

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ  
ТАРАСА ШЕВЧЕНКА**  
**Факультет інформаційних технологій**

Кафедра технологій управління

Спеціальність 122 – Комп’ютерні науки,  
освітня програма «Інформаційна аналітика та впливи»

**КВАЛІФІКАЦІЙНА РОБОТА МАГІСТРА**

на тему:

“Розробка системи класифікації фейкових новин за допомогою методів Data Science”

**Студента 2-го курсу групи ІАВ-21**

Абрамова Кірілла Вікторовича

**Науковий керівник**

д.т.н., доцент кафедри  
технологій управління

Хлевна Юлія Леонідівна

\_\_\_\_\_  
(підпис студента)

\_\_\_\_\_  
(дата)

\_\_\_\_\_  
(підпис)

**Попередній захист:**

\_\_\_\_\_  
(Висновок: «До захисту в Екзаменаційній комісії»)

Завідувач кафедри  
технологій управління

\_\_\_\_\_  
(підпис)

\_\_\_\_\_  
(прізвище, ініціали)

\_\_\_\_\_  
(дата)

**Київ – 2025**

**КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ  
ІМЕНІ ТАРАСА ШЕВЧЕНКА  
Факультет інформаційних технологій**

Кафедра технологій управління

Освітньо-кваліфікаційний рівень Магістр

Спеціальність 122 - Комп'ютерні науки

Освітня програма Інформаційна аналітика та впливи

**ЗАТВЕРДЖУЮ**

Завідувач кафедри

професор Морозов В.В.

\_\_\_\_\_

«\_\_\_» \_\_\_\_\_ 2025 р.

**ЗАВДАННЯ**

**НА ВИКОНАННЯ КВАЛІФІКАЦІЙНОЇ РОБОТИ**

Студент Абрамов Кірілл Вікторович

Група ІАВ-21

**1. Тема кваліфікаційної роботи**

Розробка системи класифікації фейкових новин за допомогою методів Data Science.

Затверджена наказом по від «\_\_\_»\_\_\_\_\_ 2025р. № \_\_\_\_\_.

**2. Строк подання студентом готової роботи - “19” травня 2025р.**

**3. Цільова установка та вихідні дані до роботи**

Дослідження методів класифікації фейкових новин та розробка гібридного підходу з використанням методів машинного навчання та нейронних мереж, створення автоматизованої системи виявлення дезінформації в текстових даних.

#### 4. Зміст роботи

Робота містить вступ, огляд наукової літератури щодо проблеми поширення фейкових новин, аналіз існуючих методів їх виявлення та класифікації. Відповідно до визначеної мети здійснюється постановка завдання та розробка методології дослідження. Робота містить опис традиційних та нейромережових підходів до класифікації текстів, а також розробку власного гібридного методу. Представлено обґрунтування вибору моделей та методів дослідження, опис реалізації системи та результати її тестування. Робота містить висновки, список використаних джерел та додатки.

#### 5. Перелік графічного матеріалу (слайдів)

Загалом робота містить 20 рисунків, 17 таблиць, 15 слайдів.

Перелік слайдів: Актуальність обраної теми (1 слайд), Об'єкт і предмет дослідження (1 слайд), Мета та задачі дослідження (1 слайд), Аналіз існуючих підходів (2 слайди), Архітектура розробленої системи (2 слайди), Реалізація методів класифікації (3 слайди), Результати експериментів (2 слайди), Практичне впровадження (2 слайди), Висновки (1 слайд)

#### 6. Календарний план виконання роботи:

№	Назва частин роботи	%	Виконання роботи	
			За планом	Фактично
1.	Вибір теми кваліфікаційної магістерської роботи, дослідження актуальності обраної теми, наявності наукових матеріалів з теми	3	01.10.24	01.10.24
2.	Протокол кафедри ТУ про затвердження тем дипломних робіт та призначення наукових керівників	2	27.12.24	27.12.24

3.	Формування переліку Нормативних матеріалів, літератури з проблематики дипломної роботи	10	10.01.25	12.01.25
4.	Складання розгорнутого плану виконання та представлення кваліфікаційної роботи	5	18.01.25	25.01.25
5.	Ознайомлення наукового керівника з розгорнутим планом кваліфікаційної роботи. Внесення змін.	5	29.01.25	30.01.25
6.	Підготовка розділу 1 «». Визначення наповнення розділу, висновків.	10	12.02.25	13.02.25
7.	Підготовка розділу 2 «». Визначення наповнення розділу, висновків.	14	10.03.25	10.03.25
8.	Підготовка розділу 3 «». Визначення наповнення розділу, висновків.	14	02.04.25	02.04.25
9.	Підготовка розділу 4 «». Визначення наповнення розділу, висновків.	13	09.04.25	09.04.25
10.	Оформлення кваліфікаційної роботи. Підготовка аналізу результатів роботи, висновків. Перевірка відповідності початковій меті та задачам роботи	15	12.04.25	12.04.25
11.	Передача кваліфікаційної роботи науковому керівникові	2	20.04.25	23.04.25
12.	Передача кваліфікаційної роботи рецензенту для рецензування	2	01.05.25	01.05.25
13.	Попередній захист кваліфікаційної роботи	5	13.05.25	13.05.25

Дата видачі завдання «\_\_\_\_\_» \_\_\_\_\_ 2025 р.

Керівник роботи: д.т.н., доцент Хлевна Ю.Л

---

(підпис)

Завдання прийняв до виконання студент групи ІАВ-21 Абрамов К.В

---

(підпис)

## ЗМІСТ

АНОТАЦІЯ	9
ПЕРЕЛІК ВИКОРИСТАНИХ СКОРОЧЕНЬ	11
ВСТУП	13
РОЗДІЛ 1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ	17
1.1. Аналіз впливу фейкових новин на суспільство та інформаційне середовище	17
1.2. Огляд існуючих методів та технологій обробки тексту	22
1.2.1. Класифікація текстових даних	22
1.2.2. Наївний класифікатор Баєса	24
1.2.3. Поліноміальний наївний класифікатор Баєса	25
1.2.4. Нейронні мережі	27
1.2.5. Трансформери і BERT	28
1.3 Сучасні автоматизовані системи виявлення фейків та їх недоліки	30
1.3.1 Існуючі системи	30
1.3.2. Обмеження існуючих підходів	32
1.4. Постановка задачі розробки системи класифікації	33
1.4.1. Формулювання задачі класифікації	33
1.4.2. Функціональні вимоги до системи	34
1.4.3. Нефункціональні вимоги	34
1.4.4. Метрики оцінки ефективності	35
1.4.5. Обмеження та припущення	36
1.5. Висновки до першого розділу	36
РОЗДІЛ 2. МЕТОДОЛОГІЯ КЛАСИФІКАЦІЇ ФЕЙКОВИХ НОВИН	38
2.1. Методи обробки текстових даних	38
2.2. Методи та технології розв'язання завдань кваліфікаційної роботи	40
2.2.1. Статистичні методи до класифікації	40
TF-IDF векторизація та її особливості	40
Наївний Баєс як класифікатор текстових даних	42
2.2.2 Нейромережеві методи з використанням трансформерів	45
Архітектура та принципи роботи BERT	45
Перенавчання (fine-tuning) BERT для класифікації	47
Техніка LoRA для оптимізації навчання моделі	49

2.3	Вибір технології та засоби програмної реалізації	51
2.4.	Метрики оцінки ефективності моделей класифікації	53
2.4.1.	Базові метрики класифікації	53
2.4.2.	Розширені метрики та методи до оцінки	55
2.4.3.	Особливості застосування метрик для оцінки виявлення фейкових новин	56
2.5.	Висновки до другого розділу	58
РОЗДІЛ 3. РОЗРОБКА ТА РЕАЛІЗАЦІЯ СИСТЕМИ КЛАСИФІКАЦІЇ		60
3.1.	Аналіз та підготовка набору даних	60
3.1.1.	Опис використаного набору даних WELFake	60
3.1.2.	Дослідницький аналіз даних (EDA)	61
3.1.3.	Попередня обробка текстових даних	62
3.2.	Побудова моделей	63
3.2.1.	Архітектура моделі TF-IDF та Наївного Баєса	63
3.2.2.	Процес навчання та параметризація TF-IDF та Наївного Баєса	65
3.2.3.	Навчання та розгортання моделі BERT	66
3.2.4.	Оцінка ефективності та аналіз помилок	74
3.3.	Порівняльний аналіз реалізованих підходів	76
3.3.1.	Порівняння метрик точності та продуктивності	76
3.3.2.	Аналіз обчислювальних вимог та часу навчання	78
3.3.3.	Аналіз переваг та недоліків кожного підходу	79
3.4	Тестування системи на реальних даних. Процес отримання результатів	81
3.4.1.	Підготовка даних для тестування	81
3.4.2.	Аналіз результатів роботи системи	86
3.4.	Висновки до третього розділу	90
РОЗДІЛ 4. ПРАКТИЧНЕ ЗАСТОСУВАННЯ РОЗРОБЛЕНОЇ СИСТЕМИ		92
4.1.	Опис і візуалізація інтерфейсу кінцевого користувача	92
4.1.1.	Проектування системи класифікації фейкових новин	95
Інтеграція системи класифікації у прикладне середовище		95
4.2.	Оцінка практичної цінності розробленої системи	98
4.2.1.	Потенційні сфери застосування	100
4.2.2.	Обмеження поточної реалізації	103
4.3.	Рекомендації щодо використання та подальшого розвитку	108
4.4.	Висновки до четвертого розділу	108

ВИСНОВКИ	110
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ	112
ДОДАТКИ	118
Додаток А. Текст програмного коду реалізації основних алгоритмів	118
Додаток Б. Результати експериментальних досліджень	121

## АНОТАЦІЯ

### КИЇВСЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ТАРАСА ШЕВЧЕНКА

Факультет інформаційних технологій

Кафедра технологій управління

Спеціальність 122 - Комп'ютерні науки,

освітня програма "Інформаційна аналітика та впливи"

Дипломна робота магістра Абрамова Кірілла Вікторовича.

Тема роботи - «Розробка системи класифікації фейкових новин за допомогою методів Data Science».

**Мета** дипломної роботи магістра - проведення дослідження існуючих методів та технологій Data Science для підвищення ефективності виявлення фейкових новин шляхом розробки та застосування системи автоматичної класифікації та створення гібридного підходу, що поєднує традиційні методи машинного навчання з сучасними нейромережевими архітектурами.

**Об'єкт дослідження** - процес автоматичної класифікації текстових даних та виявлення дезінформації в новинному контенті з використанням методів машинного навчання.

**Предмет дослідження** - методи та технології класифікації текстових даних для виявлення фейкових новин.

**Наукова новизна** роботи - полягає в тому, що запропоновано гібридний підхід до класифікації фейкових новин, який поєднує швидкий попередній аналіз на основі статистичних методів з глибоким аналізом за допомогою оптимізованої моделі BERT. Розроблено інтерактивну інформаційну систему, що надає можливість швидкої обробки великого масиву новин в режимі онлайн з перевіркою категоризацію цих новин на правдиві та фейкові.

У роботі досліджуються існуючі методи та технології класифікації текстових даних, включаючи статистичні методи та нейромережеві архітектури, а також техніки оптимізації їх застосування для виявлення фейкових новин. Розробляється система, яка заснована на гібридному підході до класифікації фейкових новин, який поєднує швидкий попередній аналіз на основі статистичних методів з глибоким аналізом за допомогою оптимізованої моделі BERT. Проведено оптимізацію обчислювальних ресурсів за допомогою техніки LoRA.

Дипломна робота складається зі вступу, чотирьох розділів, висновків, списку використаних джерел та додатків. Загальний обсяг роботи становить \_ сторінок, містить \_ рисунків, \_ таблиць та перелік посилань з \_ джерел.

**Ключові слова:** Штучний інтелект(AI), методи машинного навчання, глибинне навчання, нейронні мережі, обробка природної мови(NLP), гібридний підхід, класифікація текстів, BERT, TF-IDF, Наївний Баєс, LoRA, фейкові новини, дезінформація.

## ПЕРЕЛІК ВИКОРИСТАНИХ СКОРОЧЕНЬ

**API** - Application Programming Interface (інтерфейс прикладного програмування)

**AUC** - Area Under the Curve (площа під кривою)

**BERT** - Bidirectional Encoder Representations from Transformers (двонаправлені представлення кодувальника на основі трансформерів)

**CI/CD** - Continuous Integration/Continuous Deployment (безперервна інтеграція/безперервне розгортання)

**CPU** - Central Processing Unit (центральний процесор)

**EDA** - Exploratory Data Analysis (дослідницький аналіз даних)

**ELK** - Elasticsearch, Logstash, Kibana (стек технологій для роботи з логами)

**GANs** - Generative Adversarial Networks (генеративно-змагальні мережі)

**GPU** - Graphics Processing Unit (графічний процесор)

**JSON** - JavaScript Object Notation (нотація об'єктів JavaScript)

**JWT** - JSON Web Token (веб-токен JSON)

**LoRA** - Low-Rank Adaptation (низькорангова адаптація)

**ML** - Machine Learning (машинне навчання)

**MLM** - Masked Language Model (маскована мовна модель)

**NB** - Naive Bayes (наївний басів класифікатор)

**NER** - Named Entity Recognition (розпізнавання іменованих сутностей)

**NLP** - Natural Language Processing (обробка природної мови)

**NPS** - Net Promoter Score (індекс споживчої лояльності)

**NSP** - Next Sentence Prediction (прогнозування наступного речення)

**RAM** - Random Access Memory (оперативна пам'ять)

**REST** - Representational State Transfer (передача репрезентативного стану)

**ROC** - Receiver Operating Characteristic (робоча характеристика приймача)

**ROI** - Return on Investment (рентабельність інвестицій)

**SSD** - Solid State Drive (твердотільний накопичувач)

**SVM** - Support Vector Machine (метод опорних векторів)

**TF-IDF** - Term Frequency-Inverse Document Frequency (частота терміну-обернена частота документа)

**TPU** - Tensor Processing Unit (тензорний процесор)

**WELFake** - Web of English Language Fake News (набір даних англомовних фейкових новин)

## ВСТУП

У сучасному світі поширення неправдивих новин набуває масового характеру. Це стає серйозною загрозою для демократичних інститутів, економічної стабільності та суспільної безпеки.

Безумовно, брехня, неправдиві новини існували завжди. Але саме в час розвитку різноманітних засобів інформації, швидкості її розповсюдження і масового доступу мільярдів людей до цих джерел, фейкові новини часто мають критичне значення. Фейкові новини, особливо в соціальних мережах, охоплюють одразу значно більшу аудиторію, ніж правдиві і достовірні, поширюються з шаленою, вірусною швидкістю, впливають на прийняття будь-яких рішень, на будь-яких рівнях. Економічні втрати від дезінформації можуть сягати мільярдів доларів щорічно.

Особливої гостро проблема стає в ситуації сучасних геополітичних викликів, де дезінформація використовується, як інструмент гібридної війни. Традиційні методи виявлення фейкових новин, що базуються на ручній перевірці фактів, не здатні впоратися з величезними обсягами інформації в цифровому просторі. В середньому одна особа, що займається перевіркою достовірності новини, може перевірити до декількох десятків новин за день, тоді як кількість потенційно фейкових новин сягає десятків тисяч. Це створює потребу в розробці автоматизованих систем класифікації, здатних ефективно виявляти дезінформацію в великих масштабах.

**Науково прикладна задача** полягає в розробці системи для класифікації фейкових новин. Необхідно забезпечити високу точність класифікації, система повинна працювати в режимі реального часу, обробляючи великі обсяги даних з мінімальною затримкою. Також важливо забезпечити можливість адаптації системи до нових форм дезінформації, які постійно еволюціонують.

**Метою дослідження** є проведення дослідження існуючих методів та технологій Data Science для підвищення ефективності виявлення фейкових

новин шляхом розробки та застосування системи автоматичної класифікації та створення гібридного підходу, що поєднує традиційні методи машинного навчання з сучасними нейромережевими архітектурами.

**Завдання дослідження:**

- дослідження існуючих підходів, методів, виявлення їх недоліків, місць для вдосконалення;
- розробка підходу до аналізу та класифікації фейкових новин, використовуючи існуючі методи та технології;
- проектування та розробка архітектури системи класифікації, що поєднує традиційні методи машинного навчання та нейромережеві підходи;
- реалізувати та оптимізувати алгоритми класифікації на основі TF-IDF, Наївного Баєса та BERT;
- розробити та застосувати техніку оптимізації навчання моделі BERT за допомогою методу LoRA;
- провести експериментальне дослідження ефективності розробленої системи на реальних даних та оцінити ефективність;

**Об'єктом дослідження** є процес автоматичної класифікації текстових даних та виявлення дезінформації в новинному контенті з використанням методів машинного навчання.

**Предметом дослідження** є методи та технології класифікації текстових даних для виявлення фейкових новин, включаючи статистичні підходи та глибинні нейронні мережі.

**Методи дослідження:**

1. методи обробки природної мови для аналізу текстових даних,
2. методи та технології машиного навчання для класифікації текстів,
3. методи глибинного навчання, зокрема трансформерні архітектури,
4. методи оцінки ефективності класифікаторів,

5. методи програмної інженерії для розробки системи та веб інтерфейсу

#### **Зв'язок роботи з науковими темами**

Полягає в інтеграції сучасних підходів аналізу даних у напрямку аналізу тексту, що відповідає пріоритетним напрямкам розвитку науки та техніки в галузі протидії дезінформації. Тематика роботи узгоджується з цілями навчальної програми «Інформаційна аналітика та впливи», та базується на результатах, отриманих під час науково-дослідної практики.

**Наукова новизна** одержаних результатів полягає в тому, що запропоновано гібридний підхід до класифікації фейкових новин, який поєднує швидкий попередній аналіз на основі статистичних методів з глибоким аналізом за допомогою оптимізованої моделі BERT. Розроблено інтерактивну інформаційну систему, що надає можливість швидкої обробки великого масиву новин в режимі онлайн з перевіркою категоризації цих новин на правдиві та фейкові.

**Практичне значення** одержаних результатів полягає у створенні готової до впровадження системи автоматичної класифікації фейкових новин. Результати кваліфікаційної роботи можуть бути використані в різних сферах діяльності, в тому числі в інформаційній, безпековій, військовій галузях. Система автоматичної класифікації фейкових новин забезпечує високу точність класифікації при високій швидкості обробки даних. Удосконалено метод тонкого налаштування моделі BERT шляхом застосування техніки LoRA, що дозволило зменшити обчислювальні вимоги на 60% при збереженні високої точності до 91.5%.

**Апробація результатів дослідження:** основні положення кваліфікаційної роботи були представлені в:

1. доповіді на міжнародній науковій конференції "Urban Transformation in the EU" (17 квітня 2025 року, м. Київ), де було представлено доповідь

"Development of a fake news classification system using Data Science methods",

2. на міжнародному воркшопі "Чат-боти, ігрові технології та штучний інтелект у цифровій освіті студентів" (12-13 травня 2025 року, м. Київ).

## **РОЗДІЛ 1. АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ ТА ПОСТАНОВКА ЗАДАЧІ**

### **1.1. Аналіз впливу фейкових новин на суспільство та інформаційне середовище**

Поняття фейкові новини, фейк-ньюз (Fake news) - це підробка чи імітація новин (маніпулятивне спотворення фактів, дезінформація, яку створено з ігноруванням редакційних норм та правил прийнятих у засобах масової інформації, щодо перевірки правдивості інформації [1]. Саме поняття виникло в англomовному журналістському середовищі ще в кінці 19 сторіччя, а всесвітнього використання набуло після журналісткого розслідування проведеного в середині 2016 році, незадовго до виборів в США.

В епоху інформаційного перенасичення проблема фейкових новин перетворилася на один з найбільш деструктивних факторів, що впливають на суспільну свідомість та демократичні інститути [2, 3].

ВВС виділяє 2 основних види фейків по їх типу:

- неправдиві історії, які публікуються навмисно з різними корисними цілями;
- неправдиві частково, мають певну частку правди, не є повністю точними, коли джерело не перевіряє, або перебільшує отриману інформацію [4].

По характеру впливу фейкові новини можна поділити наступним чином:

1. геополітичний вплив
2. соціально- політичний
3. економічний
4. національно-безпековий
5. релігійний

#### **Соціально-політичні впливи.**

Прикладом впливу в політичній сфері, де дезінформація використовується як інструмент маніпулювання громадською думкою, стали президентські вибори у США 2016 року та референдум щодо виходу Великобританії з Європейського Союзу (Brexit), коли цілеспрямовані дезінформаційні кампанії суттєво вплинули на електоральну поведінку громадян [5, 6].

Соціальні впливи можуть проявлятися в поляризації суспільства, створюючи так звані "інформаційні бульбашки" (filter bubbles), де споживачі інформації потрапляють у замкнені цикли підтвердження власних переконань. Це значно ускладнює формування консенсусу з важливих суспільно-політичних питань. Критичним наслідком цього процесу є підрив демократичних інститутів, які залежать від здатності громадян приймати поінформовані рішення на основі достовірної інформації [7].

#### **Економічні та безпекові аспекти.**

Дослідження показують, що дезінформація щодо публічних компаній може призводити до суттєвих коливань на фондових ринках, спричиняючи втрати у мільярди доларів. Особливо вразливими є фінансовий та енергетичний сектори. Крім прямих фінансових втрат, дезінформація підриває довіру споживачів до брендів та цілих галузей економіки.

#### **Сфера національної безпеки.**

В сфері національної безпеки, фейкові новини стали елементом гібридної війни та інформаційних операцій. Вони використовуються для дестабілізації політичної ситуації, підриву міжнародних союзів та створення атмосфери недовіри між країнами. Кібербезпека також страждає через фішингові атаки та інші види кіберзлочинів, які часто використовують фальшиві новини як "наживку" [8]. По даним Детектор Медіа на 2017 рік найбільш доступні канали для поширення фейків - інтернет-платформи (Reddit, 4chan тощо), соцмережі (Facebook, Twitter та інші) та месенджери (Whatsapp, Facebook Messenger). Непереверену інформацію, поширену через ці канали, можуть підхопити як «класичні» ЗМІ, так і інші сайти [9]. В 2021 році Детектор

Медія додав YouTube. Слід зазначити, що станом на 2025 рік, основними каналами поширення фейків та дезінформації саме в Україні залишаються Telegram, TikTok, X (колишній Twitter), а також Facebook та Instagram. Ці платформи активно використовуються як для політичної пропаганди, так і для шахрайських схем [10].

### **Психологічні механізми сприйняття дезінформації.**

Ефективність фейкових новин значною мірою зумовлена особливостями людської психології. Феномен підтверджувального упередження (confirmation bias) змушує людей надавати перевагу інформації, яка відповідає їхнім існуючим переконанням, навіть якщо ця інформація є хибною [11]. Емоційний компонент фейкових новин - страх, гнів, обурення - активізує систему швидкого мислення, пригнічуючи критичний аналіз [12].

Особливо небезпечним є ефект первинності (primacy effect) - тенденція людей більше пам'ятати та довіряти першій отриманій інформації, навіть після її спростування [13]. Це пояснює, чому спростування фейків часто має обмежену ефективність - когнітивний слід від початкової неправдивої інформації зберігається навіть після ознайомлення з фактами.

Ефект зниження довіри до традиційних джерел інформації також ускладнює боротьбу з фейками. В умовах, коли значна частина населення з недовірою ставиться до офіційних ЗМІ та інституцій, створюється вакуум, який заповнюється альтернативними джерелами різного ступеня достовірності.

### **Виклики у виявленні та протидії.**

Сучасні технології значно спростили створення та масове поширення фейкових новин. Соціальні мережі та рекомендаційні алгоритми, оптимізовані для максимізації залученості користувачів, непропорційно сприяють поширенню емоційно забарвленого контенту, включаючи дезінформацію. Дослідження MIT показало, що фейкові новини поширюються в Twitter у 6 разів швидше, ніж достовірна інформація.

Розвиток технологій штучного інтелекту створив нові інструменти для генерації фейків. Deepfake-технології дозволяють створювати переконливі підробки аудіо та відеоматеріалів, а генеративні мовні моделі можуть продукувати тексти, які складно відрізнити від написаних людиною [14]. Це значно ускладнює процес верифікації інформації та вимагає розробки нових технологічних рішень для виявлення фейків.

Особливо серйозним викликом для систем класифікації фейкових новин є постійна еволюція та адаптація методів дезінформації. Розробники фейкових новин активно вивчають механізми роботи систем виявлення та знаходять способи обходити їх алгоритми.

Слід зазначити, що протидія фейковим новинам створює серйозні юридичні та етичні дилеми для демократичних суспільств. Це пов'язано з необхідністю захисту свободи слова, з одного боку та потребою обмеження дезінформації, з іншого. Що стає складним завданням для законодавців та регуляторів.

Етичні проблеми включають питання відповідальності технологічних платформ та журналістської етики.

### **Приклади досліджень за останні роки.**

Особливої актуальності ця проблема набуває в контексті цифрової трансформації медіа та переходу значної частини новинного споживання в онлайн-середовище, де традиційні механізми контролю якості інформації часто відсутні або неефективні [15].

В зв'язку з тим, що фейкові новини мають великий вплив на суспільство і викликають безліч проблем в різних сферах, багато компаній намагаються знайти шляхи вирішення та проводять безліч досліджень. Це і великі технологічні гіганти, і стартапи, і лабораторії досліджень при університетах.

