

Хмельницький національний університет  
Факультет інформаційних технологій  
Кафедра кібербезпеки

**КВАЛІФІКАЦІЙНА РОБОТА**

Бабаєвського Віталія Михайловича

на здобуття ступеня вищої освіти магістра

Метод протидії атакам на вебзастосунки з використанням інтелектуальної системи аналізу трафіку

Галузь знань 12 – Інформаційні технології

Спеціальність 125 – Кібербезпека та захист інформації

Освітня програма Кібербезпека та захист інформації

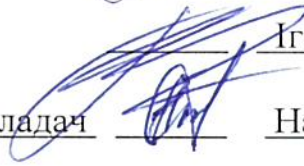
Шифр КРМКБЗІ. 240185.24.01.14 ПЗ

Виконав студент 2 курсу група КБЗІм-24-1



Віталій БАБАЄВСЬКИЙ

Керівник канд. техн. наук, доцент



Ігор МУЛЯР

Нормоконтролер д-р. філософії, ст. викладач

Наталія ПЕТЛЯК

До захисту допускаю:

Завідувач кафедри кібербезпеки



Юрій КЛЬОЦ

19 12 2025 р.

Хмельницький 2025

# ХМЕЛЬНИЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ

Факультет Інформаційних технологій  
Кафедра Кібербезпеки  
Рівень вищої освіти Магістр  
Галузь знань 12 – Інформаційні технології  
Спеціальність 125 – Кібербезпека та захист інформації  
Освітня програма Кібербезпека та захист інформації

ЗАТВЕРДЖУЮ

Завідувач кафедри кібербезпеки

Юрій КЛЬОЦ 

1 09 2025 р.

## ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

Бабаєвському Віталію Михайловичу

1 Тема роботи Метод протидії атакам на вебзастосунки з використанням інтелектуальної системи аналізу трафіку

Керівник к.т.н. доц. Муляр І.В.

Затверджено наказом ректора університету 25 08 2025 № 65

2 Строк подання студентом кваліфікаційної роботи на кафедру 01.12.2025

3 Вихідні дані до роботи Розробити метод протидії атакам на вебзастосунки шляхом застосування інтелектуальної системи аналізу вебтрафіку. Дослідити предметну область, що охоплює сучасні загрози інформаційної безпеки, методи атак на вебресурси, системи виявлення та запобігання вторгненням, а також підходи на основі штучного інтелекту для аналізу мережевих даних. На основі результатів дослідження спроектувати та реалізувати інтелектуальний модуль аналізу трафіку, який здатен виявляти шкідливу активність та забезпечувати протидію вебатакам. Провести тестування та оцінку ефективності розробленої системи.

4 Зміст пояснювальної записки (перелік питань, які потрібно розробити)

Вступ. Аналіз безпеки вебдодатків. Огляд типових атак. Традиційні методи захисту. Сучасні підходи на основі ШІ. Інструменти для аналізу вразливостей. Постановка задачі дослідження. Основи застосування ШІ для роботи з вебтрафіком. Методи виявлення аномалій і атак. Метод протидії атакам на вебзаступники. Архітектура системи. Алгоритми виявлення атак. Обробка даних і визначення аномалій. Оцінка результативності методу в реальних умовах. Тестування та валідація. Перспективи впровадження та розвитку. Висновки та рекомендації.

5 Перелік графічного матеріалу (із зазначенням обов'язкових креслень)

6 Консультанти розділів кваліфікаційної роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв

7 Дата видачі завдання 1 09 2025 р.

КАЛЕНДАРНИЙ ПЛАН

Назва етапів (розділів) кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
Грунтовне ознайомлення та дослідження предметної галузі	18.09.2025	Виконано
Визначення змісту, структури магістерської роботи	20.09.2025	Виконано
Опрацювання першого розділу магістерської роботи	26.09.2025	Виконано
Опрацювання статті за результатами дослідження	5.10.2025	Виконано
Опрацювання другого розділу магістерської роботи	17.10.2025	Виконано
Опрацювання третього розділу магістерської роботи	9.11.2025	Виконано
Підготовка та опрацювання ілюстративного матеріалу	18.11.2025	Виконано
Оформлення магістерської роботи графічної та текстової частини	24.11.2025	Виконано
Попередній захист магістерської роботи	25.11.2025	Виконано
Захист магістерської роботи на засіданні ЕК	19.12.2025	Виконано

Студент

  
Віталій БАБАЄВСЬКИЙ

Керівник кваліфікаційної роботи

  
Ігор МУЛЯР

## АНОТАЦІЯ

Тема кваліфікаційної роботи: Метод протидії атакам на вебзастосунки з використанням інтелектуальної системи аналізу трафіку.

Автор роботи: студент групи КБЗІм-24-1 Віталій БАБАЄВСЬКИЙ

Керівник роботи: к.т.н., доц. Ігор МУЛЯР

Загальний обсяг роботи: 94 сторінок, 12 рисунків, 71 посилання, 4 формули, 1 додаток.

Ключові слова: вебзастосунки, протидія атакам, аналіз трафіку, інтелектуальні системи, виявлення аномалій

Метою дослідження є розроблення та обґрунтування сучасних методів протидії атакам на вебдодатки, що поєднують традиційні механізми захисту з інтелектуальними підходами аналізу поведінки користувачів та запитів. Особлива увага приділяється методам контролювання та розмежування доступу, а також побудові політик безпеки, здатних попереджувати реалізацію шкідливих дій у динамічному середовищі вебресурсів.

У роботі запропоновано моделі, алгоритми та політики безпеки, орієнтовані на виявлення та блокування типових і складних атак на вебдодатки, зокрема ін'єкцій, несанкціонованої ескалації привілеїв, спроб обходу автентифікації та аномальної активності.

01.12.2025



## ANNOTATION

Theme of qualification work: Method for mitigating attacks on web applications using an intelligent traffic analysis system.

Author of the work: Vitalii BABAIEVSKYI, student of group KBZIm-24-1

Mentor: Ihor MULIAR

Total volume of work: 94 pages, 12 figures, 71 references, 4 formulas, 1 appendices.

Keywords: web applications, attack mitigation, traffic analysis, intelligent systems, anomaly detection

The aim of the research is to develop and substantiate modern methods for countering attacks on web applications, combining traditional protection mechanisms with intelligent approaches to analyzing user and request behavior. Special attention is given to access control and authorization techniques, as well as to the development of security policies capable of preventing malicious actions in the dynamic environment of web resources.

The work proposes models, algorithms, and security policies aimed at detecting and blocking both common and advanced attacks on web applications, including injections, unauthorized privilege escalation, authentication bypass attempts, and anomalous activity.

01.12.2025



## ЗМІСТ

Вступ	7
1 Дослідження предметної області	11
1.1 Аналіз безпеки вебдодатків	11
1.2 Огляд типових атак на вебдодатки	12
1.3 Традиційні методи виявлення та запобігання вторгнень	19
1.4 Сучасні підходи на основі штучного інтелекту	22
1.5 Огляд інструментів для аналізу вразливостей вебресурсів	25
1.6 Постановка задачі дослідження	31
2 Застосування ші для захисту вебдодатків	32
2.1 Аналіз мережевого трафіку	32
2.2 Виявлення аномалій у вебдодатках	41
2.3 Модель інтелектуального виявлення атак на вебдодатки	50
2.4 Метод інтелектуального виявлення атак на вебдодатки	52
2.5 Висновки	55
3 Програмна реалізація модуля виявлення атак	57
3.1 Програмна реалізація	57
3.2 Процес тестування модуля	62
3.3 Перспективи розвитку та вдосконалення системи	65
3.4 Висновки	68
Висновки	71
Перелік джерел посилань	72
Додаток А. Список праць	79

## ВСТУП

У сучасному цифровому суспільстві вебдодатки відіграють ключову роль у функціонуванні економіки, державного управління, фінансового сектору, освіти та соціальних комунікацій. Через вебдодатки користувачі отримують доступ до банківських сервісів, електронної комерції, медичних інформаційних систем, державних порталів та інших критично важливих інформаційних ресурсів. Водночас зі зростанням функціональних можливостей вебдодатків стрімко зростає і кількість кіберзагроз, спрямованих на їх компрометацію. Уразливості в програмному кодї, помилки конфїгурації серверів, неналежний контроль доступу або недостатній захист каналів зв'язку можуть бути використані зловмисниками для здійснення кібератак, що призводить до витоку конфіденційних даних, фінансових втрат, порушення безперервності роботи сервісів та зниження рівня довіри користувачів.

Сучасний ландшафт кіберзагроз характеризується зростанням складності та динамічності атак на вебдодатки, серед яких поширеними є SQL-ін'єкції, міжсайтові сценарні атаки, атаки на механізми автентифікації й авторизації, а також багаторівневі автоматизовані атаки, що використовують нетипові шаблони поведінки та модифікований шкідливий трафік. Традиційні методи захисту вебдодатків, зокрема сигнатурні системи виявлення вторгнень, статичні правила міжмережєвих екранів і ручне тестування безпеки, здебільшого орієнтовані на відомі загрози та мають обмежені можливості адаптації до нових типів атак. У результаті такі підходи часто виявляються недостатньо ефективними для забезпечення належного рівня кібербезпеки в умовах постійної еволюції загроз.

У зв'язку з цим особливої актуальності набуває впровадження методів машинного навчання та штучного інтелекту для аналізу мережевого трафіку вебдодатків і виявлення атак. Інтелектуальні системи дозволяють здійснювати обробку великих обсягів даних у режимі реального часу, виявляти аномальні патерни поведінки користувачів і систем, а також адаптуватися до змін у

характері кіберзагроз. Поєднання традиційних засобів захисту з інтелектуальними алгоритмами аналізу трафіку створює передумови для підвищення точності виявлення атак і зменшення кількості хибних спрацювань, що є важливим фактором для практичного впровадження таких систем.

Актуальність дослідження значно посилюється в контексті сучасних викликів кібербезпеки України. В умовах цифровізації державних сервісів, розвитку електронного урядування та зростання кількості кібератак на інформаційні ресурси органів державної влади, фінансових установ і об'єктів критичної інфраструктури постає нагальна потреба у впровадженні ефективних і адаптивних методів захисту вебдодатків. Розробка інтелектуальних методів протидії атакам сприяє підвищенню стійкості національних інформаційних систем, забезпеченню захисту персональних даних громадян і зміцненню загального рівня кібербезпеки держави.

Метою даної кваліфікаційної роботи є розробка та дослідження методу протидії атакам на вебдодатки з використанням інтелектуальної системи аналізу мережевого трафіку, який забезпечує підвищення ефективності виявлення та запобігання сучасним кіберзагрозам. Для досягнення поставленої мети в роботі визначено наступні завдання дослідження:

- провести аналіз сучасного стану кібербезпеки вебдодатків та обґрунтувати актуальність застосування інтелектуальних методів для виявлення і протидії атакам;
- дослідити основні типи атак на вебдодатки (SQL-ін'єкції, XSS, brute-force атаки, автоматизовані атаки та інші) та особливості їх прояву в мережевому трафіку;
- проаналізувати існуючі підходи до захисту вебдодатків, зокрема сигнатурні методи, статистичні методи та алгоритми машинного навчання, визначити їх переваги та обмеження;
- обґрунтувати доцільність поєднання сигнатурного аналізу з алгоритмами машинного навчання для виявлення відомих і раніше невідомих атак;
- розробити модель інтелектуального аналізу вебтрафіку, яка враховує як

параметри HTTP-запитів, так і поведінкові характеристики користувачів;

- розробити метод і алгоритми виявлення атак на основі аналізу шкідливих шаблонів, аномальної активності та статистичних показників мережевого трафіку;
- реалізувати програмний модуль для моніторингу й аналізу вебтрафіку в режимі реального часу з функціями виявлення та блокування атак;
- реалізувати механізми адаптивного rate limiting для протидії brute-force атакам і надмірній активності користувачів;
- провести експериментальне дослідження ефективності розробленого методу та порівняти результати з традиційними підходами захисту;
- оцінити можливість адаптації розробленої системи до нових типів атак шляхом автоматичного навчання моделей на основі нових даних вебтрафіку.

Предметом дослідження є методи та алгоритми виявлення і протидії атакам на вебдодатки на основі інтелектуального аналізу мережевого трафіку, тоді як об'єктом дослідження є процеси забезпечення кібербезпеки вебдодатків у комп'ютерних мережах. У процесі виконання роботи використовуються методи аналізу та узагальнення науково-технічної літератури, системний аналіз, статистичні методи обробки даних, методи машинного навчання, моделювання процесів аналізу мережевого трафіку та експериментальні методи тестування програмних засобів.

Наукова новизна отриманих результатів полягає в такому:

- удосконалено метод виявлення атак на вебдодатки на основі інтелектуального аналізу мережевого трафіку шляхом поєднання сигнатурного підходу з алгоритмами машинного навчання, що забезпечує підвищення точності та своєчасності ідентифікації шкідливої активності;
- запропоновано адаптивний підхід до аналізу поведінки користувачів, який базується на статистичних характеристиках вебтрафіку та дозволяє в режимі реального часу виявляти brute-force атаки й аномальну надмірну активність;
- набув подальшого розвитку механізм протидії атакам шляхом впровадження динамічного rate limiting та автоматичного оновлення моделей машинного навчання, що підвищує стійкість системи захисту до еволюції

кіберзагроз.

Практична цінність одержаних результатів полягає в можливості використання розробленого методу та програмного модуля для підвищення рівня безпеки вебдодатків, упровадження в системи моніторингу й захисту мережевого трафіку, застосування під час розробки та тестування вебзастосунків, а також у навчальному процесі з дисциплін, пов'язаних із кібербезпекою та інформаційною безпекою. За матеріалами кваліфікаційної роботи публікацій не здійснювалося.

## 1 ДОСЛІДЖЕННЯ ПРЕДМЕТНОЇ ОБЛАСТІ

### 1.1 Аналіз безпеки вебдодатків

У сучасних умовах цифрової трансформації вебзастосунки посідають ключове місце в забезпеченні функціонування як комерційних, так і державних структур. Зростаючий попит на онлайн-сервіси сприяв широкому впровадженню вебтехнологій у різних сферах, таких як бізнес, державне управління, освіта, медицина, фінанси тощо. Вебзастосунки забезпечують доступ до послуг електронного урядування, дистанційного навчання, електронної торгівлі, банківських операцій і інших складових інформаційної інфраструктури, які є критично важливими для суспільства [1, 2]. Масове використання цих систем та їх безперервна інтеграція з іншими сервісами роблять їх важливою частиною критичної інформаційної інфраструктури держави [3].

Водночас із поширенням вебзастосунків зростають і ризики, пов'язані з їхньою вразливістю до кібератак. Основним чинником цього є відкритість вебсервісів у глобальній мережі Інтернет, що створює численні можливості для несанкціонованого доступу з боку злоумисників [4]. Уразливості в програмному коді, недоліки у конфігурації серверів, ненадійні механізми аутентифікації й авторизації, а також людський фактор залишають вебзастосунки основною мішенню для кібератак різного ступеня складності [5]. Злоумисники часто застосовують відомі типи атак – SQL-ін'єкції, міжсайтове скриптування, атаки типу DoS/DDoS, а також напади на системи автентифікації, сесії та API, що дає їм змогу отримувати несанкціонований доступ до інформації, порушувати роботу систем або виводити їх з ладу.

Особливу загрозу становлять атаки на вебзастосунки, які обробляють персональні дані громадян, виконують фінансові операції або надають державні послуги. Наслідки таких інцидентів можуть бути не лише економічно значущими, а й спричинити втрату репутації, компрометацію конфіденційної інформації, а в окремих випадках – порушення стабільності функціонування критично важливих державних установ. Світовий досвід демонструє, що кібератаки на вебзастосунки

великих корпорацій чи державних установ можуть охоплювати мільйони користувачів і мати тривалі негативні наслідки [6].

З огляду на це, питання безпеки вебзастосунків набуває пріоритетного значення у сфері кібербезпеки. Традиційні засоби захисту – міжмережеві екрани, антивірусні програми та системи виявлення вторгнень – хоч і залишаються важливими, однак не завжди забезпечують достатній рівень оборони проти сучасних складних і цілеспрямованих атак. Сучасні кібератаки часто мають адаптивний характер, обходять сигнатурні системи, імітують легітимну активність користувачів, що ускладнює їхнє виявлення традиційними методами [7].

У зв'язку з цим зростає необхідність впровадження інноваційних технологій аналізу мережевого трафіку, здатних ідентифікувати ознаки шкідливої діяльності на основі поведінкових характеристик запитів і виявлення аномалій у мережевому середовищі. Особливу увагу привертають підходи, які базуються на застосуванні штучного інтелекту та машинного навчання, що дозволяють створювати динамічні моделі нормальної роботи вебзастосунків і виявляти відхилення, які можуть свідчити про потенційні атаки. Таким чином, розробка інтелектуальних систем виявлення атак на основі аналізу вебтрафіку є одним із перспективних напрямів підвищення стійкості вебзастосунків до кіберзагроз [8].

## 1.2 Огляд типових атак на вебдодатки

Вебдодатки є посередниками між користувачами та бізнесовою логікою сервісів і водночас найвразливішою ланкою для атак через численні точки взаємодії – поля для введення, API-ендпоінти, конфігураційні файли та внутрішні сервіси. Різноманітні загрози від маніпуляцій із введеними даними до зловживань логікою роботи системи. Втім, у більшості випадків успішні атаки базуються на наявних недоліках у валідації, механізмах аутентифікації, контролі доступу або налаштуваннях середовища.

SQL-ін'єкція є типовим прикладом вектору атаки, який ілюструє наслідки

нехтування розмежуванням коду й даних при формуванні запитів до реляційної бази. Механізм атаки полягає в тому, що зовнішні введені дані безпосередньо включаються в текст SQL-команди, у результаті чого сформований запит змінює свою семантику під контролем хакера [9-12].

Ін'єкції класифікують за способом експлуатації. У випадку in-band відповідь сервера одразу містить потрібні дані. При blind-ін'єкції підтвердження одержують через побічні канали без прямої відповіді від сервера. У режимі out-of-band хакер змушує СУБД ініціювати зовнішні запити на контрольовані ресурси. Кожен із цих режимів має свої тактичні особливості і вимагає окремих підходів до виявлення.

Практична експлуатація ін'єкції часто починається з формування простих додаткових умов у рядку запиту. Уявімо типову уразливість, де значення параметра id напряду конкатенується в текст SQL. Така реалізація дозволяє підставити вхід, який перетворить фільтр на завжди істинний вираз або додасть нову команду, що змінює структуру результатів. Навіть якщо механізм автентифікації присутній, поєднання уразливого запиту з неправильними правами доступу або з надлишковими привілеями облікового запису бази може призвести до катастрофічних наслідків, оскільки хакер отримує можливість оперувати даними або виконувати дії за межами передбаченої функціональності.

Основним технічним заходом протидії є чітке розмежування даних і операторів у SQL-запитах. У Python-проектах із використанням psycopg2 для PostgreSQL це досягається застосуванням параметризованих запитів, коли значення передаються окремо від тексту запиту, а драйвер безпечно прив'яже параметри. Нижче наведено приклад уразливого коду (рис. 1.1).

```
user_id = request.args.get("id")
query = "SELECT * FROM users WHERE id = " + user_id
cursor.execute(query)
```

Рисунок 1.1 – Приклад вразливого коду до SQL-ін'єкції

У цьому випадку будь-який рядок, що надійшов від клієнта, потрапляє в текст

SQL, і злоумисник може підставити спеціальний вхід, що змінить логіку. Безпечна альтернатива використовує параметри, які гарантують, що передані значення трактуються як дані, а не як частина SQL (рис. 1.2).

```
user_id = request.args.get("id")
query = "SELECT * FROM users WHERE id = %s"
cursor.execute(query, (user_id,))
```

Рисунок 1.2 – Приклад безпечного параметризованого SQL-запиту

Однак безпечна розробка вимагає не лише параметризації. Необхідно розмежувати облікові записи бази даних за функціоналом і застосувати принцип найменших привілеїв: операції читання повинні виконуватися від імені користувача з правами лише на читання, тоді як сервіси, яким не потрібні права на зміну структури, не повинні їх мати. Також слід уникати виконання кількох SQL-операторів у межах одного запиту, якщо СУБД допускає таку можливість, і забороняти небажані розширення або зовнішні виклики на рівні конфігурації СУБД.

У процесі розробки і тестування безпеки доцільно інтегрувати як автоматизовані, так і ручні методи. Статичний аналіз коду дозволяє виявити ризикові патерни формування SQL-запитів на ранніх стадіях розробки, що зменшує ймовірність потрапляння вразливого коду в репозиторій. Динамічне тестування імітує реальні взаємодії із застосунком і виявляє уразливості, які проявляються тільки під час виконання. Ручні пентести дають змогу проаналізувати комбіновані сценарії й логічні помилки, які важко автоматично виявити. Інтеграція цих інструментів у CI/CD процеси із автоматичними перевірками перед розгортанням забезпечує системну профілактику появи ін'єкційних уразливостей.

У контексті використання ORM також потрібно зберігати пильність. ORM звільняє розробника від низки низькорівневих помилок і зазвичай захищає від простих ін'єкцій, але застосування сирих SQL-виразів, форматованих рядків або динамічних конструкцій у межах ORM може звести нанівець ці переваги. Тому

навіть при використанні ORM слід віддавати перевагу високорівневим інтерфейсам, уникати ручного формування SQL.

Міжсайтове скриптування, відоме як XSS, становить окрему категорію загроз, що спирається на довіру браузера до контенту, згенерованого довіреним сайтом. Суть атаки полягає в тому, що шкідливий скрипт потрапляє в HTML вивід і виконується в контексті домену, отримуючи тим самим доступ до ресурсів, доступних цьому контексту, зокрема до cookie, localStorage і DOM. Наслідки експлуатації XSS можуть бути серйозними: викрадення сесійних токенів, несанкціоноване виконання дій від імені користувача, інжекція фішингових форм або завантаження додаткового шкідливого програмного забезпечення через браузерну інфраструктуру. У поєднанні з іншими векторами, наприклад із міжсайтовими запитами підробки, XSS значно підвищує ефективність атак і ускладнює процес відновлення після інциденту [13].

З практичної точки зору розрізняють три домінантні варіанти реалізації XSS. Перший варіант - збережений тип, коли шкідливий код зберігається на сервері і надалі віддається іншим користувачам. Другий варіант - відображуваний тип, коли шкідливий скрипт є частиною запиту й одразу повертається у відповіді сервера. Третій варіант - DOM-орієнтований XSS, коли вразливість реалізується на стороні клієнта через небезпечну роботу з DOM і даними, що надходять від користувача. Кожна з цих форм має власні сигнатури поведінки й потребує відмінних стратегій виявлення та пом'якшення.

В теоретичному й практичному компонентах захисту ключовим є контекстно-орієнтоване кодування вхідних даних перед їхнім відображенням у вихідному HTML чи JavaScript. Для HTML контенту необхідно замінювати символи амперсанд, менше, більше, лапки подвійні та одинарні на відповідні HTML сутності. Коли дані потрапляють в атрибутний контекст, додатково має контролюватися правильне використання та закриття кавичок, а коли дані передаються в JavaScript контекст, їх слід уникати прямого вбудовування і застосовувати безпечну серіалізацію або спеціалізовані API, що гарантують коректне кодування. У середовищі шаблонізаторів автоматичний ескейпінг слід

розглядати як стандартну практику, а умисне відключення ескейпу має бути добре задокументовано і виправдано.

Як ілюстрацію наведено приклад потенційно небезпечного рендерингу в середовищі Flask, який демонструє пряме вставляння користувацьких даних у шаблон (рис. 1.3).

```
from flask import Flask, request, render_template_string

# /
app = Flask(__name__)

# /greet
@app.route("/greet")
def greet():
    name = request.args.get("name", "")
    return render_template_string(f"<p>Ласкаво просимо, {name}</p>")
```

Рисунок 1.3 – Приклад небезпечного рендерингу шаблону Flask (XSS-вразливість)

У цьому фрагменті значення `name` вставляється без гарантій кодування і може містити скрипт, що виконається в контексті домену. Безпечніший спосіб полягає у використанні шаблонів із увімкненим автоматичним ескейпінгом або явному ескейпуванню значень перед виводом, наприклад через стандартні можливості Jinja2 (рис. 1.4).

```
from flask import render_template

@app.route("/greet_safe")
def greet_safe():
    name = request.args.get("name", "")
    return render_template("greet.html", name=name)
```

Рисунок 1.4 – Безпечне вставлення даних у шаблон із використанням Jinja2

Окрім правильного кодування даних у застосунку, варто застосовувати й інші способи захисту від XSS. Наприклад, політика Content Security Policy допомагає обмежити джерела виконуваного коду, що ускладнює атаку. Також потрібно уважно перевіряти шаблони, забороняти довільне вставлення HTML, стежити за підозрілою поведінкою сервера і поєднувати автоматичні інструменти для пошуку уразливостей з ручним аналізом коду. Такий комплексний підхід забезпечує надійний захист від міжсайтового скриптування.

Атаки на процес автентифікації займають центральне місце в аналізі загроз, оскільки саме коректна і надійна ідентифікація та верифікація особи гарантують доступ до ресурсів лише уповноваженим суб'єктам. Типові вразливості пов'язані з повторним використанням облікових даних, недостатньо суворими політиками формування паролів, відсутністю механізмів захисту від масових спроб входу та неналежним менеджментом сесій. Автоматизовані методи атак, зокрема bruteforce і credential stuffing, легко реалізуються скриптами та мають підвищену ефективність у разі відсутності лімітації запитів, аудиту спроб входу або механізмів тимчасової чи постійної блокування облікових записів та IP адрес.

Підвищення стійкості системи до таких загроз досягається комплексом заходів. Серед них - впровадження багатофакторної аутентифікації, застосування адаптивних криптографічних хешів з налаштованою складністю (наприклад, Argon2 або bcrypt) та імплементація механізмів одноразових підтверджень як другого фактора. Не менш важливою є політика управління сесіями: використання захищених куки з атрибутами HttpOnly, Secure і SameSite, регенерація ідентифікаторів сесії після успішного входу та обмеження часу життя сесії. Архітектурно доцільно вводити обмеження привілеїв і розділення ролей, а також застосовувати захист від автоматизованих запитів на рівні прикладного шару і мережевої інфраструктури.

Одна з критичних уразливостей вебзастосунків сучасності – підміна серверного запиту, або SSRF (Server-Side Request Forgery). Суть цієї атаки полягає у тому, що зловмисник, використовуючи неналежну перевірку вхідних параметрів, змушує сервер ініціювати запити до зовнішніх або внутрішніх ресурсів. Це створює

можливість обійти мережеві обмеження, отримати доступ до захищених інтерфейсів, у тому числі до служб керування хмарною інфраструктурою [14-15].

Особливої загрози такі атаки набувають у середовищах, де сервер має доступ до служб з підвищеними повноваженнями. У хмарних обчисленнях це, зокрема, метадані віртуальних машин або конфігураційні ендпоінти. Запити, ініційовані зсередини довіреного середовища, зазвичай не блокуються традиційними засобами фільтрації, що значно ускладнює їхнє виявлення та стримування.

Належний захист від SSRF потребує системного підходу, де ключовим принципом є обмеження цільових адрес, до яких сервер може звертатися. Рекомендується використовувати білий список дозволених доменів або IP-адрес. Користувачі не повинні мати змоги передавати довільні мережеві адреси без ретельної перевірки. Важливо здійснювати нормалізацію введених URL-адрес, контролювати редиректи, не дозволяти доступ до внутрішніх підмереж, а також блокувати використання потенційно небезпечних протоколів, таких як file, ftp чи data.

Окрім цього, критично важливим є контроль вихідного трафіку. Усі запити до зовнішніх ресурсів повинні проходити через централізований проксі-сервер, який забезпечує логування та аудит дій. Це дозволяє не лише обмежувати доступ до зовнішніх адрес, а й фіксувати аномальні звернення для подальшого аналізу.

Ще одним обов'язковим компонентом захисної стратегії є система моніторингу та фіксації подій. Вона має забезпечувати збирання детальної телеметрії, логування HTTP запитів, аналіз частоти помилок на певних вузлах, а також виявлення аномальної поведінки за допомогою поведінкових алгоритмів. Сучасні вебзастосункові екрани можуть бути використані як проміжний захисний рівень, однак вони не замінюють правильної реалізації безпеки в коді. Їхнє завдання - компенсувати потенційні прогалини на етапах розробки або оновлення системи.

