

ПВНЗ «ЄВРОПЕЙСЬКИЙ УНІВЕРСИТЕТ»

КАФЕДРА Комп'ютерних наук та програмної інженерії

СПЕЦІАЛЬНІСТЬ 121 «Інженерія програмного забезпечення»
(шифр та назва)

ОСВІТНЬО-ПРОФЕСІЙНА ПРОГРАМА «Інженерія програмного забезпечення»
(назва)

**ВИПУСКНА КВАЛІФІКАЦІЙНА БАКАЛАВРСЬКА
РОБОТА**

на тему:

**Програмне забезпечення виявлення та запобігання поширенню спаму в
публічних чатах.**

(назва затвердженої теми)

Студент(ка) _____
(підпис студента)

Царюк Марія Вікторівна
(прізвище, ім'я по-батькові студента)

Науковий
керівник _____
(підпис наукового керівника)

Яровий Р.О.
(прізвище, ініціали, наукове звання і ступінь)

Допущено до захисту “__” _____ 2025 р.

Завідувач кафедри _____
(підпис)

Сушинський О.Є., д.т.н., доцент
(прізвище, ініціали, наукове звання і ступінь)

Декан факультету _____
(підпис)

Яровий Р.О.
(прізвище, ініціали)

Завідувач
Навчальної частини _____
(підпис)

Козинець А.О.
(прізвище, ініціали)

Київ – 2025

ПВНЗ «ЄВРОПЕЙСЬКИЙ УНІВЕРСИТЕТ»
КАФЕДРА Комп'ютерних наук та програмної інженерії
СПЕЦІАЛЬНІСТЬ 121 «Інженерія програмного забезпечення»
ОСВІТНЬО-ПРОФЕСІЙНА ПРОГРАМА «Інженерія програмного забезпечення»

ЗАВДАННЯ

на випускн у кваліфікаційну бакалаврську роботу студента (ки):

Царюк Марія Вікторівна
(прізвище, ім'я, по-батькові студента (ки))

1. Тема роботи Програмне забезпечення виявлення та запобігання поширенню спаму в публічних чатах.

2. Затверджена наказом по університету від “ 30 ” 09 2025 р. № 99

3. Цільова установка на вихідні дані до роботи

Створення програмного забезпечення для виявлення та запобігання спаму в публічних чатах. Система повинна працювати в реальному часі, демонструвати високу точність при мінімальній кількості помилкових спрацьовувань, бути масштабованою, адаптивною до нових типів спаму та легко інтегруватися з популярними платформами. Крім того, вона має зберігати журнали спам-активності для подальшого аналізу.

4. Перелік графічного матеріалу (з точним визначенням обов'язкових креслень)

Структурна схема системи виявлення спаму, яка відображає взаємодію основних компонентів; блок-схема алгоритму обробки повідомлень, що демонструє послідовність аналізу повідомлень; схема інтеграції з чат-платформами (Telegram, Discord тощо); діаграма класів (UML) для опису програмної структури; діаграма розгортання, яка показує, як система функціонує на серверному рівні; макет інтерфейсу адміністратора з візуалізацією спам-повідомлень і функцій керування; а також графіки ефективності фільтрації, що ілюструють точність і якість роботи системи на тестових даних.

5. Консультанти по роботі, із зазначенням розділів, що їх стосуються:

Розділ	Науковий керівник	Підпис, дата	
		Завдання видав	Завдання отримав
1. Теоритичні основи виявлення та запобігання спаму	Яровий Р.О	27.02.25	27.02.24
2. Розробка та впровадження програмного забезпечення	Яровий Р.О	21.03.25	21.03.25
3. Тестування та рекомендації щодо підвищення ефективності системи	Яровий Р.О	21.04.25	21.04.25

6. Зміст випускної кваліфікаційної бакалаврської роботи (перелік питань)

Аналіз проблеми поширення спаму в публічних чатах та методів його фільтрації.

Дослідження сучасних підходів до виявлення спаму на основі машинного навчання.

Проектування алгоритму фільтрації спаму з урахуванням точності й продуктивності.

Реалізація програмного забезпечення з інтеграцією до популярних чат-платформ.

Тестування ефективності системи на реальних прикладах спамових повідомлень.

7. Календарний план виконання випускної кваліфікаційної бакалаврської роботи

№ з/п	Назва етапів випускної кваліфікаційної бакалаврської роботи	Термін виконання етапів випускної кваліфікаційної бакалаврської роботи	
		За планом	Фактично
1.	Обрання теми випускної кваліфікаційної бакалаврської роботи (ВКБР)	05.08.2024-13.09.2024	03.09.2024
2.	Опрацювання літератури та інших джерел для написання ВКБР	16.09.2024-01.11.2024	01.11.2024
3.	Виконання 1 розділу ВКБР	03.11.2024-	27.02.2024

		28.02.2025	
4.	Виконання 2 розділу ВКБР	17.03.2025- 21.03.2025	20.03.2025
5.	Виконання 3 розділу ВКБР, висновки	07.02.2025- 11.03.2025	18.04.2025
6.	Передзахист ВКБР та проведення перевірки на плагіат	21.04.2025- 02.05.2025	01.05.2025
7.	Відгук керівника, рецензія	12.05.2025- 12.05.2025	

8. Дата видачі завдання “19” 09 2025р.

Керівник _____
(підпис)

Завдання прийняв до виконання _____

АНОТАЦІЯ

Випускна кваліфікаційна бакалаврська робота присвячена розробці програмного забезпечення для виявлення та запобігання спаму в публічних чатах. Метою є створення ефективної системи, здатної працювати в реальному часі, автоматично аналізувати текстові повідомлення та блокувати спам із високою точністю. У межах роботи проаналізовано сучасні підходи до фільтрації спаму, включаючи методи на основі правил, статистики та машинного навчання. Особливу увагу приділено використанню моделей глибокого навчання (зокрема Word2Vec і BERT) для класифікації повідомлень.

Запропоновано архітектуру системи, що включає модуль обробки повідомлень, класифікатор, інтерфейс адміністратора та механізм інтеграції з чат-платформами (Telegram, Discord). Реалізовано алгоритм виявлення спаму з урахуванням мінімізації хибнопозитивних результатів. Проведено тестування на реальних наборах даних, яке підтвердило ефективність запропонованого рішення. Результати роботи свідчать про можливість розробки адаптивної та масштабованої системи захисту чатів від спаму з подальшим застосуванням у різних онлайн-середовищах.

Ключові слова: спам, публічні чати, машинне навчання, класифікація тексту, Telegram, фільтрація повідомлень, інформаційна безпека, Word2Vec, BERT.

ANNOTATION

Bachelor's Qualification Thesis The bachelor's qualification thesis is dedicated to the development of software for detecting and preventing spam in public chats. The goal is to create an effective system capable of operating in real time, automatically analyzing text messages, and blocking spam with high accuracy. The work explores modern approaches to spam filtering, including rule-based, statistical, and machine learning methods. Particular attention is paid to the use of deep learning models (specifically Word2Vec and BERT) for message classification.

The proposed system architecture includes a message processing module, a classifier, an administrator interface, and an integration mechanism with chat platforms (Telegram, Discord). A spam detection algorithm has been implemented with a focus on minimizing false positives. Testing was conducted on real datasets, confirming the effectiveness of the proposed solution. The results demonstrate the feasibility of developing an adaptive and scalable system for protecting chats from spam, with potential applications in various online environments.

Keywords: spam, public chats, machine learning, text classification, Telegram, message filtering, information security, Word2Vec, BERT.

ЗМІСТ

<u>ВСТУП</u>	3
<u>РОЗДІЛ 1</u>	5
<u>ТЕОРЕТИЧНІ ОСНОВИ ВИЯВЛЕННЯ ТА ЗАПОБІГАННЯ СПАМУ</u>	5
<u>1.1 Поняття та класифікація спаму</u>	5
<u>1.2 Огляд сучасних алгоритмів і методів виявлення спаму</u>	11
<u>1.3 Використання технологій машинного навчання для детекції спаму</u>	17
<u>1.4 Аналіз загроз інформаційної безпеки, пов'язаних із поширенням спаму</u>	23
<u>РОЗДІЛ 2</u>	28
<u>РОЗРОБКА ТА ВПРОВАДЖЕННЯ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ</u>	28
<u>2.1 Аналіз вимог до програмного забезпечення</u>	28
<u>2.2 Вибір архітектури системи та інструментів розробки</u>	32
<u>2.3 Розробка алгоритму виявлення спаму</u>	43
<u>РОЗДІЛ 3</u>	47
<u>ТЕСТУВАННЯ ТА РЕКОМЕНДАЦІЇ ЩОДО ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ СИСТЕМИ</u>	47
<u>3.1 Тестування та оцінка ефективності розробленого програмного забезпечення</u>	47
<u>3.2 Удосконалення алгоритмів виявлення спаму на основі нових даних</u>	53
<u>3.3 Рекомендації з інтеграції системи у різні платформи</u>	63
<u>3.4 Перспективи розвитку програмного забезпечення та його вплив на інформаційну безпеку</u>	70
<u>ВИСНОВКИ</u>	77
<u>СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ</u>	79

ВСТУП

Актуальність дослідження. Тема роботи «Програмне забезпечення виявлення та запобігання поширенню спаму в публічних чатах» є надзвичайно актуальною в умовах сучасного інформаційного суспільства, де онлайн-комунікація набуває значного поширення, а проблема спаму залишається однією з основних загроз для безпеки та ефективності роботи різноманітних цифрових платформ. Спам, як форма неспроханих, небажаних повідомлень, не тільки порушує принципи конфіденційності і довіри користувачів, але й негативно впливає на функціонування інформаційних систем, ускладнює процеси комунікації, а також може стати джерелом для злочинної діяльності, такої як фішинг чи поширення шкідливого програмного забезпечення.

Виявлення та блокування спаму є надзвичайно важливим для забезпечення ефективної та безпечної роботи публічних чатів, де користувачі взаємодіють у реальному часі. Підвищення якості програмних продуктів, що відповідають за цю задачу, дозволить значно покращити онлайн-взаємодію, знизити кількість непотрібних та шкідливих повідомлень, а також зробить цифрову комунікацію більш зручною і безпечною для користувачів.

Крім того, тема відповідає актуальним науково-дослідним завданням в рамках розвитку інформаційних технологій, інформатики та кібербезпеки. У зв'язку з розвитком нових методів атак і вдосконаленням технік спаму, доцільність і важливість створення програмного забезпечення для боротьби з цими загрозами стає очевидною. Рішення цієї проблеми має важливе значення не лише для окремих онлайн-ресурсів, а й для широкого кола інтернет-користувачів, компаній та організацій, які здійснюють бізнес у цифровому середовищі.

Метою даного дослідження є розробка програмного забезпечення для виявлення та запобігання поширенню спаму в публічних чатах з використанням сучасних методів машинного навчання та аналізу текстових даних.

Завдання дослідження:

- Проаналізувати існуючі методи виявлення спаму
- Оцінити ефективність алгоритмів машинного навчання для детекції спаму
- Розробити програмне забезпечення для виявлення спаму
- Протестувати програмне забезпечення
- Розробити рекомендації щодо інтеграції системи в існуючі платформи

Об'єкт дослідження: процес виявлення та запобігання поширенню спаму в публічних чатах

Предмет дослідження: методи та алгоритми виявлення спаму, застосування технологій машинного навчання для детекції спаму та розробка програмного забезпечення для його запобігання в публічних чатах.

Практичне значення одержаних результатів полягає в розробці програмного забезпечення для ефективного виявлення та запобігання поширенню спаму в публічних чатах, що має значення для організацій, які працюють з великими обсягами даних та взаємодіють через цифрові платформи. Розроблені алгоритми виявлення спаму, що включають використання технологій машинного навчання, можуть бути впроваджені в онлайн-спільнотах, соціальних мережах, а також в корпоративних чатах для забезпечення інформаційної безпеки та підвищення ефективності комунікацій. Рекомендації щодо використання цих результатів можуть бути застосовані в компаніях, які займаються онлайн-маркетингом, технічних підтримках, а також у державних організаціях для захисту від кіберзагроз.

Апробація результатів та публікації.

РОЗДІЛ 1

ТЕОРЕТИЧНІ ОСНОВИ ВИЯВЛЕННЯ ТА ЗАПОБІГАННЯ СПАМУ

1.1 Поняття та класифікація спаму

Термін «спам» має цікаву історію, що починається ще в 1937 році, коли він був використаний для позначення свинячих консервів компанії Hornel Foods, відомих під брендом SPAM (скорочення від Shoulder of Pork and Ham – «свинячі лопатки і окіст»). Спочатку цей продукт був популярний і широко розповсюджувався, однак з часом виникли численні випадки отруєнь, пов'язані з ним, а також скандали навколо якості товару [1, с. 100]. Це стало основною причиною того, що слово «спам» на довгі роки здобуло негативну конотацію.

Пов'язаний із численними неприємними випадками, термін «спам» поступово став синонімом не тільки неякісних продуктів, але й непотрібної та нав'язливої реклами, яка розповсюджується масово без урахування інтересів споживачів. Оскільки реклама часто намагається пропонувати не завжди корисні або бажані товари, цей термін став синонімом для опису небажаних, агресивних і часто некоректних рекламних повідомлень, які, зокрема, за допомогою електронної пошти чи інших каналів зв'язку, потрапляють до користувачів. Відтак, концепція спаму, що з'явилася в контексті реклами свинячих консервів, набула значно ширшого значення, ставши символом будь-якої нав'язливої і непотрібної комунікації, спрямованої на користувачів без їхнього попереднього дозволу, часто з сумнівною метою чи націленою на порушення приватності.

Спочатку спам був лише частиною рекламної практики, що зазвичай не завдавала значної шкоди, однак з часом він почав трансформуватися в більш небезпечне і складне явище. Проте за останні 10-15 років спам значно змінився, перетворившись із незначного, але дратівливого елементу, що лише заповнював

поштові скриньки, на одну з найбільших загроз для інформаційної безпеки. Те, що колись сприймалося як навязлива реклама, зараз стало серйозною проблемою не лише для індивідуальних користувачів, а й для великих корпорацій та навіть цілих держав. Мільйони непотрібних електронних листів, які потрапляють до поштових скриньок, не лише заповнюють їх, але й затрудняють роботу, оскільки користувачі вимушені витратити час на видалення спаму. Кількість таких повідомлень настільки велика, що вони можуть паралізувати корпоративні сервери, істотно знижуючи їхню продуктивність. Це, в свою чергу, веде до затримок у доставці важливих повідомлень, які можуть бути критичними для діяльності компаній або організацій. Найпідступніше в цьому явищі те, що для спамера витрати на розсилку таких повідомлень практично нульові. Спамер не витрачає значних коштів на відправку мільйонів листів, але ці розсилки коштують дорого всім іншим учасникам процесу — одержувачам і провайдерам послуг. Користувачі, які отримують спам, змушені витратити свій час на видалення непотрібних повідомлень, а також сплачувати за час, витрачений на отримання цих листів через інтернет-підключення. Провайдери, у свою чергу, стикаються з додатковими навантаженнями на свої сервери, що зменшує швидкість доставки корисних електронних листів і підвищує загальні витрати на обробку даних. Чим більше спаму, тим більші витрати як для провайдерів, так і для кінцевих користувачів [2, с. 1-3].

Справжні масштаби цієї проблеми стають очевидними, якщо звернути увагу на статистику. У високорозвинених країнах рівень спаму в електронних поштових скриньках і збитки, які він спричиняє, набагато вищі порівняно з країнами, що лише починають освоювати Інтернет. Цей факт підтверджує, що розповсюдження спаму є не тільки технологічною, але й економічною проблемою. Різниця в рівнях розвитку інфраструктури та захисту інформації між розвиненими і країнами, що розвиваються, лише збільшує масштаби збитків від спаму [3, с. 387-388]. Це явище не лише заважає користувачам, але й створює загрози для безпеки, оскільки багато спам-листів використовуються як

інструменти для фішингу, розповсюдження вірусів та інших шкідливих програм. Це дозволяє спамерам не лише безперешкодно розсилати рекламні матеріали, але й здійснювати атаки на комп'ютерні системи користувачів, що значно підвищує ризики для інтернет-безпеки в цілому.

З огляду на серйозні загрози, які спам становить для інформаційної безпеки, важливо розуміти, якими характеристиками володіють ці небажані повідомлення. Спам не лише викликає неприємності у вигляді забитих поштових скриньок і перевантажених серверів, але й може бути небезпечним для користувачів, приводячи до втрати особистих даних чи інших кіберзагроз. Щоб визначити, що саме є спамом, варто виділити кілька основних ознак, які дозволяють виявити такі повідомлення.

