

Хмельницький національний університет
Факультет інформаційних технологій
Кафедра кібербезпеки

КВАЛІФІКАЦІЙНА РОБОТА

Мусіюка Андрія Володимировича

на здобуття ступеня вищої освіти магістра

Метод моніторингу аномальної активності мобільних застосунків
Галузь знань 12 – Інформаційні технології
Спеціальність 125 – Кібербезпека та захист інформації
Освітня програма Кібербезпека та захист інформації

Шифр КРМКБЗІ. 2301149.23.01.17 ПЗ

Виконав студент 2 курсу група КБЗІм-23-1  Андрій МУСІЮК

Керівник канд. техн. наук, доцент  Володимир ПЕТРУШАК

Нормоконтролер старший викладач  Сергій МОСТОВИЙ

До захисту допускаю:

Завідувач кафедри кібербезпеки  Юрій КЛЬОЦ

16 12 2024 р.

Хмельницький 2024

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 _____

_____ 2 _____ 09 _____ 2024 р.

ЗАВДАННЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ

Мусіюку Андрію Володимировичу

1 Тема роботи Метод підвищення стійкості електронного цифрового підпису за рахунок комбінованих схем аутентифікації

Керівник роботи канд.техн.наук, доцент Володимир ПЕТРУШАК

Затверджено наказом ректора університету від 26 08 2024 № 60

2 Строк подання студентом кваліфікаційної роботи на кафедру _____

3 Вихідні дані до роботи Дослідження, розробка та апробація методу виявлення аномальної активності мобільних додатків із використанням сучасних технологій машинного навчання.

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

Вступ. Дослідження предметної області: мобільні операційні системи, структура APK-файлу, аномалії, сучасні методи їх виявлення, постановка задачі. Класифікація ознак методу виявлення аномальної поведінки мобільних додатків: збір і аналіз даних, класифікація ознак, бінарне представлення, використання нейронних мереж. Метод кореляційного аналізу дозволів: передумови, реалізація, навчання нейронної мережі. Дослідження працездатності методу: середовище тестування, результати, моделювання. Висновки. Перелік джерел посилань.

5 Консультанти розділів кваліфікаційної роботи

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

7 Дата видачі завдання 2 09 2024 р.

КАЛЕНДАРНИЙ ПЛАН

Назва етапів (розділів) кваліфікаційної роботи	Строк виконання етапів роботи	Примітка
Ґрунтовне ознайомлення та дослідження предметної галузі		Виконано
Визначення змісту, структури кваліфікаційної роботи		Виконано
Підготовка першого розділу кваліфікаційної роботи		Виконано
Підготовка другого розділу кваліфікаційної роботи		Виконано
Підготовка третього розділу кваліфікаційної роботи		Виконано
Підготовка статті/тези за темою кваліфікаційної роботи		Виконано
Підготовка четвертого розділу кваліфікаційної роботи		Виконано
Підготовка та оформлення ілюстративного матеріалу		Виконано
Оформлення кваліфікаційної роботи		Виконано
Попередній захист кваліфікаційної роботи		Виконано
Захист кваліфікаційної роботи на засіданні ЕК		Виконано

Студент



Андрій МУСІЮК

Керівник кваліфікаційної роботи



Володимир ПЕТРУШАК

АНОТАЦІЯ

Тема кваліфікаційної роботи: Метод виявлення аномальної активності мобільних додатків на основі поведінкового аналізу

Автор роботи: Мусіюк Андрій Володимирович

Керівник роботи: к.т.н., доцент Петрушак Володимир Степанович

Загальний обсяг роботи: 87 сторінок, 12 рисунків, 14 таблиць, 60 посилань.

Ключові слова: машинне навчання, поведінковий аналіз, мобільні додатки, аномальна активність, нейронна мережа, класифікація.

Цифровізація суспільства створює нові виклики для інформаційної безпеки, особливо в контексті мобільних додатків. Значна частина загроз спричинена шкідливим програмним забезпеченням, яке часто маскується під легітимні програми. Це зумовлює потребу у впровадженні сучасних методів виявлення аномальної активності для мінімізації ризиків витоку даних та несанкціонованого доступу.

У роботі проведено аналіз сучасних методів моніторингу активності мобільних додатків. Особливу увагу приділено поведінковим підходам, які враховують патерни користувацької активності. Основою запропонованого методу є використання алгоритмів машинного навчання для аналізу викликів API, дозволів додатків та інших поведінкових характеристик.

Розроблено модель нейронної мережі для класифікації поведінкових ознак мобільних додатків, яка дозволяє відрізнити нормальну активність від аномальної. Проведено тестування моделі в умовах експериментального середовища, що підтвердило її високу ефективність у виявленні потенційних загроз.

Результати дослідження показують, що запропонований метод забезпечує точну класифікацію мобільних додатків та дозволяє своєчасно ідентифікувати загрози. Це відкриває можливості для інтеграції розробленого підходу в сучасні системи захисту мобільних платформ.

14. 12. 24

ANNOTATION

Title of the qualification work: Method for Detecting Anomalous Activity in Mobile Applications Based on Behavioral Analysis

Author: Musiiuk Andrii Volodumurovych

Mentor: Ph.D., Assoc Petrushak Volodymyr Stepanovych

Total volume of the work: 87 pages, 12 figures, 14 tables, 60 references.

Keywords: machine learning, behavioral analysis, mobile applications, anomalous activity, neural network, classification.

The digitalization of society poses new challenges for information security, especially in the context of mobile applications. A significant portion of threats is caused by malicious software, which often masquerades as legitimate programs. This underscores the need for modern methods to detect anomalous activity, minimizing risks of data leakage and unauthorized access.

This study analyzes modern methods for monitoring the activity of mobile applications. Special attention is paid to behavioral approaches that consider patterns of user activity. The proposed method is based on machine learning algorithms to analyze API calls, app permissions, and other behavioral characteristics.

A neural network model for classifying behavioral features of mobile applications has been developed, allowing differentiation between normal and anomalous activity. The model was tested in an experimental environment, demonstrating high effectiveness in identifying potential threats.

The results of the study show that the proposed method provides accurate classification of mobile applications and enables timely threat identification. This opens opportunities for integrating the developed approach into modern protection systems for mobile platforms.

9.12.24



ЗМІСТ

ВСТУП.....	9
1 Дослідження предметної області.....	11
1.1 Мобільні операційні системи та структура APK файлу	11
1.2 Аномалії та вектори появи аномалій.....	17
1.3 Сучасні методи виявлення аномалій	19
1.4 Альтернативні шляхи виявлення аномалій в мобільних додатках	26
1.5 Постановка задачі.....	27
2 Класифікація ознак методу виявлення аномальної поведінки мобільних додатків. 29	
2.1 Збір та аналіз даних поведінки мобільних додатків.....	29
2.2 Класифікація ознак	35
2.3 Бінарне представлення ознак	38
2.4 Класифікація векторів ознак за допомогою нейронних мереж.....	45
2.5 Висновок	49
3.Метод кореляційного аналізу дозволів для виявлення аномальної поведінки мобільних додатків.....	50
3.1 Передумови методу аналізу дозволів.....	50
3.2 Реалізація методу виявлення аномальної поведінки	56
3.3 Навчання та тестування нейронної мережі	61
3.4 Висновки по розділу	70
4. Дослідження роботоздатності методу виявлення аномальної поведінки мобільних додатків.....	71
4.1 Середовище тестування та інструменти тестування	71
4.2 Результати аналізу та вимірювання ефективності класифікатора дозволів.....	72

4.3 Моделювання та аналіз методу виявлення аномальної поведінки мобільних додатків.....	75
4.4 Результати тестування методу виявлення аномальної поведінки мобільних додатків.....	82
4.5 Висновки по розділу	86
Висновки	88
Перелік джерел посилань	90

ПЕРЕЛІК СКОРОЧЕНЬ

API – інтерфейс прикладного програмування

APK – файл пакету Android

IDS – система виявлення вторгнень

IPS – система запобігання вторгненням

ML – машинне навчання

HMM – прихована марковська модель

LSTM – довга короткочасна пам'ять

ANN – штучна нейронна мережа

UI – користувацький інтерфейс

DNS – система доменних імен

ВСТУП

Розвиток інформаційних технологій став невід'ємною частиною життя сучасного суспільства. В умовах швидкого поширення мобільних пристроїв інформаційна безпека набуває все більшої важливості. Особливо це стосується конфіденційних даних, які обробляються та зберігаються на смартфонах. Шкідливе програмне забезпечення є значною загрозою для користувачів мобільних платформ, оскільки воно може порушувати конфіденційність інформації, завдавати фінансових збитків та порушувати нормальну роботу пристроїв.

Актуальність проблеми безпеки мобільних пристроїв зумовлена значним поширенням операційної системи Android, яка наразі займає понад 80% ринку мобільних платформ. Відкритість цієї системи є її перевагою, але водночас вона створює ризики. Зловмисники використовують вразливості платформи для розповсюдження шкідливих програм, які часто маскуються під легітимні додатки.

Сучасні методи захисту, такі як обмеження доступу, криптографія, контроль дозволів додатків, не завжди забезпечують достатній рівень безпеки. Це пов'язано зі складністю шкідливого програмного забезпечення, яке може адаптуватися до традиційних механізмів захисту. У зв'язку з цим виникає потреба у впровадженні додаткових методів моніторингу та аналізу поведінки додатків для виявлення потенційних загроз.

Проблема виявлення аномальної активності в мобільних додатках полягає в необхідності обробки великих обсягів даних та адаптації до нових загроз. Ефективні методи аналізу повинні враховувати не лише технічні аспекти, але й поведінкові патерни користувачів, що є важливим для зниження кількості хибнопозитивних спрацьовувань.

Мета дослідження полягає у розробці та впровадженні методу моніторингу аномальної активності мобільних додатків із використанням сучасних технологій

машинного навчання. Це дозволить своєчасно виявляти загрози та мінімізувати їхній вплив на користувачів.

Завдання дослідження наступні:

Провести аналіз існуючих методів виявлення та ідентифікації порушень у мобільних додатках, визначити їх переваги та недоліки, особливості реалізації.

Дослідити можливості застосування поведінкового аналізу для моніторингу активності мобільних додатків.

Розробити метод виявлення аномальної поведінки мобільних додатків, заснований на аналізі поведінкових патернів.

Реалізувати та протестувати розроблений метод у контексті мобільних платформ.

Провести порівняльний аналіз розробленого методу з існуючими підходами та визначити його ефективність.

Об'єктом дослідження є процеси виявлення аномальної активності мобільних додатків.

Предметом дослідження є методи аналізу поведінки мобільних додатків для виявлення аномальної активності.

Наукова новизна роботи полягає в розробці моделі класифікації поведінкових патернів мобільних додатків із застосуванням сучасних технологій машинного навчання. Встановлено нові кореляційні залежності між дозволами, викликами API та іншими характеристиками, що підвищують ефективність виявлення аномальної активності.

Практична значимість полягає в можливості інтеграції розробленого методу в системи інформаційної безпеки мобільних платформ для своєчасного виявлення загроз, зниження хибнопозитивних спрацьовувань і захисту конфіденційних даних користувачів.

1 ДОСЛІДЖЕННЯ ПРЕДМЕТНОЇ ОБЛАСТІ

1.1 Мобільні операційні системи та структура APK файлу

Платформа Android пропонує широкі можливості для налаштування та контролю, маючи водночас значний набір вбудованих засобів безпеки в останніх версіях ОС. Тому доцільно зосередитися на огляді методів моніторингу безпеки, зокрема для виявлення аномальної активності, які інтегровані в систему Android. iOS, у свою чергу, є більш закритою екосистемою з обмеженими можливостями налаштування, успадкованою від спрощеної версії macOS. Проте останні оновлення принесли більше інструментів для персоналізації, що відкриває нові можливості для впровадження механізмів моніторингу аномалій, спрямованих на покращення безпеки користувачів.

Пристрої на базі Android набули популярності завдяки своїй відкритості для сторонніх розробників та схожості з ОС Linux. Проте в цій системі існують суттєві відмінності, що були впроваджені для підвищення зручності використання та обслуговування мобільних пристроїв[1].

Як показано на рисунку. 1.1, основою системи є ядро Linux Kernel, яке виконує більшість важливих функцій: контроль процесів, забезпечення їх коректного виконання, дотримання прав доступу, а також слугує рівнем абстракції обладнання (Hardware Abstraction Layer, HAL). Така архітектура була обрана через те, що ядро Linux задовольняє всі необхідні функціональні вимоги й є відкритим для налаштувань.

Однією з особливостей ядра Android порівняно з Linux є саме використання HAL. Існують два основні підходи до інтеграції драйверів у Linux – вони або вбудовані в ядро, або реалізовані як модулі.

Оскільки вбудовування великої кількості драйверів у ядро мобільної системи є недоцільним, було створено HAL – проміжний рівень взаємодії між ядром та драйверами, що являє собою набір інтерфейсів, реалізація яких відбувається в драйверах.

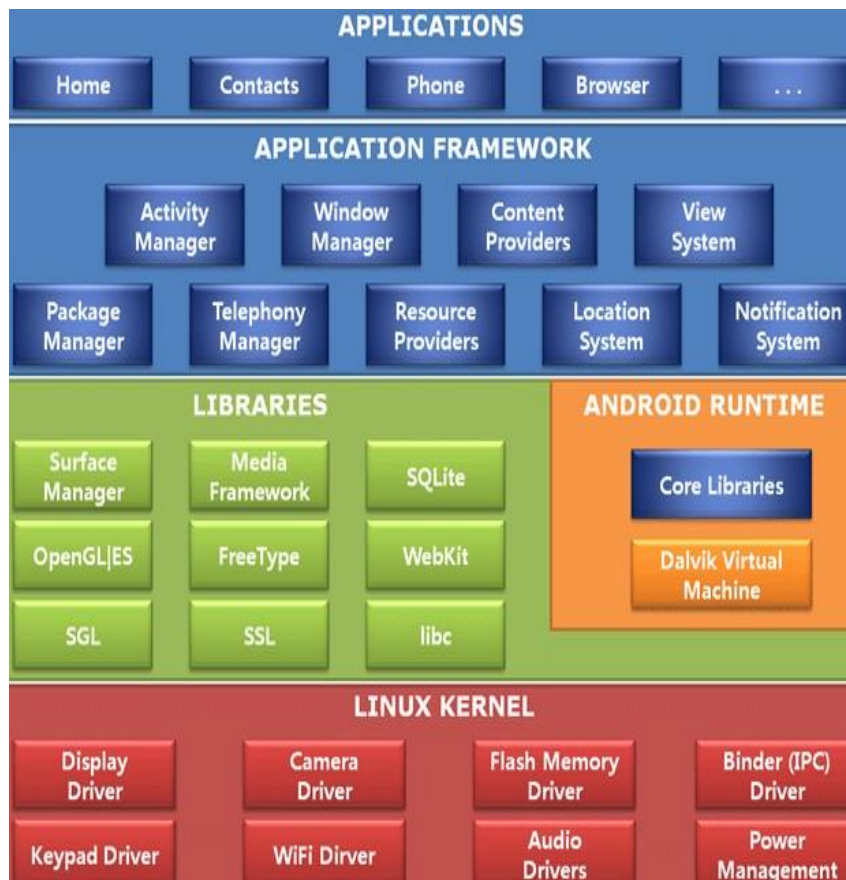


Рисунок 1.1 – Архітектура операційної системи Android

Крім того, мобільне ядро Android має вбудовані системи, характерні лише для цієї ОС, зокрема Binder (модуль для міжпроцесної взаємодії IPC/RPC), Ashmem (драйвер роздільної пам'яті), WakeLocks (механізм керування живленням, який затемнює екран і вимикає процесор), Low Memory Killer, Alarm та Logger[2,3].

