

Міністерство освіти і науки України
Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____
(повна назва)
Кафедра _____ програмної інженерії _____
(повна назва)

КВАЛІФІКАЦІЙНА РОБОТА Пояснювальна записка

рівень вищої освіти _____ другий (магістерський)

Дослідження моделей нейронних мереж типу трансформери для семантичного та емоційного аналізу природної мови людини
(тема)

Виконав:
здобувач _____ 2 _____ року навчання
групи _____ ПЗМ-23-2 _____

Кирило КРЕМЕНЕНКО

(власне ім'я, прізвище)

Спеціальність _____ 121 – Інженерія програмного забезпечення _____
(код і повна назва спеціальності)

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

Освітня програма _____ Інженерія програмного забезпечення _____
(повна назва освітньої програми)

Керівник _____ доц. Ірина АФАНАСЬЄВА _____
(посада, власне ім'я, прізвище)

Допускається до захисту
Зав. кафедри

_____ Кирило СМЕЛЯКОВ _____
(підпис) (власне ім'я, прізвище)

Харківський національний університет радіоелектроніки

Факультет _____ комп'ютерних наук _____

Кафедра _____ програмної інженерії _____

Рівень вищої освіти _____ другий (магістерський) _____

Спеціальність _____ 121 – Інженерія програмного забезпечення _____

Тип програми _____ освітньо-наукова _____

Освітня програма _____ Інженерія програмного забезпечення _____

(шифр і назва)

ЗАТВЕРДЖУЮ:

Зав. кафедри _____

(підпис)

«___» _____ 20___ р.

ЗАВДАННЯ

на кваліфікаційну роботу

здобувачеві _____ Кремененко Кирилу Олеговичу
(прізвище, ім'я, по батькові)

1. Тема роботи _____ Дослідження моделей нейронних мереж типу трансформери для семантичного та емоційного аналізу природньої мови людини _____

затверджена наказом університету від 15 квітня 2025р. №290 СТ

2. Термін подання здобувачем роботи до екзаменаційної комісії 19 червня 2025 р.

3. Вихідні дані до роботи текстові корпуси, моделі нейронних мереж, метрики оцінювання _____

4. Перелік питань, що потрібно опрацювати у роботі

вступ, аналіз предметної галузі, огляд та аналіз літературних джерел, постановка задачі, теоретичне дослідження, проведення експерименту,

висновки _____

КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Отримання завдання	16.10.2024	виконано
2	Аналіз предметної галузі і постановка задачі	26.10.2025	виконано
3	Огляд й аналіз літературних, наукових джерел	16.11.2025	виконано
4	Теоретичне дослідження	08.01.2025	виконано
5	Підготовка до апробації результатів дослідження. Публікація матеріалів	08.03.2025	виконано
6	Проведення експерименту	27.03.2025	виконано
7	Підготовка пояснювальної записки	15.04.2025	виконано
8	Підготовка презентації та доповіді	02.05.2025	виконано
9	Перевірка на плагіат	10.06.2025	виконано
10	Нормоконтроль	14.06.2025	виконано
11	Рецензування	14.06.2025	виконано
12	Попередній захист	14.06.2025	виконано
13	Занесення диплома в електронний архів	18.06.2025	виконано
14	Допуск до захисту у зав. кафедри	18.06.2025	виконано

Дата видачі завдання 16 жовтня 2024 р.

Здобувач _____

(підпис)

Кирило КРЕМЕНЕНКО

Керівник роботи _____

(підпис)

доц. Ірина АФАНАСЬСВА
(посада, власне ім'я, прізвище)

РЕФЕРАТ / ABSTRACT

Пояснювальна записка містить: 66 с., 2 табл., 16 джерел, 4 додатки.

АНАЛІЗ, BERT, NLP, SVM, TF-IDF, GPT, roBERTa.

Об'єктом дослідження є процеси семантичного та емоційного аналізу природної мови, які забезпечують розуміння змісту текстових повідомлень та їхнього контексту сучасними мовними моделями.

Метою роботи є дослідження ефективності моделей нейронних мереж типу трансформери (зокрема BERT, RoBERTa та GPT) у задачах автоматизованого аналізу тексту для визначення його емоційної тональності та семантичного змісту.

Методами дослідження є аналіз сучасних архітектур трансформерних моделей, побудова експериментального середовища для тестування, порівняння результатів за допомогою стандартних метрик класифікації (точність, повнота, F1-міра), а також інтерпретація отриманих результатів для різних сценаріїв використання.

У результаті роботи було реалізовано та протестовано кілька моделей на основі трансформерної архітектури. Проведено порівняльний аналіз їх ефективності, що дозволило зробити висновки щодо доцільності використання таких моделей для задач емоційного та семантичного аналізу текстів у сфері автоматизованої обробки природної мови.

ANALYSIS, BERT, NLP, SVM, TF-IDF, GPT, RoBERTa.

The object of the research is the processes of semantic and emotional analysis of natural language, which enable modern language models to understand the meaning of text messages and their context.

The aim of the thesis is to investigate the effectiveness of transformer-based neural network models (in particular, BERT, RoBERTa, and GPT) in tasks of automated text analysis for identifying emotional tone and semantic content.

The research methods include the analysis of modern transformer model architectures, construction of an experimental environment for testing, comparison of results using standard classification metrics (accuracy, recall, F1-score), and interpretation of the obtained results for various application scenarios.

As a result of the study, several models based on transformer architecture were implemented and tested. A comparative analysis of their performance was conducted, which allowed for conclusions to be drawn regarding the feasibility of using such models for semantic and emotional text analysis in the field of automated natural language processing.

Умови публікації звіту: заява щодо самостійного виконання кваліфікаційної роботи та можливості її публікації в електронному архіві відкритого доступу EIAr KhNURE.

Завідувачу кафедри

ПІ

(скорочена назва кафедри)

проф. Кирилу СМЕЛЯКОВУ

(вчене звання, сласне ім'я, прізвище)

ЗАЯВА

щодо самостійності виконання кваліфікаційної роботи та можливості її публікації (та/або публікації анотації кваліфікаційної роботи) в електронному архіві відкритого доступу EIAr KhNURE

Я, Кремененко Кирило Олегович

(прізвище, ім'я, по батькові)

здобувач вищої освіти на другому (магістерському) рівні вищої освіти академічної групи ПІЗМ-23-2

кафедра програмної інженерії,
(повна назва кафедри)

заявляю: моя кваліфікаційна робота на тему «Дослідження моделей нейронних мереж типу трансформери для семантичного та емоційного аналізу природньої мови людини»

(назва роботи)

що буде представлена в екзаменаційну комісію для публічного захисту, виконана самостійно, в ній не містяться елементи плагіату і вона може бути опублікована в репозиторії "EIArKhNURE". Погоджуюся з авторським договором, відповідно до Положення про репозиторій ХНУРЕ "EIArKhNURE". Всі запозичення з друкованих та електронних джерел мають відповідні посилання.

Я ознайомлений (а) з вимогами академічної доброчесності, згідно з якими виявлення плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту та застосування дисциплінарних заходів.

Дата 09 червня 2025 р.

Підпис _____

ЗМІСТ

Вступ.....	9
1 Аналіз предметної галузі.....	11
1.1 Тенденції та перспективи.....	11
1.2 Огляд існуючих підходів.....	12
1.3 Обмеження існуючих рішень.....	13
1.4 Масштаб проблеми.....	14
1.5 Визначення рівня інноваційності.....	14
2 Огляд та аналіз літературних джерел.....	16
2.1 Огляд основних джерел.....	16
2.2 Оцінка актуальності та новизни.....	17
2.3 Висновки з огляду.....	18
3 Постановка задачі.....	21
3.1 Визначення тематики та кінцевих результатів.....	21
3.2 Обґрунтування вибору методів дослідження.....	21
3.3 Обмеження дослідження.....	22
3.4 Ресурси для виконання проєкту.....	23
4 Теоретичне дослідження.....	24
4.2 Обрані моделі для дослідження.....	25
4.3 Критерії та методи комплексного оцінювання результатів.....	27
4.4 Класичні методи.....	29
4.5 Особливості навчання моделей.....	30
4.6 Дані для навчання трансформерів.....	32
5 Проведення експерименту.....	34
5.1 Набір даних.....	34

5.2 Підготовка даних.....	35
5.3 Результати моделей.....	36
Висновки	42
Перелік джерел посилання	44
Перелік джерел посилання за науковими напрямками керівника та науковців кафедри програмної інженерії	46
Додаток А Слайди презентації.....	47
Додаток Б Апробація результатів роботи.....	53
Додаток В Звіт результатів перевірки на унікальність тексту в базі ХНУРЕ.....	63
Додаток Г Експертний висновок результатів перевірки кваліфікаційної роботи на відповідність оформлення вимогам ДСТУ 3008:2015	66

ВСТУП

З огляду на постійне зростання обсягів текстових даних, що генеруються в цифровому середовищі, значно підвищується потреба в ефективних засобах автоматизованої обробки природної мови (NLP)[1]. Сфера NLP тісно пов'язана з досягненнями глибокого навчання, яке залишається домінуючим підходом завдяки впровадженню прогресивних архітектур штучних нейронних мереж. Серед них особливу увагу привертає архітектура трансформерів, що дозволяє ефективно моделювати довгі текстові залежності та одночасно забезпечує масштабовану паралельну обробку. Її центральним компонентом є механізм уваги (attention), який дає змогу зберігати смислові зв'язки між словами в тексті — на відміну від таких моделей, як RNN[2] та LSTM[3], що мають обмеження у роботі з контекстом.