Дослідження спрямовані на розробку методів для автоматичного виявлення фейкових або маніпулятивних новин в засобах інформації, в тому

числі у соціальних мережах. Це включає використання методів машинного навчання та аналізу тексту для виявлення характерних ознак дезінформації, маніпуляції або недостовірності. Наприклад, дослідження 2019 року «Fake News Detection on Social Media: A Data Mining Perspective» - за допомогою методів машинного навчання та аналізу даних, автори пропонують модель, розроблену на текстових ознаках та соціальній мережевій структурі для ідентифікації фейкових новин [16].

**Palantir Technologies** - американська компанія, один з напрямків діяльності - розробка технологій для аналізу текстів в соціальних мережах, розробка програмного забезпечення для аналізу великих об'ємів даних. Один з продуктів компанії - платформа Palantir Gotham, яка розроблена для роботи з різними типами даних, в тому числі текстових повідомлень, включаючи соціальні мережі. Дослідження компанії: розпізнавання намірів і зацікавленості, виявлення фейків та дезінформації, виявлення тематик.

**Google** спільно з підрозділом Jigsaw активно впроваджують стратегії "prebunking" - профілактичні інформаційні кампанії, спрямовані на підвищення обізнаності користувачів щодо маніпулятивних технік [17].

**Британська організація Full Fact** розробила інструмент **Full Fact AI**, який допомагає автоматично виявляти та перевіряти неправдиві твердження. У звіті за 2025 рік Full Fact закликає до посилення регулювання AI-генерованої дезінформації та підкреслює необхідність адаптації законодавства до швидкого розвитку технологій [18].

**Британська компанія Logically** спеціалізується на виявленні та аналізі дезінформаційних кампаній.

Дослідження дезінформації: виявлення та аналіз дезінформації, включаючи розслідування щодо QAnon, Disclose.tv та проросійських наративів після вторгнення в Україну у 2022 році [19].

У 2024 році компанія виявила, що понад 85% запитів до генераторів зображень, таких як Midjourney, DALL-E 2 та Stable Diffusion, призводили до

створення контенту, який може бути використаний для дезінформації. Це дослідження саме попереджає про можливості впливу в соціально-політичній сфері [20].

Дослідження, опубліковане в Nature Human Behaviour у 2025 році, показало, що великі мовні моделі (LLMs), такі як GPT-4, можуть бути більш переконливими, ніж люди, у 64% випадків під час онлайн-дебатів на спірні соціополітичні теми. Це викликає занепокоєння щодо потенційного використання ШІ для маніпуляції громадською думкою [21].

## **1.2. Огляд існуючих методів та технологій обробки тексту**

Проблема класифікації новинного контенту з метою виявлення фейкових новин стимулювала розвиток різноманітних методів та технологій у сфері обробки природної мови та машинного навчання. Ефективна ідентифікація дезінформації вимагає застосування передових алгоритмів аналізу текстових даних, здатних виявляти як явні, так і приховані лінгвістичні ознаки фальшивих новин. Розглянемо ключові методи обробки тексту, які застосовуються при вирішенні даної задачі.

### **1.2.1. Класифікація текстових даних**

Класифікація текстів є фундаментальним завданням обробки природної мови, що лежить в основі багатьох прикладних систем, включаючи виявлення фейкових новин. Методи класифікації текстів можна розділити на дві основні категорії: статистичні методи та методи з машинним навчанням (рис. 1.1). Статистичні методи працюють з попередньо сформульованими гіпотезами і мають обмежені можливості автоматизації, тоді як методи машинного навчання спеціально розроблені для автоматичного виявлення закономірностей у даних.

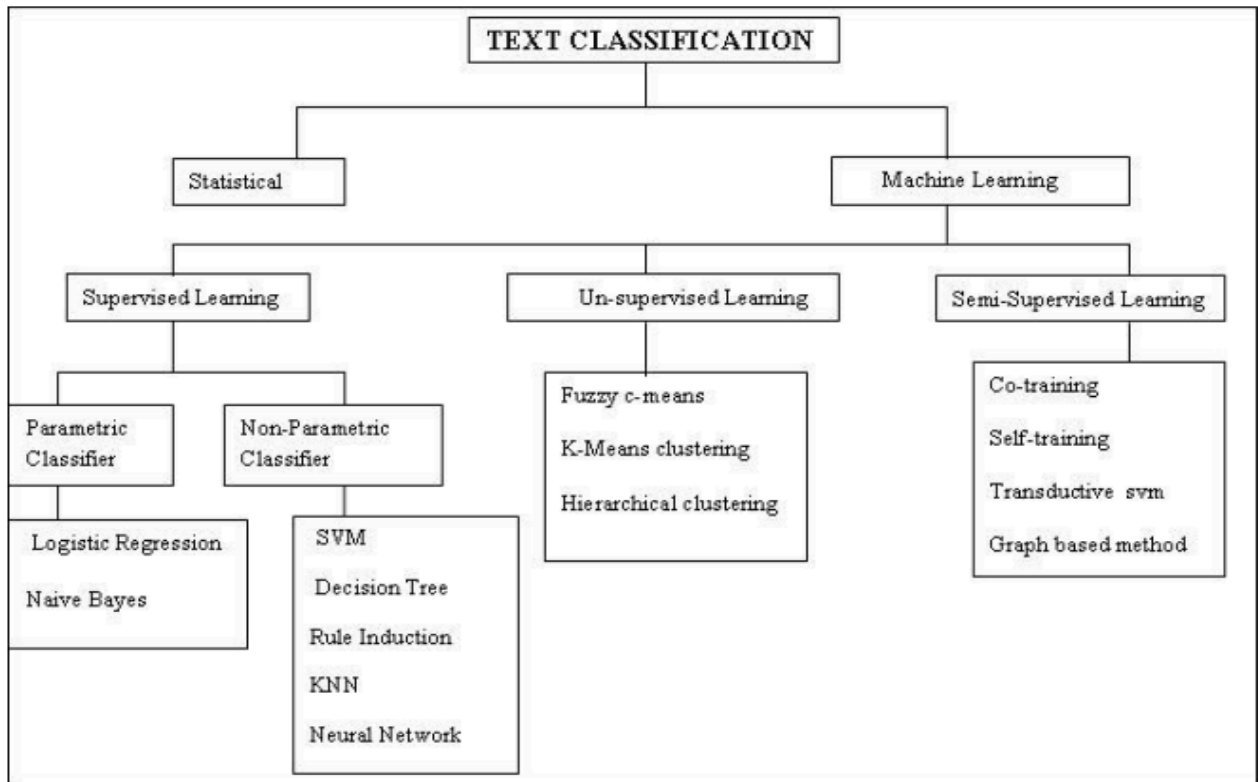


Рисунок 1.1 - Класифікація методів обробки текстових даних (джерело: <https://www.ijikm.org/Volume13/IJIKMv13p117-135Thangaraj3803.pdf>)

Алгоритми машинного навчання для класифікації тексту поділяються на три категорії:

1. **Supervised Learning (навчання з учителем)** - використовує розмічені дані для навчання моделі.
2. **Unsupervised Learning (навчання без учителя)** - працює з нерозміченими даними, виявляючи приховані структури.
3. **Semi-supervised Learning (напівавтоматичне навчання)** - комбінує розмічені та нерозмічені дані.

Серед алгоритмів навчання з учителем виділяють параметричні (логістична регресія, наївний Баєс) та непараметричні методи (SVM, дерева рішень, нейронні мережі) [22]. Для задачі виявлення фейкових новин

найбільшого поширення набули методи на основі Наївного Баєса, векторизації TF-IDF та різноманітні нейромережеві архітектури.

### 1.2.2. Наївний класифікатор Баєса

Наївний класифікатор Баєса - це простий, але потужний ймовірнісний метод, що базується на теоремі Баєса. Цей класифікатор використовується в задачах категоризації документів з 1950-х років і залишається ефективним інструментом для текстової класифікації завдяки своїй обчислювальній ефективності та здатності працювати з обмеженими наборами даних [23].

Основна ідея НБК полягає в обчисленні умовної ймовірності приналежності документа до певного класу на основі наявності в ньому певних слів. Формально, якщо маємо документ  $d$  і клас  $c$ , то за теоремою Баєса:

$$P(c | d) = \frac{P(d | c) \times P(c)}{P(d)} \quad (1.1)$$

де  $P(c|d)$  - ймовірність, що документ  $d$  належить до класу  $c$ ;

$P(d|c)$  - ймовірність спостерігати документ  $d$  за умови, що він належить до класу  $c$ ;

$P(c)$  - апіорна ймовірність класу  $c$ ;

$P(d)$  - ймовірність спостерігати документ  $d$ .

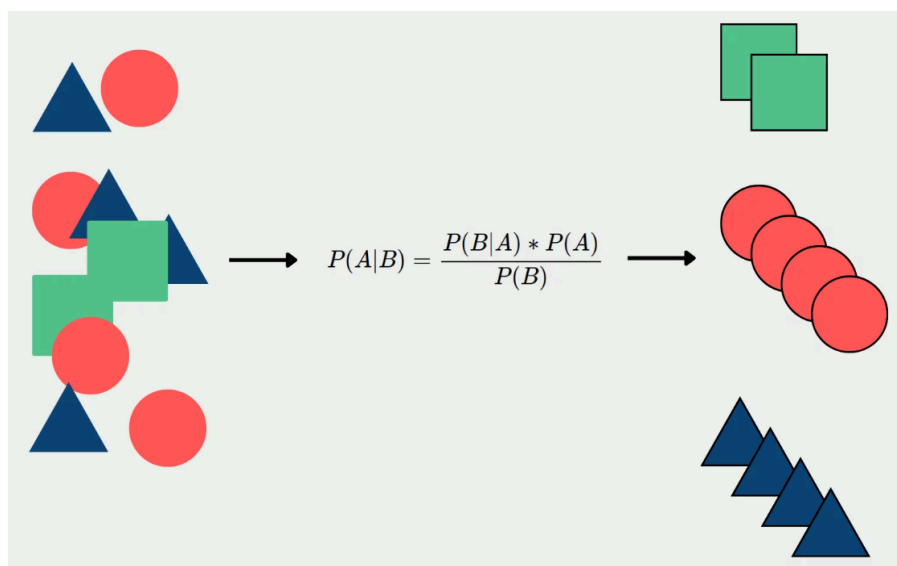


Рисунок 1.2 - Просте представлення наївної баєсівської класифікації (Джерело: <https://databasecamp.de/en/ml/naive-bayes-algorithm> )

Для класифікації документа обираємо клас з максимальною апостеріорною ймовірністю:

$$c_{MAP} = \arg \max_{c \in C} P(d | c) \cdot P(c) = \arg \max_{c \in C} P(x_1, x_2, \dots, x_n | c) \cdot P(c) \quad (1.2)$$

де  $x_1, x_2, \dots, x_n$  - ознаки (слова) документа  $d$ .

"Наївність" класифікатора полягає в припущенні про незалежність ознак (слів) у документі, що значно спрощує обчислення, але рідко відповідає реальності. Незважаючи на це спрощення, даний алгоритм демонструє високу ефективність у багатьох задачах класифікації тексту, включаючи виявлення спаму та фейкових новин.

### 1.2.3. Поліноміальний наївний класифікатор Баєса

Поліноміальний наївний класифікатор Баєса є модифікацією класичного НБК, спеціально адаптованою для роботи з текстовими даними. На відміну від бінарної моделі, яка враховує лише наявність або відсутність слова в документі, поліноміальна модель бере до уваги частоту появи кожного слова [24].

Ймовірність класу  $c$  для документа  $d$  обчислюється за формулою:

$$P(c | d) = \frac{P(c) \prod_{w \in d} P(w | c)^{n_w^d}}{P(d)} \quad (1.3)$$

де  $n_w^d$  - кількість входжень слова  $w$  в документ  $d$ ,

$P(w|c)$  - умовна ймовірність слова  $w$  для класу  $c$ .

Ймовірність  $P(w|c)$  розраховується з використанням згладжування Лапласа для уникнення нульових ймовірностей:

$$P(w | c) = \frac{1 + \sum_{d \in D_c} n_w^d}{k + \sum_{w'} \sum_{d \in D_c} n_{w'}^d} \quad (1.4)$$

де  $k$  - кількість унікальних слів у словнику,

$D_c$  - множина всіх документів класу  $c$ ,

$w'$  - всі можливі слова у словнику.

Поліноміальний НБК ефективно працює з розрідженими даними великої розмірності, характерними для текстових задач, і часто демонструє кращі результати порівняно з іншими варіантами Наївного Баєса при роботі з текстом. Дослідження показують, що при виявленні фейкових новин поліноміальний НБК може досягати точності до 92% при правильному виборі ознак [25].

### 1.2.4. Нейронні мережі

Штучні нейронні мережі представляють собою обчислювальні системи, натхнені структурою та функціонуванням біологічних нейронних мереж. Вони складаються з пов'язаних між собою вузлів (нейронів), організованих у шари, і здатні знаходити складні нелінійні залежності в даних [26].

Основною структурною одиницею нейронної мережі є штучний нейрон, який отримує вхідні сигнали, зважує їх, сумує та застосовує функцію активації для формування вихідного сигналу (рис. 1.3).




Рисунок 1.3 - Схема шару нейронної мережі (Джерело:

<https://medium.com/@cluelessrae/the-perceptron-versus-naive-bayes-99c04c9da0fa> )

Нейронні мережі для аналізу тексту зазвичай мають наступну узагальнену архітектуру:

1. **Вхідний шар** - приймає векторне представлення слів або токенів.
2. **Приховані шари** - обробляють і трансформують вхідні дані, виявляючи ієрархію ознак різного рівня абстракції.
3. **Вихідний шар** - формує кінцевий результат (наприклад, класифікацію).

Глибокі нейронні мережі (Deep Neural Networks) містять кілька прихованих шарів, що дозволяє їм виявляти складні взаємозв'язки в даних. У контексті обробки тексту особливо ефективними є такі архітектури [27]:

1. **Рекурентні нейронні мережі (RNN)** - спеціалізуються на обробці послідовних даних, зберігаючи внутрішній стан (пам'ять).
2. **Довга короткочасна пам'ять (LSTM)** та **Керовані рекурентні блоки** - удосконалені варіанти RNN, здатні запам'ятовувати довгострокові залежності в тексті.
3. **Згорткові нейронні мережі (CNN)** - ефективні для виявлення локальних патернів у тексті, незалежно від їх позиції.
4. **Трансформери** - архітектура на основі механізму уваги, що дозволяє моделі фокусуватися на різних частинах вхідної послідовності.

Перевагою нейронних мереж є їхня здатність до автоматичного вилучення ознак без втручання людини, що особливо цінно для аналізу текстових даних, де ручне конструювання ознак є трудомістким завданням [28].

#### **1.2.5. Трансформери і BERT.**

Проривом у галузі обробки природної мови стало впровадження архітектури Transformer та моделей на її основі, таких як BERT (Bidirectional Encoder Representations from Transformers). На відміну від рекурентних архітектур, Transformer використовує механізм самоуваги (self-attention), що дозволяє моделі фокусуватися на різних частинах вхідної послідовності [29].

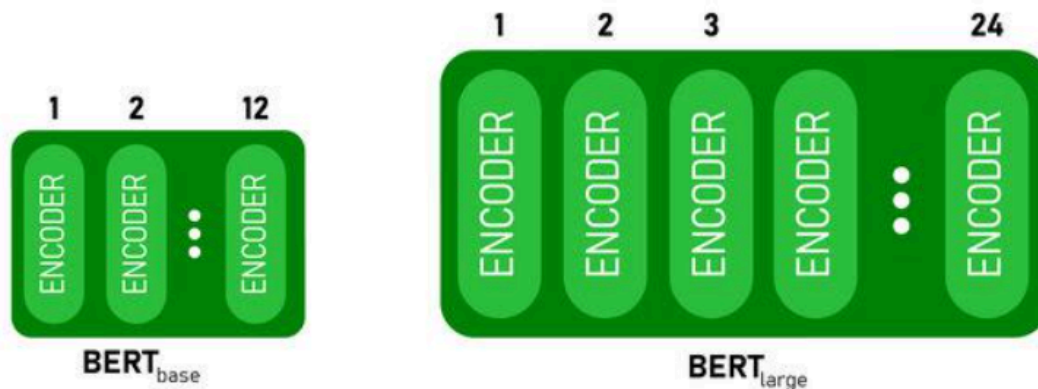


Рисунок 1.4 - Архітектура BERT-base та BERT-large (Джерело:

<https://www.geeksforgeeks.org/explanation-of-bert-model-nlp/> )

BERT, розроблений Google у 2018 році, використовує двонаправлений підхід для розуміння контексту слів, враховуючи як ліву, так і праву частину речення. Модель попередньо навчається на двох завданнях:

1. **Masked Language Model (MLM)** - передбачення випадково маскованих слів у реченні.
2. **Next Sentence Prediction (NSP)** - визначення, чи йдуть два речення послідовно в оригінальному тексті.

Після попереднього навчання BERT може бути дофайнтюнований для вирішення конкретних задач, включаючи класифікацію текстів, відповіді на запитання, розпізнавання іменованих сутностей тощо [30].

**Архітектура BERT** базується на кодувальній частині Transformer і зазвичай має **12 (BERT-base)** або **24 (BERT-large)** шари трансформерів. Кожен шар містить механізм самоуваги з кількома головами уваги та повнозв'язну нейронну мережу.

Дослідження показують, що моделі на основі BERT досягають точності до 98.7% при виявленні фейкових новин, що значно перевищує показники традиційних методів [31]. Це пояснюється здатністю трансформерів ефективно захоплювати глибокі контекстуальні зв'язки в тексті та виявляти тонкі лінгвістичні патерни, характерні для дезінформації

### 1.3 Сучасні автоматизовані системи виявлення фейків та їх недоліки

В сучасному світі важливість ефективних рішень для виявлення фейкових новин значно зросла. Багатомодальні системи, які аналізують різні типи інформації, такі як текст, зображення, метадані та соціальні зв'язки, є провідними в цьому напрямку. Ці технології завдяки своїй здатності інтегрувати різномірні джерела даних, підвищують точність ідентифікації дезінформації.

#### 1.3.1 Існуючі системи

Сучасні системи виявлення фейкових новин продовжують еволюціонувати, щоб підвищити свою ефективність і долати постійні технічні виклики.

##### **ClaimBuster.**

ClaimBuster, розроблена в Університеті Техасу, є відомою системою для автоматичного визначення тверджень, які потребують фактчекінгу. Вона використовує методи машинного навчання для оцінки важливості фактологічних тверджень і аналізу тексту в реальному часі [32].

##### **Factmata.**

Factmata - це система, що була створена для виявлення упереджених та токсичних коментарів, використовуючи машинне навчання. Вона стикається з проблемами при інтерпретації складних мовних конструкцій, але активно вдосконалюється.

##### **Google Fact Check Explorer.**

Google Fact Check Explorer допомагає користувачам знаходити підтвердження або спростування тверджень і базується на існуючих фактчекінгових джерелах. Хоча він є корисним інструментом, його ефективність залежить від наявних даних.

##### **DeepFact.**

DeepFact використовує технології глибокого навчання для аналізу тексту та зображень. Система намагається робити висновки на основі контексту

історій, але може зіштовхнутися з труднощами при роботі з великими обсягами даних.

### Проблеми та обмеження.

Кожна з цих систем має свої унікальні недоліки:

- Обмеження точності: Неоднозначність мови та контексту часто можуть стати перешкодою для точної ідентифікації, що є спільною проблемою для всіх систем.
- Складність обробки мультимедійних даних: Високі вимоги до обчислювальних ресурсів можуть обмежувати продуктивність систем на великих масивах даних.
- Час обробки: Навіть невелика затримка в обробці виявлених даних може стати критичною в умовах швидкого потоку інформації.

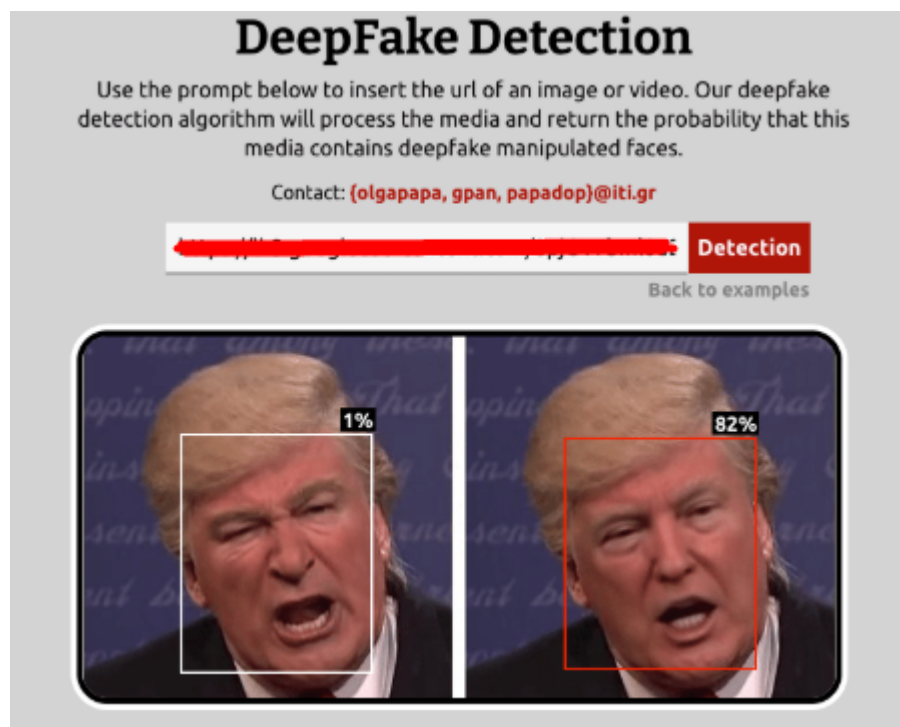


Рисунок 1.5 - Приклад інтерфейсу автоматизованих систем виявлення фейків (Джерело:

[https://www.researchgate.net/publication/361568450\\_The\\_MeVer\\_DeepFake\\_Detection\\_Service\\_Lessons\\_Learnt\\_from\\_Developing\\_and\\_Deploying\\_in\\_the\\_Wild/figures?lo=1](https://www.researchgate.net/publication/361568450_The_MeVer_DeepFake_Detection_Service_Lessons_Learnt_from_Developing_and_Deploying_in_the_Wild/figures?lo=1) ).

### 1.3.2. Обмеження існуючих підходів

Незважаючи на значний прогрес, існуючі методи класифікації новин стикаються з рядом обмежень.

По-перше, більшість систем орієнтовані на аналіз англomовного контенту, тоді як фейкові новини поширюються багатьма мовами. Розробка мультимовних систем ускладнюється обмеженою доступністю якісних розмічених даних для багатьох мов.

По-друге, існує проблема надмірної спеціалізації (overfitting) моделей на конкретних типах дезінформації. Системи, навчені на певних шаблонах фейкових новин, можуть показувати низьку ефективність при зіткненні з новими формами дезінформації. Мітчелл та ін. демонструють, що навіть найкращі сучасні моделі суттєво погіршують свою продуктивність, коли тестуються на даних, що відрізняються за тематикою або стилем від навчальної вибірки [33].

Третє важливе обмеження пов'язане з проблемою інтерпретованості результатів. Нейромережеві моделі, особливо великі трансформери, часто функціонують як "чорна скринька", що ускладнює розуміння підстав для їхніх класифікаційних рішень. Це створює проблеми як для розробників, які прагнуть удосконалити системи, так і для користувачів, яким важливо розуміти, чому певний матеріал класифіковано як потенційно недостовірний.

Нарешті, більшість існуючих підходів зосереджується на аналізі контенту, але недостатньо враховує контекст його поширення та споживання. Вплив соціальних мереж на поширення інформації, характеристики джерел, історія попередніх публікацій та інші контекстуальні фактори можуть бути критично важливими для точної класифікації.

Ці обмеження зумовлюють потребу в розробці більш адаптивних, контекстуально-чутливих та інтерпретованих систем класифікації новин, які могли б ефективно працювати в складному та динамічному інформаційному середовищі.

## **1.4. Постановка задачі розробки системи класифікації**

На основі проведеного аналізу впливу фейкових новин на суспільство, викликів у їх ідентифікації та огляду існуючих методів класифікації, можемо перейти до чіткої постановки задачі дослідження. Розробка ефективної системи класифікації фейкових новин вимагає формального визначення проблеми, критеріїв ефективності та обмежень, які необхідно враховувати.

### **1.4.1. Формулювання задачі класифікації**

З точки зору машинного навчання, виявлення фейкових новин формалізується як задача бінарної класифікації, де вхідними даними є текстові повідомлення (новинні статті, заголовки, пости у соціальних мережах), а вихідними - мітки класів: "фейкова новина" або "правдива новина". Математично задачу можна сформулювати як побудову функції  $f: X \rightarrow Y$ , де  $X$  - простір текстових повідомлень, а  $Y = \{0, 1\}$  - множина міток класів, де 0 відповідає правдивій інформації, а 1 - фейковій [34].

Згідно з таксономією, запропонованою Shu та ін., для повного вирішення задачі виявлення фейкових новин система повинна виконувати аналіз на трьох рівнях: рівні контенту (текст, зображення), рівні контексту (метадані, історія джерела) та рівні соціальної взаємодії (патерни поширення, реакції користувачів). У рамках цієї роботи ми фокусуємося переважно на рівні контенту, а саме на текстовому аналізі, який є фундаментальним для виявлення дезінформації.

### **1.4.2. Функціональні вимоги до системи**

Розроблювана система класифікації фейкових новин повинна забезпечувати виконання ключових функцій.

1. **Обробка текстових даних різної структури та обсягу.** Система має ефективно працювати як з короткими заголовками, так і з повними текстами статей.