Основний аспект безпеки в Android реалізується через розмежування прав доступу, що забезпечується ядром системи. Кожен застосунок працює ізольовано в так званій "пісочниці" (sandboxing), де йому надається унікальний ідентифікатор користувача (UID) та групи (GID), як це реалізовано для процесів у Linux. Застосунку виділяється власна директорія всередині каталогу /data, що дозволяє читати і записувати лише власні файли й забороняє доступ до файлів інших застосунків. Цей підхід не тільки забезпечує захист даних користувачів, але й допомагає відстежувати

аномальну активність, оскільки кожен застосунок функціонує незалежно в межах своїх дозволів.

Процеси, що працюють із привілеями root, не входять у цю ізоляцію, проте таких процесів небагато – зокрема, це початковий процес init, який контролює виконання застосунків, та окремі системні сервіси. Завдяки обмеженню прав доступу, навіть шкідливе ПЗ має обмежений доступ до інформації, зокрема тільки до даних на зовнішніх носіях, якщо користувач дозволив цей доступ.

Таким чином, ізольоване середовище Android створює безпечну базу для моніторингу та виявлення аномалій у поведінці застосунків, мінімізуючи ризики витоку особистих даних та несанкціонованого доступу.

Доступ до системної інсталяції Android також обмежений, оскільки всі дані інсталяції та автозапуску зберігаються на окремому блоці пам'яті NAND, віртуально підключеному до каталогу /system[6]. За замовчуванням цей каталог змонтований лише для читання і не містить конфіденційної інформації, а дані, що циркулюють у цьому каталозі, також потрапляють під дію механізму "пісочниці". Це ускладнює можливість впровадження шкідливого коду в автозапуск або його модифікацію, що підвищує захищеність системи від аномальної активності. Злом такої системи безпеки можливий лише через використання root-експлойту, який дозволяє шкідливому коду отримати права суперкористувача.

Важливим аспектом захисту на цьому рівні є наявність жорстко заданих ідентифікаторів деяких системних користувачів. Оскільки Android спроектований як система для одного користувача, було прийнято рішення використовувати різні Linux user IDs для ізоляції застосунків і захисту їхніх даних – кожен застосунок отримує власний унікальний ідентифікатор користувача (UID)[7,8]. Крім того, у системі зафіксовані деякі стандартні користувачі з постійними UID, зокрема root з UID 0 та system з UID 1000.

У разі привілейованих програм (наприклад, su) діють обмеження, які регулюють, які застосунки можуть їх викликати, щоб запобігти несанкціонованому

отриманню прав суперкористувача. Цей механізм допомагає контролювати аномальну активність, перевіряючи UID процесу – програма спочатку перевіряє, від чийого імені здійснюється виклик, що дозволяє виявляти потенційно шкідливу активність.

Особливістю цього рівня Application framework є можливість взаємодії застосунків між собою. Програми повинні мати доступ до інформації від системних процесів за відповідного дозволу[5]. Оскільки застосунки та системні сервіси працюють у різних процесах, операційна система повинна реалізувати механізм «спілкування» між процесами, що також стосується взаємодії між звичайними застосунками.

В системі Android важливу функцію міжпроцесної взаємодії (Inter-Process Communication, IPC) виконує фреймворк Binder IPC. Він забезпечує можливість синхронного та асинхронного виклику методів віддалених об'єктів, а також обмін дескрипторами між процесами.

Робота Binder організована за класичною схемою клієнт-сервер. Клієнт ініціює з'єднання та очікує на відповідь від сервера. Варто також зазначити, що у випадку асинхронного виклику сервер одразу надсилає клієнту порожню відповідь. Взаємодію в рамках Binder у системі Android забезпечує Linux Binder Driver (драйвер пристрою), який знаходиться в каталозі /dev/binder. Адресація між процесами реалізується через механізм токенізації. Binder призначає кожному сервісу унікальний токен, який є вказівником на цей сервіс. Тільки якщо клієнт має цей токен, він може отримати доступ до відповідного сервісу. Проте, спочатку клієнту необхідно отримати цей унікальний токен.

Процедура отримання токена виконується через Binder context manager, який в системі Android відомий як Service Manager. Цей спеціальний сервіс за замовчуванням має токен із значенням 0, відомим усім сервісам. Service Manager виконує функцію довідника, в якому зареєстровано всі доступні сервіси. Після запиту клієнта на отримання сервісу з певною назвою, менеджер надає клієнту токен, який той може використовувати для взаємодії з цим сервісом. Перед використанням сервісу його

необхідно зареєструвати у менеджері, що служить одним із заходів безпеки і запобігає вставленню шкідливих сервісів у систему.

Таким чином, Binder забезпечує передачу ідентифікаторів процесів, які викликають сервіси, що дозволяє обмежити доступ до них лише довіреним процесам. Унікальність токенів у процесному середовищі Android робить їх ефективним маркером для контролю доступу до сервісів, допомагаючи виявляти та запобігати аномальній активності через доступ тільки довірених процесів до системних сервісів.

Android Application Package (APK) дозволяє розповсюджувати програми між мобільними пристроями та постачальниками на ринку. APK — це добре організований пакет зі стилем форматування Java ARchive (JAR)[12], що містить різні файли Android, такі як виконувані файли, класи, маніфест, необроблені ресурси та бібліотека. Зловмисне програмне забезпечення також інкапсулюється в цьому форматі файлу таким же чином хакерами. APK використовується Android для встановлення додатків і створення інших залежностей і фреймворків відповідно. Щоб побудувати структуру класифікації, яка буде надійною для визначення ознак шкідливого файлу, ми перевірили структуру APK як показано на рисунку 1.2, щоб зрозуміти особливості, пов'язані з кожним сегментом. Наприклад, файл manifest.xml містить усі атрибути змінних дозволів, які використовують більшість варіантів зловмисного програмного забезпечення для зараження пристрою жертви. Таким чином, це дослідження надає детальне архітектурне представлення структури формату файлу APK, розглядаючи всі з'єднувальні компоненти та служби. Коли файл APK декомпілюється за допомогою будь-якого інструменту, наприклад компілятора JADX, основні структури файлу витягуються для подальшого аналізу структури програми. Розуміння структури APK є важливим для аналізу зловмисного програмного забезпечення на основі Android. Основна структура APK містить конфігураційні файли активів, бібліотек, оригіналів, ресурсів і джерел

Активи: це сегмент конфігурації APK, який містить назви файлів для привілеїв дозволів і методи, які використовуються для їх запиту відповідно. В основному data3,

data1, data4, data2, fj і fs є ієрархічним розташуванням файлової структури. Деталі зловмисної діяльності можна дослідити за допомогою аналізу цих файлових секторів[11].

Lib: папка Armeabi цієї файлової структури створює плаваючий контакт для налагодження програми читаних і перезаписуваних даних Libf-jni.So і libdata.So відповідно. Це бібліотека в модулі середовища Android, яка полегшує керування операційними службами на фоні ОС Android [9].

Оригінал: тут розташовані META-INF і AndroidManifest. Іншими важливими компонентами оригінального дерева архіву є ANDROID_.SF, ANDROID_.RSA та MANIFEST.MF відповідно. Це асоційований сектор файлу ресурсів.

Ресурси: містить дві основні функції: папку res і AndroidManifest.xml. Android drawable, values, layout, anim і layout контролюються компонентом res. У розробці архітектури Android res представляє набори визначених ресурсів Android,

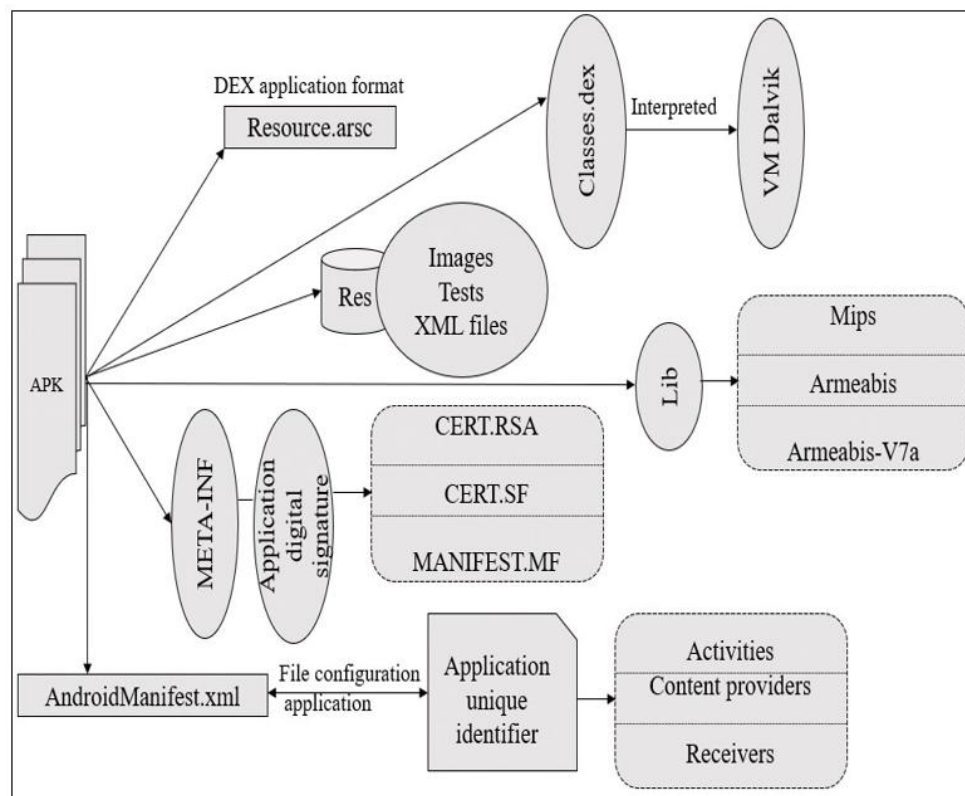


Рисунок 1.2 – Структура файлу APK

Для виявлення векторів атак, які зловмисне програмне забезпечення розгортає для зараження платформ на базі Android, розуміння основних компонентів сегмента файлу `res` є критичним. Шкідливі програми, такі як рекламне програмне забезпечення та спливаюча реклама, можуть порушувати безпеку

1.2 Аномалії та вектори появи аномалій

Аномалії в мобільному пристрої можуть виникати з різних причин, серед яких найбільш поширені — збої у логіці роботи додатку та зараження зловмисним програмним забезпеченням. Збої можуть бути викликані помилками у коді, несумісністю з іншими додатками або особливостями апаратного забезпечення, що призводить до нестабільної поведінки, наприклад, до несподіваних аварійних завершень роботи додатка або підвищеного споживання ресурсів. З іншого боку, аномальна поведінка може свідчити про наявність шкідливого ПЗ, яке прагне отримати доступ до системних привілеїв, даних користувача чи навіть контролю над самим пристроєм. Такі загрози включають віруси, руткіти та інші види шкідливого ПЗ, які використовують вразливості системи для прихованого виконання зловмисних операцій[13].

Еволюція шкідливого ПЗ для Android демонструє загальний вектор розвитку в напрямку посилення складності атак і використання аномальної поведінки для прихованого виконання шкідливих дій. Відкрита архітектура Android і відсутність ретельних перевірок безпеки при завантаженні додатків на офіційні магазини сприяють швидкому поширенню шкідливого ПЗ. Відкритий код дозволяє стороннім розробникам модифікувати операційну систему, що створює потенційні вразливості для атак і полегшує впровадження зловмисного коду.

Шкідливі програми для Android часто маскуються під звичайні додатки, зловживаючи наданими дозволами для отримання доступу до SMS, контактів,

місцеположення та інших конфіденційних даних. Це дозволяє зловмисникам підписувати пристрої на платні послуги, відстежувати місцезнаходження користувача та пересилати дані на віддалені сервери без відома власника. Аномальна активність, що виникає внаслідок таких дій, може бути виявлена за допомогою аналізу дозволів і поведінкових патернів.

З кожним новим поколінням шкідливого ПЗ з'являються все більш складні техніки ухилення від виявлення, такі як обфускація коду, використання ботнетів, контроль через віддалені сервери і адаптація до віртуальних середовищ. Ці техніки ускладнюють виявлення за допомогою традиційних методів аналізу, що стимулює розвиток методів для ідентифікації аномальної поведінки. Зрештою, цей вектор розвитку призводить до необхідності застосування більш складних алгоритмів і моделей для виявлення аномалій, щоб забезпечити належний рівень кібербезпеки для користувачів Android[14].

Можна класифікували аномальну поведінку мобільних пристроїв у п'ять (5) категорій, спираючись на рівень складності, характеристики та наміри:

Категорія 1: Додатки можуть викликати нав'язливі спливаючі вікна або показувати рекламні оголошення, що займають екран мобільного пристрою. Ці додатки часто запитують дозволи, які не відповідають їхній функціональності, наприклад, доступ до SMS або Bluetooth, без необхідності. Така поведінка може свідчити про намагання зловмисного програмного забезпечення збирати інформацію про користувача чи тестувати реакцію системи.

Категорія 2: Аномалії, пов'язані з крадіжкою інформації або порушенням конфіденційності. Шкідливі програми можуть запитувати доступ до конфіденційних ресурсів, таких як контакти, місцезнаходження або камера, використовуючи соціальну інженерію для отримання дозволів. У цьому випадку дозволи можуть запитуватися приховано, з використанням фальшивих інтерфейсів, що вводять користувача в оману. Основна мета – фінансова вигода чи отримання особистих даних.

Категорія 3: Додатки з аномальною поведінкою, що включає рутування або джейлбрейк пристрою для отримання повного контролю. Вони можуть просити права, які явно не потрібні для основного функціонала, наприклад, адміністративний доступ. Мета – отримання фінансової вигоди або пошкодження пристрою. Зазвичай ці додатки поширюються через сторонні магазини[15].

Категорія 4: Додатки, які дозволяють віддалений доступ до мобільного пристрою. Вони часто просять доступ до мережевих ресурсів і налаштувань безпеки, що може бути використано для віддаленого моніторингу, шпигунства або організації атак. Така поведінка зазвичай прихована, а доступ до дозволів запитується непомітно для користувача.

Категорія 5: Модульні шкідливі програми, здатні отримувати адміністративні права на пристрої, що дозволяє проводити атаки типу DDoS або створювати ботнети. Вони можуть запитувати максимальний рівень доступу до системних ресурсів, навіть якщо це не потрібно для заявленого функціоналу, використовуючи мережеві з'єднання для координації атак.

Як зазначалось вище зазвичай аномалії викликає зловмисне програмне забезпечення розглянемо більш детально типи зловмисного програмного забезпечення та проаналізуємо його.

1.3 Сучасні методи виявлення аномалій

Останнім часом стало очевидним, що навіть найнадійніші системи захисту не можуть забезпечити повний захист мобільних додатків державних і комерційних установ від атак. Одна з причин полягає в тому, що більшість систем безпеки мобільних додатків використовують стандартні механізми захисту: ідентифікацію та аутентифікацію, обмеження доступу до функціоналу додатків відповідно до прав користувача, а також криптографічні засоби захисту даних. Такий традиційний підхід

має певні недоліки, зокрема: можливість зловживань з боку користувачів, що мають доступ, розмитість меж між “власними” і “чужими” користувачами через глобальний доступ до додатків, відносно легкість підбору паролів через слабкий рівень паролів користувачів, зниження продуктивності й ускладнення процесів користування через обмеження доступу до функцій додатка[16].

З огляду на це, виникла необхідність у додаткових механізмах, які б доповнювали традиційні підходи до захисту мобільних додатків і дозволяли виявляти спроби несанкціонованого доступу, інформувати про це відповідальних за безпеку або автоматично реагувати на такі інциденти. Важливим аспектом є те, щоб такі системи могли протистояти атакам навіть тоді, коли зловмисник вже пройшов аутентифікацію та авторизацію й формально має необхідні права для виконання своїх дій. Такі функції можуть виконувати системи виявлення аномалій (ADS - anomaly detection systems), орієнтовані на мобільні додатки.