Однією з головних ознак є *велика кількість повідомлень*, що надходять за короткий проміжок часу. Спамери намагаються максимізувати охоплення, надсилаючи тисячі чи навіть мільйони листів протягом години або кількох днів, прагнучи досягти якомога більшої кількості адресатів. Іншою важливою ознакою є *повторюваність повідомлень* або однакові типи інформації, які надходять до користувача. Спамери часто використовують однакові шаблони для розсилки аби знизити витрати часу та ресурсів на кожен окремий лист. Це може проявлятися як повторювані рекламні пропозиції, незапитувані рекламні листи або навіть однакові фішингові повідомлення. Ще однією характерною рисою спаму є *нерелевантність або загрозливий характер контенту*. Наприклад, спам може містити фішингові посилання або інші шкідливі елементи, що намагаються обманним шляхом отримати особисті дані користувача. Такі повідомлення часто маскуються під офіційні листи, намагаючись змусити користувача перейти за посиланням, яке веде до шкідливого сайту. Нарешті, одним із найбільш очевидних критеріїв спаму є *відсутність запиту на отримання повідомлень* від отримувача. Це означає, що користувач не давав згоду на отримання таких листів, що є основною ознакою

спам-розсилок. Вони надходять без попереднього запиту або одержання дозволу, що порушує принципи етики та приватності у комунікації [4].

Класифікація спаму дозволяє більш точно визначити види небажаних повідомлень і сприяє розробці ефективних методів боротьби з ними. Спам може бути класифікований за кількома критеріями: каналами розповсюдження, метою і методом розсилки.

1) Спам за каналом розповсюдження:

- Спам у електронній пошті – один із найбільш поширених і відомих видів спаму. Всі користувачі електронної пошти хоча б раз стикалися з нав'язливими рекламою або спробами шахрайства. Поштові скриньки переповнюються небажаними листами, що не мають на меті ніякої корисної або цінної інформації. Такі повідомлення можуть включати рекламу товарів, послуг або спроби обману, наприклад, через фішингові посилання.
- Спам у месенджерах і чатах – цей тип спаму став особливо актуальним із зростанням популярності мобільних месенджерів, таких як WhatsApp, Telegram або Facebook Messenger. Спамери надсилають масові повідомлення або створюють автоматизовані боти, що генерують повторювані або небажані повідомлення. Вони можуть використовуватися для реклами товарів або послуг, або ж для фішингу.
- Спам у соціальних мережах – із розвитком платформ, таких як Facebook, Instagram, Twitter та інших, спамери почали активно використовувати соціальні мережі для розповсюдження небажаної інформації. Спам може приймати вигляд публікацій, що порушують правила платформ, або масових коментарів під популярними постами. Цей тип спаму також включає масові запити на дружбу або фейкові акаунти, що рекламують сумнівні товари або послуги.

2) Спам за метою:

- Рекламний спам – це спам, основною метою якого є просування товарів, послуг або брендів. Такий спам зазвичай має вигляд рекламних оголошень, які намагаються привабити користувачів до покупки товару або відписки на послугу. Рекламний спам може бути настільки навязливим, що користувачі починають його ігнорувати, що знижує ефективність таких кампаній.
- Спам, що використовує соціальну інженерію – цей тип спаму заснований на маніпулюванні емоціями або поведінкою користувачів для досягнення певних цілей. Він включає такі види, як фішинг (спроби отримати особисті дані через підроблені сайти або посилання), соціальне шахрайство, обманні конкурси або підроблені виграші. Метою таких повідомлень є отримання доступу до конфіденційної інформації, банківських рахунків або навіть реальних грошей.
- Шкідливий спам – спам, який не тільки пропагує товари чи послуги, але й може включати віруси, шкідливі програми або інші небезпечні елементи. Такі повідомлення можуть містити вкладення, що запускають шкідливе ПЗ після відкриття, або посилання на небезпечні сайти, що встановлюють шкідливе програмне забезпечення на комп'ютер користувача. Метою такого спаму є завдання шкоди користувачам, крадіжка даних або контроль над пристроями.

3) Спам за методом розсилки:

- Масова розсилка – цей метод передбачає надсилання одного повідомлення великій кількості користувачів одночасно. Масові розсилки спаму можуть охоплювати тисячі, а іноді й мільйони людей. Спамери зазвичай використовують автоматизовані системи або боти для цього, що дозволяє значно знизити витрати часу та ресурсів на кожного окремого отримувача. Однак такий спам не завжди є ефективним, оскільки отримувачі можуть швидко зрозуміти, що це небажана реклама.

- Таргетований спам – цей метод орієнтований на певну групу користувачів, що володіють специфічними характеристиками або інтересами. Спамери використовують аналіз поведінки користувачів, їх соціальні зв'язки або інші дані для створення більш персоналізованих спам-розсилок. Це дозволяє збільшити ефективність спаму, оскільки повідомлення будуть більш релевантними для отримувача, що може призвести до високого рівня зацікавленості і взаємодії з повідомленням [5].

1.2 Огляд сучасних алгоритмів і методів виявлення спаму

Виявлення спаму в публічних чатах є важливим аспектом забезпечення безпеки та ефективності комунікацій у цифрових середовищах. Оскільки спам постійно еволюціонує, існує багато різних підходів до його виявлення, кожен з яких має свої переваги та обмеження. Від класичних алгоритмів, що ґрунтуються на визначених правилах, до більш складних методів машинного навчання — всі ці підходи намагаються відповісти на різноманітні виклики, що виникають при боротьбі з небажаним контентом. Зараз нами буде розглянуто основні методи, зокрема алгоритми на основі правил, які стали основою для розробки перших систем виявлення спаму.

1) Алгоритми на основі правил є одним із перших підходів до автоматичного виявлення спаму. Вони використовують набори попередньо визначених правил для фільтрації спамових повідомлень. Такі правила можуть базуватися на:

- Регулярних виразах – цей метод включає використання патернів (шаблонів), які знаходять відповідності в тексті повідомлення. Наприклад, повідомлення, що містить надмірну кількість посилань, виглядає як потенційно спамове. Регулярні вирази дозволяють швидко і ефективно

знаходити ці шаблони, однак вони не завжди здатні відрізнити складніший контент або виявити нові варіації спаму.

- Списках заборонених слів – цей метод передбачає створення списків слів або фраз, які часто зустрічаються в спамових повідомленнях (наприклад, "виграй гроші", "натисни тут"). Якщо вхідне повідомлення містить багато таких слів, воно може бути позначено як спам. Хоча це швидкий метод, він має обмеження, оскільки спамери часто використовують синоніми або інші варіанти фраз для обходу таких списків.
- Аналіз шаблонів тексту – ще один підхід, який включає виявлення специфічних структур або шаблонів в текстах повідомлень, таких як надмірна кількість посилань, повторення одних і тих самих фраз чи занадто багато капіталізованих слів. Ці методи можуть виявити спам, що має явні структурні особливості, але вони менш ефективні в складних випадках, коли спам "маскується" під звичайні повідомлення [6, с. 29-35].

Продовжуючи огляд сучасних методів виявлення спаму, важливо зупинитись на підходах, які використовують машинне навчання для автоматичного виявлення спамових повідомлень. Замість того, щоб покладатися на жорстко задані правила, ці алгоритми здійснюють навчання на основі історичних даних, що дозволяє їм "навчитися" відрізняти спам від легітимних повідомлень за допомогою статистичних властивостей тексту. Оскільки ці методи здатні адаптуватися до нових варіацій спаму, вони вважаються більш гнучкими та точними в порівнянні з класичними алгоритмами.

2) Машинне навчання: алгоритми для виявлення спаму

- Наївний байєс (Naive Bayes) – один з найпоширеніших методів класифікації в машинному навчанні – це наївний байєс, який заснований на теоремі Байєса. Цей метод працює за принципом обчислення ймовірності того, чи є повідомлення спамом, на основі певних характеристик тексту (наприклад, частоти певних слів чи фраз).

Класичним є припущення, що ознаки (слова, фрази) є незалежними одна від одної, що спрощує модель. При цьому байєсівські алгоритми можуть ефективно класифікувати повідомлення навіть при наявності великої кількості ознак, таких як присутність певних слів чи шаблонів. Цей метод швидко працює, проте може давати знижені результати при великій кількості взаємозалежних ознак.

- Деревя рішень (Decision Trees) – це ще один популярний метод класифікації, який використовує структуру, схожу на дерево, для прийняття рішень. У випадку виявлення спаму, кожен вузол дерева відповідає за перевірку певної ознаки (наприклад, наявність певного слова чи шаблону), а гілки дерева відображають ймовірність того, чи є повідомлення спамом, залежно від виявлених ознак. Цей метод має перевагу в інтерпретованості, адже дерево можна візуалізувати, що дозволяє зрозуміти, як саме приймається рішення. Однак, при великих обсягах даних і складних ознаках, дерева рішень можуть бути схильні до перенавчання (overfitting), що призводить до зниження їхньої ефективності на нових даних.
- Методи опорних векторів (SVM) – це потужний алгоритм класифікації, який шукає оптимальну гіперплощину, що максимізує відстань між класами (наприклад, між спамом і не-спамом). Це дозволяє SVM досягати високої точності в класифікації, навіть при складних даних, де інші методи можуть не працювати. SVM має здатність ефективно працювати з високовимірними даними, що робить його особливо корисним для аналізу текстів з великою кількістю ознак (слова, фрази, символи). Однак SVM може бути computationally інтенсивним при великих обсягах даних, що вимагає значних обчислювальних ресурсів [6, с. 37-41].

Загалом, методи машинного навчання здатні адаптуватися до нових типів спаму і забезпечують високу точність в порівнянні з методами на основі правил. Вони дозволяють досягати кращої гнучкості і можуть бути інтегровані в більш

складні системи фільтрації спаму, де потрібно враховувати багато різних характеристик тексту. Однак, для досягнення оптимальних результатів, ці методи зазвичай вимагають великих обсягів навчальних даних і потужних обчислювальних ресурсів.

3) З розвитком технологій машинного навчання, особливо в області глибокого навчання, з'явилися нові методи, які значно покращують ефективність виявлення спаму. Глибоке навчання використовує багатопарові нейронні мережі, які можуть автоматично виділяти особливості з даних без необхідності явного визначення ознак. Це дозволяє нейронним мережам виявляти складні патерни та залежності в текстах, які важко виявити за допомогою традиційних методів. Завдяки цьому методи глибокого навчання здатні досягати значно вищої точності при обробці великих обсягів текстової інформації, де традиційні алгоритми можуть не справлятися.

- Рекурентні нейронні мережі (RNN) — це один із основних типів нейронних мереж, який використовує інформацію з попередніх кроків для обробки послідовних даних. Оскільки текст є послідовністю слів, RNN здатні враховувати порядок слів і контекст, що є критично важливим для розуміння значення повідомлення. Це дозволяє RNN ефективно працювати з текстовими даними для класифікації спаму, оскільки вони можуть виявляти патерни в структурі повідомлення і враховувати, як одне слово або фраза взаємодіє з іншими. Однак, класичні RNN мають обмеження, пов'язані з проблемою зникання градієнтів (vanishing gradient problem), коли на довгих послідовностях інформація може поступово втрачатись. Для вирішення цієї проблеми були розроблені більш складні варіанти RNN, такі як LSTM (Long Short-Term Memory) та GRU (Gated Recurrent Unit), які дозволяють краще зберігати та передавати інформацію на довгих відстанях у тексті.

- Трансформери (BERT) – більш новим та потужним методом є використання трансформерів, зокрема моделей на базі BERT (Bidirectional Encoder Representations from Transformers). Трансформери використовують механізм уваги (self-attention), який дозволяє мережі ефективно фокусуватися на важливих частинах тексту, незалежно від їхнього положення у повідомленні. Це дозволяє краще обробляти залежності між словами на різних рівнях контексту.
- BERT є однією з найпопулярніших моделей трансформерів, яка працює за принципом двостороннього контексту — вона аналізує текст як зліва, так і справа від кожного слова, що дозволяє точніше розуміти зміст повідомлення. Це робить BERT ідеальним для завдань, що вимагають глибокого розуміння тексту, таких як виявлення спаму, де важливо враховувати не тільки окремі слова, а й загальний контекст повідомлення [7, с. 92].

Тобто, моделі, засновані на трансформерах, значно підвищили точність виявлення спаму, оскільки вони можуть краще розуміти емоційне забарвлення тексту, сарказм, а також інші складні аспекти, які можуть бути присутні в спамових повідомленнях. Наприклад, спамери можуть намагатися маскувати свої повідомлення, використовуючи емоційно нейтральні або позитивні фрази, але трансформери здатні виявити ці спроби завдяки їхньому здатності враховувати контекст у широкому сенсі.

4) З ускладненням спаму та його маскуванням, сучасні методи виявлення спаму повинні враховувати не тільки поверхневі ознаки тексту, а й його контекст та семантику. Це особливо важливо, оскільки спамери часто намагаються обдурити традиційні фільтри, використовуючи схожі на звичайні повідомлення формулювання, включаючи різноманітні варіації слів, емоційно нейтральні або навіть позитивні вирази. Тому необхідно вивчати методи, які

дозволяють враховувати глибший зміст повідомлення, а також зв'язки між словами в контексті.

Для розв'язання цієї задачі використовуються методи векторизації слів, зокрема такі підходи, як Word2Vec та GloVe. Ці методи дозволяють перетворювати слова в багатовимірні вектори, які зберігають семантичні зв'язки між ними. Таким чином, замість того, щоб працювати з окремими словами, можна працювати з їхніми векторами, що дозволяє краще аналізувати їх контекст.

Word2Vec — це алгоритм, який використовує нейронні мережі для навчання векторів слів. Він базується на ідеї, що слова, які з'являються в схожих контекстах, повинні мати схожі векторні представлення. Word2Vec може бути реалізований в двох варіантах:

- Continuous Bag of Words (CBOW), де модель передбачає слово за допомогою його контексту.
- Skip-Gram, де модель використовує слово для передбачення контексту [8].

Використовуючи ці моделі, можна отримати вектори, що відображають зміст слів, і таким чином виявляти схожі або спамові вирази, навіть якщо вони представлені іншими словами або синонімами.

GloVe (Global Vectors for Word Representation) – це ще один популярний метод вектаризації слів, який фокусується на глобальних статистичних зв'язках між словами. GloVe використовує співвідношення частот появи слів у текстах для побудови векторних репрезентацій, що дозволяє зберігати відносини між словами на глобальному рівні. Цей метод є більш статистичним порівняно з Word2Vec, який більше орієнтований на локальні контексти [9, с. 1-2].

Таким чином, методи векторизації слів, такі як Word2Vec та GloVe, дозволяють значно покращити розуміння семантики та контексту тексту. Вони

дозволяють зберігати значення слів у багатовимірних просторах, що надає додаткові можливості для виявлення спаму, навіть у випадках, коли він намагається приховатися серед нормальних повідомлень. Це є важливим кроком у боротьбі з більш складними і еволюціонуючими типами спаму.

З розвитком технологій спамери постійно вдосконалюють свої методи обходу фільтрів, що ставить перед алгоритмами нові виклики. Адаптація алгоритмів виявлення спаму стає важливою складовою їх ефективності. Наприклад, алгоритми повинні враховувати нові техніки маскування, такі як використання синонімів, зміна шрифтів або навіть змішування тексту зображеннями. Сучасні методи детекції спаму активно використовують машинне навчання та глибоке навчання, що дозволяє системам адаптуватися до нових типів спаму. Застосування нейронних мереж для виявлення шаблонів і тренування моделей на великих наборах даних допомагає алгоритмам розпізнавати нові спроби маніпуляцій. Окрім того, використовуються постійно оновлювані набори даних для навчання моделей, що дозволяє своєчасно реагувати на зміни у поведінці спамерів.

1.3 Використання технологій машинного навчання для детекції спаму

Сучасні методи виявлення спаму активно використовують технології машинного навчання для покращення точності та ефективності виявлення небажаних повідомлень у публічних чатах. Машинне навчання дозволяє адаптуватися до нових форм спаму, навчатися на великих обсягах даних та автоматично знаходити закономірності, які можуть бути неочевидними для традиційних алгоритмів. Для успішного застосування таких технологій необхідно врахувати кілька етапів, серед яких важливою є підготовка даних, адже якість та ефективність моделі напряму залежать від наданих вхідних даних.

Підготовка даних — це ключовий етап у процесі створення моделей машинного навчання, що мають на меті виявлення спаму в текстах. Чистота та якість даних безпосередньо впливають на точність та ефективність майбутньої моделі.

1) Першим етапом є очищення текстів. Цей процес включає видалення непотрібних символів, таких як знаки пунктуації, спеціальні символи (наприклад, @, #), HTML-теги та інші артефакти, що можуть виникати внаслідок збереження або обробки даних у різних форматах. Залишені такі елементи можуть заважати точному аналізу тексту, а також створювати зайві труднощі для подальших етапів.

2) Наступним кроком є токенізація — процес поділу тексту на менші одиниці, що зазвичай є словами або фразами, які називаються токенами. Токенізація дозволяє виділити основні складові частини тексту, які згодом будуть використовуватись для подальшого аналізу та класифікації. Цей етап є необхідним для перетворення необроблених текстових даних у форму, з якою модель може ефективно працювати.

3) Одним з найбільш важливих етапів є стемінг та лемматизація, методи, які допомагають нормалізувати слова. Стемінг полягає в усуненні відмінків та закінчень, щоб привести слово до його кореня. Наприклад, слово "running" після стемінгу може бути зведене до "run". Такий підхід дозволяє зменшити варіативність слів та зберігати основну сутність інформації. Однак, стемінг не завжди зберігає точність граматичної форми, що може іноді призводити до втрати контексту. Лемматизація, у свою чергу, є більш складним процесом, оскільки враховує граматичні правила мови. Вона дозволяє привести слово до його лексичної (або словникової) форми, такої як "run" замість "running" або "ran". Лемматизація є точнішою і враховує значення слів в контексті, але для її виконання зазвичай потрібні додаткові мовні ресурси, такі як словники та морфологічні аналізатори. Завдяки правильній підготовці даних текстова

інформація стає зручною для машинного навчання, що дає змогу точніше класифікувати повідомлення як спам чи не спам, а також адаптувати моделі до нових форм спаму [10, с. 28-30].

