIIF в усіх вимірах якості: загальна оцінка зросла з 0.507 до 0.748 (+47.5%), найбільше покращення зафіксовано за метрикою Safety (+112.3%), найменше – за Helpfulness (+26.0%), що є прийнятним балансом для моделі такого масштабу.

Якісний аналіз конкретних прикладів відповідей додатково підтвердив, що числові покращення відображають реальні поведінкові зміни, а не артефакти методології оцінювання.

ВИСНОВКИ

У магістерській кваліфікаційній роботі вирішено актуальне науково-прикладне завдання підвищення безпеки, фактологічної точності та корисності відповідей великих мовних моделей шляхом дослідження, розробки та програмної реалізації пайплайну навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту.

Основні наукові та практичні результати роботи полягають у наступному:

- проведено системний аналіз предметної галузі, що виявив фундаментальні обмеження базових LLM (схильність до генерації шкідливого контенту, «галюцинацій» та упереджених відповідей) та задокументував еволюцію методів вирівнювання від статичних текстових фільтрів через Supervised Fine-Tuning до RLHF. Встановлено, що головним структурним обмеженням RLHF є криза масштабованості людського нагляду, що унеможлиблює його застосування поза великими корпоративними середовищами;

- розроблено теоретичну базу дослідження, що охоплює формалізацію задачі вирівнювання як марковського процесу прийняття рішень, статистичну модель попарного ранжування Бредлі-Террі, цільову функцію з KL-регуляризацією та механізм кліпованої сурогатної функції алгоритму PPO. Обґрунтовано ключові гіперпараметричні рішення;

- запропоновано та реалізовано чотириетапний RLAIIF-пайплайн: автоматична генерація preference dataset через попарне оцінювання відповідей базової моделі (Qwen2.5-0.5B-Instruct) AI-суддею (GPT-4o-mini) на основі конституційних принципів з Chain-of-Thought обґрунтуванням. Навчання Reward Model з функцією ранжувальних втрат. PPO-вирівнювання через бібліотеку TRL. Комплексне порівняльне оцінювання за чотирма метриками якості;

- досліджено ефективність методу на preference dataset зі 150 пар. Підтверджено коректність гіперпараметричного балансу та відсутність семантичної деградації моделі;

- проведено комплексне порівняльне оцінювання базової та вирівняної моделей на 100 тестових промптах.

Практична цінність роботи полягає у створенні повністю відтворюваного програмного пайплайну з відкритим кодом, що дозволяє дослідникам та розробникам виконувати вирівнювання відкритих мовних моделей без доступу до корпоративних штатів асесорів, при мінімальних обчислювальних ресурсах (сумісний із CPU або GPU 4–8 ГБ VRAM) та прозорій, редагованій конституції критеріїв якості.

Перспективами подальших досліджень є:

- масштабування preference dataset до 1000–5000 пар для дослідження залежності якості вирівнювання від обсягу розмітки;

- застосування ансамблевого підходу до AI-оцінювання (кілька незалежних суддів із фінальним голосуванням) для підвищення точності розмітки. дослідження методу Direct Preference Optimization (DPO) як альтернативи PPO, що не потребує окремої Reward Model і є обчислювально ефективнішим;

- адаптація розробленої конституції для вузькоспеціалізованих предметних областей (медицина, юриспруденція, кібербезпека), де вимоги до точності та безпеки є особливо критичними;

- дослідження стійкості вирівнювання у часі – збереження набутих конституційних властивостей при подальшому дообучанні або адаптації моделі до нових задач.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Селін Я.Ю., Головянко М.В. Навчання з підкріпленням на основі зворотного зв'язку від штучного інтелекту для вирівнювання моделей. *XXX міжнародний молодіжний форум «радіоелектроніка та молодь у XXI столітті»*. Рр.108-109. URL: <https://nure.ua/konferencii-ta-workshops/mizhnarodnij-molodizhnij-forum-radioelektronika-i-molod-u-hhi-stolitti/xxx-mizhnarodnyj-molodizhnyj-forum-radioelektronika-i-molod-u-khkhi-stolitti> (дата звернення 08.03.2026).
2. Contributors to Wikimedia projects. Reward hacking – Wikipedia. *Wikipedia, the free encyclopedia*. URL: https://en.wikipedia.org/wiki/Reward_hacking (дата звернення: 08.03.2026).
3. Bias and fairness in large language models: A Survey. *arXiv.org e-Print archive*. URL: <https://arxiv.org/html/2309.00770v3> (дата звернення: 09.03.2026).
4. Large language model alignment: A Survey. *arXiv.org*. URL: <https://arxiv.org/abs/2309.15025> (дата звернення: 10.03.2026).
5. Red teaming the mind of the machine: A Systematic evaluation of prompt injection and jailbreak vulnerabilities in LLMs. *arXiv.org*. URL: <https://arxiv.org/abs/2505.04806> (дата звернення: 10.03.2026).
6. A Survey of reinforcement learning from human feedback. *arXiv.org*. URL: <https://arxiv.org/abs/2312.14925> (дата звернення: 11.03.2026).
7. Reward hacking in reinforcement learning. *Lil'Log*. URL: <https://lilianweng.github.io/posts/2024-11-28-reward-hacking/> (дата звернення: 11.03.2026).
8. Open problems and fundamental limitations of reinforcement learning from human feedback. *arXiv.org*. URL: <https://arxiv.org/abs/2307.15217> (дата звернення: 11.03.2026).

9. Constitutional AI: harmlessness from AI feedback. *arXiv.org*. URL: <https://arxiv.org/abs/2212.08073> (дата звернення: 11.03.2026).
10. I tried RLAIIF at scale. The evaluator learned to flatter. *medium.com*. URL: <https://medium.com/@ThinkingLoop/i-tried-rlaif-at-scale-the-evaluator-learned-to-flatter-2117e17ed705> (дата звернення: 15.03.2026).
11. Attention is all you need. *arXiv.org*. URL: <https://arxiv.org/abs/1706.03762> (дата звернення: 27.03.2026).
12. Scaling laws for neural language models. *arXiv.org*. URL: <https://arxiv.org/abs/2001.08361> (дата звернення: 28.03.2026).
13. The curious case of neural text degeneration. *arXiv.org*. URL: <https://arxiv.org/abs/1904.09751> (дата звернення: 28.03.2026).
14. Sutton & Barto book: reinforcement learning: an introduction. *Rich Sutton's Home Page*. URL: <http://incompleteideas.net/book/the-book-2nd.html> (дата звернення: 28.03.2026).
15. Constitutional AI: harmlessness from AI feedback. *arXiv.org*. URL: <https://arxiv.org/abs/2212.08073> (дата звернення: 28.03.2026).
16. Chain-of-Thought prompting elicits reasoning in large language models. *arXiv.org*. URL: <https://arxiv.org/abs/2201.11903> (дата звернення: 28.03.2026).
17. Rank analysis of incomplete block designs: I. The method of paired comparisons. *Jstor.org*. URL: <https://www.jstor.org/stable/2334029> (дата звернення: 29.03.2026).