Таким чином, надійний захист від SSRF, як і від інших векторів атак, вимагає не лише належної реалізації запобіжних заходів на рівні коду та конфігурації, а й ефективної системи виявлення, моніторингу та реагування на інциденти.

Ще однією поширеною уразливістю вебзастосунків є міжсайтове підроблення запитів – CSRF (Cross-Site Request Forgery). Суть цієї атаки полягає у тому, що зловмисник змушує автентифікованого користувача виконати небажану дію у вебзастосунку без його відома або згоди. Оскільки запит надсилається від імені легітимного користувача разом із його сесійними даними, сервер сприймає його як довірений та коректно обробляє, що може призвести до зміни облікових даних, налаштувань або виконання інших критичних операцій [16-19].

Ефективний захист від CSRF вимагає впровадження механізмів перевірки достовірності запитів, зокрема використання унікальних CSRF-токенів, пов'язаних із сесією користувача, а також перевірки заголовків Origin і Referer. Додатково рекомендується обмежувати виконання критичних операцій лише методами HTTP, що не можуть бути ініційовані автоматично сторонніми ресурсами, та застосовувати принцип мінімальних привілеїв. У поєднанні з коректною обробкою сесій та контролем доступу ці заходи дозволяють суттєво знизити ризик успішної реалізації CSRF-атак.

### 1.3 Традиційні методи виявлення та запобігання вторгнень

У сфері захисту вебзастосунків важливою залишається не лише профілактика несанкціонованих дій, а й своєчасне розпізнавання атак, їхнє блокування та мінімізація можливих наслідків. Протягом останніх десятиліть підходи до виявлення та протидії кіберзагрозам істотно трансформувалися – від простих механізмів фільтрації та баз шаблонів до складних інтелектуальних систем, здатних до адаптації й самонавчання. В умовах стрімкого зростання обсягів мережевого трафіку, ускладнення атак і впровадження динамічних методів обходу захисних механізмів класичні підходи дедалі частіше виявляються малоефективними. Це зумовлює необхідність перегляду традиційних засобів і впровадження новітніх рішень, які базуються на поведінковому аналізі та виявленні аномалій у трафіку [21-25].

Класичні методи виявлення атак, що застосовуються ще з початку двотисячних років, ґрунтуються на детермінованих правилах, шаблонах і сигнатурах, які описують конкретні прояви зловмисної активності [26]. Такий підхід реалізований у більшості систем виявлення та запобігання вторгненням, зокрема в Snort, Suricata, ModSecurity та інших. Головною перевагою цих рішень є висока точність виявлення відомих загроз, мінімальна кількість хибних спрацювань і помірне споживання обчислювальних ресурсів. Подібні системи активно впроваджуються в корпоративному середовищі, де забезпечують базовий рівень захисту вебзастосунків та серверної інфраструктури [27].

Водночас ефективність сигнатурного методу різко знижується у випадку появи нових, ще не описаних атак або модифікованих варіацій відомих загроз. Зокрема, атаки нульового дня, а також цілеспрямовані дії проти конкретних об'єктів можуть обійти шаблонну фільтрацію. Крім того, активне використання обфускації, шифрування та інших технік приховування дозволяє маскувати справжню суть запиту, що значно ускладнює або унеможлиблює виявлення загрози за допомогою статичного аналізу [28]. Ще однією вразливістю класичних засобів є їхня нездатність до самостійного оновлення чи адаптації – усі зміни у сигнатурних базах мають виконуватись вручну, що призводить до затримки між появою нової загрози та її фактичним виявленням [29-31].

У відповідь на ці обмеження фокус розробників і дослідників поступово зміщується у бік сучасних рішень, які поєднують динамічний аналіз мережевої активності, контекстну оцінку дій користувачів і застосування алгоритмів машинного навчання для класифікації трафіку. Основна ідея таких підходів полягає не в розпізнаванні окремих відомих атак, а у виявленні відхилень від звичних моделей поведінки – так званих аномалій. Саме вони можуть свідчити про спроби несанкціонованого доступу, сканування системи, впровадження шкідливого коду або автоматизовану взаємодію із сервісами.

Аномальні прояви у трафіку вебзастосунків можуть мати різноманітні форми: нестандартні послідовності запитів, підвищену частоту звернень, незвичну географію джерел трафіку, спроби доступу до службових ресурсів, змінені

заголовки або використання невідомих методів взаємодії з API. Виявлення подібних характеристик потребує засобів, що здатні опрацьовувати багатовимірні дані та враховувати контекст дій. На відміну від традиційних засобів, інструменти, які застосовують методи машинного навчання, можуть формувати адаптивні моделі нормальної поведінки на основі історичних даних, що дозволяє своєчасно виявляти нетипові ситуації. Одним із перспективних напрямів є використання алгоритмів класифікації, таких як дерева рішень, метод опорних векторів або баєсівські моделі, а також методів виявлення аномалій – кластеризації, нейронних мереж, автоенкодерів і рекурентних архітектур. Навчання таких моделей може здійснюватися як у контрольованому режимі, коли відомо, які приклади є шкідливими, так і в неконтрольованому – без чіткого поділу на «нормальні» та «аномальні» дані. У першому випадку вдається досягти високої точності у класифікації вже відомих загроз, тоді як другий підхід ефективніше виявляє нові, ще не задокументовані загрози.

У сучасних системах аналізу трафіку дедалі частіше використовується комбінований підхід, що об'єднує елементи шаблонного аналізу з поведінковим. Це дозволяє одночасно виявляти як відомі типи атак, так і нові загрози, які проявляються через зміну поведінки користувача або сервісу. Важливу роль у таких системах відіграють модулі кореляції подій і автоматичного реагування, які здатні обробляти дані в реальному часі, зіставляти події з різних джерел – серверів, баз даних, API, зовнішніх логів – і своєчасно блокувати підозрілу активність.

Інтеграція інтелектуальних систем виявлення атак із загальною інфраструктурою кіберзахисту передбачає також взаємодію з системами управління подіями безпеки, моніторинговими платформами та хмарними аналітичними сервісами. Це створює підґрунтя для побудови єдиної архітектури захисту, в якій трафік аналізується у контексті всіх внутрішніх і зовнішніх процесів взаємодії вебзастосунку.

Водночас ефективність таких рішень значною мірою залежить від якості й репрезентативності даних, що використовуються для навчання моделей. У реальному середовищі мережевий трафік є вкрай різноманітним, змінним у часі й

залежним від особливостей конкретного застосунку. Це вимагає постійного оновлення моделей, їх перенавчання, адаптації до нових умов, а також ретельного налаштування параметрів виявлення з метою мінімізації хибнопозитивних результатів.

#### 1.4 Сучасні підходи на основі штучного інтелекту

Сучасні умови функціонування вебзастосунків передбачають постійну взаємодію з великою кількістю зовнішніх користувачів, сервісів і пристроїв. Унаслідок цього обсяги мережевого трафіку зростають експоненційно, а його структура стає дедалі складнішою. Така динаміка створює сприятливе підґрунтя для появи нових векторів атак, виявлення яких ускладнене за допомогою традиційних засобів захисту. В цих умовах застосування методів штучного інтелекту, зокрема машинного навчання та аналізу аномалій, є не лише перспективним, а й необхідним для забезпечення ефективного виявлення загроз у вебтрафіку.

На відміну від сигнатурних методів, що ґрунтуються на зіставленні мережевої активності з наперед визначеними шаблонами, моделі, побудовані із застосуванням штучного інтелекту, здатні самостійно виявляти відхилення в поведінці користувачів, сервісів або застосунків. Це дає змогу оперативно реагувати на нові, ще не класифіковані типи атак, які не мають сигнатурного опису та можуть залишатися непоміченими для класичних систем безпеки. Штучний інтелект дозволяє моделювати поведінку мережевих об'єктів, аналізувати історичні дані, будувати прогностичні моделі та адаптуватися до змін, знижуючи ризик як хибнопозитивних, так і хибнонегативних результатів.

Основна концепція застосування ШІ у сфері аналізу трафіку полягає у побудові моделей нормальної (тобто легітимної) поведінки системи, які використовуються як еталон для виявлення відхилень. Аномалією вважається будь-яка дія, що істотно відрізняється від встановленої норми – наприклад, різке

зростання інтенсивності запитів з одного джерела, спроби доступу до заборонених ресурсів, незвичні параметри HTTP-запитів або нетипова послідовність дій користувача. Сучасні атаки часто маскуються під легальну активність, тож лише багаторівневий, контекстуальний аналіз поведінки дає змогу точно відрізнити легітимний трафік від потенційно шкідливого.

Серед основних напрямів застосування ШІ в аналізі трафіку можна виокремити класифікацію, регресійний аналіз, кластеризацію, виявлення аномалій і послідовне прогнозування. У практиці широко використовуються алгоритми прийняття рішень, зокрема дерева рішень, баєсівські моделі, метод опорних векторів, логістична регресія, а також нейронні мережі – як класичні, так і глибокі. Для виявлення аномалій ефективними є автоенкодери, здатні навчатися відтворенню вхідних даних із мінімальними втратами, завдяки чому вони можуть виявляти нетипові зразки, які не відповідають раніше встановленим нормам.

Суттєвою перевагою таких підходів є можливість їх застосування у режимі без учителя, коли моделі створюються без потреби у попередньо маркованих даних. Це особливо важливо в ситуаціях, коли навчальні вибірки є обмеженими або застарілими, або коли виникає потреба виявляти загрози, ще не описані в існуючих базах знань. Водночас методи з учителем, що передбачають навчання моделей на заздалегідь класифікованих даних, дають високу точність у розпізнаванні вже відомих загроз за умови якісної підготовки вибірки.

Актуальним підходом також є використання гібридних методів, які поєднують переваги як контрольованого, так і неконтрольованого навчання. Наприклад, система спочатку самостійно виокремлює підозрілі зразки, після чого вони проходять додаткову перевірку або маркування з боку адміністратора. Така стратегія підвищує точність детекції, водночас зберігаючи здатність моделі до адаптації. Додатково для підвищення надійності застосовуються ансамблеві методи, як-от випадкові ліси чи градієнтне підсилення, що поєднують кілька простіших моделей в одну узгоджену систему ухвалення рішень.

На практиці інтелектуальні модулі аналізу трафіку можуть функціонувати як окремі елементи безпекової інфраструктури або інтегруватися в комплексні

платформи кіберзахисту. Залежно від архітектури, такі системи розгортаються безпосередньо на рівні вебсервера (наприклад, у складі проксі або шлюзів доступу), на рівні мережевої інфраструктури (як модулі глибокої інспекції пакетів чи системи кореляції подій) або у хмарному середовищі, що забезпечує віддалений аналіз за допомогою розподілених обчислювальних ресурсів.

Поряд із очевидними перевагами, впровадження ШІ супроводжується низкою викликів. Насамперед – це залежність якості моделей від якості вхідних даних, що вимагає створення надійної інфраструктури збору, фільтрації та нормалізації трафіку. Також варто враховувати обчислювальну складність моделей, яка може ускладнювати їхню інтеграцію в системи, що працюють у режимі реального часу або мають обмежені ресурси. Крім того, важливим фактором є правильне налаштування параметрів виявлення, вибір ознак і значень порогів, що суттєво впливають на кількість хибних спрацювань.

Особливої уваги потребує питання інтерпретованості моделей. У сфері кібербезпеки надзвичайно важливо не лише виявити загрозу, а й пояснити причину, через яку система класифікувала певну дію як підозрілу чи небезпечну. Це необхідно для формування звітів, прийняття рішень щодо реагування, а також навчання персоналу. У зв'язку з цим все ширше застосовуються технології пояснюваного штучного інтелекту, які забезпечують прозорість роботи моделей та можливість її аналізу фахівцями.

Загалом використання ШІ у сфері аналізу трафіку вебзастосунків відкриває широкі можливості для створення ефективних, гнучких і масштабованих систем виявлення загроз. Такий підхід дає змогу не лише своєчасно реагувати на кіберінциденти, а й запобігати їм, прогнозуючи потенційну поведінку зловмисника. Інтеграція інтелектуальних моделей із загальною системою моніторингу, логування, реагування на інциденти та управління ризиками сприяє формуванню цілісної стратегії кіберзахисту, в основі якої – здатність системи вчитися, адаптуватися й розвиватися разом із середовищем, у якому вона функціонує.

## 1.5 Огляд інструментів для аналізу вразливостей вебресурсів

У сучасному інформаційному середовищі, де вебзастосунки виконують критичні функції як у державному, так і в комерційному секторі, питання їхньої безпеки набуває особливої важливості. Одним із основних етапів забезпечення безпеки є своєчасне виявлення вразливостей, що можуть бути використані зловмисниками для несанкціонованого доступу, викрадення даних або порушення роботи системи. Для цієї мети застосовуються спеціалізовані програмні засоби, які дозволяють проводити аналіз захищеності вебдодатків на різних етапах їхнього життєвого циклу.

Інструменти для аналізу вразливостей умовно можна поділити на кілька категорій залежно від методів дослідження. Найпоширенішими є сканери типу «чорної скриньки», які працюють з боку кінцевого користувача або потенційного зловмисника, не маючи доступу до внутрішнього коду. Вони моделюють реальні сценарії атак і дозволяють виявити вразливості, помітні зовні. Такі інструменти найчастіше використовуються для поверхневого аудиту системи перед її розгортанням у продуктивному середовищі.

Одним із найвідоміших інструментів у цій категорії є OWASP ZAP (Zed Attack Proxy), який дозволяє автоматизовано сканувати вебзастосунки на наявність поширених вразливостей, таких як SQL-ін'єкції, міжсайтовий скриптинг (XSS), CSRF, проблеми автентифікації та керування сесіями. Інструмент функціонує як перехоплювальний проксі-сервер, що забезпечує аналіз HTTP- та HTTPS-трафіку між клієнтом і сервером, дозволяючи детально досліджувати поведінку вебзастосунку під час взаємодії з користувачем.

Ключовою перевагою OWASP ZAP є наявність вбудованого автоматичного сканера, який здійснює активне та пасивне тестування безпеки. Пасивний аналіз дозволяє виявляти вразливості без втручання в роботу застосунку, зокрема проблеми з налаштуваннями заголовків безпеки, витіки службової інформації або небезпечні конфігурації. Активний сканер, у свою чергу, моделює атаки шляхом надсилання спеціально сформованих запитів, що дозволяє виявляти уразливості

ін'єкційного типу, некоректну валідацію введених даних та помилки обробки виняткових ситуацій.

OWASP ZAP також надає потужні засоби для ручного тестування, зокрема інструменти перехоплення та модифікації HTTP-запитів, фазинг параметрів, повторне надсилання запитів і аналіз відповідей сервера. Підтримка сценаріїв авторизації дозволяє тестувати захищені ділянки застосунку, а вбудований механізм управління сесіями сприяє аналізу cookie, токенів та параметрів автентифікації. Це робить ZAP ефективним не лише для автоматизованого, але й для глибокого ручного аналізу.

Важливою функціональною особливістю OWASP ZAP є можливість розширення через систему плагінів (Add-ons), що дозволяє додавати підтримку нових типів атак, протоколів або методів аналізу. Інструмент також має REST API та командний режим роботи, завдяки чому його легко інтегрувати в конвеєри CI/CD для автоматичного тестування безпеки під час збірки та розгортання вебзастосунків. Відкритий вихідний код і активна спільнота OWASP забезпечують регулярні оновлення, актуальність сигнатур та адаптацію інструмента до сучасних загроз, що робить OWASP ZAP одним із базових засобів для аналізу безпеки вебдодатків [32–33].

Поряд із OWASP ZAP значного поширення набув інструмент Burp Suite, який є однією з найбільш функціонально насичених платформ для тестування безпеки вебзастосунків у парадигмі «чорної скриньки». Інструмент розроблений компанією PortSwigger та широко використовується фахівцями з інформаційної безпеки для проведення ручного та напівавтоматизованого penetration testing. Burp Suite функціонує як перехоплювальний проксі-сервер, що розміщується між клієнтським браузером і цільовим вебсервером, забезпечуючи повний контроль над HTTP- та HTTPS-трафіком, включно з параметрами запитів, заголовками, cookies та вмістом відповідей.

Центральним компонентом Burp Suite є модуль Proxy, який дозволяє перехоплювати та аналізувати мережеву взаємодію вебзастосунку в режимі реального часу. Це дає змогу досліджувати механізми обробки користувацьких

даних, перевіряти коректність серверної валідації, а також виявляти логічні помилки, пов'язані з обробкою параметрів форм, API-запитів і JSON-повідомлень. Перехоплені запити можуть бути змінені вручну та повторно надіслані серверу з метою аналізу реакції застосунку на нетипові або навмисно спотворені дані.

Для детального ручного аналізу Burp Suite надає інструмент Repeater, який дозволяє багаторазово відправляти змінені HTTP-запити та порівнювати відповіді сервера. Це особливо корисно під час дослідження SQL-ін'єкцій, XSS, некоректної обробки помилок, а також для перевірки контролю доступу до захищених ресурсів. У свою чергу, модуль Intruder призначений для автоматизованого тестування шляхом перебору параметрів, фазингу та імітації атак типу brute-force, що дає змогу виявляти слабкі паролі, небезпечні шаблони обробки вхідних даних і вразливості бізнес-логіки.

Важливим аспектом безпеки вебзастосунків є керування сесіями користувачів, для аналізу якого в Burp Suite реалізовано модуль Sequencer. Він дозволяє оцінити рівень випадковості та криптографічної стійкості токенів сесій, ідентифікаторів авторизації та CSRF-токенів. Недостатня ентропія таких значень може призвести до атак типу session hijacking або prediction attacks, що становить серйозну загрозу для конфіденційності даних.

У професійній версії Burp Suite доступний модуль Scanner, який автоматизує процес виявлення типових уразливостей, зокрема SQL-ін'єкцій, міжсайтового скриптингу, небезпечної десеріалізації, некоректних перенаправлень та проблем з конфігурацією безпеки. На відміну від повністю автоматичних сканерів, результати Scanner інтегруються з ручним аналізом, що дозволяє зменшити кількість хибнопозитивних спрацювань і підвищити точність оцінки ризиків.

Додатковою перевагою Burp Suite є підтримка розширюваності через механізм Burp Extender, який дозволяє підключати сторонні плагіни або розробляти власні модулі мовами Java, Python або Kotlin. Це дає змогу адаптувати інструмент до специфічних вимог тестування, зокрема аналізу REST- та GraphQL-API, нестандартних протоколів або кастомних механізмів автентифікації. Завдяки модульній архітектурі, гнучким налаштуванням і високому рівню контролю над

процесом тестування Burp Suite вважається де-факто стандартом серед інструментів для глибокого аналізу безпеки вебзастосунків і широко застосовується у професійній практиці penetration testing [34].

Інструменти аналізу типу «білої скриньки», на відміну від «чорної скриньки», проводять аудит із повним доступом до вихідного коду, конфігурації додатку та даних про його архітектуру. Такий підхід дозволяє виявляти логічні помилки, помилки програмування, неправильне використання бібліотек або недоліки в застосуванні криптографічних алгоритмів. Одним із таких інструментів є SonarQube – система статичного аналізу коду, яка дозволяє ідентифікувати вразливості на ранніх етапах розробки. Вона підтримує численні мови програмування та забезпечує глибоку інтеграцію з популярними системами керування версіями.

Засоби типу OpenVAS та Nessus займають проміжну позицію між аналізом окремих вебзастосунків і комплексною оцінкою безпеки всієї інфраструктури організації. Вони дозволяють проводити глибинне сканування мережі, виявляти відкриті порти, некоректно налаштовані служби та застаріле програмне забезпечення, яке може бути використане зловмисниками для компрометації системи. Це забезпечує більш широке уявлення про стан безпеки порівняно зі стандартними веб-сканерами, що обмежуються перевіркою лише логіки роботи вебдодатку.

Крім технічної конфігурації серверів і мережевих пристроїв, OpenVAS та Nessus дозволяють оцінювати правила доступу та політики користувачів, визначати потенційні вектори несанкціонованого доступу і недоліки в управлінні обліковими записами. Виявлені уразливості систематизуються за ступенем критичності, що дозволяє адміністраторам пріоритетувати заходи щодо їх усунення та знижувати ризики, пов'язані з можливими кібератаками.

Завдяки своїй функціональності ці інструменти використовуються для формування комплексної картини захищеності інформаційної системи в цілому. Поєднання результатів сканування OpenVAS або Nessus із даними інших засобів моніторингу та тестування безпеки дозволяє організаціям отримати більш повне

уявлення про слабкі місця інфраструктури і підвищити ефективність заходів з кіберзахисту [35–36].

З огляду на зростаюче використання API та мікросервісної архітектури, питання безпеки програмних інтерфейсів набуває особливої актуальності. API часто виступають ключовим елементом взаємодії між компонентами сучасних вебзастосунків, а також між внутрішніми сервісами та зовнішніми клієнтами. Уразливості на цьому рівні можуть призвести до витоку конфіденційних даних, порушення цілісності системи або повного обходу механізмів автентифікації, що робить тестування безпеки API невід’ємною частиною загальної стратегії захисту.

Для аналізу захищеності API-інтерфейсів застосовуються спеціалізовані інструменти, зокрема Postman (у поєднанні з розширеннями та скриптами для тестування безпеки), ReadyAPI та Insomnia. Вони дозволяють моделювати запити до REST- та GraphQL-API, перевіряти коректність реалізації механізмів автентифікації та авторизації (OAuth 2.0, JWT, API keys), аналізувати обробку помилок і граничних випадків, а також тестувати контроль доступу до ресурсів. Завдяки підтримці колекцій запитів і автоматизованих сценаріїв ці інструменти можуть використовуватися як для ручного тестування, так і для повторюваних перевірок у процесі розробки.

Крім того, зазначені інструменти підтримують інтеграцію з конвеєрами CI/CD, що дозволяє автоматизувати перевірки безпеки API на етапах збірки та розгортання застосунків. Це сприяє ранньому виявленню помилок у реалізації шифрування переданих даних, некоректних налаштувань CORS або недостатньої валідації вхідних параметрів. У поєднанні з іншими засобами аналізу безпеки тестування API дозволяє сформувати цілісний підхід до захисту мікросервісних систем і зменшити ризики, пов’язані з експлуатацією вразливостей на рівні інтерфейсів взаємодії.

Окрему категорію становлять фреймворки для моделювання атак, серед яких варто згадати Metasploit Framework [37]. Цей інструмент широко використовується для симуляції експлуатації вразливостей, надає доступ до великої бібліотеки експлоїтів і дозволяє відтворювати складні сценарії реальних атак, тим самим

допомагаючи оцінити, наскільки глибоко потенційна вразливість може бути використана уразливим місцем системи.

Важливою складовою сучасних систем інформаційної безпеки є постійний моніторинг та централізоване логування подій, що відбуваються в інформаційній інфраструктурі. Логи містять критично важливу інформацію про роботу вебсерверів, застосунків, баз даних, мережевих компонентів та систем автентифікації, а їх своєчасний аналіз дозволяє оперативно виявляти відхилення від нормальної поведінки системи. Без належного моніторингу навіть добре захищені вебзастосунки можуть залишатися вразливими до прихованих атак, які тривалий час не проявляють себе явно.

Для вирішення цих завдань використовуються спеціалізовані платформи аналізу логів, зокрема Splunk, Kibana (у складі Elastic Stack) та Graylog, які забезпечують централізований збір, зберігання, агрегацію та кореляцію подій із різних джерел. Такі інструменти дозволяють не лише аналізувати вже відомі сигнатури атак, але й виявляти аномальну поведінку, що може свідчити про підготовку до атаки, спроби обходу механізмів автентифікації або несанкціонований доступ до ресурсів. Використання візуалізацій, дашбордів та механізмів пошуку значно спрощує роботу аналітиків безпеки та скорочує час реагування на інциденти.

У більшості організацій платформи моніторингу та аналізу логів інтегруються в SIEM-системи (Security Information and Event Management), які формують єдине середовище для управління подіями інформаційної безпеки. SIEM-рішення забезпечують кореляцію подій у масштабах усієї інфраструктури, автоматизацію реагування на інциденти та підтримку процесів аудиту й відповідності нормативним вимогам. Таким чином, поєднання логування, моніторингу та SIEM-технологій дозволяє підвищити загальний рівень захищеності організації та забезпечити проактивний підхід до управління ризиками інформаційної безпеки [38–41].

З огляду на широкий спектр інструментів, вибір конкретного рішення для аналізу вразливостей залежить від поставлених цілей, доступних ресурсів, типу

вебзастосунку та рівня технічної підготовки персоналу. Найбільш ефективною вважається стратегія комбінованого підходу, за якої поєднуються автоматичні сканери, ручне тестування, аналіз коду та моніторинг у реальному часі. Така комплексна методика дозволяє забезпечити високий рівень обізнаності про поточний стан безпеки вебдодатку й оперативно реагувати на виявлені загрози.

## 1.6 Постановка задачі дослідження

Метою даної роботи є розробка методу протидії атакам на вебзастосунки шляхом інтелектуального аналізу вхідного трафіку. Основне завдання полягає у створенні системи, яка зможе в режимі реального часу виявляти шкідливі запити (зокрема XSS, SQL-ін'єкції, brute-force) та аномальну активність, використовуючи поєднання сигнатурного методу і алгоритмів машинного навчання.

Вимоги до системи:

- виявлення XSS та SQL-ін'єкцій на основі сигнатур та моделей машинного навчання;
- виявлення та блокування спроб brute-force атак;
- обмеження надмірної активності користувача (rate limiting);
- здатність адаптації до нових типів атак.

## 2 ЗАСТОСУВАННЯ ШІ ДЛЯ ЗАХИСТУ ВЕБДОДАТКІВ

### 2.1 Аналіз мережевого трафіку

Аналіз мережевого трафіку - це практика постійного моніторингу та оцінки мережевих даних, щоб отримати уявлення про те, як трафік рухається через середовище. Він включає в себе збір інформації про трафік (наприклад, записи потоку або пакети) та аналіз її для характеристики IP-трафіку - по суті, розуміння того, як і де надходить мережевий трафік. Використовуючи спеціалізовані інструменти та методи, інженери можуть детально вивчити ці дані, часто в режимі реального часу, для виявлення закономірностей та аномалій. По суті, NTA забезпечує видимість поведінки вашої мережі, збираючи та синтезуючи дані потоку трафіку для моніторингу, усунення несправностей та аналізу безпеки. Ця видимість має вирішальне значення для забезпечення здоров'я мережі. Без аналізу трафіку важко дізнатися, чи працює ваша мережа ефективно або чи проблеми ховаються під поверхнею [42].

Сьогоднішній аналіз мережевого трафіку виходить за рамки моніторингу локальної мережі, що охоплює центри обробки даних, філії та хмарних провайдерів. Тому NTA включає аналіз телеметрії з локальних пристроїв (маршрутизаторів, комутаторів тощо), хмарної інфраструктури (віртуальні мережі, журнали потоків VPC тощо) і навіть контейнеризованих або безсерверних середовищ. Обсяг може варіюватися від тенденцій використання на високому рівні до детальної перевірки пакетів [43].

Через цю широку сферу застосування, NTA іноді розбивається на субдомени, такі як аналіз потоку (вивчення агрегованих записів потоку) та аналіз пакетів (глибока перевірка корисних навантажень пакетів). Незалежно від методу, мета залишається незмінною: отримати корисну інформацію про використання мережі та продуктивність, вивчаючи сам трафік. Аналіз мережевого трафіку відіграє важливу роль в управлінні та оптимізації мереж з кількох причин. По-перше, він дозволяє здійснювати моніторинг продуктивності мережі. Аналізуючи мережевий трафік, оператори можуть визначати вузькі місця, розуміти споживання пропускної

здатності та оптимізувати використання ресурсів. Постійний аналіз трафіку допомагає застосовувати політику якості обслуговування та забезпечує безперебійний, ефективний досвід для користувачів. Це дозволяє переконатися, що критичні програми отримують необхідну пропускну здатність, а проблеми із затримкою або перевантаженням вирішуються оперативно.

По-друге, перевірка моделей трафіку є життєво важливою для забезпечення безпеки мережі. Незвичайні стрибки трафіку або підозрілі схеми потоку можуть виявляти проблеми, такі як зараження шкідливим програмним забезпеченням, ексфільтрація даних або атаки розподіленої відмови в обслуговуванні. Інструменти аналізу мережевого трафіку дозволяють позначати аномалії або відомі шкідливі показники трафіку, надаючи командам безпеки ранні попередження. Дані аналізу мережевого трафіку часто інтегруються із системами виявлення вторгнень та аналітикою безпеки для всебічного моніторингу загроз.