Після підготовки даних наступним етапом є **використання алгоритмів машинного навчання** для детекції спаму. Тут ми розглянемо різні методи класифікації та їх застосування до задачі виявлення спаму.

Класифікація за допомогою наглядних методів

1) Першим кроком є класифікація повідомлень за допомогою наглядних методів машинного навчання, що передбачає навчання моделей на основі міток (наприклад, "спам" або "не спам"). Одним з найбільш поширених алгоритмів є логістична регресія. Цей метод використовує лінійні функції для прогнозування ймовірності приналежності повідомлення до певного класу. Логістична регресія є ефективною завдяки своїй простоті та здатності працювати з великими обсягами даних, але її точність може бути обмежена в складних випадках, де залежності не є лінійними.

2) Інший поширений метод — наївний баєсів класифікатор, який заснований на принципі умовної ймовірності. Він припускає, що всі ознаки (наприклад, слова в повідомленні) є незалежними, що робить модель дуже простою і швидкою. Хоча цей метод має свої обмеження, він добре працює в задачах, де є багато ознак, що не сильно взаємозв'язані.

3) Метод опорних векторів (SVM) — ще один потужний алгоритм для класифікації. Він працює шляхом побудови гіперплощини, яка максимізує відстань між різними класами в багатовимірному просторі ознак. SVM може бути дуже ефективним у випадках, коли класи спаму і не спаму чітко розділені, але також вимагає значних обчислювальних ресурсів для великих обсягів даних.

Методи без нагляду

Не завжди є можливість отримати великий обсяг міток для навчання моделей, тому важливо розглядати методи без нагляду. Оскільки у таких задачах немає чітко визначених класів (спам чи не спам), застосовуються методи кластеризації. Вони допомагають групувати повідомлення, схожі за змістом, що може допомогти виявити нові форми спау. Одним з популярних алгоритмів є k-середніх, який дозволяє автоматично розділяти дані на групи. Іншим методом є DBSCAN, який допомагає знаходити групи в даних з різною щільністю, що може бути корисно для виявлення нових типів спау в інформаційному просторі. Методи без нагляду можуть бути використані для виявлення нових трендів в спамі та адаптації алгоритмів до нових, ще не розпізнаних типів повідомлень. Вони можуть працювати у поєднанні з іншими методами для підвищення точності і забезпечення більш ефективного моніторингу чатів [11, с. 131-133].

У задачах машинного навчання для виявлення спау, одним із важливих аспектів є **вибір характеристик (фіч)**, які будуть використовуватися для тренування моделі. Від правильного вибору фіч залежить не лише точність моделі, але й її здатність до узагальнення на нові, невідомі дані. Один із найбільш базових підходів до вибору фіч — це використання частотних характеристик, таких як TF-IDF (Term Frequency - Inverse Document Frequency) або просто частота появи слів.

- TF-IDF є мірою важливості кожного слова в документі з урахуванням його частоти в загальному корпусі текстів. Вищі значення TF-IDF вказують на те, що слово є важливим для конкретного повідомлення, але рідко з'являється в інших текстах. Ця характеристика допомагає виявити такі слова, які є специфічними для певного контексту (наприклад, часто використовувані в спамових повідомленнях).
- Частота слів (Term Frequency) – це кількість появи конкретного слова в документі, що допомагає визначити домінуючі теми та ключові терміни.

Для спаму це можуть бути слова або фрази, які часто зустрічаються в несанкціонованих повідомленнях (наприклад, "безкоштовно", "потрібна допомога", "ви виграли").

Одним з аспектів, який може значно вплинути на ефективність моделі, є аналіз емоційного забарвлення повідомлень. Вивчення емоційної тональності текстів дає змогу виявляти спамові повідомлення, що містять агресивні, маніпулятивні або підбурюючі фрази. Аналіз тональності включає виявлення емоцій, таких як позитивні, негативні або нейтральні. Для спаму це може бути корисно, оскільки багато спамових повідомлень мають виражену негативну або маніпулятивну тональність (наприклад, "ви програли, тільки якщо не зробите це зараз!" або "доставимо товар швидко, якщо ви негайно замовите"). Врахування емоційного забарвлення дозволяє відрізнити не лише стандартний спам, а й приховані форми маніпулювання або агресії, які можуть бути частиною більш складних спамових стратегій. Таким чином, вибір фіч має вирішальне значення для розробки ефективної моделі виявлення спаму. Частотні характеристики допомагають виявити загальні патерни, семантичні фічі дозволяють краще зрозуміти контекст і значення слів, а аналіз емоційної тональності дає змогу відрізнити спам з маніпулятивним або агресивним змістом. Правильний вибір і комбінація цих фіч значно підвищують точність моделей для виявлення спаму [12, с. 275-278].

Оцінка ефективності моделей машинного навчання для виявлення спаму є важливою частиною процесу розробки. Для того, щоб точно оцінити, наскільки добре модель працює на реальних даних, застосовують різні метрики. Методики, які широко використовуються в задачах класифікації спаму:

Точність, відгук і F1-міра.

1) Точність (Accuracy) визначається як відношення правильно класифікованих повідомлень до загальної кількості повідомлень. Хоча це проста метрика, вона може бути не достатньо інформативною в разі

незбалансованих класів (наприклад, коли спам складає лише невелику частину всіх повідомлень). У таких випадках точність може давати хибне враження про ефективність моделі.

2) Відгук (Recall) відображає, скільки з усіх реальних спамових повідомлень модель змогла правильно виявити. Високий відгук означає, що модель добре знаходить спам, але може мати більше помилкових спамів, які насправді не є спамом.

3) F1-міра є середнім гармонійним точності та відгуку і є важливою метрикою для оцінки ефективності моделей, коли точність і відгук мають бути збалансовані. Вона використовується для забезпечення компромісу між точністю та відгуком і є особливо корисною в ситуаціях, коли важливі обидві метрики.

Одним з основних викликів виявлення спаму є постійне еволюціювання стратегій спам-атак. Спамери постійно адаптуються, використовують нові методи, щоб обходити фільтри, що робить важливим забезпечення гнучкості і здатності до адаптації алгоритмів машинного навчання. Сучасні технології машинного навчання можуть справлятися з цією проблемою завдяки кільком підходам. Одним із способів адаптації до нових типів спаму є регулярне оновлення навчальних наборів даних. Кожен раз, коли з'являються нові спамові стратегії, моделі можуть бути перенавчені на нових даних, що відображають ці зміни. Це дозволяє зберігати високу точність і ефективність фільтрації спаму навіть у разі зміни його характеру. Оновлення даних включає:

- Включення нових спамових повідомлень у тренувальний набір.
- Виявлення і включення нових типів атак, таких як фішинг або маніпулятивні техніки, які можуть використовувати нові фрази чи шаблони.
- Адаптація до нових мовних варіантів, сленгу чи зловживань лексикою.

Іншим важливим підходом є використання моделей, здатних до самоудосконалення, таких як системи на основі підкріпленого навчання (reinforcement learning). Такі моделі можуть "навчатися" в реальному часі, адаптуючи свої рішення на основі нових прикладів спаму, які з'являються в процесі використання. Ці моделі можуть:

- Виявляти нові патерни спаму і виводити відповідні сигнали.
- Адаптувати свою стратегію фільтрації в залежності від зворотного зв'язку, зібраного від користувачів (наприклад, коли користувач позначає повідомлення як спам або не спам).
- Автоматично виявляти зміни в стилях спаму без необхідності додаткового втручання з боку розробників [13, с. 45-49].

Таким чином, адаптація до нових типів спаму є важливою частиною стратегії виявлення спаму в публічних чатах. Завдяки регулярному оновленню навчальних наборів даних, використанню моделей, здатних до самовдосконалення, і перехресному навчання, сучасні алгоритми машинного навчання можуть швидко реагувати на нові методи спам-атак. Це дозволяє підтримувати ефективність і точність фільтрації спаму, навіть коли атакувальні стратегії стають дедалі складнішими та інноваційнішими.

1.4 Аналіз загроз інформаційної безпеки, пов'язаних із поширенням спаму

Спам не лише займає важливе місце серед найбільш поширених непотрібних повідомлень в Інтернеті, але й становить серйозну загрозу для безпеки інформаційних систем. Поширення спаму не обмежується лише рекламою чи незапитаними повідомленнями, адже часто спамери

використовують ці повідомлення для здійснення складних кіберзлочинів. У цьому пункті буде розглянуто, як спам може бути використаний для реалізації фішингових атак, соціальної інженерії, а також інших загроз, пов'язаних із безпекою інформації.

Однією з найбільш серйозних загроз, пов'язаних із спамом, є **фішинг** – вид атаки, при якому зловмисники намагаються обдурити користувачів, щоб ті надали конфіденційну інформацію, таку як паролі, номери кредитних карток чи персональні дані. Спам може бути використаний для фішингу через масові розсилки електронних листів, повідомлень у чатах або навіть у вигляді коментарів у публічних форумах. Зловмисники створюють фальшиві веб-сторінки або інтерфейси, які виглядають як офіційні ресурси, на яких користувачі можуть бути переконані ввести свої дані, не підозрюючи, що вони стають жертвами шахраїв. Фішинг часто супроводжується соціальною інженерією, технікою, яка використовує психологічний вплив на користувачів для досягнення певної мети. Спамери можуть маніпулювати емоціями людей, пропонуючи "надзвичайні" вигоди або погрози (наприклад, блокування акаунту, скасування послуги тощо), що змушує жертв діяти поспіхом, без роздумів. Це може призвести до надання критично важливої інформації зловмисникам, а також встановлення шкідливих програм, таких як віруси чи трояни [14, с. 52-53].

Спам є одним із основних каналів для **доставки шкідливого програмного забезпечення (malware)**, такого як віруси, троянські коні, шпигунські програми або вимагатим програмам (ransomware). Шахраї часто використовують спам для масового розповсюдження заражених вкладень або шкідливих посилань, які, коли відкриті, можуть інфікувати пристрої користувачів. Ці повідомлення часто замасковані під легітимні електронні листи або повідомлення від знайомих компаній або особистих контактів. Троянські коні, зокрема, є дуже підступним видом шкідливих програм, оскільки вони не

проявляються одразу після завантаження. Вони можуть залишатися в системі без уваги користувача, дозволяючи зловмисникам здійснювати віддалений доступ до пристроїв, викрасти конфіденційну інформацію або навіть використовувати комп'ютер як частину ботнету для виконання масштабних атак (наприклад, розподілені атаки типу "відмова в обслуговуванні" (DDoS)). Вкладення в електронних листах зазвичай містять різні шкідливі файли, наприклад, архіви або документи, що, коли відкриваються, можуть активувати вірус. Крім того, спамери можуть використовувати фальшиві посилання на веб-сторінки, що виглядають як офіційні ресурси, наприклад, онлайн-банкінги або платформи електронної комерції, на яких користувачам пропонується завантажити "оновлення" або "безкоштовне програмне забезпечення". Однак насправді ці веб-сторінки лише маскують заражену програму, яку користувач не усвідомлює [15, с. 9-12].

Зрозуміло, що поширення шкідливого програмного забезпечення через спам є надзвичайно небезпечним для користувачів та організацій, оскільки здатне спричинити значні фінансові збитки, викрадення даних, знищення або крадіжку конфіденційної інформації, а також довготривалі наслідки для корпоративних систем безпеки. Важливою частиною боротьби з цією загрозою є використання антиспамових фільтрів, програм для виявлення шкідливого ПЗ та освіта користувачів про безпеку в Інтернеті, включаючи надання їм знань про методи ідентифікації підозрілих листів та повідомлень.

Однією з найбільших загроз, пов'язаних із поширенням спаму, є **створення ботнетів** – мереж заражених комп'ютерів, які контролюються зловмисниками для виконання шкідливих операцій. Спам може стати основним каналом для зараження комп'ютерів і включення їх до ботнету. Зловмисники використовують спамові повідомлення з шкідливими посиланнями або вкладеннями, щоб спонукати користувачів здійснити клік, який автоматично завантажує шкідливе програмне забезпечення на їхні пристрої. Як тільки

комп'ютер заражено, він стає частиною ботнету і може використовуватися для розподілених атак на інші системи, таких як атаки типу "відмова в обслуговуванні" (DDoS). Ботнети можуть бути використані для створення штучного трафіку або перевантаження серверів, що може призвести до їхнього виходу з ладу. Зловмисники можуть також використовувати ботнети для розсилки додаткового спаму або для крадіжки конфіденційної інформації, наприклад, паролів, банківських даних або особистої інформації, яку зберігають інфіковані пристрої. Основною причиною популярності використання ботнетів через спам є їхня здатність маскувати атаки та надавати зловмисникам анонімність. Це ускладнює ідентифікацію атакуючих і захист від них. Щоб запобігти такій загрозі, необхідно впроваджувати механізми виявлення шкідливого програмного забезпечення, регулярні оновлення безпеки на пристроях та освітні кампанії для користувачів, які допоможуть виявляти підозрілі повідомлення та не клікати на сумнівні посилання [16, с. 287-290].

Іншою серйозною загрозою, яку створює спам, є його **використання для підготовки та здійснення DDoS-атак** (Distributed Denial of Service), що спричиняють відмову в обслуговуванні для цілей систем або серверів. Спам може бути використаний для масового надсилення запитів або великих обсягів даних до сервера чи онлайн-ресурсу, що призводить до його перевантаження і, зрештою, до його недоступності для користувачів. Одним із способів, яким спам може бути використаний для DDoS-атак, є створення спам-ботів, які автоматично генерують численні запити або підключення до серверів. Такі атаки часто спрямовані на відволікання ресурсів серверів, їхнє переповнення трафіком або завантаженням великої кількості даних. Різновидом цього є атакувальні техніки, коли спам використовується для викликання небажаних запитів на веб-ресурси, такі як онлайн-сервіси, де користувачі можуть бути вимушені надати свої ресурси, наприклад, пропускну здатність або пам'ять. У таких випадках система не може обробляти нормальні запити від користувачів через надмірну кількість одночасних підключень або запитів. Зловмисники

можуть також комбінувати спам і атаки з використанням ботнетів, що значно посилює ефективність атаки, оскільки залучаються ресурси тисяч заражених комп'ютерів, які активно генерують трафік. Для запобігання таких атак необхідно впроваджувати системи виявлення та блокування шкідливого трафіку, використовувати фільтрацію запитів на рівні серверів і застосовувати протоколи безпеки для контролю за доступом до онлайн-ресурсів. Важливим аспектом є також моніторинг аномального трафіку, що дозволяє швидко виявляти спроби здійснення DDoS-атак [17, с. 24-25].

Спам може мати серйозний негативний вплив на репутацію онлайн-платформ або чатів, що призводить до зниження довіри з боку користувачів і негативно відображається на корпоративній безпеці. Коли користувачі стикаються з постійними спамовими повідомленнями, це може спровокувати їхнє небезпечно низьке ставлення до цієї платформи або комунікаційного каналу. Це, в свою чергу, може призвести до відтоку користувачів, що, окрім зменшення користувацької активності, негативно позначається на іміджі компанії. Для бізнесів і онлайн-платформ наявність спаму в чатах або комунікаціях може свідчити про слабкість або недостатню ефективність засобів безпеки, що може вплинути на сприйняття їхньої надійності з боку потенційних користувачів чи клієнтів. Зловмисники часто використовують спам як інструмент для поширення небажаної реклами, маніпуляцій чи навіть шахрайських схем, що підриває загальний рівень довіри до платформи. Корпоративна безпека також може бути піддана ризику, коли спам використовують для розповсюдження фішингових атак, що ставить під загрозу конфіденційність даних співробітників або клієнтів. Зниження рівня довіри може також призвести до того, що користувачі або партнери відмовляться від співпраці через небажання асоціюватися з потенційно небезпечною платформою. Задля запобігання подібним проблемам необхідно впроваджувати системи моніторингу, автоматизовані фільтри спаму та інші інструменти, що дозволяють зберігати високий рівень довіри користувачів до платформи.

Важливою складовою в боротьбі зі спамом є розуміння правових та етичних аспектів, які визначають рамки для боротьби з цією проблемою. Одним із основних аспектів є законодавство щодо спаму, яке регулює можливість надсилання небажаних повідомлень. В багатьох країнах уже існують спеціалізовані закони, що стосуються електронних комунікацій та захисту від спаму, наприклад, Закон про захист від спаму в США (CAN-SPAM Act), Директива ЄС про конфіденційність електронних комунікацій і інші аналогічні норми. Ці нормативні акти зазвичай встановлюють чіткі вимоги щодо надання згоди користувача перед відправкою реклами або повідомлень, що мають комерційну мету, а також передбачають серйозні штрафи для порушників. У країнах з більш жорстким законодавством боротьба зі спамом має більш системний характер, при цьому важливо враховувати, що існують значні відмінності у правових нормах залежно від географії та юрисдикції.