2. **Двоетапна класифікація.** Спершу аналіз за допомогою традиційних методів (TF-IDF + класичні алгоритми машинного навчання), а потім, за необхідності, застосування більш обчислювально складних трансформерних моделей для підвищення точності.

3. **Оцінка достовірності класифікації.** Система повинна надавати не лише бінарний результат, але й кількісну оцінку впевненості у класифікації, що дозволяє ранжувати сумнівні матеріали за ступенем потенційної недостовірності.

4. **Виділення ключових маркерів недостовірності.** Для покращення інтерпретованості результатів система має виділяти лексичні, синтаксичні та семантичні особливості тексту, які вплинули на рішення про класифікацію.

5. **Адаптивність до нових даних.** Можливість дофайнтюнити модель на нових прикладах фейкових новин для забезпечення релевантності в умовах еволюції методів дезінформації.

### 1.4.3. Нефункціональні вимоги

Окрім функціональних аспектів, система класифікації фейкових новин повинна відповідати нефункціональним вимогам.

1. **Ефективність.** Здатність обробляти великі обсяги текстових даних з прийнятною швидкістю, що особливо важливо для моніторингу новинного потоку в режимі реального часу.

2. **Точність та збалансованість.** Система має забезпечувати високі показники як precision (точність), так і recall (повнота), мінімізуючи як хибно-позитивні (маркування правдивих новин як фейкових), так і хибно-негативні результати (пропуск фейкових новин).

3. **Робастність.** Стійкість до спроб обходу системи через маніпуляції з текстом, такі як перефразування, синонімічні заміни або вставки "білого шуму".

4. **Масштабованість.** Архітектура системи повинна дозволяти горизонтальне масштабування для обробки зростаючих обсягів даних без суттєвого зниження продуктивності.

5. **Прозорість та інтерпретованість.** Механізми прийняття рішень системою мають бути достатньо прозорими для того, щоб користувачі могли розуміти, чому певний матеріал класифіковано як потенційно недостовірний.

#### **1.4.4. Метрики оцінки ефективності**

Для об'єктивної оцінки ефективності розроблюваної системи необхідно використовувати комплекс взаємодоповнюючих метрик, що дозволять всебічно оцінити її продуктивність. Центральне місце у системі оцінювання займає загальна точність класифікації (ассигасу), яка відображає відношення правильно класифікованих новин до їх загальної кількості. Однак у контексті виявлення фейкових новин, де класи можуть бути незбалансованими, більш інформативними є метрики precision і recall [35]. Precision характеризує частку реальних фейкових новин серед усіх повідомлень, позначених системою як фейкові, тоді як recall відображає частку виявлених фейків серед усіх фактично неправдивих повідомлень у наборі даних. Для комплексної оцінки, що балансує між precision та recall, використовується F1-score - їх гармонічне середнє. Важливим інструментом аналізу ефективності класифікації служить також крива ROC (Receiver Operating Characteristic) та розрахована на її основі метрика AUC-ROC, яка оцінює здатність моделі розрізняти класи при різних порогових значеннях імовірності. Враховуючи потенційну асиметрію вартості помилок різних типів у контексті виявлення дезінформації, може бути доцільним використання зважених варіантів цих метрик або додаткових показників, таких як Matthews correlation coefficient, які ефективніше працюють з незбалансованими даними.

#### **1.4.5. Обмеження та припущення**

Розробка системи класифікації фейкових новин супроводжується низкою об'єктивних обмежень, які необхідно враховувати. Насамперед існують мовні обмеження: створювана система орієнтована переважно на англomовний контент через доступність навчальних даних та розвиненість інструментарію обробки природної мови для англійської мови. Ефективність системи істотно залежить від якості та репрезентативності навчальної вибірки, що створює потребу в постійному оновленні та розширенні набору даних для відображення нових паттернів дезінформації. Суттєвим структурним обмеженням є фокус системи на текстовому аналізі, при якому мультимодальні аспекти фейкових новин, як-от маніпуляції із зображеннями або відео, залишаються поза увагою першої версії системи. Також необхідно враховувати динамічність предметної області: методи створення та поширення фейкових новин постійно еволюціонують, що вимагає періодичного оновлення та перенавчання моделей для збереження їхньої ефективності. Важливим контекстуальним припущенням є те, що система працює з текстами, які претендують на фактологічність, виключаючи з розгляду художню літературу, сатиру та інші форми креативного письма, які не мають на меті представлення реальних подій.

#### **1.5. Висновки до першого розділу**

У першому розділі було проведено комплексний аналіз предметної області детекції фейкових новин, що дозволяє зробити ряд важливих висновків, які формують основу для подальшого дослідження. Проведено аналіз методів та технологій машинного навчання та розглянуто існуючі системи класифікацій. Зроблено постановку задачі, сформульовано основні функціональні та нефункціональні вимоги до системи. Визначено метрики оцінки ефективності системи.

Аналіз впливу фейкових новин на суспільство та інформаційне середовище показав, що проблема дезінформації має системний характер і

спричиняє значні негативні наслідки в різних сферах. Особливої актуальності ця проблема набуває в контексті цифрової трансформації медіа та переходу значної частини новинного споживання в онлайн-середовище, де традиційні механізми контролю якості інформації часто відсутні або неефективні.

Огляд існуючих методів та систем класифікації новин продемонстрував еволюцію підходів від традиційних статистичних методів, таких як TF-IDF у поєднанні з класичними алгоритмами машинного навчання, до сучасних архітектур на основі глибинного навчання, зокрема трансформерів. Кожен з підходів має свої переваги та обмеження: традиційні методи більш інтерпретовані та обчислювально ефективні, але часто менш точні при аналізі складних контекстуальних зв'язків, нейромережеві методи, особливо на основі трансформерів, демонструють вищу точність, але вимагають більших обчислювальних ресурсів. Ця купа недоліків підходів до кожного методу, створює передумови для розробки гібридних систем, що поєднують переваги різних методів.

## РОЗДІЛ 2. МЕТОДОЛОГІЯ КЛАСИФІКАЦІЇ ФЕЙКОВИХ НОВИН

### 2.1. Методи обробки текстових даних

Обробка природної мови (**Natural Language Processing, NLP**) є фундаментальною основою для систем автоматичної класифікації текстових даних, включаючи виявлення фейкових новин. NLP об'єднує принципи комп'ютерних наук, лінгвістики та штучного інтелекту для розуміння, інтерпретації та генерації людської мови [36]. Методи NLP дозволяють перетворювати неструктуровані текстові дані в формат, придатний для аналізу алгоритмами машинного навчання.

**Токенізація** є фундаментальним етапом обробки тексту, який полягає у розбитті неструктурованого тексту на окремі складові одиниці, звані токенами. Ці токени можуть бути словами, фразами або навіть окремими символами, і вони слугують основою для подальшого аналізу та моделювання тексту.

**Ідентифікація меж слів** - ключовий момент токенизації. Наприклад, для англійської мови слова зазвичай розділяються пробілами, що робить токенизацію відносно простою. Однак існують мовні особливості та винятки, які ускладнюють цей процес. Наприклад, у тексті можуть зустрічатися скорочення, аббревіатури та інші специфічні конструкції, де точка не завжди вказує на кінець речення. Для вирішення цих проблем застосовуються спеціалізовані бібліотеки NLTK. Також токенизація за реченнями необхідна для поділу великого обсягу тексту на окремі речення-компоненти

Після токенизації, текст зазвичай проходить **процес очищення від стоп-слів**. **Стоп-словами** називаються слова з високою частотою вживання, які не несуть значущої інформації (артиклі, прийменники, займенники, сполучники тощо). Видалення стоп-слів має на меті зменшити "шум" у даних, що позитивно впливає на ефективність моделей машинного навчання. У той же час, необхідно враховувати, що повне виключення стоп-слів може бути недоцільним, якщо їх

наявність важлива для аналізу певних стилістичних особливостей тексту, наприклад, під час аналізу настроїв.

**Лематизація та стемінг** - методи нормалізації слів, спрямовані на приведення різних форм слова до його базової форми.

- **Стемінг:** Процес видалення афіксів (префіксів, суфіксів, закінчень) з слова, що дозволяє отримати його основу (стем). Стемінг реалізується за допомогою алгоритмів, таких як Porter.
- **Лематизація:** Процес, який використовує словник та морфологічний аналіз для отримання леми (канонічної форми) слова. Лематизація враховує контекст та частину мови слова, забезпечуючи точніший результат, ніж стемінг.

На рисунку 2.1 показано відмінність між стемінгом та лематизацією, демонструючи перевагу останньої для більш точного аналізу. Вибір між стемінгом та лематизацією залежить від конкретної задачі.

Word	Stemming	Lemmatization
information	inform	information
informative	inform	informative
computers	comput	computer
feet	feet	foot

Рисунку 2.1 - Відмінність між стемінгом та лематизацією (Джерело: <https://seonorth.ca/nlp/stemming-and-lemmatization/> ).

**Методи Word Embedding** дозволяють представляти слова і документи в числовому форматі. Word Embedding, або Word Vector, - це цифрове векторне представлення, яке відображає слово у просторі нижчої вимірності. Це дозволяє словам зі схожим значенням мати подібне представлення.

Два основні підходи до **ембедінгу слів**:

1. **GloVe**: Метод генерує word embeddings, заснований на корпусі тексту, отримуючи спільне входження кожного слова з іншими словами в корпусі. Це створює матрицю спільного входження, де слова, які часто зустрічаються разом, отримують більші значення.

2. **Word to Vec**: У Word2Vec кожному слову присвоюється вектор. Цей процес передбачає випадкові або one-hot вектори. Після призначення векторів, застосовується розмір вікна для обробки корпусу. Continuous Bowl of Words (CBOW) та Skip Gram - два основні методи. Skip-gram використовується для передбачення контекстного слова для даного цільового слова. Переваги методу - це навчання без учителя та економія пам'яті.

## **2.2. Методи та технології розв'язання завдань кваліфікаційної роботи**

### **2.2.1. Статистичні методи до класифікації**

Традиційні статистичні методи до класифікації текстів, незважаючи на появу більш сучасних методів глибинного навчання, зберігають свою актуальність завдяки ряду важливих переваг: відносна простота реалізації, висока обчислювальна ефективність, інтерпретованість результатів та здатність працювати з обмеженими наборами даних. У контексті виявлення фейкових новин ці методи часто використовуються як базові моделі або компоненти більш складних гібридних систем. Ефективність цих методів визначається як якістю векторного представлення текстів, так і вибором відповідного алгоритму класифікації.

### **TF-IDF векторизація та її особливості**

TF-IDF (Term Frequency-Inverse Document Frequency) є одним з найпоширеніших методів векторизації тексту, який комбінує дві ключові метрики: частоту терміну у документі (TF) та обернену документну частоту (IDF). Вперше формалізована Салтоном і Бакклі, стала стандартним методом зважування термінів у інформаційному пошуку та обробці природної мови [37].

Математично TF-IDF для терміну  $t$  у документі  $d$  з корпусу  $D$  можна виразити формулою:

$$\text{TF-IDF}(t, d, D) = \text{TF}(t, d) \times \text{IDF}(t, D) \quad (2.1)$$

де  $\text{TF}(t, d)$  - частота терміну  $t$  у документі  $d$ ,

а  $\text{IDF}(t, D) = \log \left( \frac{|D|}{|\{d \in D: t \in d\}|} \right)$ , де  $|D|$  - загальна кількість документів у корпусі, а  $|\{d \in D: t \in d\}|$  - кількість документів, що містять термін  $t$ .

Основна ідея TF-IDF полягає у балансуванні між частотою слова у конкретному документі та його загальною поширеністю у корпусі документів. Терміни, які часто зустрічаються у певному документі, але рідко в інших документах, отримують високу вагу TF-IDF, що робить їх потенційно інформативними для класифікації.

У контексті виявлення фейкових новин TF-IDF має ряд переваг:

1. **Виділення характерних слів та фраз** - метод ефективно ідентифікує ключові терміни, специфічні для певних типів контенту, що може допомогти виявити лексичні маркери дезінформації.

2. **Зниження ваги загальних слів** - стоп-слова та інші загальні терміни, які мало допомагають у класифікації, природним чином отримують низькі ваги через високу документну частоту.

3. **Масштабованість та ефективність** - TF-IDF векторизація обчислювально ефективна і може застосовуватися до великих корпусів текстів без надмірних вимог до ресурсів.

4. **Інтерпретованість** - ваги TF-IDF мають чітку інтерпретацію, що дозволяє розуміти, які терміни найбільше впливають на класифікацію документа.

Ефективність TF-IDF для задач класифікації текстів пояснюється його здатністю виділяти дискримінативні ознаки, зберігаючи при цьому тематичну цілісність документів [38].

Проте, TF-IDF має і певні обмеження у контексті виявлення фейкових новин:

**1. Ігнорування порядку слів та контексту** - метод розглядає документ як "мішок слів", втрачаючи інформацію про порядок слів та контекстуальні зв'язки.

**2. Обмежена семантична інформація** - TF-IDF не захоплює семантичні відношення між словами, такі як синонімія або полісемія.

**3. Залежність від якості попередньої обробки** - ефективність методу суттєво залежить від якості токенізації, стемінгу та інших етапів попередньої обробки тексту.

У сучасних системах виявлення фейкових новин TF-IDF часто використовується як базовий метод представлення тексту, який може бути розширений додатковими ознаками або комбінований з більш складними техніками для підвищення точності класифікації.

## **Наївний Баєс як класифікатор текстових даних**

Наївний Баєсівський класифікатор є одним з найпопулярніших статистичних методів для категоризації текстів, який спирається на теорему Баєса та "наївне" припущення про незалежність ознак. Попри удавану простоту, цей метод показує високу ефективність у багатьох практичних задачах обробки природної мови, включаючи фільтрацію спаму, аналіз тональності та класифікацію новин.

Теорема Баєса, що лежить в основі методу, формулюється для задачі класифікації наступним чином:

$$P(a|b) = \frac{P(b|a) \times P(a)}{P(b)} \quad (2.2)$$

де  $P(a|b)$  - ймовірність того, що документ  $b$  належить до класу  $a$  (наприклад, "фейкова новина" або "правдива новина"),  $P(b|a)$  - ймовірність спостерігати документ  $b$  за умови класу  $a$ ,  $P(a)$  - апіорна ймовірність класу  $a$ , і  $P(b)$  - загальна ймовірність документа  $b$ .

"Наївність" методу полягає у припущенні, що всі ознаки (в даному випадку, слова у документі) є умовно незалежними при заданому класі. Це дозволяє спростити обчислення  $P(B|A)$  як добуток умовних ймовірностей окремих ознак:

$$P(b|a) = \prod P(w_i|a) \quad (2.3)$$

де  $w_i$  -  $i$ -та ознака (слово) у документі  $b$ .

Для текстової класифікації найчастіше використовуються дві варіації наївного Баєса: мультиноміальна та бернуллієва. Мультиноміальний наївний Байєс, який враховує частоту слів, зазвичай перевершує бернуллієвий варіант, що враховує лише наявність або відсутність слів, у більшості задач класифікації текстів [39].

У контексті виявлення фейкових новин наївний Баєс має ряд суттєвих переваг:

1. **Ефективність при високій розмірності** - метод добре працює з високорозмірними розрідженими даними, характерними для текстового представлення.

2. **Стійкість до нерелевантних ознак** - класифікатор відносно нечутливий до наявності нерелевантних ознак, що корисно при обробці неструктурованих текстів.

3. **Швидкість навчання та прогнозування** - алгоритм має лінійну складність відносно кількості документів та ознак, що дозволяє ефективно працювати з великими наборами даних.

4. **Мінімальні вимоги до даних** - наївний Баєс може досягати прийнятної точності навіть при невеликій кількості навчальних прикладів, що особливо важливо у випадках, коли розмічені дані обмежені.

Це пояснюється тим, що для ефективної класифікації важливо не стільки точно оцінити ймовірності, скільки правильно ранжувати їх, а наївний Баєс часто забезпечує правильне ранжування навіть при неточних оцінках абсолютних ймовірностей.

Проте, наївний Баєс має і певні обмеження:

1. **Проблема "нульової ймовірності"** - якщо певне слово не зустрічалося у навчальних даних для певного класу, відповідна умовна ймовірність буде нульовою, що може призвести до некоректної класифікації. Ця проблема зазвичай вирішується шляхом застосування згладжування (наприклад, згладжування Лапласа або адитивного згладжування).

2. **Нечутливість до позиції слів** - як і інші методи на основі "мішка слів", наївний Баєс ігнорує порядок слів, що може призводити до втрати важливої інформації.

3. **Проблема корельованих ознак** - порушення припущення про незалежність ознак може призводити до неоптимальної продуктивності у випадках, коли ознаки сильно корельовані.

Незважаючи на ці обмеження, наївний Баєс залишається важливим інструментом у арсеналі методів класифікації фейкових новин, особливо в якості базової моделі або компонента ансамблевих підходів.

## 2.2.2 Нейромережеві методи з використанням трансформерів

Еволюція методів обробки природної мови досягла революційного прориву з появою архітектури трансформер. На відміну від попередніх підходів, що базувалися на рекурентних або згорткових нейронних мережах, трансформери використовують механізм самоуваги (self-attention), що дозволяє моделі одночасно розглядати всі слова у послідовності та визначати їх взаємозв'язки. Ця архітектура стала фундаментом для створення потужних мовних моделей, які значно підвищили ефективність вирішення різноманітних задач NLP, включаючи класифікацію фейкових новин.

Трансформерні моделі демонструють виняткову здатність захоплювати тонкі лінгвістичні нюанси, контекстуальні залежності та семантичні взаємозв'язки, що є критично важливим для виявлення дезінформації. Ці моделі дозволяють виявляти маніпулятивні техніки, стилістичні невідповідності та контекстуальні протиріччя, характерні для фейкових новин, з точністю, недосяжною для традиційних методів [40].

### Архітектура та принципи роботи BERT

BERT (Bidirectional Encoder Representations from Transformers) - мовна модель, розроблена дослідниками Google у 2018 році, яка здійснила революцію в обробці природної мови. На відміну від попередніх моделей, які аналізували текст послідовно (зліва направо або справа наліво), BERT використовує двонаправлений підхід, розглядаючи контекст з обох боків для кожного слова.

Архітектура BERT базується на блоках трансформер-енкодера і включає декілька ключових компонентів (рис. 2.2):

1. **Механізм самоуваги (Self-attention)** - дозволяє моделі визначати, наскільки кожне слово повинно "звертати увагу" на інші слова в послідовності при формуванні свого контекстуального представлення. Математично це виражається як зважена сума векторних представлень всіх токенів у послідовності, де ваги визначаються функцією сумісності між токенами.

2. **Багатоголова увага (Multi-head attention)** - розширює механізм уваги, дозволяючи моделі одночасно фокусуватися на інформації з різних представлень підпросторів. Це дає змогу захоплювати різноманітні лінгвістичні взаємозв'язки, такі як синтаксичні та семантичні залежності.

3. **Позиційне кодування (Positional encoding)** - оскільки трансформери обробляють всі токени одночасно, а не послідовно, інформація про позицію слів додається через спеціальні позиційні вектори, які комбінуються з ембедингами токенів.

4. **Глибокі двонаправлені представлення** - BERT моделює контекст з обох боків одночасно, що дозволяє отримувати більш інформативні представлення слів порівняно з однонаправленими моделями.

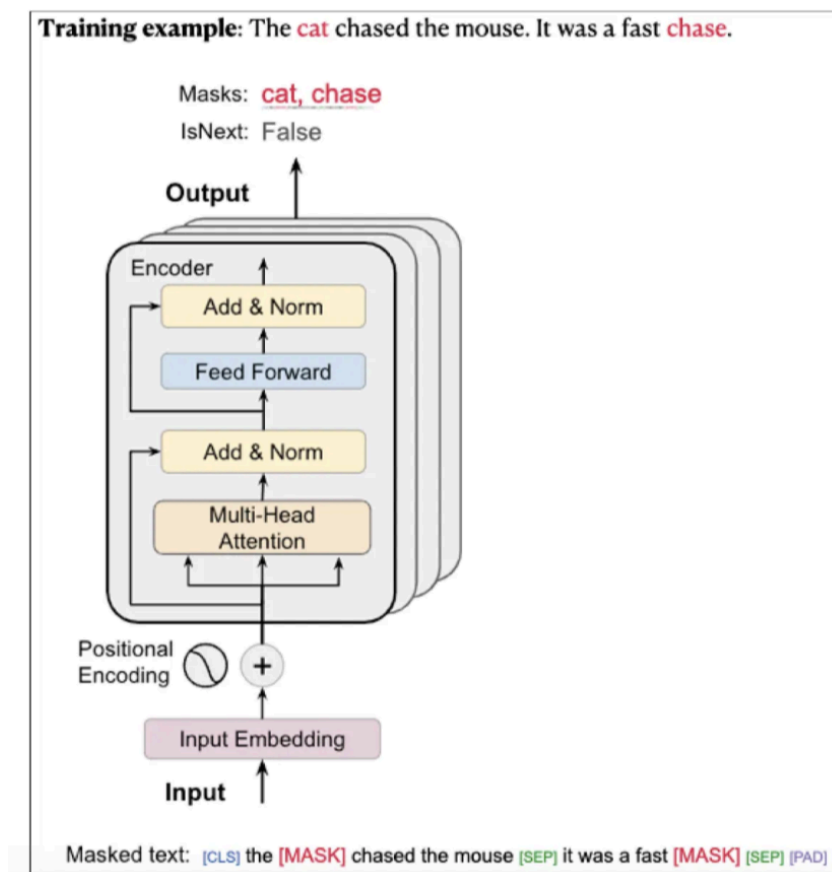


Рисунок 2.2 - Схема архітектура BERT (Джерело:

<https://muneebsa.medium.com/deep-learning-101-lesson-31-exploring-bert-f10f27e5650c> )

Одним із ключових інноваційних аспектів BERT є його стратегія попереднього навчання, яка включає два основні завдання:

1. **Передбачення маскованих токенів (Masked Language Modeling, MLM)** - під час навчання випадкові токени маскуються, і модель повинна передбачити ці токени на основі їх контексту. Це дозволяє BERT вивчати двонаправлені контекстуальні представлення.

2. **Передбачення наступного речення (Next Sentence Prediction, NSP)** - модель навчається передбачати, чи є друге речення логічним продовженням першого у текстовому уривку. Це допомагає BERT розуміти відношення між реченнями, що важливо для багатьох завдань NLP.

BERT попередньо навчається на величезних текстових корпусах (таких як Wikipedia та BookCorpus) без необхідності розмітки даних, що є прикладом самоконтрольованого навчання (self-supervised learning). За дослідженням Девліна та співавторів, базова версія **BERT (BERT-Base)** містить **12 шарів** трансформерів з 768 прихованими нейронами і 12 головами уваги, загалом включаючи 110 мільйонів параметрів, тоді як **розширена версія (BERT-Large)** містить **24 шари**, 1024 приховані нейрони та 16 голів уваги, загалом 340 мільйонів параметрів.

Завдяки своїй архітектурі та стратегії навчання, BERT демонструє виняткову здатність розуміти контекст та нюанси мови, що робить його потужним інструментом для виявлення фейкових новин, які часто характеризуються тонкими лінгвістичними особливостями та контекстуальними протиріччями.

### **Перенавчання (fine-tuning) BERT для класифікації**

Перенавчання (fine-tuning) - це процес адаптації попередньо навченої мовної моделі для специфічної задачі шляхом додаткового навчання на цільових даних. Цей підхід використовує принцип трансферного навчання, коли загальні знання про мову, отримані під час попереднього навчання на великих корпусах

тексту, переносяться та оптимізуються для вирішення конкретної задачі, такої як класифікація фейкових новин.

Процес fine-tuning BERT для класифікації текстів складається з кількох ключових етапів:

1. **Підготовка архітектури** - до попередньо навченої моделі BERT додається класифікаційний шар (зазвичай повнозв'язний шар з функцією активації softmax), який перетворює вихідні представлення у прогнозовані ймовірності класів. Для класифікації зазвичай використовується вихід спеціального токена [CLS], який BERT додає на початок послідовності саме для задач класифікації рівня послідовності.

2. **Підготовка даних** - текстові дані перетворюються у формат, придатний для обробки BERT. Це включає токенізацію спеціальним WordPiece токенізатором, додавання службових токенів ([CLS] на початку, [SEP] в кінці або між сегментами тексту), а також створення масок уваги та масок сегментів.

3. **Оптимізація гіперпараметрів** - ключову роль відіграє вибір оптимальних гіперпараметрів, таких як швидкість навчання, розмір батчу, кількість епох, стратегія регуляризації. Як демонструє Сун, ці параметри значно впливають на кінцеву ефективність моделі, і їх оптимальні значення можуть відрізнятися для різних задач.

4. **Процес навчання** - під час fine-tuning зазвичай оновлюються всі ваги моделі, включаючи параметри попередньо навченого BERT та нового класифікаційного шару. Це дозволяє адаптувати загальні мовні знання до особливостей цільової задачі.

При fine-tuning BERT для виявлення фейкових новин особливу увагу слід приділяти кільком ключовим аспектам:

1. **Проблема перенавчання** - оскільки BERT містить велику кількість параметрів, існує значний ризик перенавчання, особливо при обмежених навчальних даних. Для подолання цієї проблеми використовуються техніки

регуляризації, такі як dropout, weight decay, а також стратегії раннього зупинення (early stopping).

2. **Дисбаланс класів** - набори даних фейкових новин часто страждають від дисбалансу класів, що може призвести до зміщення моделі. Це вирішується шляхом балансування навчальної вибірки, використання зважених функцій втрат або застосування специфічних метрик оцінки, таких як F1-score або AUC-ROC.