Вихід на ринок таких моделей, як BERT[4], GPT[5], RoBERTa[6], T5 та їхніх модифікацій значно удосконалив підходи до розв'язання завдань, пов'язаних із розумінням змісту й виявленням емоцій у текстах. Семантичний аналіз фокусується на витяганні значення, встановленні логічних та смислових зв'язків між елементами тексту, а також на визначенні комунікативних намірів автора. Емоційний аналіз, у свою чергу, зосереджений на ідентифікації емоційного стану або тональності повідомлення — від базових категорій (позитив, нейтральність, негатив) до конкретних емоцій, таких як радість, тривога, агресія чи сум. Застосування таких технологій особливо важливе в практичних задачах: у сфері клієнтської підтримки, аналізу соціальних медіа, вивчення громадської думки тощо.

Інтеграція трансформерів у ці сфери відкриває нові горизонти для покращення точності та гнучкості мовних систем. У бізнес-середовищі це дозволяє аналізувати реакцію споживачів на продукти або бренди, оперативно виявляти проблемні чи токсичні висловлювання, а також пропонувати індивідуалізовані рішення. У контексті соціальних мереж такі технології допомагають виявляти агресивні або маніпулятивні повідомлення, що можуть мати шкідливий вплив на користувачів. У сфері охорони здоров'я системи аналізу тексту здатні розпізнавати

симптоми емоційних або психологічних розладів та надавати підтримку у вигляді діалогових агентів.

З наукової точки зору особливо актуальним є вивчення того, як змінюється продуктивність трансформерних моделей залежно від типу, довжини та стилістичних особливостей тексту. Це питання набуває особливої ваги в контексті мов зі складною граматикою, зокрема української, де лексичні форми тісно залежать від морфологічних категорій. У цьому зв'язку дослідження зосереджено на аналізі ефективності різних трансформерних архітектур у задачах змістового та емоційного розпізнавання, а також на розробці підходів до побудови, розмітки та аугментації корпусів для забезпечення високої якості моделювання.

Ціллю цієї роботи є ґрунтовне вивчення переваг і недоліків трансформерних моделей у контексті обробки англійського та українського текстового контенту, а також пошук оптимальних стратегій підготовки даних для досягнення надійних результатів у завданнях семантичного та емоційного аналізу. Подальші розділи дослідження охоплюють теоретичні аспекти функціонування трансформерів, сучасні підходи до навчання мовних моделей і методики оцінювання результатів на основі релевантних метрик. Це створює підґрунтя для комплексного порівняння моделей і формування рекомендацій щодо їхнього ефективного впровадження в прикладних сценаріях.

1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ

У сучасному онлайн-просторі, де обсяги текстових даних зростають надзвичайно швидко, потреба у дієвих інструментах автоматизованої модерації стає все більш нагальною. Постійне збільшення контенту на соціальних платформах, форумах та новинних ресурсах зумовлює необхідність оперативного й точного реагування на порушення правил спільнот. Мета цього розділу полягає в узагальненні та систематизації наявних рішень, виявленні їхніх обмежень, а також у визначенні перспективних напрямів подальшого розвитку в цій сфері.

1.1 Тенденції та перспективи

Загальний розвиток технологій обробки природної мови (NLP) та глибинного навчання стимулює появу нових підходів до автоматичної модерації контенту.

Перехід від традиційних алгоритмів до моделей трансформерів. Сучасні архітектури, такі як BERT, GPT, RoBERTa, T5 досягають вищих показників точності та гнучкості, що дає змогу ефективніше виявляти порушення правил.

Урахування емоційного аспекту. Крім простого визначення небажаної лексики, зростає попит на розпізнавання тональності, такої як позитивної, негативної, нейтральної та специфічних емоцій, наприклад злість, сум, страх, аби відфільтрувати потенційно небезпечний чи образливий контент.

Також дуже важливим фактором сьогодення є мультикультурність та багатомовність. Глобальний характер більшості онлайн-платформ вимагає підтримки різних мов і здатності коректно інтерпретувати культурний та лінгвістичний контекст.

Не менш важливим фактором модерації контенту є етичні та правові аспекти. З кожним роком законодавча база стає жорсткішою щодо захисту прав користувачів та контролю за поширенням шкідливого контенту. Це відкриває перспективи для інноваційних технічних рішень, які будуть відповідати чинним нормам.

Інтеграція з іншими напрямками ШІ. Застосування модулів комп'ютерного зору, розпізнавання мови, відстеження біометричних даних може підвищити загальну якість автоматизованої модерації.

Таким чином, головні тенденції вказують на перехід до все більш інтелектуальних, універсальних та етичних систем, здатних працювати з великими масивами даних у різних культурних і мовних контекстах.

1.2 Огляд існуючих підходів

У сфері автоматизованої модерації контенту застосовується низка підходів, що розрізняються за складністю та ступенем інтеграції лінгвістичних особливостей. Найпростішими є системи на основі правил, які працюють з попередньо визначеними списками забороненої лексики чи типових шаблонів порушень. Такі рішення легко впроваджувати і вони забезпечують оперативну фільтрацію очевидно неприпустимих слів. Утім, їхні можливості залишаються обмеженими, оскільки вони здебільшого не здатні розрізнити різноманітні лінгвістичні тонкощі, наприклад сарказм чи складні випадки слововживання.

Поступово системи на основі правил доповнилися чи були витіснені методами машинного навчання, які можуть опрацьовувати текст із залученням різноманітних лінгвістичних ознак, зокрема n-грам і TF-IDF. Класичні алгоритми на кшталт метод опорних векторів та наївний баєсів класифікатор виявилися досить ефективними у простих завданнях класифікації, проте потребували ретельного формування цих ознак та ручної оптимізації моделей. Ще один крок уперед зробили рекурентні нейронні мережі, адже вони краще фіксують залежності між словами в реченнях, дозволяючи враховувати контекст, але через проблему «зникаючих градієнтів» та складнощі з обробкою довгих текстів їхня ефективність теж має обмеження.

Новий етап розвитку галузі пов'язаний із впровадженням трансформерів: архітектури BERT, GPT, RoBERTa та інші варіації з механізмом самоуваги продемонстрували істотно кращі результати в розпізнаванні токсичності й визначенні тональності. Вони не лише враховують глобальний контекст у межах

речення або навіть цілого тексту, а й можуть бути адаптовані до різноманітних завдань модерації — від фільтрації образливої мови до підвищеної уваги до специфічних культурних чи мовних нюансів. Завдяки багат шаровій структурі та значним обчислювальним ресурсам, потрібним для навчання, ці моделі дедалі частіше стають базою для сучасних рішень.

Паралельно існує й підхід, який комбінує кілька описаних методів, утворюючи своєрідні «гібридні» системи. Вони можуть включати початкові перевірки за жорстко заданими правилами, щоб відсіяти типові «грубіяні» тексти або спам, а потім використовувати потужні нейронні мережі для більш ретельної оцінки складніших випадків. Такий підхід забезпечує збалансованість щодо часу обробки й точності, адже поєднує швидку реакцію на очевидні порушення із глибинним аналізом неоднозначних ситуацій. Таким чином, розвиток інструментів автоматизованої модерації контенту демонструє чітку тенденцію до комплексної оцінки змісту, де трансформери відіграють ключову роль у підвищенні точності та загальної ефективності систем.

1.3 Обмеження існуючих рішень

Незважаючи на активний розвиток та впровадження сучасних технологій, чинні системи модерації мають чимало обмежень. Одним із найвагоміших є залежність від наявності репрезентативних датасетів для певної мови чи культурного середовища: чимало великих мовних моделей тренують переважно на англomовних текстах, а це зменшує їхню ефективність в інших мовах чи специфічних діалектах. Наступний виклик полягає у «непрозорості» моделей глибинного навчання: трансформери часто виступають у ролі «чорної скриньки», і пояснити, чому саме вони визначили певне повідомлення як неприйнятне, доволі складно, що може викликати питання довіри в користувачів чи регуляторів. Також при розпізнаванні образ чи агресії важливо враховувати контекст і культуру, адже те, що в одній країні може бути сприйнято як нешкідливий вислів, в іншій вважається грубим порушенням. Додатково системам бракує й потужностей для обробки колосальних обсягів даних у реальному часі, що є неминучим наслідком

вибухового зростання кількості повідомлень у соцмережах. До того ж, навіть найбільш просунуті рішення можуть бути неспроможні розпізнати всі види прихованих чи маніпулятивних порушень, оскільки зловмисники нерідко змінюють способи поширення забороненого контенту, пристосовуючись до алгоритмів модерації.

1.4 Масштаб проблеми

Сучасні онлайн-платформи щодня генерують величезні обсяги інформації, які зростають у геометричній прогресії. Соціальні мережі, блоги, форуми та новинні портали передбачають постійний потік коментарів, публікацій і відповідей, що ускладнює процес перевірки та контролю за їхнім змістом. За таких умов людські модератори просто не здатні вчасно реагувати на всі порушення, що можуть виникати, особливо якщо це стосується шкідливого чи провокативного контенту, який розповсюджується дуже швидко. Крім того, варто брати до уваги розмаїття тем, форматів і жанрів: від коротких твітів до довгих гілок на форумах і статей із коментарями, що утворює складну систему інформаційних потоків. Усе це підвищує важливість розвитку технологій, здатних функціонувати у реальному часі й обробляти величезні обсяги тексту, адже затримки у виявленні та блокуванні порушень можуть призводити до серйозних наслідків, включно з масштабними інформаційними атаками чи поширенням мови ворожнечі.