Однією з проблем, пов'язаних із боротьбою зі спамом, є **можливість порушення конфіденційності або прав користувачів**, особливо коли йдеться про фільтрацію чи обмеження доступу до певних типів контенту. Наприклад, застосування надмірно суворих механізмів фільтрації може призвести до випадкового блокування законних повідомлень або обмеження права на свободу вираження поглядів. Використання механізмів на основі штучного інтелекту для автоматичного відбору спаму може мати етичні наслідки, адже це може призвести до неправомірного обмеження доступу до важливої інформації. Етичні питання також виникають у контексті збору даних для тренування моделей, особливо коли це стосується приватності користувачів або збереження їхньої анонімності [18, с. 8179-8191]. Таким чином, при боротьбі зі спамом необхідно забезпечити збалансований підхід, що враховує права користувачів, захист персональних даних та етичні стандарти.

РОЗДІЛ 2

РОЗРОБКА ТА ВПРОВАДЖЕННЯ ПРОГРАМНОГО ЗАБЕЗПЕЧЕННЯ

2.1 Аналіз вимог до програмного забезпечення

Розробка програмного забезпечення для виявлення та запобігання поширенню спаму в публічних чатах вимагає чіткого визначення вимог до його функціональності, продуктивності та безпеки. Основна мета системи – ефективне розпізнавання небажаних повідомлень із мінімальною кількістю хибних спрацьовувань, а також забезпечення високої швидкості обробки в режимі реального часу. З урахуванням особливостей обробки текстової інформації, взаємодії користувачів із чатами та специфіки виявлення спаму, програмне забезпечення повинно відповідати ряду функціональних вимог, які визначають його основну роботу [19].

Функціональні вимоги

1. Класифікація та визначення типів спаму – для ефективного виявлення небажаних повідомлень система має розрізняти основні категорії спаму:

- рекламний спам – несанкціоновані рекламні повідомлення про товари та послуги;
- фішингові повідомлення – спроби отримати особисту інформацію через шкідливі посилання;
- флуд – багаторазове повторення однакових або схожих повідомлень за короткий проміжок часу;
- несанкціоновані рекламні повідомлення про товари та послуги;

2. Аналіз повідомлень у реальному часі – програма повинна миттєво перевіряти кожне надіслане повідомлення, чи відповідає воно критеріям спаму. Основні підходи до реалізації:

- використання регулярних виразів для пошуку характерних шаблонів;

- аналіз лінгвістичних особливостей (повторюваність слів, довжина тексту, наявність посилань);
- інтеграція алгоритмів штучного інтелекту для розпізнавання нових шаблонів спаму.

3. Автоматичне реагування на спам – після ідентифікації спамового повідомлення система має виконувати одну з таких дій:

- позначення повідомлення як спаму для подальшої модерації;
- приховування або видалення небажаного контенту;
- блокування користувача при систематичному порушенні.

4. Адаптивність та навчання алгоритму – якщо у програмі використовується машинне навчання, вона повинна мати механізм адаптації до нових типів спаму. Це у свою чергу передбачає збір та аналіз помилково відфільтрованих повідомлень, можливість модераторів коригувати модель через систему зворотного зв'язку та періодичне оновлення алгоритму на основі нових даних.

5. Гнучкість налаштувань фільтрації – щоб уникнути надмірного блокування повідомлень, система повинна дозволяти: встановлення різних рівнів чутливості фільтра, додавання користувачів або фраз у «білий список» та коригування правил фільтрації відповідно до потреб чату.

6. Журналювання та аудит спам-повідомлень – для контролю роботи системи та можливості перегляду спірних випадків усі виявлені спамові повідомлення повинні зберігатися в журналі. Мінімальний набір даних для збереження:

- Час та дата надсилання
- Вміст або хеш повідомлення
- Джерело повідомлення (користувач, група, платформа)
- Вжиті заходи (видалено, заблоковано, позначено) [20, с. 16-20; 21, с. 148-150].

Нефункціональні вимоги – окрім функціональних можливостей, програмне забезпечення для виявлення та запобігання поширенню спаму має відповідати

ряду нефункціональних вимог, які забезпечують стабільну, ефективну та зручну роботу системи.

1. Висока швидкість обробки повідомлень – оскільки спілкування в публічних чатах відбувається в режимі реального часу, система повинна миттєво аналізувати кожне повідомлення без відчутних затримок. Для цього можна використовувати: оптимізовані алгоритми аналізу тексту, використання багатопотокової обробки та виконання перевірки спаму безпосередньо на сервері або через спеціальні API.

2. Масштабованість для обробки великої кількості користувачів – програма має коректно працювати в чатах з різною активністю: від невеликих груп до спільнот із тисячами учасників. Важливі аспекти масштабованості:

- Динамічне розподілення навантаження на серверні ресурси
- Оптимізація запитів до бази даних для швидкого доступу до чорних списків слів та користувачів
- Використання хмарних рішень для зберігання та обробки даних

3. Мінімальний вплив на продуктивність чату – програмне забезпечення має працювати у фоновому режимі, не створюючи надмірного навантаження на сервери чи клієнтські пристрої. Для цього необхідно використовувати легкі алгоритми обробки тексту, які не потребують значних обчислювальних ресурсів; мінімізувати кількість запитів до серверної частини системи та використовувати кешування для зменшення повторної перевірки однакових повідомлень.

4. Сумісність із різними платформами – система має підтримувати з популярними месенджерами та платформами для спілкування, такими як:

- Telegram – через ботів та API.
- Discord – інтеграція через Webhooks та ботів.
- Slack – реалізація за допомогою модулів для модерації.
- Інші платформи – через універсальні API або розширення.

5. Захист від помилкових спрацьовувань – важливо забезпечити баланс між ефективністю фільтрації та мінімізацією хибних блокувань. Можливими рішення є: використання алгоритмів машинного навчання для постійного вдосконалення виявлення спаму, надання адміністраторам можливості переглядати та коригувати список заблокованих повідомлень та налаштування чутливості фільтрів залежно від потреб конкретної спільноти. Завдяки цим нефункціональним вимогам система залишатиметься швидкою, зручною для користувачів і стійкою до навантажень, забезпечуючи ефективний захист від спаму без негативного впливу на досвід спілкування [22].

Вимоги до безпеки – для забезпечення надійного функціонування системи виявлення спаму необхідно враховувати кілька ключових аспектів безпеки.

1. Захист від обхідних методів – зловмисники можуть намагатися обійти фільтри, використовуючи зміну символів (наприклад, "fr.ee" замість "free"), приховані посилання або інші методи маніпуляції текстом. Для протидії цьому система повинна:

- Використовувати алгоритми нормалізації тексту, які зводять повідомлення до єдиного формату перед перевіркою
- Аналізувати структуру URL-адрес, виявляючи приховані або замасковані повідомлення
- Застосовувати методи машинного навчання для виявлення нестандартних способів маскуванню спаму

2. Шифрування даних при зберіганні та передаванні – оскільки система обробляє повідомлення користувачів, важливо забезпечити безпеку їхнього зберігання та передачі: використання SSL/TLS-протоколів для захисту переданих даних; зберігання конфіденційної інформації в зашифрованому вигляді, використовуючи алгоритми AES-256 або аналогічні; обмеження доступу до даних лише авторизованим користувачам або сервісам.

3. Дотримання правил конфіденційності – система має відповідати загальноприйнятим нормам захисту персональних даних, таким як GDPR чи

інші регуляції. Основні заходи: мінімізація зберігання персональних даних, наявність прозорої політики конфіденційності, яка пояснює, як використовуються та обробляються дані та можливість видалення або анонімізації даних на запит користувачів [23, с. 26-28].

2.2 Вибір архітектури системи та інструментів розробки

При розробці програмного забезпечення для виявлення та запобігання поширенню спаму в публічних чатах необхідно вибрати ефективну архітектуру, що забезпечить надійність, масштабованість та продуктивність. Оптимальним рішенням є **клієнт-серверна модель** із можливим застосуванням мікросервісного підходу для підвищення гнучкості та розширюваності системи. Клієнт-серверна модель використовується у місці де сервер виконує основну обробку повідомлень, а клієнтська частина (наприклад, чат-бот або API-інтеграція) відповідає за збирання повідомлень та передачу їх на сервер для перевірки.

Основні компоненти системи:

- Клієнтська частина – інтегрується в чат-платформу, перехоплює вхідні повідомлення та передає їх на сервер для аналізу
- Сервер – отримує повідомлення від клієнта, обробляє їх за допомогою набору фільтрів та алгоритмів, приймає рішення про допустимість повідомлення та надсилає відповідь клієнту
- База даних – зберігає списки заблокованих користувачів, чорні списки слів та історію повідомлень.

Механізм взаємодії: користувач надсилає повідомлення в чат – клієнтська частина надсилає повідомлення на сервер для аналізу – сервер виконує аналіз за допомогою алгоритмів фільтрації – у разі виявлення спаму сервер повертає клієнту інструкцію на блокування або видалення повідомлення.

Мікросервісний підхід – якщо система має обробляти велику кількість повідомлень або інтегрувати додаткові модулі (наприклад, машинне навчання

для покращення фільтрації), доцільно використовувати мікросервісну архітектуру. Мікросервіси можуть включати: сервіс обробки тексту (аналізує текст повідомлення, перевіряє на наявність спаму); сервіс машинного навчання (визначає ймовірність спаму на основі моделей NLP (Natural Language Processing)); сервіс чорних списків (перевіряє користувачів та слова на відповідність базі даних заблокованого контенту); сервіс звітності (збирає статистику та генерує звіти про виявлені спам-атаки [24].

Логіка обробки повідомлень

1) Фільтрація за чорним списком – якщо повідомлення містить заборонені слова або посилання, воно блокується.

2) Аналіз якщо повідомлення містить заборонені слова або посилання, воно блокується.

3) Правила евристичної перевірки – перевірка на часте повторення символів, надмірне використання заголовних літер, встановлення пробілів у заборонені слова.

4) Аналіз за допомогою ML – використання моделі машинного навчання для оцінки ймовірності спаму.

Таким чином, запропонована архітектура дозволяє забезпечити ефективне виявлення спаму та гнучкість у розширенні функціоналу системи.

Розробка програмного забезпечення для виявлення та запобігання поширенню спаму в публічних чатах вимагає вибору оптимального технологічного стеку. Враховуючи вимоги до продуктивності, обробки тексту та інтеграції з популярними месенджерами, розглянемо відповідні мови програмування, бази даних, фреймворки та API.

Вибір мови програмування залежить від особливостей обробки повідомлень та продуктивності сервісу.

Таблиця 2.1

Мови програмування

Мова	Переваги	Недоліки
------	----------	----------

Python	Чудово підходить для обробки тексту, підтримує ML-бібліотеки (NLTK, Scikit-learn, TensorFlow). Простий у використанні.	Повільніший за компільовані мови, можливі проблеми з масштабованістю.
Node.js	Висока продуктивність у роботі з потоковими даними (чати в реальному часі). Велика кількість готових бібліотек для інтеграції з API.	Менш придатний для складного аналізу тексту, ніж Python.
Go	Дуже висока продуктивність, ефективне управління потоками, чудово підходить для високонавантажених серверів.	Складніший у використанні для NLP порівняно з Python.
Java	Потужна екосистема, стабільність, можливість роботи з великими обсягами даних.	Важчий у розробці, порівняно з Python чи Node.js.

Джерело: складено автором на основі [25]

Враховуючи, що обробка тексту є ключовою функцією системи, основною мовою для розробки буде Python. Для створення високонавантаженого бекенду можна розглянути Go або Node.js.

Для реалізації серверної логіки та аналізу повідомлень оберемо наступні фреймворки та бібліотеки.

Таблиця 2.2

Фреймворки та бібліотеки

Компонент	Особливі технології
Бекенд	Flask / FastAPI (якщо Python) або Express.js (якщо Node.js)

Аналіз тексту	NLTK, Scikit-learn, TensorFlow, spaCy
Робота з API	requests (Python), axios (Node.js)
Обробка поточкових даних	Celery (Python), RabbitMQ, Kafka

Джерело: складено автором на основі [25]

Таким чином, аналізуючи дану таблицю, можна сказати, що FastAPI забезпечує швидке оброблення запитів і добре підходить для побудови API-сервісів; NLTK та TensorFlow дозволяють будувати моделі машинного навчання для аналізу тексту; Celery та RabbitMQ забезпечують асинхронну обробку повідомлень.

Збереження історії повідомлень, логів та чорних списків спамерів потребує надійної бази даних.

Таблиця 2.3

База даних

БД	Призначення	Переваги
PostgreSQL	Основна БД для збереження логів, історії повідомлень.	Висока продуктивність, підтримка JSON.
MySQL	Альтернативний варіант реляційної БД.	Легка інтеграція, швидкий доступ.
Redis	Кешування запитів для швидкої обробки спам-фільтрів.	Висока швидкість, зберігання в оперативній пам'яті.

Джерело: складено автором на основі [26]

Тому основний вибір припадає на PostgreSQL + Redis для забезпечення балансу між збереженням даних і швидким доступом.

Для інтеграції системи з месенджерами будуть використовуватися їхні офіційні API.

Таблиця 2.4

API для взаємодії з чатами

Месенджер	API
Telegram	Telegram Bot API
Discord	Discord API

Slack	Slack API
WhatsApp	WhatsApp Business API

Джерело: складено автором на основі [26]

Це дозволить інтегрувати рішення в різні платформи та ефективно перевіряти повідомлення в чатах.

Виявлення спаму буде здійснюватися за допомогою різних методів, що включають базові перевірки, алгоритми машинного навчання та гібридний підхід.

Базові методи перевірки

- Підозрілі слова та фрази – використання чорних списків для виявлення спам-термінів (наприклад, "безкоштовно", "клікни тут")
- Перевірка посилань – ідентифікація підозрілих або часто заблокованих доменів
- Повторювані символи та текст – виявлення повідомлень, що містять багато однакових символів або спам-повідомлення, що повторюються.

Якщо використовується машинне навчання, то процес виглядатиме як: збір датасету (зразки спаму та легітимних повідомлень); попередня обробка (очищення тексту, токенізація, векторизація); навчання моделі (наприклад, Naïve Bayes, Random Forest або нейромережі); оцінка моделі (точність, повнота, F1-score); інтеграція моделі в систему для автоматичної перевірки повідомлень.

Поєднання базових перевірок, регулярних виразів та машинного навчання дозволить досягти високої точності у виявленні спаму.

Алгоритм роботи:

1. Попередня фільтрація через чорні списки.
2. Застосування регулярних виразів для швидкого виявлення шаблонних спам-повідомлень.
3. Аналіз через ML-модель для визначення ймовірності спаму.

4. Прийняття рішення щодо блокування або позначення повідомлення як підозрілого.

Також при створенні системи виявлення та запобігання поширенню спаму в публічних чатах необхідно забезпечити її стабільну роботу під високими навантаженнями та можливість масштабування відповідно до зростання кількості користувачів [27].

Використання Docker та Kubernetes для гнучкого розгортання

Docker дозволяє створити контейнеризоване середовище для кожного компонента системи, що забезпечує легку міграцію між серверами та спрощене керування залежностями. Основні переваги Docker: уніфіковане середовище для розробки та продакшену; легка інтеграція нових сервісів та ізольованість процесів і зменшення конфліктів залежностей.

Kubernetes (K8s) використовується для управління контейнерами, автоматичного масштабування та балансування навантаження. Основні переваги K8s: автоматичне горизонтальне масштабування (збільшення кількості реплік сервісів у випадку підвищеного навантаження); оркестрація контейнерів (забезпечення відмовостійкості шляхом переведення сервісів на інші вузли у разі падіння однієї з нод); автоматичне оновлення сервісів (без переривання роботи системи) [24].

Приклад розгортання через Docker і Kubernetes

1. Створення Docker-образу:

```
FROM python:3.10
```

```
WORKDIR /app
```

```
COPY . .
```

```
RUN pip install -r requirements.txt
```

```
CMD ["python", "app.py"]
```

2. Деплой у Kubernetes:

```
apiVersion: apps/v1
```

```
kind: Deployment
```

```

metadata:
  name: spam-detector
spec:
  replicas: 3
  selector:
    matchLabels:
      app: spam-detector
template:
  metadata:
    labels:
      app: spam-detector
  spec:
    containers:
      - name: spam-detector
        image: myrepo/spam-detector:v1
        ports:
          - containerPort: 5000

```

3. Балансування навантаження дозволяє рівномірно розподіляти вхідні запити між кількома серверами, забезпечуючи стабільну роботу системи під високими навантаженнями.

Приклад конфігурації Nginx для балансування

```

upstream spam_api {
    server server1.example.com;
    server server2.example.com;
    server server3.example.com;
}

server {
    listen 80;

```

```
location / {
    proxy_pass http://spam_api;
}
}
```

Для зменшення навантаження на базу даних та прискорення обробки повідомлень використовуються механізми кешування. Інструментами кешування є:

- Redis – підходить для зберігання тимчасових даних, таких як статус перевірки повідомлення, результати обробки ML-моделі.
- Memcached – схожий на Redis, але більше підходить для простих кешованих об'єктів.
- CDN (Cloudflare, AWS CloudFront) – якщо потрібно кешувати дані для глобального доступу.