Оскільки передбачити всі можливі сценарії небажаної поведінки у мобільному додатку неможливо, підходи до захисту можуть ґрунтуватися на двох принципах: або максимально детально описати можливі "шкідливі" сценарії, або ж, навпаки, — описати нормальні сценарії використання додатка і вважати, що будь-яка активність, яка не відповідає визначеному стандарту "нормальності", є потенційно небезпечною.

Розглянемо основні методи пошуку аномалій систем виявлення аномалій в мобільних пристроях.

Методи, засновані на зберіганні прикладів поведінки, використовуються також для виявлення аномалій у мобільних додатках. Найпростішим підходом є пряме збереження прикладів дій користувача, послідовностей команд або інших параметрів, доступних для моніторингу (instance-based learning). Хоча цей підхід не завжди ефективний для моделювання поведінки користувача в загальному контексті, для виявлення аномалій у мобільних додатках він є доволі ефективним, що пояснюється обмеженою кількістю можливих дій у додатку, чітко визначеними завданнями, які

може виконувати користувач, і структурою самого додатку. На рисунку 1.3 зображена модель методу виявлення аномалії на основі зберігання поведінки [17,18].

Реакцією мобільного додатка на аномальну поведінку може бути примусове обмеження доступу або зниження продуктивності, що дозволяє мінімізувати потенційні загрози.

Записані під час тренування послідовності дій або системних викликів зберігаються для подальшої перевірки на їхню наявність у поточній сесії.

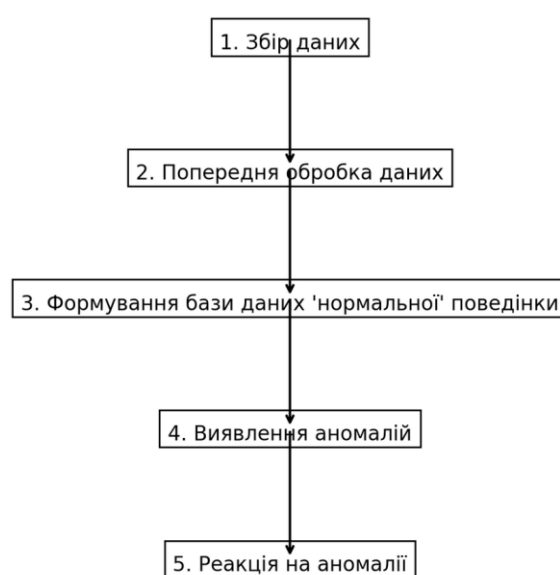


Рисунок 1.3 –Методу виявлення аномалії на основі зберігання поведінки.

Оскільки спостереження ведеться за активністю додатку (наприклад, частотою звернень до API або активністю користувача), розмір бази підпослідовностей зазвичай залишається прийнятним для мобільних пристроїв. Якщо виявляється підпослідовність, якої не було серед тренувальних даних, вона розглядається як потенційно аномальна.

Цей підхід вимагає інтеграції додаткових модулів у мобільну операційну систему або додаток, що може бути складним і не завжди можливим. Крім того, постійний моніторинг може спричинити загальне уповільнення роботи пристрою на 4

% – 50 %. Для полегшення роботи з великими обсягами даних для кожного користувача застосовуються спеціальні методи зменшення розміру бази послідовностей. Один із таких методів включає вибіркоче збереження послідовностей, коли зберігаються лише останні n записів або всі, крім n із найменшою ймовірністю, що дозволяє зберігати тільки найзначущіші приклади.

Таким чином, через високі вимоги до ресурсів instance-based системи можуть ефективно застосовуватись лише у задачах виявлення аномалій у мобільних додатках із відносно обмеженою кількістю можливих варіантів поведінки користувача або статичними сценаріями використання.

Метод на основі частотної моделі також може бути застосований для виявлення аномалій у мобільних додатках. У цьому підході зберігається інформація про шаблони активності користувача у вигляді частотного розподілу ключових подій додатка, таких як частота запуску додатка, доступ до певних функцій, частота використання API або звернення до серверів. Відхилення у цих частотах дозволяє виявляти аномальну поведінку. Наприклад, відстежується, чи входить відносна частота певних подій у заздалегідь визначений діапазон, встановлений на основі статистики нормального використання.

Модифікацією цього підходу є метод із використанням "структурних нулів". Тут фіксуються події або команди, які зазвичай використовуються дуже рідко або взагалі не використовуються в додатку; відповідні їм комірки у таблиці ймовірностей встановлені як нульові (структурні нулі). Запроваджується індекс унікальності, який обчислюється для кожної сесії користувача. Індекс отримує додаткові бали за використання частих команд, але ці бали зменшуються, якщо команда використовується занадто часто, що дозволяє виявляти широке використання рідкісних команд. Такі дії можуть спричинити зростання індексу унікальності. Якщо виявляються команди або події, що не характерні для даного користувача, індекс знижується. Вважається, що значення індексу стабільне для нормального

використання додатку, що дає змогу відрізнити нормальні та аномальні сесії за його змінами[19].

Попри переваги, частотні методи мають певні недоліки. Зокрема, вони можуть бути неадаптивними, оскільки еталонні значення частот часто встановлюються разово на основі тренувальної вибірки або експертних даних. Крім того, вони не враховують послідовність дій користувача, що може знижувати ефективність виявлення складних аномалій.

Метод на основі нейромережевої моделі є перспективним для виявлення аномалій у мобільних додатках завдяки здатності нейронних мереж розпізнавати приховані закономірності в поведінці користувачів, модель зображена на рисунку 1.4. Ідея полягає в тому, щоб надати нейронній мережі «тренувальну» множину даних, яка описує типову поведінку користувачів додатка. На етапі тренування нейромережа отримує вхідні параметри, які характеризують нормальну активність користувача: години активності, частоту викликів API, типовий набір функцій додатка, що використовуються, та середню тривалість сесій. Таким чином, мережа поступово вчиться розпізнавати шаблони звичайної поведінки, зокрема виявляти нетипові сценарії взаємодії з додатком. На основі цих даних створюється модель, здатна автоматично класифікувати нові дані як нормальні або аномальні, дозволяючи вчасно реагувати на потенційні загрози. Метод дозволяє ідентифікувати не лише очевидні аномалії, але й складні, малопомітні відхилення, які можуть свідчити про шкідливу активність або збої в роботі додатка. Такий підхід забезпечує високу адаптивність, оскільки модель може оновлюватися та перенавчатися на нових даних, враховуючи змінну поведінку користувачів і нові загрози [19]. Під час реальної роботи додатка нейронна мережа оцінює, наскільки поточна поведінка користувача відповідає тренувальним даним, надаючи вихідний коефіцієнт «нормальності».

Якщо цей коефіцієнт значно відхиляється від нормального діапазону, це може вказувати на можливу аномалію.

Для підвищення ефективності мережі важливо застосувати оптимальне кодування даних, щоб уникнути втрати контексту користувацьких дій. Наприклад, дані можуть бути закодовані за допомогою векторів, що відображають частоту використання команд або API, без введення зайвого порядку, який може викривити інтерпретацію нейронною мережею. Метод виявлення аномалій у мобільних додатках, заснований на побудові скінченних автоматів, дозволяє досягти вищої точності, ніж прості частотні або instance-based методи.

Це важливо, оскільки нейронні мережі можуть помилково сприйняти числову близькість значень як семантичну близькість, що може призвести до помилок у розпізнаванні аномалій [20].

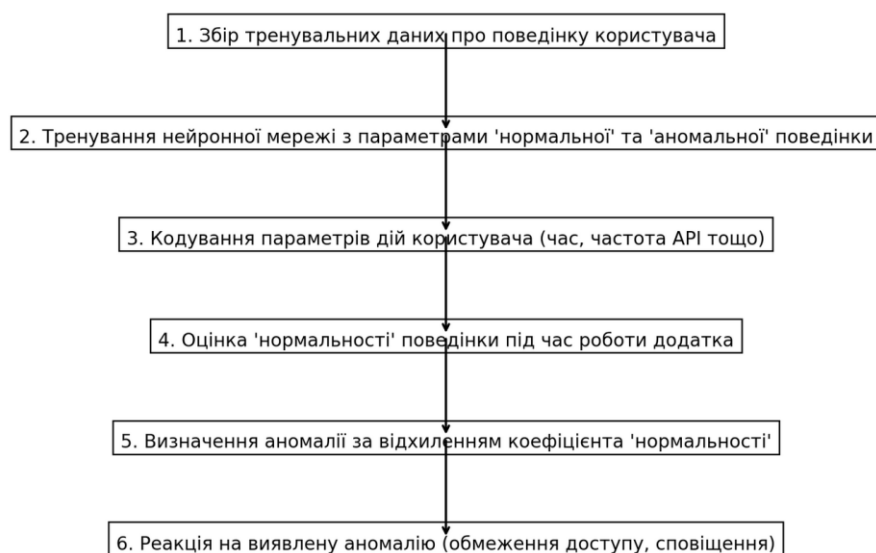


Рисунок 1.4 – Метод виявлення аномалій на основі нейромережевої моделі

У цьому підході події всередині додатка розглядаються як потік дискретних подій, наприклад, виклики API або дії користувача. Основна мета — створити автомат, який моделює типову послідовність подій у додатку, враховуючи ймовірні залежності між поточними і попередніми подіями. Такий метод дозволяє враховувати, що ймовірність наступної події часто залежить від кількох попередніх.

Для моделювання таких послідовностей можуть використовуватися марковські ланцюги, але збільшення порядку ланцюгів призводить до експоненційного зростання кількості станів автомата, що вимагає значних ресурсів. Спрощений підхід використовує матрицю переходів першого порядку, де ймовірність певної сесії розраховується як добуток імовірностей переходів між станами. Більш просунутим є підхід на основі прихованих марковських моделей (НММ), де ймовірність наступної події в послідовності визначається стохастично, а не лише через поточний стан. Проте навчання НММ є складним процесом, що потребує ручного налаштування кількості прихованих станів, а також періодичного переналаштування для адаптації до змінної поведінки користувачів, що є значним недоліком.

Для мобільних додатків можна побудувати автомат за n-грамами подій з тренувальних даних без аномальних випадків. У цьому підході кожна n-грама представляє стан автомата, причому кілька n-грам можуть належати одному стану. Побудований таким чином недетермінований автомат дозволяє виявляти нові, раніше не зафіксовані послідовності подій, хоча цей підхід не враховує статистичних параметрів. Альтернативно, може бути побудований імовірнісний автомат, де послідовність подій перетворюється на набір чисел, що відображають ступінь аномальності кожного переходу між станами. Це дозволяє оцінювати ймовірність аномалій на основі відхилень від типових переходів [21].

Для адаптації моделі до змін поведінки користувачів автомат можна налаштовувати на марковські ланцюги змінного порядку, які враховують лише значущі контексти. Це дозволяє уникнути експоненційного зростання ресурсних вимог і покращує точність виявлення аномалій, зберігаючи адаптивність. Важливо, щоб модель підтримувала актуальність інформації, що дозволяє уникати надмірного перенавчання і зберігати її ефективність у виявленні потенційно небажаної поведінки в мобільних додатках.

Байєсівські мережі можуть бути корисними для виявлення аномалій у мобільних додатках завдяки своїй здатності моделювати залежності між різними

подіями та імовірнісними розподілами, що виникають у додатку. На основі тренувальних даних байєсівська мережа оцінює кореляції між станами подій у мобільному додатку, створюючи мережу із взаємозалежних вузлів, що відображають ймовірності переходів між подіями. Проте така модель має обмежену адаптивність, оскільки її структура жорстко прив'язана до тренувальних даних [22].

Теоретико-інформаційний підхід також може застосовуватися для виявлення аномалій у мобільних додатках. Він поєднує два методи для визначення оптимальної ширини вікна для аналізу послідовності подій у додатку. Перший метод включає обчислення умовної ентропії $H(X|Y)$ наступної події на основі попереднього контексту. Ширина вікна обирається таким чином, щоб звести ентропію до мінімуму. Методика, яка виявляє аномалії без попереднього тренування на «чистих» даних нормальної поведінки. У цьому підході сукупність подій мобільного додатку моделюється як «змішана» стохастична модель, де кожна подія має ймовірність бути аномальною (λ) або нормальною ($1-\lambda$). При відсутності апіорних даних про розподіл аномалій вважається, що вони розподілені рівномірно. Нормальні події можуть оцінюватися з використанням технік машинного навчання, формуючи суміш розподілів.

1.4 Альтернативні шляхи виявлення аномалій в мобільних додатках

Розглянуті вище методи є основою для виявлення аномалій у мобільних додатках, проте жоден з них не гарантує виявлення всіх можливих атак. У реальних системах виявлення вторгнень (IDS) доцільно застосовувати комбінацію різних методів для підвищення ефективності, що дозволить приймати більш обґрунтоване рішення про наявність або відсутність вторгнень та їхній характер.

Моделі, що використовуються у цих методах, не повинні залежати від конкретного типу даних додатку, що забезпечує їх універсальність для різних типів

поведінкових послідовностей. Наприклад, окрім звичайних дій користувача у додатку, можна аналізувати послідовності API викликів, характерних для додатку, інтервали між діями, характерними жестами користувача, частоту доступу до різних функцій, а також інші поведінкові маркери. Будь-яка хронологічна або інша послідовність сигналів чи подій, що відображає унікальну активність користувача або особливості функціонування додатка, може стати джерелом даних для системи виявлення аномалій (ADS) [24].

Варто врахувати, що поведінка користувачів змінюється (через нові звички або задачі), тому моделі виявлення аномалій у мобільних додатках повинні бути адаптивними. Багато атак спрямовані на системні функції або надання додатку надмірних прав, що може спричинити аномалії у типових викликах системних функцій чи ресурсів додатку. У випадку таких атак мобільний додаток починає демонструвати нехарактерну активність, яка помітно відрізняється від звичайного профілю дій. Це робить популярним підхід до виявлення аномалій на рівні системних викликів та викликів API, який дозволяє абстрагуватись від змінної людської поведінки.

Проте аналіз даних, які надходять безпосередньо від користувача, залишається важливим, оскільки дає змогу виявляти аномалії, які можуть бути непомітні на рівні системних викликів (наприклад, використання вкраденого пароля).

1.5 Постановка задачі.

Метою кваліфікаційної роботи є розробка методу виявлення аномальної активності мобільних додатків шляхом аналізу поведінкових ознак та інтеграції сучасних методів машинного навчання.

Для досягнення поставленої мети необхідно вирішити наступні завдання дослідження:

- провести аналіз існуючих методів виявлення аномальної активності в мобільних додатках, визначити їх переваги, недоліки та можливості вдосконалення;
- дослідити особливості застосування методів поведінкового аналізу для моніторингу активності мобільних додатків;
- створити модель класифікації поведінкових патернів мобільних додатків, здатну розрізняти нормальну та аномальну поведінку;
- розробити метод моніторингу аномальної активності мобільних додатків із застосуванням машинного навчання, який включає аналіз дозволів, викликів API та інших характеристик;
- реалізувати запропонований метод на тестовому середовищі та провести його оцінку;
- порівняти ефективність запропонованого методу з існуючими підходами та обґрунтувати його переваги.

2 КЛАСИФІКАЦІЯ ОЗНАК МЕТОДУ ВИЯВЛЕННЯ АНОМАЛЬНОЇ ПОВЕДІНКИ МОБІЛЬНИХ ДОДАТКІВ.