По-третє, аналіз мережевого трафіку сприяє швидкому усуненню несправностей у мережі. Він допомагає інженерам визначати та вирішувати проблеми, зменшуючи час простою. Коли виникають проблеми, наприклад, користувачі повідомляють про повільне підключення або відключення додатків, дані про трафік можуть виявити, де саме відбувається розрив, наприклад, через проблеми маршрутизації або перевантажені пакети. Завдяки цьому команди мережевої підтримки можуть ізолювати першопричину швидше, скорочуючи середній час для ремонту та підвищуючи задоволення користувачів.

Крім того, аналіз трафіку необхідний для ефективного планування пропускну здатності мережі. Він дає уявлення про поточні тенденції використання та прогнозує майбутнє навантаження. Вимірювання обсягів трафіку та схеми спостереження дозволяють приймати обґрунтовані рішення щодо розширення пропускну спроможності або оптимізації мережевої інфраструктури. Це гарантує, що мережа може обробляти майбутній попит без надмірного забезпечення, а стратегічні рішення щодо модернізації або оптимізації маршрутизації трафіку базуються на фактичних даних [43-45].

Аналіз мережевого трафіку також забезпечує відповідність регуляторним

вимогам та внутрішнім політикам організацій. Детальні журнали трафіку та аналітика дозволяють продемонструвати аудиторам, що конфіденційні дані не покидають мережу неправильно та що використання ресурсів відповідає правилам конфіденційності. Багато стандартів безпеки, таких як PCI-DSS або HIPAA, передбачають моніторинг мережевої активності, і аналіз трафіку забезпечує документовані докази виконання цих вимог [47].

Нарешті, аналіз трафіку допомагає оптимізувати витрати та ресурси, особливо в сучасних хмарних і гібридних мережах. Він дозволяє виявляти неефективні маршрути, оптимізувати шляхи передачі даних і зменшувати витрати на трафік. Наприклад, порівняння обсягів трафіку через дорогі канали з менш затратними альтернативами дає змогу оптимізувати витрати на WAN. В хмарних середовищах аналіз допомагає виявляти недостатньо використовувані ресурси та можливості для повторного архівування даних, що дозволяє економити кошти. Співставлення даних про трафік із даними про витрати забезпечує не тільки ефективну роботу мережі, а й економічну доцільність її експлуатації [48].

Таким чином, аналіз мережевого трафіку є ключовим інструментом для підтримки надійної, вискоєфективної та захищеної мережі. У сучасних умовах зростаючої складності мереж, що включають мультихмарні середовища, віддалену роботу та пристрої IoT, детальна видимість трафіку є необхідною для ефективного управління мережевими операціями [49-51].

Вимірювання мережевого трафіку є життєво важливим компонентом аналізу мережевого трафіку [52]. Воно передбачає кількісну оцінку обсягу та типів даних, що переміщуються по мережі в певний час. Вимірюючи трафік, адміністратори мережі можуть розуміти навантаження на свою мережу, відстежувати моделі використання та ефективно керувати пропускнуою здатністю. Іншими словами, вимірювання перетворює необроблений потік пакетів на значущі метрики, такі як байти в секунду, пакети в секунду або найпоширеніші протоколи, які можна аналізувати та використовувати для прогнозування тенденцій.

Вимірювання трафіку забезпечує кілька ключових переваг та є невід'ємною частиною ефективних мережевих операцій. По-перше, воно дає обізнаність про

використання мережевих ресурсів. Знання того, яка частина потужності мережі використовується в будь-який момент часу, є фундаментальним для планування та управління мережею. Вимірювання трафіку дозволяє визначити базове використання та пікові навантаження, що допомагає в плануванні оновлень і забезпеченні того, щоб канали не були ні недостатньо, ні надмірно завантажені. Наприклад, постійна робота ланцюга WAN на 90% у години пікових навантажень сигналізує про необхідність збільшення пропускної здатності або проведення оптимізації маршрутизації.

По-друге, вимірювання трафіку дає уявлення про моделі використання. Воно показує щоденні піки, які програми або служби генерують найбільше трафіку та як трафік розподіляється між сегментами мережі. Ця інформація допомагає оптимізувати продуктивність мережі, наприклад, шляхом планування інтенсивних передач даних у непікові години, а також керувати точками перевантаження. Розуміння того, хто і що споживає пропускну здатність, корисне для проектування мережі та розробки політик управління ресурсами.

По-третє, вимірювання трафіку сприяє усуненню несправностей та підвищує видимість безпеки. Завдяки детальним вимірюванням оператори можуть швидко виявляти аномалії або раптові зміни, які вказують на проблеми. Раптовий сплеск трафіку на зазвичай тихому каналі може свідчити про DDoS-атаку або неправильну конфігурацію. Постійне вимірювання трафіку забезпечує команди базовими даними для виявлення нетипових умов як у контексті продуктивності, так і безпеки.

Крім того, вимірювання трафіку дозволяє ефективно управляти пропускну здатністю та якістю обслуговування (QoS). Воно дає змогу визначити основних споживачів ресурсів або програми з високим навантаженням та застосовувати правила QoS або обмеження швидкості, щоб гарантувати справедливий розподіл ресурсів. Це також забезпечує необхідну пропускну здатність для критично важливих послуг.

Існують дві основні методології вимірювання мережевого трафіку, що зосереджуються на різних аспектах даних. Перший підхід – вимірювання на основі об'єму, яке кількісно визначає загальну кількість даних, що передаються через

мережу протягом певного періоду. Воно враховує такі показники, як передані байти, кількість пакетів та відсоток використання каналів. Для цього використовуються інструменти та протоколи, такі як SNMP та потокова телеметрія з мережевих пристроїв. SNMP дозволяє опитувати лічильники інтерфейсів для оцінки обсягів трафіку, а сучасна потокова телеметрія може передавати ці показники в режимі реального часу, що забезпечує постійний огляд використання пропускної здатності та базовий моніторинг.

Другий підхід – вимірювання на основі потоку, яке зосереджується на потоках, тобто наборах пакетів із спільними властивостями, такими як IP-адреси, порти та протокол. Інструменти на основі потоку узагальнюють трафік з точки зору розмов або потоків, що дає детальне уявлення про взаємодію між хостами та використання додатків. Класичними прикладами таких технологій є NetFlow, IPFIX і sFlow. Вони дозволяють збирати записи потоків, які показують, який хост спілкувався з яким, за яким протоколом і з яким обсягом даних. Аналіз цих записів надає детальну інформацію про схеми трафіку, основних споживачів і використання додатків. Вимірювання на основі потоку важливе для розуміння складу трафіку, а не лише його обсягу.

Окрім основних методів, спеціалізоване апаратне або програмне забезпечення допомагає вимірювати трафік більш ефективно. Мережеві брокери пакетів (NPB) та TAP пристрої об'єднують і дублюють трафік із декількох посилянь, що дозволяє інструментам моніторингу отримувати копію трафіку для аналізу без впливу на основний потік. Вони можуть фільтрувати та спрямовувати трафік на аналітичні інструменти, забезпечуючи централізоване та ефективне збирання даних у великих мережах. Також існують комплексні платформи моніторингу, які поєднують дані про потоки, метрики SNMP та захоплення пакетів, створюючи єдине уявлення про мережевий трафік у різних сегментах.

Використання цих методів та інструментів дозволяє мережевим операторам ефективно вимірювати трафік, отримувати детальну інформацію про використання ресурсів і приймати обґрунтовані рішення для забезпечення продуктивності, безпеки та надійності мережі.

Після отримання необроблених даних за допомогою різних методів вимірювання наступним етапом є безпосередній аналіз мережевого трафіку. Існує кілька підходів до збору та аналізу таких даних, кожен з яких орієнтований на різні аспекти функціонування мережі та має власні сфери застосування. У практичних умовах ці методи не протиставляються один одному, а доповнюють, формуючи комплексне уявлення про стан і поведінку мережі.

Одним із найбільш поширених підходів є аналіз на основі потоків. Він полягає у зборі записів потоків із мережевих пристроїв, таких як маршрутизатори, комутатори або міжмережеві екрани, та подальшому їх узагальненні. Протоколи потокової телеметрії формують записи, що описують мережеві «розмови», включаючи інформацію про джерело та призначення, використаний протокол, обсяг переданих даних і тривалість сеансу. Такий підхід дозволяє визначати основні джерела і приймачі трафіку, аналізувати споживання пропускну здатності окремими додатками та будувати матриці обміну між сегментами мережі. Аналіз потоків є добре масштабованим, оскільки значно зменшує обсяг даних у порівнянні з повним захопленням пакетів, зберігаючи при цьому важливу інформацію про структуру трафіку. Він застосовується як у традиційних локальних мережах, так і у віртуалізованих та хмарних середовищах, де дозволяє виявляти зміни в маршрутизації, дисбаланс навантаження або нетипові шаблони обміну даними.

Більш глибокий рівень дослідження забезпечує аналіз на основі пакетів, який передбачає захоплення та детальний розбір реальних пакетів, що передаються мережею. Цей метод дає змогу аналізувати як заголовки, так і корисне навантаження пакетів, що є основою для глибокої перевірки пакетів. Такий підхід дозволяє виявляти помилки на рівні протоколів, детально досліджувати транзакції прикладного рівня та аналізувати вміст незашифрованого трафіку. Разом з тим аналіз пакетів є ресурсомістким, оскільки захоплення і зберігання всього трафіку на високонавантажених каналах практично неможливе в довгостроковій перспективі. Тому він зазвичай використовується вибірково, наприклад, під час розслідування інцидентів або для діагностики конкретних проблем. У поєднанні з поточним аналізом цей метод дозволяє переходити від загальної картини до

детального дослідження окремих аномалій.

Важливим доповненням до аналізу потоків і пакетів є аналіз на основі журналів. Мережеві пристрої, сервери та прикладні системи постійно генерують журнали подій, які містять відомості про встановлені з'єднання, помилки, спроби доступу та інші аспекти мережевої активності. Збирання і кореляція таких журналів дозволяють виявляти шаблони поведінки, що не завжди очевидні лише з видимості трафіку. Наприклад, журнали міжмережєвих екранів можуть показувати повторювані заблоковані спроби підключення, а журнали DNS – підозрілі запити до нетипових доменів. Аналіз журналів забезпечує контекст подій і дозволяє пов'язувати мережеві явища з діями користувачів або системними подіями, що значно збагачує загальний аналіз.

Окрему категорію становить синтетичний моніторинг, який відрізняється від попередніх методів активним характером. Замість спостереження за реальним трафіком користувачів у цьому випадку створюється контрольований штучний трафік або тестові транзакції. Регулярне виконання пінгів, трасувань або запитів до сервісів дозволяє оцінювати затримку, втрату пакетів, джиттер і доступність ключових ресурсів. Такий підхід дає змогу виявляти проблеми ще до того, як вони почнуть впливати на кінцевих користувачів, і часто використовується для оцінки якості користувацького досвіду. Синтетичні вимірювання добре доповнюють пасивний аналіз, оскільки дозволяють порівнювати очікувану поведінку мережі з реальною.

Загалом кожен із розглянутих методів надає власний «зріз» інформації про мережевий трафік. Поточковий аналіз забезпечує масштабовану оглядову картину, аналіз пакетів дозволяє заглибитися в деталі, журнали додають контекст подій, а синтетичний моніторинг дає змогу активно перевіряти стан мережі. Їх поєднання формує цілісну стратегію аналізу мережевого трафіку, яка є необхідною для забезпечення продуктивності, надійності та безпеки сучасних мереж.

Існує широкий спектр інструментів і платформ для збору та аналізу мережевого трафіку, що допомагають операторам ефективно оцінювати стан мережі та приймати обґрунтовані рішення щодо управління нею. До таких рішень

належать як утиліти з відкритим вихідним кодом, так і комерційне програмне забезпечення та SaaS-платформи.

Одним із найпоширеніших інструментів для аналізу пакетів є Wireshark, який дозволяє захоплювати та детально досліджувати мережевий трафік на рівні окремих пакетів. Цей інструмент забезпечує доступ до заголовків і корисного навантаження пакетів, відстеження TCP-сесій і розшифрування численних протоколів. Wireshark особливо цінний для глибокого аналізу проблем мережі або дослідження інцидентів безпеки, проте через обсяг оброблюваних даних його зазвичай застосовують у лабораторних умовах або на обмежених сегментах мережі.

Для комплексного моніторингу продуктивності мережі застосовують рішення на кшталт SolarWinds Network Performance Monitor (NPM). Воно поєднує дані SNMP та потокові показники для надання огляду використання пропускну здатності, стану мережевих пристроїв і сповіщень про порушення порогових значень. Такі платформи дозволяють операторам відстежувати основні додатки, що споживають трафік, і контролювати роботу мережевої інфраструктури в режимі реального часу.

PRTG Network Monitor використовує підхід на основі датчиків, що дозволяє збирати інформацію з різних джерел, включно з SNMP, NetFlow, sFlow, пінгами та HTTP-запитами. Це рішення забезпечує уніфікований моніторинг мережевих пристроїв, додатків і трафіку, надаючи детальні статистичні дані та легкі у використанні інтерфейси для візуалізації. PRTG часто застосовується в малих і середніх організаціях, де важливе поєднання простоти налаштування та широкого спектра функцій.

Для аналізу журналів та подій мережевих пристроїв часто використовують стек ELK (Elasticsearch, Logstash, Kibana). Він дозволяє збирати, індексувати та візуалізувати журнали з різних джерел, включаючи журнали брандмауерів, проксі-серверів і потокові записи. Хоча ELK не є спеціалізованим інструментом для мережевого аналізу, налаштування відповідних конекторів дозволяє створювати потужні інформаційні панелі, проводити пошук і кореляцію подій, а також здійснювати довгострокове зберігання даних. Стек ELK активно використовується

для аналітики безпеки та звітності щодо відповідності стандартам.

Додатково існують колектори та інструменти з відкритим вихідним кодом, такі як `nfdump` і `pmacct`, а також спеціалізовані рішення для мережевої криміналістики, наприклад `Zeek` (раніше `Bro`) [46]. Кожен із цих інструментів має свої сильні сторони: одні забезпечують сповіщення в режимі реального часу, інші – глибокий аналіз пакетів або зручне довгострокове зберігання даних. Часто організації комбінують кілька рішень для досягнення оптимального покриття. У сучасних мережах дедалі популярнішими стають платформи, що інтегрують різні методи аналізу – потоки, SNMP, синтетичний моніторинг та інші джерела даних – в єдину систему, забезпечуючи централізовану видимість і аналітику трафіку.

Щоб отримати максимальну користь від аналізу мережевого трафіку, варто дотримуватися певних найкращих практик. Насамперед необхідно встановити базові значення, які відображають «нормальний» стан мережі. Це включає типовий розподіл трафіку, середнє використання смуги пропускання та щоденні піки. Базові показники допомагають легко відрізнити закономірні зміни, наприклад розширення бізнесу, від аномальних сплесків, які можуть сигналізувати про атаки або несправності.

Необхідно використовувати кілька джерел даних, не обмежуючись одним типом телеметрії. Поєднання даних потоків, захоплення пакетів і журналів дає більш повну картину продуктивності та безпеки мережі. Різні джерела доповнюють одне одного: записи потоків можуть показати підозрілі зв'язки, аналіз пакетів виявити їх зміст, а журнали відобразити часову шкалу подій. Таке багатоджерельне спостереження є основою сучасної видимості мережевих процесів.

Важливо поєднувати дані в режимі реального часу та історичні дані. Моніторинг у реальному часі дозволяє швидко реагувати на збої та атаки, тоді як історичний аналіз допомагає виявляти довгострокові тенденції, планувати пропускну здатність і передбачати повторні інциденти. Оптимальним є використання інструментів, що підтримують обидва типи аналізу, забезпечуючи як миттєву видимість, так і контекст для стратегічного планування.

Автоматизація виявлення аномалій є ключовим аспектом ефективного

моніторингу. Використання алгоритмів штучного інтелекту та машинного навчання дозволяє визначати відхилення від базових значень, які вручну важко помітити. Такі системи можуть позначати незвичні зміни в трафіку або шаблонах поведінки мережі, що допомагає скоротити час реагування та зусилля операторів.

Не менш важливо інтегрувати інструменти аналізу трафіку з іншими ІТ-системами, включно з SIEM, платформами управління інцидентами та системами оркестрації. Це дозволяє отримати цілісний погляд на стан мережі, автоматично реагувати на інциденти та ефективніше використовувати наявні ресурси.

Постійний моніторинг і оптимізація процесів є ще однією критичною практикою. Мережі постійно змінюються – з'являються нові додатки, збільшується пропускна здатність і зростає хмарне навантаження. Регулярне оновлення інформаційних панелей, перевірка охоплення моніторингу та оптимізація конфігурацій забезпечують актуальність і ефективність аналізу.

Безпека повинна бути пріоритетом. Аналіз трафіку слід розглядати не лише як засіб оцінки продуктивності, але й як систему раннього попередження про атаки та порушення. Необхідно моніторити підозрілі IP-адреси, внутрішній трафік для виявлення бічного руху та аномальні шаблони, що можуть свідчити про DDoS-атаки або інші загрози.

Дотримання цих практик дозволяє перетворити дані про трафік на реальну цінність, роблячи мережу більш стабільною, безпечною та ефективною.

## 2.2 Виявлення аномалій у вебдодатках

Виявлення аномалій мережі - це процес виявлення нерегулярних або нетипових моделей у мережевому трафіку, які відхиляються від нормальної поведінки. За своєю суттю, виявлення мережевих аномалій передбачає постійний збір даних мережевої телеметрії, таких як записи потоків, пакети або журнали, і порівняння їх з базовою лінією нормальної поведінки мережі. Базовий рівень встановлюється з використанням історичних даних та статистичного аналізу того,

як виглядає «нормальний» трафік з точки зору обсягу, протоколів, IP-адрес, шаблонів доступу користувачів тощо. Коли поточні моделі трафіку значно відхиляються від цієї базової лінії, система позначає мережеву аномалію [53-55].

Розуміння типів аномалій має вирішальне значення для ефективного проектування та впровадження систем виявлення аномалій. Кожен тип аномалії представляє набір унікальних проблем і вимагає різних аналітичних підходів для їхнього виявлення. Як правило, аномалії можна класифікувати на три основні категорії: точкові, контекстні та колективні [56].

Точкові аномалії виникають, коли окремих екземпляр даних значно відхиляється від очікуваного діапазону значень. Вони часто є найпростішими для виявлення, проте можуть мати серйозні наслідки. Наприклад, у фінансовій сфері незвично велика транзакція порівняно з типовими витратами клієнта може сигналізувати про шахрайство з кредитними картками. В охороні здоров'я раптовий сплеск серцевого ритму пацієнта, що виходить за межі його нормального діапазону, може вказувати на необхідність невідкладної медичної допомоги. Однією з проблем виявлення точкових аномалій є те, що вони можуть бути замасковані шумом у даних, що робить попередню обробку та точний вибір порогових значень критично важливими [57].

Контекстні аномалії можна ідентифікувати лише тоді, коли дані розглядаються у певному контексті: те, що здається нормальним в одній ситуації, може бути аномальним в іншій. Вони особливо актуальні для часових рядів і просторових даних. Наприклад, у сфері управління енергією сплеск споживання електроенергії в піковий денний час є нормальним, тоді як такий самий сплеск о третій ранку може свідчити про ненормальну поведінку обладнання. У роздрібній торгівлі раптове падіння онлайн-замовлень може бути очікуваним протягом міжсезонних періодів, але викликати занепокоєння під час великої святкової акції. Виявлення таких аномалій потребує врахування контекстних змінних, таких як час, місце розташування або профіль користувача, а не лише необроблених значень.

Колективні аномалії виникають, коли група окремих точок даних виглядає нормальною окремо, але в сукупності створює підозрілий або аномальний патерн.

Вони часто складніші для виявлення, оскільки нерегулярність проявляється не в одній точці, а в групі даних. Наприклад, у кібербезпеці послідовність спроб входу з різних глобальних локацій протягом декількох хвилин може свідчити про скоординовану атаку. У виробничій сфері серія невеликих коливань показань датчиків машин у сукупності може сигналізувати про деградацію обладнання. Виявлення колективних аномалій потребує використання моделей, здатних аналізувати послідовності або кластери даних, таких як рекурентні нейронні мережі чи алгоритми кластеризації [58].

Виявлення аномалій за допомогою штучного інтелекту є складним і структурованим процесом, який поєднує інженерію даних, проектування моделі та безперервне вдосконалення системи. Кожен етап побудований на результатах попереднього, що дозволяє створювати систему, яка з часом навчається, адаптується та підвищує свою точність.

Процес виявлення аномалій починається зі збору та попередньої обробки даних. Якість, різноманітність та узгодженість даних визначають ефективність роботи моделі. Джерела даних можуть включати транзакційні записи, показання датчиків, журнали подій або потоки активності користувачів. Перед тим як дані стануть придатними для аналізу, їх необхідно очистити від помилок, нормалізувати для забезпечення узгодженості форматів і сегментувати на значущі категорії. Такий підхід дозволяє уникнути перевантаження моделі шумом та гарантує, що виявлені закономірності відображають реальні події, а не випадкові артефакти.

Наступним етапом є вибір функцій, тобто характеристик даних, які несуть найбільшу інформаційну цінність для виявлення аномалій. У фінансових наборах даних це можуть бути сума транзакції, частота операцій та місцезнаходження, а не ім'я клієнта. В охороні здоров'я життєві показники пацієнтів з часом можуть сигналізувати про відхилення краще, ніж статичні демографічні дані. Ретельна інженерія ознак є критично важливою: надлишок нерелевантних змінних знижує точність моделі, тоді як правильно підібрані ознаки дозволяють чітко розділяти нормальні та аномальні патерни поведінки.

Після визначення ключових ознак відбувається навчання моделі штучного

інтелекту. Історичні дані, де відомі «нормальні» шаблони поведінки, використовуються для навчання системи. Застосовуються методи машинного навчання, такі як кластеризація чи класифікація, а також методи глибокого навчання, зокрема автокодери або рекурентні нейронні мережі. Мета навчання полягає в тому, щоб модель чітко розуміла, як виглядає нормальна поведінка в різних контекстах, щоб відхилення від неї були легко виявлені.

Після навчання система здатна обробляти нові дані як у режимі реального часу, так і в пакетному режимі. Вона постійно порівнює вхідні дані зі своєю навченою базовою моделлю, позначаючи ті точки або послідовності, які суттєво відрізняються від очікуваного. Наприклад, раптовий сплеск невдалих спроб входу в систему може вважатися підозрілим, а падіння показань датчиків обладнання може сигналізувати про майбутній збій. Точність виявлення залежить від якості навчання моделі та репрезентативності навчальних даних.

Ключовим етапом є зворотний зв'язок і постійне вдосконалення системи. Системи виявлення аномалій не можуть залишатися статичними, оскільки з часом те, що раніше вважалось аномалією, може стати новою нормою, наприклад, сплески онлайн-покупок під час святкових періодів. Аналітики перевіряють позначені аномалії, підтверджують їхню справжню природу і повертають цю інформацію до системи. Такий ітераційний процес дозволяє коригувати порогові значення, знижувати кількість помилкових спрацьовувань та підвищувати точність, забезпечуючи адаптацію моделі до постійно змінюваних патернів у даних.

Використання штучного інтелекту для виявлення аномалій надає явні переваги порівняно з традиційними методами на основі правил. Системи виявлення аномалій, побудовані на основі ШІ, аналізують історичні дані, щоб глибше зрозуміти нормальну поведінку, ніж це дозволяють статичні порогові значення. Це забезпечує більш точне виявлення незвичних патернів даних навіть тоді, коли відхилення є незначними.

Зі зростанням обсягів даних масштабованість стає критично важливою. Моделі ШІ здатні обробляти мільйони записів без втрати швидкості або точності,

що робить їх придатними для галузей із великими безперервними потоками даних. Крім того, на відміну від традиційних методів, які часто працюють пакетно і залишають «сліпі зони», системи на базі ШІ підтримують безперервний моніторинг, виявляючи відхилення у мережевому трафіку, транзакціях або даних сенсорів у режимі реального часу. Це дозволяє швидше реагувати на інциденти та мінімізувати потенційні збитки.

Нормальна поведінка не є статичною – ділові цикли, сезонні тенденції чи нові методи атак можуть змінювати уявлення про «норму». Системи ШІ автоматично адаптуються до таких змін, що зменшує потребу в постійній ручній перенастройці. Однією з найбільших проблем старих систем була велика кількість хибних спрацювань. Моделі ШІ зменшують цей шум, поступово навчаючись враховувати контекст і уточнювати правила виявлення, що дозволяє командам зосереджуватися на реальних ризиках, а не на хибних тривогах.

Покращене виявлення аномалій також призводить до скорочення збоїв у роботі, зменшення випадків шахрайства та простоїв, що безпосередньо підвищує операційну ефективність та знижує витрати, особливо в галузях, де навіть невеликі аномалії можуть мати значні фінансові або безпекові наслідки. Крім того, використання ШІ для виявлення аномалій забезпечує цінні інсайти щодо поведінки системи, активності користувачів та операційних тенденцій, що дозволяє керівникам приймати рішення на основі даних, оптимізувати процеси та передбачати майбутні ризики.

Виявлення аномалій за допомогою штучного інтелекту стикається з низкою серйозних викликів, що впливають на ефективність та надійність таких систем. Одним із основних труднощів є маркування аномалій. Аномалії за своєю природою є рідкісними подіями, тому отримання достовірно позначених даних у багатьох сценаріях виявлення аномалій обмежене. Нестача таких прикладів ускладнює навчання моделі та точне визначення, що саме вважається аномалією. Для подолання цієї проблеми використовуються методи без нагляду або напівнагляду, які дозволяють моделі виявляти закономірності та аномалії без потреби у великому наборі маркованих даних.

Ще одним важливим викликом є зменшення хибних спрацювань, коли нормальні події помилково позначаються як аномалії. Для практичного використання систем виявлення аномалій критично важливо досягти балансу між чутливістю моделі та ігноруванням нормальних варіацій даних. Використання сучасних методів машинного навчання, таких як порогова оцінка аномалій і впровадження циклів зворотного зв'язку, дозволяє підвищити точність виявлення та зменшити кількість хибних спрацювань.

Масштабованість систем також є важливим аспектом. У міру зростання обсягів даних здатність системи обробляти та аналізувати великі набори даних у режимі реального часу стає критичною для своєчасного виявлення аномалій. Використання розподілених обчислювальних платформ та оптимізація алгоритмів для високої продуктивності сприяють ефективному управлінню та аналізу великих обсягів даних.

Інтерпретованість моделей є ще одним викликом. Складність сучасних моделей штучного інтелекту часто ускладнює розуміння того, як приймаються рішення, що особливо проблематично у критично важливих застосуваннях, де довіра та відповідальність є ключовими. Підвищення інтерпретованості передбачає використання методів, які надають прозорість у процесі ухвалення рішень моделі, а також пояснюють користувачу, чому певна поведінка була позначена як аномальна.

Нарешті, системи виявлення аномалій піддаються ризику атак з боку зловмисників, які навмисно маніпулюють даними або моделями, щоб уникнути виявлення. Розробка моделей, здатних розпізнавати та протидіяти таким маніпуляціям, є важливою для збереження цілісності алгоритмів. Крім того, застосування «адверсарного навчання», коли моделі під час тренування піддаються сценаріям атак, дозволяє підвищити їхню стійкість до подібних загроз.

У виявленні аномалій із застосуванням штучного інтелекту використовуються різні техніки для виявлення нерегулярних патернів даних, залежно від природи набору даних, поставленої задачі та наявності маркованих історичних даних.

Серед основних підходів сьогодні виділяють методи з навчанням із учителем та без учителя. У методах навчання з учителем моделі тренуються на маркованих наборах даних, де аномалії вже позначені. Це забезпечує високу точність при наявності якісно маркованих даних, але вимагає значних підготовчих зусиль. У свою чергу, методи без учителя не залежать від маркованих даних. Моделі навчаються визначати нормальну поведінку безпосередньо з даних, а потім позначають відхилення. Це особливо цінно для динамічних середовищ, де аномалії можуть змінюватися з часом.