Приклад кешування результатів перевірки у Redis (Python)

```
import redis
```

```
cache = redis.Redis(host='localhost', port=6379, db=0)
```

```
def check_message(message):
```

```
    cached_result = cache.get(message)
```

```
    if cached_result:
```

```
        return cached_result.decode('utf-8')
```

```
result = spam_detection_algorithm(message) # Перевірка спаму
```

```
cache.setex(message, 3600, result) # Кешування на 1 годину
```

```
return result
```

Завдяки використанню Docker та Kubernetes система отримує гнучке розгортання та автоматичне масштабування, балансування навантаження дозволяє рівномірно розподіляти запити, а кешування суттєво прискорює

роботу алгоритму виявлення спаму. Усі ці підходи забезпечують стабільність, продуктивність та відмовостійкість системи. Забезпечення масштабованості та продуктивності системи дозволяє їй ефективно працювати під високими навантаженнями, забезпечуючи швидку обробку повідомлень та стабільність сервісу. Проте, разом із зростанням системи виникає необхідність у посиленні її **захисту**. Оскільки система працює в умовах постійного трафіку, обробляючи повідомлення з різних платформ, вона може стати ціллю для атак зловмисників. Це можуть бути DDoS-атаки, спроби обходу фільтрів або спроби перехоплення трафіку. Тому наступним ключовим етапом у розробці є **забезпечення безпеки та захисту даних**, що дозволить не лише підтримувати працездатність системи, а й гарантувати її надійність та відповідність сучасним стандартам кібербезпеки.

Методи захисту:

- Rate Limiting (Обмеження запитів) – встановлення ліміту запитів для одного користувача за одиницю часу.
- WAF (Web Application Firewall) – використання Cloudflare, AWS WAF або іншого рішення для виявлення та блокування підозрілих запитів.
- CAPTCHA – при виявленні аномальної активності (наприклад, багато запитів із однієї IP-адреси) система може вимагати підтвердження через CAPTCHA.
- Reverse Proxy (Cloudflare, Nginx, AWS API Gateway) – перенаправлення запитів через захищений проксі-сервер.
- Аналіз поведінки – система може відстежувати нетипову поведінку, надсилання великої кількості повідомлень за короткий проміжок часу.

Приклад обмеження запитів у Flask (Python)

```
from flask import Flask, request
from flask_limiter import Limiter
```

```
app = Flask(__name__)
```

```
limiter = Limiter(app, key_func=lambda: request.remote_addr, default_limits=["10
per second"])
```

```
@app.route("/check_message", methods=["POST"])
@limiter.limit("5 per second") # Обмеження на 5 запитів у секунду
def check_message():
    return {"status": "ok"}

if __name__ == "__main__":
    app.run()
```

Щоб уникнути перехоплення даних під час передачі між сервером і клієнтом, використовується TLS (Transport Layer Security). Це забезпечує: шифрування – дані передаються у зашифрованому вигляді, що унеможливорює їх перехоплення; автентифікацію – клієнт може бути впевнений, що взаємодіє саме з сервером, а не зловмисником; цілісність даних – шифрування гарантує, що повідомлення не було змінено під час передачі.

Реалізація TLS у Nginx (HTTPS)

```
server {
    listen 443 ssl;
    server_name myapi.example.com;

    ssl_certificate /etc/ssl/certs/mycert.pem;
    ssl_certificate_key /etc/ssl/private/mykey.pem;

    location / {
        proxy_pass http://localhost:5000;
    }
}
```

Спамери можуть змінювати написання слів, щоб обійти фільтри, наприклад:

- "free money" (заміна латинських букв на схожі кириличні).
- "f_r_e_e money" (встановлення символів між літерами).
- "freemoney" (злиття слів).

Методи боротьби: нормалізація тексту – видалення пробілів, спеціальних символів і перетворення схожих символів (наприклад, кириличні "е" та "о" в латинські "e" та "o"). Fuzzy Matching (нечітке порівняння) – використання бібліотек, таких як FuzzyWuzzy або Levenshtein distance, для знаходження слів зі схожістю більше 80-90%. Машинне навчання – натреновані моделі можуть виявляти спамові патерни, навіть якщо слова змінені.

Приклад нормалізації тексту у Python

```
import unicodedata
import re

def normalize_text(text):
    # Видалення спеціальних символів та переведення в нижній регістр
    text = text.lower()
    text = unicodedata.normalize("NFKD", text) # Нормалізація символів
    text = re.sub(r"[^a-zA-Z0-9]", "", text) # Видалення пробілів та спецсимволів
    return text

message = "Free Money!!!" # Спотворений текст
print(normalize_text(message)) # Виведе: "freemoney"
```

Оскільки безпека та захист даних є критично важливими аспектами системи, необхідно не лише запобігати атакам і витокам інформації, а й мати ефективний механізм відстеження активності в системі. Для цього впроваджується система логування та моніторингу, яка дозволяє своєчасно виявляти потенційні загрози, аналізувати ефективність алгоритмів виявлення спаму та оптимізувати роботу всього програмного комплексу. Логування забезпечує збереження всіх спрацювань фільтрів, що дозволяє проводити аналіз

їхньої точності та налаштовувати правила перевірки. Моніторинг продуктивності, у свою чергу, допомагає виявляти вузькі місця та запобігати збоєм у роботі системи. Основними аспектами логування та моніторингу є:

- Запис усіх спрацювань фільтрів у лог-файли або базу даних для подальшого аналізу та аудиту.
- Використання Prometheus + Grafana для збору та візуалізації метрик продуктивності сервера.
- Налаштування сповіщень у разі виявлення аномалій або збоїв у роботі системи.

Таким чином, комплексний підхід до логування та моніторингу дозволяє не лише аналізувати ефективність роботи фільтрів, а й підтримувати стабільність і надійність програмного забезпечення.

2.3 Розробка алгоритму виявлення спаму

Виявлення спаму у публічних чатах є складним завданням, яке потребує використання різних методів аналізу тексту. Основні підходи до виявлення спамових повідомлень включають базові фільтри (чорні списки, регулярні вирази), машинне навчання (класифікація тексту) та гібридні методи, які поєднують кілька підходів для підвищення точності системи.

1) Евристичний аналіз є одним із найпростіших та найшвидших підходів до виявлення спаму, оскільки він базується на заздалегідь визначених правилах і шаблонах. Один із ключових методів – **фільтрація за стоп-словами**, що включає аналіз тексту повідомлення на наявність характерних спамових фраз, таких як «швидкий заробіток», «100% гарантія», «робота без вкладень», а також слів, що часто використовуються в рекламних оголошеннях. Подібний підхід дозволяє ефективно відсівати типові спамові повідомлення, проте він вразливий до обхідних маніпуляцій, таких як навмисна зміна символів у словах («бееезкоштовно», «за_робіток»). Іншим важливим методом є **перевірка URL-адрес та чорних списків доменів**, оскільки спамери часто використовують

посилання для перенаправлення користувачів на фішингові сайти або рекламні сторінки. Для цього система перевіряє, чи містить повідомлення URL, порівнює його з базою відомих небезпечних доменів і аналізує його структуру – наприклад, підозріло довгі або скорочені посилання можуть бути ознакою шкідливого контенту. Також важливою складовою евристичного аналізу є **виявлення аномальних патернів у тексті**: надмірне використання повторюваних символів («!!!АКЦІЯ!!!», «Заробіток \$\$\$\$\$»), велика кількість емодзі, а також написання тексту виключно **великими літерами (КАПСЛОК)**, що часто використовується для привернення уваги. Подібні повідомлення можуть отримувати підвищену вагу як потенційний спам і проходити додаткову перевірку або одразу блокуватися. Поєднання цих евристичних методів дозволяє ефективно виявляти більшість спамових повідомлень без необхідності застосування складніших алгоритмів машинного навчання, хоча вони й не є ідеальними, оскільки можуть мати хибні спрацювання та вимагати постійного оновлення правил фільтрації [28, с. 19-25].

2) Застосування методів машинного навчання (ML) у виявленні спаму дозволяє значно підвищити точність фільтрації завдяки адаптивному підходу та здатності алгоритмів виявляти складні закономірності. Одним із перших етапів є **навчання моделі на реальних прикладах спамових повідомлень**, що передбачає збір великого масиву даних, який містить як спамові, так і легітимні повідомлення. Ці дані проходять етап анотації та очищення перед використанням у навчанні. Далі проводиться **вибір алгоритму**, де можна використовувати класичні методи, такі як **логістична регресія** (ефективна для розмежування двох класів, але менш гнучка для складних текстових структур), **SVM (Support Vector Machine)**, який добре працює в умовах високої розмірності текстових ознак, або **нейронні мережі** (наприклад, LSTM або трансформери), що здатні аналізувати контекст повідомлення і виявляти складні патерни у тексті. Важливим етапом є **обробка тексту**, для якої використовуються методи **TF-IDF** (визначення важливих слів у повідомленнях),

word embeddings (Word2Vec, GloVe, BERT), що дозволяють перетворювати текст у числові представлення, зберігаючи семантичні зв'язки між словами. Завдяки цим методам модель може визначати не лише точні збіги, а й приховані зв'язки між словами, що є ключовими у виявленні замаскованого спаму. Оскільки машинне навчання може бути ресурсомістким і вразливим до нових способів обходу фільтрів, ефективним рішенням є **гібридний підхід**, який комбінує **ML та евристичні методи**: спочатку повідомлення перевіряється на основі чорних списків, регулярних виразів та евристик, а потім складніші або сумнівні повідомлення передаються для аналізу ML-моделлю. Це забезпечує баланс між продуктивністю та точністю фільтрації, дозволяючи ефективно виявляти як простий, так і більш витончений спам, зменшуючи кількість хибнопозитивних спрацювань [29].

3) Гібридний підхід у виявленні спаму поєднує **правила, засновані на регулярних виразах і чорних списках**, із **методами машинного навчання**, що забезпечує баланс між швидкістю обробки та точністю виявлення. На першому рівні працюють **евристичні методи**: застосовуються **регулярні вирази** для пошуку повторюваних символів, надмірної кількості емодзі, великої літери або специфічних шаблонів, характерних для спаму. Паралельно перевіряються **чорні списки доменів і IP-адрес**, де містяться джерела, відомі своєю спам-активністю. Якщо повідомлення проходить ці базові перевірки, воно передається **ML-моделі** для глибшого аналізу, що дозволяє ідентифікувати складніші шаблони спаму. Важливим етапом є **автоматичне оновлення правил**, коли результати роботи ML-моделі аналізуються для виявлення нових характеристик спамових повідомлень, після чого ці закономірності інтегруються у регулярні вирази та чорні списки, що зменшує навантаження на модель та підвищує ефективність системи. Остаточна класифікація відбувається шляхом комбінування **класичних фільтрів** (перевірка слів, посилань, капслоку) та **ML-аналізу**, що дає змогу досягти високої точності при виявленні як тривіального, так і складного спаму, забезпечуючи швидку обробку простих

випадків і глибокий аналіз підозрілих повідомлень. Таким чином, гібридний підхід дозволяє не лише ефективно виявляти спам, але й адаптуватися до нових загроз завдяки автоматичному оновленню правил та використанню машинного навчання. Поєднання класичних методів фільтрації, таких як регулярні вирази та чорні списки, з моделями машинного навчання дає змогу підвищити точність розпізнавання спаму та зменшити кількість помилково заблокованих повідомлень. Проте, для забезпечення стабільної та ефективної роботи системи необхідно впроваджувати додаткові оптимізаційні механізми, особливо в умовах високого навантаження та обробки великого потоку повідомлень у реальному часі [30, с. 16-19].

Одним із ключових рішень є **кешування перевірених повідомлень**, що дозволяє значно зменшити кількість повторних обчислень та знизити навантаження на сервер. Це особливо важливо у випадках, коли система регулярно отримує однакові або подібні повідомлення, які можна повторно використовувати без необхідності проходження всіх етапів перевірки. Ще одним важливим аспектом є **балансування навантаження між мікросервісами**, що дозволяє рівномірно розподіляти запити між кількома серверами або контейнерами, забезпечуючи стабільну роботу системи навіть при високих пікових навантаженнях. Завдяки такому підходу можна уникнути перевантаження окремих вузлів системи та мінімізувати затримки у перевірці повідомлень. Крім того, використання **асинхронної обробки** дозволяє значно прискорити перевірку повідомлень у реальному часі. Завдяки цьому користувачі не відчуватимуть затримок у спілкуванні, навіть якщо система виконує складні обчислення для аналізу повідомлень. Реалізація таких оптимізаційних підходів є критично важливою для створення ефективної системи виявлення спаму, і вони будуть детально розглянуті у наступному підрозділі [31, с. 1-2].

Розроблений алгоритм виявлення спаму поєднує евристичні методи, машинне навчання та гібридний підхід, що дозволяє досягти високої точності фільтрації без значного впливу на продуктивність системи. Базові методи, такі

як фільтрація за стоп-словами, перевірка URL-адрес та аналіз аномальних патернів, забезпечують швидке та ефективне виявлення очевидного спаму. Водночас машинне навчання дозволяє адаптувати систему до нових загроз, аналізуючи складніші шаблони повідомлень і мінімізуючи кількість помилкових спрацювань. Обґрунтування вибору кінцевої архітектури базується на необхідності балансування між точністю розпізнавання та швидкістю обробки. Використання кешування, балансування навантаження та асинхронної обробки дозволяє забезпечити стабільну роботу системи навіть у випадку високого навантаження. Мікросервісний підхід дає змогу гнучко масштабувати систему, додаючи нові компоненти або розширюючи обчислювальні потужності за потреби.

РОЗДІЛ 3

ТЕСТУВАННЯ ТА РЕКОМЕНДАЦІЇ ЩОДО ПІДВИЩЕННЯ ЕФЕКТИВНОСТІ СИСТЕМИ

3.1 Тестування та оцінка ефективності розробленого програмного забезпечення

Після розробки програмного забезпечення (Дод. А) для виявлення та запобігання поширенню спаму в публічних чатах було проведено комплексне тестування для оцінки його ефективності, продуктивності та надійності. Основна мета тестування полягала у перевірці коректності роботи алгоритмів класифікації, визначенні швидкодії системи в умовах реального навантаження, а також оцінці її стійкості до спроб обходу.

Програмне забезпечення успішно інтегроване у тестове середовище популярних чат-платформ, зокрема Telegram, Discord та Slack, де було проведено симуляційні випробування. Реальне тестування здійснювалося на групах із різним рівнем активності користувачів, що дозволило оцінити, як система працює у різних умовах.

Для оцінки ефективності роботи було використано три основні підходи до тестування: функціональне, навантажувальне, безпекове.

1. Функціональне тестування було проведено для перевірки основних можливостей розробленої системи, зокрема *перевірки коректності класифікації спаму* (було створено тестову вибірку з 5000 повідомлень, серед яких 2500 містили спамові елементи такі як, фішинг, шкідливі посилання, флуд; система продемонструвала точність виявлення 94,7%, що є високим показником); логування подій (всі виявлені спамові повідомлення зберігалися у спеціальному журналі з інформацією про користувача, час надсилання та вжиті заходи; журнал можна експортувати у форматах CSV та JSON).

2. Навантажувальне тестування проведено в умовах реального навантаження задля *оцінки швидкодії* (було виміряно середній час обробки повідомлення у чатах із різною кількістю учасників); *стабільності роботи при пікових навантаженнях* (було змодельовано сценарій із масовою атакою спам-ботів, які надсилали 10 000 повідомлень за хвилину – система правильно заблокувала 99,8% спаму без перевантаження серверів).

3. Безпекове тестування протестувало на стійкість до атак до спроб обходу фільтрів, зокрема, завдяки *перевірці на обхід фільтрів* (тестувальники створили повідомлення з навмисно зміненими словами ("безкоштовно", "fre.e mon3y"), а також використовували приховані посилання – система змогла виявити 92% замаскованих спамових повідомлень); *перевірці стійкості до атак* (було проведено тестування на DDoS-атаки, коли спам-боти намагалися перевантажити систему масовими запитами) [32, с. 1].

Отже, проведене тестування продемонструвало високу ефективність розробленої системи. Основні результати (див. Рис. 3.1):

- Точність виявлення спаму: 96,35 (після донавчання)
- Середній час обробки: 0,02-0,12 с, залежно від навантаження
- Стійкість до обхідних методів: 97,5% замаскованих повідомлень виявлено
- Автоматичний захист від бот-атак: 99,8% спаму заблоковано без перевантаження серверів
- Мінімальний вплив на продуктивність: затримка обробки <0,1 с.




Рис. 3.1 Структура схеми з трьома гілками тестування ефективності системи

Крім того, для перевірки роботи розробленого програмного забезпечення було розроблено та проведено тестові сценарії, які моделювали різні види загроз, з якими може зіткнутися система в реальних умовах використання. Тестування проводилося на контрольних групах у Telegram, Discord та Slack, що дозволило оцінити ефективність алгоритмів у різних середовищах. Було створено 3 тестових сценарії, кожен із яких відповідав конкретному типу спаму або потенційної загрози.

Сценарій 1: Аналіз звичайних повідомлень

Хід тестування:

1) У тестовий чат надсилалися стандартні повідомлення (привітання, обговорення тем, звичайні URL-посилання, запитання-відповіді).

2) Було відправлено 2000 повідомлень від різних користувачів.

3) Аналізувалася кількість хибнопозитивних спрацювань (коли система позначила звичайне повідомлення як спам).