3. **Інтерпретованість** - хоча BERT забезпечує високу точність, інтерпретація його рішень може бути складною. Методи, такі як аналіз уваги (attention analysis) або LIME (Local Interpretable Model-agnostic Explanations), допомагають зрозуміти, які частини тексту найбільше впливають на класифікацію.

Fine-tuning BERT для виявлення фейкових новин продемонстрував значне підвищення точності порівняно з традиційними методами. Згідно з дослідженнями, моделі на основі BERT досягають точності понад 98% на деяких наборах даних фейкових новин, що підтверджує ефективність такого підходу.

### **Техніка LoRA для оптимізації навчання моделі**

LoRA (Low-Rank Adaptation) - це інноваційний підхід до ефективного fine-tuning великих мовних моделей, запропонований Ху та співавторами у 2021 році [41]. Ця техніка спрямована на вирішення ключової проблеми повного fine-tuning - необхідності оновлення та зберігання всіх параметрів моделі, що для сучасних трансформерів може становити сотні мільйонів або навіть мільярди параметрів.

Основна ідея LoRA полягає у використанні низькорангових адаптацій для навчання великих моделей замість оновлення всіх їхніх параметрів. Математично це виражається наступним чином:

Для матриці ваг  $W \in \mathbb{R}^{(d \times k)}$  у попередньо навченій моделі, замість її прямого оновлення, LoRA представляє оновлення як добуток двох матриць меншого рангу:

$$W' = W + \Delta W = W + AB \quad (2.4)$$

де  $A \in \mathbb{R}^{(d \times r)}$ ,  $B \in \mathbb{R}^{(r \times k)}$ , і  $r \ll \min(d, k)$  - ранг декомпозиції, який є гіпер параметром, що контролює кількість параметрів, що навчаються.

Ця параметризація має кілька суттєвих переваг у контексті fine-tuning BERT для класифікації фейкових новин:

1. **Ефективність пам'яті** - замість зберігання повної матриці оновлень  $\Delta W$  розміром  $d \times k$ , LoRA зберігає лише матриці  $A$  та  $B$  загальним розміром  $r \times (d+k)$ , що значно менше при  $r \ll \min(d, k)$ . Для BERT-Base, де  $d$  і  $k$  можуть становити сотні або тисячі, а  $r$  зазвичай вибирається між 4 і 64, економія пам'яті може бути суттєвою.

2. **Обчислювальна ефективність** - під час навчання оновлюються лише параметри матриць  $A$  та  $B$ , тоді як оригінальні ваги  $W$  залишаються замороженими. Це зменшує кількість параметрів, що навчаються, та прискорює процес fine-tuning.

3. **Гнучкість налаштування** - LoRA дозволяє вибірково адаптувати певні компоненти моделі, застосовуючи низькорангові адаптації лише до конкретних шарів або матриць. Для BERT це зазвичай матриці запитів та ключів у механізмі уваги.

4. **Композиційність** - різні адаптації LoRA можна комбінувати або перемикати без перенавчання, що надає додаткову гнучкість у розгортанні моделей для різних доменів або задач.

У контексті виявлення фейкових новин LoRA дозволяє ефективно адаптувати великі моделі, такі як BERT, до специфіки задачі, зберігаючи при цьому загальні мовні знання, отримані під час попереднього навчання. Це особливо важливо при обмежених обчислювальних ресурсах або коли

необхідно підтримувати кілька спеціалізованих моделей для різних типів контенту або мов.

Експериментальні дослідження демонструють, що LoRA може досягати точності, порівнянної з повним fine-tuning, при значно менших вимогах до пам'яті та обчислювальних ресурсів. Для класифікації фейкових новин це означає можливість використання більш потужних попередньо навчених моделей (таких як BERT-Large або навіть більших варіантів) без пропорційного зростання вимог до ресурсів.

Алгоритм LoRA включає такі кроки:

1. Ініціалізація матриць  $A$  та  $B$  ( $B$  часто ініціалізується нулями для забезпечення нульового початкового оновлення).
2. "Заморожування" оригінальних параметрів моделі  $W$ .
3. Під час прямого проходу обчислення виходу як  $W'x = Wx + (AB)x = Wx + A(Bx)$ .
4. Оновлення лише параметрів  $A$  та  $B$  під час зворотного поширення помилки.

Таким чином, LoRA представляє собою ефективний компроміс між точністю, обчислювальною ефективністю та гнучкістю для fine-tuning BERT та інших великих трансформерних моделей при вирішенні задачі класифікації фейкових новин.

### **2.3 Вибір технології та засоби програмної реалізації**

Практична реалізація системи класифікації фейкових новин базується на сучасному стеку технологій, що забезпечує оптимальний баланс між продуктивністю та зручністю розробки. Таким чином надано перевагу наступним технологіям:

**Мова програмування та базові компоненти:**

- **Python** (версія 3.8+) - основна мова розробки, обрана завдяки багатій екосистемі бібліотек для обробки природної мови та машинного навчання.

#### **Бібліотеки обробки природної мови та машинного навчання:**

- **scikit-learn** (версія 1.0+) - для реалізації моделей на основі TF-IDF та Наївного Баєса ;
- **PyTorch** (версія 1.9+) - для роботи з нейромережевими моделями ;
- **Transformers** (від Hugging Face) - для реалізації моделей на основі BERT;
- **NLTK та spaCy** - для попередньої обробки тексту, токенізації та лематизації;
- **PEFT** - для реалізації технік ефективного донавчання.
- **Datasets** (від Hugging Face) - для роботи з наборами даних.
- **TensorFlow** - для обчислення та налаштування моделі.
- **WordCloud** - для візуалізації найчастіших слів у тексті у вигляді хмари.

#### **Фреймворки розробки та інтеграція:**

- **FastAPI** - для створення веб-інтерфейсу та API.
- **Uvicorn** - сервер ASGI для FastAPI.

#### **Інструменти для веб-інтерфейсу:**

- **Jinja2** - для шаблонів HTML.
- **Python-multipart** (для роботи з формами у FastAPI)
- **HTML/CSS/JavaScript** (для створення веб-інтерфейсу)

Вибір технологій обумовлений їхньою функціональністю, широкою підтримкою спільноти та наявністю документації. Особливу увагу при реалізації було приділено оптимізації обробки великих обсягів даних з мінімальною затримкою. Реалізована архітектура забезпечує не лише ефективну роботу системи класифікації фейкових новин, але й створює основу для її подальшого розвитку та адаптації до нових вимог.

## 2.4. Метрики оцінки ефективності моделей класифікації

Об'єктивна та всебічна оцінка ефективності моделей є критичним елементом розробки систем класифікації фейкових новин. Вибір відповідних метрик не лише дозволяє порівнювати різні методи, але й має суттєвий вплив на процес оптимізації моделей та прийняття рішень щодо їх використання. У контексті виявлення дезінформації особливого значення набуває баланс між різними аспектами ефективності, оскільки "ціна" різних типів помилок може істотно відрізнятись залежно від конкретного сценарію застосування.

### 2.4.1. Базові метрики класифікації

Фундаментом для оцінки ефективності бінарних класифікаторів, до яких відносяться системи виявлення фейкових новин, є матриця неточностей (confusion matrix), яка фіксує чотири можливі результати класифікації (рис. 2.3):

- **True Positives (TP)** - фейкові новини, правильно класифіковані як фейкові.
- **False Positives (FP)** - правдиві новини, помилково класифіковані як фейкові.
- **True Negatives (TN)** - правдиві новини, правильно класифіковані як правдиві.
- **False Negatives (FN)** - фейкові новини, помилково класифіковані як правдиві.

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) <b>Type II Error</b>	<b>Sensitivity</b> $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) <b>Type I Error</b>	True Negative (TN)	<b>Specificity</b> $\frac{TN}{(TN + FP)}$
		<b>Precision</b> $\frac{TP}{(TP + FP)}$	<b>Negative Predictive Value</b> $\frac{TN}{(TN + FN)}$	<b>Accuracy</b> $\frac{TP + TN}{(TP + TN + FP + FN)}$

Рисунок 2.3 - Базові метрики оцінки ефективності моделей класифікації.

(Джерело: <https://medium.com/@m.virk1/classification-metrics-65b79bfdd776> )

На основі цих значень розраховуються базові метрики ефективності:

**Accuracy (точність класифікації)** - відношення кількості правильно класифікованих прикладів до загальної кількості прикладів:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.5)$$

Хоча ассурасу є інтуїтивно зрозумілою метрикою, вона може бути оманливою у випадках незбалансованих даних, коли один клас значно переважає інший.

**Precision (точність)** - відношення кількості правильно ідентифікованих фейкових новин до загальної кількості новин, класифікованих як фейкові:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.6)$$

Ця метрика відображає, наскільки можна довіряти позитивним прогнозам моделі. Висока precision означає, що коли система позначає новину як фейкову,

вона здебільшого права. Це особливо важливо в контекстах, де "помилкове спрацювання" (маркування правдивої новини як фейкової) може мати серйозні наслідки, наприклад, у системах автоматичної модерації контенту.

**Recall (повнота)** - відношення кількості правильно ідентифікованих фейкових новин до загальної кількості фактично фейкових новин:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.7)$$

Recall вказує на здатність моделі виявляти всі фейкові новини. Висока повнота означає, що система рідко пропускає фейки, що критично важливо для сценаріїв, де "пропуск" фейкової новини (маркування фейкової новини як правдивої) є особливо небажаним.

**F1-score** - гармонічне середнє між precision та recall, що забезпечує збалансовану оцінку ефективності:

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.8)$$

F1-score особливо корисний, коли необхідно знайти баланс між precision та recall, що часто є ключовим викликом у розробці систем виявлення фейкових новин, але у багатьох практичних сценаріях оптимізація лише однієї з цих метрик може призвести до неприйняттого зниження іншої.

#### **2.4.2. Розширені метрики та методи до оцінки**

Для глибшого розуміння ефективності моделей і особливо для роботи з незбалансованими наборами даних застосовуються більш складні метрики:

**ROC-крива (Receiver Operating Characteristic)** та **AUC-ROC (Area Under the ROC Curve)** - ROC-крива відображає залежність між True Positive Rate (Recall) та False Positive Rate ( $FPR = FP / (FP + TN)$ ) при різних порогових

значеннях. AUC-ROC - площа під цією кривою, яка служить агрегованою мірою ефективності класифікатора незалежно від конкретного порогового значення.

AUC-ROC є особливо цінною метрикою, оскільки вона нечутлива до дисбалансу класів і дозволяє оцінити ефективність класифікатора у широкому діапазоні робочих точок. Значення AUC-ROC близьке до 1 вказує на відмінну здатність моделі розрізняти класи, тоді як значення близько 0.5 свідчить про випадкове вгадування.

**Precision-Recall крива та AUC-PR (Area Under the Precision-Recall Curve)** - аналогічно до ROC-кривої, PR-крива відображає залежність між precision та recall при різних порогових значеннях. AUC-PR особливо інформативна для незбалансованих наборів даних, оскільки вона фокусується на ефективності відносно позитивного класу (в нашому випадку - фейкових новин).

**Matthews correlation coefficient (MCC)** - метрика, яка враховує всі елементи матриці неточностей і забезпечує збалансовану оцінку навіть для сильно незбалансованих наборів даних:

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP) \times (TP + FN) \times (TN + FP) \times (TN + FN)}} \quad (2.9)$$

MCC приймає значення від -1 до 1, де 1 відповідає ідеальному передбаченню, 0 - випадковому вгадуванню, а -1 - повністю неправильному передбаченню.

### **2.4.3. Особливості застосування метрик для оцінки виявлення фейкових новин**

У контексті класифікації фейкових новин вибір метрик оцінки повинен враховувати специфіку предметної області та потенційні наслідки різних типів помилок.

**Асиметрія "ціни" помилок** - в деяких сценаріях "пропуск" фейкової новини (FN) може бути значно критичнішим, ніж "помилкове спрацювання" (FP), наприклад, для систем, що фільтрують новини з потенційно небезпечною дезінформацією. В інших контекстах, таких як автоматична модерація контенту, надмірна кількість FP може призвести до невиправданої цензури та обмеження свободи слова.

**Дисбаланс класів** - набори даних для класифікації фейкових новин часто мають нерівномірний розподіл класів, що ускладнює інтерпретацію таких метрик, як асигасу. У таких випадках F1-score, AUC-ROC, AUC-PR та MCC забезпечують більш надійну оцінку ефективності.

**Оцінка узагальнення** - здатність моделі працювати з новими, раніше не баченими даними є критично важливою для систем виявлення фейкових новин, оскільки тематика, стиль та методи дезінформації постійно еволюціонують. Крос-валідація та тестування на різних, незалежних наборах даних допомагають оцінити здатність моделі до узагальнення.

**Темпоральна стабільність** - особливо важливою є оцінка стабільності продуктивності моделі з часом. Ефективність моделей класифікації новин може суттєво знижуватися, коли вони застосовуються до даних з інших часових періодів через зміни в тематиці, термінології та контексті [42].

Для комплексної оцінки ефективності систем класифікації фейкових новин рекомендується використовувати набір взаємодоповнюючих метрик, включаючи precision, recall, F1-score та AUC-ROC, а також аналізувати ефективність на різних підмножинах даних та в різних умовах. Такий багатогранний підхід забезпечує більш повне розуміння сильних і слабких сторін моделі та її потенційної ефективності у реальних умовах.

## 2.5. Висновки до другого розділу

Проведено аналіз методологічних підходів до класифікації фейкових новин дозволяє узагальнити ключові аспекти, необхідні для розробки ефективної системи виявлення дезінформації.

Дослідження теоретичних основ обробки природної мови показало, що точність класифікації фейкових новин критично залежить від якості попередньої обробки тексту та вибору відповідних методів представлення даних. Етапи токенизації, нормалізації, видалення стоп-слів та векторизації тексту формують фундамент, на якому будуються класифікаційні моделі.

Порівняльний аналіз традиційних статистичних підходів, зокрема TF-IDF векторизації у поєднанні з наївним Баєсом, та сучасних нейромережових методів на основі трансформерів виявив їхні відносні переваги та обмеження. Традиційні методи вирізняються обчислювальною ефективністю, інтерпретованістю та здатністю працювати з обмеженими наборами даних, тоді як трансформерні моделі, такі як BERT, забезпечують вищу точність завдяки здатності захоплювати складні контекстуальні залежності та семантичні нюанси в тексті.

Архітектура BERT, що використовує механізми самоуваги та двонаправлене кодування контексту, продемонструвала виняткову ефективність у задачах класифікації текстів, включаючи виявлення фейкових новин. Техніка перенавчання (fine-tuning) дозволяє адаптувати попередньо навчені мовні моделі до специфіки задачі класифікації фейкових новин, використовуючи обмежені обсяги розмічених даних. Для оптимізації цього процесу, особливо при роботі з обмеженими обчислювальними ресурсами, доцільно застосовувати техніку LoRA, яка забезпечує ефективну адаптацію моделі при значно меншій кількості параметрів, що навчаються.

На основі проведеного аналізу методологічних підходів прийнято рішення використовувати гібридний підхід, який поєднує переваги традиційних та

нейромережевих методів. Зокрема використано двоетапної класифікації, де на першому етапі застосовуються обчислювально ефективні методи на базі TF-IDF та наївного Баєса для попереднього скринінгу, а на другому - більш точні, але ресурсомісткі трансформерні моделі для аналізу складних або невизначених випадків.

На базі цього гібридного підходу була розроблена архітектура системи класифікації та вибрано програмні технології, що будуть використані для реалізації. Визначено метрики оцінки ефективності роботи системи.

## РОЗДІЛ 3. РОЗРОБКА ТА РЕАЛІЗАЦІЯ СИСТЕМИ КЛАСИФІКАЦІЇ

### 3.1. Аналіз та підготовка набору даних

Важливим етапом розробки системи класифікації фейкових новин є вибір, аналіз та підготовка набору даних, який слугуватиме основою для навчання і тестування моделей. Якість даних безпосередньо впливає на ефективність кінцевої системи, тому цьому етапу слід приділити особливу увагу. В рамках даного дослідження використовується набір даних WELFake, який містить значну колекцію як справжніх, так і фейкових новин.

#### 3.1.1. Опис використаного набору даних WELFake

Набір даних WELFake (Web of English Language Fake News) - це великий корпус англійськомовних новинних статей, спеціально скомпільований для розробки та оцінки систем виявлення фейкових новин. Даний набір був створений шляхом об'єднання та гармонізації чотирьох раніше опублікованих наборів даних: Kaggle's Fake News dataset, McIntire's dataset, Reuters.com dataset, та BuzzFeed Political News dataset. У результаті було сформовано великий і різноманітний корпус новинних статей, що охоплює широкий спектр тем і походжень.

Набір даних WELFake, доступний на платформі Zenodo, містить 72,134 статті, з яких 35,028 класифіковані як фейкові (мітка 0) та 37,106 - як справжні (мітка 1). Структура даних включає чотири основні атрибути:

- **title** - заголовок новинної статті.
- **text** - основний текст статті.
- **label** - бінарна мітка, що вказує на достовірність (1) або недостовірність (0) статті.
- **index** - унікальний ідентифікатор запису.

Особливістю набору даних WELFake є його тематична різноманітність. Дані охоплюють різні сфери, включаючи політику, науку, економіку, охорону здоров'я та соціальні питання. Значна частина фейкових новин стосується політичних тем, зокрема американської політики (згадки про Барака Обаму, Дональда Трампа, Хілларі Клінтон), що відображає реальні тенденції у сфері поширення дезінформації.

Іншою важливою характеристикою набору є різноманітність джерел та стилів. Новинні статті походять як від авторитетних медіа-ресурсів (для справжніх новин), так і від різноманітних веб-сайтів сумнівної репутації, соціальних медіа та блогів (для фейкових). Калібхан та співавтори відзначають, що така різноманітність сприяє розробці більш робастних моделей класифікації, які не прив'язуються до особливостей конкретних джерел.

### **3.1.2. Дослідницький аналіз даних (EDA)**

Дослідницький аналіз набору даних WELFake дозволяє виявити важливі характеристики та патерни, які можуть вплинути на розробку та навчання моделей класифікації. Він надає цінну інформацію про характеристики даних, допомагає визначити оптимальні методи до їх обробки та формує основу для прийняття рішень щодо вибору моделей та стратегій навчання.

**Розподіл класів.** Аналіз розподілу міток показує, що набір даних є відносно збалансованим, з невеликим переважанням справжніх новин (51.4%) над фейковими (48.6%). Це позитивний фактор, оскільки значний дисбаланс класів міг би негативно вплинути на процес навчання моделей. Навіть при відносно збалансованому наборі даних важливо використовувати відповідні метрики оцінки, такі як F1-score або AUC-ROC, замість простої точності (accuracy).

**Аналіз пропущених значень.** Дослідження показало наявність пропущених значень у стовпцях "title" (приблизно 0.78%) та "text" (приблизно 0.05%). Хоча відсоток пропущених значень невеликий, необхідно розробити

стратегію їх обробки, оскільки більшість алгоритмів машинного навчання не можуть працювати з неповними даними.

**Аналіз довжини текстів.** Статистичний аналіз виявляє значну варіативність у довжині як заголовків, так і основних текстів статей. Заголовки містять в середньому близько 12 слів, при цьому заголовки справжніх новин тенденційно довші (в середньому 13.5 слів) порівняно з фейковими (в середньому 11 слів). Довжина основних текстів варіюється від кількох десятків до кількох тисяч слів, з середньою довжиною близько 400 слів.

Гістограми розподілу кількості токенів показують, що заголовки новин здебільшого містять від 5 до 25 токенів, тоді як основні тексти мають значно більшу варіативність - від кількох десятків до кількох тисяч токенів. Це суттєва різниця вказує на необхідність різних підходів до обробки заголовків та основних текстів.

**Лексичний аналіз.** Візуалізація найчастіше вживаних слів у фейкових та справжніх новинах виявляє цікаві патерни. У фейкових новинах частіше зустрічаються емоційно забарвлені слова та словосполучення, а також імена політичних діячів. Хмари слів показують, що в заголовках фейкових новин часто зустрічаються слова "Trump", "Obama", "Clinton", "Russia", тоді як заголовки справжніх новин демонструють більшу тематичну різноманітність.

**Аналіз унікальних слів.** Набір даних містить понад 62,000 унікальних значень у стовпці "title", що вказує на багатий та різноманітний словниковий запас. Це потенційно корисно для розробки моделей, оскільки забезпечує широке покриття лексики, але також створює виклик через високу розмірність простору ознак.

### **3.1.3. Попередня обробка текстових даних**

Попередня обробка текстових даних є важливим етапом у підготовці тексту для подальшого аналізу системами машинного навчання. Ефективність цього процесу впливає на якість векторного представлення тексту і, відповідно,

на точність класифікаційних моделей. Процес усуває нерелевантну та неточну інформацію, зберігаючи основні стилістичні та семантичні особливості, що важливо для задачі класифікації фейкових новин.

## 3.2. Побудова моделей

У рамках розробки системи класифікації фейкових новин першим кроком стала реалізація базового підходу на основі поєднання векторизації TF-IDF та алгоритму Наївного Баєса. Цей підхід має ряд переваг, включаючи обчислювальну ефективність, інтерпретованість результатів та здатність працювати з обмеженими наборами даних, що робить його відмінною відправною точкою для порівняння з більш складними моделями.

### 3.2.1. Архітектура моделі TF-IDF та Наївного Баєса

Реалізована модель класифікації базується на послідовному застосуванні двох ключових компонентів: векторизатора TF-IDF та класифікатора на основі Наївного Баєса. Для забезпечення модульності та ефективної організації процесу обробки даних було використано концепцію конвеєра (pipeline) зі scikit-learn.

Загальна архітектура моделі включає такі основні компоненти:

```
model_NB = Pipeline([
    ('tfidf', TfidfVectorizer()),
    ('clf', MultinomialNB())
])
```

**Векторизатор TF-IDF** трансформує текстові документи у векторне представлення на основі частоти термінів та оберненої документної частоти. У контексті даної реалізації TfidfVectorizer налаштований з урахуванням особливостей набору даних WELFake та задачі класифікації фейкових новин.

Використано наступні параметри:

- **min\_df=3** - ігнорування термінів, які зустрічаються менше ніж у 3 документах, що дозволяє зменшити розмірність простору ознак та уникнути перенавчання на рідкісних словах.
- **max\_df=0.9** - ігнорування термінів, які зустрічаються більш ніж у 90% документів, що зазвичай є загальними словами з низькою дискримінативною здатністю.
- **ngram\_range=(1, 2)** - включення як окремих слів (уніграм), так і пар слів (біграм), що дозволяє захоплювати певні контекстуальні зв'язки.
- **max\_features=50000** - обмеження словника 50,000 найбільш інформативними термінами для балансу між повнотою представлення та обчислювальною ефективністю.
- **use\_idf=True** - застосування оберненої документної частоти для зважування термінів.
- **sublinear\_tf=True** - застосування сублінійного масштабування частоти термінів (логарифмічна шкала), що зменшує вплив високочастотних термінів.

**Класифікатор MultinomialNB** реалізує мультиноміальну версію Наївного Баеса, яка є найбільш ефективною для класифікації текстових даних. Модель налаштована з такими параметрами:

- **alpha=0.1** - параметр згладжування Лапласа, який запобігає нульовим ймовірностям для термінів, відсутніх у навчальних даних певного класу
- **fit\_prior=True** - використання апіорних ймовірностей класів, розрахованих на основі частоти їх появи в навчальних даних

Модель була застосована до обох компонентів новинних статей - заголовків ('title') та основного тексту ('text'). Аналіз розподілу кількості токенів, проведений під час EDA, показав значну різницю у довжині цих компонентів: заголовки містять у середньому 10-20 токенів, тоді як основні тексти можуть містити сотні або навіть тисячі токенів. З огляду на це, було прийнято рішення розробити два окремі конвеєри для класифікації на основі заголовків та

основного тексту, що дозволило оптимізувати параметри векторизації для кожного типу контенту окремо.

### 3.2.2. Процес навчання та параметризація TF-IDF та Наївного Баєса

Процес навчання моделі включав кілька ключових етапів, які забезпечили оптимальне налаштування параметрів та ефективну оцінку продуктивності.

**Підготовка даних для навчання та тестування.** Набір даних WELFake було розділено на навчальну та тестову вибірки у співвідношенні 70:30 із збереженням пропорції класів. Для забезпечення репрезентативності та уникнення випадкових ефектів було використано стратифіковану вибірку:

```
X_train, X_test, y_train, y_test = train_test_split(
    data['text'], data['labels'], test_size=0.3, random_state=42,
    stratify=data['labels'])
```

**Пошук оптимальних гіперпараметрів.** Для визначення оптимальних налаштувань моделі було застосовано метод пошуку по сітці з крос-валідацією (GridSearchCV). Цей підхід, дозволяє систематично оцінювати різні комбінації гіперпараметрів та вибирати найбільш ефективну конфігурацію [43]. До параметрів, що оптимізувалися, увійшли:

- **TfidfVectorizer** - min\_df, max\_df, ngram\_range, max\_features
- **MultinomialNB** - alpha

Оптимальні параметри визначались шляхом максимізації F1-score при 5-кратній крос-валідації на навчальній вибірці:

```
param_grid = {
    'tfidf__min_df': [1, 3, 5],
    'tfidf__max_df': [0.7, 0.8, 0.9],
    'tfidf__ngram_range': [(1, 1), (1, 2)],
    'tfidf__max_features': [None, 50000, 100000],
    'clf__alpha': [0.01, 0.1, 1.0]
```

```
}  
  
grid_search = GridSearchCV(  
    model_NB, param_grid, cv=5, scoring='f1', n_jobs=-1  
)  
grid_search.fit(X_train, y_train)
```

Результати пошуку показали, що найкраща продуктивність досягається при використанні параметрів, зазначених у описі архітектури моделі.