1.5 Визначення рівня інноваційності

Інноваційність сучасних рішень у галузі модерації контенту прямо залежить від рівня впровадження провідних технологій глибинного навчання та штучного інтелекту загалом. Так, використання трансформерів, здатних паралельно аналізувати великі обсяги тексту й адекватно реагувати на багатомовні та багатокультурні сценарії, змінює підхід до виявлення порушень. У поєднанні з методами аналізу настроїв і емоцій такі рішення дають змогу краще розрізняти агресію, ненависть чи інші форми ворожості, що мають не лише вербальну, а й приховану семантичну природу. Значний поступ також спостерігається в напрямку

пояснюваних систем, де шукають способи зробити процес прийняття рішень зрозумілішим для звичайного користувача та регулятора. Інші новації стосуються оптимізації обчислювальної складової: моделі стають компактнішими й більш придатними для роботи у хмарних чи периферійних середовищах.

Не менш важливою є інтеграція з іншими напрямками штучного інтелекту, такими як комп'ютерний зір, аудіоаналітика та мультимодальні моделі, що поєднують кілька типів вхідних даних. Такий підхід дозволяє створювати комплексні системи, здатні відстежувати, аналізувати та блокувати неприпустимий або шкідливий контент не лише в текстовому форматі, але й у відео, зображеннях чи аудіо. Це, у свою чергу, відкриває нові можливості для забезпечення безпеки користувачів на цифрових платформах. Усе це вказує на високу динаміку інноваційних змін, спрямованих на посилення ефективності, масштабованості, адаптивності та прозорості процесу автоматизованої модерації контенту в умовах постійно зростаючих інформаційних потоків.

2 ОГЛЯД ТА АНАЛІЗ ЛІТЕРАТУРНИХ ДЖЕРЕЛ

2.1 Огляд основних джерел

У рамках дослідження, присвяченого застосуванню трансформерних моделей у завданнях семантичного та емоційного аналізу тексту, було залучено низку авторитетних джерел — включно з працями провідних науковців і матеріалами провідних конференцій у сфері NLP, зокрема ACL, EMNLP і NeurIPS. Основу теоретичної бази становлять публікації Devlin et al., Vaswani et al., Radford et al. та інші, що істотно вплинули на розвиток сучасних методів обробки природної мови.

Фундаментальні принципи трансформерної архітектури вперше були викладені у статті “Attention Is All You Need” [7], де було представлено підхід на основі механізму самоуваги (self-attention) без залучення рекурентних структур. Це рішення дало змогу ефективно моделювати довготривалі залежності в тексті й стало основою для подальших моделей, таких як BERT і GPT.

Модель BERT була детально описана в публікації “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding” [8], де автори запропонували двонаправлений підхід до попереднього навчання на великих текстових корпусах. Це значно покращило результати у багатьох NLP-завданнях, зокрема в емоційному та семантичному аналізі, завдяки глибшому розумінню контексту.

Цінним ресурсом для моделювання емоційної складової тексту є датасет GoEmotions [9], який охоплює понад два десятки емоційних категорій. Його використання дозволяє навчати моделі, здатні розрізняти як загальний емоційний фон повідомлень, так і конкретні емоційні стани, що має велике значення для тонкої класифікації.

Робота Google Research “Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer” [10] представила модель T5, що трактує будь-яке NLP-завдання як задачу перетворення тексту в текст. Такий підхід забезпечує універсальність моделі, полегшуючи її адаптацію до широкого спектра задач — від класифікації до генерації.

Поліпшення, запропоновані в “RoBERTa: A Robustly Optimized BERT Pretraining Approach”, показали, що навіть за умови збереження архітектури BERT, вдосконалення гіперпараметрів і збільшення обсягу навчальних даних здатні помітно підвищити точність аналізу, особливо в задачах тонального аналізу.

Нарешті, модель XLNet, описана у публікації “XLNet: Generalized Autoregressive Pretraining for Language Understanding”, поєднує властивості авторегресивного й двонапрявленого навчання. Це дозволяє їй досягати високих результатів у задачах розуміння тексту, що робить її перспективним інструментом для емоційного аналізу складних повідомлень.

2.2 Оцінка актуальності та новизни

Сучасний стан досліджень у галузі NLP засвідчує високу актуальність розробок на базі трансформерів, оскільки вони дають змогу суттєво поліпшити показники точності у низці ключових завдань, зокрема семантичному та емоційному аналізу тексту. Це особливо помітно в контексті стрімкого зростання обсягів інформації, яку необхідно обробляти автоматично у соціальних мережах, інформаційних порталах та різноманітних аналітичних системах. Авторами розглянутих робіт наголошується, що класифікація за допомогою трансформерів швидко стає де-факто стандартом для розв’язання широкого спектра лінгвістичних завдань, витісняючи методи на базі рекурентних нейронних мереж чи традиційних алгоритмів машинного навчання.

Актуальність зазначених досліджень також пов’язана з різноманітністю мовних і культурних контекстів, в яких застосовуються трансформери. Хоча на ранніх етапах їхнього розвитку переважали англійські корпуси, нині з’являється все більше моделей, адаптованих до інших мов, у тому числі з урахуванням складних морфологічних особливостей. Такі тенденції сприяють активному пошуку нових ідей для покращення багатомовних моделей, розширюючи їх функціональність у різноманітних прикладних сценаріях. Це підтверджує, що навіть якщо новітні архітектури трансформерів є “зрелими” для англійського

середовища, все ще існує значний простір для інновацій у напрямку адаптації до менш поширених мов або спеціалізованих доменів.

Новизна більшості проаналізованих робіт полягає в удосконаленні та оптимізації механізмів попереднього тренування: дослідники постійно експериментують із вибором гіперпараметрів, специфікацією вхідних даних і розробкою спеціалізованих підходів до навчання. Такі варіації часто дають змогу підвищити продуктивність без суттєвого збільшення витрат на обчислення, що є вкрай важливим для практичного використання систем. Крім того, у контексті емоційного аналізу дедалі помітніший внесок робіт, котрі фокусуються на комплексній ідентифікації специфічних емоцій, а не лише визначенні позитивної чи негативної тональності. Використання розширених емоційних класифікаторів, як у дослідженні GoEmotions набуває особливого значення для прикладних сфер, де точне розуміння настрою користувача дозволяє створювати персоналізовані рекомендації, поліпшувати роботу сервісів підтримки клієнтів чи вчасно виявляти ознаки потенційних конфліктів.

Отже, актуальність та новизна залучених джерел полягають у переході до більш комплексного та масштабованого використання трансформерів для аналізу великих текстових масивів, а також у розробці нових методів, які забезпечують глибше розуміння семантичних і емоційних складових. Такий активний прогрес у дослідженнях свідчить про те, що галузь залишатиметься одним із пріоритетних напрямків штучного інтелекту, здатного відчутно впливати на автоматизацію та якість комунікацій у цифровому середовищі.

2.3 Висновки з огляду

Проаналізовані джерела виявили спільну тенденцію до широкого впровадження трансформерів у задачі семантичного та емоційного аналізу тексту. Основною причиною такого поширення є високі результати, які демонструють моделі на базі механізму самоуваги, а також їхня здатність уніфікувати процеси попередньої підготовки й застосування в різних прикладних сценаріях. Що стосується безпосереднього впливу на тему дослідження, то зібрані відомості

свідчать про зростаюче визнання емоційної складової в інтеракціях користувачів із цифровими платформами. Це підтверджують експерименти з різними модифікаціями BERT, GPT, XLNet і T5, які демонструють здатність уловлювати не лише загальну тональність, а й тонкі відтінки емоцій.

Водночас результати літературного огляду засвідчили існування низки прогалин, що потребують подальшого дослідження. Зокрема, велика частина існуючих розробок зорієнтована переважно на англійськомовні корпуси, а багатомовні моделі, хоч і розвиваються, ще не завжди гарантують однаково високу точність для інших мов, особливо тих, що мають складну граматику чи обмежену кількість наявних наборів даних.

Необхідність подальших досліджень зумовлена і тим, що емоційний аналіз часто обмежується трьома чи п'ятьма базовими категоріями, тоді як життєві ситуації вимагають глибшої градації настроїв і ширшого спектра можливих емоцій. Деякі роботи роблять крок у цьому напрямку, пропонуючи великі й детально анотовані датасети, проте загального стандарту або усталеної методики ще не склалося. Також залишаються відкритими питання адаптації моделей трансформерів до специфічних галузей (медицина, право, освітнє середовище), де використання унікальної термінології та контекстуальних знань може потребувати розробки спеціалізованих підмоделей чи гібридних підходів.

Таким чином, літературний огляд окреслив поточні здобутки й визначив найважливіші напрямки, які варто досліджувати далі. Ступінь розробленості теми підтверджує її потенціал як для академічних досліджень, так і для прикладних розробок. З урахуванням виявлених прогалин наступні кроки можуть передбачати не лише покращення параметрів уже наявних моделей і збільшення мовного різноманіття навчальних корпусів.