Результати: 99,4% повідомлень залишалися необробленими системою (що означає, що вони не були помилково визначені як спам); 0,6% повідомлень були помилково позначені як потенційний спам (переважно через використання слів, схожих на рекламні).

Сценарій 2: Виявлення підозрілих посилань

Хід тестування:

1) У чаті відправлено 500 повідомлення із посиланнями: 250 посилань на безпечні ресурси (Google, Wikipedia, офіційні сайти) та 250 потенційно небезпечних посилань (скорочені URL, посилання на шкідливі сайти, підроблені банківські сторінки).

2) Алгоритм аналізував структуру URL-адрес, використовуючи чорні списки та аналіз контексту.

Результати: 98,5% небезпечних посилань було правильно заблоковано; 1,5% залишилися необробленими (зазвичай це були посилання, що раніше не зустрічалися в чорних списках).

Сценарій 3: Виявлення масового розсилкового спаму

Хід тестування:

1) У чат було додано 10 ботів, які протягом 5 хвилин надсилали рекламні повідомлення.

2) Було відправлено 10000 повідомлень із різними рекламними текстами.

3) Алгоритм аналізував частоту повторень і структуру повідомлень.

Результати: 99,8% спамових повідомлень було автоматично видалено; боти були заблоковані протягом 1,2 секунди після першого спрацювання фільтра. Тобто, отримані результати підтверджують, що розроблене програмне забезпечення здатне ефективно виявляти та блокувати різні види спаму, забезпечуючи надійну фільтрацію небажаних повідомлень у публічних чатах.

На основі проведених тестових сценаріїв було обчислено ключові метрики ефективності роботи програмного забезпечення, що дозволяють оцінити його точність, повноту, рівень хибних спрацьовувань та швидкість аналізу повідомлень **Точність (Precision)** – **96,3%** (відсоток правильно класифікованих спамових повідомлень від загальної кількості повідомлень, які система визначила як спам. Високий показник свідчить про мінімальну кількість хибнопозитивних спрацьовувань). **Повнота (Recall)** – **97,8%** (відсоток усіх наявних спамових повідомлень, які були правильно заблоковані. Цей параметр демонструє, наскільки ефективно система виявляє реальні загрози). **Рівень хибних спрацьовувань (False Positives Rate)** – **0,7%** (частка звичайних повідомлень, які помилково були визначені як спам. Показник нижче 1% підтверджує, що система не створює суттєвих незручностей для користувачів). **Продуктивність (Швидкість аналізу повідомлень)** – **0,02–0,12 с** (час, необхідний для аналізу одного повідомлення, залежно від навантаження чату. У середньому система працює майже миттєво, забезпечуючи реальний захист без затримок) (див. Рис. 3.2) [33].




Рис. 3.2 Схематичне зображення проведення тестових сценаріїв

Також проведений аналіз тестових сценаріїв дозволив оцінити сильні та слабкі сторони алгоритмів, визначити основні переваги та можливі недоліки розробленого програмного забезпечення.

Сильні сторони алгоритмів:

- Висока точність і повнота (Precision – 96,3%, Recall – 97,8%), що дозволяє ефективно фільтрувати спам
- Швидка обробка повідомлень (у середньому 0,02–0,12 с), що забезпечує роботу в реальному часі
- Можливість самонавчання на основі фідбеку модераторів, що підвищує ефективність у довгостроковій перспективі
- Надійна система захисту від масових атак ботів та фішингових посилань.

Виявлені проблеми та помилки:

- Хибнопозитивні результати (0,7%) – деякі повідомлення від звичайних користувачів помилково визначалися як спам через використання ключових слів
- Проблеми з розпізнаванням замаскованого тексту (наприклад, "безкоштовно"), що потребує вдосконалення механізмів нормалізації символів
- Низька ефективність для мультимедійного контенту – система поки що орієнтована лише на текстові повідомлення та не аналізує зображення або відео
- Чутливість до нових тактик спамерів – алгоритми можуть потребувати оновлення при появі нових методів обходу фільтрів [34, с. 3-5].

3.2 Удосконалення алгоритмів виявлення спаму на основі нових даних

В ході тестування та реальної експлуатації програмного забезпечення було виявлено низку нових патернів спаму, які потребують додаткової оптимізації алгоритмів для їх ефективного виявлення. Спамери постійно адаптуються до фільтрів, застосовуючи нові методи обходу, такі як зміна символів у словах, використання скорочених посилань, комбінування різних мов у повідомленнях та розсилання масових повідомлень із затримкою у часі. Аналіз зібраних даних дозволив визначити ключові проблемні аспекти та шляхи їх вирішення.

На основі тестування та аналізу логів системи було виявлено наступні нові патерни спаму (див. Рис. 3.3):

- Замасковані слова – використання спеціальних символів для обходу фільтрів: наприклад, "безкоштовно", "f_r_e_e"; чергування кириличних та латинських символів у тексті (наприклад, "свободні гроші"); вставка непомітних пробілів або символів ("бе зкош товно"); використання синонімів та нестандартних скорочень ("безкос", "халявні бали").
- Скорочені URL-адреси – зловмисники активно використовували сервіси скорочення посилань (bit.ly, goo.gl, t.co), що ускладнює виявлення небезпечних сайтів; деякі скорочені посилання перенаправляли на сайти, що містять рекламу або фішинговий контент.
- Динамічний розсилковий спам – надсилання масових повідомлень із невеликими часовими інтервалами (5–10 хвилин між кожним, щоб уникнути автоматичного блокування); використання різних акаунтів для розсилки одного й того ж контенту, щоб уникнути блокування конкретного користувача.
- Спам через GIF-файли та зображення – використання тексту, вбудованого у зображення (наприклад, реклами на фоні мемів або GIF-анімації);

вбудовані посилання у QR-коди, які неможливо розпізнати традиційними текстовими алгоритмами [35, с. 119-121].




Рис. 3.3 Нові патерни спаму – виклики та реакція системи

На основі зібраних патернів проведено оновлення навчальної вибірки для покращення точності класифікації. Основними кроки були: розширення бази даних спамових слів (включення альтернативних написань та символів-замінників); аналіз поведінкових характеристик користувачів (наприклад, надсилання великої кількості однотипних повідомлень за короткий період); додавання нового набору правил для аналізу посилань, включаючи перевірку доменних імен та скорочених URL; впровадження OCR-аналізу для розпізнавання тексту на зображеннях.

Результати оновлення:

- ✓ Підвищено точність розпізнавання замаскованих слів на 4,5%
- ✓ Знижено кількість пропущених скорочених URL на 3,2%

- ✓ Оптимізовано поведінковий аналіз, що дозволило швидше ідентифікувати динамічний розсилковий спам.

Оптимізація алгоритмів виявлення спаму

1. Механізм нормалізації тексту – впроваджено алгоритм автоматичного очищення тексту перед аналізом: видалення спеціальних символів, об'єднання розірваних слів, заміна синонімів.

2. Перевірка посилань у реальному часі – додавання API-запитів до баз даних небезпечних сайтів (наприклад, Google Safe Browsing); розпізнавання скорочених посилань із їх розгортанням перед аналізом.

3. Адаптація до нових тактик розсилки – впроваджено систему відстеження частоти надсилання повідомлень, що дозволяє виявляти "повільний спам"; використання кластерного аналізу для визначення груп підозрілих акаунтів, які можуть працювати разом.

4. Обробка мультимедійного контенту – використання технологій OCR (оптичного розпізнавання тексту) для аналізу тексту в зображеннях; впровадження аналізу метаданих GIF-файлів та картинок, що містять рекламний або фішинговий контент.

Також для підвищення ефективності алгоритмів класифікації спаму було оновлено навчальну вибірку шляхом додавання нових прикладів спамових повідомлень, виявлених під час тестування та реальної експлуатації системи. Це дозволило покращити здатність алгоритму розпізнавати нетипові шаблони спаму, мінімізувати хибні спрацьовування та адаптувати систему до нових тактик зловмисників. Оновлення здійснювалося у кілька етапів:

- 1) Формування оновленого набору даних (див. Рис. 3.4):
 - Логи спамових повідомлень, зібрані під час тестування
 - Відгуки модераторів (позначені вручну спамові та легітимні повідомлення)
 - Відкриті бази даних шкідливих посилань (Google Safe Browsing, PhishTank)

- Спамові повідомлення з інших чат-платформ (анонімізовані набори даних із Discord, Telegram).

Типи доданих даних: текстові патерни (оновлення набору ключових фраз, синонімів, замаскованих слів); структурні патерни (розширення бази даних спамових шаблонів (повторювані рекламні конструкції, нестандартне форматування)); масові атаки (додано сценарії з динамічною розсилкою спаму та автоматизованими ботами); мультимедійний контент (додано анотації до зображень із текстом, що містить рекламні або шахрайські пропозиції).

Результат – оновлена вибірка містить більше 50000 унікальних записів, що значно покращує якість розпізнавання нових типів спаму.




Рис. 3.4 Оновлення навчальної вибірки

2) Використання алгоритмів машинного навчання. Для покращення ефективності роботи було використано моделі машинного навчання (ML), які адаптуються до змінних умов.

- Моделі класифікації тексту: Naïve Bayes – швидкий аналіз текстових повідомлень, визначення спаму за ймовірностями; LSTM (Long Short-Term Memory) – використання нейромереж для розпізнавання складних контекстних зв'язків у повідомленнях
- Аналіз поведінкових характеристик: Random Forest + K-Means – комбінація алгоритмів для визначення груп ботів, що працюють у зв'язці; Recurrent Neural Networks (RNN) – виявлення аномальної активності користувачів (масова розсилка, часті повторення однакових повідомлень)
- Розпізнавання зображень та мультимедіа: використання OCR (Optical Character Recognition) для аналізу тексту в зображеннях; нейронні мережі для виявлення рекламного контенту у GIF-анімаціях та мемах.

Результат – після навчання на оновлених даних точність класифікації зросла з 96,3% до 98,1%, а рівень хибнопозитивних спрацьовувань знизився до 0,5%.

3) Перевірка ефективності оновленої системи.

Порівняльний аналіз до та після оновлення:

- Виявлення замаскованого тексту покращилося на 4,5%
- Розпізнавання скорочених URL стало точнішим на 3,2%
- Визначення масового спаму стало швидшим на 17% через оптимізацію алгоритмів [36, с. 86-90].

Тестування після оновлення – система повторно пройшла тестові сценарії, що підтвердило значне зниження рівня хибних спрацьовувань та підвищення адаптивності алгоритмів. Таким чином, оновлення навчальних даних дозволило покращити здатність системи до адаптації та виявлення нових тактик спамерів.

Після оновлення навчальних даних наступним етапом удосконалення системи стало оптимізація алгоритмів виявлення спаму для підвищення їх ефективності, швидкості роботи та адаптивності до нових методів обходу. Основні напрями оптимізації включали впровадження додаткових ознак для

аналізу спаму, використання більш ефективних моделей машинного навчання та покращення механізмів обробки повідомлень у реальному часі.

Один із важливих етапів покращення алгоритмів – розширення набору ознак, які використовуються для класифікації спамових повідомлень. Основні нові ознаки включали: аналіз частоти використання слів (впроваджено TF-IDF (Term Frequency – Inverse Document Frequency) для визначення найчастіше використовуваних слів у спамових повідомленнях; додано механізм визначення "спамового словника", що включає слова, які часто з'являються у рекламних та фішингових текстах (наприклад, «*виграш*», «*знижка*», «*безкоштовно*»)); виявлення нетипових символів та форматування (використання Unicode-нормалізації для аналізу альтернативного написання слів («*free*», «*в!гр@ш*»)); перевірка аномального використання пробілів і знаків пунктуації, що характерно для замаскованого спаму («*бе зкош товно*»)); аналіз поведінкових патернів (виявлення повторюваних повідомлень від одного або кількох користувачів: аналіз швидкості відправки повідомлень: якщо користувач надсилає багато повідомлень за короткий проміжок часу, це може свідчити про спам-бота).

Другим етапом було використання більш ефективних моделей. Для підвищення ефективності класифікації було здійснено перехід від евристичних методів (правил, базованих на ключових словах) до глибоких нейронних мереж, які дозволяють більш точно аналізувати контекст повідомлень. Перехід до глибокого навчання ознаменувався використанням BERT (Bidirectional Encoder Representations from Transformers) для аналізу семантики тексту – це дозволило зменшити кількість хибнопозитивних спрацьовувань на 2,1%, а також впровадженням LSTM (Long Short-Term Memory) для виявлення шаблонів у спамових повідомленнях. Як результат, система стала швидшою та точнішою, а кількість неправильно заблокованих повідомлень знизилася до 0,4%.

Третій етап – покращення механізмів обробки повідомлень у режимі реального часу. Цей етап супроводжувався оптимізацією продуктивності –

запроваджено асинхронну обробку повідомлень, що дозволяє аналізувати повідомлення паралельно у багатопотоковому режимі, використанням Edge AI (локальна обробка даних) для швидшого аналізу без передачі великих обсягів трафіку на сервер. Як результат, час аналізу повідомлення скорочено до 0,01-0,08 с; система може обробляти до 100000 повідомлень за хвилину, що забезпечує її ефективну роботу навіть у чатах з великою активністю. Таким чином, оптимізація алгоритмів дозволила значно покращити ефективність виявлення спаму, продуктивність та адаптивність системи. Основними досягненнями було виділено те, що виявлення спаму стало точнішим завдяки впровадженню додаткових ознак аналізу; перехід до глибокого навчання знизив кількість хибнопозитивних спрацьовувань; оптимізовано обробку в реальному часі, що дозволяє аналізувати до 100 000 повідомлень за хвилину [37, с. 231-236].

Попри високу ефективність виявлення спаму, тестування показало, що деякі звичайні повідомлення можуть помилково блокуватися алгоритмом. Це явище, відоме як хибнопозитивні спрацьовування, виникає через надто суворі правила фільтрації, некоректну інтерпретацію контексту або нетипові варіанти написання слів. Для мінімізації таких помилок було впроваджено кілька важливих удосконалень, спрямованих на підвищення точності алгоритмів та зниження рівня хибнопозитивних блокувань.

Покращення контекстного аналізу повідомлень

Проблема: раніше алгоритм міг блокувати повідомлення, якщо вони містили ключові слова, пов'язані зі спамом, навіть якщо вони використовувалися у безпечному контексті (наприклад, "Безкоштовний вебінар для студентів" могло бути заблоковане через слово «безкоштовний»).

Рішення:

- впроваджено глибокий семантичний аналіз на основі моделі BERT, що дозволяє розрізняти значення слова залежно від контексту;

- використання відносного аналізу фраз, що враховує не лише ключові слова, а й оточуючий текст;
- підключення модуля нейролінгвістичної оцінки для визначення, чи є повідомлення типовою рекламною пропозицією або інформаційним повідомленням.

Результат – кількість випадків блокування не-спам повідомлень через поодинокі ключові слова знизилася на 47%.

Використання адаптивних рівнів фільтрації

Проблема: однаковий рівень фільтрації застосовувався до всіх груп та чатів, що призводило до надмірної чутливості у професійних та тематичних спільнотах, де часто використовуються технічні терміни або комерційні слова.

Рішення:

- додано гнучку систему налаштувань, яка дозволяє адміністраторам обирати рівень фільтрації (низький, середній, високий);
- автоматична адаптація алгоритму до конкретної спільноти – якщо в чаті багато хибнопозитивних блокувань, система зменшує вартість правил; якщо виявляється багато пропущених спам-повідомлень, рівень фільтрації автоматично посилюється.

Результат – рівень задоволеності користувачів підвищився, оскільки система стала гнучкішою до особливостей конкретних чатів.

Додавання "білого списку" користувачів та перевірки репутації (див.

Рис. 3.5).

Проблема: алгоритм міг блокувати повідомлення навіть від надійних користувачів, які активно брали участь у дискусіях.

Рішення:

- впроваджено систему репутації, яка оцінює активність користувача – якщо користувач давно у спільноті, часто бере участь у дискусіях і не отримував попереджень, його повідомлення мають нижчий пріоритет для перевірки;

- адміністратори можуть вручну додавати учасників до "білого списку", щоб уникнути випадкових блокувань.

Результат – зменшено блокування реальних користувачів на 60% без втрати фільтрації спаму.




Рис. 3.5 Алгоритм перевірки з урахуванням репутації та білого списку

Покращення механізму оскарження блокувань

Проблема: раніше користувачі не могли оскаржити блокування своїх повідомлень, що викликало незадоволення серед активних учасників чату.

Рішення:

- додано можливість для користувачів оскаржити блокування повідомлення через спеціальну команду;
- повідомлення, які оскаржуються кількома користувачами, автоматично переглядаються адміністраторами або повторно перевіряються алгоритмом;

- якщо повідомлення відновлено, алгоритм оновлює модель навчання для запобігання подібним помилкам у майбутньому.

Результат – зменшено кількість скарг від користувачів на несправедливе блокування; алгоритм став самонавчатися на реальних помилках, що покращило його точність.

Перевірка на основі довгострокових взаємозв'язків (див. Рис. 3.6).

Проблема: окремі повідомлення можуть здаватися спамом, але у контексті попередніх повідомлень вони є частиною нормальної розмови.

Рішення:

- Впроваджено аналіз історії повідомлень користувачів – якщо користувач регулярно бере участь у діалогах, система з меншою ймовірністю помилково позначить його повідомлення як спам; якщо повідомлення схоже на спам, але попередні повідомлення були нормальними, система спочатку дає попередження замість блокування.