2.1 Збір та аналіз даних поведінки мобільних додатків

Для дослідження було використано набір даних про зловмисне програмне забезпечення Android, отриманий із репозиторіїв Contagio [31] та DREBIN [46]. Файли зразків були перевірені за допомогою онлайн-сканера VirusTotal, щоб підтвердити їхню доброякісність або шкідливість. Після сканування APK-файли були розархівовані для вилучення вмісту, що зберігався в папці з набором даних. Загалом набір даних складався з 100 шкідливих програм та 100 доброякісних зразків, що дало загальну кількість 200 екземплярів у форматі APK.

Для отримання ресурсів із необробленого набору даних APK-файли було декомпільовано за допомогою Apktool, інтегрованого в останню версію Androguard. У результаті декомпіляції отримано доступ до таких ресурсів, як папки lib, res, original assets і файлу маніфесту Android. Вихідні дані включали папки класів Smali та Java, що містять відповідні файли ресурсів. Було вилучено ключові характеристики, такі як дозволи з файлу AndroidManifest.xml, підписи викликів API, наміри (intents) і командні підписи, які сформували набори функцій для побудови вхідних векторів до мережі. Додаткові характеристики, такі як спільні бібліотеки та бібліотеки даних, також було отримано через розбір вихідного коду файлів “.so” [18,23].

Загалом, використовуючи умовні ймовірності класу з мінімальними значеннями, було отримано 154 атрибутів, які сформували загальний набір функцій. Зокрема, набір включав 82 дозволів маніфесту, 53 підписи викликів API, 23 наміри, 6 командних підписів і бінарні атрибути для нешкідливих додатків (B) і зловмисного програмного забезпечення (S). Таким чином, запропонований класифікатор використовує функції дозволу, викликів API, команд і намірів для аналізу поведінки додатків.

Маніфест дозволів є одним із ключових механізмів безпеки, який Android використовує для контролю доступу. Цей механізм накладає обмеження на функціонування будь-якого процесу в Android, забезпечуючи захист системних ресурсів. Дозволи, запитувані додатками, містять важливу інформацію про їхню поведінку. Зазвичай дозволи визначаються та декларуються у файлі маніфесту Android APK.

Під час встановлення додатку файл `manifest.xml` містить ключову інформацію про його функціонал. У разі надання дозволу програма отримує доступ до захищених функцій пристрою. Усі дозволи Android поділяються на чотири рівні загрози: звичайні дозволи, небезпечні дозволи, дозволи підпису та дозволи підпису/системи. У цьому дослідженні рівні захисту та дозволи маніфесту були згруповані як окремі характеристики, що формують функції дозволів для роботи фреймворку.

Підписи команд представляють інструкції для підписання мітки та класу активності в Android. Вони використовуються для підтвердження дозволів, які запитують програми. У разі доброякісних додатків підпис команд відповідає сертифікату програми та заявленим дозволам. Якщо сертифікати збігаються, Android автоматично надає доступ програмі без сповіщення користувача та без запиту його згоди[12,40].

Проте шкідливі додатки, які мають підписи, ідентичні заявленим дозволам на пристрої, можуть отримати доступ до системних ресурсів у фоновому режимі. Хоча запити дозволів шкідливих файлів становлять загрозу для системної інформації, функції команд зосереджені на доступі до системних даних і обладнання.

Для підвищення ефективності класифікатора та зменшення обчислювальних витрат було скорочено кількість вхідних змінних моделі. Було відібрано лише ті змінні, які мали найсильнішу кореляцію з цільовими змінними. Для цього на попередньому етапі застосовувався підхід ранжування характеристик, що дозволило визначити ключові особливості додатків і скоротити набір вхідних змінних.

З APK-файлів було вилучено такі характеристики, як підписи викликів API, наміри, дозволи маніфесту та командні підписи. Ці дані сформували загальні вектори ознак, які були організовані у базу даних для подальшої класифікації. Всі ознаки були класифіковані за двома основними класами. Для нормалізації даних використовувався метод масштабування Min-Max, який приводив значення до діапазону від 0 до 1: якщо значення було відсутнє, його встановлювали як 0, а присутнє значення масштабувалося до 1.

Для групування даних застосовувався метод кластеризації K-means. Було виконано 8 ітерацій, у процесі яких мінімізувалася сума квадратів помилок у кожному кластері. Два основні кластери (C0 і C1) відповідали двом класам: C0 містив 66 об'єктів, а C1 — 34 об'єкти. Ці кластери визначили центроїди, на основі яких розподілялися атрибути дозволів. Логічна таблиця атрибутів відображала класи характеристик і їхні логічні значення, а список рішень містив правила, сформовані на основі таблиці 2.1.

Після обробки всі категорії ознак, включаючи дозволи, API-виклики, наміри та командні підписи, були об'єднані в єдиний набір векторів. Цей єдиний набір векторів слугував вхідними даними для процесу класифікації, дозволяючи моделі аналізувати всі ключові характеристики додатків у комплексі. Вектори було конвертовано у формат CSV, щоб спростити інтеграцію з інструментами аналізу, які вимагають роздільника полів для коректного зчитування даних..

Використання векторного представлення у форматі CSV також оптимізує підготовку даних для різних алгоритмів машинного навчання, зберігаючи структуру та цілісність інформації. Завдяки цьому підходу, інструменти аналізу можуть ефективніше виявляти аномалії та закономірності, що мають вирішальне значення для класифікації поведінки додатків. [29].

Усі чотири категорії ознак (дозволи, API-виклики, наміри та командні підписи) були об'єднані у єдиний набір, який використовувався як вхідний вектор для подальшого аналізу.

Таблиця 2.1 – Кластер, що містить бінарні ознаки вектора

	Кластери	Бінарні ознаки
1	Cluster 0(c0)S	0,0,0,0,0,0,0,0,0,0,0,0,1,0,1,0,0,0,1,0,0,0,0,0,1,0,0,0,1,0
2		1,0,0,0,0,0,0,0,0,0,0,1,0,1,0,0,0,1,0,1,0,0,0,0,1,1,0,0,0,0
3		0,0,1,0,0,1,0,0,0,0,1,0,0,0,0,1,0,1,0,0,0,0,0,1,0,0,0,1,0,0
4		0,0,0,1,0,0,1,0,0,0,1,0,0,1,0,1,0,0,1,0,0,0,0,0,0,1,0,1,0,1
5		0,S
6	Cluster 1(c1)B	1,1,1,1,1,1,1,1,1,1,1,1,1,1,0,1,0,0,0,1,1,0,1,1,0,0,1,1,1
7		1,0,1,0,1,1,0,1,0,1,1,0,1,1,0,0,1,1,1,1,0,1,1,0,1,1,1,1,0,0
8		1,0,0,1,1,0,0,1,1,1,1,0,1,1,0,1,0,1,1,1,0,0,0,1,0,1,1,0,1,1
9		0,1,1,1,1,0,1,0,1,1,1,1,0,1,1,0,1,1,0,1,1,0,1,0,1,1,1,0,1,1
10		0,0,1,0,1,0,0,1,1,1,1,0,1,0,1,1,0,1,1,1,1,0,0,1,0,0,0,1,0,B

Таблиця 2.2 – Розподіл ознак набору даних

Статистичні атрибути	Значення
Мінімум	0
Максимум	1
Середнє	0,412
Стандартне відхилення	0,478
Класовий патерн	600
Доброякісні	0,062
Класовий патерн	400
шкідливі	0,938

Для набору даних із 1000 APK-файлів було розраховано такі статистичні атрибути: мінімум дорівнює 0, що представляє найменше значення для двійкового атрибута в кластері, а максимум дорівнює 1, як максимальне значення. Середнє значення розподілу атрибутів у наборі даних становить 0.412, а стандартне відхилення — 0.478[30]. Ці значення використовуються для подальшого аналізу кластерів у наборі даних зловмисного програмного забезпечення. Формат CSV було обрано для зберігання вхідного вектору, щоб забезпечити сумісність з інструментами, які

потребують роздільника полів для коректного зчитування даних. На рисунку 2.1 графічно зображений алгоритм групування ознак Android додатків.

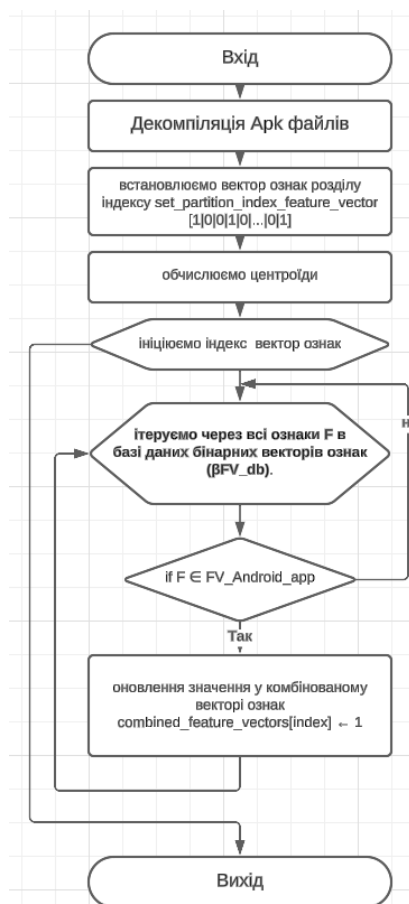


Рисунок 2.1 – Алгоритм об'єднання ознак для класифікації Android додатків

Результатом роботи алгоритму отримано таблицю логічних атрибутів $a_0, a_1 \dots a_n$ де кожен атрибут представляє бінарне значення присутності або відсутності певної ознаки в аналізованому додатку. Ці атрибути відображають ключові характеристики, виділені в процесі обробки даних, і дозволяють класифікувати додаток на основі його поведінкових ознак. Усі параметри, отримані в результаті роботи алгоритму, представлені в таблиці 2.3, що дозволяє наочно проаналізувати ознаки та використовувати їх для подальшого навчання та роботи класифікатора[33].

Таблиця 2.3 Логічні ознаки

Ознака	Логічне значення
@attribute a0	{ false,true }
@attribute a1	{ false,true }
@attribute a2	{ false,true }
@attribute a3	{ false,true }
@attribute a4	{ false,true }
@attribute a5	{ false,true }
@attribute a6	{ false,true }
@attribute a7	{ false,true }
@attribute a8	{ false,true }
@attribute a9	{ false,true }
@attribute	{ c0,c1 }
class	

Інформація про вектор ознак витягується з набору даних, взятого з бази зловмисних ознак, яка містить рядки, дозволи, компоненти та інші зовнішні характеристики. Структура бази даних складається з різних компонентів, де всі ознаки були підготовлені та класифіковані. Всі рядкові ознаки містять відповідні хеші та розміри, а дозволи зберігаються в тегах <uses-permission> і <permission>. Загальні компоненти бази ознак включають теги <provider>, <filter>, <activity>, <intent>, <grant-uri-permission>, <service> і <receiver>, які визначають основний склад бази даних ознак, з якої виділяються всі унікальні характеристики.

Додаткові зовнішні компоненти, такі як <library> та <uses-sdk>, також враховуються в базі даних. Методи Opcode і API, такі як send_message, socket, та invoke, є ключовими ознаками. Інформація про набір ознак, отримана алгоритмом, містить наміри (як зазначено в таблиці 2-5), командні підписи (таблиця 2-6), дозволи

(таблиця 2-7) та підписи викликів API (таблиця 2-8), що формують основні категорії ознак у комбінованій базі даних[35].

Цей опис підходить для нашої тематики аналізу поведінкових ознак мобільних додатків, зосереджуючи увагу на характеристиках, які є ключовими для класифікації та виявлення аномальної або шкідливої поведінки.

2.2 Класифікація ознак

Класифікації ознак базується на механізмі зворотного поширення помилки. Зворотне поширення є ключовим елементом процесу навчання нейронної мережі для отримання точних результатів класифікації. Воно полягає в передачі інформації про помилку, яка генерується під час прогнозування або класифікації певного набору даних, з метою коригування ваг. Цей процес складається з ітераційного навчання, де задіяні вхідний, прихований і вихідний рівні нейронної мережі, з випадковою ініціалізацією ваг і зміщення.

У моделі також застосовується підхід інформаційного приросту (IG) для класифікації ознак, який дозволяє визначити, наскільки певна ознака X зменшує невизначеність у вибірці. Інформаційний приріст IG для ознаки X визначається як різниця між початковою ентропією вибірки ($H(S)$) та умовною ентропією ($H(S|X)$), яка розраховується після врахування цієї ознаки. Ця метрика дозволяє оцінити значущість кожної ознаки, вимірюючи, наскільки вона сприяє покращенню точності класифікації. Використання IG допомагає відфільтрувати малозначущі ознаки, зосереджуючи модель на найбільш впливових параметрах.

$$IG(X) = H(X) - H(X|Y) \quad (2.1)$$

де $H(X)$ є ентропією ознаки X , що показує ступінь випадковості або невизначеності цієї ознаки в загальній вибірці, а $H(X|Y)$ — умовна ентропія X з урахуванням Y , що вказує на те, скільки невизначеності залишається в X після врахування Y .

Ентропія $H(X)$ обчислюється за формулою:

$$H(X) = - \sum p(x) \log_2(p(x)) \quad (2.2)$$

де $p(x)$ — ймовірність кожного значення x у X . Ця формула відображає середню кількість інформації, яку можна отримати, знаючи значення X у загальній вибірці.

Аналогічно, умовна ентропія $H(X|Y)$ розраховується так:

$$H(X|Y) = - \sum p(x|Y) \log_2(p(x|Y)) \quad (2.3)$$

де $p(x|y)$ — Умовна ймовірність $p(x|y)$ відображає ймовірність виникнення значення x у ознаці X за умови, що відоме значення y у ознаці Y . Ця умовна ймовірність використовується для обчислення умовної ентропії $H(X|Y)$, яка показує невизначеність або випадковість ознаки X з урахуванням інформації про Y . Іншими словами, $H(X|Y)$ оцінює, наскільки знання про ознаку Y зменшує невизначеність щодо ознаки X .

Якщо між X та Y існує сильний зв'язок, умовна ентропія $H(X|Y)$ буде нижчою, оскільки інформація про Y допомагає точніше передбачити або пояснити значення X . Високе значення умовної ймовірності $p(x|y)$ вказує на те, що значення x з більшою ймовірністю виникає при певному значенні y , що зменшує загальну невизначеність. Це означає, що якщо $p(x|y)$ має високі значення для певних комбінацій x і y , то ознака Y є значущою для пояснення або прогнозування значення ознаки X .

У контексті інформаційного приросту (IG) це означає, що високе значення $IG(X)$ вказує на значну інформацію, яку ознака Y надає про ознаку X . Коли умовна ймовірність $p(x|y)$ виявляється великою, умовна ентропія $H(X|Y)$ зменшується, що

призводить до збільшення інформаційного приросту. Це вказує на високу значимість ознаки Y для прогнозування або класифікації на основі X

Далі представлено таблицю з правилами класифікації ознак на основі обчислених атрибутів. У цій таблиці логічні правила (RULE) визначають умови присутності або відсутності атрибутів $a_0, a_1 \dots a_n$ для визначення класу додатків. Таблиця 2.4 містить логічні вирази, які описують умови, за яких ознаки класифікуються, що дозволяє точно визначати класифікаційні межі для кожного правила.