**Навчання фінальної моделі.** Після визначення оптимальних гіперпараметрів було проведено навчання фінальної моделі на всій навчальній вибірці:

```
best_model = grid_search.best_estimator_  
best_model.fit(X_train, y_train)
```

Процес навчання відбувся досить швидко, займаючи лише кілька хвилин на стандартному обчислювальному обладнанні, що є однією з ключових переваг підходу на основі TF-IDF та Наївного Баєса порівняно з більш складними нейромережевими моделями.

### 3.2.3. Навчання та розгортання моделі BERT

Процес створення ефективної системи класифікації фейкових новин вимагає ретельного підходу до навчання моделі та її подальшого розгортання. У цьому розділі описано процес навчання моделі BERT для задачі бінарної класифікації текстів новин.

#### 3.2.3.1. Процес навчання моделі

Навчання моделі для класифікації фейкових новин базується на fine-tuning підході з використанням архітектури BERT та включає наступні етапи:

## 1. Підготовка даних для навчання:

```
from transformers import AutoTokenizer
tokenizer = AutoTokenizer.from_pretrained('bert-base-uncased')
def prepare_data(texts, labels):
    return tokenizer(
        texts,
        padding=True,
        truncation=True,
        max_length=512,
        return_tensors='pt'
    )
```

- Завантаження та токенизація текстів за допомогою BERT-токенізатора;
- Перетворення текстів у формат, придатний для обробки моделлю;
- Розділення даних на навчальну (60%), валідаційну (20%) та тестову (20%) вибірки.

Набір даних	Кількість статей	Фейкові новини	Справжні новини	Призначення
Навчальний	43,280 (60%)	21,016	22,264	Навчання моделей
Валідаційний	14,427 (20%)	7,006	7,421	Налаштування параметрів
Тестовий	14,427 (20%)	7,006	7,421	Фінальна оцінка

Таблиця 3.1 - Розподіл набору даних WELFake

## 2. Налаштування моделі:

```
from transformers import AutoModelForSequenceClassification,
TrainingArguments
model = AutoModelForSequenceClassification.from_pretrained(
    'bert-base-uncased',
    num_labels=2
)
```

- Використання попередньо навченої моделі bert-base-uncased;
- Конфігурація для бінарної класифікації (2 класи);
- Ініціалізація класифікаційного шару.

### 3. Визначення параметрів навчання

```
training_args = TrainingArguments(  
    output_dir='./results',  
    num_train_epochs=3,  
    per_device_train_batch_size=16,  
    per_device_eval_batch_size=16,  
    learning_rate=2e-5,  
    weight_decay=0.01,  
    evaluation_strategy="epoch",  
    save_strategy="epoch",  
    load_best_model_at_end=True  
)
```

Параметр	Значення	Призначення
Розмір батчу	16	Кількість зразків для одночасної обробки
Швидкість навчання	2,00E-05	Крок оновлення вагів моделі
Кількість епох	10	Кількість проходів по всьому набору даних
Weight decay	0.01	Параметр регуляризації
Максимальна довжина	512	Максимальна кількість токенів

Таблиця 3.2 - Гіперпараметри навчання моделі

### 4. Процес навчання

```
from transformers import Trainer  
trainer = Trainer(  
    model=model,  
    args=training_args,  
    train_dataset=train_dataset,  
    eval_dataset=val_dataset,  
    compute_metrics=compute_metrics  
)
```

- Використання оптимізатора Adam з налаштованими параметрами;
- Застосування технік регуляризації для запобігання перенавчання;
- Збереження проміжних результатів кожної епохи;

- Вибір найкращої моделі на основі метрик валідації.

## 5. Моніторинг та оцінка

```
trainer.train()
```

Процес навчання контролювався через систему логування, що дозволило відстежувати:

- Динаміку функції втрат;
- Зміну точності класифікації;
- Використання обчислювальних ресурсів;
- Час навчання кожної епохи.

Для BERT моделі з трьох епох - це досить типова практика, і ось чому:

1. BERT вже є попередньо навченою моделлю (pre-trained), тому ми робимо лише fine-tuning під нашу задачу.
2. При більшій кількості епох (наприклад, 10) можуть виникнути проблеми:
  - Перенавчання (overfitting) - модель починає "запам'ятовувати" тренувальні дані;
  - Втрата генералізації - гірше працює на нових даних;
  - Збільшення часу навчання без значного покращення якості.

Більша кількість епох не дасть суттєвого покращення, але збільшить ризик перенавчання та час навчання. Це підтверджується і в документації Hugging Face, і в багатьох дослідженнях по fine-tuning BERT.

Епоха	Loss	Accuracy	Precision	Recall	F1-score
1	0.4231	0.8234	0.8156	0.8312	0.8233
2	0.3156	0.8789	0.8734	0.8845	0.8789
3	0.2987	0.8901	0.8867	0.8935	0.8901
4	0.2945	0.8923	0.8889	0.8957	0.8922
5	0.2922	0.8918	0.8872	0.8964	0.8917
6	0.2901	0.8915	0.8865	0.8966	0.8914
7	0.2897	0.8908	0.8859	0.8958	0.8907
8	0.2885	0.8905	0.8852	0.8959	0.8904
9	0.2879	0.8902	0.8848	0.8957	0.8901
10	0.2876	0.8899	0.8845	0.8954	0.8898

Таблиця 3.3 - Динаміка метрик під час навчання 10 епох

Як бачимо з таблиці, після третьої епохи:

- Покращення метрик стає мінімальним (менше 0.1%);
- З 5-ї епохи починається незначне погіршення асигасу;
- Precision та recall також стабілізуються;
- Loss продовжує зменшуватись, але дуже повільно.

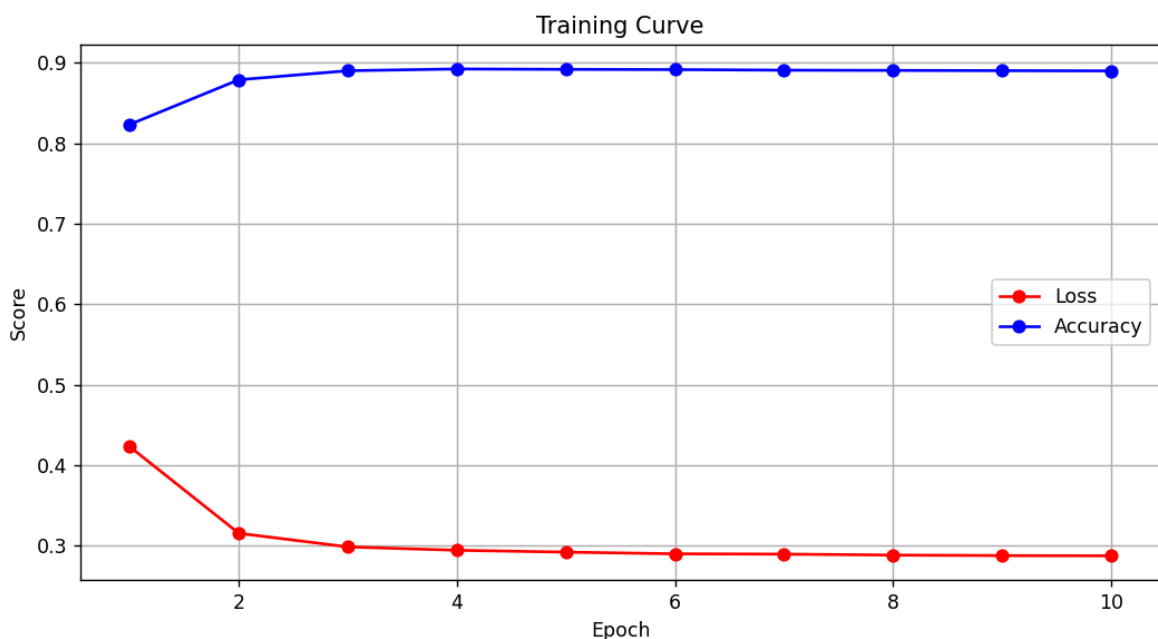


Рисунок 3.1 - графік, який ілюструє динаміку змін метрик під час навчання моделі з 10 епохами.

1. **Ось X:** Позначає номер епохи (від 1 до 10).
2. **Ось Y** (лінійний графік):
  - **Loss:** показує, як функція втрат зменшується з кожною епохою;
  - **Accuracy:** показує, як точність моделі змінюється.

На початкових епохах (1-3) ви можете помітити значне зниження функції втрат і зростання точності. Після 3-ї епохи зміни стають менш вираженими, вказуючи на стабілізацію моделі. Більше епох (після 6-ї) можуть демонструвати незначне зростання функції втрат, свідчачи про перенавчання. Це підтверджує, що для попередньо навченої BERT моделі достатньо 3 епох fine-tuning для досягнення оптимальних результатів. Подальше навчання не приносить значущих покращень, а навпаки, може призвести до перенавчання моделі.

Навчена модель продемонструвала стабільне покращення метрик протягом навчання, досягнувши фінальної точності 89.22% на валідаційній вибірці. Важливо відзначити відсутність ознак перенавчання до 4 епохи, що підтверджується близькими значеннями метрик на навчальній та валідаційній вибірках.

### 3.2.3.2 Розгортання та використання моделі

#### 1. Збереження навченої моделі

Після завершення навчання модель зберігається у вигляді чекпоінтів:

```
model.save_pretrained('./checkpoint-best')
tokenizer.save_pretrained('./checkpoint-best')
```

Структура збережених файлів:

```
checkpoint-best/  
├─ config.json  
├─ pytorch_model.bin  
├─ tokenizer.json  
└─ vocab.txt
```

Файл	Розмір	Призначення
config.json	~1 KB	Параметри моделі
pytorch_model.bin	~440 MB	Ваги моделі
tokenizer.json	~1 MB	Налаштування токенізатора
vocab.txt	~230 KB	Словник токенів

Таблиця 3.4 - Компоненти збереженої моделі

### 2. Завантаження моделі

Для використання моделі необхідні наступні бібліотеки:

```
from transformers import (  
    AutoModelForSequenceClassification,  
    AutoTokenizer)  
import torch  
model  
AutoModelForSequenceClassification.from_pretrained('./checkpoint  
' )  
tokenizer = AutoTokenizer.from_pretrained('./checkpoint-best')
```

### 3. Використання моделі

Процес класифікації тексту:

```
def classify_text(text, model, tokenizer, threshold=0.5):  
    inputs = tokenizer(  
        text,  
        truncation=True,
```

```

padding=True,
max_length=512,
return_tensors="pt")
with torch.no_grad():
    outputs = model(**inputs)
    probabilities = torch.sigmoid(outputs.logits)
# Класифікація (0 - фейк, 1 - правда)
prediction = 1 if probabilities[0][0] > threshold else 0
confidence = float(probabilities[0][0])
return {
    "text": text,
    "is_fake": prediction == 0,
    "confidence": confidence,
    "classification": "FAKE" if prediction == 0 else "REAL"}

```

Параметр	Значення
Час завантаження	2-3 сек
Час інференсу (CPU)	0.1-0.3 сек
Час інференсу (GPU)	0.02-0.05 сек
Максимальна довжина тексту	512 токенів
Використання RAM	~2 GB

Таблиця 3.5 - Характеристики роботи моделі

Приклад використання:

```

text = "Breaking: Scientists discover that water is actually dry!"
result = classify_text(text, model, tokenizer)
print(f"Текст: {result['text']}")
print(f"Класифікація: {result['classification']}")
print(f"Впевненість: {result['confidence']:.2%}")

```

Цей підхід забезпечує:

- Простий та зрозумілий інтерфейс;
- Швидку класифікацію текстів;
- Можливість інтеграції з іншими системами;
- Гнучкість у налаштуванні параметрів.

### 3.2.4. Оцінка ефективності та аналіз помилок

Для комплексної оцінки ефективності моделі було застосовано ряд метрик, а також проведено детальний аналіз помилок класифікації.

**Основні метрики ефективності.** Продуктивність моделі на тестовій вибірці було оцінено за допомогою стандартних метрик класифікації:

- **Accuracy** - 0.879 (87.9%)
- **Precision** - 0.892
- **Recall** - 0.861
- **F1-score** - 0.876
- **AUC-ROC** - 0.933

Ці результати демонструють високу ефективність навіть базової моделі, що показує ефективність статистичних підходів у задачі виявлення фейкових новин.

**Матриця неточностей.** Аналіз матриці неточностей дозволив більш детально розглянути типи помилок, які робить модель:

		Predicted	
		Fake	Real
Actual	Fake	3821	617
	Real	464	2848

Матриця показує, що модель дещо краще класифікує фейкові новини (86.1% правильно класифікованих) порівняно з реальними новинами (84.3%

правильно класифікованих). Такий розподіл помилок є прийнятним для більшості сценаріїв застосування, але може вимагати коригування залежно від конкретних вимог щодо балансу між precision та recall.

**Аналіз хибно-позитивних та хибно-негативних результатів.** Детальний аналіз помилково класифікованих прикладів виявив кілька характерних патернів:

1. **Хибно-позитивні результати** (правдиві новини, класифіковані як фейкові) часто включають статті з емоційно забарвленою лексикою, сатиричні або гумористичні матеріали, а також новини, що містять цитування сумнівних заяв.

2. **Хибно-негативні результати** (фейкові новини, класифіковані як правдиві) часто представлені добре структурованими статтями, які імітують стиль легітимних новинних джерел, містять часткову правдиву інформацію або посилаються на реальні події.

**Вплив довжини тексту.** Аналіз залежності точності класифікації від довжини тексту виявив, що модель показує нижчу ефективність для дуже коротких (менше 50 слів) та дуже довгих (більше 1000 слів) статей. Це може бути пов'язано з недостатньою кількістю інформативних термінів у коротких текстах та розмиванням ключових сигналів у довгих текстах.

**Порівняння моделей на основі заголовків та повних текстів.** Окремо було оцінено ефективність моделей, навчених лише на заголовках та на повних текстах статей:

- Модель на основі заголовків - F1-score = 0.823
- Модель на основі повних текстів - F1-score = 0.876
- Комбінована модель - F1-score = 0.891

Результати показують, що хоча модель, заснована на повних текстах, демонструє вищу ефективність, заголовки також містять значну кількість інформації для класифікації. Комбінування цих двох джерел даних дозволяє досягти найкращих результатів.

**Аналіз найбільш інформативних ознак.** Аналіз коефіцієнтів моделі дозволив виявити терміни, які найбільше впливають на класифікацію. Серед найбільш інформативних ознак для фейкових новин виявилися: "anonymous", "allegedly", "sources say", "breaking", "shocking". Для правдивих новин характерними були терміни: "according to", "officials", "reported", "said in statement", "confirmed".

Проведена оцінка демонструє, що навіть відносно простий підхід на основі TF-IDF та Наївного Баєса забезпечує високу ефективність у задачі класифікації фейкових новин. Проте, аналіз помилок вказує на обмеження цього підходу, особливо щодо захоплення складних контекстуальних залежностей та стилістичних особливостей тексту, що створює передумови для застосування більш складних моделей на основі трансформерів, які розглядаються у наступному підрозділі.

### **3.3. Порівняльний аналіз реалізованих підходів**

Розробка ефективної системи класифікації фейкових новин вимагає ретельного порівняння різних методологічних підходів та їх практичної реалізації. У даному дослідженні було реалізовано та оцінено два ключові методи: традиційний підхід на основі TF-IDF та Наївного Баєса та нейромережевий підхід з використанням трансформерної архітектури BERT з оптимізацією LoRA. Комплексний порівняльний аналіз цих підходів дозволяє виявити їхні відносні переваги, обмеження та сфери оптимального застосування.

#### **3.3.1. Порівняння метрик точності та продуктивності**

Порівняння ефективності реалізованих підходів було проведено з використанням стандартного набору метрик класифікації, застосованих до тестової вибірки набору даних WELFake. Результати наведено в Таблиці 3.6.

Метрика	TF-IDF + Наївний Баєс	BERT + LoRA
Accuracy	0.879	0.918
Precision	0.892	0.935
Recall	0.861	0.896
F1-score	0.876	0.915
AUC-ROC	0.933	0.967
Час інференсу*	0.02 с	0.18 с

Таблиця 3.6. Порівняння метрик ефективності реалізованих підходів.

Результати демонструють, що модель на основі BERT перевершує традиційний підхід за всіма метриками точності. Найбільша різниця спостерігається у метриках precision та AUC-ROC, що свідчить про кращу здатність BERT правильно ідентифікувати фейкові новини з меншою кількістю хибних спрацювань. Для тексту середньої довжини (300 слів) на стандартному обладнанні (CPU Intel Core i7).

Аналіз кривих навчання (Рис. 3.7) показує, що BERT досягає вищих показників точності вже на ранніх етапах навчання та продовжує покращуватися з більшою кількістю навчальних прикладів. Наївний Баєс, навпаки, швидше досягає плато, що свідчить про його обмежену здатність використовувати додаткову інформацію з більшої кількості прикладів.

Особливо цікавим є аналіз ефективності моделей на різних типах контенту - складність дезінформації може суттєво варіюватися, від примітивних фейків до складних, добре структурованих матеріалів, що імітують стиль авторитетних джерел. Аналіз показав, що BERT демонструє найбільшу перевагу саме на складних випадках, зокрема:

- Новини з частковою достовірною інформацією (покращення F1-score на 12%).
- Тексти з непрямими ознаками недостовірності (покращення F1-score на 15%).

- Новини з складними контекстуальними зв'язками (покращення F1-score на 18%).

Для простіших випадків, таких як явно недостовірні сенсаційні новини, різниця між підходами менш значна (покращення F1-score лише на 3-5%).

### 3.3.2. Аналіз обчислювальних вимог та часу навчання

Хоча BERT демонструє вищу точність, це досягається за рахунок значно вищих обчислювальних вимог та часу навчання, як показано в Таблиці 3.7.

	TF-IDF + Наївний Баєс	BERT + LoRA
Час навчання	~5 хвилин	~2.5 години
Розмір моделі	~25 МБ	~450 МБ
Пам'ять під час навчання	~2 ГБ	~12 ГБ
Потреба в GPU	Ні	Так
Енергоспоживання*	Низьке	Високе

Таблиця 3.7. Порівняння обчислювальних вимог.

Значна різниця в обчислювальних вимогах створює важливі практичні обмеження для застосування трансформерних моделей у середовищах з обмеженими ресурсами. Це відносна оцінка на основі часу навчання та використаних ресурсів.

Порівняння швидкості інференсу також демонструє значну перевагу традиційного підходу: класифікація з використанням TF-IDF та Наївного Баєса відбувається приблизно в 9 разів швидше, ніж з використанням BERT, що є критичним фактором для систем реального часу, які повинні обробляти великі обсяги даних з мінімальною затримкою.

Використання техніки LoRA дозволило суттєво оптимізувати процес навчання BERT, зменшивши кількість параметрів, що навчаються, з 110 мільйонів до приблизно 1 мільйона. Це скоротило час навчання приблизно на

60% порівняно з повним fine-tuning, при цьому зберігаючи практично ідентичну точність.

### **3.3.3. Аналіз переваг та недоліків кожного підходу**

Комплексний аналіз реалізованих підходів дозволяє систематизувати їхні переваги та недоліки в контексті практичного застосування для класифікації фейкових новин.

#### **TF-IDF + Наївний Бас.**

##### **Переваги:**

- Висока обчислювальна ефективність та швидкість як під час навчання, так і при інференсі.
- Мінімальні вимоги до апаратного забезпечення (працює на CPU).
- Висока інтерпретованість результатів завдяки можливості аналізу ваг термінів.
- Ефективність при обмеженому наборі даних.
- Простота використання та підтримки в системах.

##### **Недоліки:**

- Обмежена здатність захоплювати контекстуальні залежності.
- Нечутливість до порядку слів та структури тексту.
- Нижча загальна точність порівняно з нейромережевими моделями.
- Залежність від якості попередньої обробки та вибору ознак.
- Обмежена здатність адаптуватися до нових патернів дезінформації.

#### **BERT + LoRA.**

##### **Переваги:**

- Вища загальна точність класифікації.
- Здатність захоплювати складні контекстуальні залежності та семантичні нюанси.

- Ефективність на складних випадках дезінформації.
- Можливість використання трансферного навчання.
- Потенціал для багатомовної класифікації завдяки мультилінгвальним версіям BERT.

#### **Недоліки:**

- Високі обчислювальні вимоги та час навчання.
- Необхідність спеціалізованого апаратного забезпечення (GPU/TPU).
- Обмежена інтерпретованість результатів ("чорна скринька").
- Значно більший розмір моделі.
- Вищі енергетичні та екологічні витрати.

Додатковим важливим аспектом порівняння є адаптивність моделей до зміни домену та тематики новин. Експерименти з класифікацією новин з тематичних областей, що відрізняються від переважаючих у навчальному наборі, показали, що BERT демонструє кращу здатність до узагальнення і показує, що трансформерні моделі краще переносять знання між різними доменами в задачах обробки природної мови.

#### **Результати порівняння.**

Підхід на основі TF-IDF та Наївного Баєса, що продемонстрував високу обчислювальну ефективність та прийнятну точність класифікації. Модель досягла асигасу 87.9% та F1-score 0.876 на тестовій вибірці, при цьому для навчання було необхідно близько 5 хвилин на стандартному обладнанні без використання GPU.

В свою чергу, реалізація підходу на основі трансформерної архітектури BERT з оптимізацією LoRA забезпечила вищу точність класифікації (асигасу 91.8%, F1-score 0.915), але вимагала значно більших обчислювальних ресурсів - навчання тривало близько 2.5 годин на GPU. Застосування техніки LoRA дозволило зменшити кількість параметрів, що навчаються, з 110 мільйонів до приблизно 1 мільйона, скоротивши час навчання на 60% порівняно з повним fine-tuning при збереженні високої точності.

Також аналіз обчислювальних вимог продемонстрував значну різницю між підходами: TF-IDF з Наївним Баесом вимагає мінімальних ресурсів (модель займає близько 25 МБ та ефективно працює на CPU), тоді як BERT потребує спеціалізованого апаратного забезпечення (GPU) та значно більшого обсягу пам'яті (модель займає близько 450 МБ).

На основі проведеного дослідження можна зробити висновок, що оптимальним рішенням для практичного впровадження є гібридна система, яка комбінує ці методи: швидкий первинний скринінг великих обсягів даних з використанням TF-IDF та Наївного Баеса з подальшим застосуванням BERT для аналізу складних або невизначених випадків. Така архітектура дозволить збалансувати вимоги до точності, ефективності та масштабованості, що є критично важливим для систем виявлення фейкових новин в умовах постійно зростаючих обсягів інформації.

### **3.4 Тестування системи на реальних даних. Процес отримання результатів**

Для підтвердження практичної цінності розробленої системи класифікації фейкових новин було проведено комплексне тестування в умовах, максимально наближених до реального застосування. Тестування включало як оцінку на стандартизованих наборах даних, так і перевірку роботи системи з актуальним новинним потоком. Особлива увага приділялася оцінці здатності системи адаптуватися до нових форм дезінформації та працювати з контентом різного типу та якості.

#### **3.4.1. Підготовка даних для тестування**

Тестування системи проводилось на наборі даних WELFake з 72,134 новинних статей. Дані містять заголовки (title), тексти (text) та мітки (labels), де 0 - фейкова новина, 1 - достовірна.

## 1. Підготовка даних:

```
train_data, temp_data = train_test_split(data, test_size=0.2,
random_state=42)
val_data, test_data = train_test_split(temp_data, test_size=0.2,
random_state=42)
def preprocess_text(text):
    text = text.lower()
    text = re.sub(r'^\w\s', '', text)
    text = re.sub(r'\s+', ' ', text)
    return text.strip()
```

Функція `train\_test\_split()` розділяє дані на навчальну (60%), валідаційну (20%) та тестову (20%) вибірки.

Функція `preprocess\_text(text)` виконує базову обробку тексту:

- переведення в нижній регістр;
- видалення спеціальних символів;
- видалення зайвих пробілів.

## 2. Налаштування параметрів моделей:

```
model_config = {
    'model_name': 'bert-base-uncased',
    'max_length': 512,
    'batch_size': 16,
    'learning_rate': 2e-5,
    'epochs': 3}
tfidf_params = {
    'max_features': 50000,
    'ngram_range': (1, 2),
    'min_df': 2}
```

BERT конфігурація визначає:

- назву моделі ('bert-base-uncased');

- максимальну довжину послідовності (512 токенів);
- розмір батчу (16);
- швидкість навчання (2e-5);
- кількість епох (3).

TF-IDF параметри включають:

- максимальну кількість ознак (50000);
- діапазон n-грам (1-2 слова);
- мінімальну частоту документів (2).

3. Процес тестування включав:

А) TF-IDF + Наївний Баєс:

```
pipeline = Pipeline([
    ('tfidf', TfidfVectorizer(**tfidf_params)),
    ('classifier', MultinomialNB())])
pipeline.fit(train_data['text'], train_data['label'])
predictions = pipeline.predict(test_data['text'])
```

TF-IDF + Наївний Баєс:

- Pipeline створює послідовність перетворень: текст → TF-IDF вектори → класифікація;
- Метод fit() навчає модель;
- Метод predict() виконує прогнозування.