Окрім того, не менш важливо звернути увагу на етичні аспекти використання технологій емоційного аналізу, зокрема питання приватності, упередженості моделей та потенційного маніпулювання емоціями користувачів. Врахування цих аспектів під час розробки і застосування систем забезпечить більш відповідальне і прозоре використання штучного інтелекту в суспільстві.

Отже, комплексний підхід, що поєднує технічні інновації, міждисциплінарні дослідження та етичні стандарти, є ключем до подальшого розвитку та широкого впровадження трансформерів у задачах семантичного й емоційного аналізу тексту. Такий підхід дозволяє не лише вдосконалити самі моделі з технічної точки зору — підвищити точність, стійкість до шуму, інтерпретованість і адаптивність до нових контекстів, — але й сприяє створенню більш справедливих і безпечних систем у взаємодії з користувачами.

Залучення знань із суміжних дисциплін дозволяє краще зрозуміти природу емоційної реакції людини, особливості сприйняття текстової інформації, а також виявити культурні й індивідуальні відмінності в емоційному забарвленні мови. Це, своєю чергою, відкриває можливості для побудови більш персоналізованих і чутливих до контексту моделей.

3 ПОСТАНОВКА ЗАДАЧІ

3.1 Визначення тематики та кінцевих результатів

Магістерська робота присвячена вивченню трансформерних нейронних мереж, які застосовуються для емоційного та семантичного аналізу текстових даних у сучасному інформаційному середовищі. Метою дослідження є проведення серії експериментів, спрямованих на виявлення найбільш ефективних методів обробки природної мови, зокрема для визначення тональності та змістових зв'язків. У межах роботи планується всебічне тестування, яке допоможе виявити сильні сторони та обмеження цих моделей у різних прикладних ситуаціях.

3.2 Обґрунтування вибору методів дослідження

У контексті завдань семантичного й емоційного аналізу тексту ключову роль відіграють методи, здатні одночасно розпізнавати точний зміст повідомлення та нюанси його емоційного забарвлення. Трансформери довели свою перевагу над попередніми архітектурами, такими як рекурентні нейронні мережі і класичні методи машинного навчання, завдяки здатності ефективно враховувати контекст на рівні всього речення або навіть цілого тексту. Така здатність базується на механізмі самоуваги, що дає змогу моделі «звертати увагу» на різні фрагменти тексту залежно від їхньої взаємодії між собою.

Під час розроблення експериментів доцільно обирати вже попередньо навчені моделі (наприклад, BERT, RoBERTa, GPT або XLNet), оскільки вони зазвичай пропонують високу початкову точність і можуть бути досить швидко адаптовані до конкретного набору даних або предметної галузі шляхом донавчання. Цей підхід знижує вимоги до обсягів корпусу, адже значна частина лінгвістичних закономірностей «засвоєна» моделлю завдяки глобальним наборам даних (наприклад, мільярдам токенів англійської мови). Окрім того, трансформери підтримують широке коло метрик оцінювання, що дає змогу провести всебічний кількісний аналіз різних аспектів якості — від семантичної відповідності до здатності розпізнавати точні емоційні категорії.

Для отримання максимально об'єктивних результатів дослідження заплановано зробити експерименти з трансформерами. Статистична обробка підсумкових показників (точність, повнота, F1-міра) допоможе визначити, наскільки отримані результати узгоджуються з гіпотезами про ефективність трансформерів у комплексній обробці природної мови. Також передбачається проведення невеликих порівняльних експериментів, де обрані трансформер-архітектури зіставлятимуться з класичними методами та гібридними рішеннями, які поєднують особливості різних підходів. Це дозволить чіткіше окреслити переваги й недоліки кожного методу.

3.3 Обмеження дослідження

Оскільки трансформери є одними з найсучасніших і найпотужніших інструментів глибинного навчання, у процесі їхнього застосування можуть виявлятися певні обмеження, пов'язані з доступністю та якістю ресурсів. Одним із ключових питань є достатній обсяг і різноманітність даних. Навіть найкраще оптимізована модель не здатна продемонструвати свої можливості, якщо навчальний корпус виявиться однорідним, неповним або нерепрезентативним для тієї сфери, де вона має бути використана. Це особливо актуально у випадку аналізу емоцій, де для кожної категорії (наприклад, іронія, сарказм) потрібно мати значну кількість прикладів.

Високі обчислювальні вимоги трансформерів також створюють певні труднощі, зокрема, потребу в наявності потужних графічних процесорів чи кластерних обчислювальних платформ. Якщо технічні можливості будуть обмеженими, час навчання та експериментів може суттєво зрости, що вплине на загальну швидкість отримання результатів.

Не менш важливою є проблема пояснюваності, оскільки навіть успішні результати, отримані від «чорної скриньки», можуть викликати питання щодо прозорості роботи системи. Дослідник або користувач часто потребує зрозуміти, чому модель класифікує певне речення як сумне чи радісне, особливо у чутливих областях (медицина, психологія, соціальні мережі з великою кількістю вразливих

груп). У контексті різних культурних норм таке пояснення стає ще більш складним, адже відповідна фраза у певному культурному середовищі може мати зовсім інше емоційне навантаження.

3.4 Ресурси для виконання проєкту

Для проведення цього дослідження вкрай важливо мати доступ до актуальних і різноманітних текстових корпусів, де кожен приклад містить анотації, що відповідають конкретній меті — наприклад, вказівку на емоційну категорію або семантичну роль.

З технічного погляду важливо мати програмне середовище, яке дасть змогу проводити експерименти в гнучкому форматі. Найбільш доречним вибором виглядає Python із бібліотеками Hugging Face Transformers, PyTorch чи TensorFlow, де є готові інструменти для роботи з передтренованими моделями та масштабування обчислень.

Результати фінального дослідження потребують ретельної візуалізації й аналізу з використанням відповідних бібліотек (Matplotlib, Seaborn), що посилить наочність і робитиме підсумки зрозумілішими для сторонніх зацікавлених осіб.

4 ТЕОРЕТИЧНЕ ДОСЛІДЖЕННЯ

4.1 Трансформери у семантичному та емоційному аналізі

Розвиток трансформерних архітектур істотно змінив підходи до аналізу природної мови, надавши змогу ефективніше обробляти текстові дані. На відміну від попередніх моделей, які покладалися на послідовну обробку слів (зокрема, рекурентні нейронні мережі), трансформери аналізують всю вхідну послідовність одночасно. Це дозволяє уникати втрат контексту на великих відстанях і краще відстежувати взаємозв'язки між словами, навіть якщо вони перебувають далеко одне від одного.

Центральним компонентом трансформерів є механізм self-attention, який дає змогу кожному елементу тексту взаємодіяти з усіма іншими, незалежно від їхнього порядку в реченні. Це забезпечує моделі здатність враховувати контекст на глобальному рівні та формувати глибші уявлення про зміст тексту.

У сфері семантичного аналізу трансформери демонструють здатність ідентифікувати смислові структури, концепти та лексичні залежності між словами. Багатоголовий механізм уваги, притаманний цим моделям, дозволяє виявляти паралельні зв'язки, що полегшує розпізнавання сутностей, граматичних конструкцій і смислових нюансів у реченні. Також трансформери вирізняються стабільністю під час навчання — зокрема, завдяки використанню резидуальних з'єднань та шарів нормалізації, які сприяють кращій збіжності навіть на великих обсягах даних.

Що стосується емоційного аналізу, трансформери відкривають можливості для виявлення складних емоційних реакцій, які не завжди виражаються очевидними словами. Вони враховують широкий контекст, розподілений у кількох реченнях, що критично важливо для розпізнавання прихованих намірів, іронії чи сарказму. Така здатність робить ці моделі надзвичайно корисними в практичних задачах — від фільтрації контенту до створення адаптивних систем, чутливих до емоцій користувача.

Крім того, архітектура трансформерів підтримує паралельну обробку, що суттєво пришвидшує тренування моделей та забезпечує ефективне використання великих корпусів текстів. Це, у свою чергу, сприяє побудові більш потужних і гнучких систем обробки мови.

У підсумку, трансформери стали універсальним інструментом для розв'язання широкого спектра NLP-завдань. Вони поєднують точність, масштабованість і глибоке розуміння мовного контексту — як семантичного, так і емоційного — і продовжують знаходити застосування в різноманітних галузях: від комунікаційних сервісів до медицини й автоматизованої аналітики.

4.2 Обрані моделі для дослідження

У рамках дослідження планується проаналізувати низку моделей, побудованих на трансформерній архітектурі, серед яких основний фокус спрямований на BERT, RoBERTa та GPT. Ці моделі реалізують різні стратегії попереднього навчання й мають специфічні риси, що визначають їхню ефективність у задачах семантичного розбору й виявлення емоцій у текстах.

Модель BERT (Bidirectional Encoder Representations from Transformers) запровадила концепцію двонапрявленого оброблення контексту, що дозволяє моделі враховувати інформацію як зліва направо, так і з протилежного боку одночасно. Завдяки цьому BERT здатна точніше інтерпретувати значення слів залежно від їх оточення. У процесі навчання використовується масковане мовне моделювання (Masked Language Modeling), коли частина токенів у реченні замінюється на спеціальний символ [MASK], а модель намагається їх відновити. У початковій версії також був застосований механізм Next Sentence Prediction для вивчення взаємозв'язку між парами речень, хоча в подальших дослідженнях його доцільність була поставлена під сумнів.