Таблиця 2.4 – Список рішень з використанням відповідних правил

Правило(Rule)	Логічний Вираз (Decision List)
Rule1	$c0 = (a0 = 1) \text{ AND } (a2 = 0) \text{ AND } (a4 = 1)$
Rule2	$c1 = (a1 = 1) \text{ AND } (a3 = 0) \text{ AND } (a5 = 0) \text{ AND NOT}(a0)$
Rule3	$c0 = (a2 = 1) \text{ AND } (a5 = 1) \text{ AND } (a6 = 0) \text{ AND } (a0 = 0)$
Rule4	$c1 = (a1 = 1) \text{ AND } (a3 = 1) \text{ AND } (a7 = 0)$
Rule5	$c0 = (a2 = 1) \text{ AND } (a4 = 1) \text{ AND } (a8 = 0) \text{ AND } (a0 = 0)$
Rule6	$c1 = \text{NOT}(a1) \text{ AND } (a3 = 1) \text{ AND } (a6 = 1)$
Rule7	$c0 = (a0 = 1) \text{ AND } (a5 = 1) \text{ AND NOT}(a2)$
Rule8	$c1 = (a3 = 1) \text{ AND NOT}(a1) \text{ AND } (a7 = 1)$
Rule9	$c0 = (a2 = 1) \text{ AND NOT}(a5) \text{ AND } (a8 = 1)$
Rule10	$c1 = (a1 = 0) \text{ AND } (a4 = 1) \text{ AND } (a9 = 0)$
Rule11	$c0 = (a0 = 1) \text{ AND NOT}(a3) \text{ AND } (a6 = 0)$
Rule12	$c1 = (a2 = 1) \text{ AND NOT}(a4) \text{ AND } (a7 = 1)$
Rule13	$c0 = \text{NOT}(a0) \text{ AND } (a5 = 1) \text{ AND } (a8 = 1)$
Rule14	$c1 = (a1 = 1) \text{ AND } (a3 = 1) \text{ AND } (a9 = 1)$
Rule15	$c0 = (a2 = 1) \text{ AND } (a4 = 0) \text{ AND } (a6 = 1)$
Rule16	$c1 = (a0 = 1) \text{ AND NOT}(a5) \text{ AND } (a8 = 0)$

Якщо ймовірність відмови виникає при будь-якому заданому часу виживання, то функція ризику $h(t)$ може бути визначена як співвідношення інтегрального та миттєвого показників. Функцію ризику або небезпеки $h(t)$ визначають за допомогою наступної інтегральної формули

$$H(x) = \int_0^x h(t)dt \quad (2.4)$$

е x є верхньою межею часу виживання, а t змінюється від 0 до x . Наша модель передбачає, що всі ознаки у наборі даних "виживають" в умовах дії функції ризику. Відповідно, функція виживання $s(t)$ визначає ймовірність того, що ознака "пережила" минулий час t без відмови, і розраховується за формулою:

$$s(t) = P(T > t) = 1 - F(t) \quad (2.5)$$

де $s(t)$ — це функція виживання в момент часу t , T — випадкова змінна, яка представляє час до відмови, $P(T > t)$ — ймовірність того, що ознака пережила момент t , а $F(t)$ — функція щільності події відмови.

У нашому дослідженні ми використовували три різні розподіли — Вейбуллів, нормальний та Бірнбаум-Сандерс, — щоб показати, що зі збільшенням значення FFF відповідне значення $s(t)$ зменшується..

2.3 Бінарне представлення ознак

Для процесу класифікації дозволів класифікатора використовується метод кластеризації K-середніх для створення бінарних векторів ознак на основі дозволів Android-додатків. Класифікатор позначає кожен запит на дозвіл однією з класових міток: $C_i \in \{c_m, c_b, c_k\}$ де c_m - класова мітка для шкідливого запиту, c_b - класова мітка для безпечного запиту, c_k — класова мітка для невідомого запиту.

Кожен додаток має вектор ознак f_i який визначає набір характеристик дозволів: $f_i \in \{f_1, f_2, \dots, f_n\}$, де f_1, f_2, \dots, f_n онкретні ознаки (дозволи, API-виклики тощо), які використовуються для класифікації. Класифікатори $R = \{r_1, r_2, \dots, r_n\}$, призначають запитам на дозвіл класову мітку на основі їхнього змісту та природи (шкідливі, безпечні або невідомі).

Таблиця 2.5 – Вектори ознак наміру

Ознака	Категорія
android.permission.ACCESS_FINE_LOCATION",	Intent
"android.permission.ACCESS_COARSE_LOCATION",	Intent
"android.permission.READ_CONTACTS",	Intent
"android.permission.WRITE_CONTACTS",	Intent
"android.permission.READ_CALENDAR",	Intent
"android.permission.WRITE_CALENDAR",	Intent
"android.permission.CAMERA",	Intent
"android.permission.RECORD_AUDIO",	Intent
"android.permission.READ_SMS",	Intent
"android.permission.SEND_SMS",	Intent
"android.permission.RECEIVE_SMS",	Intent
"android.permission.READ_CALL_LOG",	Intent
"android.permission.WRITE_CALL_LOG",	Intent
"android.permission.PROCESS_OUTGOING_CALLS",	Intent
"android.permission.READ_PHONE_STATE",	Intent
"android.permission.ACCESS_WIFI_STATE",	Intent
"android.permission.CHANGE_WIFI_STATE",	Intent

В таблиці 2.5 представлено набір дозволів Android-додатків, які визначають доступ до різних функцій та ресурсів пристрою. Кожен запис у стовпці "Feature" відображає конкретний дозвіл, необхідний додатку для виконання певних дій,

Таблиця 2.6 – Вектори ознак командних підписів

Ознака	Категорія
Rm	Командна ознака
Dd	Командна ознака
Chmod	Командна ознака
Su	Командна ознака
Mount	Командна ознака
Systemctl	Командна ознака
Iptables	Командна ознака
Reboot	Командна ознака
pkill	Командна ознака

Наведенні в таблиці 2.6 критичні команди часто використовуються для спроб виконання небезпечних або несанкціонованих дій у системі Android. На основі цього, ми включили їх у набір команд, які можуть використовуватися додатками для обходу системних обмежень, отримання привілеїв суперкористувача або зміни системних налаштувань без відома користувача.

Таблиця 2.7 – Вектори ознак дозволів

Ознака	Категорія
MANAGE_EXTERNAL_STORAGE	Manifest Permission
USE_FULL_SCREEN_INTENT	Manifest Permission
ACTIVITY_RECOGNITION	Manifest Permission
FOREGROUND_SERVICE	Manifest Permission
READ_PRIVILEGED_PHONE_STATE	Manifest Permission
PACKAGE_USAGE_STATS	Manifest Permission
BLUETOOTH_ADVERTISE	Manifest Permission
BLUETOOTH_CONNECT	Manifest Permission
POST_NOTIFICATIONS	Manifest Permission
NEARBY_WIFI_DEVICES	Manifest Permission
ACCESS_MEDIA_LOCATION	Manifest Permission
READ_EXTERNAL_STORAGE	Manifest Permission
WRITE_EXTERNAL_STORAGE	Manifest Permission
PROCESS_OUTGOING_CALLS	Manifest Permission

В результаті виконання дослідження поведінки мобільних додатків було сформовано вектори ознак, які вказують на те, на які дозволи були спрямовані наміри додатків. Дані дозволи можуть безпосередньо впливати на безпеку, конфіденційність та дані користувача, оскільки вони дозволяють додаткам отримувати доступ до важливих ресурсів пристрою, таких як місцезнаходження, контакти, дзвінки, повідомлення, камеру, мікрофон та інші функції. Наприклад, дозволи на доступ до мережі, системних налаштувань або особистої інформації можуть бути використані для несанкціонованого збору даних або зміни системних параметрів без відома користувача. Зібрані вектори ознак представлені в таблиці 2.7 не лише дозволяють класифікувати поведінку додатків, але й сприяють

виявленню потенційно небезпечних дій, що допомагає ефективно виявляти шкідливі програми та захищати пристрій від загроз [45].

Таблиця 2.8 – Вектори ознак API викликів

Ознака	Категорія
android.telephony.SmsManager	API call signature
onServiceConnected	API call signature
attachInterface	API call signature
Ljava.net.URLDecoder	API call signature
ClassLoader	API call signature
HttpGet.init	API call signature
SecretKey	API call signature
Ljava.lang.Object.getClass	API call signature
Binder	API call signature
Ljavax.crypto.spec.SecretKeySpec	API call signature
DexClassLoader	API call signature
getCallingUid	API call signature
Ljava.lang.Class.getMethods	API call signature
System.loadLibrary	API call signature

Таблиця відображає ключові API-виклики, що використовуються для аналізу поведінки мобільних додатків. Наприклад, `java.net.URLDecoder` вказує на декодування URL-адрес, `HttpGet.init` – на HTTP-запити, а `DexClassLoader` – на динамічне завантаження класів, що може свідчити про приховану активність. Ці виклики формують бінарні вектори ознак, які класифікатор аналізує для визначення додатків як безпечних або шкідливих.

Ключовими метриками оцінки класифікатора є обчислювальний час (TR) і точність (AR). TR показує, скільки часу потрібно для аналізу ознак, що важливо для практичності моделі в умовах обмежених ресурсів. AR визначає точність класифікації додатків. Баланс між TR та AR критично важливий для ефективності системи. Вводяться обмеження на мінімальну кількість класифікаторів (E) та максимальний час виконання для оптимізації продуктивності, забезпечуючи високу точність і низькі витрати.

Для обчислення часу роботи моделі (TR) та точності класифікації (AR) використовуються наступні формули:

$$TR = \sum_{i=1}^n T(r_i), r_i \in R \quad (2.6)$$

де TR – це загальний обчислювальний час для всіх класифікаторів r_i у моделі, а $T(r_i)$ представляє час, необхідний для роботи окремого класифікатора.

$$AR = \sum_{i=1}^n a(r_i), r_i \in R \quad (2.7)$$

де AR — це середній показник точності класифікації для всіх класифікаторів (r_i), $a(r_i)$ — точність кожного класифікатора.

Щоб уникнути перевищення класифікаторами порогового рівня точності ϕ , всі класифікатори в моделі повинні відповідати мінімальній кількості класифікаторів (E). Це визначається за допомогою наступної формули:

$$\min = \sum_{i=1}^n r_i \leq E \quad (2.8)$$

де n — кількість класифікаторів, а E — мінімальна кількість класифікаторів, необхідна для підтримки ефективності.

У нашій моделі кожен запит на дозвіл, здійснений додатком, позначається як шкідливий (C_m) або нешкідливий (C_b). Класифікатор аналізує всі дозволи, визначаючи їх відповідність класам. Ми включили параметр E , щоб оцінити ефективність роботи класифікатора і порівняти його з іншими алгоритмами машинного навчання, якщо спостерігається різниця в точності класифікації.

Бінарні вектори ознак представляють атрибути кластерів, що використовуються для аналізу поведінки додатків. У процесі класифікації вони визначають належність ознак до кластерів. Метод 2-fold крос-валідації забезпечує точність, розділяючи дані

на навчальну та тестову вибірки. Ознаки розподілено між двома кластерами: кластер 0 відповідає нешкідливим додаткам, кластер 1 – потенційно шкідливим.

Асоціативні правила забезпечують адаптивний підхід до аналізу даних, дозволяючи автоматично виявляти складні та приховані взаємозв'язки між атрибутами навіть у нестабільних та динамічних середовищах. Це особливо актуально у сферах, де поведінкові патерни постійно змінюються, наприклад, у кібербезпеці, де нові загрози та методи атак з'являються майже щодня.

Завдяки здатності асоціативних правил швидко виявляти аномалії та нетипові залежності, аналітики отримують потужний інструмент для ефективного моніторингу та виявлення потенційних загроз. Такий підхід знижує залежність від ручного аналізу, який є ресурсомістким і не завжди може врахувати всі можливі сценарії. У результаті автоматизовані моделі стають гнучкішими, що дозволяє не лише ідентифікувати ризики у реальному часі, але й покращувати точність прогнозів та захищеність інформаційних систем загалом. Крім того, інтеграція асоціативних правил у класифікаційні моделі сприяє підвищенню їхньої пояснюваності.

Оскільки правила відображають причинно-наслідкові зв'язки між ознаками, це дозволяє легше розуміти, чому певний додаток було віднесено до конкретного класу. Така прозорість є ключовою у розробці надійних систем, оскільки допомагає аналітикам краще довіряти результатам моделі і використовувати їх для прийняття обґрунтованих рішень.

Цей підхід також забезпечує масштабованість аналізу, дозволяючи працювати з великими обсягами даних і складними структурами залежностей між атрибутами. Асоціативні правила сприяють створенню гнучких і адаптивних моделей, які легко інтегруються в існуючі системи аналізу. Завдяки цьому можна ефективно розпізнавати навіть малопомітні або нетипові патерни, що значно покращує виявлення аномалій та забезпечує високий рівень захисту в інформаційних системах.

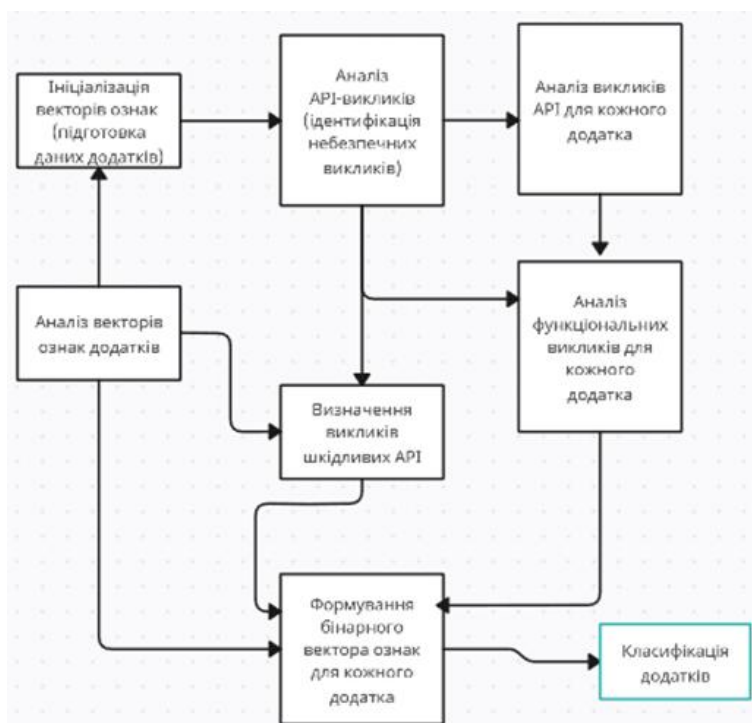


Рисунок 2.1 – Процес класифікації додатків

Таким чином, процес кластеризації й аналізу ознак є ключовим етапом у побудові ефективної моделі класифікації додатків.

Процес класифікації векторів ознак дозволів Android-додатків аналізує дозволи з маніфестного XML-файлу для визначення потенційно шкідливих чи нешкідливих дозволів. Алгоритм генерує інформацію про дозволи, перевіряючи кожен на відповідність певним критеріям. Формується бінарний вектор ознак, де "1" означає шкідливий дозвіл, а "0" — нешкідливий.

Ітерації включають аналіз, додавання нових дозволів через "кросовер", порівняння шкідливих і нешкідливих дозволів, видалення дублікатів і уточнення набору. Остаточний вектор ознак використовується для класифікації додатків, дозволяючи виявляти небезпечні дозволи для подальшої аналітики або машинного навчання. Цей вектор інтегрує всі ключові характеристики, зібрані на попередніх етапах, забезпечуючи цілісне уявлення про кожний додаток. Використання такого підходу дозволяє автоматизувати процеси аналізу, скорочуючи час, необхідний для

ідентифікації потенційних загроз. Завдяки цьому моделі можуть більш точно визначати ризиковані патерни поведінки, які можуть свідчити про наявність шкідливого коду або порушень безпеки. Крім того, аналіз небезпечних дозволів сприяє побудові профілів ризиків, що можуть використовуватися для прийняття рішень у системах реального часу.