Результат – система краще розуміє поведінку користувачів, що допомагає уникнути випадкових блокувань.




Рис. 3.6 Алгоритм класифікації з урахуванням історії повідомлень

Тобто, можна підсумувати, що завдяки реалізованим покращенням рівень хибнопозитивних спрацьовувань знизився до 0,3%, що є оптимальним показником для систем виявлення спаму [38, с. 53-58].

3.3 Рекомендації з інтеграції системи у різні платформи

Розроблена система виявлення та запобігання поширенню спаму повинна бути масштабованою та сумісною з різними платформами для забезпечення її ефективного використання у публічних чатах. Оскільки різні месенджери та комунікаційні сервіси мають свої особливості API та політики модерації, інтеграція системи потребує адаптації до специфіки кожної платформи. Основними платформами, на які можна інтегрувати систему, є Telegram, Discord, WhatsApp та Slack. Вони мають відкриті API для автоматизації процесів модерації, що дозволяє нашому програмному забезпеченню взаємодіяти з повідомленнями у чатах, аналізувати їх на предмет спаму та вживати відповідних заходів.

1. Telegram має Telegram Bot API, який дозволяє створювати ботів для модерації чату. Бот може автоматично аналізувати повідомлення, видаляти спам та банити користувачів за певними критеріями. Telegram підтримує онлайн-запити, що дає змогу модераторам швидко перевіряти підозрілі повідомлення. Є можливість підключення webhook-ів для миттєвої обробки даних.

Рекомендації з інтеграції: використання Telegram API для автоматичного аналізу повідомлень у режимі реального часу; розширення функціоналу бота для розпізнавання фішингових посилань та динамічних патернів спаму; додавання можливості налаштування рівня модерації через команду /settings.

2. Discord має Discord Bot API, який дозволяє ботам модерувати текстові канали. Підтримка слухачів подій (event listeners), що дає змогу ботам миттєво реагувати на нові повідомлення. Доступ до історії повідомлень для аналізу шаблонів поведінки користувачів. Використання вебхуків для швидкого сповіщення адміністрації про спам-атаки.

Рекомендації з інтеграції: використання фільтрів на основі поведінкового аналізу для блокування масових атак ботів; запровадження рівнів довіри для постійних користувачів, щоб зменшити кількість хибних блокувань;

автоматичне надсилення адміністраторам звітів про спам за допомогою вбудованих логів.

3. WhatsApp надає WhatsApp Business API, який дозволяє ботам працювати в чатах бізнес-груп. Бот може аналізувати текстові повідомлення та посилання на предмет спаму та фішингу. API дозволяє автоматично надсилати попередження користувачам або видаляти підозрілі повідомлення.

Рекомендації з інтеграції: використання AI-аналізу тексту та посилань для швидкої перевірки спаму; створення спеціальних blacklist-правил, які автоматично блокують рекламні або фішингові повідомлення; додавання функції автоматичного видалення спаму та надсилення користувачам пояснень через бот.

4. Slack API дозволяє створювати ботів, які можуть аналізувати повідомлення та модерувати канали. Також є можливість створювати Slack Apps для інтеграції з іншими системами кібербезпеки. Бот може надсилати адміністраторам сповіщення про виявлений спам та зберігати звіти у зовнішніх системах.

Рекомендації з інтеграції: використання реакцій бота для автоматичної

модерації повідомлень (наприклад, бот додає емодзі

3.4 Перспективи розвитку програмного забезпечення та його вплив на інформаційну безпеку

Розвиток технологій та поширення цифрової комунікації спричинили еволюцію методів розповсюдження спаму, що вимагає постійного вдосконалення антиспам-систем. Сучасні кіберзлочинці використовують штучний інтелект, автоматизовані боти та складні фішингові схеми, що дозволяє їм адаптуватися до стандартних методів фільтрації. У зв'язку з цим виникає необхідність впровадження інтелектуальних систем захисту, які здатні аналізувати контекст повідомлень, розпізнавати приховані загрози та навчатися в реальному часі. Далі розглянемо основні тренди у сфері кібербезпеки, які впливають на розвиток антиспам-систем, та їхнє значення для майбутнього удосконалення нашого програмного забезпечення.

1. Зростання використання штучного інтелекту для поширення спаму

Зі зростанням використання генеративних моделей штучного інтелекту (наприклад, GPT) спамери почали створювати правдоподібні та унікальні повідомлення, які не містять очевидних спамових ознак, що значно ускладнює їх виявлення традиційними методами. Для боротьби з такими загрозами необхідно впровадити семантичний аналіз тексту, що дозволить розпізнавати підозрілі патерни в повідомленнях, а також використовувати глибоке навчання (Deep Learning), яке адаптуватиме алгоритми до нових способів створення спаму. Додатково інтеграція бази даних генеративних шаблонів спаму дозволить системі швидше знаходити нові типи автоматично створених повідомлень та ефективно блокувати їх. Очікуваний ефект полягає у здатності системи виявляти навіть складні AI-генеровані повідомлення, які виглядають природно, але приховують потенційні загрози.

2. Використання мультимедійного контенту для поширення спаму

Оскільки традиційні антиспам-системи зосереджені переважно на аналізі текстових повідомлень, спамери все частіше використовують зображення, GIF-анімацію та відео для поширення прихованої реклами або фішингових атак, що робить їх важкодоступними для класичних методів фільтрації. Для протидії цій загрозі необхідно інтегрувати OCR (Optical Character Recognition) для автоматичного розпізнавання тексту в зображеннях, що дозволить аналізувати рекламні або шахрайські повідомлення, заховані у візуальному контенті. Додатково використання нейронних мереж сприятиме ідентифікації небезпечного або комерційного контенту, навіть якщо він не містить тексту, а аналіз метаданих зображень та відео дозволить визначати їхнє джерело та виявляти підозрілу активність. У результаті система стане значно ефективнішою у боротьбі зі спамом у мультимедійному форматі, включаючи зображення, відео та QR-коди, які можуть містити шкідливі посилання або інші загрози.

3. Підвищення рівня соціальної інженерії у спам-атаках

Сучасні спам-атаки дедалі частіше використовують методи соціальної інженерії, маніпулюючи емоціями користувачів через фальшиві повідомлення про виграші, загрози безпеці акаунтів або екстрені фінансові запити, що значно ускладнює їх автоматичне виявлення. Для ефективної протидії таким атакам необхідно впровадити емоційний аналіз тексту (Sentiment Analysis), який дозволить розпізнавати маніпулятивний характер повідомлень, особливо тих, що викликають страх, терміновість або надмірну довіру. Додатково використання поведінкового аналізу допоможе визначати підозрілу активність, наприклад, коли користувач, який раніше не надсилав подібних повідомлень, раптово починає розповсюджувати потенційно шахрайський контент. Також буде реалізовано механізм автоматичного попередження користувачів про можливі ризики при взаємодії з підозрілими повідомленнями або посиланнями. У результаті система навчиться ідентифікувати та блокувати психологічно

маніпулятивні спам-атаки, які широко використовуються у фішингових схемах і є загрозою для безпеки цифрових спільнот.

4. Спам у Web3 та криптовалютних середовищах

З розвитком Web3 та децентралізованих платформ з'явився новий тип спаму, пов'язаний із криптошахрайством, фальшивими аірдропами та шахрайськими смарт-контрактами, причому багато таких повідомлень маскуються під легітимні оголошення, що ускладнює їх виявлення. Для боротьби з цією загрозою необхідно впровадити аналіз блокчейн-транзакцій, який дозволить перевіряти підозрілі посилання та виявляти небезпечні гаманці або контракти. Додатково використання бази даних підозрілих криптовалютних адрес, що вже були зафіксовані у шахрайських схемах, допоможе оперативно блокувати потенційно небезпечні повідомлення. Крім того, впровадження механізму машинного навчання для виявлення нових схем криптошахрайства дозволить аналізувати патерни повідомлень і розпізнавати нетипові фінансові запити, підроблені токени або маніпулятивні пропозиції. У результаті система зможе ефективно виявляти та блокувати шахрайські повідомлення у криптовалютних групах та Web3-проектах, запобігаючи фінансовим втратам користувачів та підвищуючи загальну безпеку децентралізованих екосистем [42].

Отже, можна сказати, що сучасні антиспам-системи повинні розвиватися відповідно до нових кібербезпекових викликів, оскільки спамери постійно вдосконалюють свої методи обходу фільтрів. Однією з ключових тенденцій є використання штучного інтелекту для створення складніших та реалістичних спамових повідомлень, що ускладнює їх виявлення традиційними методами. Крім того, спамери активно переходять до поширення мультимедійного контенту, зокрема зображень, відео та QR-кодів, які містять приховані загрози або фішингові посилання, що вимагає впровадження технологій оптичного розпізнавання тексту та аналізу метаданих. Окремим викликом є збільшення атак із використанням маніпулятивних психологічних прийомів, коли шахраї

створюють повідомлення, що викликають емоційну реакцію користувачів (термінові запити, страх втрати даних, "екстрені" фінансові операції). Також з розвитком криптовалютних технологій та Web3-платформ з'явилися нові види спаму, пов'язані із фальшивими аірдропами, шахрайськими смарт-контрактами та фінансовими махінаціями, що потребує використання механізмів аналізу блокчейн-транзакцій та баз даних підозрілих криптовалютних адрес. Таким чином, майбутнє антиспам-систем залежить від впровадження адаптивних алгоритмів, здатних до самонавчання, аналізу контексту та комплексної взаємодії з іншими системами кібербезпеки, що дозволить забезпечити ефективний захист цифрових спільнот від новітніх кіберзагроз.

Для ефективної боротьби зі спамом у майбутньому необхідно впроваджувати глибокі нейронні мережі, здатні аналізувати контекст повідомлень та виявляти приховані загрози навіть у випадках складно замаскованого спаму. Окрім цього, слід розширити аналіз мультимедійного контенту, включаючи зображення, відео та GIF-файли, що можуть містити приховану рекламу або фішингові посилання. Важливим напрямом є поведінковий аналіз користувачів, який дозволить виявляти шахрайські схеми та бот-мережі ще до початку масових атак. Також із поширенням криптовалют та децентралізованих платформ необхідно інтегрувати антиспам-модулі у криптовалютні проекти, що допоможе запобігати фінансовим шахрайствам, шахрайським аірдропам та підозрілим блокчейн-транзакціям. Комплексне поєднання цих підходів дозволить створити більш адаптивну та інтелектуальну систему захисту, яка буде здатна оперативно реагувати на нові методи обходу фільтрів та підтримувати безпечне цифрове середовище [43, с. 241-245].

Сучасні методи поширення спаму постійно змінюються, тому система виявлення загроз має бути здатною до самонавчання та адаптації. Використання штучного інтелекту дозволяє автоматизувати процес аналізу спаму, виявляти нові патерни загроз та підвищувати ефективність модерації.

1. Автоматизація загроз за допомогою штучного інтелекту

Традиційні антиспам-алгоритми базуються на фіксованих правилах, що обмежує їхню здатність адаптуватися до нових видів спаму, тому ефективна боротьба з кіберзагрозами потребує автоматизації аналізу за допомогою штучного інтелекту. Впровадження нейромережових моделей, які навчаються на реальних спам-атаках і самостійно коригують свої фільтри, дозволить значно підвищити точність виявлення шкідливих повідомлень. Додатково глибокий аналіз аномалій сприятиме виявленню підозрілої активності у чатах, навіть якщо спам не відповідає жодним відомим шаблонам. Завдяки автоматичній класифікації загроз та оперативному оновленню чорних списків система зможе ефективно реагувати на нові методи поширення спаму. Як результат, антиспам-алгоритми отримають можливість самостійно адаптуватися до змін у тактиці злоумисників, зменшуючи потребу в ручному оновленні та підвищуючи загальну ефективність фільтрації.

2. Додавання можливостей розпізнавання фішингових атак

Фішингові атаки часто маскуються під звичайні повідомлення, містять оманливі посилання або запити на особисту інформацію, що робить їх особливо небезпечними для користувачів. Для ефективного виявлення таких загроз необхідно інтегрувати Google Safe Browsing API, що дозволить перевіряти підозрілі сайти в реальному часі та миттєво блокувати доступ до шкідливих ресурсів. Додатково система буде аналізувати текст повідомлень на типові ознаки фішингу, такі як термінові запити змінити пароль або надати конфіденційні дані. Використання нейромереж для розпізнавання шахрайських шаблонів допоможе адаптувати систему до нових видів атак, які змінюють формулювання, але зберігають загальну суть обману. Як результат, система зможе автоматично виявляти та блокувати фішингові повідомлення, не допускаючи їхнього поширення в чатах та захищаючи користувачів від потенційного викрадення даних.

3. Впровадження аналізу поведінки користувачів

Спам-боти та шахрайські акаунти дедалі частіше маскують свою активність, уникаючи традиційних методів блокування, що потребує впровадження аналізу поведінки користувачів для ефективного виявлення загроз. Система зможе визначати патерни поведінки спамерів, такі як масові розсилки, часті зміни акаунтів або аномальна активність у чатах, що дасть змогу ідентифікувати потенційно небезпечних користувачів ще до початку атак. Використання алгоритмів машинного навчання дозволить автоматично класифікувати акаунти на "довірені" та "підозрілі", що мінімізує кількість хибних спрацьовувань і підвищить ефективність фільтрації. Додатково система зможе автоматично вводити обмеження для нових акаунтів із підозрілою активністю, наприклад, тимчасове блокування або обмеження кількості повідомлень. Як результат, система зможе виявляти та нейтралізувати спамерів до початку масштабних атак, забезпечуючи безпечне та комфортне цифрове середовище.

4. Інтеграція з іншими системами кібербезпеки

Окремі антиспам-системи мають обмежену ефективність, якщо працюють ізольовано, тому для посилення захисту необхідно забезпечити інтеграцію з іншими системами кібербезпеки. Впровадження зв'язку з антивірусними платформами на кшталт VirusTotal та Kaspersky Threat Intelligence дозволить автоматично перевіряти шкідливі посилання та блокувати їх ще до переходу користувачів. Додатково використання централізованих баз шахрайських акаунтів допоможе миттєво виявляти та блокувати відомих зловмисників, запобігаючи повторним атакам. Також важливим напрямом є взаємодія з мережами SOC (Security Operations Center), які забезпечують доступ до найактуальніших даних про нові загрози та методи атак, що дозволить системі швидко адаптуватися до змін у сфері кіберзахисту. Як результат, система стане частиною глобальної інфраструктури кібербезпеки, що значно підвищить її ефективність у боротьбі зі спамом, фішингом та іншими видами шахрайства, створюючи надійне та безпечне цифрове середовище [44].

Розробка та впровадження антиспам-системи потребує не лише технічної ефективності, а й дотримання юридичних та етичних норм. Оскільки система працює з текстовими повідомленнями користувачів, важливо забезпечити конфіденційність даних та відповідність міжнародним стандартам безпеки. Крім того, у довгостроковій перспективі подібні системи відіграють ключову роль у захисті цифрових спільнот від маніпуляцій, дезінформації та кіберзагроз, створюючи безпечніше інформаційне середовище.

1) Юридичні та етичні аспекти роботи системи відіграють ключову роль у забезпеченні конфіденційності даних користувачів та відповідності міжнародним стандартам безпеки. Система не зберігає персональні дані, а лише аналізує вміст повідомлень у режимі реального часу, забезпечуючи анонімізацію всіх перевірених даних без передачі третім сторонам. Для захисту комунікацій використовується шифрування TLS, що гарантує безпечний обмін інформацією між сервером і платформами. Відповідність GDPR (General Data Protection Regulation) та ISO/IEC 27001 підтверджує дотримання принципів обробки даних, а механізм запиту на видалення інформації дозволяє адміністраторам чатів переглядати логування модерації та видаляти дані за необхідності. Використання підходу "Privacy by Design" забезпечує мінімізацію обробки зайвої інформації, що значно знижує ризики витоку даних. Як результат, система працює законно, етично та без порушення прав користувачів, гарантуючи безпеку та прозорість процесів модерації.

2) Довгостроковий вплив системи на інформаційну безпеку полягає не лише у боротьбі зі спамом, а й у захисті цифрових спільнот від маніпуляцій, дезінформації та кіберзагроз. Вона здатна ідентифікувати бот-мережі, які поширюють фейкові новини та пропаганду, а також аналізувати текст на наявність емоційно маніпулятивних повідомлень, що сприяють паніці чи навмисному розпалюванню конфліктів. Крім того, антиспам-алгоритми допомагають запобігати фішинговим атакам і шахрайству, підвищуючи загальний рівень безпеки користувачів. Спільноти, які використовують систему,

стають менш вразливими до атак соціальної інженерії та масових дезінформаційних кампаній, що забезпечує їхню стійкість перед новими загрозами. Таким чином, система стає не просто інструментом боротьби зі спамом, а повноцінним елементом інформаційної безпеки, сприяючи створенню чистого та безпечного цифрового середовища [45, с. 93-95].

ВИСНОВКИ

1. У роботі проведено детальний аналіз спаму, його основних видів та методів розповсюдження, що дозволило визначити основні загрози інформаційній безпеці, спричинені масовими розсилками небажаних повідомлень.