Методи, засновані на кластеризації, групують точки даних за схожістю. Будь-яка точка, яка суттєво відхиляється від кластера, може сигналізувати про аномалію. Популярні техніки включають k-means, DBSCAN та ієрархічну кластеризацію. Такі методи добре підходять для високорозмірних наборів даних, де аномалії ізольовані або розріджені.

Штучні нейронні мережі та методи глибокого навчання широко застосовуються для складних завдань виявлення аномалій. Автокодери працюють шляхом реконструкції вхідних даних, при цьому великі помилки реконструкції сигнализують про аномалії. Рекурентні нейронні мережі (RNN) добре моделюють послідовні дані, наприклад сеанси користувачів або показники сенсорів, що робить їх ідеальними для виявлення незвичних послідовностей подій.

Техніки виявлення аномалій у часових рядах особливо актуальні для галузей, де дані генеруються послідовно, як-от фінансові транзакції, життєві показники пацієнтів або журнали мережевого трафіку. Такі методи аналізують часові тенденції, щоб виявити нерегулярні коливання або аномальні сплески. До них належать як статистичні моделі, наприклад ARIMA, так і сучасні підходи глибокого навчання, зокрема LSTM (Long Short-Term Memory).

Традиційні статистичні та ймовірнісні методи, такі як z-оцінки, моделі гаусових сумішей або байєсівські мережі, залишаються ефективними. Вони оцінюють ймовірність появи точки даних за припущеними розподілами та позначають ті, що виходять за очікувані межі.

Енсамблеві та гібридні підходи дозволяють підвищити надійність системи,

оскільки жоден метод не є універсальним для всіх сценаріїв. Енсамблеві методи поєднують кілька моделей для підвищення стійкості, а гібридні інтегрують статистичні правила з машинним навчанням для балансу між точністю та адаптивністю. Такі стратегії допомагають зменшити кількість хибних спрацювань та покращити загальну надійність системи виявлення аномалій.

Алгоритми машинного навчання відіграють центральну роль у точному виявленні аномалій. Традиційні методи, такі як кластеризація, моделі на основі відстаней або ймовірнісні підходи, залишаються ефективними для структурованих наборів даних із чіткими статистичними патернами.

Водночас підходи глибокого навчання, зокрема штучні нейронні мережі, такі як автокодери та рекурентні моделі, значно розширили можливості систем для роботи з комплексними, високорозмірними даними, наприклад зображеннями, текстом або мережевим трафіком. Вибір оптимального алгоритму залежить від природи даних, масштабу операцій та типу аномалій, які необхідно виявити.

Серед ключових алгоритмів варто виділити Local Outlier Factor (LOF), який визначає аномалії на основі локальної щільності точок даних. Якщо щільність точки значно нижча, ніж у сусідів, вона позначається як аномальна. LOF особливо ефективний для високорозмірних наборів даних, де аномалії рідкісні та важко виявляються за допомогою стандартної візуалізації [66-67].

Алгоритм K-Nearest Neighbors (kNN), хоча часто використовується для класифікації, може застосовуватися для безнаглядного виявлення аномалій. Замість заздалегідь визначених класів він порівнює відстані між точками даних для виявлення аномалій. Його простота, гнучкість та здатність працювати з великими та малими наборами даних роблять його практичним методом для виявлення як явних, так і тонких аномалій [59-62].

Метод опорних векторів (SVM) широко використовується для задач класифікації, але його можна адаптувати для виявлення аномалій у форматі «one-class». У цьому випадку алгоритм навчається визначати межу нормальної поведінки, а все, що виходить за ці межі, позначається як аномалія. SVM особливо ефективний для виявлення аномалій у структурованих наборах даних із чітко

визначеними ознаками [63-65].

DBSCAN (Density-Based Spatial Clustering of Applications with Noise) – це метод кластеризації на основі щільності, який групує точки даних із подібною щільністю. Точки, що не належать до жодного кластера, позначаються як аномальні. Цей підхід корисний для великих наборів даних із нерегулярними формами кластерів і дозволяє виявляти аномалії без попередньо визначених міток [68].

Автокодери – це штучні нейронні мережі, призначені для стиснення та відновлення даних. Коли помилка відновлення велика, це свідчить про наявність аномалії. Цей метод ефективний для виявлення тонких аномалій, які можуть залишитися непоміченими традиційними статистичними підходами, особливо у складних системах і високорозмірних наборах даних, таких як показники сенсорів, медичні зображення або мережевий трафік.

Байєсівські мережі використовують ймовірнісні залежності між змінними для моделювання взаємозв'язків у даних. Вони особливо ефективні у високорозмірних сценаріях, де аномалії не є очевидними при розгляді окремих змінних. Ці методи дозволяють виявляти аномалії, що проявляються лише при одночасному аналізі кількох змінних, що робить їх цінними у таких сферах, як охорона здоров'я та фінанси.

Роль людського експерта у виявленні аномалій за допомогою штучного інтелекту є критичною для ефективності таких систем. Інтеграція доменної експертизи дозволяє точно визначати, що в конкретному контексті слід вважати аномалією. Фахівці у певній галузі мають глибоке розуміння нормальної та аномальної поведінки у своїй сфері, що є необхідним для налаштування параметрів системи виявлення аномалій. Їхні знання допомагають коректно формувати навчальні дані для моделей ШІ та забезпечують відповідність очікуваним реаліям.

Співпраця між доменними експертами та дата-сайентистами є ключовою в проєктах з виявлення аномалій. Експерти допомагають виділити значущі ознаки та потенційні хибні спрацювання, тоді як фахівці з даних використовують ці знання для розробки та вдосконалення моделей ШІ. Такий підхід забезпечує технічну

надійність і практичну релевантність систем. У сфері безпеки хмарних сервісів ця взаємодія дозволяє точніше виявляти загрози та мінімізувати хибні спрацювання у динамічних умовах.

Навіть при наявності передових моделей ШІ роль людини у тлумаченні та прийнятті рішень щодо виявлених аномалій не можна недооцінювати. Складність аномалій часто потребує тонкого розуміння, яке може виходити за межі можливостей автоматичних систем. Коли ШІ позначає потенційні аномалії, людські експерти відіграють ключову роль у їхній валідації, визначаючи, чи дійсно відхилення є проблемою, чи лише рідкісним випадком, що не потребує втручання.

Безперервне вдосконалення моделей виявлення аномалій значною мірою залежить від людського зворотного зв'язку. Аналіз результатів та коментарі експертів дозволяють дата-сайєнтистам налаштовувати моделі, підвищувати їх точність і зменшувати ймовірність хибних спрацювань у майбутньому. Цей ітеративний процес, коли моделі регулярно оновлюються на основі експертних знань, гарантує, що системи виявлення аномалій еволюціонують відповідно до змінних патернів і нових типів аномалій.

### 2.3 Модель інтелектуального виявлення атак на вебдодатки

Забезпечення інформаційної безпеки вебдодатків в умовах зростання обсягів мережевого трафіку та ускладнення кіберзагроз потребує формалізованих підходів до аналізу HTTP-запитів, здатних адекватно відображати їхні структурні та поведінкові характеристики. У межах даної магістерської роботи розроблено математичну модель інтелектуального виявлення атак на вебдодатки, яка ґрунтується на поєднанні методів машинного навчання Support Vector Machines та K-Nearest Neighbors і забезпечує формалізацію процесу класифікації мережевого трафіку в просторі ознак.

Основою запропонованої моделі є представлення кожного HTTP-запиту у вигляді вектора ознак у  $n$ -вимірному евклідовому просторі. Формально HTTP-

запит описується вектором:

$$x = (x_1, x_2, \dots, x_n), \quad (2.1)$$

де  $x_i$  - кількісні та якісні характеристики HTTP-запиту;  $n$  - розмірність простору ознак.

Множина ознак формується з урахуванням специфіки HTTP-протоколу та типових сценаріїв реалізації атак на вебдодатки. До неї входять параметри, що описують тип HTTP-методу, довжину URL-адреси, розмір тіла запиту, кількість параметрів у запиті, частоту звернень з однієї IP-адреси, часові інтервали між послідовними запитами, а також наявність спеціальних символів, ключових слів і синтаксичних конструкцій, характерних для атак типу SQL injection, Cross-Site Scripting та інших поширених класів вебатак. Для забезпечення коректності математичних операцій передбачається нормалізація числових ознак та кодування категоріальних параметрів, що дозволяє уникнути домінування окремих ознак у процесі класифікації.

Класифікація HTTP-запитів у межах моделі здійснюється у два послідовні рівні. На першому рівні використовується алгоритм Support Vector Machines, призначений для побудови оптимальної розділювальної гіперплощини між класами «нормальний трафік» та «атака» у просторі ознак. Рішення SVM визначається знаковою функцією:

$$f_{SVM}(x) = \left( \sum_{i=1}^m \alpha_i y_i K(x_i, x) + b \right), \quad (2.2)$$

де  $x_i$  опорні вектори;  $y_i \in \{-1, +1\}$  – мітки класів;  $\alpha_i$  – вагові коефіцієнти, отримані в процесі навчання;  $K(\cdot)$  – ядрова функція;  $b$  – параметр зміщення;  $m$  – кількість опорних векторів.

Другий рівень класифікації реалізується з використанням алгоритму K-Nearest Neighbors, який дозволяє здійснювати уточнення результатів у випадках, коли об'єкт не має чітко виражених ознак належності до одного з класів. Алгоритм

KNN визначає клас HTTP-запиту на основі аналізу локального оточення вектора ознак у просторі шляхом вибору  $k$  найближчих сусідів відповідно до евклідової метрики відстані. Клас об'єкта визначається за правилом більшості:

$$y = \{x_j \in N_k(x)\}, \quad (2.3)$$

де  $N_k(x)$  – множина  $k$  найближчих сусідів вектора  $x$ ;  $y_j$  – клас відповідного сусіднього вектора.

Узагальнена функція прийняття рішення в межах комбінованої моделі SVM–KNN визначається таким чином:

$$F(x) = \begin{cases} \text{атака,} & f_{SVM}(x) = -1, \\ \text{атака,} & f_{SVM}(x) = +1 \wedge f_{KNN}(x) = -1, \\ \text{норма,} & \text{в іншому випадку.} \end{cases} \quad (2.4)$$

де  $f_{SVM}(x)$  результат класифікації вхідного вектора  $x$  методом опорних векторів;  $f_{KNN}(x)$  – результат класифікації вхідного вектора  $x$  методом  $k$  найближчих сусідів;  $F(x)$  – узагальнене рішення комбінованої моделі; «атака» та «норма» – відповідні класи вебзапитів.

Така формалізація дозволяє описати процес класифікації HTTP-запитів як композицію двох функцій прийняття рішень, що поєднують глобальне розділення класів та локальний аналіз аномалій. Запропонована математична модель задає формальний опис інтелектуального виявлення атак на вебдодатки, забезпечуючи узгоджене використання детермінованих та локально-адаптивних методів класифікації. Вона створює теоретичну основу для побудови алгоритмічного методу, реалізації програмного модуля та проведення експериментальних досліджень ефективності виявлення атак у мережевому трафіку.

## 2.4 Метод інтелектуального виявлення атак на вебдодатки

Запропонований метод інтелектуального виявлення атак на вебдодатки базується на комбінованому аналізі HTTP-трафіку з використанням алгоритмів машинного навчання Support Vector Machines та K-Nearest Neighbors. Метод орієнтований на практичне застосування в системах моніторингу вебтрафіку та забезпечує виявлення як відомих атак, так і аномальних запитів, що не мають явно виражених сигнатур.

На відміну від традиційних сигнатурних підходів, запропонований метод використовує аналіз ознакового простору HTTP-запитів, що дозволяє враховувати не лише структурні параметри запитів, але й поведінкові характеристики взаємодії клієнтів із вебдодатком. Центральним елементом методу є дворівнева схема класифікації, у межах якої поєднуються детермінований та адаптивний підходи до аналізу мережевого трафіку.

Метод реалізується у вигляді послідовного процесу, який включає такі основні етапи:

- приймання HTTP-запитів та їх попередню обробку з метою виділення значущих параметрів протоколу;
- формування вектора ознак, що відображає структурні та поведінкові характеристики запиту;
- нормалізацію та кодування ознак для забезпечення коректної роботи алгоритмів машинного навчання;
- первинну класифікацію HTTP-запитів із використанням алгоритму Support Vector Machines;
- додатковий аналіз запитів, віднесених до нормального трафіку, за допомогою алгоритму K-Nearest Neighbors;
- формування остаточного рішення щодо належності запиту до класу атак або нормального трафіку.

На першому рівні аналізу алгоритм SVM використовується для швидкого виявлення HTTP-запитів, що мають явно виражені ознаки шкідливої активності. Завдяки здатності ефективно працювати у високорозмірних просторах ознак, SVM забезпечує точну класифікацію запитів та дозволяє суттєво зменшити обсяг

трафіку, що потребує подальшого аналізу.

Другий рівень аналізу реалізується з використанням алгоритму KNN та призначений для виявлення аномальних HTTP-запитів, поведінка яких відрізняється від типового нормального трафіку, але не відповідає відомим сигнатурам атак. Застосування KNN дозволяє адаптувати метод до появи нових типів атак та змін у поведінці користувачів без необхідності повної перебудови системи.

Загальна логіка роботи методу передбачає, що рішення про наявність атаки приймається на основі результатів обох алгоритмів. Такий підхід забезпечує зниження кількості хибнопозитивних спрацьовувань та підвищує загальну точність виявлення атак у порівнянні з використанням одного алгоритму машинного навчання (рис. 2.1).

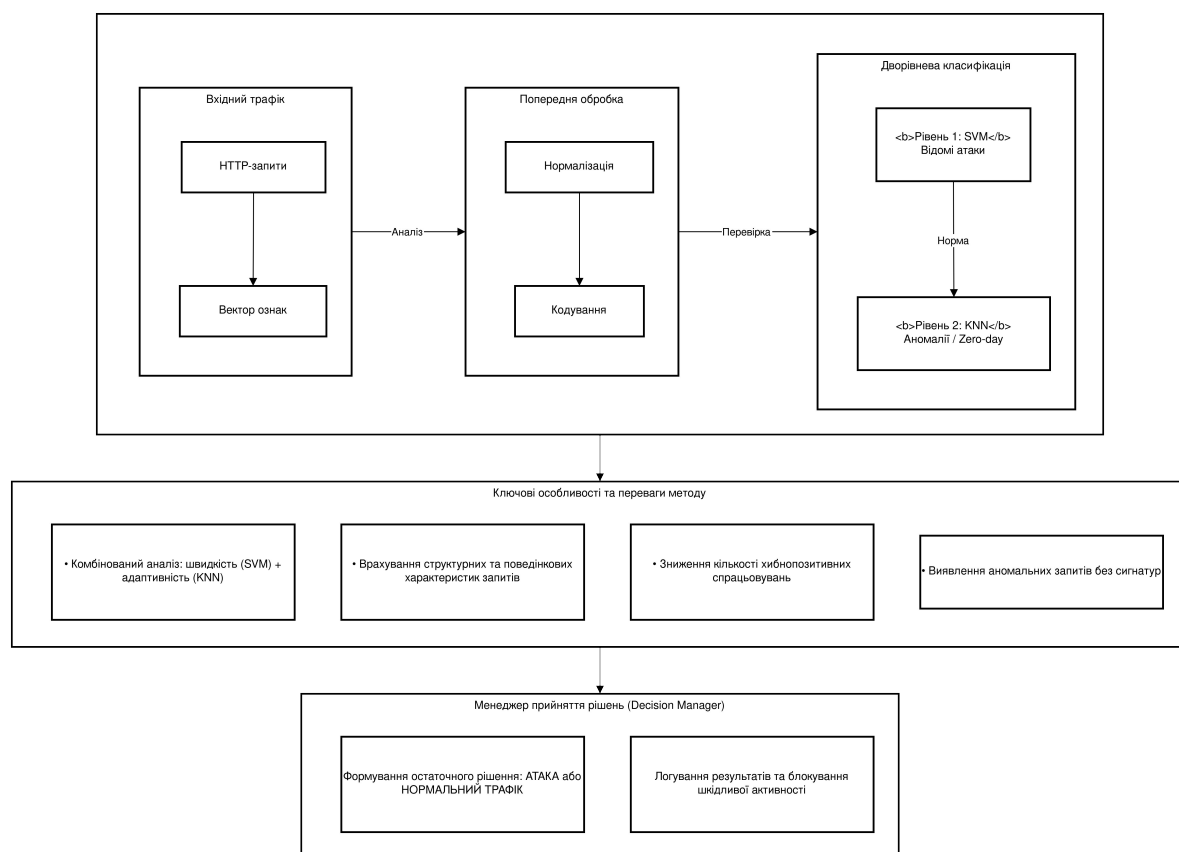


Рисунок 2.1 – Схема методу інтелектуального виявлення атак

Перевагами запропонованого методу є висока швидкість за рахунок

дворівневої схеми аналізу, здатність виявляти як відомі, так і раніше невідомі атаки, а також масштабованість при зростанні обсягів мережевого трафіку. Метод може бути інтегрований у системи захисту вебдодатків, міжмережеві екрани та платформи моніторингу безпеки.

До обмежень методу належать залежність якості виявлення атак від повноти та репрезентативності навчальної вибірки, а також можливість виникнення хибнопозитивних результатів у разі різких змін у поведінці легітимних користувачів. Водночас ці обмеження можуть бути зменшені шляхом періодичного оновлення навчальних даних та коригування параметрів алгоритмів.

Таким чином, запропонований метод інтелектуального виявлення атак на вебдодатки забезпечує ефективне поєднання швидкої детермінованої класифікації та адаптивного аналізу аномалій, що робить його придатним для практичного використання в сучасних вебсистемах.

## 2.5 Висновки

У розділі було детально розглянуто застосування штучного інтелекту для забезпечення безпеки вебдодатків, включаючи основи роботи з вебтрафіком, методи виявлення аномалій і атак, а також інтеграцію алгоритмів машинного навчання у системи захисту. Було обґрунтовано принципи формування ознак HTTP-запитів та їхнє представлення у багатовимірному просторі, що дозволяє ефективно застосовувати методи машинного навчання для класифікації трафіку. Особлива увага приділялася підготовці даних, включаючи нормалізацію числових параметрів та кодування категоріальних ознак, що забезпечує стабільну роботу алгоритмів і підвищує точність виявлення шкідливих запитів.

Розглянуто основні методи виявлення аномалій і атак, зокрема алгоритми класифікації та детекції нетипової поведінки трафіку. Показано, що застосування адаптивних методів машинного навчання дозволяє виявляти нові типи атак, які не описані сигнатурами, і забезпечує можливість автоматичного реагування на зміну

поведінки користувачів та потенційних зловмисників. Було підкреслено, що успішна інтеграція ШІ в системи захисту вимагає поєднання високої точності алгоритмів із можливістю швидкої обробки великих обсягів НТТР-трафіку, що особливо важливо для хмарних та розподілених вебсистем.

Розроблено комбінований метод інтелектуального виявлення атак на основі алгоритмів SVM і KNN, який забезпечує багаторівневу класифікацію НТТР-запитів: первинну детерміновану фільтрацію шкідливих запитів і додатковий аналіз аномальних запитів. Запропонована модель дозволяє ефективно виявляти як відомі, так і нові типи атак, зменшує кількість хибних спрацьовувань, забезпечує масштабованість при обробці великого обсягу трафіку та дає змогу динамічно адаптуватися до змін поведінки користувачів і атакуючих.

Таким чином, сформовано теоретичні та практичні основи використання ШІ для захисту вебдодатків, розроблено методику побудови ознакового простору НТТР-запитів та запропоновано ефективний інтелектуальний метод виявлення атак на основі комбінованої класифікації SVM–KNN. Застосування запропонованої моделі дозволяє підвищити рівень інформаційної безпеки вебдодатків, зменшити ризики витоку даних і фінансових втрат, а також забезпечує практичну придатність для використання в сучасних високонавантажених вебсистемах.

## 3 ПРОГРАМНА РЕАЛІЗАЦІЯ МОДУЛЯ ВИЯВЛЕННЯ АТАК

### 3.1 Програмна реалізація

Архітектура розробленої системи виявлення атак спроектована з урахуванням вимог до гнучкості, масштабованості та інтеграції з іншими безпековими інструментами. Вона має модульну структуру, що забезпечує простоту налаштувань і можливість адаптації до різних вебдодатків, побудованих на основі популярного фреймворку Django [70]. Таке проектування дозволяє легко інтегрувати систему без необхідності значних змін у основному коді вебдодатка, що, у свою чергу, дозволяє скоротити час на розгортання і налаштування нових інстанцій системи на різних проектах (рис. 3.1).

Оскільки безпека вебдодатків є важливою частиною забезпечення безперебійної роботи сучасних інтернет-ресурсів, система виявлення атак має на меті не лише захист від відомих загроз, але й здатність адаптуватися до нових, невідомих атак. Всі компоненти цієї системи спроектовані так, щоб вони могли працювати спільно, утворюючи єдину цілісну структуру для ефективного аналізу трафіку і виявлення аномалій.

На основі Django створено ефективний вебсервер, який обробляє всі HTTP-запити. Першочергове завдання цього сервера – правильно розподілити запити та передати їх на наступні етапи обробки. Проте для забезпечення безпеки вебдодатку важливим є попередній етап обробки запитів, що здійснюється через механізм *middleware*, який дає можливість здійснити первинну перевірку і фільтрацію трафіку до того, як він потрапить до основної логіки додатка. Це дозволяє значно знизити ймовірність проникнення шкідливих запитів, не впливаючи при цьому на кінцевого користувача.

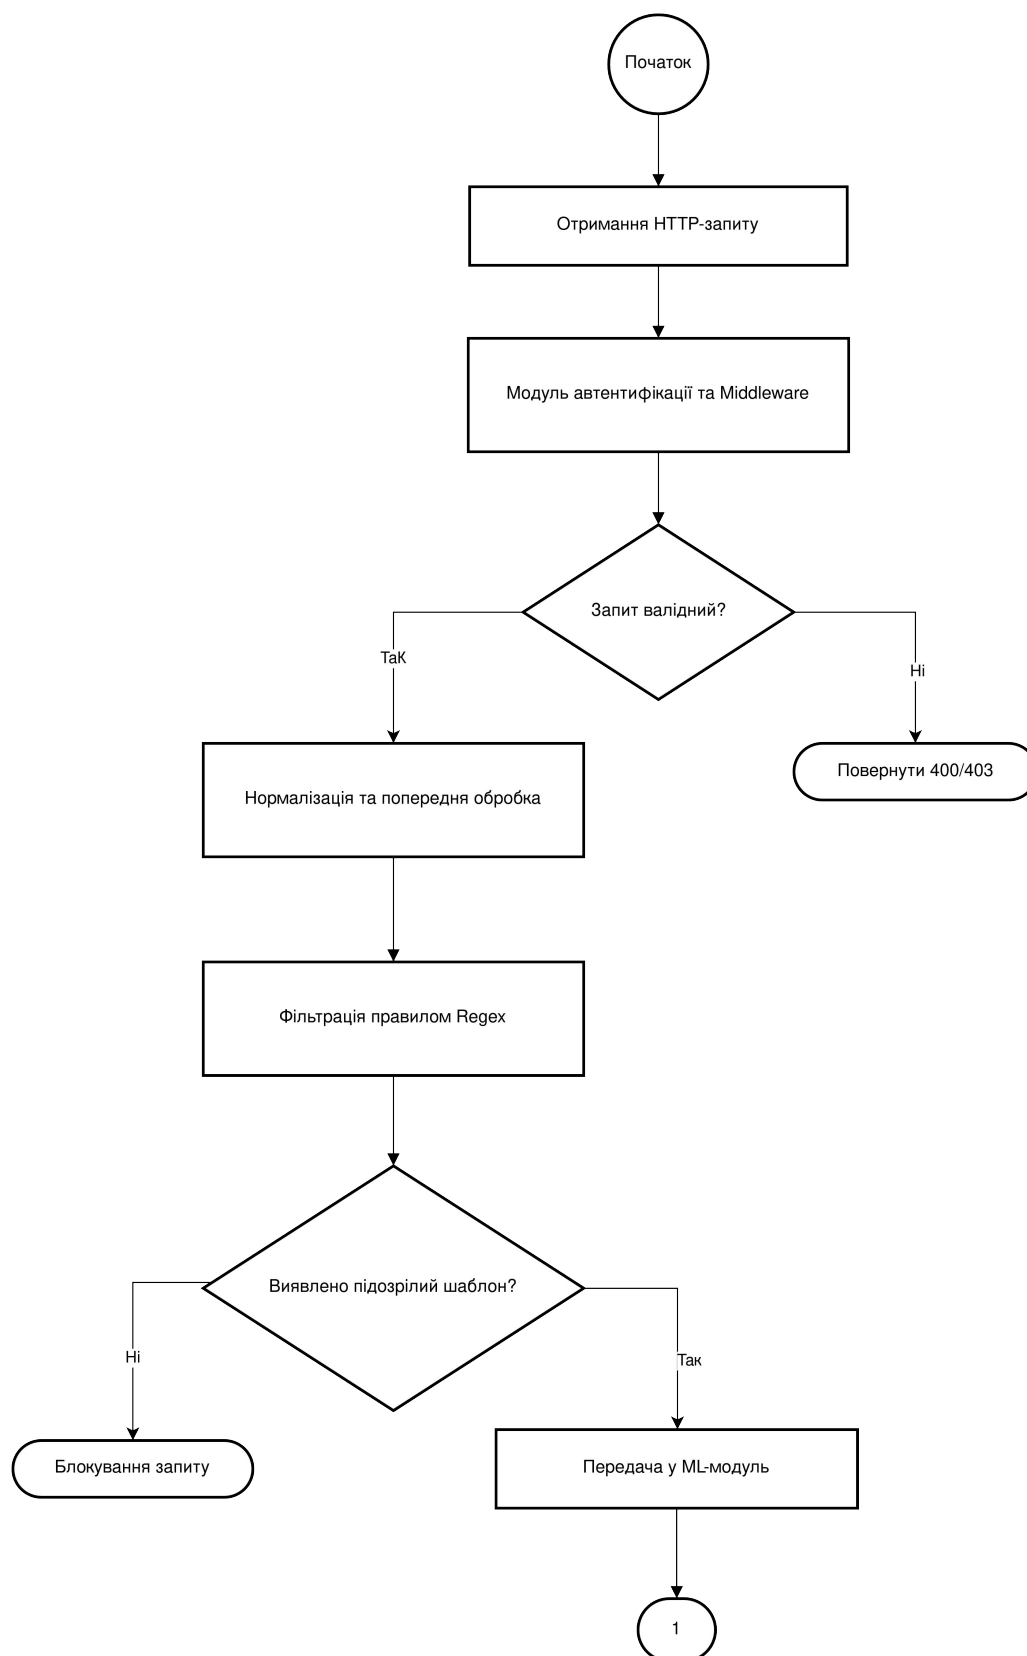


Рисунок 3.1 – Схема роботи інтелектуального модуля виявлення атак

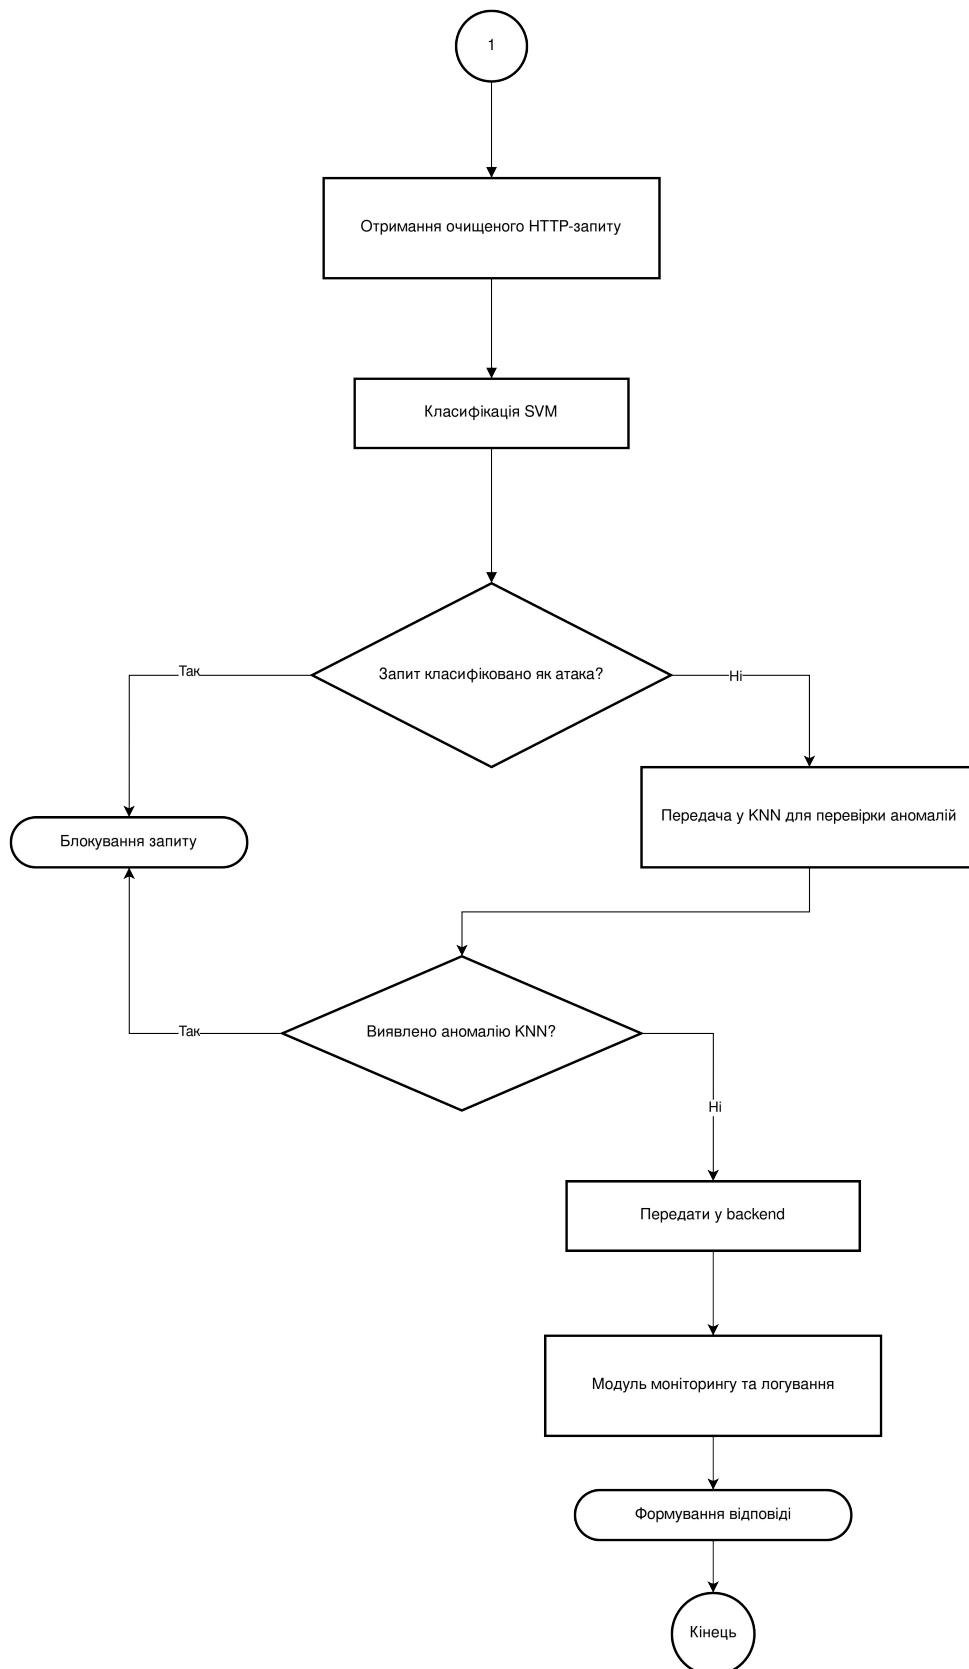


Рисунок 3.1– Схема роботи інтелектуального модуля виявлення атак  
(продовження)

Middleware, інтегрований у стек обробки запитів Django, перехоплює кожен HTTP-запит на самому початку його обробки. На цьому етапі здійснюється перевірка вхідних даних на наявність відомих загроз, що дозволяє відхиляти або модифікувати запити до того, як вони потрапляють до основної бізнес-логіки додатка. Оскільки цей компонент працює прозоро для користувачів, система не викликає додаткових затримок у відповіді сервера, що забезпечує непомітну роботу захисту [69].