2.4 Класифікація векторів ознак за допомогою нейронних мереж

Структура нейронної мережі, яка є основою фреймворку Android Permission Classifier (APC) для виявлення аномальної поведінки мобільних додатків. Фреймворк базується на згорткових нейронних мережах (CNN), які аналізують шаблони у векторах ознак, отриманих із поведінкових характеристик додатків. Мережа складається з кількох шарів, кожен із яких перетворює вхідний вектор ознак x у вихідний вектор u , використовуючи універсальну формулу

$$y = f(\omega \cdot x + b) \quad (2.9)$$

де w — ваги мережі, b — зміщення, а f — функція активації. У нашому випадку це Rectified Linear Unit (ReLU), яка підвищує ефективність роботи мережі, залишаючи значення $x > 0$ без змін і встановлюючи $x < 0$ на 0 . На кожному етапі лінійна трансформація векторів ознак дозволяє моделі виділяти найбільш значущі патерни в даних. Вихідні вектори з початкових шарів передаються на наступні, поступово звужуючи набір характеристик і підкреслюючи ті, які впливають на визначення "нормальної" чи "аномальної" поведінки додатка. Процес класифікації охоплює три основні етапи: формування вхідного вектора з даних про дозволи, виклики API та команди; згортку та max-pooling для виявлення локальних патернів; і подачу результатів до останнього шару для класифікації. Цей підхід дозволяє ефективно аналізувати великі набори даних і точно прогнозувати безпеку додатків, мінімізуючи складність моделі.

У фінальному шарі нейронної мережі для прогнозування ймовірності результату в діапазоні від 0 до 1 використовується функція стискання (σ). Це дозволяє визначити, чи є дозвіл шкідливим (1) або нешкідливим (0) у нашому фреймворку. Функція стискання (σ) застосовується до вихідного вектора останнього шару мережі. Вектор x , що подається у вхідний шар, проходить трансформацію через ваги w , зміщення b та функцію активації ReLU, отримуючи фінальний вихід. Перетворення на останньому шарі нейронної мережі описується формулою:

$$y^{n_x} = \sigma(z^{(n_x)}) \quad (2.10)$$

Тут σ — функція стискання, n — кількість шарів у нейронній мережі, y^{n_x} — вихідний вектор останнього шару, x — вхідний вектор у мережу, а Z — матриця векторів відповідно.

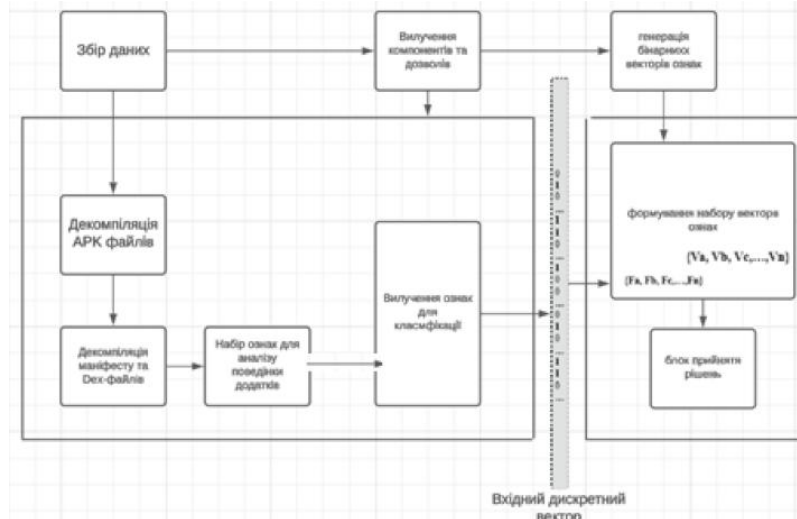


Рисунок 2.2 – Процес збору даних та генерації бінарних ознак

Архітектура системи забезпечує виконання всіх етапів — від збору даних до генерації бінарних векторів ознак, що дозволяє класифікувати поведінку мобільних додатків як шкідливу або нешкідливу. Загальна архітектура системи на рисунку 2.2

показує процеси, що виконуються від збору даних до генерації вектору бінарних ознак.

Баєсовська регуляризація (Bayesian Regularization, BR) використовується в нашій нейронній мережі для вирішення проблеми перенавчання. Перенавчання виникає, коли модель адаптується до специфічних даних тренувального набору, втрачаючи здатність узагальнювати нові дані. На відміну від Dropout, який відключає окремі нейрони під час навчання, BR зменшує залежність моделі від конкретних параметрів, забезпечуючи стабільність і точність класифікації.

У процесі регуляризації використовуються ваги w та зміщення b для оптимізації функції активації та підвищення якості моделі. Функція зв'язку між вхідними та вихідними даними визначається як:

$$y = \omega \cdot x + b \quad (2.11)$$

Тут x — вхідні дані (вектор ознак), w — ваги, а b — зміщення.

Для оцінки помилки та її мінімізації застосовується функція втрат, яка розраховує різницю між очікуваним $y_{expected}$ та фактичним результатом y :

$$L = (y_{expected} - y)^2 \quad (2.12)$$

Середнє значення втрат $E[L]$ враховує всі можливі випадки, пов'язані з вхідними та вихідними даними, що підвищує стійкість моделі до варіативності:

$$E[L] = \int L(x)p(x)dx \quad (2.13)$$

Де $p(x)$ — ймовірність входу x . Завдяки баєсовській регуляризації модель досягає оптимального балансу між точністю та узагальненням, що особливо важливо для класифікації шкідливих і нешкідливих додатків.

Регуляризація різноманітності ознак основна з проблем класифікації та виявлення — надлишковості ознак. Ця проблема виникає, коли алгоритми класифікації помилково виділяють ознаки, що мають низьку унікальність, що призводить до невірної класифікації. Для мінімізації цих помилок у моделі застосовано регуляризацію різноманітності ознак, яка зосереджена на усуненні надмірності шляхом відбору ознак із самокореляцією та обмеження використання подібних ознак.

Векторний простір $V = \{f_1, f_2, \dots, f_n\}$ представляє набір ознак. Схожість між ознаками f_a і f_b визначається кореляцією між ними.

Загальна міра розмаїття ознак DCDCDC під час навчання визначається як:

$$DC = \frac{1}{k} \sum_{i=1}^k m_i (SIM(f_a, f_b))^2 \quad (2.14)$$

m_i бінарна маска, що визначає, чи потрібно включати пари ознак до обчислень. Параметр регуляризації контролює допустиму схожість між ознаками.

Для покращення точності класифікатора та вирішення проблеми часткового вилучення ознак кожен тип дозволу з вектору ознак вивчався на кожному початковому шарі нейронної мережі з коефіцієнтом навчання 0,01. Цей підхід повторювався від початкового шару до кінцевого. На кожному шарі наступний шар вивчав інформацію з попереднього шару. Згідно з мережею, де шари позначено як $l^s = \{1, 2, \dots, n\}$, шар l^0 отримував знання від наступних шарів забезпечуючи оновлення інформації на кожному етапі.

У випадках, коли ознаки дозволу не могли бути вилучені з файлу Manifest, використовувалися нулі для формування вектора ознак без асоціації з векторами дозволів. Це дозволяло класифікатору диференціювати ознаки високого ризику, якщо у векторі ознак було хоча б одне значення. Стратегія навчання моделі АРС значно скоротила час навчання мережі, уникнувши витрат, пов'язаних із використанням алгоритму регуляризації BR. Алгоритм Левенберга-Марквардта потребує менше часу,

але не забезпечує достатньої генералізації для невеликих або зашумлених даних. Нова стратегія покращила точність класифікації моделі, зменшила середньоквадратичну помилку (MSE) і суму квадратів помилок (SSE), а також забезпечила високу кореляцію між ефективністю та точністю класифікації. Використання функції заперечення у BR дозволило зосередитися на ключових аспектах моделі, мінімізуючи помилку оцінки й підвищуючи якість виявлення аномалій у мобільних додатках, незважаючи на необхідність додаткових обчислювальних ресурсів.

2.5 Висновок

Запропонований підхід базується на використанні класифікаційних моделей, що забезпечують високу точність розпізнавання аномальної поведінки. Розроблена архітектура нейронної мережі дозволяє враховувати широкий спектр ознак, таких як виклики API, підписи команд, дозволи та інші ключові параметри. Особливу увагу приділено мінімізації проблем надлишкових даних та підвищенню різноманітності ознак для покращення генералізації моделі. У процесі роботи було використано регуляризацію та адаптивний підхід до відбору ознак, що дозволило створити ефективну систему класифікації.

3.МЕТОД КОРЕЛЯЦІЙНОГО АНАЛІЗУ ДОЗВОЛІВ ДЛЯ ВИЯВЛЕННЯ АНОМАЛЬНОЇ ПОВЕДІНКИ МОБІЛЬНИХ ДОДАТКІВ

3.1 Передумови методу аналізу дозволів

Android — це найпопулярніша платформа для смартфонів, яка займає близько 74,5% ринку мобільних пристроїв. Її відкритий код, зручність у використанні та низька вартість сприяють широкому поширенню сторонніх додатків. Однак ці фактори також призвели до значного збільшення кількості шкідливих програм, які зловживають дозволами для отримання доступу до чутливих даних користувачів.

Для забезпечення безпеки користувачів Android використовує механізм дозволів, який обмежує доступ до ресурсів пристрою. Деякі дозволи класифікуються як «небезпечні» через їх потенційно високий рівень ризику. Користувачі часто нехтують цим ризиком, надаючи дозволи без належного аналізу їхньої необхідності, що відкриває можливості для атак.

Зловмисники використовують техніки, які приховують шкідливу активність у дозволах, що вже були надані. Наприклад, одноразово отримавши доступ до ресурсів пристрою, додаток може автоматично виконувати додаткові запити без повідомлення користувача.

Розуміння взаємозв'язків між дозволами дозволяє виявляти аномалії та підозрілу поведінку додатків. Виявлення таких аномалій є ключовим для захисту конфіденційності та даних користувачів. Аналіз дозволів дозволяє класифікувати додатки за рівнем ризику та виявляти шкідливі програми на основі їхніх поведінкових патернів.

Модель кореляційного аналізу дозволів Android використовує методи t-SNE та SOM для візуалізації взаємозв'язків між дозволами. Це дозволяє ідентифікувати підозрілі патерни в поведінці додатків, які можуть свідчити про потенційну небезпеку або аномалії.

Дослідження показують, що дозволи Android мають певний рівень загрози, навіть якщо вони класифікуються як нормальні чи небезпечні. Виявлення взаємозв'язків між рівнями захисту та загрози допомагає зрозуміти, як кожен дозвіл може впливати на загальну безпеку системи.

Аналіз дозволів демонструє, що дозволи з однаковим рівнем захисту часто мають однаковий рівень загрози. Проте рівень загрози може змінюватися залежно від конкретного використання додатком. Це дозволяє визначити потенційно небезпечні додатки навіть у межах одного класу захисту.

Модель дозволяє класифікувати додатки як шкідливі чи нешкідливі, ґрунтуючись на аналізі їхніх дозволів. Групування додатків у кластери за подібністю дозволів допомагає ідентифікувати родини шкідливих програм та зрозуміти загальні риси їхньої поведінки.

Результати дослідження спрямовані на розширення існуючих підходів до аналізу системи дозволів Android. Це дозволяє глибше зрозуміти сучасний стан безпеки додатків та підвищити ефективність виявлення аномалій і загроз.

Архітектура безпеки Android базується на системі дозволів. Вона створена таким чином, щоб жоден додаток не міг бути встановлений або функціонувати, якщо це може негативно вплинути на операційну систему, інші додатки або дані користувача. Ця система постійно вдосконалюється відповідно до оновлень версій Android.

З кожним новим оновленням Android додається більше дозволів і функцій, пов'язаних з API. Наприклад, перша версія Android з кодовою назвою "Base" мала рівень API 2 та всього 73 дозволи. З часом кількість дозволів значно зросла, що пояснюється необхідністю забезпечення більш високого рівня захисту пристрою. Рівень захисту є однією з груп дозволів, визначених системою Android, і він впливає на загальну архітектуру безпеки платформи.

Таблиця 3.1 – Ріст API рівня та дозволів від версії Android

Назва Платформи	Версія Платформи	Рівень API	Кількість Дозволів
Android 11 beta	11	30	160
Q	10	29	158
PI	9	28	148
Oreo	8	26-27	144
Nougat	7	24-27	135
Marshmallow	6	24-25	131
Lollipop	5	23	125
KitKat watch	4.4W	21-22	120
KitKat	4.4	20	112
Jelly Bean	4.1-4.3.1	19	104
Ice Cream Sandwich	4.0.1-4.3.1	16-18	98
Honeycomb	3.0-3.2	14-15	95
Froyo	2.2	11-13	94
Éclair	2.0-2.1	6-10	87
Donut	1.6	4	86
Cupcake	1.5	3	81
Base	1-1.1	1-2	73

Класифікація рівнів захисту дозволів Android є основою для виявлення аномалій у мобільних додатках. Вона дозволяє зрозуміти, як різні типи дозволів впливають на безпеку системи і можуть використовуватися для потенційно шкідливої активності. Аналіз цих рівнів допомагає ідентифікувати ризики та підозрілу поведінку додатків.

Звичайний рівень є базовим рівнем, де дозволи зазвичай надаються без участі користувача. Хоча ці дозволи не вимагають явно вираженої згоди, зловмисники можуть використовувати їх для обходу безпекових обмежень. Наприклад, надмірне використання таких дозволів може вказувати на аномалію, яка пов'язана зі спробою прихованого доступу до ресурсів пристрою.

Сигнатурний рівень безпеки передбачає, що дозволи можуть бути надані лише за умови відповідності сертифікатів заявленого та запитуючого додатка. Цей рівень ускладнює зловмисне використання дозволів, але у разі компрометації сертифікатів аномальні запити можуть залишатися непоміченими. Аналіз кореляцій дозволяє виявляти такі випадки та посилити перевірку відповідності сертифікатів.

Високий рівень захисту стосується дозволів, які надають доступ до критично важливих ресурсів, таких як особисті дані, камера чи мікрофон. Зловмисники часто маніпулюють цими дозволами, використовуючи соціальну інженерію або приховуючи запити. Аномальна поведінка, наприклад, запит дозволу на доступ до камери додатком, який не повинен використовувати її за своїм функціоналом, може свідчити про потенційну загрозу.

Використання аналізу рівнів захисту дозволів є важливим етапом у моделюванні кореляцій для виявлення аномалій. Додатки, які демонструють нетипове використання дозволів або запити на доступ до незвичних ресурсів, можуть бути класифіковані як підозрілі, що допомагає забезпечити додатковий рівень захисту для користувачів.

Системний рівень захисту визначає дозволи, які надаються лише додаткам, підписаним тим самим сертифікатом, що і система Android. Цей рівень захисту призначений для забезпечення обміну специфічними системними функціями між додатками, створеними декількома вендорами. Хоча такі дозволи повинні бути недоступні для сторонніх додатків, шкідливі програми можуть використовувати уразливості, такі як прапорець `pre23`, щоб автоматично отримати доступ до системних функцій. Аномалії в таких запитах, наприклад, наявність привілейованих прапорів у додатку без відповідного сертифіката, можуть сигналізувати про шкідливу активність.

Повідомлення про намір є механізмом, що використовується Android для передачі даних між компонентами додатків. Намір (Intent) може бути використаний для виклику дій або послуг у системі, наприклад, для зйомки фотографій або перегляду карт. Шкідливі додатки часто маніпулюють Intent-повідомленнями для підвищення привілеїв, викликаючи несанкціоновані дії або доступ до даних. Наприклад, якщо додаток ініціює запит на виконання дії, яка не відповідає його основному функціоналу, це може бути ознакою аномалії.

Ці аспекти є важливими елементами у виявленні аномалій у мобільних додатках. Аналіз взаємодії дозволів, сертифікатів і намірів дозволяє ідентифікувати підозрілу поведінку додатків, що сприяє запобіганню загрозам і захисту даних користувачів.