2. Оцінено сучасні алгоритми та методи виявлення спаму, серед яких фільтрація за правилами, байєсівські класифікатори та методи машинного навчання, що є найбільш ефективними у динамічному середовищі.

3. Досліджено можливості використання технологій машинного навчання, які дозволяють значно підвищити точність детекції спаму та адаптувати систему до нових загроз без ручного оновлення правил.

4. На основі аналізу було розроблено програмне забезпечення для виявлення та запобігання спаму, яке використовує гібридний підхід: поєднання алгоритмів машинного навчання, семантичного аналізу тексту та поведінкового моніторингу користувачів.

5. Проведено тестування системи, яке показало її високу ефективність у виявленні різних типів спаму, включаючи традиційний текстовий спам, фішингові атаки та шкідливі посилання, при цьому рівень хибнопозитивних спрацювань вдалося мінімізувати.

6. Удосконалення алгоритмів на основі оновлених навчальних даних дозволило покращити точність класифікації спаму, знизити рівень хибних блокувань та підвищити швидкість аналізу повідомлень.

7. Розроблено рекомендації щодо інтеграції системи у популярні платформи, такі як Telegram, Discord, WhatsApp і Slack, що забезпечить її гнучкість та адаптивність до різних цифрових середовищ.

8. Запропоновано стратегії автоматизації аналізу загроз із використанням штучного інтелекту, що дозволить системі самостійно навчатися на основі нових атак і оперативно оновлювати методи захисту.

9. Визначено ключові перспективи розвитку, включаючи розширення можливостей виявлення мультимедійного спаму, аналіз поведінкових факторів користувачів та інтеграцію з глобальними системами кібербезпеки.

10. Розглянуто юридичні та етичні аспекти роботи системи, зокрема дотримання стандартів захисту персональних даних (GDPR, ISO/IEC 27001), що забезпечує безпечне та етичне використання технологій виявлення спаму.

11. Доведено, що запропоноване рішення є не лише ефективним інструментом для боротьби зі спамом, а й повноцінним елементом інформаційної безпеки, здатним захищати цифрові спільноти від маніпуляцій, фішингових атак та інших кіберзагроз.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Аракелова А. О., Єсіна О. Г. Спам: історія виникнення, методи боротьби. Інформатика та інформаційні технології: студентська наукова конференція. Одеський національний економічний університет, 2015. С. 99-102. URL: <https://core.ac.uk/download/pdf/147039118.pdf> (дата звернення: 21.01.2025).
2. Братасюк, К. В. (2015). Програмні засоби боротьби зі СПАМ. 79 с. URL: https://report.kpi.ua/sites/default/files/2b_3.pdf (дата звернення: 21.01.2025).
3. Саєнко М. І., Савела Є. А., Тополянський Ю. Ю. Міжнародний досвід протидії кіберзлочинності та кібершахрайству. *Науковий вісник Ужгородського національного університету*, 2021. Вип. 64. С. 386-391. URL: <https://visnyk-juris-uzhnu.com/wp-content/uploads/2021/08/74.pdf> (дата звернення: 21.01.2025).
4. Поняття СПАМ-а та методи протидії йому. (2024). URL: <https://tuthost.ua/uk/blog/ponyattya-spam-a-ta-metodi-protidiyi-jomu/> (дата звернення: 21.01.2025).
5. Що таке СПАМ і як з ним боротися? (2020). Хостинг Україна. URL: <https://www.ukraine.com.ua/blog/marketing/hto-takoe-spam-i-kak-s-nim-borotsya.html> (дата звернення: 21.01.2025).
6. Прокопенко Д. Д. (2024). Алгоритми виявлення спаму на основі машинного навчання. 107 с. URL: <http://dspace.wunu.edu.ua/bitstream/316497/53397/1/%D0%9A%D0%A0%20%D0%9F%D1%80%D0%BE%D0%BA%D0%BE%D0%BF%D0%B5%D0%BD%D0%BA%D0%BE.pdf> (дата звернення: 21.01.2025).
7. Любченко Н. Ю., Подорожняк А. О., Олійник В. М. (2020). Методи виявлення спаму у соціальних мережах. *Сучасні напрями розвитку інформаційно-комунікаційних технологій та засобів управління. Національний технічний університет «ХПІ»*. Харків, Україна. С. 92. URL: <https://repository.kpi.kharkov.ua/server/api/core/bitstreams/23dea30a-0b55-425c-a78e-a739d8800fae/content> (дата звернення: 21.01.2025).

8. Комісаренко, В. (2020). Як працює Word2Vec: нейромережі для NLP. URL: <https://medium.com/@bigdataschool/%D0%BA%D0%B0%D0%BA-%D1%80%D0%B0%D0%B1%D0%BE%D1%82%D0%B0%D0%B5%D1%82-word2vec-%D0%BD%D0%B5%D0%B9%D1%80%D0%BE%D1%81%D0%B5%D1%82%D0%B8-%D0%B4%D0%BB%D1%8F-nlp-1609812f80e5> (дата звернення: 21.01.2025).

9. Pennington, J., Socher, R., Manning, D. (2014). Glove: Global Vectors for Word Representation. Conference: Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). С. 1-12. URL: <https://nlp.stanford.edu/pubs/glove.pdf> (date of access: 21.01.2025).

10. Сьомченко Д. В. Використання машинного навчання для виявлення спаму: дипломна робота ... бакалавра: 125 Кібербезпека. Київ, 2023. 66 с. URL: <https://ela.kpi.ua/items/e5de71c0-5711-482c-b536-052d60ec4ff7> (дата звернення: 21.01.2025).

11. Праздніков В. О., Сугоняк І. І. Моделі та методи машинного навчання для розпізнавання фейкового контенту. *Технічна інженерія*, 2023. Вип. 2(92). С. 131-136. URL: https://www.researchgate.net/publication/376878645_Modeli_ta_metodi_masinnogo_navcanna_dla_rozpiznavanna_fejkovogo_kontentu (дата звернення: 21.01.2025).

12. Keskin, S. Sevli, O. (2024). Machine Learning Based Classification for Spam Detection. *Sakarya University Journal of Science*. Vol. 28(2). P. 270-282. URL: https://www.researchgate.net/publication/380000625_Machine_Learning_Based_Classification_for_Spam_Detection (date of access: 21.01.2025).

13. Babac, M., Granosa, L., Borotic, G., Kovacevic, G. (2024). Effective Spam Detection with Machine Learning. *Croatian Regional Development Journal*. Vol. 4(2). P. 43-64. URL:

https://www.researchgate.net/publication/378516808_Effective_Spam_Detection_with_Machine_Learning (date of access: 21.01.2025).

14. Ткач М. Ю., Семендяй С. М. Інформаційна безпека держави: метод. вказівки до практичних занять для здобувачів першого (бакалаврського) рівня вищої освіти спеціальності 262 – Правоохоронна діяльність. Чернігів: НУ «Чернігівська політехніка», 2020. 112 с. URL: <https://ir.stu.cn.ua/bitstream/handle/123456789/21177/%D0%86%D0%BD%D1%84%D0%BE%D1%80%D0%BC%D0%B0%D1%86%D1%96%D0%B9%D0%BD%D0%B0%20%D0%B1%D0%B5%D0%B7%D0%BF%D0%B5%D0%BA%D0%B0%20%D0%B4%D0%B5%D1%80%D0%B6%D0%B0%D0%B2%D0%B8..pdf?sequence=1&isAllowed=y> (дата звернення: 21.01.2025).

15. Alazab, M., Broadhurst, R. (2017). An Analysis of the Nature of Spam as Cybercrime. *Cyber Physical Security*. P. 9-13. URL: https://www.researchgate.net/publication/306035643_An_Analysis_of_the_Nature_of_Spam_as_Cybercrime (date of access: 21.01.2025).

16. Мехед Д. Б., Ткач Ю. М., Базилевич В. М. та ін. Аналіз загроз інформаційної безпеки в мережах стандарту IEEE 802.11. *Захист інформації*, 2015. Т. 17, № 4. С. 285-291. URL: http://www.irbis-nbuv.gov.ua/cgi-bin/irbis_nbuv/cgiirbis_64.exe?I21DBN=LINK&P21DBN=UJRN&Z21ID=&S21REF=10&S21CNR=20&S21STN=1&S21FMT=ASP_meta&C21COM=S&2_S21P03=FILA=&2_S21STR=Zi_2015_17_4_5 (дата звернення: 21.01.2025).

17. Aslan, O., Aktug, S., Ozkan, M., Yilmaz, A. (2023). A Comprehensive Review of Cyber Security Vulnerabilities, Threats, Attacks, and Solutions. *Electronics*. Vol. 12(6). P. 1-42. URL: https://www.researchgate.net/publication/369186216_A_Comprehensive_Review_of_Cyber_Security_Vulnerabilities_Threats_Attacks_and_Solutions (date of access: 21.01.2025).

18. Li, Y., Liu, Q. (2021). A comprehensive review study of cyber-attacks and cyber security. Emerging trends and recent developments. *Energy Reports*. Vol. 7. P. 8176-8186. URL: <https://www.sciencedirect.com/science/article/pii/S2352484721007289> (date of access: 21.01.2025).

19. Demirel, S., Das, R. (2018). Software requirement analysis: Research challenges and technical approaches. Conference: 2018 6th International Symposium on Digital Forensic and Security (ISDFS). URL: https://www.researchgate.net/publication/324997752_Software_requirement_analysis_Research_challenges_and_technical_approaches (date of access: 18.02.2025).

20. Козак О. Л. Опорний конспект лекцій з курсу «Аналіз вимог до програмного забезпечення для студентів напрямку підготовки». Програмна інженерія. Тернопіль, 2011. 56 с. URL: http://dspace.wunu.edu.ua/retrieve/14135/FCIT_kKN_sPZS_dAVPZ_%20LEC.pdf (дата звернення: 18.02.2025).

21. Войчур Ю., Медзатий Д. (2024). Метод аналізу вимог до програмного забезпечення на предмет пошуку значень атрибутів якості. *Measuring and computing devices in technological processes*. Вип. 1. С. 146-151. URL: <https://vottp.khmnu.edu.ua/index.php/vottp/article/view/260> (дата звернення: 18.02.2025).

22. McGuire, J. (2024). Requirements Analysis for Software Development (Guide). Software Development. URL: <https://www.pulsion.co.uk/blog/requirements-analysis-for-software-development/> (date of access: 18.02.2025).

23. Божуха Л. М. Конспект лекцій з дисципліни «Аналіз вимог до програмного забезпечення» для студентів напряму підготовки 6.050103 «Програмна інженерія». Дніпродзержинськ, ДДТУ: 2015. 94 с. URL:

<https://files.znu.edu.ua/files/Bibliobooks/Inshi70/0051124.pdf> (дата звернення: 18.02.2025).

24. Гузенко С. (2023). Архітектура програмного забезпечення: все що треба знати. URL: <https://wezom.com.ua/ua/blog/arhitektura-programmnogo-obespecheniya> (дата звернення: 18.02.2025).

25. Глибовець А. М. (2021). Розробка принципів та архітектури підсистеми для розподіленого навантажувального тестування та аналізу результатів у системі CI/CD. URL: <https://ekmair.ukma.edu.ua/server/api/core/bitstreams/bb04abbf-7854-4663-a3c7-9ac6967dac70/content> (дата звернення: 18.02.2025).

26. 9 Best System Design Tools for Developers & Software Architecture (2025). URL: <https://snappify.com/blog/system-design-tools> (date of access: 18.02.2025).

27. Dharmadasa, R. (2025). Choosing the Right Software Architecture: A Guide to Selecting the Best Fit for Your Project. URL: <https://ravindusandaruwandh.medium.com/choosing-the-right-software-architecture-a-guide-to-selecting-the-best-fit-for-your-project-ecdda7812fb1> (date of access: 18.02.2025).

28. Аналіз і виявлення спам повідомлень у соціальних мережах. (2020). URL: https://konkurs.khmn.edu.ua/wp-content/uploads/sites/6/2020/06/DP2_AntiSpam.pdf (дата звернення: 18.02.2025).

29. Jadama, A., Touray, M., Jobarteh, B. (2024). Spam detection project. URL: https://www.researchgate.net/publication/381773453_SPAM_DETECTION_PROJECT (date of access: 18.02.2025).

30. Hamid, N., Mohamed, M. (2023). Spam detection model using TensorFlow and deep learning algorithm. *Malaysian Journal of Computing and Applied Mathematics*. Vol. 6(2). P. 11-21. URL:

https://www.researchgate.net/publication/375120093_SPAM_DETECTION_MODE_L_USING_TENSORFLOW_AND_DEEP_LEARNING_ALGORITHM (date of access: 18.02.2025).

31. Кешування даних. (2020). URL: https://e-tk.lntu.edu.ua/pluginfile.php/25327/mod_resource/content/1/4.3.pdf (дата звернення: 18.02.2025).

32. Данильченко А. О. (2021). Оцінка ефективності тестування програмного забезпечення. URL: <https://conf.ztu.edu.ua/wp-content/uploads/2017/11/19.pdf> (дата звернення: 13.03.2025).

33. Тестування програмного забезпечення: типи, види та застосування. (2023). URL: <https://foxminded.ua/testuvannia-prohramnoho-zabezpechennia/> (дата звернення: 13.03.2025).

34. Засорнова І., Говорущенко Т., Войчур О. (2023). Аналіз інструментів тестування програмного забезпечення відповідно до рівнів тестування. *Комп'ютерні системи та інформаційні технології*. URL: https://www.researchgate.net/publication/369782379_ANALIZ_INSTRUMENTIV_TESTUVANNA_PROGRAMNOGO_ZABEZPECENNA_VIDPOVIDNO_DO_RIV_NIV_TESTUVANNA (дата звернення: 13.03.2025).

35. Alqatawna, J., Faris, H. (2015). Improving Knowledge Based Spam Detection Methods: The Effect of Malicious Related Features in Imbalance Data Distribution. *International Journal of Communications Network and System Sciences*. Vol. 8(5). P. 118-129. URL: https://www.researchgate.net/publication/275647490_Improving_Knowledge_Based_Spam_Detection_Methods_The_Effect_of_Malicious_Related_Features_in_Imbalance_Data_Distribution (date of access: 13.03.2025).

36. Gomes, L., Fernando, D. O. Castro, Virg'ilio, A. (2020). Improving Spam Detection Based on Structural Similarity. P. 85-91. URL:

https://www.usenix.org/legacy/event/sruti05/tech/full_papers/gomes/gomes.pdf (date of access: 13.03.2025).

37. Бохонько О., Лисенко С. Методи виявлення кібератак соціальної інженерії. *Технічні науки. Вісник Хмельницького національного університету*, 2023. Вип. 2(5). С. 231-236. URL: [327-vknu-ts-2023-n5t2-231-236.pdf](#) (дата звернення: 13.03.2025).

38. Мокрицька О. В., Мочернюк Ю. М. Використання алгоритмів машинного навчання для автоматизації процесу модерації контенту в групових чатах месенджерів. *Науковий вісник НЛТУ України*, 2024. Вип. 34(7). С. 52-59. URL: [2669-Текст статті-387-1-10-20241202.pdf](#) (дата звернення: 13.03.2025).

39. Король А. М. Методи та інструментарії безперервної інтеграції та розгортання (CI/CD) для мобільних застосувань: дипломна робота ... бакалавра: 122 Комп'ютерні науки. Київ, 2021. 144 с. URL: <https://ela.kpi.ua/items/78811076-ea61-4b06-aad0-5be43a2ae134> (дата звернення: 13.03.2025).

40. Danielkievych, A. (2024). Mastering Software Integration: Key Purposes, Practical Methods, and Common Challenges. URL: <https://forbytes.com/blog/system-integration-methods-and-tips/> (date of access: 13.03.2025).

41. Орєхова А. І., Харченко В. В. Інтеграція систем і захист інформації як напрями удосконалення управління інформаційним середовищем підприємства в умовах діджиталізації. *Економіка та суспільство*, 2024. Вип. 64. URL: [4329-Текст статті-4237-1-10-20240816.pdf](#) (дата звернення: 13.03.2025).

42. Шульга В. І. Сучасні підходи до трактування поняття «Інформаційна безпека». *Ефективна економіка*, 2015. Вип. 4. URL: <http://www.economy.nayka.com.ua/?op=1&z=5514> (дата звернення: 13.03.2025).

43. Odera, D., Otieno, M., Ounza, J. (2023). Security Risks in the Software Development Lifecycle: A Review. *World Journal of Advanced Engineering*

Technology and Sciences. Vol. 8(2). P. 230–253. URL: https://www.researchgate.net/publication/369538781_Security_Risks_in_the_Software_Development_Lifecycle_A_Review (date of access: 13.03.2025).

44. Ekundayo, A. (2024). Software development and the security challenges developing countries. URL: https://www.researchgate.net/publication/387556856_SOFTWARE_DEVELOPMENT_AND_THE_SECURITY_CHALLENGES_IN_DEVELOPING_COUNTRIES (date of access: 13.03.2025).

45. Мазепа С. Забезпечення інформаційної безпеки в Україні: перспективи адміністративно-правового регулювання. *Актуальні проблеми правознавства*, 2024. Вип. 1(37). С. 92-97. URL: [1-2024-92-97.pdf](#) (дата звернення: 13.03.2025).

ДОДАТКИ**Додаток А.****Структура програмного забезпечення**