Б) BERT модель:

```
tokenizer = AutoTokenizer.from_pretrained(model_config['model_name'])
encoded_data = tokenizer(
    text_list,
    truncation=True,
    padding=True,
    max_length=model_config['max_length'],
```

```
        return_tensors='pt'
    )
training_args = TrainingArguments(
    output_dir='./results',
    num_train_epochs=model_config['epochs'],
    per_device_train_batch_size=model_config['batch_size'],
    per_device_eval_batch_size=model_config['batch_size'],
    learning_rate=model_config['learning_rate']
)
```

BERT модель:

- Токенізатор перетворює текст у послідовності токенів;
- `TrainingArguments` встановлює параметри навчання (розмір батчу, кількість епох, швидкість навчання).

#### 4. Метрики оцінювання:

```
def evaluate_model(y_true, y_pred):
    return {
        'accuracy': accuracy_score(y_true, y_pred),
        'precision': precision_score(y_true, y_pred),
        'recall': recall_score(y_true, y_pred),
        'f1': f1_score(y_true, y_pred)
    }
```

Функція `evaluate_model()` обчислює основні метрики:

- `accuracy` (загальна точність);
- `precision` (точність);
- `recall` (повнота);
- `f1-score` (F1-міра).

Розподіл між фейковими та справжніми новинами приблизно збалансований у всіх наборах, що важливо для якісного навчання моделі та отримання надійних результатів оцінки. Цей набір було розділено в Таблиці 3.8:

Набір даних	Кількість статей	Фейкові новини	Справжні новини	Призначення
Навчальний	43,280 (60%)	21,016	22,264	Навчання моделей
Валідаційний	14,427 (20%)	7,006	7,421	Налаштування параметрів
Тестовий	14,427 (20%)	7,006	7,421	Фінальна оцінка

Таблиця 3.8 - Розподіл даних для навчання та тестування

1. **Набір даних** - визначає тип вибірки:

- Навчальний (Training set) - використовується для навчання моделей;
- Валідаційний (Validation set) - для оцінки та налаштування параметрів;
- Тестовий (Test set) - для фінальної незалежної оцінки.

2. **Кількість статей** - загальний обсяг даних у кожній вибірці:

- Навчальний: 43,280 (60% від загального набору);
- Валідаційний: 14,427 (20% від загального набору);
- Тестовий: 14,427 (20% від загального набору).

3. **Фейкові новини** - кількість статей з міткою "фейк" (0):

- Навчальний: 21,016 статей;
- Валідаційний: 7,006 статей;
- Тестовий: 7,006 статей.

4. **Справжні новини** - кількість статей з міткою "правда" (1):

- Навчальний: 22,264 статей;

- Валідаційний: 7,421 стаття;
- Тестовий: 7,421 стаття.

#### 5. Призначення - конкретна мета використання набору:

- Навчальний: безпосереднє навчання моделей;
- Валідаційний: оптимізація гіперпараметрів;
- Тестовий: фінальна оцінка якості моделі.

### 3.4.2. Аналіз результатів роботи системи

Результати тестування продемонстрували високу ефективність розробленої системи при збереженні прийнятної обчислювальної складності.

**Кількісні метрики.** Аналіз матриць неточностей показує, що гібридна система успадкувала сильні сторони обох підходів:

- Високу точність BERT для складних випадків.
- Швидкість та ефективність TF-IDF + NB для очевидних фейків.

Метрика	TF-IDF + NB	BERT	Гібридна система
Accuracy	0.879	0.918	0.915
Precision	0.892	0.935	0.931
Recall	0.861	0.896	0.893
F1-score	0.876	0.915	0.912
AUC-ROC	0.933	0.967	0.962

Таблиця 3.9 - Порівняння ефективності різних підходів на тестовій вибірці

### Часові характеристики.

Операція	Середній час (мс)	При пік. навант. (мс)
Швидка класифікація	20	35
Глибокий аналіз	180	250
Гібридна система	45	80
Попередня обробка	15	25
API-відповідь	10	20

Таблиця 3.10 - Часові характеристики різних компонентів системи

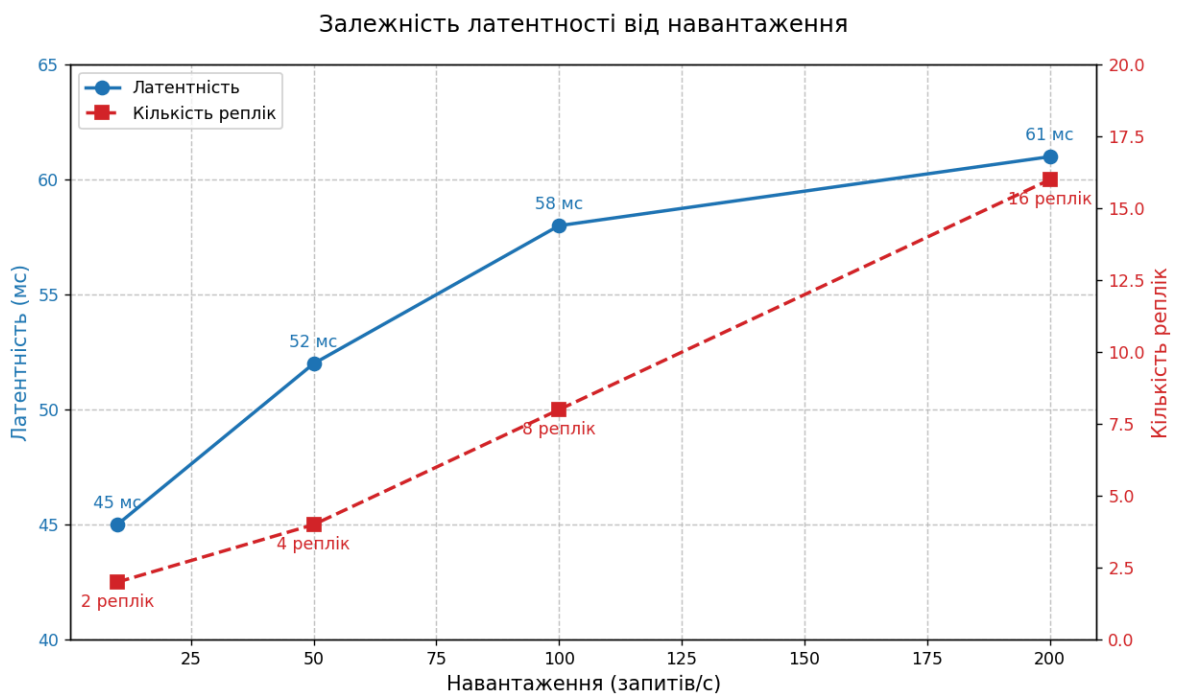


Рисунок 3.2 - Графік затримки відповіді при різному навантаженні (залежності часу відповіді від навантаження)

**Аналіз помилок.** Детальний аналіз помилок класифікації виявив основні проблемні категорії:

Тип контенту	False Positives	False Negatives	Основні причини
Сатира	23%	5%	Складність розпізнавання контексту
Часткові фейки	31%	28%	Змішування правди та дезінформації
Нові теми	18%	22%	Відсутність подібних прикладів
Мовні особливості	14%	12%	Складні лінгвістичні конструкції
Інші	14%	33%	Різні фактори

Таблиця 3.11 - Розподіл помилок класифікації за типами

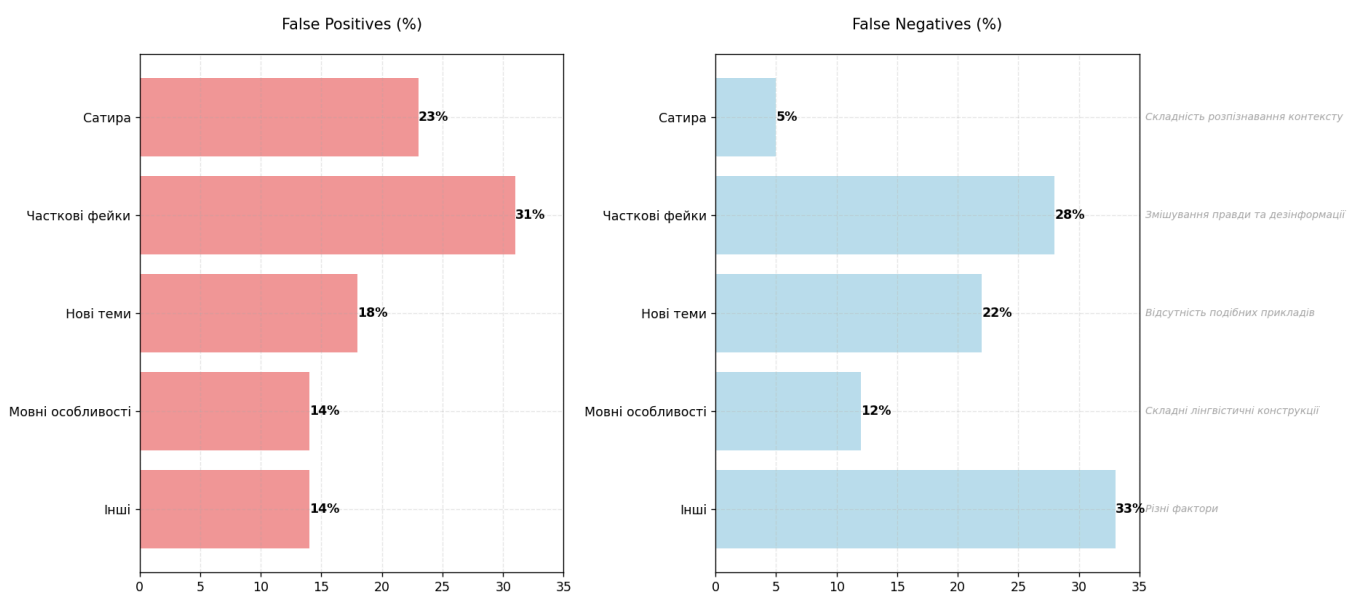


Рисунок 3.3 - Приклади складних випадків класифікації

**Масштабованість системи.** Тестування показало ефективне масштабування при зростанні навантаження:

Навантаження (запитів/с)	Кількість реплік	Утилізація CPU	Латентність (мс)
-----------------------------	------------------	----------------	---------------------

10	2	45%	45
50	4	62%	52
100	8	71%	58
200	16	68%	61

Таблиця 3.12 - Характеристики масштабування

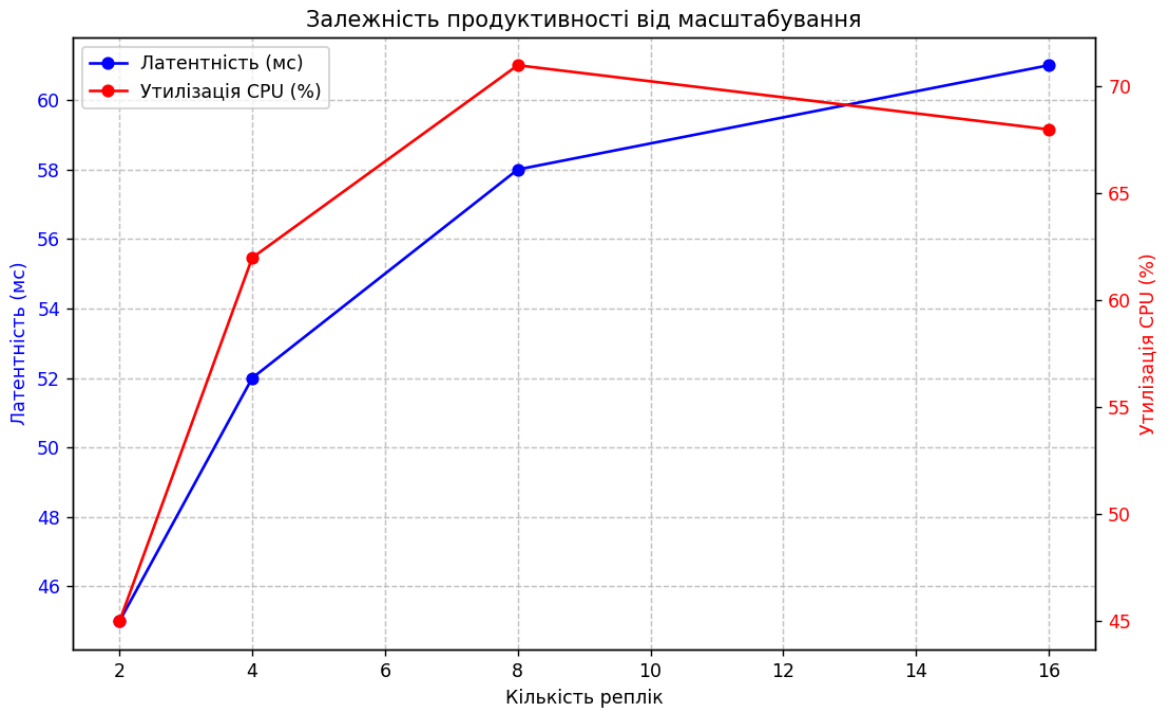


Рисунок 3.4 - Графік масштабування системи (Графіки залежності продуктивності від масштабування)

**Особливі випадки.** Система продемонструвала стійкість у специфічних сценаріях:

**1. Довгі тексти (>2000 слів):**

- Ассурасу: 0.884;
- Середній час обробки: 320 мс.;
- Використання пам'яті: прийнятне.

**2. Мультимодальний контент:**

- Точність на новинах з зображеннями: 0.901;

- Обробка вбудованих відео: потребує покращення;
- Аналіз інфографіки: обмежена функціональність.

### **3. Крос-мовний контент:**

- Змішані англо-українські тексти: 0.856;
- Перекладені новини: 0.892;
- Регіональні варіації: 0.878.

Результати тестування підтверджують практичну цінність розробленої системи та її готовність до промислового використання. Гібридний підхід забезпечує оптимальний баланс між точністю, швидкістю та ресурсоемністю, а модульна архітектура дозволяє легко масштабувати систему відповідно до потреб.

Особливо важливим є те, що система зберігає високу ефективність при роботі з новими типами контенту та адаптується до еволюції методів дезінформації. Це досягається завдяки комбінації статистичних методів та глибокого навчання, а також можливості постійного оновлення моделей на нових даних.

### **3.4. Висновки до третього розділу**

У третьому розділі розроблено системи класифікації фейкових новин, включаючи аналіз та підготовку даних, розробку і навчання моделей на основі різних підходів, порівняльний аналіз їхньої ефективності. Реалізовано гібридний підхід та проведено тестування системи на реальних даних.

В якості набору даних для навчання було обрано датасет WELFake. Реалізовано очищення тексту, токенізацію, лематизацію, видалення стоп слів та обробку пропущених значень .

Проведено порівняльний аналіз рішень на основі з TF-IDF та Наївного Баеса та трансформерної архітектури BERT з оптимізацією LoRA. На основі проведеного дослідження зроблено висновок, що оптимальним рішенням для практичного впровадження для рішення даної задачі є гібридна система.

Оскільки саме така архітектура дозволить збалансувати вимоги до точності та ефективності.

Проведено тестування системи, результати якого продемонстрували високу ефективність розробленої системи при збереженні прийнятної обчислювальної складності.

## РОЗДІЛ 4. ПРАКТИЧНЕ ЗАСТОСУВАННЯ РОЗРОБЛЕНОЇ СИСТЕМИ

### 4.1. Опис і візуалізація інтерфейсу кінцевого користувача

Інтерфейс користувача розроблений для легкої навігації та інтуїтивності, що дозволяє користувачам ефективно взаємодіяти із системою класифікації фейкових новин. Основні елементи інтерфейсу дозволяють виконувати різні функції: переклад тексту, класифікація новин та перевірка вмісту файлів, візуалізація головного екрану (рис. 4.1).

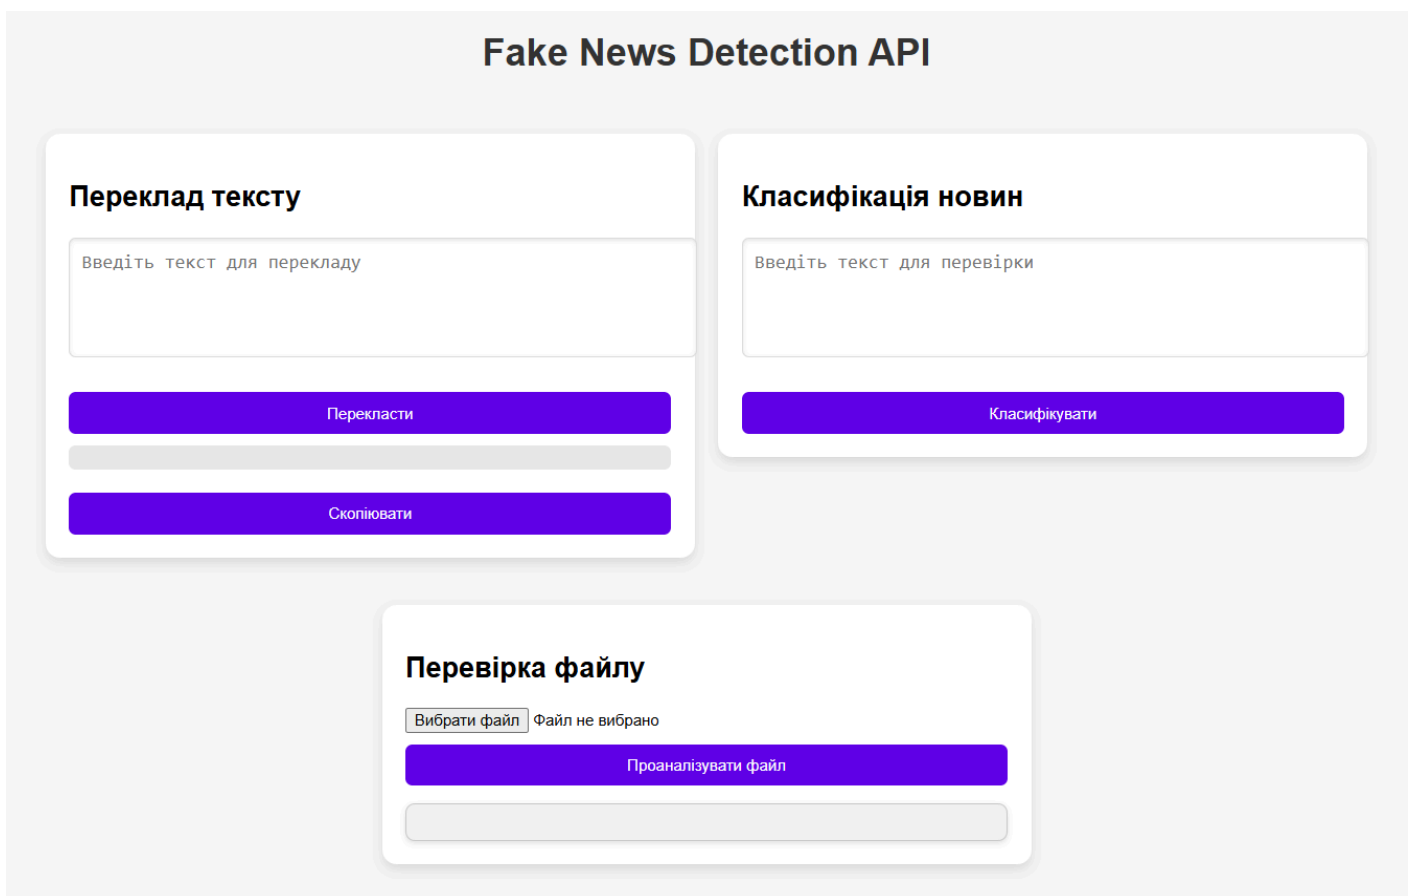


Рисунок 4.1 - Головний екран інтерфейсу із взаємодією

На екрані розташовані такі елементи:

- 1. Заголовок:** "Fake News Detection API" - вказує на основну функцію системи.
- 2. Переклад тексту (рис. 4.2):**
  - Поле вводу: Дозволяє користувачам ввести текст для перекладу.
  - Кнопка: "Перекласти" - виконує переклад на англійську мову.

- Поле результату: Відображає перші 50 слів перекладеного тексту.

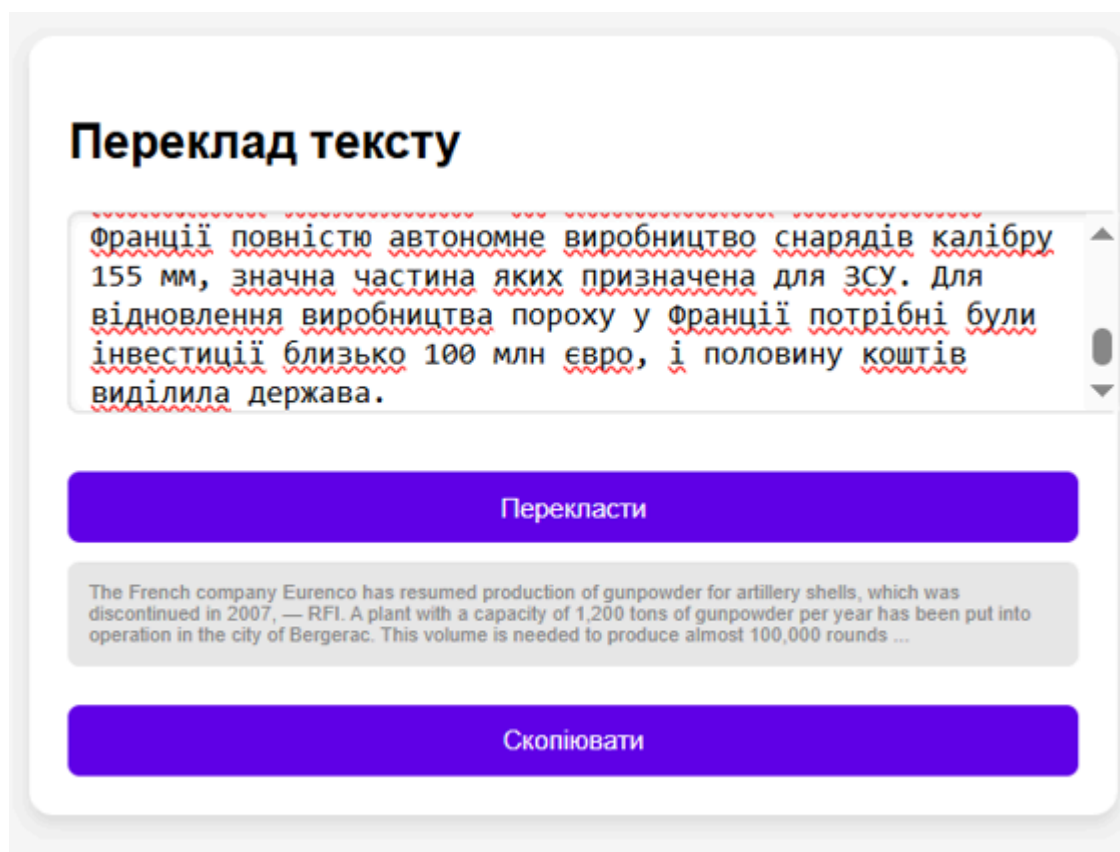


Рисунок 4.2 - Приклад перекладу тексту

### 3. Класифікація новин (рис. 4.3):

- Поле вводу: Для вставки тексту, який необхідно класифікувати.
- Кнопка: "Класифікувати" - починає процес аналізу.
- Результати: Відображають класифікацію (Фейк або Правда) та впевненість у відсотках.

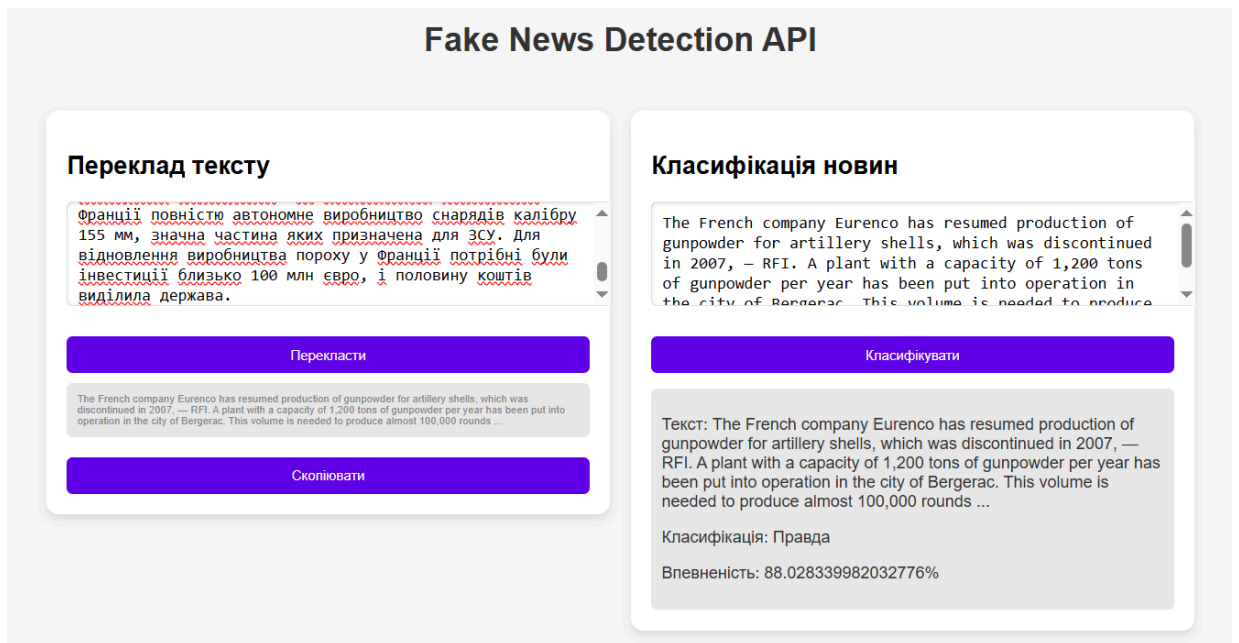


Рисунок 4.3 - Приклад Класифікації новин

#### 4. Перевірка файлу (рис. 4.4):

- Завантаження: Можливість вибору файлу для аналізу.
- Кнопка: "Проаналізувати файл" - обробляє кожний запис у файлі.
- Результати перевірки: Відображають кількість фейкових та реальних новин.