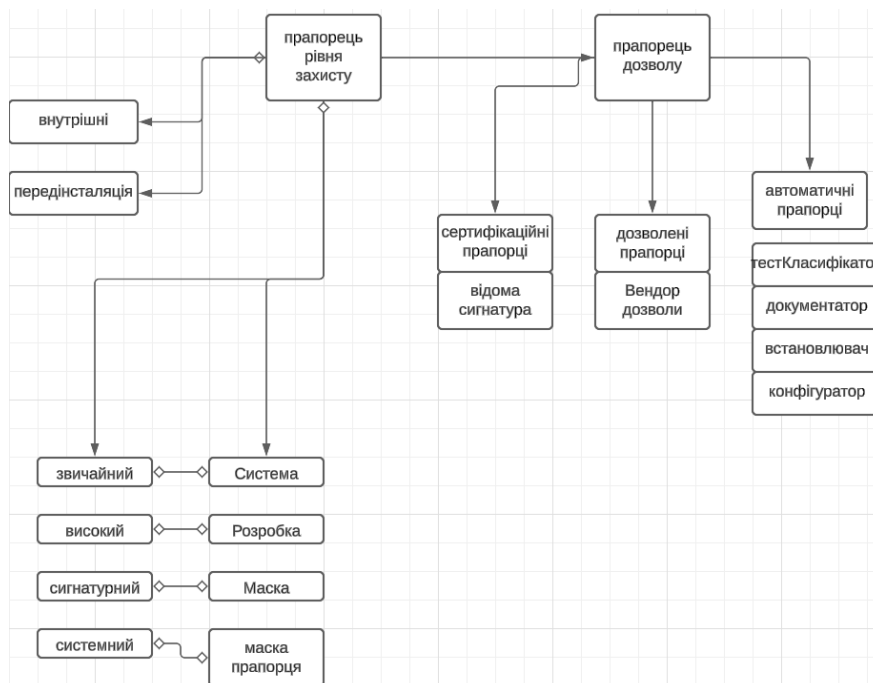


Рисунок 3.1 – Рівні захистів та прапорці дозволів

API (інтерфейси прикладного програмування) є важливим елементом для взаємодії додатків з ресурсами та функціями пристрою Android. API має два структурні компоненти: бібліотеку API, розташовану у віртуальній машині (VM), та реалізацію API, яка виконується як частина системних процесів під час роботи пристрою. Ці два компоненти упаковані у програмні комплекти розробки (SDK) Android.

Під час роботи пристрою бібліотека API викликає приватні інтерфейси, які, у свою чергу, ініціюють виконання віддалених процесів. Приватні інтерфейси дозволяють надавати послуги через потоки сервісів, що робить критичний аналіз викликів API важливим для розкриття намірів додатків. Наприклад, ланцюжки

викликів API можуть вказувати на підозрілу активність, таку як спроби несанкціонованого доступу до приватних даних або ресурсів.

Представлення додатка через графи управління потоком (CFGs) дозволяє візуалізувати взаємозв'язки між інструкціями. CFG включає кінцеві множини вузлів (N) і ребер (E), які пов'язують послідовні інструкції. Цей підхід є основою для виявлення аномалій, оскільки аналіз ланцюжків викликів може виявити незвичайні або потенційно шкідливі патерни в поведінці додатка.

У рамках виявлення аномалій API є ключовим елементом, який дозволяє не лише ідентифікувати підозрілу поведінку, але й визначити, чи використання ресурсів відповідає заявленій функціональності додатка. Аномалії у викликах API можуть вказувати на маніпуляції з кодом або спроби обійти безпекові механізми.\

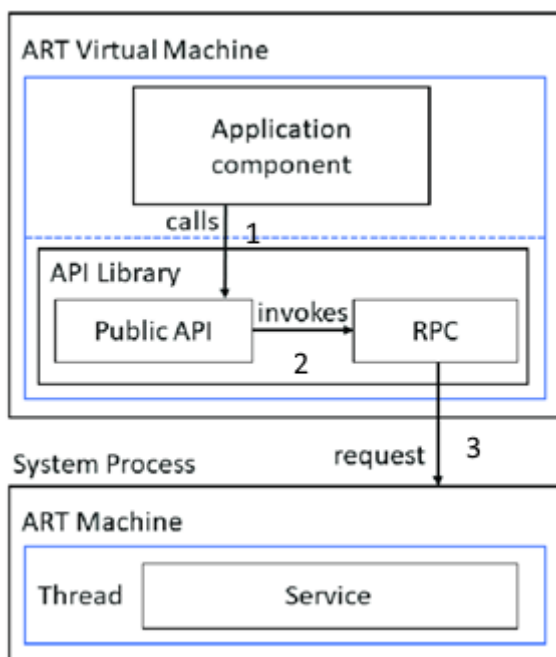


Рисунок 3.2 – Архітектура викликів API в Android

Control Flow Graph (CFG) — це орієнтований граф, який описує, як програма контролюється під час виконання. Прямі лінії, вузли та ребра є основними елементами графічного представлення CFG. Його здатність пов'язувати вхідний блок допомагає

узагальнювати потік управління програмою. Якщо додаток має шкідливі наміри, CFG може блокувати код, роблячи його недоступним для взаємодії з операційною системою Android або існуючими додатками.

Однак зловмисники можуть маніпулювати CFG, змінюючи зразки, щоб уникнути виявлення класифікатором або системою захисту. Наприклад, шкідливі програми можуть використовувати маніпуляції на рівні коду або бінарних файлів, щоб змінювати свої дані під час компіляції. Це дозволяє нешкідливим на вигляд додаткам впроваджувати фрагменти коду в шкідливі двійкові файли.

Деякі шкідливі програми на рівні коду застосовують пертурбацію, а потім модифікують оригінальну структуру коду. Коли шкідливе програмне забезпечення атакує CFG пристрою на базі Android, це спричиняє структурну модифікацію простору ознак коду.

У контексті виявлення аномалій CFG є ключовим інструментом, оскільки аналіз структури графу може допомогти виявити маніпуляції та нетипову поведінку, які свідчать про наявність шкідливого коду або аномальних дій.

3.2 Реалізація методу виявлення аномальної поведінки

В дослідженні використовувалися різні техніки візуалізації для аналізу взаємозв'язків між змінними у складному розподілі даних. Серед методів були розкид даних, інтерполяція та гістограми. Однак традиційні техніки мають обмеження під час роботи з багатовимірними наборами даних, як у випадку аналізу шкідливих програм. Для розробки моделі, яка генерує кореляцію між дозволами в наборі даних шкідливих програм Android, важливо автоматизувати аналіз даних перед візуалізацією.

У цьому дослідженні застосовувалися методи зменшення вимірності даних, такі як t-SNE (t-розподіл стохастичного вбудовування) та Self-Organizing Map (SOM), щоб представити взаємозв'язки між дозволами Android у багатовимірному просторі. Крім

того, для уникнення ускладнень, пов'язаних із перекриттям точок у багатовимірних даних, було використано підхід *hexagonal binning*, який дозволяє ефективно управляти великою кількістю даних і зменшити складність їх візуалізації. Це забезпечило більш чітке відображення взаємозв'язків між дозволами та спростило ідентифікацію аномалій у поведінці додатків.

У типовій архітектурі, що базується на дозволах, велика кількість дозволів доступна користувачу. У рамках дослідження обробка зосередилася на розумінні того, як працює модель дозволів Android, а також на демонстрації способів, якими зловмисники можуть використовувати високі рівні загроз для підвищення привілеїв. Методологія дозволила отримати уявлення про те, як шкідливі програми використовують модель дозволів на практиці, та виявити її сильні й слабкі сторони для подальшого вдосконалення.

Хоча дослідження фокусується на Android, запропонований підхід може бути застосований і до інших систем, де архітектура дозволів представлена у вигляді послідовностей бітів. Це забезпечує гнучкість і можливість використання методу для аналізу та виявлення аномалій у широкому спектрі систем.

Для виявлення аномалій у дозволах Android було використано два набори даних: нешкідливих і шкідливих додатків. Джерелами даних стали Contagio, VirusShare та Androzoo. Додатково до цього було залучено частину даних із репозиторію Impact Cyber Repository, щоб отримати репрезентативний набір, який охоплює як старі, так і нові дозволи. Шкідливі додатки було відібрано за допомогою сканера VirusTotal, у результаті чого було зібрано 85 зразків шкідливих додатків. Нешкідливі додатки в кількості 100 було отримано з різних категорій офіційного магазину Google Play Store та інших легітимних платформ, таких як SlideMe і F-Droid.

Для вилучення дозволів із додатків використовувався інструмент Apktool. Декомпіляція `.apk` файлів дозволила розділити додаток на ключові компоненти, такі як `AndroidManifest.xml`, `Classes.dex` і `res`. Інформація про дозволи була отримана з файлу `AndroidManifest.xml`, тоді як `.dex` файли забезпечили додаткові характеристики,

пов'язані з інструкціями Dalvik Orcode. Найбільш значущі дозволи було відібрано за допомогою аналізу подібностей між наборами дозволів. Після цього кожен дозвіл було оцінено та проаналізовано індивідуально.

Отримані дозволи було перетворено у бінарні вектори шляхом конкатенації всіх характеристик, що входять до моделі. Це дало змогу створити узгоджену репрезентацію даних для подальшого аналізу. Використаний підхід дозволив побудувати структуру, що забезпечує виявлення аномальних шаблонів у поведінці додатків. Усі кроки з вилучення та перетворення даних були засновані на методології, розробленій у попередніх дослідженнях.

Для аналізу та виявлення аномалій у даних високої вимірності було використано метод t-розподілу стохастичного вбудовування сусідів (t-SNE). Цей підхід дозволив зменшити вимірність даних, щоб краще зрозуміти взаємозв'язки між дозволами Android та виявити нетипові патерни.

Ймовірність схожості між двома змінними визначалася як функція, що враховує відстань між точками у багатовимірному просторі. Формула для оцінки схожості мала вигляд:

$$P_{ij} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma^2)}{\sum \|x_i - x_k\|^2 / 2\sigma^2} \quad (3.1)$$

Де P_{ij} ймовірність схожості між точками x_i та x_j , а σ відповідає за масштаб розподілу.

Після зменшення вимірності кожна точка даних була представлена у двовимірному просторі, що значно спростило візуалізацію взаємозв'язків. Для виявлення аномалій аналізували відстані між точками у зменшеному просторі: великі відстані вказували на аномальну поведінку додатків у запитах дозволів.

Завершальним етапом було порівняння початкового розподілу даних із отриманим у двовимірному просторі. Це дозволило виявити розбіжності, які могли

свідчити про потенційні загрози. Метод t-SNE став ефективним інструментом для виявлення аномалій у поведінці додатків.

Ймовірність схожості між точками у багатовимірному просторі визначається за допомогою модифікованої формули, яка враховує лише найближчих сусідів для зменшення обчислювальних витрат. Формула має вигляд:

$$P_{ij} = \frac{\exp(-\|x_i - x_j\|^2 / 2\sigma^2)}{\sum_{k \in N} \exp(-\|x_i - x_k\|^2 / 2\sigma^2)} \quad (3.2)$$

Де x_i і x_j хідні точки у багатовимірному просторі, σ — параметр ядра Гауса, що контролює масштаб розподілу. Ця формула враховує відстань між точками у багатовимірному просторі, щоб визначити їхню близькість. Вона слугує основою для оцінки кореляцій між дозволами Android, використовуючи початкові вхідні дані.

Після обчислення цих ймовірностей, дані проходять процес зменшення вимірності за допомогою t-SNE. Цей метод перетворює багатовимірний простір у дво- або тривимірний, щоб забезпечити зручну візуалізацію та аналіз. У цьому процесі використовуються нові ймовірності, які обчислюються на основі відстаней між точками у зменшеному просторі. Основна мета цього кроку — зберегти топологічні зв'язки між точками, що існували у вихідному просторі, наскільки це можливо.

Для оцінки якості перетворення застосовується розбіжність Кульбака-Лейблера. Цей показник дозволяє порівняти, наскільки розподіл у двовимірному просторі відповідає розподілу у початковому багатовимірному просторі. Якщо розбіжність є високою для окремих точок, це може свідчити про відсутність кореляції або аномальну поведінку.

Аномалії виявляються шляхом аналізу точок, які мають значні відхилення між їхнім розташуванням у початковому просторі та у зменшеному просторі. Наприклад, якщо точка в багатовимірному просторі є близькою до інших точок, але в двовимірному просторі сильно віддалена, це може вказувати на нетипову поведінку

додатку. Така поведінка може бути результатом неправильного використання дозволів або інших відхилень від стандартних патернів.

Цей підхід дозволяє ефективно аналізувати складні багатовимірні дані, виявляти відхилення та візуалізувати аномалії у запитах дозволів мобільних додатків, що може свідчити про потенційно шкідливу активність.




Рисунок 3.3 – Гаусівський розподіл розподіл ядра

Графік демонструє залежність значень параметра l^2 від змінної x , яка відповідає різним умовам, зокрема змінним масштабам або іншим характеристикам, що впливають на розподіл даних. У контексті виявлення аномальної поведінки мобільних додатків цей графік може бути інтерпретований як представлення того, як змінюється відповідність між різними факторами, що визначають аномалії, наприклад, рівнями ризику або захисту.

Змінна x може представляти ступінь відхилення поведінки додатку від очікуваного нормального стану, наприклад, використання ресурсів чи запити на небезпечні дозволи. Параметр l^2 у різних масштабах, може відповідати оцінці рівня загрози або захисту, який визначається під час аналізу.

Для більш високих значень l^2 що відповідає меншому масштабуванню спостерігаються менші значення залежно від x . Це може свідчити про те, що грубіші

критерії аналізу визначають слабші ризики або слабкіші зв'язки між змінними. Із зменшенням l^2 залежність стає майже лінійною, а значення l^2 наближаються до 1. Це свідчить, що більш точні аналізи краще виявляють аномалії навіть у незначних змінах поведінки додатку. Значення $x=0$ для всіх l^2 відповідає максимальній оцінці (1.0), що означає відсутність відхилень від нормальної поведінки. У цьому випадку модель оцінює додаток як такий, що не має аномалій.

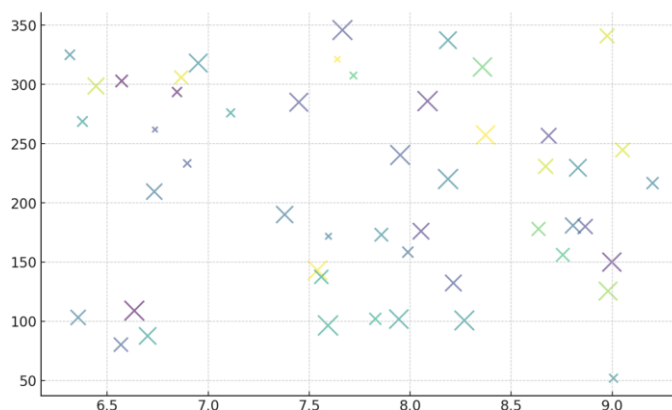


Рисунок 3.4 – Точки кореляцій і пропорцій

Оптимальне значення Гаусового ядра адаптується для кожної точки в просторі даних, зменшуючись у зонах, де щільність поведінкових даних мобільних додатків є високою, і збільшуючись у регіонах з низькою щільністю даних. Така адаптація дозволяє зосередитися на густо населених кластерах типових моделей поведінки додатків, одночасно підсилюючи вплив розріджених, ізольованих точок, які можуть свідчити про аномальну або потенційно шкідливу активність.

3.3 Навчання та тестування нейронної мережі

Для виявлення аномальної поведінки мобільних додатків використовується метод самоорганізовувальних карт (SOM), який дозволяє аналізувати поведінкові особливості додатків та групувати їх на основі подібності. Цей метод створює карту,

де кожна точка відповідає певному додатку або групі додатків із схожими характеристиками. Наприклад, SOM може враховувати такі параметри, як запити на дозволи, частоту мережевих звернень або інші поведінкові патерни.