Після первинної перевірки запит передається до модуля фільтрації трафіку, що є наступним етапом обробки. Це модуль, який використовує регулярні вирази для виявлення небезпечних патернів у запитах, таких як типові ознаки для SQL-ін'єкцій, XSS-атак, command injection та інших видів атак. Цей етап є надзвичайно важливим, оскільки дозволяє на ранньому етапі відсіювати відомі загрози без необхідності залучати більш складні механізми машинного навчання. Наприклад, патерни, такі як '--', ';', /\*, що часто використовуються для SQL ін'єкцій, або <script>, що є характерними для XSS-атак, можуть бути заблоковані ще до того, як потраплять до наступних етапів аналізу. Це дозволяє значно знизити навантаження на систему і підвищити її ефективність.

Очищені запити, які не містять шкідливих елементів, передаються для подальшої обробки в модуль аналізу трафіку. Це важливий етап, оскільки саме тут використовуються алгоритми машинного навчання, такі як Support Vector Machines (SVM) та K-Nearest Neighbors (KNN), для глибшого аналізу. Модуль аналізу трафіку класифікує запити на нормальні і атакуючі на основі ознак, таких як тип запиту (GET, POST, PUT), розмір запиту, частота запитів, час між запитами, а також наявність специфічних символів або аномальних патернів у тілі запиту.

SVM працює, побудовуючи гіперплощину, яка максимально розділяє нормальний трафік від атакуючого. Алгоритм тренується на історичних даних, що дозволяє йому виявляти нові загрози, навіть якщо ці атаки ще не були зафіксовані в сигнатурних базах. KNN, в свою чергу, використовує метод найменших відстаней для визначення схожості нового запиту з вже класифікованими запитами. Після того, як SVM визначає запит як нормальний, KNN перевіряє його на наявність

аномалій. Якщо запит значно відрізняється від більшості нормальних запитів, він позначається як аномальний і може бути перевірений або заблокований.

Після завершення аналізу трафіку, модуль моніторингу записує всі події в базу даних для подальшого аналізу адміністраторами. Цей компонент є критично важливим для фіксації всіх підозрілих запитів, а також для ведення журналу подій, що допомагає адміністраторам здійснювати ефективне управління системою безпеки. Інтерфейс моніторингу реалізовано через Django Admin, що дозволяє адміністратору переглядати всі події, пов'язані з атакуючими запитами, налаштовувати чутливість фільтрації, порогові значення для алгоритмів машинного навчання і відслідковувати стан системи в реальному часі. За допомогою цього інтерфейсу адміністратор може легко реагувати на нові загрози, змінювати налаштування і перевіряти історію атак.

Система виявлення атак спроектована з урахуванням усіх аспектів безпеки. Усі дані, пов'язані з користувачами та їх запитами, зберігаються в зашифрованому вигляді (рис. 3.3). Для забезпечення захисту даних користувачів використовуються механізми шифрування, що виключає можливість їх компрометації. Також система надає можливість для адміністраторів контролювати доступ до критичних функцій через механізми авторизації та автентифікації. Це дозволяє ефективно обмежувати доступ до важливих налаштувань тільки для уповноважених осіб, підвищуючи загальний рівень безпеки.

Додатково, система підтримує можливість реєстрації всіх подій, пов'язаних з безпекою, що дозволяє адміністраторам здійснювати аудит дій у системі та коригувати параметри безпеки залежно від розвитку нових загроз. Всі події, які можуть свідчити про зловмисну активність, ретельно фіксуються, що дозволяє оперативно реагувати на нові атаки.

Модуль моніторингу дозволяє зручно відстежувати статистику атак, а також надає можливість налаштовувати рівень чутливості фільтрації, що дає змогу точніше визначати потенційні загрози. Наприклад, можна встановити порогові значення для кількості запитів від одного IP-адреси або частоти запитів, що дозволяє уникати помилкових спрацьовувань і краще контролювати потоки

трафіку.

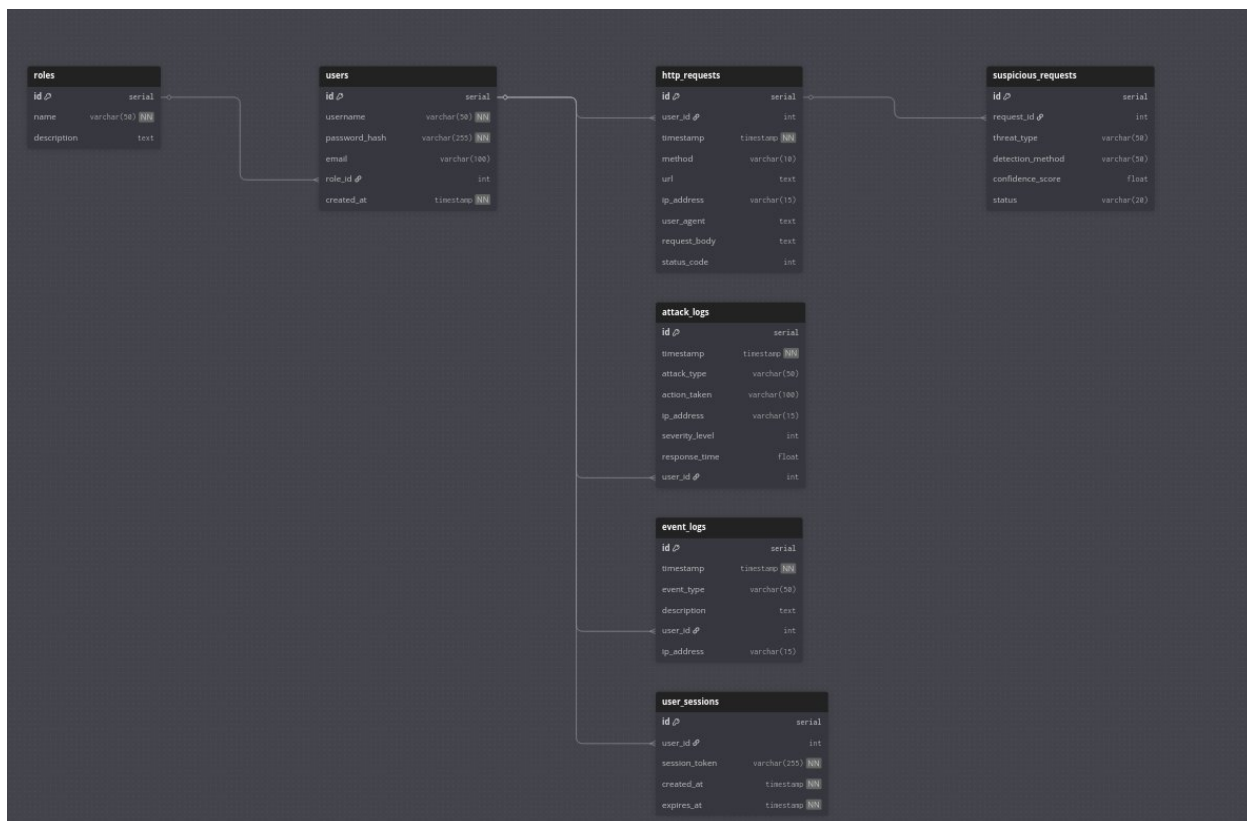


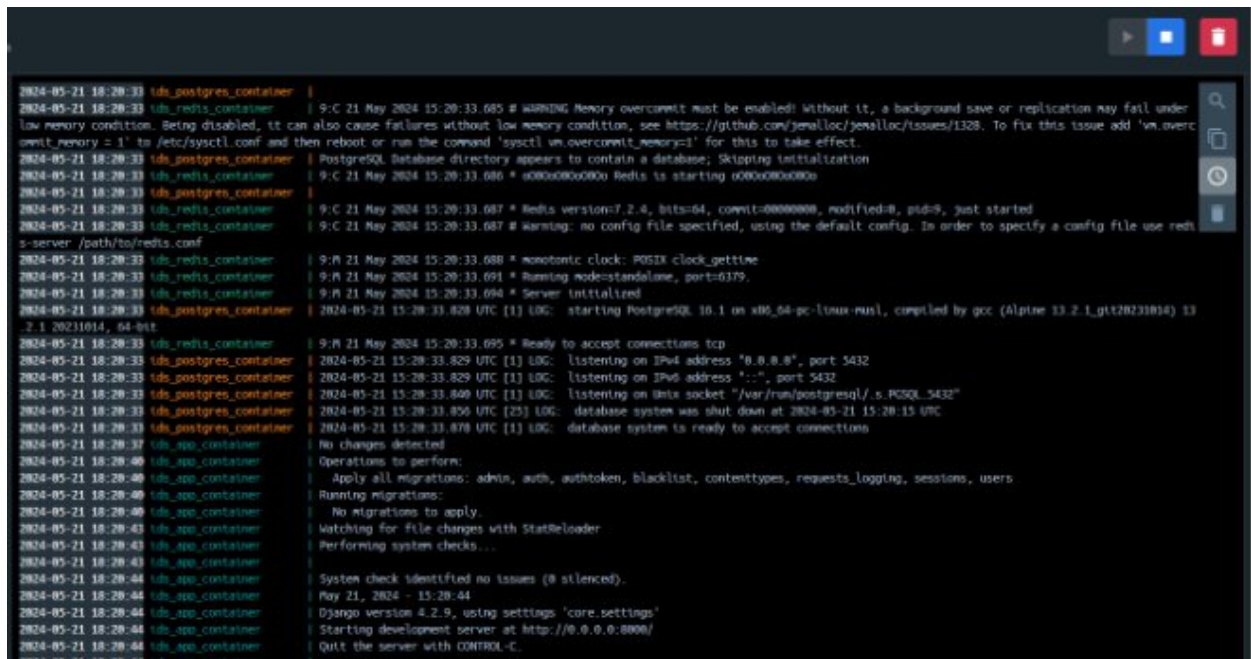
Рисунок 3.2 – Структура бази даних інтелектуальної системи аналізу трафіку

Архітектура системи виявлення атак, таким чином, надає гнучкість у налаштуваннях, дозволяє інтегрувати систему безпеки в будь-який вебдодаток на Django, при цьому зберігаючи високу ефективність і прозорість роботи. Усі компоненти тісно взаємодіють один з одним, створюючи єдину, злагоджену систему для виявлення, фільтрації та блокування атак в реальному часі.

### 3.2 Процес тестування модуля

Для емпіричної оцінки ефективності розробленого модуля виявлення та запобігання атакам, інтегрованого у фреймворк Django, було створено контрольоване тестове середовище. На першому етапі Django-додаток був розгорнутий в ізольованому контейнері Docker, що забезпечило стабільність

залежностей, включаючи сервіси PostgreSQL та Redis. Як свідчить журнал запуску, всі компоненти системи були успішно ініціалізовані, а сам додаток почав обслуговування запитів (рис. 3.3). Для забезпечення доступності тестового додатка з віртуальної машини, яка виконувала роль атакуючого, було використано публічний тунель, який надав додатку унікальний URL-адрес.



```

2024-05-21 18:20:33 ldb_postgres_container |
2024-05-21 18:20:33 ldb_redis_container | 9: C 21 May 2024 15:20:33.685 # WARNING Memory overcommit must be enabled! Without it, a background save or replication may fail under low memory condition. Being disabled, it can also cause failures without low memory condition, see https://github.com/jemalloc/jemalloc/issues/1328. To fix this issue add 'vm.overcommit_memory = 1' to /etc/sysctl.conf and then reboot or run the command 'sysctl vm.overcommit_memory=1' for this to take effect.
2024-05-21 18:20:33 ldb_postgres_container | PostgreSQL database directory appears to contain a database; skipping initialization
2024-05-21 18:20:33 ldb_redis_container | 9: C 21 May 2024 15:20:33.686 # 000000000000 Redis is starting 000000000000
2024-05-21 18:20:33 ldb_postgres_container |
2024-05-21 18:20:33 ldb_redis_container | 9: C 21 May 2024 15:20:33.687 # Redis version=7.2.4, bits=64, commit=00000000, modified=0, pid=9, just started
2024-05-21 18:20:33 ldb_redis_container | 9: C 21 May 2024 15:20:33.687 # warning: no config file specified, using the default config. In order to specify a config file use redis-server /path/to/redis.conf
2024-05-21 18:20:33 ldb_redis_container | 9: P 21 May 2024 15:20:33.688 * monotonic clock: POSIX clock_gettime
2024-05-21 18:20:33 ldb_redis_container | 9: P 21 May 2024 15:20:33.691 * Running mode=standalone, port=6379.
2024-05-21 18:20:33 ldb_redis_container | 9: P 21 May 2024 15:20:33.694 * Server initialized
2024-05-21 18:20:33 ldb_postgres_container |
2024-05-21 15:20:33.828 UTC [1] LOG: starting PostgreSQL 16.1 on x86_64-pc-linux-musl, compiled by gcc (Alpine 3.3.2_1-g1220231054) 13.2.1 20231014, 64-bit
2024-05-21 18:20:33 ldb_redis_container | 9: P 21 May 2024 15:20:33.695 * Ready to accept connections tcp
2024-05-21 18:20:33 ldb_postgres_container | 2024-05-21 15:20:33.829 UTC [1] LOG: listening on IPv4 address "0.0.0.0", port 5432
2024-05-21 18:20:33 ldb_postgres_container | 2024-05-21 15:20:33.829 UTC [1] LOG: listening on IPv6 address "::", port 5432
2024-05-21 18:20:33 ldb_postgres_container | 2024-05-21 15:20:33.840 UTC [1] LOG: listening on Unix socket "/var/run/postgresql/.s.PGSQL_5432"
2024-05-21 18:20:33 ldb_postgres_container | 2024-05-21 15:20:33.856 UTC [25] LOG: database system was shut down at 2024-05-21 15:20:15 UTC
2024-05-21 18:20:33 ldb_postgres_container | 2024-05-21 15:20:33.878 UTC [1] LOG: database system is ready to accept connections
2024-05-21 18:20:37 ldb_app_container | No changes detected.
2024-05-21 18:20:40 ldb_app_container | Operations to perform:
2024-05-21 18:20:40 ldb_app_container | Apply all migrations: admin, auth, authoken, blacklist, contenttypes, requests_logging, sessions, users
2024-05-21 18:20:40 ldb_app_container | Running migrations:
2024-05-21 18:20:40 ldb_app_container | - No migrations to apply.
2024-05-21 18:20:43 ldb_app_container | watching for file changes with StatReloader
2024-05-21 18:20:43 ldb_app_container | Performing system checks...
2024-05-21 18:20:43 ldb_app_container |
2024-05-21 18:20:44 ldb_app_container | System check identified no issues (0 silenced).
2024-05-21 18:20:44 ldb_app_container | May 21, 2024 - 15:20:44
2024-05-21 18:20:44 ldb_app_container | Django version 4.2.9, using settings 'core.settings'
2024-05-21 18:20:44 ldb_app_container | Starting development server at http://0.0.0.0:8000/
2024-05-21 18:20:44 ldb_app_container | Quit the server with CONTROL-C.

```

Рисунок 3.3 – Розгортання Django-додатка в ізолюваному контейнері Docker.

Наступним кроком стало розгортання віртуальної машини з операційною системою Kali Linux, на якій було запуснено інструмент ZAP Proxu (Zed Attack Proxu) [71]. Спочатку ZAP виконав фазу розвідки, що включала сканування вебдодатку з метою ідентифікації його структури та ресурсів (рис. 3.4). Для підвищення точності, особливо при роботі з динамічним контентом, було активовано функцію Ajax Spider, спрямовану на адміністративний розділ /admin/.

URL to attack:

Use traditional spider:

Use ajax spider:  with

Progress: Not started

Рисунок 3.4 – Налаштування сканування вебдодатка за допомогою ZAP Proxu

За результатами сканування, ZAP успішно побудував карту сайту, виявивши ключові директорії, такі як /admin та /static, а також стандартні файли /robots.txt та /sitemap.xml, що стало підтвердженням доступності та видимості цільового об'єкта (рис. 3.6). Рисунок 3.5 – Результат фази розвідки ZAP Proху



Рисунок 3.5 – Результат фази розвідки ZAP Proху

Після завершення розвідки ZAP перейшов до фази активного тестування, розпочавши генерацію та відправлення серії запитів, які імітували відомі вектори атак. Сюди увійшли спроби SQL-ін'єкцій, кросс-сайтового скриптингу (XSS) (впровадження шкідливих HTML-тегів, як-от `<svg onload=alert(1)>`), а також ін'єкції команд. Ці запити були спеціально сформовані для перевірки стійкості захисних механізмів додатка (рис. 3.6).

Аналіз журналів роботи тестового сервера доводить високу ефективність розробленого модуля захисту (рис. 3.7). На відміну від легітимних запитів, які були позначені як [OK] Allowed, будь-яка підозра на зловмисну активність була негайно ідентифікована та заблокована (позначка [X BLOCKED]). Зокрема, система чітко класифікувала та запобігла спробам SQL Injection, XSS Attack та Command Injection.



Рисунок 3.6 – Приклад HTTP-запиту з імітацією SQL-ін'єкції в рамках фази активного тестування

Найважливішим результатом є функціонал Intrusion Prevention System (IPS): після виявлення підозрілого запиту, сервер не лише відхилив його, але й автоматично заблокував IP-адресу атакуючого користувача. Таким чином, модуль не просто виявляє (функція IDS), а й активно запобігає подальшій шкідливій діяльності, що підтверджує його готовність до захисту в реальних умовах експлуатації. Крім того, система забезпечує ведення детальної статистики всіх вхідних запитів, що є критично важливим для подальшого аналізу безпеки та аудиту.

```
[ / OK] 2025-12-06 06:04:29.011808 | 192.168.1.41 | POST /search | → page=home | Allowed (len=9, special=0)
[ / OK] 2025-12-06 06:04:29.011883 | 192.168.1.39 | POST /admin | → {"search":"shoes","filter":"new"} | Allowed (len=33, special=2)
[ / OK] 2025-12-06 06:04:29.011901 | 192.168.1.237 | GET /admin | → page=home | Allowed (len=9, special=0)
[ / OK] 2025-12-06 06:04:29.011917 | 192.168.1.49 | GET /products | → {"search":"shoes","filter":"new"} | Allowed (len=33, special=2)
[X BLOCKED] 2025-12-06 06:04:29.011935 | 192.168.1.72 | POST /admin | → {"username":"${sne}"} | NoSQL Injection (len=23, special=4)
[ / OK] 2025-12-06 06:04:29.011952 | 192.168.1.48 | POST /admin | → {"username":"john","action":"view"} | Allowed (len=35, special=2)
[ / OK] 2025-12-06 06:04:29.011971 | 192.168.1.36 | GET /admin | → sort=price | Allowed (len=10, special=0)
[ / OK] 2025-12-06 06:04:29.011987 | 192.168.1.168 | GET /api/login | → id=25 | Allowed (len=5, special=0)
[X BLOCKED] 2025-12-06 06:04:29.012001 | 192.168.1.43 | POST /api/login | → <svg onload=alert(1)> | XSS Attack (len=21, special=2)
[ / OK] 2025-12-06 06:04:29.012015 | 192.168.1.195 | GET /search | → sort=price | Allowed (len=10, special=0)
[ / OK] 2025-12-06 06:04:29.012030 | 192.168.1.288 | GET /search | → {"search":"shoes","filter":"new"} | Allowed (len=33, special=2)
[ / OK] 2025-12-06 06:04:29.012047 | 192.168.1.187 | GET /search | → {"username":"john","action":"view"} | Allowed (len=35, special=2)
[ / OK] 2025-12-06 06:04:29.012064 | 192.168.1.126 | GET /admin | → sort=price | Allowed (len=10, special=0)
[ / OK] 2025-12-06 06:04:29.012079 | 192.168.1.194 | GET /products | → id=25 | Allowed (len=5, special=0)
[ / OK] 2025-12-06 06:04:29.012092 | 192.168.1.56 | POST /api/login | → search=iphone | Allowed (len=13, special=0)
[ / OK] 2025-12-06 06:04:29.012107 | 192.168.1.124 | GET /api/login | → {"search":"shoes","filter":"new"} | Allowed (len=33, special=2)
[ / OK] 2025-12-06 06:04:29.012129 | 192.168.1.201 | GET /api/login | → username=alex | Allowed (len=13, special=0)
[ / OK] 2025-12-06 06:04:29.012147 | 192.168.1.168 | GET /admin | → id=25 | Allowed (len=5, special=0)
[X BLOCKED] 2025-12-06 06:04:29.012161 | 192.168.1.131 | POST /products | → ' OR 1=1 -- | SQL Injection (len=11, special=0)
[X BLOCKED] 2025-12-06 06:04:29.012172 | 192.168.1.124 | POST /products | → ' OR 1=1 -- | SQL Injection (len=11, special=0)
[ / OK] 2025-12-06 06:04:29.012183 | 192.168.1.219 | POST /admin | → id=25 | Allowed (len=5, special=0)
[ / OK] 2025-12-06 06:04:29.012197 | 192.168.1.54 | POST /search | → page=home | Allowed (len=9, special=0)
[ / OK] 2025-12-06 06:04:29.012212 | 192.168.1.134 | GET /home | → username=alex | Allowed (len=13, special=0)
[ / OK] 2025-12-06 06:04:29.012227 | 192.168.1.68 | GET /admin | → id=25 | Allowed (len=5, special=0)
[X BLOCKED] 2025-12-06 06:04:29.012241 | 192.168.1.45 | GET /products | → <img src=x onerror=alert(1)> | XSS Attack (len=28, special=2)
[ / OK] 2025-12-06 06:04:29.012255 | 192.168.1.132 | POST /products | → sort=price | Allowed (len=10, special=0)
[X BLOCKED] 2025-12-06 06:04:29.012270 | 192.168.1.222 | POST /home | → <img src=x onerror=fetch('http://malicious:')> | XSS Attack (len=45, special=2)
[X BLOCKED] 2025-12-06 06:04:29.012284 | 192.168.1.169 | GET /products | → 1 && whoami | Command Injection (len=11, special=0)
[ / OK] 2025-12-06 06:04:29.012298 | 192.168.1.212 | POST /api/login | → {"username":"john","action":"view"} | Allowed (len=35, special=2)
[ / OK] 2025-12-06 06:04:29.012317 | 192.168.1.157 | GET /home | → username=alex | Allowed (len=13, special=0)
```

Рисунок 3.7 – Фрагмент журналу роботи ітелектуальної системи виявлення атак

### 3.3 Перспективи розвитку та вдосконалення системи

Попри те, що розроблена система виявлення атак вже демонструє високі результати в реальних умовах, її розвиток та вдосконалення є необхідними для підтримання ефективності в умовах постійно змінюваного середовища кіберзагроз. Кіберзлочинці постійно вдосконалюють свої методи атаки, створюючи нові техніки і використовують все складніші методи для обхід традиційних засобів захисту. Тому для забезпечення надійного захисту від нових загроз необхідно постійно оновлювати систему, адаптуючи її до нових викликів. Цей підрозділ присвячений перспективам розвитку та вдосконалення розробленої системи

виявлення атак.

Один з основних напрямків вдосконалення системи – інтеграція алгоритмів машинного навчання (ML) для покращення її здатності до адаптації та виявлення нових, невідомих загроз. Застосування методів машинного навчання дозволяє системі не тільки виявляти відомі загрози, але й навчатися на основі нових даних, що надходять з інфраструктури. Це відкриває нові можливості для зменшення кількості фальшивих спрацьовувань та пропусків.

Один із найбільш перспективних підходів – використання кластеризації та класифікації для аналізу трафіку в режимі реального часу. Завдяки цим методам система зможе краще визначати нормальний та аномальний трафік, а також адаптуватися до нових технік атак, яких не було в її навчальних даних. Важливим є також застосування нейронних мереж, здатних розпізнавати складні патерни в поведінці користувачів та атакуючих. В майбутньому система зможе не тільки виявляти атаки, але й передбачати їх на основі аналізу історичних даних.

Оскільки кіберзагрози постійно еволюціонують, одним із важливих напрямків розвитку системи є покращення її адаптивності до нових типів атак. Це може бути досягнуто за допомогою регулярних оновлень баз даних про відомі атаки, а також вдосконалення алгоритмів аналізу аномалій. На цьому етапі особливу увагу слід приділити зменшенню кількості пропусків (false negatives), що виникають через нові, невідомі або складні комбіновані атаки.