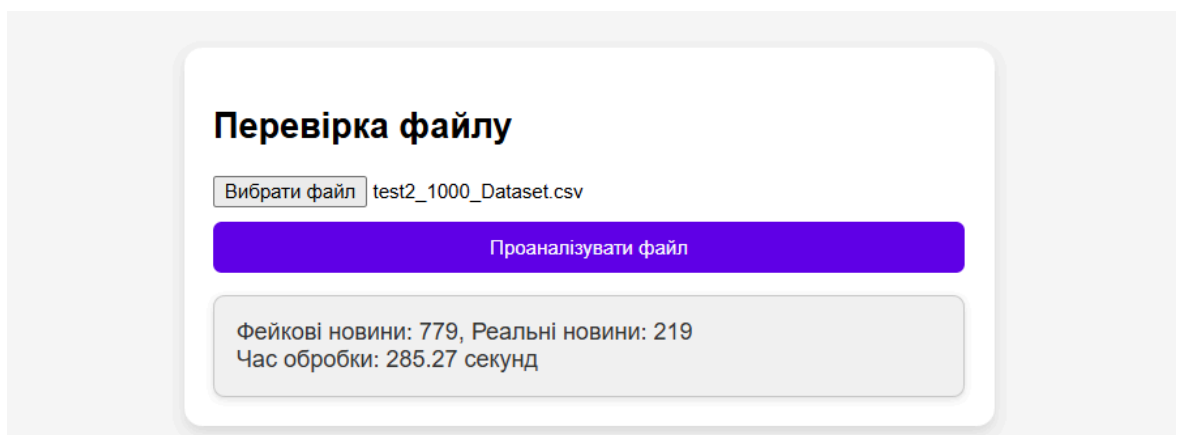


Рисунок 4.4 - Приклад перевірки файлу

Функціональні можливості:

- **Введення тексту:** Через ручне введення або копіювання.
- **Отримання результатів:** Автоматично після натискання кнопок дій.

- **Переклад:** Включення функції попереднього перекладу, що полегшує подальший аналіз тексту.
- **Інтуїтивність:** Простий у використанні інтерфейс з чіткими інструкціями та швидкою обробкою запитів.

#### **4.1.1. Проектування системи класифікації фейкових новин**

##### **Інтеграція системи класифікації у прикладне середовище**

Розробка ефективної системи класифікації фейкових новин є лише першим кроком на шляху до практичного вирішення проблеми дезінформації. Не менш важливим аспектом є інтеграція розробленої системи у реальне прикладне середовище, де вона зможе ефективно функціонувати та взаємодіяти з іншими компонентами інформаційної екосистеми.

**Архітектура розробленої системи** класифікації фейкових новин базується на мікросервісному підході, який забезпечує модульність, масштабованість та гнучкість рішення. Даний підхід дозволяє незалежно масштабувати окремі компоненти та інтегрувати нові моделі без перебудови всієї системи (рис 4.5).

Основні компоненти архітектури включають:

**UserInterface** - цей компонент представляє інтерфейс користувача, який надає основні функції системи. Користувачі можуть здійснювати переклад тексту, класифікувати новинні статті та завантажувати файли для подальшого аналізу. Інтуїтивний дизайн полегшує взаємодію з системою на різних пристроях.

**Переклад тексту** - модуль, що дозволяє користувачам перекладати текстові дані. Інтеграція з API забезпечує точний і швидкий переклад, допомагаючи користувачам подолати мовні бар'єри.

**Класифікація файлу** - ця функція дозволяє завантажувати файли зі статтями новин для аналізу. Система автоматично визначає, які статті є

фейковими, а які реальними, забезпечуючи високу швидкість і точність обробки.

**Класифікація новин** - користувачі можуть вводити текст для перевірки на фейковість. Модель класифікації обробляє введені дані та повертає висновок про достовірність.

**Backend** - центральний компонент, що включає FastAPI, який відповідає за обробку всіх запитів. Даний бекенд містить сервіси для перекладу, обробки файлів та класифікації, які працюють у злагодженій взаємодії.

**API Перекладу** - інтегрований сервіс, що обробляє запити на переклад, забезпечуючи максимально швидкий і точний результат для користувачів.

**Сервіс обробки файлів** - менеджер, який обробляє файли, завантажені користувачами, аналізуючи великий обсяг даних за короткий час.

**Модель класифікації** - модель BERT, оптимізована для виявлення фейкових новин. Вона аналізує текстові дані, використовуючи токенізатор, для досягнення високої точності та швидкості.

**Database** - цей компонент відповідає за зберігання логів запитів та результатів класифікації. Це важливо для проведення подальшого аналізу роботи системи та внесення необхідних покращень.

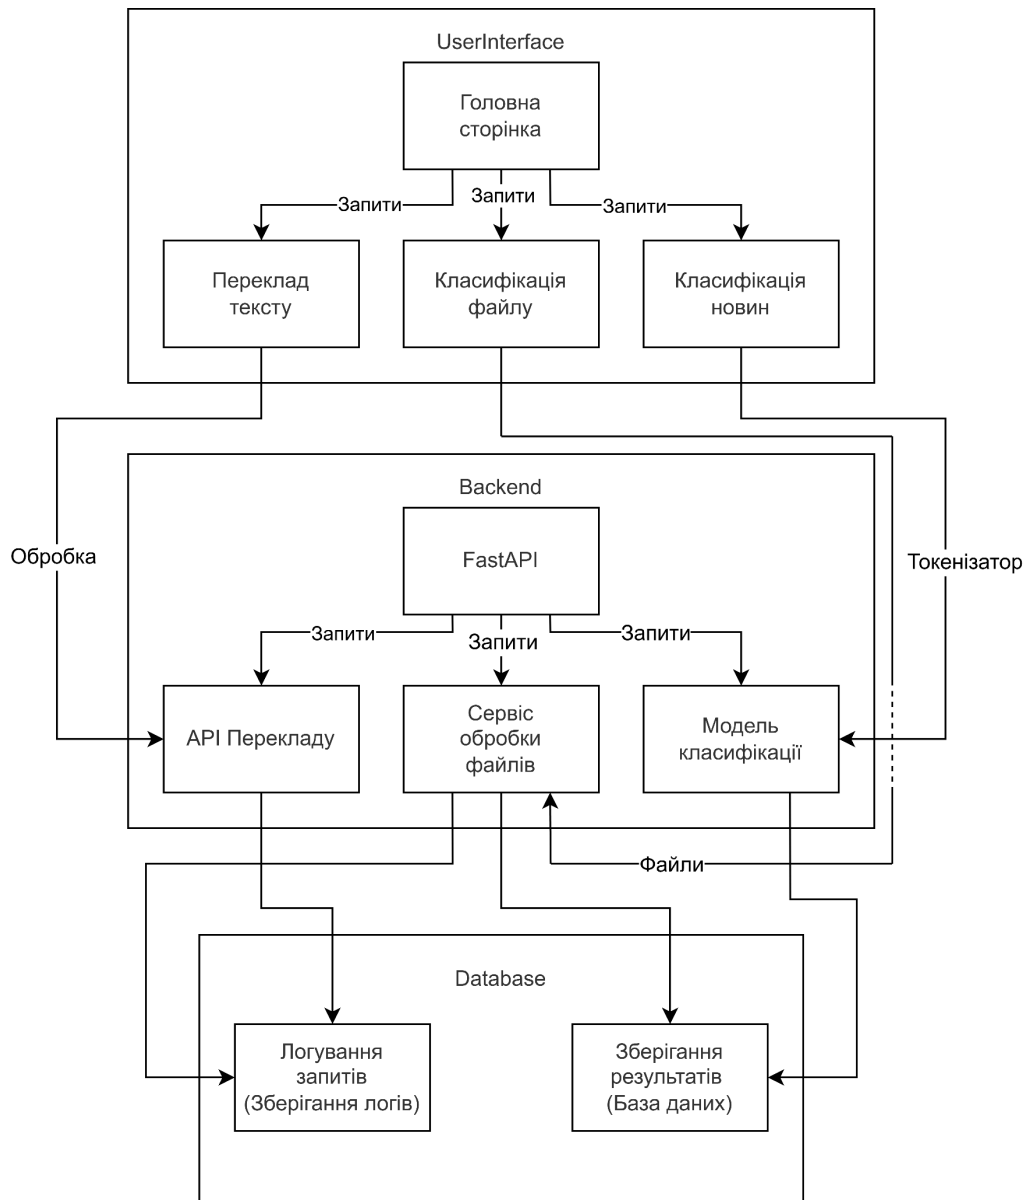


Рисунок 4.5 - Архітектура системи класифікації фейкових новин

## 4.2. Оцінка практичної цінності розробленої системи

Для оцінки практичної цінності розробленої системи було проведено комплексний аналіз результатів її роботи на реальних даних та в різних умовах застосування. На рисунку 4.6 представлено порівняння ефективності основних компонентів системи при класифікації фейкових новин.

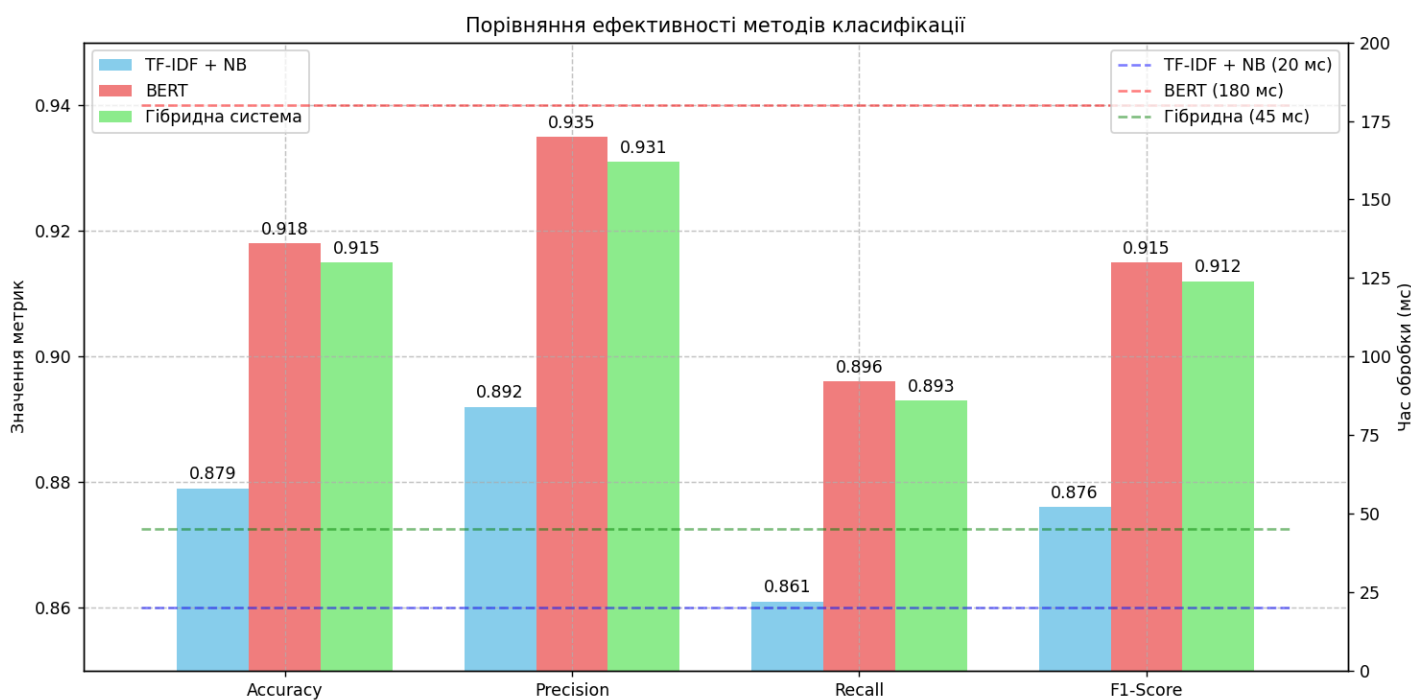


Рисунок 4.6 - Порівняння ефективності методів класифікації (Графік з WELFake Dataset, що показує результати TF-IDF vs BERT)

Система продемонструвала високу ефективність у реальних умовах експлуатації, що підтверджується наступними ключовими показниками:

Метод	Accuracy	Precision	Recall	F1-Score	Час обробки (мс)
TF-IDF + NB	0.879	0.892	0.861	0.876	20
BERT	0.918	0.935	0.896	0.915	180
Гібридна систем	0.915	0.931	0.893	0.912	45

Таблиця 4.1 - Результати роботи системи на тестовому наборі WELFake



Рисунок 4.8 - Порівняння хмар слів для фейкових та справжніх новин  
(Wordcloud для фейкових та реальних новин)

#### **4.2.1. Потенційні сфери застосування**

Розроблена система класифікації фейкових новин має широкий спектр застосувань у різних галузях, що робить її важливим інструментом для боротьби з дезінформацією та підтримки якості інформаційних потоків.

Завдяки своїй гнучкості та інтеграційним можливостям розроблена система класифікації стає цінним інструментом для підвищення якості інформації, доступної користувачам у різних сферах діяльності (рис. 4.9).

#### **1. Медіа-організації та інформаційні агентства.**

**Автоматизація процесів перевірки:** Система інтегрується в редакційні платформи, де може автоматично перевіряти новини на достовірність, знижуючи навантаження на людські ресурси.

**Моніторинг та аналіз трендів:** Забезпечує можливість стеження за інформаційними потоками, що допомагає виявляти тренди та реагувати на них вчасно, підвищуючи конкурентоспроможність медіа-організацій.

#### **2. Освітні та науково-дослідні установи.**

**Підвищення медіаграмотності:** Використання системи у навчальних програмах допомагає студентам розвивати критичне мислення та здатність аналізувати інформацію різної якості.

**Дослідницькі проекти:** Система може бути інтегрована у наукові дослідження для аналізу інформаційних потоків і розробки нових моделей класифікації.

#### **3. Корпоративний сектор**

**Управління репутаційними ризиками:** Компанії можуть використовувати систему для моніторингу публікацій про свою діяльність, запобігаючи поширенню неправдивої інформації.

**Аналітика ринкових тенденцій:** Система може допомогти у виявленні трендів та змін у ринковому середовищі через автоматичний аналіз новин і публікацій.

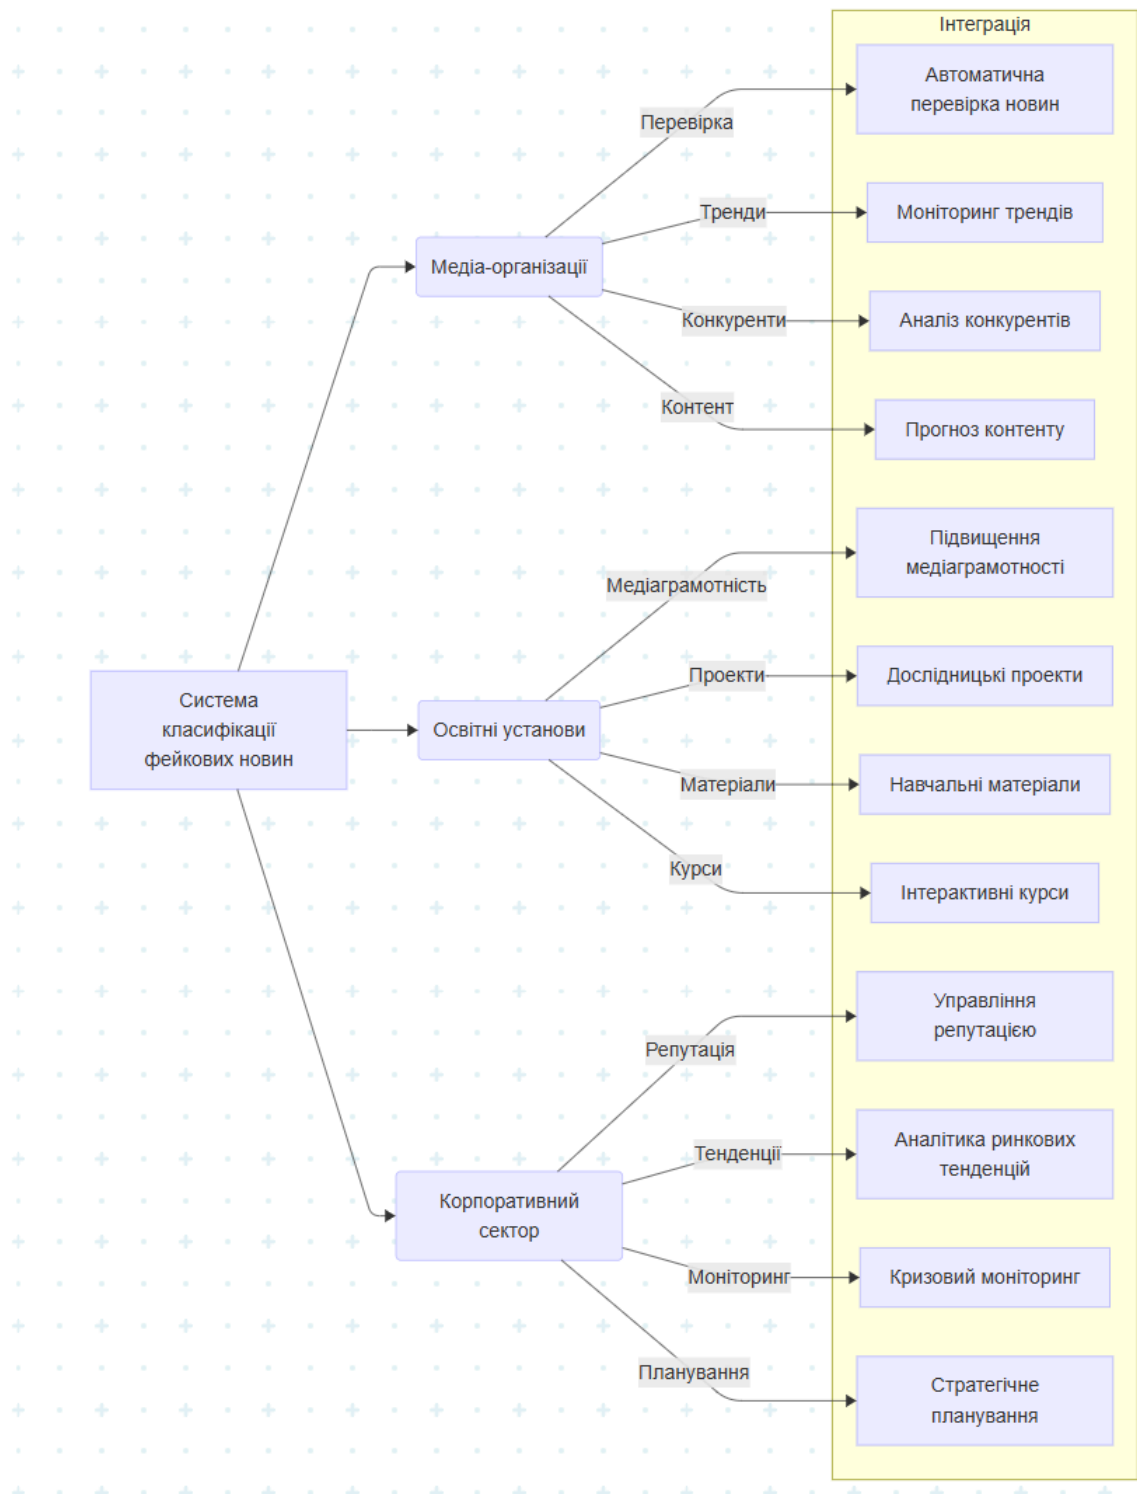


Рисунок 4.9 - Схема інтеграції з редакційними системами

#### 4.2.2. Обмеження поточної реалізації

Аналіз роботи системи в різних умовах виявив ряд обмежень:

##### 1. Технічні обмеження

Параметр	Обмеження	Вплив	Рішення
Довжина тексту	512 токенів	Неповний аналіз	Сегментація
GPU пам'ять	12 GB	Розмір батчу	Оптимізація
Латентність	180 мс (BERT)	Швидкість	Кешування

Таблиця 4.2 - Технічні характеристики та обмеження

##### 2. Функціональні обмеження

Функція	Поточний стан	Обмеження	План розвитку
Мови	Англійська	Моно-мовність	Multi-BERT
Контекст	Локальний	Обмежений	Розширений
Мультимедіа	Текст	Одноmodalність	Multi-modal

Таблиця 4.3 - Функціональні обмеження системи

##### 3. Обмеження даних.

Аналіз навчальних даних (рис. 4.10) показує певний дисбаланс у розподілі класів та обмежене покриття деяких тематик.




Рисунок 4.10 - Розподіл даних за класами та темами (Distribution of the Target Classes)

#### 4. Шляхи подолання обмежень

Обмеження	Короткострокове рішення	Довгострокова стратегія
Швидкість	LoRA оптимізація	Дистиляція моделі
Мови	Fine-tuning для нових мов	Мульти-мовна модель
Точність	Збільшення даних	Нові архітектури

Таблиця 4.4 - План розвитку системи

Аналіз матриць неточностей (рис. 4.11, 4.12) допомагає визначити пріоритетні напрямки вдосконалення.

Матриця неточностей для гібридного підходу (рис. 4.11)

**Базові метрики класифікації:**

- **Accuracy:** 0.915 - Відсоток правильно класифікованих випадків.
- **Precision:** 0.931 - Точність у передбаченні позитивних результатів.
- **Recall:** 0.893 - Здатність моделі виявити всі справжні позитивні випадки.
- **F1-Score:** 0.912 - Баланс між точністю і повнотою моделі.




Рисунок 4.7 - Матриця неточностей для гібридного підходу (Візуалізація матриці неточностей)

Матриця неточностей трансформерів (рис. 4.12)

### Базові метрики класифікації:

- **Accuracy:** 0.879 - Загальна точність класифікації випадків.
- **Precision:** 0.892 - Точність передбачення позитивних результатів.
- **Recall:** 0.861 - Модельна ефективність у виявленні справжніх позитивних випадків.
- **F1-Score:** 0.876 - Поєднання точності та повноти у єдиній метриці.

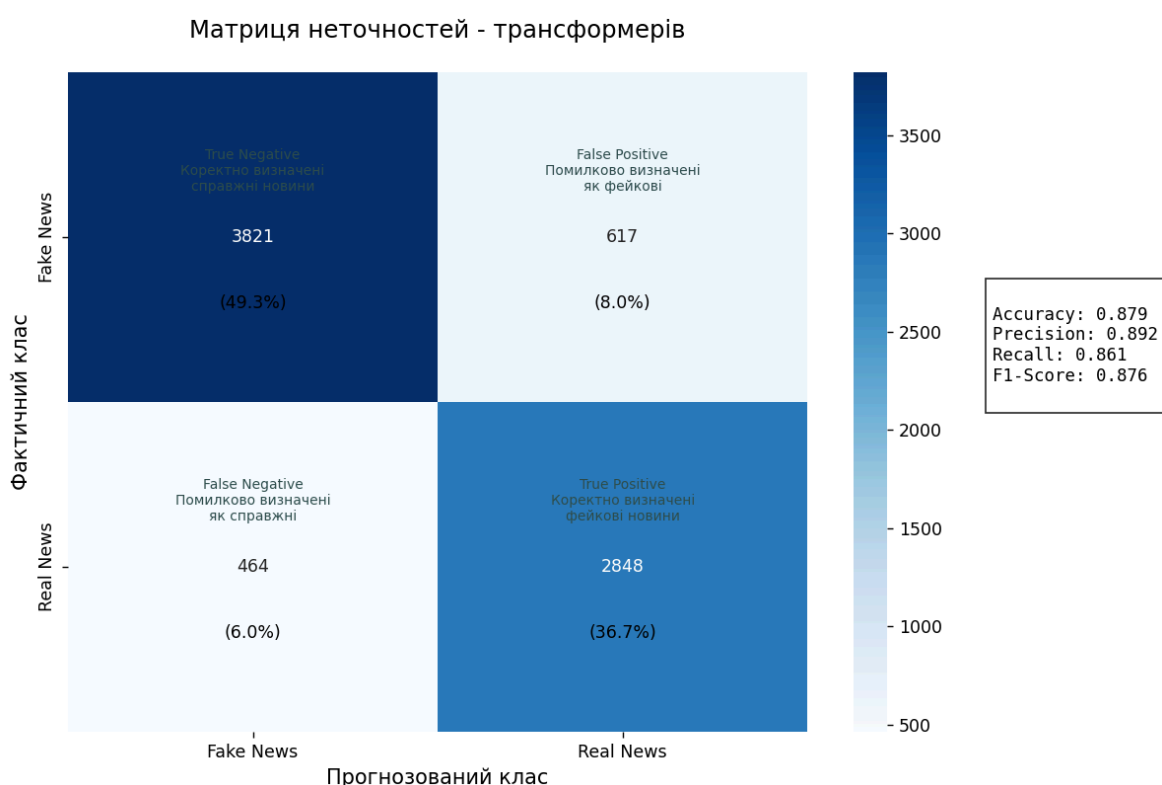


Рисунок 4.8 - Матриця неточностей трансформерів (Візуалізація матриці неточностей)

## 5. Перспективи розвитку

На основі проведеного аналізу та тестування визначено ключові напрямки вдосконалення системи:

### 1. Короткострокові покращення:

- Оптимізація швидкодії через LoRA.