RoBERTa (Robustly Optimized BERT Approach) — це модифікація BERT, яка усуває компонент NSP і замість нього впроваджує динамічне маскування токенів під час навчання. Завдяки цьому модель стикається з різними варіантами контексту на кожній епосі, що сприяє кращій узагальнюваності. Додатково RoBERTa

тренувалася довше, з використанням більших обсягів текстових даних та оптимізованих гіперпараметрів, що позитивно вплинуло на результати в широкому спектрі завдань, включно з класифікацією емоцій і розпізнаванням сутностей.

На відміну від BERT-подібних моделей, GPT реалізує генеративний підхід: кожне нове слово прогнозується на основі попередніх. Така послідовна структура дозволяє моделі ефективно відтворювати логіку мовлення, що робить її особливо корисною для обробки діалогів і прогнозування реакцій у контекстуально насичених ситуаціях. GPT добре справляється з визначенням загального емоційного фону тексту, хоча її унікальність полягає саме в побудові послідовного, а не двонапрявленого контексту.

Окрім цих моделей, варто звернути увагу на альтернативні архітектури, що адаптовані до обмежених ресурсів або поєднують риси різних підходів. Зокрема, DistilBERT пропонує спрощену й більш легку версію BERT, досягаючи компромісу між точністю та швидкістю завдяки техніці дистиляції знань — коли компактна модель навчається на поведінці потужнішої. XLNet, своєю чергою, поєднує ідеї автогресивного прогнозування з перевагами двонапрявленого контексту, пропонуючи альтернативу традиційним рішенням.

Дослідження має на меті зіставити продуктивність моделей BERT, RoBERTa та GPT у завданнях семантичного й емоційного аналізу, використовуючи спільний корпус текстів та єдину методику оцінювання. Це дозволить встановити, наскільки виправданим є використання ресурсомістких моделей типу RoBERTa у порівнянні з менш вимогливими, як-от DistilBERT. Особливу увагу буде приділено здатності моделей точно передавати значення в контексті, розпізнавати багатозначні лексеми та складні синтаксичні конструкції, а також виявляти тонкі емоційні відтінки, включаючи іронію та сарказм. Для цього передбачається проведення серії експериментів із різними характеристиками вхідного тексту: довжиною речень, варіативністю синтаксису та словниковим розмаїттям.

4.3 Критерії та методи комплексного оцінювання результатів

В рамках дослідження буде проведено низку експериментів для оцінки ефективності трансформерних моделей (BERT, RoBERTa, GPT) у задачах семантичного та емоційного аналізу текстових даних. Основними критеріями оцінювання виступають такі показники, як точність, повнота та F1-міра, які широко застосовуються у задачах класифікації. Важливо також розуміти, як розраховуються ці метрики і які обмеження вони можуть мати у певних контекстах.

Показник точності (*precision*) характеризує відсоток правильно визначених позитивних результатів серед усіх передбачених як позитивні. Цей критерій особливо важливий, коли необхідно зменшити кількість хибнопозитивних спрацьовувань.

Формула набуває вигляду 4.1:

$$Precision = \frac{TP}{TP + FP} \quad (4.1)$$

де TP – кількість істинно позитивних передбачень,

FP – помилково позитивні передбачення.

Показник повноти (*recall*) показує, яку частку реальних позитивних прикладів модель змогла правильно ідентифікувати у тестовому наборі. Цей критерій є особливо корисним, коли необхідно мінімізувати пропуски важливих категорій, наприклад, токсичних чи негативних повідомлень. Повнота обчислюється за формулою 4.2:

$$Recall = \frac{TP}{TP + FN} \quad (4.2)$$

де TP – кількість істинно позитивних передбачень,

FN – помилково негативні передбачення.

Для досягнення балансу між точністю й повнотою зазвичай звертаються до F1-міри[11], що є гармонійним середнім цих двох показників. Обчислення F1-міри дає більш зважену оцінку загальної ефективності моделі, коли важливо одночасно враховувати кількість помилкових тривог і «пропусків».

Формула для F1-міри має вигляд 4.3:

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4.3)$$

де Precision – точність,

Recall – повнота.

Коли у текстовому корпусі спостерігається суттєва диспропорція між кількістю прикладів певних емоційних або семантичних класів, постає задача коректного оцінювання моделі. У таких умовах важливо застосовувати відповідні стратегії усереднення метрик.

Micro-F1 використовує сукупні значення істинно позитивних, хибнопозитивних і хибнонегативних передбачень по всіх категоріях, обчислюючи загальну ефективність без розподілу на окремі класи. Цей підхід є доцільним у випадках, коли основним критерієм є точність у цілому, незалежно від дисбалансу класів.

У протилежність йому, macro-F1 розглядає кожен клас окремо: для кожного обчислюється точність, повнота та F1, після чого ці значення усереднюються. Така методика дозволяє краще виявити, як модель працює з менш представленими або складними для розпізнавання категоріями. Наприклад, якщо корпус має великий обсяг «нейтральних» повідомлень, це може приховати слабкі результати для інших емоцій, що спотворює загальне враження про якість класифікації.

Окрім суто кількісних показників, цінним інструментом є аналіз хибних класифікацій. Дослідження помилкових передбачень — зокрема в контексті емоцій, що легко плутаються, або текстів із подвійним змістом, як-от іронія чи сарказм, — допомагає виявити обмеження моделі. Конфузійна матриця, яка фіксує найчастіші

помилки між класами, є додатковим джерелом для виявлення таких тенденцій. Наприклад, якщо емоція «радість» часто визначається як «нейтральність», це може свідчити про недостатню чутливість моделі до позитивного контексту або про недоліки в розмітці.

Загалом, поєднання кількісного оцінювання з якісним аналізом результатів дозволяє сформулювати глибше розуміння сильних і слабких сторін моделі, а також окреслити напрями для подальших удосконалень у сфері автоматичного емоційного й семантичного аналізу.

4.4 Класичні методи

У межах дослідження доцільно розглянути й традиційні підходи машинного навчання, які будуть використані як базові моделі для порівняння з трансформерними архітектурами. Таке порівняння дозволить з'ясувати, у чому саме полягають переваги новітніх методів при виконанні завдань семантичного та емоційного аналізу текстів, а також виявити ситуації, у яких класичні алгоритми залишаються конкурентоспроможними.

Одним із таких методів є алгоритм опорних векторів (Support Vector Machine, SVM). Він добре зарекомендував себе як у задачах класифікації, так і у випадках регресії та виявлення аномалій. Принцип дії SVM полягає у побудові роздільної гіперплощини у просторі ознак, що забезпечує максимальну відстань між представниками різних класів. Таке формулювання допомагає підвищити здатність моделі до узагальнення, навіть коли дані містять шум. Алгоритм орієнтований на роботу з невеликими або середніми за обсягом наборами даних, де границя між класами є досить чіткою. На відміну від підходів, що мінімізують помилки класифікації, SVM прагне збільшити так звану маржу між класами, що робить його більш стійким до варіативності вхідних даних.

Ще одним класичним методом, який буде використано для порівняння, виступає логістична регресія. Цей статистичний інструмент традиційно застосовується для задач бінарної класифікації. Незважаючи на свою назву, логістична регресія не передбачає прогнозування безперервних значень. Натомість

вона оцінює ймовірність належності об'єкта до певного класу, використовуючи сигмоїдну функцію, яка перетворює лінійну комбінацію ознак у значення в діапазоні від 0 до 1. Завдяки своїй простоті, високій швидкості навчання та легкій інтерпретованості, логістична регресія часто виконує роль базової моделі для оцінювання ефективності складніших алгоритмів.

Включення цих методів до експериментальної частини дослідження дозволить на практиці оцінити різницю між класичними та сучасними підходами до обробки текстової інформації, зокрема в контексті розпізнавання складних мовних структур та емоційних відтінків.

4.5 Особливості навчання моделей

Для успішної адаптації обраних трансформерних моделей (таких як BERT, RoBERTa, GPT) до задач семантичного й емоційного аналізу тексту застосовується двоетапний підхід, що забезпечує гнучкість і високу якість результатів. На першому етапі використовують уже попередньо навчені варіанти цих моделей, які були треновані на великих корпусах загального призначення, зокрема таких, як Common Crawl[12] чи BooksCorpus[13]. Завдяки цьому моделі набувають глибокого розуміння синтаксису, граматики та базової семантики природної мови.

Другий етап передбачає донавчання (fine-tuning) на цільовому наборі даних, що містить анотовані приклади, спеціально підготовлені для розв'язання завдань класифікації тональності (sentiment analysis), емоційного спектру (emotion detection) або семантичного групування (semantic categorization). Це дозволяє моделі переналаштуватися на специфіку конкретної задачі або домену, зберігаючи при цьому базові мовні знання.

У процесі донавчання моделей BERT чи RoBERTa, які є бінаправленими трансформерами (bidirectional transformers), часто додається класифікаційний шар (наприклад, feed-forward neural network) на базі [CLS]-токена — спеціального символу, що репрезентує весь вхідний текстовий фрагмент. Такий підхід дозволяє узагальнити інформацію про весь текст. У більш складних випадках або при роботі з довшими фрагментами доцільно розглядати середні значення векторів токенів у

певному вікні контексту, або застосовувати механізми attention-масок, щоб сконцентрувати увагу моделі на найбільш релевантних фрагментах.