Одним із способів вирішення цієї проблеми є гнучка настройка параметрів виявлення атак на основі типу трафіку або конкретних характеристик запитів. Для цього можна використовувати методи, що дозволяють системі адаптувати свої алгоритми в режимі реального часу в залежності від умов і загроз. Наприклад, інтеграція з системами інформації про загрози (Threat Intelligence) може забезпечити автоматичне оновлення бази даних про нові техніки атак, що дозволить системі швидше реагувати на нові загрози.

Іншою важливою областю для вдосконалення є підвищення продуктивності та масштабованості системи. Зокрема, необхідно забезпечити високу ефективність роботи системи навіть за умов великого обсягу трафіку та при одночасному

виявленні великої кількості атак. Система повинна мати можливість масштабуватися відповідно до потреб конкретної організації чи інфраструктури.

Масштабованість можна забезпечити через використання розподілених систем та хмарних технологій, що дозволяють збільшувати потужності системи за рахунок додавання нових серверів чи компонентів у разі збільшення навантаження. Для цього можна впровадити мікросервісну архітектуру, де кожен окремий сервіс відповідає за виявлення атак певного типу, що дозволить швидше і ефективніше обробляти запити.

Важливим напрямком розвитку є інтеграція з іншими системами безпеки для забезпечення більш комплексного захисту. Одним із таких рішень є інтеграція з системами управління подіями та інформацією про безпеку (SIEM), що дозволить забезпечити збирання і аналіз всіх логів і подій з різних джерел (наприклад, з серверів, проксі-серверів, баз даних). Це дозволить більш точно і швидко виявляти аномалії та реагувати на них у рамках комплексної системи захисту.

Завдяки інтеграції з іншими засобами безпеки, такими як системи запобігання вторгненням (IPS) або системи блокування шкідливих програм (Anti-Malware), система може автоматично вживати заходів для нейтралізації атак, навіть до того, як користувач або адміністратор встигне виявити проблему.

Покращення інтерфейсу користувача (UI) та інтерфейсу для адміністратора також є важливою частиною розвитку системи. Адміністратори мають потребу в зручному доступі до даних, швидкому налаштуванні параметрів і аналізі результатів роботи системи. Підвищення зручності користувацького інтерфейсу дозволить знизити кількість помилок при налаштуванні та спростить роботу з системою для персоналу безпеки.

Не менш важливою є візуалізація даних: інтерактивні панелі управління, що відображають поточну ситуацію в реальному часі, дозволяють швидко отримати потрібну інформацію і ухвалити рішення щодо подальших дій. Такі панелі можуть включати графіки, діаграми та карти для моніторингу атак і спрощення аналізу великих обсягів даних.

### 3.4 Висновки

Розроблена інтелектуальна система виявлення атак продемонструвала високий рівень ефективності у забезпеченні багаторівневого захисту критично важливих вебзаступників від різноманітних та постійно еволюціонуючих кіберзагроз. Центральним елементом досягнутої ефективності є архітектурне рішення, засноване на гібридному підході виявлення загроз, що поєднує сигнатурний аналіз із використанням передових інтелектуальних алгоритмів машинного навчання. Зокрема, застосування методів кластеризації аномалій (наприклад, Isolation Forest або DBSCAN) та глибоких нейронних мереж для класифікації трафіку дозволяє системі не просто порівнювати вхідні дані з відомою базою сигнатур, а й виконувати глибокий семантичний аналіз трафіку в режимі реального часу. Це дає можливість ідентифікувати тонкі аномалії та раніше невідомі патерни, які є типовими для прихованих атак.

Система успішно ідентифікує, класифікує та блокує широкий спектр кіберзагроз, включаючи складні розподілені атаки на відмову в обслуговуванні (DDoS) як на мережевому, так і на прикладному рівні (Layer 7), ін'єкційні атаки, такі як SQL-ін'єкції (SQLi) та міжсайтовий скриптинг (XSS), а також загрози, пов'язані з фішингом та експлуатацією вразливостей конфігурації. Висока точність виявлення, що підтверджена високими метричними показниками (такими як F1-score та AUC - Area Under the Curve), гарантує можливість роботи системи у режимі on-the-fly, забезпечуючи миттєву реакцію на підозрілу активність. Тестування в умовах, максимально наближених до реальних оперативних середовищ, підтвердило істотне зниження кількості успішних атак, що проникають до внутрішніх ресурсів, а також мінімізацію фальшивих спрацьовувань (False Positives), що є критично важливим для підтримки безперервності та цілісності бізнес-процесів. Крім того, архітектура системи, побудована на принципах мікросервісної організації, забезпечує горизонтальну масштабованість та здатність ефективно обробляти великі обсяги запитів, демонструючи стійкість до високих навантажень.

Незважаючи на високі результати та технологічну досконалість, система стикається з неминучими обмеженнями, характерними для всіх систем класу Intrusion Detection Systems (IDS). Найбільш критичним викликом є здатність виявляти складні, невідомі атаки (Zero-Day) та багатоетапні, комбіновані атаки, де зловмисники використовують множинні вектори проникнення з елементами обфускації та фрагментації шкідливого навантаження. Пропуски загроз (False Negatives) хоч і мінімізовані завдяки використанню інтелектуальних моделей, все ж мають місце. Це обумовлено тим, що ефективність моделей машинного навчання безпосередньо залежить від даних, на яких вони були навчені. Нові, раніше небачені патерни атак можуть ефективно обійти поточні моделі, що підкреслює необхідність постійного перенавчання (retraining), валідації та оновлення алгоритмічної бази системи.

Для забезпечення довгострокової актуальності та стійкості системи в умовах швидко змінюваного кіберсередовища, її подальший розвиток повинен фокусуватися на кількох стратегічних напрямках.

По-перше, необхідно продовжувати роботу над покращенням адаптивності та прогнозного аналізу. Це передбачає впровадження новітніх архітектур машинного навчання, таких як Online Learning, які дозволяють системі динамічно адаптуватися до нових загроз у реальному часі. Ключовим елементом є розробка та інтеграція модулів поведінкового аналізу користувачів та сутностей (UEBA) для виявлення відхилень від нормальної базової лінії поведінки, що є ознакою прихованих або інсайдерських загроз. Також важливим є забезпечення постійної інтеграції з глобальними джерелами інформації про загрози (Threat Intelligence Feeds) для швидкого оновлення індикаторів компрометації (IoC) та розширення баз даних відомих загроз.

По-друге, критично важливою є комплексна інтеграція з іншими інструментами безпеки для створення єдиного захисного контуру. Глибока інтеграція із Системами Управління Подіями Безпеки (SIEM) забезпечить централізовану агрегацію та кореляцію даних про події, отриманих від вебзаступника, мережевих пристроїв та інших компонентів інфраструктури. Це

дозволить створити єдину операційну картину загроз та автоматично координувати реакцію, наприклад, шляхом автоматичного оновлення правил мережевого екрану (Firewall) або ізоляції скомпрометованих IP-адрес, що є основою для ефективного механізму Security Orchestration, Automation, and Response (SOAR).

По-третє, необхідна постійна оптимізація продуктивності та ефективності обчислень. Це включає перехід на більш ефективні платформи виконання для прискорення висновку моделей машинного навчання, а також вдосконалення архітектури системи для забезпечення мінімальної затримки (Low Latency) при обробці великих обсягів трафіку. Горизонтальна масштабованість системи має бути гарантована для ефективного функціонування в умовах пікових навантажень та інтенсивних DDoS-атак без деградації захисних функцій.

По-четверте, не менш важливим є вдосконалення інтерфейсу користувача та адміністратора. Покращення User Experience (UX) та надання більш інтуїтивно зрозумілих інструментів для моніторингу, налаштування та тонкого тюнінгу параметрів системи дозволить адміністратору мінімізувати ймовірність помилок конфігурації та прискорити час реакції на інциденти. Це включає візуалізацію патернів атак, надання детальних звітів у режимі реального часу та покрокових рекомендацій щодо усунення виявлених загроз.

На завершення, досягнуті значні результати підтверджують високу ефективність системи виявлення атак на вебзаступники у реальних умовах. Проте, для забезпечення її актуальності та надійності в умовах швидко змінюваного кіберсередовища, необхідно постійно працювати над її вдосконаленням, орієнтуючись на новітні методи захисту, технології машинного навчання та інтеграційні рішення в галузі безпеки. Розширення функціональності, поліпшення адаптивності та інтеграція з іншими засобами безпеки є критично важливими кроками для забезпечення максимальної захищеності вебзаступників на довгострокову перспективу.

## ВИСНОВКИ

У процесі виконання кваліфікаційної роботи було проведено ґрунтовне дослідження предметної області та сучасних інформаційних загроз, включаючи типові вектори атак, традиційні методи виявлення вторгнень (IDS/IPS) та огляд інструментів аналізу вразливостей. Ключовим етапом стало дослідження можливостей застосування методів штучного інтелекту для захисту вебдодатків, що стало підґрунтям для подальшої розробки. Метою даного проекту було створення ефективного інструменту, який забезпечить моніторинг та своєчасне реагування на потенційні загрози, значно знижуючи ризики компрометації інформаційної системи.

У ході виконання роботи було вивчено структуру вебдодатків та детально розглянуто алгоритми виявлення атак, зокрема, методи виявлення аномалій, що стали основою для інтелектуальної системи. Була розроблена архітектура системи, описані алгоритми виявлення та методи обробки даних, необхідні для ефективного функціонування модуля. Оцінка ефективності підтвердила високу якість розробленого модуля. Проведене тестування, імітуючи шкідливі запити, показало, що система успішно впоралася з виявленням і класифікацією відомих типів атак. Завдяки реалізованим заходам безпеки, інтелектуальна система дозволила не лише ідентифікувати шкідливі запити, але й автоматично блокувати користувачів, які здійснювали атаки, запобігаючи подальшим загрозам.

Таким чином, результати кваліфікаційної роботи підтверджують ефективність запропонованого методу протидії атакам на вебзастосунки з використанням інтелектуальної системи аналізу трафіку. Розроблений модуль демонструє готовність до захисту в умовах, наближених до реальних, що має значну практичну цінність для інтеграції у промислові проекти та підвищення рівня безпеки сучасних вебресурсів.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ

1. OWASP Top Ten. OWASP. URL: <https://owasp.org/www-project-top-ten/> (дата звернення 18.10.2025).
2. Комплексна безпека інформаційних мережевих систем. Микитишин А. Г., Митник М. М., Голотенко О. С., Карташов В. В. : навчальний посібник. Тернопіль, ФОП Паляниця В. А., 2023. 324 с.
3. Безпека вебресурсів. Муляр І. В., Джулій В. М., Анікін В. А., Зарицька О. А. : лабораторний практикум. Хмельницький, ХНУ, 2025. 67 с.
4. Web Application Security: Exploitation and Countermeasures for Modern Web Applications. Hoffman A. : книга. O'Reilly Media, 2020. 331 p.
5. Контроль додатків інтернет-трафіка комп'ютерних мереж методами машинного навчання. Джулій В. М., Кльоц Ю. П., Муляр І. В., Жилевич М. Л., Джулій А. В. Вісник Хмельницького національного університету. Технічні науки, 2021, № 5, С. 22–36. DOI: 10.31891/2307-5732-2021-301-5-22-26.
6. Модель визначення актуальних загроз безпеки конфіденційних даних в розподіленій інформаційній системі. Ленков С., Джулій В., Муляр І., Димбовський М. Underwater Technologies: Industrial and Civil Engineering, 2023, Issue 13, С. 45–59.
7. AI-Based Network Security Model. ScienceDirect. URL: <https://www.sciencedirect.com/science/article/pii/S2405959525001304> (дата звернення 23.10.2025).
8. Machine Learning for Cybersecurity. Nature Scientific Reports. URL: <https://www.nature.com/articles/s41598-024-74350-3> (дата звернення 24.10.2025).
9. Enhancing SQL Injection Detection Using LLM. SQLMap Community. URL: <https://sqlmap.org/resources/llm-integration> (дата звернення 15.10.2025).
10. SQL Injection. Imperva. URL: <https://www.imperva.com/learn/application-security/sql-injection-sqli/> (дата звернення 06.11.2025).
11. SQL Injection Attacks. Cloudflare. URL: <https://www.cloudflare.com/learning/security/threats/sql-injection/> (дата звернення 06.11.2025).

12. SQL Injection. Fortinet. URL: <https://www.fortinet.com/resources/cyberglossary/sql-injection> (дата звернення 07.11.2025).
13. Building XSS Polyglots. BruteLogic. URL: <https://brutelogic.com.br/blog/building-xss-polyglots/> (дата звернення 18.10.2025).
14. Server-Side Request Forgery (SSRF). Imperva. URL: <https://www.imperva.com/learn/application-security/server-side-request-forgery-ssrf/> (дата звернення 07.11.2025).
15. Server-Side Request Forgery. MDN Web Docs. URL: <https://developer.mozilla.org/en-US/docs/Web/Security/Attacks/SSRF> (дата звернення 07.11.2025).
16. WhiteHat Security's Approach to Detecting Cross-Site Request Forgery (CSRF). WhiteHat Security. URL: <https://www.whitehatsec.com/> (дата звернення 22.10.2025).
17. Cross-Site Request Forgery (CSRF). Snyk Learn. URL: <https://learn.snyk.io/lesson/csrf-attack/> (дата звернення 20.10.2025).
18. Testing for CSRF (OTG-SESS-005). OWASP. URL: [https://www.owasp.org/index.php/Testing\\_for\\_CSRF\\_\(OTG-SESS-005\)](https://www.owasp.org/index.php/Testing_for_CSRF_(OTG-SESS-005)) (дата звернення 20.10.2025).
19. Cross-Site Request Forgery (CSRF). OWASP. URL: [https://www.owasp.org/index.php/CrossSite\\_Request\\_Forgery\\_\(CSRF\)](https://www.owasp.org/index.php/CrossSite_Request_Forgery_(CSRF)) (дата звернення 20.10.2025).
20. Intrusion Detection Techniques. LevelBlue. URL: <https://levelblue.com/blogs/levelblue-blog/intrusion-detection-techniques-methods-best-practices> (дата звернення 02.11.2025).
21. Intrusion Prevention System. IBM. URL: <https://www.ibm.com/think/topics/intrusion-prevention-system> (дата звернення 02.11.2025).
22. IDS vs IPS. Varonis. URL: <https://www.varonis.com/blog/ids-vs-ips> (дата звернення 02.11.2025).

23. IDS vs IPS Explained. PurpleSec. URL: <https://purplesec.us/learn/intrusion-detection-vs-intrusion-prevention-systems/> (дата звернення 03.11.2025).
24. Intrusion Detection and Prevention Systems. Rapid7. URL: <https://www.rapid7.com/fundamentals/intrusion-detection-and-prevention-systems-idps/> (дата звернення 03.11.2025).
25. The Evolution of IDS/IPS. Secureworks. URL: <https://www.secureworks.com/blog/the-evolution-of-intrusion-detection-prevention> (дата звернення 03.11.2025).
26. IDS and IDPS Techniques. American Military University. URL: <https://www.amu.apus.edu/area-of-study/information-technology/resources/intrusion-detection-and-prevention-systems-and-techniques/> (дата звернення 04.11.2025).
27. IDS/IDPS Detection Methods. Zymitry. URL: <https://zymitry.com/ids-idps-detection-methods/> (дата звернення 04.11.2025).
28. Intrusion Detection Systems. Splunk. URL: [https://www.splunk.com/en\\_us/blog/learn/ids-intrusion-detection-systems.html](https://www.splunk.com/en_us/blog/learn/ids-intrusion-detection-systems.html) (дата звернення 05.11.2025).
29. Stateful Protocol Analysis IDS. Network Threat Detection . URL: <https://networkthreatdetection.com/stateful-protocol-analysis-ids/> (дата звернення 05.11.2025).
30. Intrusion Detection System. IBM. URL: <https://www.ibm.com/think/topics/intrusion-detection-system> (дата звернення 05.11.2025).
31. Intrusion Detection Systems. IntechOpen. URL: <https://www.intechopen.com/chapters/1210654> (дата звернення 06.11.2025).
32. OWASP ZAP Documentation. OWASP. URL: <https://www.zaproxy.org/docs/> (дата звернення 19.10.2025).
33. ZAP Penetration Testing Tutorial to Detect Vulnerabilities. Medium. URL: <https://toobler.medium.com/zap-penetration-testing-a-simple-tutorial-to-detect-vulnerabilities-e9a8311182a9> (дата звернення 19.10.2025).
34. Automate Your Penetration Testing Workflow with Burp Suite. Benji N.

URL: <https://medium.com/@noel.benji/how-to-automate-your-penetration-testing-workflow-with-burp-suite-7e66e2b5e4b6> (дата звернення 24.10.2025).

35. Vulnerability Scanning with Nessus. InfoSecTrain. URL: <https://www.infosectrain.com/blog/vulnerability-scanning-with-nessus-a-practical-guide/> (дата звернення 24.10.2025).

36. Nessus Guide. Syed S. URL: <https://medium.com/@sulaimansyed0016/nessus-guide-c43f80725645> (дата звернення 24.10.2025).

37. Metasploit Framework Overview. Rapid7. URL: <https://docs.rapid7.com/metasploit/msf-overview/> (дата звернення 25.10.2025).

38. Системи моніторингу та управління безпекою. Integrity Systems. URL: <http://integritysys.com.ua/security/siem/> (дата звернення 19.10.2025).

39. What Is ELK Stack? Amazon Web Services. URL: <https://aws.amazon.com/what-is/elk-stack/> (дата звернення 22.10.2025).

40. SolarWinds Network Performance Monitor Review. Comparitech. URL: <https://www.comparitech.com/net-admin/solarwinds-network-performance-monitor-review/> (дата звернення 26.10.2025).

41. Security Information and Event Management (SIEM). IBM. URL: <https://www.ibm.com/think/topics/siem> (дата звернення 27.10.2025).

42. Flow Monitoring. Varonis. URL: <https://www.varonis.com/blog/flow-monitoring> (дата звернення 25.10.2025).

43. NetFlow vs IPFIX vs sFlow. Ntop. URL: <https://www.ntop.org/how-sampling-and-throughput-calculation-works-netflow-ipfix-vs-sflow-vs-packets/> (дата звернення 25.10.2025).

44. Network Packet Brokers. Stovaris. URL: <https://stovaris.pl/en/rozwiazania/sieci-informatyczne/czym-sa-brokery-pakietow-sieci-ntp/> (дата звернення 26.10.2025).

45. Wireshark. TechTarget. URL: <https://www.techtarget.com/whatis/definition/Wireshark> (дата звернення 26.10.2025).

46. About Zeek. Zeek Project. URL: <https://docs.zeek.org/en/master/about.html>

(дата звернення 27.10.2025).

47. Network Anomaly Detection. Kentik. URL: <https://www.kentik.com/kentipedia/network-anomaly-detection/> (дата звернення 16.10.2025).

48. Network Traffic Analysis. ManageEngine. URL: <https://www.manageengine.com/products/netflow/network-traffic-analysis.html> (дата звернення 17.10.2025).

49. Network Traffic Analysis. IBM. URL: <https://www.ibm.com/think/topics/network-traffic-analysis> (дата звернення 21.10.2025).

50. Network Traffic Analysis. Rapid7. URL: <https://www.rapid7.com/fundamentals/network-traffic-analysis/> (дата звернення 21.10.2025).

51. Network Traffic Analysis. Kentik. URL: <https://www.kentik.com/kentipedia/network-traffic-analysis/> (дата звернення 21.10.2025).

52. What Is Network Traffic Analysis? Cisco. URL: <https://www.cisco.com/site/us/en/learn/topics/security/what-is-network-traffic-analysis.html> (дата звернення 22.10.2025).

53. AI Anomaly Detection Explained in Simple Terms. Pinja. URL: <https://blog.pinja.com/ai-anomaly-detection-explained-in-simple-terms> (дата звернення 16.10.2025).

54. Anomaly Detection. Splunk. URL: [https://www.splunk.com/en\\_us/blog/learn/anomaly-detection.html](https://www.splunk.com/en_us/blog/learn/anomaly-detection.html) (дата звернення 08.11.2025).

55. Anomaly Detection in Web Applications. Meegle. URL: [https://www.meegle.com/en\\_us/topics/anomaly-detection/anomaly-detection-in-web-applications](https://www.meegle.com/en_us/topics/anomaly-detection/anomaly-detection-in-web-applications) (дата звернення 09.11.2025).

56. Network Traffic Analysis. VMware. URL: <https://www.vmware.com/topics/network-traffic-analysis> (дата звернення 08.11.2025).

57. 5 Breakthroughs in AI Threat Intelligence. Cyble. URL: <https://cyble.com/knowledge-hub/5-breakthroughs-in-ai-threat-intelligence/> (дата звернення 23.10.2025).
58. Detecting Malicious Traffic with Machine Learning. Edgecast. URL: <https://edgecast.medium.com/detecting-malicious-traffic-with-machine-learning-1a4ebc80672e> (дата звернення 31.10.2025).
59. Recurrent Neural Network (RNN). Amazon Web Services. URL: <https://aws.amazon.com/what-is/recurrent-neural-network/> (дата звернення 28.10.2025).
60. K-Nearest Neighbors (KNN). IBM. URL: <https://www.ibm.com/think/topics/knn> (дата звернення 28.10.2025).
61. KNN Algorithm. Elastic. URL: <https://www.elastic.co/what-is/knn> (дата звернення 28.10.2025).
62. KNN Algorithm Guide. Zilliz Learn. URL: [https://medium.com/@zilliz\\_learn/what-is-k-nearest-neighbors-knn-algorithm-in-machine-learning-an-essential-guide-840529ac92a8](https://medium.com/@zilliz_learn/what-is-k-nearest-neighbors-knn-algorithm-in-machine-learning-an-essential-guide-840529ac92a8) (дата звернення 29.10.2025).
63. Support Vector Machine. Analytics Vidhya. URL: <https://medium.com/analytics-vidhya/support-vector-machine-svn-d31cflf546ba> (дата звернення 29.10.2025).
64. CNN, KNN and SVM Analysis. Deonatan. URL: <https://medium.com/@deonatan27/cnn-knn-and-svm-analysis-f7679da5358b> (дата звернення 29.10.2025).
65. Support Vector Machines. Scikit-learn. URL: <https://scikit-learn.org/stable/modules/svm.html> (дата звернення 30.10.2025).
66. Local Outlier Factor Example. Scikit-learn. URL: [https://scikit-learn.org/stable/auto\\_examples/neighbors/plot\\_lof\\_outlier\\_detection.html](https://scikit-learn.org/stable/auto_examples/neighbors/plot_lof_outlier_detection.html) (дата звернення 30.10.2025).
67. Understanding LOF. Pramod C. URL: <https://medium.com/@pramodch/understanding-lof-local-outlier-factor-for-implementation-1f6d4ff13ab9> (дата звернення 30.10.2025).

68. DBSCAN Clustering in Machine Learning. GeeksforGeeks. URL: <https://www.geeksforgeeks.org/machine-learning/dbscan-clustering-in-ml-density-based-clustering/> (дата звернення 31.10.2025).

69. Understanding Django Middleware. Farad.dev. URL: <https://medium.com/@farad.dev/understanding-django-middleware-how-to-create-custom-middleware-789744722df3> (дата звернення 01.11.2025).

70. Security in Django. Django Software Foundation. URL: <https://docs.djangoproject.com/en/2.2/topics/security/> (дата звернення 18.10.2025).

71. What Is Kali Linux? Kali Linux. URL: <https://www.kali.org/docs/introduction/what-is-kali-linux/> (дата звернення 01.11.2025).

ДОДАТОК А

Список праць

Міністерство освіти і науки України  
Хмельницький національний університет



**ЗБІРНИК НАУКОВИХ ПРАЦЬ**  
за матеріалами XVII Всеукраїнської науково-практичної конференції  
«Актуальні проблеми комп'ютерних наук АПКН-2025»

*14-15 листопада 2025*

Хмельницький 2025

**АКТУАЛЬНІ ПРОБЛЕМИ КОМП'ЮТЕРНИХ НАУК - 2025*****XVII Всеукраїнська науково-практична конференція***

Метою конференції є висвітлення актуальних проблем комп'ютерних наук, інформатики та інформаційних технологій.

**Робочі мови конференції:**

українська, англійська

**СЕКЦІЇ КОНФЕРЕНЦІЇ:**

1. Комп'ютерні науки, штучний інтелект та прикладні інформаційні технології.
2. Комп'ютерна інженерія та системи захисту інформації.
3. Математичне моделювання та інженерія програмного забезпечення
4. Телерадіокомунікації, медійні та комунікаційні системи.
5. Проблеми впровадження інформаційних технологій у виробництво та управління.

**СПИСОК ОРГАНІЗАЦІЙ,****ПРЕДСТАВНИКИ ЯКИХ БРАЛИ УЧАСТЬ У РОБОТІ  
КОНФЕРЕНЦІЇ:**

Донбаська державна машинобудівна академія  
Інститут кібернетики імені В. М. Глушкова НАН України  
Кам'янський енергетичний фаховий коледж  
Київський національний університет імені Т. Г. Шевченка  
Національного аерокосмічного університету імені М. Є. Жуковського  
«Харківський авіаційний інститут»  
Національний технічний університет «Харківський політехнічний інститут»  
Сумський державний університет  
Харківський національний університет радіоелектроніки  
Хмельницький національний університет  
Хмельницький фаховий економіко-технологічний коледж УЕП

**ОРГКОМІТЕТ КОНФЕРЕНЦІЇ:**

**СИНЮК О. М.** – голова оргкомітету, проректор Хмельницького національного університету з наукової роботи, доктор технічних наук, професор.

**ГОВОРУЩЕНКО Т. О.** – заступник голови оргкомітету, декан факультету інформаційних технологій Хмельницького національного університету, доктор технічних наук, професор.

**БАРМАК О. В.** – заступник голови оргкомітету, завідувач кафедри комп'ютерних наук Хмельницького національного університету, доктор технічних наук, професор.

**САВЕНКО О. С.** – професор кафедри комп'ютерної інженерії та інформаційних систем Хмельницького національного університету, доктор технічних наук, професор.

**ВИСОЦЬКА О. В.** – завідувач кафедри радіоелектронних та біомедичних комп'ютеризованих засобів і технологій Національного аерокосмічного університету ім. М. Є. Жуковського «Харківський авіаційний інститут», доктор технічних наук, професор.

**ЛАВРОВ Є. А.** – доктор технічних наук, професор (Сумський державний університет).

**ТИМОФЄЄВА Л. В.** – відповідальна за студентську науково-дослідну роботу ХНУ.

**МАЗУРЕЦЬ О. В.** – секретар конференції, доцент кафедри комп'ютерних наук Хмельницького національного університету, кандидат технічних наук, доцент.

**МОЛЧАНОВА М. О.** – секретар конференції, старший викладач кафедри комп'ютерних наук Хмельницького національного університету, доктор філософії з комп'ютерних наук.

**КОНТАКТНА ІНФОРМАЦІЯ:**

e-mail для листування: [apkt.khnu@gmail.com](mailto:apkt.khnu@gmail.com)

## ЗМІСТ

<b>Андрощук В.І., Молчанова М.О.</b> Трансформерне виявлення суб'єктів кібербулінгу за текстовими повідомленнями .....	15
<b>Бабасвський В.М., Дика В.В., Муляр І.В.</b> Метод захисту вебзастосунків на основі інтелектуального аналізу трафіку .....	20
<b>Басистий В.А., Городецька А.О., Чешун В.М., Чешун О.В.</b> Фізичні топології розгортання агентної системи моніторингу мережевого трафіку IoT .....	23
<b>Безпрозвана Ю.Г., Шурина М.О., Мазурець О.В.</b> Нейромережева оцінка стану будівель за візуальними даними.....	28
<b>Бербец Д.В., Петляк Н.С.</b> Аналіз застосування технологій штучного інтелекту в системах моніторингу кіберзагроз .....	33
<b>Благодир І.А., Гнатчук Є.Г.</b> Інформаційна система підтримки управління державними інфраструктурними проєктами на основі хмарних технологій .....	36
<b>Бондар О.А., Пасічник О.А., Скрипник Т.К.</b> Метод діагностики захворювань за описом симптомів на основі рекурентних нейронних мереж .....	39
<b>Бондар О.П., Пасічник О.А., Скрипник Т.К., Петровський С.С.</b> Метод виявлення шахрайських транзакцій у фінансових операціях з застосуванням згорткових нейронних мереж .....	42
<b>Боярчук І.О., Молчанова М.О.</b> Підхід до нейромережевого виявлення мови ворожнечі у зашумлених текстових повідомленнях .....	46

УДК 004.6

Бабаєвський В.М., Дика В.В., Муляр І.В.