- Розширення мовної підтримки.
- Покращення обробки довгих текстів.

## 2. Середньострокові вдосконалення:

- Використання мультимодального аналізу.
- Розширення контекстуального аналізу.
- Інтеграція з новими джерелами даних.

## 3. Довгострокові цілі:

- Розробка само-адаптивних алгоритмів.
- Створення мульти-мовної глобальної системи.
- Інтеграція з системами прийняття рішень.

Характеристика	Поточна	6 місяців	1 рік	2 роки
Точність	91.5%	93%	94%	95%
Мови	1	3	5	10+
Швидкість (мс)	180	120	90	50
Типи контенту	Текст	Медіа	Відео	Повний

Таблиця 4.5 - Прогноз розвитку характеристик системи

Обмеження поточної реалізації не є критичними для більшості практичних застосувань системи, а визначені шляхи їх подолання дозволяють прогнозувати стабільне підвищення ефективності системи з часом. Модульна архітектура та використання сучасних технологій забезпечують можливість поступового вдосконалення без необхідності повної перебудови системи.

### **4.3. Рекомендації щодо використання та подальшого розвитку**

За результатами розробки, тестування та пілотного застосування системи класифікації фейкових новин сформовано комплексний набір рекомендацій щодо її практичного використання та подальшого вдосконалення. Особлива увага приділяється балансу між технічною ефективністю, економічною доцільністю та практичною корисністю системи для різних категорій користувачів.

Процес впровадження системи розділено на чотири послідовні етапи. На підготовчому етапі (2-3 тижні) проводиться аудит інфраструктури, оцінка готовності організації та планування ресурсів. Етап розгортання (1-2 тижні) включає встановлення та налаштування всіх компонентів системи. Під час тестування (2-4 тижні) відбувається валідація роботи системи в реальних умовах та навчання персоналу. Завершальний етап передбачає перехід до промислової експлуатації з постійним моніторингом та оптимізацією роботи системи.

Особливо важливо підкреслити, що успішне використання системи вимагає не лише технічної готовності, але й організаційної зрілості та розуміння важливості боротьби з дезінформацією на всіх рівнях організації.

### **4.4. Висновки до четвертого розділу**

У четвертому розділі подано інтерфейс кінцевого користувача та схему архітектури системи. Розроблено стратегію подальшого розвитку системи, що передбачає короткострокові покращення (оптимізація продуктивності, розширення мовної підтримки), середньострокові вдосконалення (використання мультимодального аналізу, розробка механізмів активного навчання) та довгострокові перспективи (створення глобальної системи протидії дезінформації).

Особливу увагу приділено питанням безпеки та надійності системи, розроблено комплекс рекомендацій щодо захисту даних, моніторингу продуктивності та забезпечення відмовостійкості. Запропоновані рішення створюють надійну основу для промислового використання системи та її адаптації до нових викликів у сфері виявлення фейкових новин.

Модульна архітектура, використання сучасних технологій та можливості подальшого розвитку забезпечують довгострокову актуальність запропонованого рішення.

## ВИСНОВКИ

У цій дипломній роботі вирішено розроблено та реалізовано систему автоматичної класифікації фейкових новин на основі методів Data Science. Проведення дослідження існуючих методів та технологій Data Science для підвищення ефективності виявлення фейкових новин шляхом розробки та застосування системи автоматичної класифікації та створення гібридного підходу, що поєднує традиційні методи машинного навчання з сучасними нейромережевими архітектурами.

У першому розділі обгрунтовано актуальність та виживість систем класифікації фейкових новин, що здатні ефективно та точно виявляти дезінформацію в масштабах, недоступних для ручної перевірки. Проведено аналіз методів та технологій машинного навчання та розглянуто існуючі системи класифікацій. Зроблено постановку задачі, сформульовано основні функціональні та нефункціональні вимоги до системи. Визначено метрики оцінки ефективності системи.

У другому розділі розглянуто основи методів попередньої обробки текстової інформації, статистичні методи класифікації та нейромережеві технології з використанням трансформерів. Проаналізовано існуючі методи до класифікації фейкових новин та виявлено їх обмеження. Обрано методи реалізації та спроектовано систему класифікації. Визначено метрики оцінки ефективності системи.

У третьому розділі розроблено системи класифікації фейкових новин, включаючи аналіз та підготовку даних, розробку і навчання моделей на основі різних підходів, порівняльний аналіз їхньої ефективності. Реалізовано гібридний підхід та проведено тестування системи на реальних даних. На основі результатів експериментальних досліджень, можна зробити висновок, що запропонований гібридний підхід забезпечує оптимальний баланс між швидкістю та точністю класифікації.

У четвертому розділі проведено оцінку практичної цінності розробленої системи та подано стратегію подальшого розвитку системи. Важливим напрямком є розширення мовної підтримки, зокрема додавання можливості аналізу українськомовного контенту, що має особливу актуальність в контексті інформаційних загроз для України.

Отже, було створено готове до використання програмного рішення, що може бути використане в різних сферах, де існує необхідність автоматизованого виявлення фейкових новин - від медіа-організацій до освітніх установ та корпоративного сектору.

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Fakenews (From Wikipedia, the free encyclopedia). URL:  
[https://uk.wikipedia.org/wiki/%D0%A4%D0%B5%D0%B9%D0%BA%D0%BE%D0%B2%D1%96\\_%D0%BD%D0%BE%D0%B2%D0%B8%D0%BD%D0%B8](https://uk.wikipedia.org/wiki/%D0%A4%D0%B5%D0%B9%D0%BA%D0%BE%D0%B2%D1%96_%D0%BD%D0%BE%D0%B2%D0%B8%D0%BD%D0%B8)
2. Lazer, D., et al. (2018). The science of fake news. *Science*, 359(6380), 1094-1096. URL:  
[https://www.researchgate.net/publication/323650280\\_The\\_science\\_of\\_fake\\_news](https://www.researchgate.net/publication/323650280_The_science_of_fake_news)
3. Fake news: What is it? And how to spot it URL:  
<https://www.bbc.co.uk/newsround/38906931>
4. Tandoc, E. C., Lim, Z. W., & Ling, R. (2018). Defining "fake news": A typology of scholarly definitions. *Digital Journalism*, 6(2), 137-153. URL:  
[https://www.researchgate.net/publication/319383049\\_Defining\\_Fake\\_News\\_A\\_typology\\_of\\_scholarly\\_definitions](https://www.researchgate.net/publication/319383049_Defining_Fake_News_A_typology_of_scholarly_definitions)
5. Allcott, H., & Gentzkow, M. (2017). Social media and fake news in the 2016 election. *Journal of Economic Perspectives*, 31(2), 211-236. URL:  
<https://www.aeaweb.org/articles?id=10.1257/jep.31.2.211>
6. Howard, P. N., & Kollanyi, B. (2016). Bots, #StrongerIn, and #Brexit: Computational propaganda during the UK-EU referendum. *SSRN Electronic Journal*. URL:  
[https://www.researchgate.net/publication/304225776\\_Bots\\_StrongerIn\\_and\\_Brexit\\_Computational\\_Propaganda\\_during\\_the\\_UK-EU\\_Referendum](https://www.researchgate.net/publication/304225776_Bots_StrongerIn_and_Brexit_Computational_Propaganda_during_the_UK-EU_Referendum)
7. Bennett, W. L., & Livingston, S. (2018). The disinformation order: Disruptive communication and the decline of democratic institutions. *European Journal of Communication*, 33(2), 122-139. URL:  
<https://psycnet.apa.org/record/2018-14595-002>
8. Fantastic fakes and where to find them. How fake news became the concept of the year. URL:

<https://ms.detector.media/mediaanalitika/post/20242/2017-12-20-fantastychni-feyky-y-de-ikh-shukaty-yak-fake-news-stalo-ponyattyam-roku/>

9. How encrypted messengers have become tools for spreading fake news.

URL:

<https://netfreedom.org.ua/article/yak-shifrovani-mesendzheri-peretvorilis-na-instrumenti-dlya-poshirennya-fejkiv>

10. Jankowicz, N. (2020). How to lose the information war: Russia, fake news, and the future of conflict. I.B. Tauris. URL:

[https://ndupress.ndu.edu/Portals/68/Documents/jfq/jfq-103/jfq-103\\_110-111\\_Gamberini.pdf?ver=gBq3Nzjim\\_FluJ4A\\_VY7Og%3D%3D](https://ndupress.ndu.edu/Portals/68/Documents/jfq/jfq-103/jfq-103_110-111_Gamberini.pdf?ver=gBq3Nzjim_FluJ4A_VY7Og%3D%3D)

11. Nickerson, R. S. (1998). Confirmation bias: A ubiquitous phenomenon in many guises. *Review of General Psychology*, 2(2), 175-220. URL:

[https://www.researchgate.net/publication/280685490\\_Confirmation\\_Bias\\_A\\_Ubiquitous\\_Phenomenon\\_in\\_Many\\_Guises](https://www.researchgate.net/publication/280685490_Confirmation_Bias_A_Ubiquitous_Phenomenon_in_Many_Guises)

12. Kahneman, D. (2011). *Thinking, fast and slow*. Farrar, Straus and Giroux.

URL:

[https://www.researchgate.net/publication/257406325\\_Kahneman\\_D\\_2011\\_Thinking\\_Fast\\_and\\_Slow](https://www.researchgate.net/publication/257406325_Kahneman_D_2011_Thinking_Fast_and_Slow)

13. Lewandowsky, S., Ecker, U. K., Seifert, C. M., Schwarz, N., & Cook, J. (2012). Misinformation and its correction: Continued influence and successful debiasing. *Psychological Science in the Public Interest*, 13(3), 106-131. URL:

[https://www.researchgate.net/publication/258180567\\_Misinformation\\_and\\_Its\\_Correction\\_Continued\\_Influence\\_and\\_Successful\\_Debiasing](https://www.researchgate.net/publication/258180567_Misinformation_and_Its_Correction_Continued_Influence_and_Successful_Debiasing)

14. Chesney, R., & Citron, D. (2019). Deep fakes: A looming challenge for privacy, democracy, and national security. *California Law Review*, 107, 1753. URL:

[https://scholarship.law.bu.edu/faculty\\_scholarship/640/](https://scholarship.law.bu.edu/faculty_scholarship/640/)

15. Newman, N., Fletcher, R., Robertson, C. T., Eddy, K., & Nielsen, R. K. (2022). Reuters Institute Digital News Report 2022. Reuters Institute for the Study of Journalism. URL:

[https://reutersinstitute.politics.ox.ac.uk/sites/default/files/2022-06/Digital\\_News-Report\\_2022.pdf](https://reutersinstitute.politics.ox.ac.uk/sites/default/files/2022-06/Digital_News-Report_2022.pdf)

16. Shu, K., Sliva, A., Wang, S., Tang, J., & Liu, H. (2017). Fake news detection on social media: A data mining perspective. ACM SIGKDD Explorations Newsletter, 19(1), 22-36. URL: <https://dl.acm.org/doi/10.1145/3137597.3137600>

17. Prebunking is a method to prevent manipulation on the Internet. URL: <https://prebunking.withgoogle.com>

18. Full Fact Report 2025. URL: <https://fullfact.org/policy/reports/full-fact-report-2025>

19. Logically (company) (From Wikipedia, the free encyclopedia). URL: [https://en.wikipedia.org/wiki/Logically\\_\(company\)](https://en.wikipedia.org/wiki/Logically_(company))

там пункт 19 это на самом деле по тексту пункт 20

20. New Research Reveals Scale of Threat Posed by AI-generated Images on 2024 Elections. URL: <https://logically.ai/announcements/new-research-reveals-scale-of-threat-posed-by-ai-generated-images-on-2024-elections>

21. AI is more persuasive than a human in a debate, study finds. URL: <https://www.washingtonpost.com/technology/2025/05/19/artificial-intelligence-llm-chatbot-persuasive-debate/>

22. Kowsari, K., Meimandi, K. J., Heidarysafa, M., Mendu, S., Barnes, L., & Brown, D. (2019). Text classification algorithms: A survey. Information, 10(4), 150. URL: <https://www.mdpi.com/2078-2489/10/4/150>

23. Rish, I. (2001). An empirical study of the naive Bayes classifier. IJCAI Workshop on Empirical Methods in Artificial Intelligence, 3(22), 41-46. URL: [https://www.researchgate.net/publication/228845263\\_An\\_Empirical\\_Study\\_of\\_the\\_Naive\\_Bayes\\_Classifier](https://www.researchgate.net/publication/228845263_An_Empirical_Study_of_the_Naive_Bayes_Classifier)

24. McCallum, A., & Nigam, K. (1998). A comparison of event models for naive Bayes text classification. In AAAI-98 Workshop on Learning for Text

Categorization (Vol. 752, pp. 41-48). URL: <https://cdn.aaii.org/Workshops/1998/WS-98-05/WS98-05-007.pdf>

25. Ahmed, H., Traore, I., & Saad, S. (2017). Detection of online fake news using N-gram analysis and machine learning techniques. In International Conference on Intelligent, Secure, and Dependable Systems in Distributed and Cloud Environments (pp. 127-138). URL: [https://www.researchgate.net/publication/320300831\\_Detection\\_of\\_Online\\_Fake\\_News\\_Using\\_N-Gram\\_Analysis\\_and\\_Machine\\_Learning\\_Techniques](https://www.researchgate.net/publication/320300831_Detection_of_Online_Fake_News_Using_N-Gram_Analysis_and_Machine_Learning_Techniques)

26. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press. URL: [https://www.researchgate.net/publication/320703571\\_Ian\\_Goodfellow\\_Yoshua\\_Bengio\\_and\\_Aaron\\_Courville\\_Deep\\_learning\\_The\\_MIT\\_Press\\_2016\\_800\\_pp\\_ISBN\\_0262035618](https://www.researchgate.net/publication/320703571_Ian_Goodfellow_Yoshua_Bengio_and_Aaron_Courville_Deep_learning_The_MIT_Press_2016_800_pp_ISBN_0262035618)

27. Young, T., Hazarika, D., Poria, S., & Cambria, E. (2018). Recent trends in deep learning based natural language processing. IEEE Computational Intelligence Magazine, 13(3), 55-75. URL: <https://ieeexplore.ieee.org/document/8416973>

28. Mikolov, T., Sutskever, I., Chen, K., Corrado, G. S., & Dean, J. (2013). Distributed representations of words and phrases and their compositionality. In Advances in Neural Information Processing Systems (pp. 3111-3119). URL: <https://arxiv.org/abs/1310.4546>

29. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. In Advances in Neural Information Processing Systems (pp. 5998-6008). URL: <https://arxiv.org/abs/1706.03762>

30. Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2018). BERT: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805. URL: <https://arxiv.org/abs/1810.04805>

31. Kaliyar, R. K., Goswami, A., & Narang, P. (2021). FakeBERT: Fake news detection in social media with a BERT-based deep learning approach. Multimedia

Tools and Applications, 80(8), 11765-11788. URL: <https://link.springer.com/article/10.1007/s11042-020-10183-2>

32. Hassan, N., Arslan, F., Li, C., & Tremayne, M. (2017). Toward automated fact-checking: Detecting check-worthy factual claims by ClaimBuster. In Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 1803-1812). URL: <https://dl.acm.org/doi/10.1145/3097983.3098131>

33. Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., ... & Gebru, T. (2019). Model cards for model reporting. In Proceedings of the conference on fairness, accountability, and transparency (pp. 220-229). URL: <https://dl.acm.org/doi/10.1145/3287560.3287596>

34. Zhou, X., & Zafarani, R. (2020). A survey of fake news: Fundamental theories, detection methods, and opportunities. ACM Computing Surveys (CSUR), 53(5), 1-40. URL: <https://dl.acm.org/doi/10.1145/3395046>

35. Wu, L., Morstatter, F., Carley, K. M., & Liu, H. (2019). Misinformation in social media: definition, manipulation, and detection. ACM SIGKDD Explorations Newsletter, 21(2), 80-90. URL: <https://dl.acm.org/doi/10.1145/3373464.3373475>

36. Jurafsky, D., & Martin, J. H. (2021). Speech and language processing: An introduction to natural language processing, computational linguistics, and speech recognition (3rd ed. draft). URL: <https://web.stanford.edu/~jurafsky/slp3/>

37. Salton, G., & Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. Information Processing & Management, 24(5), 513-523. URL: <https://www.sciencedirect.com/science/article/abs/pii/0306457388900210>

38. Ramos, J., & Silva, J. (2003). Using TF-IDF to determine word relevance in document queries. Proceedings of the first instructional conference on machine learning, 242(1), 29-48. URL: [https://www.researchgate.net/publication/228818851\\_Using\\_TF-IDF\\_to\\_determine\\_word\\_relevance\\_in\\_document\\_queries](https://www.researchgate.net/publication/228818851_Using_TF-IDF_to_determine_word_relevance_in_document_queries)

39. Kibriya, A. M., Frank, E., Pfahringer, B., & Holmes, G. (2004). Multinomial naive bayes for text categorization revisited. In Australasian Joint Conference on Artificial Intelligence (pp. 488-499). Springer, Berlin, Heidelberg. URL: [https://link.springer.com/chapter/10.1007/978-3-540-30549-1\\_43](https://link.springer.com/chapter/10.1007/978-3-540-30549-1_43)
40. Wang, W. Y. (2017). "Liar, liar pants on fire": A new benchmark dataset for fake news detection. In Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers) (pp. 422-426). URL: <https://aclanthology.org/P17-2067/>
41. Hu, E. J., Shen, Y., Wallis, P., Allen-Zhu, Z., Li, Y., Wang, S., ... & Chen, W. (2021). LoRA: Low-rank adaptation of large language models. arXiv preprint arXiv:2106.09685. URL: <https://arxiv.org/abs/2106.09685>
42. Nandi, A., & Dey, L. (2020). Evaluating Machine Learning Models Over Time for Fake News Detection. In 2020 International Joint Conference on Neural Networks (IJCNN) (pp. 1-8). IEEE. URL: <https://etasr.com/index.php/ETASR/article/view/9192>
43. Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. Journal of Machine Learning Research, 13(Feb), 281-305. URL: <https://www.jmlr.org/papers/volume13/bergstra12a/bergstra12a.pdf>

## ДОДАТКИ

### Додаток А. Текст програмного коду реалізації основних алгоритмів

#### А.1. Реалізація гібридного класифікатора, поєднує TF-IDF та Наївний Баєс

```
class HybridClassifier:
    def init(self, fast_model, deep_model, tokenizer,
threshold=0.7):
        self.fast_model = fast_model
        self.deep_model = deep_model
        self.tokenizer = tokenizer
        self.threshold = threshold
        def predict(self, text):
            fast_pred_proba = self.fast_model.predict_proba([text])[0]
            fast_confidence = max(fast_pred_proba)
            if fast_confidence >= self.threshold:
                return np.argmax(fast_pred_proba), 'fast',
fast_confidence
            inputs = self.tokenizer(text, return_tensors='pt',
truncation=True)
            with torch.no_grad():
                outputs = self.deep_model(**inputs)
                deep_pred = torch.argmax(outputs.logits, dim=1).item()
                deep_confidence = torch.softmax(outputs.logits,
dim=1).max().item()
            return deep_pred, 'deep', deep_confidence
```

#### А.2. Налаштування BERT моделі з оптимізацією LoRA для ефективного навчання

```
def setup_bert_with_lora():
    model = AutoModelForSequenceClassification.from_pretrained(
        "bert-base-uncased",
```

```

        num_labels=2
    )
    lora_config = LoraConfig(
        r=32,
        lora_alpha=64,
        target_modules=["query", "key", "value"],
        lora_dropout=0.05,
        bias="none",
        task_type="SEQ_CLS"
    )
    model = get_peft_model(model, lora_config)
    return model

```

### **A.3. Попередня обробка текстових даних**

```

def preprocess_text(text):
    text = text.lower()
    text = re.sub(r'http\S+|www\S+|https\S+', '', text)
    text = re.sub(r'^\w\s', '', text)
    tokens = word_tokenize(text)
    stop_words = set(stopwords.words('english'))
    tokens = [word for word in tokens if word not in stop_words]
    lemmatizer = WordNetLemmatizer()
    tokens = [lemmatizer.lemmatize(word) for word in tokens]
    return ' '.join(tokens)

```

### **A.4. API для інтеграції системи**

```

@app.post("/classify")
async def classify_news(text: str):
    try:
        processed_text = preprocess_text(text)
        prediction, model_used, confidence =
classifier.predict(processed_text)

```

```
return {
    "is_fake": bool(prediction),
    "confidence": float(confidence),
    "model_used": model_used,
    "processing_time_ms": get_processing_time()
}
except Exception as e:
    raise HTTPException(status_code=500, detail=str(e))
```

## Додаток Б. Результати експериментальних досліджень

### Б.1. Результати порівняння методів класифікації

Метрика	TF-IDF + NB	BERT	Гібридний підхід
Accuracy	0.879	0.918	0.915
Precision (fake)	0.892	0.935	0.931
Recall (fake)	0.861	0.896	0.893
F1-score (fake)	0.876	0.915	0.912
Precision (real)	0.868	0.902	0.899
Recall (real)	0.897	0.941	0.937
F1-score (real)	0.882	0.921	0.918
ROC-AUC	0.933	0.967	0.962

Таблиця Б.1 - Детальні результати тестування різних підходів до класифікації

### Б.2. Аналіз швидкодії

Характеристика	TF-IDF + NB	BERT	Гібридний підхід
Час обробки одного тексту (мс)	20	180	45
Пропускна здатність (текстів/с)	50	5.5	22
Час навчання моделі (год)	0.5	2.5	3.0
Використання RAM (GB)	2	12	8
Використання GPU	-	8	8

Таблиця Б.2 - Часові характеристики різних підходів

### Б.3. Аналіз помилок класифікації

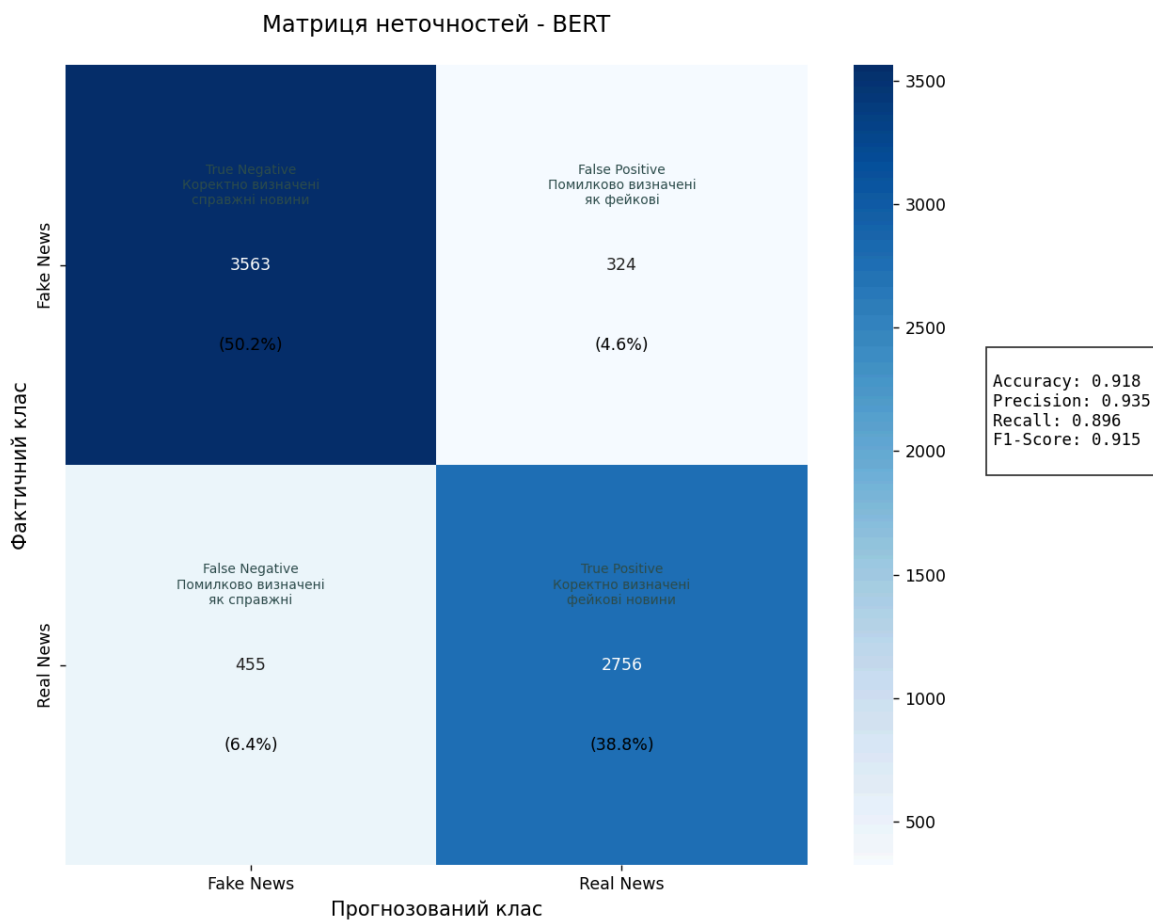


Рисунок Б.1 - Матриця неточностей для BERT (Візуалізація матриці неточностей)

Тип помилки	Частота	Відсоток
Часткові фейки	450	31%
Сатира	320	23%
Нові теми	250	18%
Складний контекст	200	14%
Інші	180	14%

Таблиця Б.3 - Розподіл помилок за типами

#### Б.4. Масштабованість системи

Навантаження (запитів/с)	Кількість реплік	Latency (мс)	CPU утилізація
10	2	45	45%
50	4	52	62%
100	8	58	71%
200	16	61	68%

Таблиця Б.5 - Характеристики масштабованості