Щодо GPT, яка є автогресивною моделлю та генерує текст послідовно токен за токеном, її адаптація до задач класифікації передбачає дещо інший підхід. Найчастіше використовують або останній прихований стан (hidden state) останнього токена як агрегований представник усього тексту, або додають спеціальний класифікаційний блок, що аналізує повний вектор виходу. GPT зберігає високу мовну компетентність завдяки попередньому масштабному тренуванню, що робить її здатною ефективно узагальнювати складні мовні патерни.

Ключовим аспектом успішного донавчання є ретельний підбір гіперпараметрів. Серед них — кількість епох навчання (epochs), розмір пакета даних (batch size), початковий темп навчання (learning rate), схема його розкладання (learning rate scheduler), рівень регуляризації (наприклад, dropout чи weight decay), а також стратегія заморожування або оновлення окремих шарів моделі. Оптимізація цих параметрів дозволяє досягнути балансу між перенавчанням (overfitting) і недонавчанням (underfitting), а також забезпечити стабільну збіжність моделі на цільовому наборі даних.

Особливу увагу слід приділити специфіці емоційного аналізу. У багатьох випадках емоції не зводяться лише до позитивного, негативного чи нейтрального тону. Моделі мають навчитися розпізнавати широкий спектр емоцій: страх, гнів, радість, сум, відразу, здивування тощо. Для цього застосовуються підходи багатокласової (multi-class) класифікації, де кожна категорія емоції відповідає окремому вихідному нейрону, або ж багатоміткової (multi-label) класифікації — якщо висловлювання може одночасно належати до кількох емоційних категорій. Такий підхід особливо актуальний у випадках подвійних емоцій або складних почуттів, як-от суміш гніву та розчарування.

Окрему складність становлять нетипові прояви емоцій, зокрема іронія, сарказм чи контекстуальні алюзії. Ці явища вимагають від моделі здатності до глибшого контекстуального аналізу, а іноді — й інтеграції зовнішніх знань (наприклад, світової енциклопедичної інформації чи культурних кодів). Тому

важливо, щоб навчальний набір був репрезентативним — включав не лише часті приклади, а й рідкісні, складні емоційні стани, а також випадки з подвійною інтерпретацією.

Крім того, важливо проводити попередню обробку (preprocessing) даних, що включає очищення тексту, нормалізацію (лематизація, зведення до нижнього регістру), а також вирівнювання класів у випадку сильної нерівноваги в розподілі емоцій. Для боротьби з дисбалансом можна використовувати такі техніки, як oversampling рідкісних класів, undersampling домінуючих або застосування спеціалізованих функцій втрат (наприклад, weighted cross-entropy або focal loss).

У підсумку, завдяки донавчанню з урахуванням мовної специфіки, контексту задачі та психологічної складності емоційних реакцій, трансформерні моделі стають потужними інструментами для аналізу семантики й емоцій у текстах різного стилю та жанру. Вони здатні не лише розпізнавати лексичні патерни, а й моделювати тонкі нюанси людських емоцій, що відкриває широкі можливості для застосування в соціальних медіа, аналізі зворотного зв'язку користувачів, психолінгвістиці, маркетингових дослідженнях та інших сферах.

4.6 Дані для навчання трансформерів

При виборі даних для тренування трансформерних моделей у завданнях семантичного та емоційного аналізу надзвичайно важливо забезпечити різноманітність тем, жанрів і стилістичних особливостей текстів, а також враховувати широкий спектр емоційних станів. Це необхідно, щоб моделі могли адекватно обробляти як найпоширеніші емоції — позитив, негатив, нейтральність — так і менш розповсюджені, але не менш важливі відтінки, такі як здивування, розчарування, сарказм або злість. Ігнорування рідкісних емоційних категорій часто призводить до заниженої здатності системи виявляти складні почуття, що значно погіршує якість аналізу в реальних сценаріях.

Крім того, семантична структура текстів може значно варіюватися в залежності від жанру й формату: новинні матеріали, огляди товарів, пости в соціальних мережах, наукові статті, діалоги або форуми — кожен із цих типів має

свої унікальні мовні патерни, лексичні особливості і стилістичні нюанси. Тому важливо формувати навчальні корпуси, які комбінують різноманітні джерела, забезпечуючи багатогранність лінгвістичних прикладів, що допомагає моделі краще узагальнювати отримані знання і адаптуватися до різних контекстів.

Серед широко використовуваних відкритих ресурсів для емоційного аналізу особливо варто відзначити датасет GoEmotions[14], який пропонує деталізовану класифікацію за 27 різними емоційними категоріями. Це дає змогу моделі не лише відрізнити базові емоції, а й розпізнавати більш тонкі психологічні стани, що значно розширює можливості емоційного аналізу. Для задач, орієнтованих на оцінку загальної полярності тексту — позитивної, негативної або нейтральної — корисними будуть набори даних Sentiment140, IMDB[15], Yelp Reviews, які містять великий обсяг анотованих текстів із чіткими позначками тональності. Вони широко застосовуються у дослідженнях аналізу настроїв, особливо в контексті відгуків про продукти або послуги, що робить їх корисними для побудови систем рекомендацій і автоматичної модерації.

Для комплексного навчання моделей корисно також включати специфічні корпуси, орієнтовані на виявлення сарказму, іронії чи складних контекстуальних залежностей, адже такі нюанси часто є викликом навіть для найсучасніших трансформерних архітектур. У зв'язку з цим, рекомендується поєднувати загальні набори даних із більш спеціалізованими, щоб покращити якість розпізнавання емоцій у реальних, багатосарових текстах.

Отже, успішне навчання моделей семантичного й емоційного аналізу значною мірою залежить від якості та різноманітності вихідних даних, що визначає їхню здатність адаптуватися до широкого спектра мовних завдань і реалістичних сценаріїв застосування.

5 ПРОВЕДЕННЯ ЕКСПЕРИМЕНТУ

5.1 Набір даних

У рамках експериментального дослідження були використані два різні за характером корпуси текстів, що дозволяє охопити ширший спектр лінгвістичних явищ — від емоційного забарвлення коротких висловлювань до логічно структурованих розгорнутих текстів. Такий підхід дає змогу повніше оцінити ефективність трансформерних моделей у завданнях емоційного та семантичного аналізу.

Перший набір даних — GoEmotions — представляє собою розмічену вибірку коротких коментарів, зібраних із різних онлайн-ресурсів. Цей корпус відзначається великою кількістю емоційних міток: кожен текст може належати одразу до кількох з 27 категорій, серед яких не лише базові емоції, як-от радість чи гнів, а й більш складні та нюансовані стани, як-от тривога, подив, вдячність чи сором. Така багатогранність дає змогу моделювати реалістичні емоційні патерни, що характерні для природного мовлення. Анотація проводилася із залученням декількох оцінювачів, що значно підвищує її достовірність. Крім того, багатолейбловий формат розмітки дозволяє враховувати складну емоційну палітру, яка часто зустрічається в реальних текстах.

Другий корпус — IMDb Large Movie Review Dataset — включає в себе 50 тисяч повнотекстових рецензій на фільми, які публікувалися користувачами популярної платформи IMDb. Усі відгуки мають чітку тональну класифікацію: позитивну або негативну, що дозволяє зосередитись на аналізі сентименту без змішаних або нейтральних прикладів. Набір рівномірно розподілений на навчальну та тестову вибірки, без перетину між ними, що забезпечує коректну оцінку здатності моделей до узагальнення. Тексти у цьому корпусі довгі й деталізовані, що дозволяє перевірити, як алгоритми справляються з контекстною зв'язністю, аргументацією автора та зміною тональності в межах одного повідомлення.

Комбіноване використання GoEmotions і IMDb дозволяє протестувати моделі в умовах різної довжини тексту, стилістики та складності змісту. Якщо GoEmotions

орієнтований на аналіз щільних емоційних реакцій у стислій формі, то IMDb дає змогу оцінити обробку змістовно насичених, структурованих повідомлень. Такий баланс сприяє формуванню повнішого уявлення про можливості трансформерів щодо інтерпретації текстів з емоційної та змістової точки зору, що є важливим кроком до створення більш гнучких і точних NLP-систем.

5.2 Підготовка даних

У процесі підготовки даних для навчання трансформерних моделей було проведено низку базових, але критично важливих етапів попередньої обробки текстів. Спочатку здійснювалося очищення корпусів — з видаленням усіх технічних та візуальних артефактів, що не мають змістового навантаження. До таких елементів належали HTML-розмітка, емодзі, службові символи або залишки форматування. Це дозволило отримати чистий текстовий матеріал, придатний для подальшого машинного аналізу.

Наступною фазою стала токенізація — процес перетворення тексту на окремі фрагменти, які моделі можуть обробляти. У випадку моделей BERT і RoBERTa застосовувалася технологія WordPiece, що дозволяє ділити слова на морфологічно релевантні частини, зберігаючи структурну інформацію про лексеми. Для GPT було використано алгоритм Byte-Pair Encoding (BPE), який, хоч і функціонує за іншим принципом, також розбиває текст на компактні одиниці для ефективнішої репрезентації. Обидва підходи дозволяють адаптувати мовні особливості під векторне представлення, що є ключовим для успішного навчання.