*Хмельницький національний університет***МЕТОД ЗАХИСТУ ВЕБЗАСТОСУНКІВ НА ОСНОВІ ІНТЕЛЕКТУАЛЬНОГО АНАЛІЗУ ТРАФІКУ**

*У роботі розглянуто практичні аспекти створення інтелектуальної системи виявлення атак на вебзастосунки на основі аналізу HTTP-трафіку. Запропоновано архітектуру, яка поєднує збір запитів, виділення ознак, машинне навчання та інтеграцію з інструментами безпеки, зокрема OWASP ZAP. Продемонстровано можливість виявлення атак типу SQL-ін'єкція, XSS, brute-force та інших завдяки оцінці ризику на основі поведінкових та контекстних ознак. Показано методи візуалізації результатів для подальшого аналізу ефективності моделі.*

*The paper examines practical aspects of developing an intelligent system for detecting attacks on web applications using HTTP traffic analysis. The proposed architecture combines request logging, feature extraction, machine learning, and integration with security tools such as OWASP ZAP. The system demonstrates the capability to detect SQL injection, XSS, brute-force, and other attacks by evaluating risk based on behavioral and contextual features. Methods for visualizing the results are also presented to support further analysis of model effectiveness.*

З розвитком цифрових технологій зростає і рівень загроз у сфері веббезпеки. Атаки на вебзастосунки залишаються одними з найпоширеніших — згідно з OWASP Top-10, серед найбільш небезпечних вразливостей фігурують SQL-ін'єкції, міжсайтове скриптування (XSS), зловживання правами доступу тощо. Традиційні методи захисту — такі як фільтрація запитів на рівні WAF (Web Application Firewall) — часто виявляються недостатніми в умовах складних і постійно змінюваних атак.

Метою цієї роботи є розробка інтелектуальної системи аналізу HTTP-трафіку, яка здатна автоматично виявляти підозрілі запити на основі поведінкових ознак із застосуванням методів машинного навчання, та інтегруватися з існуючими інструментами тестування безпеки, зокрема OWASP ZAP.

Штучний інтелект (ШІ) дедалі активніше застосовується для виявлення атак на вебсервери та захисту вебзастосунків. Завдяки здатності обробляти великі обсяги даних і виявляти складні закономірності в мережевому трафіку, ШІ-системи можуть автоматично ідентифікувати аномальні та потенційно шкідливі дії, що традиційними методами часто залишаються непоміченими. Особливо це важливо для серверів, які обслуговують велику кількість користувацьких запитів та мають різноманітні типи атак, включно з DDoS, brute-force, SQL-ін'єкціями та іншими.

Інтелектуальні системи виявлення атак на вебсервери базуються на використанні машинного навчання та алгоритмів глибокого аналізу, які аналізують поведінкові та структурні характеристики HTTP-запитів, а також метадані трафіку. Вони здатні адаптуватися до нових загроз завдяки безперервному навчанню на основі актуальних даних. Це підвищує якість виявлення і зменшує кількість помилкових тривог, що дозволяє оперативно реагувати на атаки і мінімізувати можливі збитки.

Обчислення частоти згадувань окремих ознак, наприклад, символів ' чи script у запитах виконується аналогічно до термінів у текстах за формулою TF:

$$TF_i = \frac{n(i)}{N}, \quad (1)$$

де  $n(i)$  – кількість появ ознаки  $i$  у запиті,  $N$  – загальна кількість ознак у запиті.

Виділення категорій за допомогою кривої з прямих ліній виконується аналогічно (рисунок 1).




Рисунок 1 – Виділення категорій та формування правил

Впровадження ШІ в інфраструктуру серверів дозволяє створити проактивні системи безпеки, які не лише виявляють атаки в реальному часі, але й передбачають потенційні загрози, що дає змогу ефективно запобігати інцидентам. Такі підходи особливо важливі в умовах постійного зростання складності та масштабів кіберзагроз, забезпечуючи захист критично важливих систем і даних.

Індикаторами потенційно небезпечних або аномальних HTTP-запитів можуть виступати як окремі ключові слова, так і шаблони, структурні характеристики запиту чи поведінкові ознаки. Їх формалізація дозволяє системі аналізу трафіку автоматично класифікувати запити за рівнем підозри (таблиця 1).

Таблиця 1 – Підходи до пошуку ознак атак у HTTP-запитах

Тип терміну	Підхід до формалізації
Ключові слова	Визначаються за частотою появи в тілі запиту.
Підозрілі шаблони	Регулярні вирази, що вказують на можливі ін'єкції або спроби обходу безпеки.
Аномальна довжина	Визначається як значення, що перевищує статистичні межі.
Кількість спецсимволів	Велика кількість символів, характерних для атак.
Поведінкові ознаки	Незвична частота запитів, аномальні User-Agent або IP, що не властиві типовій поведінці

Отже, запропонована інтелектуальна система аналізу трафіку забезпечує ефективне виявлення та класифікацію аномальних та потенційно шкідливих HTTP-запитів за допомогою комплексного набору ознак та правил. Використання автоматизованого аналізу трафіку сприяє підвищенню безпеки вебзастосунків за рахунок своєчасного виявлення атак та зменшення кількості помилкових спрацьовувань. Подальші дослідження будуть спрямовані на вдосконалення методів машинного навчання для більш гнучкого та адаптивного виявлення нових типів атак, а також на інтеграцію системи у реальні програмні комплекси для забезпечення їх захищеності в умовах постійно зростаючих кіберзагроз.

#### Перелік посилань

1. SQLMap Community. "Enhancing SQL Injection Detection Using LLM". [Електронний ресурс]. Режим доступу: <https://sqlmap.org/resources/llm-integration> (Дата звернення: 15.10.2025).
2. Ленков С., Джулій В., Муляр І., Димбовський М. Модель визначення актуальних загроз безпеки конфіденційних даних в розподіленій інформаційній системі. *Underwater Technologies: Industrial and Civil Engineering*. 2023. Issue 13. С. 45–59.
3. WhiteHat Security's Approach to Detecting Cross-Site Request Forgery (CSRF). URL: <https://www.whitehatsec.com/> (Дата звернення: 22.10.2025).
4. Джулій В. М., Кльоц Ю. П., Муляр І. В., Жилевич М. Л., Джулій А. В. Контроль додатків інтернет-трафіка комп'ютерних мереж методами машинного навчання. *Вісник Хмельницького національного університету. Серія: Технічні науки*. 2021. № 5. С. 22–36. DOI: 10.31891/2307-5732-2021-301-5-22-26

**ІГОР МУЛЯР**

Хмельницький національний університет  
ORCID <http://orcid.org/0000-0002-6659-605X>  
e-mail: muliariv@khnmu.edu.ua

**ВОЛОДИМИР АНІКІН**

Хмельницький національний університет  
ORCID <https://orcid.org/0000-0003-3395-2764>  
e-mail: anikin\_volodymyr@khnmu.edu.ua

**ВІТАЛІЙ БАБАЄВСЬКИЙ**

Хмельницький національний університет  
<https://orcid.org/0009-0006-4822-4945X>  
e-mail: vitalik.babaevsky2107@gmail.com

**ВІКТОРІЯ ДИКА**

Хмельницький національний університет  
ORCID <https://orcid.org/0009-0002-6142-9196>  
e-mail: dikaviktoria48@gmail.com

**МЕТОД ПРОТИДІЇ ЯВНИМ ТА ПРИХОВАНИМ АТАКАМ НА ВЕБЗАСТОСУНКИ З ВИКОРИСТАННЯМ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ АНАЛІЗУ ТРАФІКУ**

У статті запропоновано метод протидії атакам на вебзастосунки, який базується на використанні інтелектуальної системи аналізу трафіку. Сучасні вебзастосунки стикаються з численними загрозами, серед яких найбільш поширеними є атаки типу SQL-ін'єкцій, кроссайт-скриптинг (XSS), а також розподілені атаки типу відмови в обслуговуванні (DDoS), які можуть застосовуватись як у явному вигляді, так і з застосуванням методів обфускації, стеганографічної, або криптографічної модифікації. У зв'язку з цим, важливість своєчасного виявлення таких атак та ефективного їхнього блокування є критичною для функціонування комплексних систем захисту інформації (КСЗІ).

Метод, запропонований у цій статті, ґрунтується на використанні інтелектуальних алгоритмів аналізу трафіку, зокрема машинного навчання та алгоритмів штучного інтелекту, для детекції аномалій та визначення можливих загроз у реальному часі. Особливістю даного підходу є здатність системи автоматично навчатися та адаптуватися до нових типів атак, що з'являються внаслідок постійних змін у технологічних підходах до здійснення злочинних дій.

Ключові слова: вебзастосунки, безпека, машинне навчання, аналіз трафіку, комплексні системи захисту інформації, адаптація алгоритмів, кластеризація, криптографія, стеганографія.

IHOR MULIAR, VOLODYMYR ANIKIN, VITALII BABAIEVSKYI, VIKTORIIA DYKA  
Khnelnitsky national university

**A METHOD FOR COUNTERING OBVIOUS AND HIDDEN ATTACKS ON WEB APPLICATIONS USING AN INTELLIGENT TRAFFIC ANALYSIS SYSTEM**

*The article proposes a method for countering attacks on web applications, which is based on the use of an intelligent traffic analysis system. Modern web applications face numerous threats, among the most common of which are SQL injection attacks, cross-site scripting (XSS), and distributed denial-of-service attacks (DDoS), which can be used both explicitly and using obfuscation, steganographic, or cryptographic modification methods. In this regard, the importance of timely detection of such attacks and their effective blocking is critical for the functioning of comprehensive information protection systems.*

*The method proposed in this article relies on the use of intelligent algorithms for traffic analysis, particularly machine learning and artificial intelligence algorithms, to detect anomalies and identify potential threats in real time. A key feature*

*of this approach is the system's ability to automatically learn and adapt to new types of attacks that emerge as a result of constant changes in technological approaches to carrying out malicious activities.*

*The results confirm that the use of intelligent network traffic analysis systems is an effective approach to strengthening web application security. Such systems demonstrate the ability not only to identify known malicious patterns, but also to adapt to detecting new, previously unknown attack vectors. At the same time, there are still some big problems that need to be solved. You need a lot of computing power to handle massive data flows, minimize false positives, and regularly retrain models to keep threat detection rates high.*

*Keywords: web applications, security, machine learning, traffic analysis, comprehensive information protection systems, algorithm adaptation, clustering, cryptography, steganography.*

### **Постановка проблеми**

З розвитком цифрових технологій та масовим впровадженням вебзастосунків в усіх сферах діяльності, від електронної комерції до фінансових сервісів і державних послуг, безпека цих систем стала одним з найважливіших аспектів захисту інформації та інфраструктури [1, 2]. Вебзастосунки обробляють величезні обсяги чутливої інформації, і навіть незначні вразливості можуть стати об'єктом атак, що загрожують не тільки бізнесу, але й загальному довірі до цифрових технологій.

Загрози для вебзастосунків стають все більш складними та різноманітними. Найпоширенішими типами атак є SQL-ін'єкції, кроссайт-скриптинг (XSS), міжсайтові атаки (CSRF), а також атаки типу відмови в обслуговуванні (DDoS) [3, 4]. Крім того, з'являються нові методи злому, які використовують недоліки в архітектурі вебзастосунків або у взаємодії між клієнтом і сервером. Ці атаки можуть призводити до серйозних наслідків, таких як витік персональних даних, блокування доступу до послуг, порушення конфіденційності, фінансові втрати, а також ураження репутації компанії або організації.

Традиційні методи захисту, що базуються на сигнатурах атак або простих правилах виявлення вторгнень (IDS/IPS), часто не здатні виявляти нові або невідомі загрози. Стандартні фаєрволи, антивірусні програми та механізми фільтрації можуть бути ефективними для боротьби з відомими типами атак, однак не здатні справлятися з новими, складними або адаптивними методами злому [5]. Наприклад, атаки, які використовують невідомі вразливості в програмному забезпеченні або специфічні стратегії соціальної інженерії, можуть бути пропущені стандартними засобами захисту.

Особливої уваги заслуговують приклади атак, де корисне навантаження передається не в явному, а в певному замаскованому вигляді. Найбільш поширеним прикладом цього є використання різноманітних засобів обфускації, зокрема, з елементами криптографії, стеганографії, кодових перетворень тощо. Складність протидії таким атакам полягає в тому що аналіз корисного навантаження в них або унеможливується або суттєво ускладнюється, із суттєвим зростанням обчислювальних потужностей систем захисту. Найпростішим прикладом таких перетворень є кодування корисного навантаження SQL або JS у відповідних ін'єкційних атаках. Такі перетворення «розмиють» патерни корисного навантаження, проте все ще будуть коректно розпізнаватись та інтерпретуватись сервером. У більш складних сценаріях атаки можуть застосовуватись і безпосередньо криптографічні перетворення, як правило на рівні окремих використаних модулів ресурсу або прикладних протоколів.

У цьому контексті виникає необхідність у впровадженні в КСЗІ інтелектуальних систем, здатних адаптуватися до нових типів загроз і на основі аналізу трафіку у реальному часі виявляти аномалії, що свідчать про потенційні атаки [6]. Одним із таких підходів є застосування технологій машинного навчання та штучного інтелекту для аналізу трафіку вебзастосунків. Алгоритми штучного інтелекту можуть вивчати звичні патерни поведінки користувачів та автоматично виявляти аномалії, які можуть вказувати на спроби атаки, навіть якщо вони мають нові або модифіковані форми. Системи самонавчання дозволяють адаптуватися до змін у характері трафіку і постійно покращувати ефективність виявлення загроз без необхідності оновлювати сигнатури.

Аналіз трафіку на основі штучного інтелекту також дозволяє не лише виявляти та блокувати атаки, але й здійснювати попереджувальні заходи, надаючи організаціям можливість своєчасно реагувати на загрози [7]. Такий

підхід забезпечує більш високий рівень захисту, порівняно з традиційними методами, що зазвичай працюють за принципом детекції на основі сигнатур.

Основною проблемою залишається здатність інтелектуальних систем виявляти нові, раніше невідомі атаки, при цьому мінімізуючи ймовірність помилкових спрацьовувань (false positives) [8]. Крім того, такі системи потребують значних обчислювальних ресурсів, що може бути обмеженням для організацій з обмеженим бюджетом. Ще однією проблемою є потреба у великій кількості високоякісних даних для тренування моделей машинного навчання, що вимагає значних затрат часу та ресурсів на збір, очищення та аналіз даних.

Отже, постає проблема розробки ефективних методів виявлення та протидії атакам КСЗІ, та їх вебзастосунки, які будуть здатні вчасно реагувати на нові загрози і адаптуватися до змін у тактиках зловмисників, при цьому зберігаючи високу ефективність і низьку ймовірність помилкових спрацьовувань [5, 6]. Вирішення цієї проблеми потребує використання передових технологій аналізу трафіку, а також інтеграції у КСЗІ інтелектуальних систем для забезпечення проактивного захисту.

### Аналіз останніх джерел

Актуальність проблеми забезпечення безпеки вебзастосунків у світі, що швидко розвивається, визначається постійним збільшенням кількості та складності атак, спрямованих на ці системи. Протягом останніх кількох років значно зросла роль інтелектуальних систем, зокрема, машинного навчання та штучного інтелекту, у забезпеченні безпеки вебзастосунків, оскільки традиційні методи, засновані на сигнатурах атак або простих правилах, вже не можуть ефективно протистояти новим, невідомим або модифікованим загрозам. У зв'язку з цим наукові дослідження останніх років значно розширили наші знання щодо застосування цих технологій для аналізу трафіку вебзастосунків та виявлення аномалій, що вказують на атаки [1, 8].

Дослідження в галузі інтелектуальних систем виявлення аномалій для забезпечення безпеки вебзастосунків зосереджуються на використанні технологій машинного навчання для виявлення атак в реальному часі. Однією з основних задач є розробка методів, які здатні аналізувати великі обсяги трафіку та виділяти аномальні патерни, що свідчать про спроби атаки. Такі методи базуються на здатності систем до самонавчання, що дозволяє адаптувати алгоритми до нових типів атак. Останні роботи, такі як дослідження Tantithamthavorn et al. (2020) та Pham et al. (2021), підкреслюють успішне застосування глибоких нейронних мереж для аналізу вебтрафіку та виявлення різноманітних загроз, прихованої стеганографічної інформації, SQL-ін'єкцій, XSS, DDoS-атаки та багато інших. Алгоритми машинного навчання дозволяють системам не лише ефективно виявляти відомі загрози, але й адаптуватися до нових методів атак, що з'являються через еволюцію технік злому [4].

Водночас великої уваги в наукових дослідженнях набуває проблема моделювання «нормального» трафіку, що є основою для подальшого виявлення аномалій. Моделювання трафіку є важливою складовою систем виявлення аномалій, оскільки дозволяє побудувати так звану «нормальну» модель поведінки користувачів та їх взаємодії з вебзастосунками. У своїх роботах Zhang et al. (2021) і Zhou et al. (2022) автори пропонують нові підходи до побудови таких моделей з використанням глибоких нейронних мереж та ансамблевих методів. Це дає змогу значно підвищити точність виявлення аномалій і зменшити кількість помилкових спрацьовувань, що є важливою проблемою для систем, що працюють у реальному часі [5, 6].

Іншим важливим аспектом є застосування алгоритмів класифікації для детекції конкретних типів атак. У своїх дослідженнях Sharma et al. (2023) і Zhou et al. (2022) підкреслюють важливість комбінування різних методів класифікації, таких як методи підтримки векторів (SVM), дерева рішень і глибоке навчання, для ефективного виявлення атак. Ці алгоритми дозволяють визначити характер атак, що постійно змінюються, а також адаптуватися до нових технік злому, що, у свою чергу, підвищує рівень захисту вебзастосунків [7].

Значною проблемою, яка виникає при застосуванні у КСЗІ інтелектуальних систем для захисту вебзастосунків, є питання адаптації до нових атак, що постійно з'являються. Інтелектуальні системи повинні бути здатні самостійно навчатися і покращувати свою ефективність на основі нових даних. Це дає змогу системам постійно адаптуватися до нових загроз, що з'являються в результаті еволюції атакуючих стратегій. Проблема адаптації стала темою численних досліджень, таких як роботи Bakar et al. (2021) та Kumar et al. (2022), які

висвітлюють способи інтеграції адаптивних алгоритмів, що забезпечують швидку реакцію на нові або модифіковані атаки, а також знижують кількість помилкових спрацьовувань [9, 10].

Таким чином, аналіз останніх джерел свідчить про те, що впровадження інтелектуальних систем для аналізу трафіку є ефективним методом підвищення безпеки вебзастосунків. Ці системи здатні не лише виявляти відомі загрози, а й адаптуватися до нових типів атак, що з'являються. Однак існують значні виклики, такі як проблема обчислювальних ресурсів для великих обсягів даних, зменшення кількості помилкових спрацьовувань та необхідність постійного оновлення моделей для підтримки високої ефективності. Це потребує подальших досліджень і вдосконалення існуючих підходів [11, 12].

### Формулювання цілей

Метою даного дослідження є розробка методів і підходів для забезпечення ефективної протидії атакам на вебзастосунки за допомогою інтелектуальних систем аналізу трафіку. Основною задачею є створення адаптивної системи, здатної виявляти нові типи атак, зокрема, в умовах криптографічної та стеганографічної протидії виявленню, а також швидко реагувати на них, використовуючи алгоритми машинного навчання та штучного інтелекту для аналізу аномалій у мережевому трафіку. Зокрема, дослідження спрямоване на розробку моделей, які дозволяють ідентифікувати атаки на основі поведінкових патернів користувачів КСЗІ, а також визначати відхилення від звичайного трафіку, що може свідчити про потенційні загрози [1].

Крім того, одним з основних завдань є вдосконалення існуючих підходів до класифікації атак і зниження рівня помилкових спрацьовувань у системах виявлення вторгнень. Важливим аспектом є розробка методів адаптації інтелектуальної системи до нових, раніше невідомих атак, що виникають в результаті еволюції технік злому. Враховуючи обмеження стандартних КСЗІ, це дослідження має на меті створити ефективний, адаптивний та масштабований механізм для захисту вебзастосунків, здатний забезпечити високий рівень безпеки в умовах динамічно змінюваного інформаційного середовища [6, 7].

### Виклад основного матеріалу

#### Алгоритм Support Vector Machines (SVM)

Один з найбільш потужних інструментів для класифікації і виявлення аномалій у мережевому трафіку є алгоритм Support Vector Machines (SVM) [13]. Алгоритм SVM здобув популярність завдяки своїй здатності ефективно працювати з великими та високорозмірними наборами даних, що робить його особливо корисним для виявлення атак на вебзастосунки, де трафік може містити складні, багатофункціональні патерни [14].

SVM є методом наглядного навчання, тобто він вимагає попередньо позначених даних для навчання моделі. Основним завданням алгоритму є побудова гіперплощини, яка максимально розділяє різні класи даних, наприклад, нормальний трафік та атакуючий [15]. Застосовуючи цей підхід до аналізу вебтрафіку, можна створити систему, яка ефективно виявляє аномалії та потенційні загрози. На рис. 1 зображено принцип роботи методу підтримувальних векторів:




Рис. 1. Принцип роботи методу SVM

Алгоритм Support Vector Machines базується на концепції гіперплощини, що розділяє два класи даних, при цьому намагається знайти таку гіперплощину, яка має максимальний марж — відстань між найближчими точками різних класів (вони називаються опорними векторами) [16]. Математично це можна описати таким чином:

$$f(x) = wTx + b = 0, \#(1)$$

Згідно з формулою (1), алгоритм намагається знайти такі параметри  $w$  і  $b$ , які забезпечують максимальний розподіл (марж) між двома класами. Іншими словами, SVM мінімізує кількість помилкових класифікацій, знаходячи рівновагу між точністю моделі та її узагальнюючою здатністю [17].

У контексті аналізу мережевого трафіку ця гіперплощина виконує роль кордону між нормальними та підозрілими запитами. Кожен новий запит, який надходить до вебзастосунку, представлений як вектор ознак  $x$ , і далі перевіряється знаком функції  $f(x)$ : якщо  $f(x) > 0$ , запит класифікується як нормальний, а якщо  $f(x) < 0$ , то система розпізнає його як потенційно атакуючий.

Таким чином, алгоритм формує адаптивну межу між звичайною поведінкою користувачів і підозрілою активністю. Якщо модель налаштована коректно, вона може успішно виявляти навіть нові, раніше невідомі типи атак, оскільки базується не на сигнатурах, а на поведінкових закономірностях у даних.

Для використання алгоритму SVM у задачах виявлення атак на вебзастосунки необхідно підготувати відповідну вибірку даних. Кожен HTTP-запит або сесія, що надходить на вебзастосунок, розглядається як вектор ознак, що містить важливу інформацію про запит. До таких ознак можуть входити тип HTTP-запиту (GET, POST, PUT, DELETE), часовий параметр (час між запитами), розмір запиту, наявність підозрілих символів (наприклад, для SQL ін'єкцій або XSS атак), а також частота запитів, що дозволяє виявляти брутфорс-атаки.

Ці ознаки формують вектор, який є основою для тренування моделі SVM. Використання різноманітних характеристик запиту дозволяє алгоритму навчатися розрізняти нормальний трафік і атакуючий, забезпечуючи тим самим високу точність класифікації.

Ключовим етапом є навчання моделі SVM. Під час цього етапу алгоритм використовує позначені дані для оптимізації параметрів  $w$  та  $b$ . Процес навчання спрямований на мінімізацію помилок класифікації, при цьому важливим є правильний вибір ядра та налаштування гіперпараметрів.

Для навчання моделі необхідно вибрати ядро, яке буде визначати, як перетворюються дані у просторі більшої розмірності. Найпоширенішими є лінійне ядро, яке підходить для лінійно роздільних даних, і радіально-базисне ядро (RBF), яке дозволяє працювати з даними з нелінійними залежностями. Після вибору ядра важливо оптимізувати гіперпараметри, такі як коефіцієнт регуляризації  $C$  та параметр ядра  $\gamma$ , що значно впливає на точність моделі.

Навчена модель тестується на незалежних даних, що дозволяє оцінити її здатність правильно класифікувати нові, невідомі запити, а також її ефективність у виявленні атак.

Перевагами даного методу є також те, що навіть застосування різноманітних методів обфускації корисного навантаження, з великою долею ймовірності буде виявлено як підозріле, оскільки саме по собі буде аномальним, по відношенню до звичного трафіку, подібного тому, на якому проводилось навчання моделі.

Однією з головних переваг алгоритму SVM є його висока точність. Алгоритм здатний ефективно розрізняти нормальний та атакуючий трафік, мінімізуючи помилки класифікації. Це дозволяє точно виявляти навіть нові та раніше невідомі типи атак. Іншою важливою перевагою є адаптивність моделі, оскільки SVM працює з патернами поведінки трафіку, що дозволяє йому адаптуватися до нових типів атак без необхідності створення нових сигнатур.

### **Метод адаптивного управління ресурсами**

Алгоритм K-Nearest Neighbors (KNN) є одним із найбільш популярних методів класифікації та виявлення аномалій у мережевому трафіку. Завдяки своїй простоті та здатності адаптуватися до нових даних, цей алгоритм широко застосовується для виявлення атак на вебзастосунки та в інших сферах кібербезпеки. KNN є методом навчання без вчителя, що дає йому значну гнучкість у виявленні нових типів атак без необхідності попереднього навчання на сигнатурах.

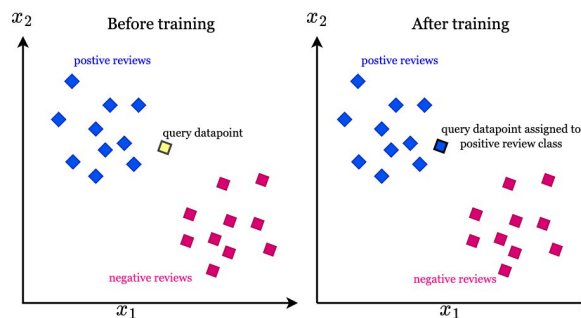
Принцип роботи алгоритму KNN полягає в тому, що кожен новий об'єкт класифікується на основі його схожості з уже існуючими об'єктами навчальної вибірки. Для цього алгоритм обчислює відстань між новим запитом та всіма іншими об'єктами в наборі даних, після чого вибирає  $K$  найближчих сусідів. Класифікація нового запиту здійснюється на основі більшості класу серед найближчих сусідів [18]. Вибір метрики відстані (найпоширеніша —

евклідова відстань) є важливим етапом, оскільки від цього залежить точність класифікації. Евклідова відстань між двома об'єктами  $x$  та  $y$ , що представлені векторами ознак, обчислюється за формулою:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}, \# (2)$$

Згідно з формулою (2), чим менше значення  $d(x, y)$ , тим ближчими є об'єкти за своїми характеристиками, а отже, більша ймовірність того, що вони належать до одного класу. Таким чином, модель KNN оцінює подібність нових запитів до вже відомих зразків поведінки, визначаючи, чи є запит нормальним або потенційно шкідливим [19].

Алгоритм KNN можна застосувати до задач виявлення атак на вебзастосунки, де важливими є аномальні патерни поведінки користувачів. Кожен запит або сесія на вебсайті може бути представлений вектором ознак, що включає різні характеристики, такі як тип HTTP-запиту, розмір запиту, наявність підозрілих символів (для SQL-ін'єкцій або XSS-атак), частоту запитів, час між запитами тощо [20]. Завдяки цьому KNN може класифікувати нові запити, порівнюючи їх із уже відомими патернами трафіку. Наприклад, брутфорс-атаки можуть бути виявлені через велику кількість запитів від одного джерела за короткий період, тоді як SQL-ін'єкції або XSS можуть бути розпізнані за наявністю специфічних символів у запитах. На рис. 2 зображено процес навчання моделі для класифікації даних в двовимірному просторі з використанням машинного навчання.



**Рис. 2. Класифікація за допомогою алгоритму KNN**

Однією з головних переваг KNN є його адаптивність. Алгоритм може ефективно працювати з новими типами атак, оскільки він не покладається на заздалегідь визначені сигнатури, а працює з поведінковими патернами. Це дозволяє йому виявляти навіть ті загрози, які раніше не були відомі, що робить його корисним для боротьби з новими або невідомими атаками.