У відповідності до архітектурних вимог кожної моделі, в текст додавалися спеціальні службові токени — наприклад, [CLS] для маркування початку текстової послідовності або [SEP] для розділення фрагментів у межах одного прикладу. Ці елементи виконують навігаційну функцію та сприяють кращому розумінню моделі щодо структури вхідних даних.

Після завершення попередньої обробки, датасети були розбиті на три логічні частини: тренувальну (близько 80% прикладів), валідаційну (приблизно 10%) і тестову (решта 10%). Такий поділ дає змогу не лише навчати модель на основному

обсязі даних, але й паралельно відстежувати її поведінку на незалежній валідаційній вибірці, що допомагає точно налаштувати параметри навчання та уникати ефекту перенавчання. Підсумкова оцінка якості проводиться на тестовій частині, яка не використовувалась у жодному з попередніх етапів. Це забезпечує об'єктивне уявлення про здатність моделі працювати з новими, невідомими даними.

5.3 Результати моделей

Нижче наведено приклад коду скрипту, який ілюструє базову схему використання бібліотеки Hugging Face Transformers для задачі класифікації тексту. У даному прикладі здійснюється завантаження попередньо натренованої моделі (зокрема, bert-base-uncased), яка адаптується до задачі класифікації з певною кількістю цільових класів (у прикладі — 2). За допомогою відповідного токенизатора текст перетворюється на формат, придатний для обробки моделлю, після чого здійснюється тренування із відстеженням основних метрик якості: точності (precision), повноти (recall) та F1-міри.

```
import torch
from transformers import AutoTokenizer,
AutoModelForSequenceClassification, Trainer, TrainingArguments
from sklearn.metrics import precision_recall_fscore_support
from sklearn.model_selection import train_test_split
from datasets import Dataset, load_dataset
import numpy as np
import pandas as pd
# 1. Завантажуємо IMDb датасет (train частина)
dataset = load_dataset("imdb")
df = pd.DataFrame(dataset['train'])
# 2. Збалансоване розбиття на train та validation
train_df, valid_df = train_test_split(df, test_size=0.2,
random_state=42, stratify=df['label'])
# 3. Обираємо модель та токенизатор
model_name = "bert-base-uncased"
tokenizer = AutoTokenizer.from_pretrained(model_name)
model =
AutoModelForSequenceClassification.from_pretrained(model_name,
num_labels=2)
# 4. Функція токенизації
def tokenize_function(examples):
    return tokenizer(examples["text"], padding="max_length",
truncation=True, max_length=128)
# 5. Перетворюємо pandas dataframe у datasets.Dataset та токенизуємо
train_data = Dataset.from_pandas(train_df).map(tokenize_function,
batched=True)
```

```

valid_data = Dataset.from_pandas(valid_df).map(tokenize_function,
batched=True)
# 6. Видаляємо зайві колонки та встановлюємо формат PyTorch
train_data = train_data.remove_columns(["text"]).with_format("torch")
valid_data = valid_data.remove_columns(["text"]).with_format("torch")
# 7. Функція для обчислення метрик
def compute_metrics(eval_pred):
    logits, labels = eval_pred
    preds = np.argmax(logits, axis=-1)
    precision, recall, f1, _ =
precision_recall_fscore_support(labels, preds, average='macro')
    return {'precision': precision, 'recall': recall, 'f1': f1}
# 8. Параметри тренування
training_args = TrainingArguments(
    output_dir="./results",
    evaluation_strategy="epoch", # Оцінюємо після кожної епохи
    num_train_epochs=2,
    per_device_train_batch_size=8,
    per_device_eval_batch_size=8,
    logging_dir="./logs",
    logging_steps=10,
    save_strategy="epoch"
)
# 9. Ініціалізуємо Trainer
trainer = Trainer(
    model=model,
    args=training_args,
    train_dataset=train_data,
    eval_dataset=valid_data,
    compute_metrics=compute_metrics
)
# 10. Запускаємо навчання
trainer.train()
# 11. Оцінка моделі
eval_results = trainer.evaluate()
print(eval_results)

```

Паралельне тестування декількох трансформерних архітектур (BERT, RoBERTa, GPT) здійснювалося шляхом зміни змінної `model_name` на відповідні конфігурації (`roberta-base`, `gpt2`, тощо), з урахуванням особливостей кожної моделі.

Результати експерименту були продемонстровані у таблиці 5.1.

Таблиця 5.1 – Результати практичних експериментів (таблиця виконана самостійно)

Модель	Набір даних	Точність	Повнота	F1-міра
	х		а	

Кінець таблиці 5.1

Логістич на регресія	GoE	67.2%	63.1%	65.0 %
Логістич на регресія	IMDb	72.4%	69.8%	71.1 %
SVM	GoE	70.4%	66.7%	68.5 %
SVM	IMDb	75.8%	72.9%	74.3 %
BERT	GoE	83.1%	80.2%	81.6 %
BERT	IMDb	80.5%	76.8%	78.6 %
RoBERT a	GoE	85.0%	82.3%	83.6 %
RoBERT a	IMDb	82.8%	79.4%	81.0 %
GPT	GoE	80.5%	78.0%	79.2 %
GPT	IMDb	78.5%	75.1%	76.8 %

У першій частині експериментального дослідження було здійснено порівняння продуктивності трансформерних моделей із традиційними методами машинного навчання в контексті текстової класифікації. Проведений аналіз виявив помітну перевагу моделей на базі трансформерів, таких як RoBERTa та GPT, над класичними алгоритмами, зокрема логістичною регресією та SVM, за усіма ключовими критеріями оцінювання.

Найвищі результати продемонструвала RoBERTa, яка впевнено впоралася з обома наборами даних — GoEmotions та IMDb — завдяки здатності до глибокого контекстуального аналізу та виявлення тонких мовних нюансів. GPT також показала високий рівень точності, особливо у роботі з об'ємними й структурованими текстами набору IMDb, що свідчить про її ефективність у завданнях, де важлива цілісність тексту.

Отримані дані дозволили ідентифікувати декілька напрямів для вдосконалення підходів. Зокрема, у GoEmotions було зафіксовано сильний переки

у частоті класів: певні емоції були представлені значно рідше. Для вирішення цього виклику впроваджено Focal Loss — спеціальну функцію втрат, яка допомагає моделі більше фокусуватися на складних прикладах замість тих, що класифікуються безпомилково. У випадку IMDb, де спостерігалася невелика перевага позитивних рецензій, забезпечено баланс за допомогою стратифікованого розбиття набору на підвибірки для навчання, валідації та тестування.

Паралельно було реалізовано механізми аугментації даних. Для коротких повідомлень GoEmotions використано методику EDA — набір простих прийомів, що включають синонімічну заміну, випадкове виключення другорядних слів і перефразування, що збільшило різноманіття текстових формулювань.

У випадку IMDb, навпаки, застосовувався метод машинного зворотного перекладу, який передбачає трансляцію тексту через проміжні мови з подальшим поверненням до оригіналу. Це дозволило отримати нові формулювання без втрати первісного сенсу.

Довгі тексти IMDb висунули окремі вимоги до архітектури моделей. Щоб обійти обмеження на довжину вхідної послідовності, для BERT і RoBERTa впроваджено Sliding Window Attention — підхід, що дозволяє обробляти довгі фрагменти з частковим перекриттям для збереження контексту. У GPT було збільшено граничну довжину оброблюваного контексту, що дало змогу охопити більш повні текстові блоки й поліпшити якість аналізу рецензій із кількох абзаців.

У сукупності застосовані стратегії привели до зростання загальної точності, зменшення впливу нерівномірного розподілу класів і підвищення стійкості моделей до різноманітності мовних форм. У наступних етапах дослідження планується розглянути ефективність комбінованих підходів і поглибити аналіз поведінки моделей у різних контекстах класифікаційних задач.

Отже, після всіх покращень результати можна побачити у таблиці 5.2.

Таблиця 5.2 – Результати практичних експериментів після покращення (таблиця виконана самостійно)

Логістич на регресія	GoE	68.9%	65.0%	66.9 %
Логістич на регресія	IMDb	74.1%	71.2%	72.6 %
SVM	GoE	71.8%	68.5%	70.1 %
SVM	IMDb	77.5%	74.8%	76.1 %
BERT	GoE	86.0%	83.7%	84.8 %
BERT	IMDb	83.2%	80.1%	81.6 %
RoBERT a	GoE	88.1%	85.6%	86.8 %
RoBERT a	IMDb	85.9%	82.9%	84.4 %
GPT	GoE	82.8%	80.5%	81.6 %
GPT	IMDb	81.3%	78.6%	79.9 %

Слід зазначити, що помилки класифікації найчастіше виникали в емоціях зі схожим семантичним забарвленням (наприклад, розчарування та сум, злість та образа). Візуалізація через confusion matrix виявила, що навіть RoBERTa періодично плутає суміжні категорії. Це вказує на потребу більш точного маркування та можливої подальшої сегментації емоцій за підгрупами.

Також час навчання GPT був удвічі більшим порівняно з BERT, що пов'язано з її генеративною природою. Найшвидше навчання демонструвала BERT, тоді як RoBERTa була золотою серединою за якістю та витратами.

Ще можна додати, що експериментальне зменшення learning rate до $2e-5$ для RoBERTa дозволило уникнути перенавчання й покращити F1-міру на IMDb на 1.3%. Також зменшення batch size дозволило точніше відслідковувати дрібні зміни в градієнтах, особливо на малих класах у GoEmotions.

Не можна не згадати, що було використано техніку t-SNE для візуалізації векторних представлень емоційних класів. Класи з чітко визначеним лексичним ядром (наприклад, "радість" або "гнів") утворювали компактні кластери, тоді як більш складні та контекстозалежні емоції мали значне накладання.

Отже, завдяки впровадженню цілого комплексу покращень, зокрема балансування класів, розширення навчальної вибірки та оптимізації обробки довгих текстів, вдалося досягти помітного покращення результатів класифікації тексту за допомогою трансформерних моделей. Зокрема, середня точність таких моделей, як BERT, RoBERTa та GPT, зросла на 2–4% порівняно з початковими експериментами без додаткових оптимізацій. Найбільш суттєвий приріст був зафіксований у задачах з набором даних GoEmotions, де завдяки використанню функції втрат Focal Loss та прийомів аугментації (EDA), F1-міра для рідкісних емоційних категорій зросла майже на 6%, що є вагомим досягненням у контексті мультикласової класифікації з дисбалансом.

Окрім підвищення метрик якості, було відзначено покращення стабільності процесу навчання моделей, що виявлялося у зниженні флуктуацій втрат і більш плавній динаміці збіжності. Це свідчить про те, що моделі стали менш чутливими до шуму в даних та краще узагальнюють на нових прикладах. Водночас, навіть класичні підходи, як-от логістична регресія та метод опорних векторів (SVM), демонстрували незначне покращення продуктивності, що ще раз підкреслює важливість ретельної підготовки даних і правильного налаштування експериментів незалежно від обраного підходу.

Загалом, отримані результати підтверджують доцільність використання сучасних трансформерних архітектур у задачах аналізу тексту.

ВИСНОВКИ

У процесі дослідження було проведено детальний аналіз наукових джерел, що стосуються застосування моделей нейронних мереж типу трансформерів у семантичному та емоційному аналізі природної мови. Вивчення фундаментальних праць, таких як "Attention Is All You Need" (Vaswani et al.) та "BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding" (Devlin et al.), а також більш пізніх розробок — RoBERTa, GPT, XLNet і T5 — дозволило сформувавши міцну теоретичну базу і зрозуміти переваги та особливості цих архітектур. Зокрема, механізм самоуваги забезпечує якісне врахування контексту й складних лінгвістичних залежностей, що є надзвичайно важливим для розпізнавання тонких емоційних відтінків у тексті.

Аналіз актуальності підтвердив, що трансформери швидко стають стандартом у завданнях обробки природної мови, випереджаючи традиційні методи, такі як логістична регресія чи SVM. Попередньо навчені моделі успішно переносять знання з великих текстових корпусів у специфічні прикладні задачі, що дозволяє досягати високої продуктивності навіть за умови обмеженої кількості анотованих даних. Важливою складовою є балансування і ретельна підготовка вибірок, що значно підвищує якість навчання.

У рамках дослідження було з'ясовано, що трансформерні моделі, зокрема BERT, RoBERTa та GPT, демонструють високий рівень ефективності при розв'язанні задач, пов'язаних із розпізнаванням змісту та емоційної складової текстів. Їхня здатність одночасно враховувати як локальні, так і глобальні контекстуальні залежності забезпечує істотну перевагу над традиційними алгоритмами машинного навчання, зокрема методами на кшталт логістичної регресії та SVM. Це набуває особливого значення в ситуаціях, де важливо точно виявити непрямі емоційні сигнали або складну семантичну структуру висловлювань.

Результати експериментів показали, що трансформери, натреновані на великих корпусах текстів, зберігають здатність до переносу знань у нові контексти

навіть при обмеженій кількості розмічених прикладів. Запровадження стратегій балансування класів і різноманітних підходів до збільшення навчальних даних дозволило значно покращити якість класифікації. Водночас, вплив конкретної архітектури залишився помітним: RoBERTa, як правило, забезпечувала кращу точність у класифікаційних задачах, тоді як GPT краще впоралася з обробкою довгих текстів і генеративними аспектами обробки природної мови.

Загалом результати підкреслюють практичну придатність трансформерів для побудови сучасних систем текстової аналітики, які можуть бути застосовані для автоматичної фільтрації контенту, виявлення ризикованих повідомлень або оцінювання емоційного тону тексту. Однак попри високу продуктивність, лишається низка викликів: моделі потребують значних обчислювальних ресурсів, а процес ухвалення рішень залишається малозрозумілим для користувача. У майбутньому планується дослідити шляхи підвищення ефективності трансформерних архітектур за збереження їх точності, а також адаптувати їх до вимог міжкультурного аналізу та багатомовного середовища.

Підсумовуючи, трансформерні підходи відкривають нові горизонти у сфері аналізу текстів, роблячи можливим створення більш інтелектуальних та гнучких систем для роботи з природною мовою.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Що таке обробка природної мови (NLP) [Електронний ресурс] // Metinvest. – 2021. - Режим доступу: <https://metinvest.digital/ru/page/1052> (дата звернення: 01.05.2024).
2. Назаренко Д. С., Афанасьєва І. В., Голян Н. В. Нейромережевий підхід для емоційного розпізнавання тексту // Біоніка інтелекту. - 2019. Т. 1, № 92. С. 9–14.
3. Назаренко Д. С., Афанасьєва І. В., Голян Н. В. Investigation of the Deep Learning Approaches to Classify Emotions in Texts // CEUR Workshop Proceedings. - 2021. Вип. 2870. С. 206–224.
4. BERT [Електронний ресурс]. – 2024. – Режим доступу: <https://h2o.ai/wiki/bert/> (дата звернення: 02.05.2025).
5. What is GPT (generative pretrained transformer) [Електронний ресурс]. – 2024. – Режим доступу: <https://www.ibm.com/think/topics/gpt> (дата звернення: 04.05.2025).
6. Introducing RoBERTa Base Model: A Comprehensive Overview [Електронний ресурс]. – 2023. – Режим доступу: https://medium.com/@marketing_novita.ai/introducing-roberta-base-model-a-comprehensive-overview-330338afa082 (дата звернення: 06.05.2025).
7. Attention Is All You Need [Електронний ресурс]. – 2017. – Режим доступу: <https://arxiv.org/abs/1706.03762> (дата звернення: 08.05.2025).
8. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding [Електронний ресурс] // arXiv. – 2018. – Режим доступу: <https://arxiv.org/abs/1810.04805> (дата звернення: 09.05.2025).
9. GoEmotions: A Dataset of Fine-Grained Emotions [Електронний ресурс] // arXiv. – 2020. – Режим доступу: <https://arxiv.org/abs/2005.00547> (дата звернення: 11.05.2025).
10. □ Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer [Електронний ресурс] // arXiv. – 2019. – Режим доступу: <https://arxiv.org/abs/1910.10683> (дата звернення: 13.05.2025).

11. Назаренко Д. С., Афанасьева И. В., Голян Н. В. Investigation of the Deep Learning Approaches to Classify Emotions in Texts // CEUR Workshop Proceedings. – 2021. – Vol. 2870. – С. 206–224.
12. Common Crawl [Электронный ресурс]. – 2024. – Режим доступа: <https://commoncrawl.org/> (дата звернения: 14.05.2025).
13. BookCorpus – a large collection of free novel books [Электронный ресурс]. – 2024. – Режим доступа: <https://paperswithcode.com/dataset/bookcorpus> (дата звернения: 16.05.2025).
14. GoEmotions Dataset released by Google [Электронный ресурс]. – 2024. – Режим доступа: <https://www.kaggle.com/datasets/debarshichanda/goemotions> (дата звернения: 17.05.2025).
15. IMDB Dataset of 50k Movie Reviews [Электронный ресурс]. – 2024. – Режим доступа: <https://www.kaggle.com/datasets/lakshmi25npathi/imdb-dataset-of-50k-movie-reviews> (дата звернения: 19.05.2025).
16. Kremenenko K. 2025_M_PI_IPZm-23-2_Kremenenko_K_O [Электронный ресурс] // GitHub. – Режим доступа: https://github.com/5haki6/2025_M_PI_IPZm-23-2_Kremenenko_K_O (дата звернения 05.06.2025).

**ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ ЗА НАУКОВИМИ НАПРЯМАМИ
КЕРІВНИКА ТА НАУКОВЦІВ КАФЕДРИ ПРОГРАМНОЇ ІНЖЕНЕРІЇ**

2. Назаренко Д. С., Афанасьєва І. В., Голян Н. В. Нейромережевий підхід для емоційного розпізнавання тексту // Біоніка інтелекту. 2019. Т. 1, № 92. С. 9–14.
3. Назаренко Д. С., Афанасьєва І. В., Голян Н. В. Investigation of the Deep Learning Approaches to Classify Emotions in Texts // CEUR Workshop Proceedings. 2021. Вип. 2870. С. 206–224.
11. Назаренко Д. С., Афанасьєва І. В., Голян Н. В. Investigation of the Deep Learning Approaches to Classify Emotions in Texts // CEUR Workshop Proceedings. – 2021. – Vol. 2870. – С. 206–224.