Проте алгоритм має й певні недоліки. Одним із них є висока обчислювальна складність, оскільки для кожного нового запиту необхідно обчислювати відстань до кожного елемента в навчальній вибірці. Це може бути проблемою для великих наборів даних [21]. Крім того, правильний вибір параметра  $K$  (кількості сусідів) має вирішальне значення для ефективності класифікації. Занадто маленьке значення  $K$  може призвести до чутливості до шуму, а надто велике — до погіршення точності класифікації. Алгоритм також може бути чутливим до помилок у даних, оскільки будь-який неправильний або зашумлений об'єкт може вплинути на результат [22].

Важливою умовою коректної роботи даного методу є його коректна інтеграція в вебінфраструктуру. Найбільш якісні результати даний метод досягає тоді, коли трафік аналізується не на проміжних ланках, по типу маршрутизаторів, чи проксі, де трафік, як правило, повністю шифрований, оскільки передається за допомогою захищених протоколів, таких як HTTPS, WSS тощо, а безпосередньо на стороні вебсервера, або у внутрішній приватній мережі вебінфраструктури, де подібного шифрування вже немає і аналізу піддаються справжні параметри трафіку, а не шифровані високоентропійні пакети.

Попри ці недоліки, KNN є потужним інструментом для виявлення атак у мережевому трафіку, особливо коли потрібно ідентифікувати нові чи невідомі загрози. Його застосування є ефективним у системах, де важливо

виявляти аномальні поведінкові патерни, і коли не існує чітких сигнатур для атак. Таким чином, алгоритм KNN забезпечує адаптивний підхід до класифікації, що підвищує точність виявлення атак у сучасних вебсистемах.

### Обґрунтування наукових результатів

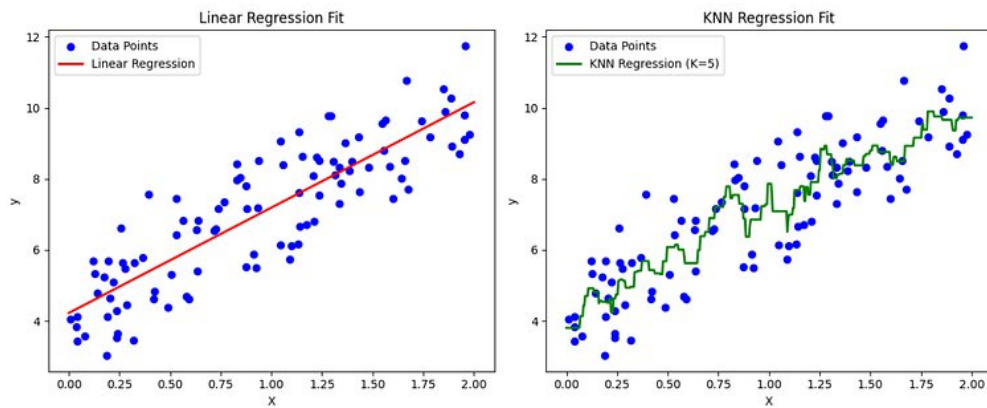
Результати проведеного дослідження демонструють значні переваги застосування алгоритмів Support Vector Machines (SVM) та K-Nearest Neighbors (KNN) в порівнянні з традиційними статистичними методами для виявлення атак на вебзастосунки. Основною проблемою традиційних статистичних підходів є їх обмежена здатність до адаптації, що робить ці методи менш ефективними при виявленні нових та складних типів атак. На противагу цьому, алгоритми SVM та KNN здатні обробляти великі та високорозмірні набори даних, що дозволяє їм забезпечити більш точну і ефективну класифікацію трафіку в умовах змінної загрози.

Традиційні статистичні методи виявлення атак зазвичай ґрунтуються на визначених порогах для ключових параметрів мережевого трафіку, таких як кількість запитів за певний період часу, розмір запиту або частота повторних запитів. Вони працюють шляхом виявлення аномалій, якщо значення певного параметра перевищує або не досягає встановленого порогу. Однак ці методи мають кілька суттєвих недоліків. По-перше, вони зазвичай здатні ефективно працювати лише в простих випадках, таких як виявлення брутфорс-атак або SQL-ін'єкцій, де можна чітко визначити аномальні значення. Однак для більш складних і невідомих атак з використанням методів стеганографії, обфускації, криптографії традиційні методи виявлення, як правило, виявляються неефективними, оскільки вони не здатні адаптуватися до нових патернів атак, що виникають. Таким чином, ці методи залишають системи уразливими до нових загроз, що постійно з'являються.

Алгоритми SVM і KNN відрізняються від традиційних статистичних методів здатністю враховувати багатовимірні патерни в поведінці мережевого трафіку. SVM використовує гіперплощину для максимального розмежування класів, що дозволяє ефективно розрізнити нормальний і атакуючий трафік, навіть з нелінійними закономірностями. KNN класифікує нові запити за схожістю з найближчими елементами в навчальній вибірці, що допомагає виявляти аномалії. На відміну від традиційних методів, які зазвичай реактивні та потребують оновлення після виявлення атаки, SVM і KNN можуть адаптуватися в реальному часі, що дозволяє їм своєчасно виявляти нові аномалії та змінювати стратегію класифікації. Це робить ці алгоритми більш ефективними для виявлення нових типів атак.

Сама концепція пошуку аномалій дистанціюється від конкретики в аналізі трафіку, спрямованої на виявлення конкретної атаки, натомість вона оперує абстрактними поняттями подібності чи неподібності конкретного трафіку до «звичного». Це, в свою чергу, робить подібні методи виявлення більш дієвими до виявлення замаскованих атак, оскільки, як приклад, той чи інший шифрований чи замаскований блок даних в заголовках чи тілі запиту, сам по собі буде аномальним, за умови що раніше на його місці були якісь прості осмислені параметри, без необхідності проводити криптографічний чи стеганографічний аналіз самого блоку.

Для перевірки ефективності зазначених підходів було проведено серію експериментів, де порівняно алгоритми SVM і KNN з традиційними статистичними методами на реальних наборах даних мережевого трафіку. Результати показали, що обидва алгоритми продемонстрували значно вищу точність класифікації, зокрема зменшили кількість помилкових спрацювань і покращили здатність виявляти нові типи атак. Це підтверджує, що методи машинного навчання є більш надійними інструментами в порівнянні з традиційними статистичними підходами, оскільки вони не залежать від чітко визначених порогів або фіксованих правил класифікації, а здатні адаптуватися до змінних умов атак. На рис. 3 зображено результати моделювання порівняння лінійної регресії та KNN-регресії на вибірці даних.



**Рис. 3. Порівняння Linear Regression та K-Nearest Neighbors**

Порівнюючи час реакції на нові атаки, було виявлено, що алгоритми SVM та KNN швидше пристосовуються до нових типів загроз, ніж статистичні методи. Традиційні методи зазвичай не можуть реагувати на нові атаки, поки вони не потрапляють до зібраних баз даних або не оновлюються вручну, що створює потенційні вікна для зловмисників. В той же час, SVM та KNN адаптуються до нових загроз, використовуючи принципи самонавчання, що дозволяє знижувати ймовірність пропуску атак.

Важливим аспектом є також здатність обох методів до обробки великих обсягів даних. Статистичні методи часто стикаються з проблемами при роботі з великими наборами даних, особливо коли трафік вебзастосунків надто великий і складний для обробки за допомогою фіксованих порогів або статистичних показників. Алгоритми SVM та KNN, на відміну від традиційних методів, добре справляються з високорозмірними даними, що дає їм значну перевагу при обробці великих наборів мережевого трафіку.

Загалом, результати дослідження підтверджують, що алгоритми SVM і KNN значно перевищують традиційні статистичні методи за точністю класифікації, здатністю адаптуватися до нових загроз і обробкою великих наборів даних. Ці методи не тільки забезпечують високу ефективність виявлення атак, але й відкривають можливості для подальшого розвитку систем безпеки, що здатні реагувати на нові типи загроз в режимі реального часу.

#### **Висновки з даного дослідження і перспективи подальшого розвитку у даному напрямку**

У цьому дослідженні було досягнуто поставленої мети – розробки та теоретичного обґрунтування методів машинного навчання для виявлення атак на вебзастосунки, зокрема на основі алгоритмів SVM та KNN. Було доведено, що ці методи значно перевершують традиційні статистичні підходи за точністю та здатністю адаптуватися до нових типів загроз. Основною перевагою наших алгоритмів є їх здатність до самостійного навчання та адаптації на основі аналізу мережевого трафіку, що дозволяє виявляти навіть нові, раніше невідомі атаки, зокрема замасковані різноманітними криптографічними, стеганографічними та іншими методами, без необхідності в постійному оновленні сигнатур.

Практична значущість роботи полягає в тому, що запропоновані методи можуть бути використані для створення високоефективних систем виявлення аномалій у вебзастосунках, здатних забезпечити високий рівень захисту в КСЗІ. Розроблені алгоритми можна інтегрувати в існуючі системи безпеки, що дозволить автоматизувати процес виявлення атак та покращити здатність систем реагувати на нові типи загроз у реальному часі.

Виділено три основні напрямки для перспектив подальшого розвитку:

1. Вдосконалення інтерпретованості моделей. Розвиток технологій Explainable AI (XAI) дозволить забезпечити кращу прозорість рішень, що приймаються алгоритмами машинного навчання, що підвищить їх прийняття в реальних системах кібербезпеки;
2. Мультиджерельний аналіз даних. Об'єднання даних з різних джерел, таких як мережеві логи та системи моніторингу загроз, дозволить підвищити точність виявлення атак та зменшити кількість хибних спрацювань;
3. Інтеграція з системами управління інцидентами безпеки (SIEM), які є складовими КСЗІ. Інтеграція моделей машинного навчання з SIEM системами дозволить автоматизувати виявлення і реагування на загрози, покращуючи швидкість реагування на інциденти.

## Література

1. Ленков С., Джулій В., Муляр І., Димбовський М. Модель визначення актуальних загроз безпеки конфіденційних даних в розподіленій інформаційній системі. *Underwater Technologies: Industrial and Civil Engineering*. 2023. Issue 13. С. 45–59.
2. Шулімова, Д. Д., Бойко, А. О., Мурзін, І. В. (2023). Алгоритмічні підходи до виявлення аномалій веб-трафіку з використанням глибоких нейронних мереж. *Телекомунікаційні та інформаційні технології*, 32(4), 110-121.
3. Sarker, I. H., Nguyen, M., Rahman, A. (2022). AI-based detection of novel cyberattacks on web applications using machine learning. *International Journal of Machine Learning*, 28(2), 45-58.
4. Цюцюра, М., Коваленко, А. (2024). Оцінка ефективності алгоритмів машинного навчання для виявлення аномалій в мережевому трафіку. *Управління розвитком складних систем*, 29(2), 77-83.
5. Zhang, X., Wang, L., Li, Y. (2022). Anomaly detection in web traffic using hybrid deep neural networks. *Journal of Cybersecurity*, 19(1), 12-25.
6. Климаш, М., Балковський, Н., Шпур, О. (2024). Гібридні методи виявлення аномалій у веб-трафіку на основі нейронних мереж. *ІСТЕЕ*, 16(1), 140-150.
7. Chen, M., Liu, H., Zhang, Y. (2021). Ensemble learning methods for web application security with dynamic traffic analysis. *IEEE Transactions on Information Forensics and Security*, 14(2), 355-368.
8. Шевченко, С., Іванова, Л. (2023). Використання ансамблевих методів для виявлення атак на веб-застосунки в умовах змінного трафіку. *Кібербезпека та захист інформаційних систем*, 15(4), 89-97.
9. Singh, V., Gupta, R., Sharma, P. (2022). Real-time classification techniques for web application security using machine learning algorithms. *Cybersecurity and Privacy*, 5(3), 122-133. <https://doi.org/10.1002/cyber.356>
10. Гусєв, І., Шаповал, Д. (2022). Методи класифікації для виявлення реальних атак на веб-додатки з використанням алгоритмів машинного навчання. *Інформаційні технології в кібербезпеці*, 10(2), 34-42.
11. Ali, A., Rahman, M., Jamil, A. (2023). Adaptive deep learning models for detecting evolving cyber threats in web applications. *Journal of Cyber Defense*, 9(3), 203-214.
12. Петренко, С., Чернявський, О. (2023). Адаптивні моделі глибокого навчання для виявлення нових типів кіберзагроз у веб-додатках. *Науково-технічний вісник Київського університету*, 17(1), 59-67.
13. Ghosh, S., Li, J., Zhang, L. (2023). Reinforcement learning for proactive threat detection in web applications. *Journal of Machine Learning Applications in Cybersecurity*, 9(1), 85-98.
14. Іванов, О., Гречаник, С. (2023). Використання методів підкріплення для проактивного виявлення загроз в веб-застосунках. *Інформаційна безпека: наука та техніка*, 12(3), 45-53.
15. Li, Y., Zhang, Z., Tang, M. (2022). AI-driven anomaly detection for securing web applications: Recent advances and challenges. *IEEE Access*, 10, 12891-12905.
16. Зайцев, С., Гречаник, С. (2023). Техніки штучного інтелекту для виявлення аномалій у веб-додатках: останні досягнення та виклики. *Український журнал кібербезпеки*, 10(1), 78-85.
17. Klimash, M., Balakovskiy, N., Shpur, O. (2024). Hybrid anomaly detection model using deep learning techniques for network traffic analysis. *ІСТЕЕ*, 16(2), 25-35.
18. Цюцюра, М., Коваленко, А. (2024). Оцінка гібридних методів виявлення аномалій в мережевому трафіку за допомогою машинного навчання. *Управління розвитком складних систем*, 29(3), 101-110.

19. Shchepin, S., Kudinov, A. (2023). Anomaly detection in web traffic using machine learning models. *Cybersecurity: Education, Science, and Technology*, 6(2), 74-82.
20. Шульга, М., Степаненко, Ю. (2023). Виявлення аномалій у веб-трафіку за допомогою моделей машинного навчання. *Інформаційні системи та кібербезпека*, 8(1), 55-63.
21. Tsytura, M., Kovalenko, A. (2024). Evaluation of machine learning algorithms for anomaly detection in network traffic. *Complex Systems Development Management*, 5(2), 65-75.
22. Власенко, Л., Томенко, Н. (2023). Оцінка алгоритмів для виявлення аномалій на основі машинного навчання в мережевому трафіку. *Кібербезпека: наука та техніка*, 13(4), 98-107.

## References

1. Lenkov, S., Juli, V., Mulyar, I., Dymbovsky, M. (2023). A model for determining current security threats to confidential data in a distributed information system. *Underwater Technologies: Industrial and Civil Engineering*, 13, 45-59.
2. Shulyмова, D. D., Boyko, A. O., Murzin, I. V. (2023). Algorithmic approaches to anomaly detection in web traffic using deep neural networks. *Telecommunication and Information Technologies*, 32(4), 110-121.
3. Sarker, I. H., Nguyen, M., Rahman, A. (2022). AI-based detection of novel cyberattacks on web applications using machine learning. *International Journal of Machine Learning*, 28(2), 45-58.
4. Tsytyura, M., Kovalenko, A. (2024). Evaluation of machine learning algorithms for anomaly detection in network traffic. *Complex Systems Development Management*, 29(2), 77-83.
5. Zhang, X., Wang, L., Li, Y. (2022). Anomaly detection in web traffic using hybrid deep neural networks. *Journal of Cybersecurity*, 19(1), 12-25.
6. Klimash, M., Balkovskiy, N., Shpur, O. (2024). Hybrid methods for anomaly detection in web traffic based on neural networks. *ICTEE*, 16(1), 140-150.
7. Chen, M., Liu, H., Zhang, Y. (2021). Ensemble learning methods for web application security with dynamic traffic analysis. *IEEE Transactions on Information Forensics and Security*, 14(2), 355-368.
8. Shevchenko, S., Ivanova, L. (2023). Using ensemble methods to detect attacks on web applications under varying traffic conditions. *Cybersecurity and Information System Protection*, 15(4), 89-97.
9. Singh, V., Gupta, R., Sharma, P. (2022). Real-time classification techniques for web application security using machine learning algorithms. *Cybersecurity and Privacy*, 5(3), 122-133.
10. Husev, I., Shapoval, D. (2022). Classification methods for detecting real-time attacks on web applications using machine learning algorithms. *Information Technologies in Cybersecurity*, 10(2), 34-42.
11. Ali, A., Rahman, M., Jamil, A. (2023). Adaptive deep learning models for detecting evolving cyber threats in web applications. *Journal of Cyber Defense*, 9(3), 203-214.
12. Petrenko, S., Chernyavskiy, O. (2023). Adaptive deep learning models for detecting new types of cyber threats in web applications. *Scientific and Technical Bulletin of Kyiv University*, 17(1), 59-67.
13. Ghosh, S., Li, J., Zhang, L. (2023). Reinforcement learning for proactive threat detection in web applications. *Journal of Machine Learning Applications in Cybersecurity*, 9(1), 85-98.
14. Ivanov, O., Grechanyk, S. (2023). Using reinforcement methods for proactive threat detection in web applications. *Information Security: Science and Technology*, 12(3), 45-53.
15. Li, Y., Zhang, Z., Tang, M. (2022). AI-driven anomaly detection for securing web applications: Recent advances and challenges. *IEEE Access*, 10, 12891-12905.
16. Zaytsev, S., Grechanyk, S. (2023). Artificial intelligence techniques for anomaly detection in web applications: Recent achievements and challenges. *Ukrainian Journal of Cybersecurity*, 10(1), 78-85.
17. Klimash, M., Balakovskiy, N., Shpur, O. (2024). Hybrid anomaly detection model using deep learning techniques for network traffic analysis. *ICTEE*, 16(2), 25-35.
18. Tsytyura, M., Kovalenko, A. (2024). Evaluation of hybrid anomaly detection methods in network traffic using machine learning. *Complex Systems Development Management*, 29(3), 101-110.
19. Shchepin, S., Kudinov, A. (2023). Anomaly detection in web traffic using machine learning models. *Cybersecurity: Education, Science, and Technology*, 6(2), 74-82.
20. Shulga, M., Stepanenko, Y. (2023). Anomaly detection in web traffic using machine learning models. *Information Systems and Cybersecurity*, 8(1), 55-63.
21. Tsytyura, M., Kovalenko, A. (2024). Evaluation of machine learning algorithms for anomaly detection in network traffic. *Complex Systems Development Management*, 5(2), 65-75.
22. Vlasenko, L., Tomenko, N. (2023). Evaluation of algorithms for anomaly detection based on machine learning in network traffic. *Cybersecurity: Science and Technology*, 13(4), 98-107.

Завідувачу кафедри кібербезпеки  
к.т.н., доц. Кльоцу Ю.П.  
здобувача вищої освіти  
Бабасвського Віталія Михайловича  
студента ФІТ, 2 курсу, групи КБЗІм-24-1

## ЗАЯВА

З правилами чинного Положення про систему забезпечення академічної доброчесності у Хмельницькому національному університеті, згідно з яким виявлення академічного плагіату є підставою для відмови в допуску кваліфікаційної роботи до захисту і застосування заходів академічної відповідальності, ознайомлений. Про використання спеціалізованих програмних засобів (СПЗ) StrikePlagiarism та Anti-Plagiarism для перевірки кваліфікаційних робіт здобувачів вищої освіти на наявність академічного плагіату оповіщений. Надаю університету право на передачу моєї роботи для обробки та збереження в базах даних СПЗ і використання роботи для виявлення академічного плагіату в інших роботах, які перевіряються СПЗ.

Також надаю свою згоду на обробку й збереження університетом моєї роботи в Інституційному репозитарії Хмельницького національного університету.

Робота надається для перевірки в електронному варіанті. Електронна версія моєї роботи збігається (ідентична) з друкованою.

19.12.2025  
дата

  
підпис

## Протокол аналізу звіту подібності науковим керівником

Заявляю, що я ознайомився (-лась) з Повним звітом подібності, який був згенерований Системою виявлення і запобігання плагіату щодо роботи:

**Автор:** Бабаєвський Віталій Михайлович

**Співавтор:**

**Назва:** Метод протидії атакам на вебзстосунки з використанням інтелектуальної системи аналізу трафіку

**Науковий керівник:** Муляр Ігор Володимирович

**Підрозділ:** Кафедра кібербезпеки

**Коефіцієнт подібності 1:** 1.7%

**Коефіцієнт подібності 2:** 0.4%

**Мікропробіли:** 0

**Заміна букв:** 2

**Інтервали:** 0

**Білі знаки:** 0

**Дата створення звіту:** 2025-12-19 16:50:14.0

Після аналізу Звіту подібності констатую наступне:

Запозичення, виявлені в роботі є законними і не є плагіатом. Рівень подібності не перевищує допустимої межі. Таким чином робота незалежна і приймається.

Запозичення не є плагіатом, але перевищено граничне значення рівня подібностей. Таким чином робота повертається на доопрацювання.

Виявлено запозичення і плагіат або навмисні текстові спотворення (маніпуляції), як передбачувані спроби укриття плагіату, які роблять роботу невідповідною вимогам законодавства (Ст. 32. ЗУ Про вищу освіту, пункт 3.1, Ст. 42. ЗУ Про освіту) та вимог НАЗЯВО (Критерій 5), а також кодексу етики і процедурам. Таким чином робота не приймається.

Обґрунтування:

Дата 20.12.25р.

експерт

# Anti-Plagiarism (UA) v-15.284 Educational

The maximum coincidence with one document **0.0%**

Dictionaries check: en\_US, ru\_RU, ua\_UA. Errors in the documents: **10%**

ID: 253839 Title: Метод протидії атакам на вебзстосунки з використанням інтелектуальної системи аналізу трафіку Added in a DB: 2025-12-19 Authors: Бабаєвський Віталій Михайлович Heads: Муляр І.В. Consultants: Opponents:	Document		Sum coincidence on the DB	
	Symbols	Lexemes	Symbols	Lexemes
	108418	764	561 (1%)	8 (1%)

## Plagiarism sources

ID	Description	Plagiarism presence in the document	
		Symbols	Lexemes

РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ КАФЕДРИ КІБЕРБЕЗПЕКИ  
ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Назва кваліфікаційної роботи: Метод протидії атакам на вебзастосунки з використанням інтелектуальної системи аналізу трафіку

Автор: Бабасвський Віталій Михайлович

Освітня програма: Кібербезпека та захист інформації

Рівень вищої освіти: другий (магістерський)

Спеціальність: 125 – Кібербезпека та захист інформації

Науковий керівник: Ігор МУЛЯР, к.т.н., доц.

На основі аналізу кваліфікаційної роботи на дотримання вимог академічної доброчесності (у т.ч. відсутності ознак академічного плагіату) з урахуванням результатів перевірки роботи спеціалізованим програмним засобом(ами) комісія зробила такий висновок:

№	Висновок	Позначка про відповідність
1	Ознаки академічного плагіату	
1.1	Запозичення, виявлені в роботі, є законними і не є академічним плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних, якщо потрібно). Робота приймається до захисту	відповідає
1.2	Виявлені запозичення не є академічним плагіатом, розміщені в розділах, які не описують безпосередньо авторське дослідження, але кількість цитат перевищує обсяг, виправданий поставленою метою роботи (далі – зазначаються детальні та аргументовані підстави віднесення запозичень до правомірних). Робота приймається до захисту, але має бути відкоригована	
1.3	Виявлені запозичення не є академічним плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. Робота може бути допущена до захисту після того як буде відкоригована та доопрацьована і успішно пройде повторну перевірку на академічний плагіат	
1.4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття текстових запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
2	Інші види порушень академічної доброчесності	

Підтвердження:

Оригінальність тексту роботи за результатами перевірки системою StrikePlagiarism складає 98.3%, оригінальність тексту роботи за результатами перевірки системою Anti-Plagiarism складає 100%

Згідно з Положенням про систему забезпечення академічної доброчесності у ХНУ (<https://khmnu.edu.ua/wp-content/uploads/normatyvni-dokumenty/polozhennya/pro-systemu-zabezpechennya-akademichnoyi-dobrochesnosti.pdf>, Додаток В) кваліфікаційна робота, виконана за освітньо-професійною програмою, кількісні показники рівня унікальності тексту у відсотках до загального обсягу матеріалу в якій складає 75-100 %, визнається роботою з високим рівнем унікальності тексту: «Текст вважається унікальним і не потребує додаткових дій щодо запобігання неправомірним запозиченням».

Дата: 19.12.2025

Завідувач кафедри кібербезпеки

Гарант освітньої програми

Керівник кваліфікаційної роботи

Юрій КЛЬОЦ

Віра ТІТОВА

Ігор МУЛЯР

# РЕЦЕНЗІЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

освітнього ступеня «магістр»

Студент Бабасвський Віталій Михайлович

Тема Метод протидії атакам на вебзастосунки з використанням інтелектуальної системи аналізу трафіку

Галузь знань 12 – Інформаційні технології

Спеціальність 125 – Кібербезпека та захист інформації

**Обсяг кваліфікаційної роботи освітньо-кваліфікаційного рівня «магістр»:**

кількість листів креслень \_\_\_\_\_ - \_\_\_\_\_; кількість сторінок записки \_\_\_\_\_ 95 \_\_\_\_\_

1. Короткий зміст кваліфікаційної роботи та прийнятих рішень У рамках роботи проведено комплексне дослідження факторів, що впливають на ефективність захисту вебдодатків, а також проаналізовано існуючі методи виявлення та запобігання атакам. Особлива увага приділялася сучасним підходам на основі штучного інтелекту для аналізу мережевого трафіку та виявлення аномалій у запитах користувачів.

Розроблено модель інтелектуальної системи протидії атакам на вебдодатки, яка поєднує традиційні механізми контролю доступу та алгоритми виявлення шкідливої активності. Вона дозволяє оцінити можливі способи витоку прав доступу та формалізувати вимоги до безпечного функціонування вебресурсів.

На основі запропонованої моделі реалізовано програмний модуль виявлення атак, проведено його тестування та оцінку ефективності. Результати демонструють високу здатність системи ідентифікувати та блокувати шкідливі запити, що забезпечує підвищення рівня безпеки вебдодатків у практичних умовах.

2. Висновок про відповідність кваліфікаційної роботи завданню Кваліфікаційна робота у повній мірі відповідає поставленому завданню як в теоретичній, так і в практичній частині.

3. Характеристика виконання кожного розділу роботи, ступінь використання останніх досягнень науки і техніки і передових методів роботи: У вступі висвітлено актуальність теми, сформульовано цілі та завдання дослідження, описано наукову новизну та практичну значущість роботи. У першому розділі розглянуто особливості функціонування вебдодатків і корпоративних мереж, типові атаки та сучасні методи їх виявлення. Наступні розділи присвячені розробці інтелектуальної системи захисту вебресурсів, алгоритмів виявлення аномалій та програмній реалізації модуля тестування безпеки, з використанням сучасних досягнень науки та передових методів роботи.

4. Позитивні сторони роботи Кваліфікаційна робота містить ряд інноваційних рішень. Запропонований метод забезпечує комплексний підхід до діагностики безпеки вебдодатків, поєднуючи можливості розмежування доступу, реалізації політик безпеки та інтелектуального аналізу мережевого трафіку. Це дозволяє своєчасно виявляти та блокувати шкідливі дії, підвищуючи ефективність захисту вебресурсів у практичних умовах.

5. Негативні сторони роботи Впровадження розробленої моделі та методу ускладнюється при роботі з масштабними та складними топологіями мереж. Також можливі обмеження продуктивності системи при великому обсязі трафіку, що потребує додаткової оптимізації алгоритмів обробки даних.

6. Оцінка графічного оформлення та пояснювальної записки роботи

Пояснювальна записка відповідає нормам для її оформлення.

7. В загальному кваліфікаційна робота заслуговує позитивної оцінки. Але матеріал роботи не достатньо структурований, чіткий та послідовний. Усі розділи роботи відповідають завданню, що дозволяє розуміти викладений матеріал в рамках тематики кваліфікаційної роботи. Робота має наукову новизну, але вона не достатньо висвітлена, та практичну цінність.

8. Інші зауваження Відсутні.

9. Оцінка кваліфікаційної роботи Розглянувши позитивні та негативні сторони представленої кваліфікаційної роботи, можна зробити висновок, що вона заслуговує оцінку «добре» 85 балів

РЕЦЕНЗЕНТ (прізвище, ім'я, по батькові, посада, місце роботи)

Бойко Юлій Миколайович, професор кафедри ТМІТ, доктор технічних наук

« 18 » 12 2025.

 (підпис)