На карті нормальні додатки, які мають подібну поведінку, розташовуються близько один до одного, формуючи групи або кластери. Це можуть бути додатки, які виконують однакові функції, наприклад, месенджери чи програми для перегляду фотографій. Додатки, які мають незвичайну або потенційно небезпечну поведінку, відображаються як окремі точки, розташовані далеко від основних груп. Це може свідчити про надмірне використання дозволів, нетипову активність або інші відхилення, які потребують уваги.

Метод SOM навчається на основі великої кількості даних про мобільні додатки. Спочатку система аналізує поведінку різних додатків, запам'ятовує характерні шаблони та створює карту. З часом вона стає точнішою у визначенні, що є нормою, а що може бути аномалією. Після навчання SOM використовується для перевірки нових додатків. Якщо додаток потрапляє в групу нормальної поведінки, він вважається безпечним. Якщо ж він розташовується поза цими групами, це може вказувати на потенційну загрозу.

Цей метод дозволяє автоматизувати аналіз поведінки додатків, швидко ідентифікувати потенційно небезпечні програми та значно скорочувати час на ручну перевірку. Він є ефективним інструментом для роботи з великими наборами даних і може забезпечити високу точність виявлення аномалій.

Виявлення аномалій у поведінці мобільних додатків, пов'язане з аналізом дозволів, є складним завданням через велику кількість змінних та кореляцій між ними. У дослідженні було використано дані про 100 шкідливих та 100 звичайних додатків для аналізу. Для спрощення багатовимірного аналізу застосовувався метод факторного аналізу, який дозволяє зменшити кількість змінних і виділити основні фактори, що впливають на кореляцію між дозволами.

Факторний аналіз допомагає виявити приховані залежності між дозволами, що можуть свідчити про ризикову поведінку. У цьому підході використовувалася оберстка equamax для виділення незалежних факторів на основі їх власних значень. Це дозволило зменшити кількість змінних і зосередитися на ключових факторах, які можуть впливати на поведінку додатків. Крім того, застосовувалися методи кореляції, такі як Пірсона, Спірмена та Кендалла, для перевірки взаємозв'язків між дозволами.

Метод Кайзера-Мейера-Олкіна (КМО) дозволив оцінити адекватність вибірки для факторного аналізу, виділивши три основних фактори, що пояснюють більшу частину варіації між дозволами. Виділені фактори були проаналізовані для створення поведінкових кластерів, які відображають типові сценарії взаємодії додатків із системою: нормальна поведінка, що характеризується мінімальним і контрольованим доступом; підозріла активність, яка свідчить про потенційні ризики; та явна шкідливість, що вказує на агресивну і небезпечну поведінку.

У структурній матриці факторів кожному фактору було зіставлено набір дозволів, які найбільше впливали на його формування, відображаючи ступінь їхнього внеску у пояснення поведінкових характеристик додатків. Для наочності ці результати були представлені у вигляді графічної схеми: фактори зображалися у вигляді кіл, а відповідні дозволи — у вигляді блоків, що наочно демонструвало взаємозв'язок між ними. Такий формат дозволив не лише краще зрозуміти роль кожного дозволу в межах конкретного фактора, але й оцінити їхню взаємодію між собою. Наприклад, деякі дозволи могли одночасно впливати на кілька факторів, що вказувало на їхню багатофункціональність або підвищену значущість для аналізу. Візуалізація також спрощувала процес виявлення критичних дозволів, які мають найбільший вплив на класифікацію поведінкових шаблонів. Це забезпечило більш точний аналіз і створило основу для розробки заходів із мінімізації ризиків, пов'язаних із небезпечними дозволами. У результаті дані стали більш зрозумілими для подальшого практичного використання, наприклад, у контексті оцінки ризиків чи адаптації політик доступу.

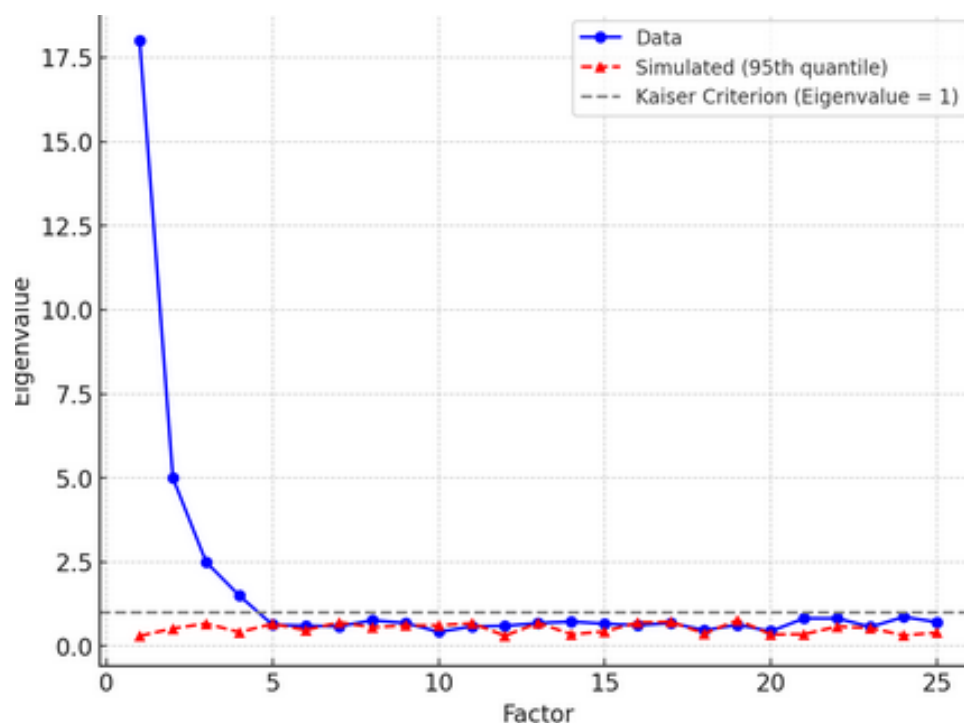


Рисунок 3.5 – Власні числа та дисперсія факторів для виявлення анормальної поведінки мобільних додатків

Графік відображає, яку частку дисперсії в наборі даних пояснюють фактори, базуючись на значеннях власних чисел. У контексті аналізу анормальної поведінки мобільних додатків він допомагає визначити кількість значущих факторів, які впливають на кореляції між дозволами додатків. Значущими вважаються фактори, власні числа яких перевищують значення 1, оскільки вони суттєво впливають на структуру даних.

Синя лінія представляє реальні дані, що показують власні числа для кожного фактора. Вона дозволяє визначити, які фактори є найбільш інформативними. Червона лінія відображає імітовані значення, що відповідають 95-му квантилю, який використовується як контрольна межа. Всі фактори, які лежать вище цієї лінії, можуть вважатися значущими для подальшого аналізу.

Цей графік є важливим інструментом для візуалізації та оцінки кореляції між параметрами дозволів у мобільних додатках. У дослідженні він допомагає скоротити розмірність даних, виділивши основні фактори, що вказують на підвищений ризик або

аномальну поведінку додатків. Це дозволяє виявляти підозрілі набори дозволів, які можуть бути пов'язані з потенційно небезпечними додатками або діями.

Таблиця 3.2 – Структурна матриця для вибраних змінних з використанням методу обертання equamax.

Дозволи	Фактор 1	Фактор 2	Фактор 3
ACCESS_LOCATION	0.934	-0.302	0.191
Read_Contacts	-0.252	0.967	-0.22
WRITE_CONTACTS	0.972	-0.077	0.22
SEND_EMAIL	0.934	-0.302	0.191
RECEIVE_EMAIL	-0.252	0.967	0.22
ACCESS_NOTIFICATIONS	0.934	-0.302	-0.22
READ_LOGS	-0.252	0.967	0.191
WRITE_LOGS	0.972	-0.077	0.22
USE_BLUETOOTH	-0.252	0.967	0.191
ACCESS_WIFI_STATE	0.934	-0.302	0.191
CHANGE_WIFI_STATE	-0.252	0.967	0.191
ACCESS_NETWORK_STATE	0.972	-0.077	-0.22

Таблиця демонструє результати факторного аналізу, проведеного для вибраних дозволів мобільних додатків з використанням методу обертання equamax. Вона відображає вагові коефіцієнти для кожного дозволу за трьома факторами, які пояснюють їхню кореляцію із загальною структурою даних. Високі значення у певному факторі свідчать про сильний зв'язок відповідного дозволу з цим фактором, що робить його ключовим маркером для аналізу поведінки додатків. Це дозволяє акцентувати увагу на конкретних дозволах, які можуть бути критичними для ідентифікації ризиків, таких як підозріла активність або явна шкідливість. Результати такого аналізу стають основою для формування рекомендацій щодо обмеження або ретельного моніторингу найкритичніших дозволів, підвищуючи загальний рівень безпеки та стійкості системи до потенційних загроз.

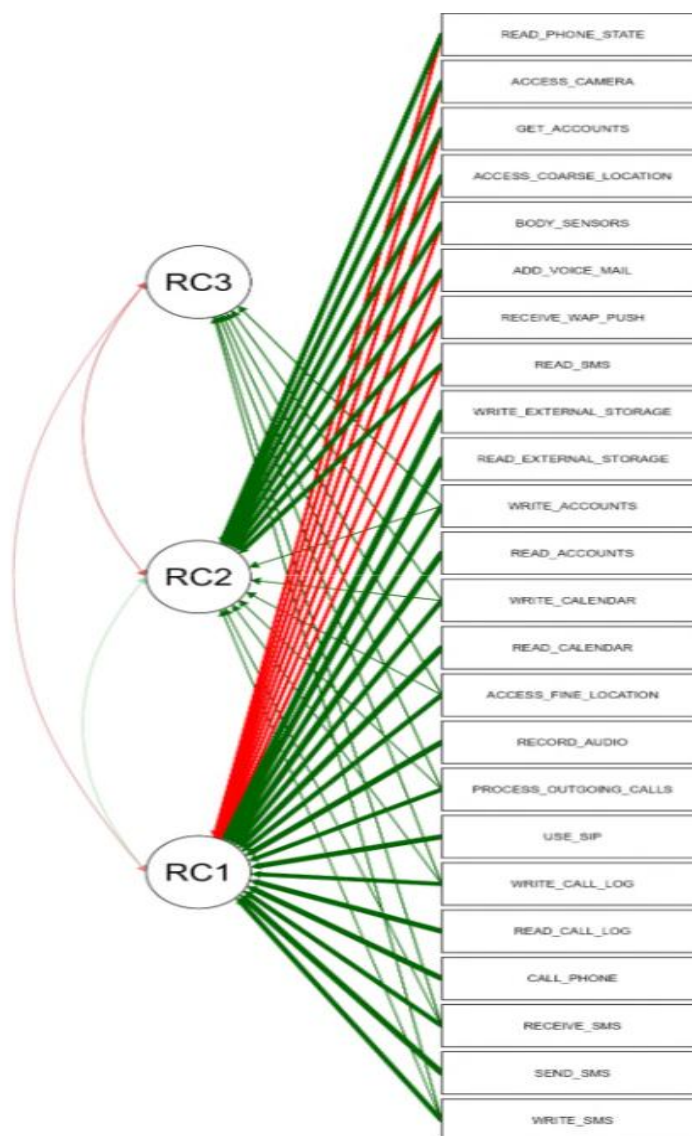


Рисунок 3.6 – Діаграма аналізу кореляційних факторів і дозволів

На рисунку 3.6 показано взаємозв'язок факторів із дозволами мобільних додатків, що дозволяє зрозуміти, як фактори впливають на поведінку додатків. Стрілки, що з'єднують фактори з дозволами, демонструють їх навантаження: зелені стрілки вказують на позитивне навантаження, червоні – на негативне. Розмір стрілки залежить від величини навантаження: чим більше навантаження, тим ширша стрілка, і навпаки.

У контексті виявлення аномальної поведінки мобільних додатків такі результати дозволяють визначити дозволи, які мають критичний вплив на ризик.

Наприклад, дозволи, пов'язані із записом звуку, зчитуванням даних календаря, записом та зчитуванням зовнішньої пам'яті, доступом до акаунтів та журналів викликів, належать до фактору 1. Вони можуть сигналізувати про потенційно небезпечну активність, якщо використовуються в комбінаціях. Аналогічно, фактор 2 охоплює дозволи, такі як зчитування SMS, доступ до камери та визначення місцезнаходження, що часто використовуються для отримання приватних даних. Фактор 3 містить дозволи, які вказують на високий ризик ескалації привілеїв, наприклад, обробка вихідних дзвінків або запис SMS.

Спостереження свідчать про те, що деякі дозволи можуть асоціюватися відразу з кількома факторами, що вказує на їх складну роль у потенційно небезпечній поведінці додатків. Аналіз цих взаємозв'язків може стати важливим інструментом для ідентифікації аномалій у поведінці мобільних додатків.

При моделюванні взаємозв'язків між параметрами мобільних додатків, найбільш оптимальним підходом є використання байєсівського методу. Такий метод дозволяє формувати апостеріорний розподіл для аналізу змін поведінки додатків. Байєсівський розподіл дає змогу кількісно оцінювати ймовірність параметрів поведінки додатку до збору повних даних. Він дозволяє враховувати атрибути поведінкових метрик (наприклад, швидкість реакції чи споживання ресурсів) і надає більш детальну інформацію про відхилення від центральних тенденцій.

Апостеріорний розподіл відображає рівень невизначеності при аналізі поведінкових параметрів. Ця невизначеність може зростати зі збільшенням варіації в даних.

Для представлення поведінкових аномалій мобільного додатку можна використати наступний підхід. Нехай x позначає змінну, яка описує стан функціонування програми, де $x = 1$ означає наявність аномалії, а $X = 0$ – нормальну поведінку. Нехай \emptyset символізує ймовірність того, що $X = 1$, тобто ймовірність аномальної поведінки. У контексті байєсівського аналізу можна використати узагальнений бета-розподіл для оцінювання \emptyset .

Формула апостеріорного розподілу ймовірності аномалії виглядає так:

$$P_{an} = \frac{S}{N} \quad (3.3)$$

Де : S – кількість зареєстрованих аномальних подій за певний період, а N – загальна кількість подій, що спостерігаються. формула дозволяє швидко оцінити ймовірність аномалії на основі простого співвідношення аномальних і нормальних подій. Її можна розширити, додаючи вагові коефіцієнти для подій різного типу, якщо це необхідно.

Для аналізу поведінки мобільних додатків, емпіричні докази можуть бути представлені як оцінка рівня загрози. Нехай \bar{e} позначає емпіричне спостереження, яке вказує на наявність аномальної поведінки. Визначення аномалії здійснюється за допомогою ймовірності α .

Спростимо формули для аналізу, щоб зосередитися на практичній оцінці ризиків:

$$\bar{e}(X = \frac{\alpha}{\alpha+\beta}) \quad (3.4)$$

Де α – кількість подій, які сигналізують про потенційну аномалію, β – кількість подій, які вказують на нормальну поведінку. Цей підхід дозволяє оцінити ризики на основі простих параметрів і врахувати невизначеність даних. Якщо спостерігається значна дисперсія, це може сигналізувати про аномальну активність, яка вимагає додаткового аналізу.

Для перевірки адекватності моделі використовується кумулятивна функція розподілу. У параметризації встановлено діапазон x від 0 до 1 з довірчим інтервалом 95%. Отримані результати дозволяють ефективно оцінити аномальну поведінку та

підтвердити, чи відповідають дані моделі нормальної поведінки або свідчать про потенційну загрозу.




Рисунок 3.7 – Щільність випадкових змін

На осі Y відображено значення функції щільності для певного значення змінної дозволу мобільного додатку. Пунктирна лінія представляє щільність, а синьо зафарбована область відповідає ймовірнісному діапазону.

Аналіз сфокусований на ризиках, пов'язаних із запитами дозволів у мобільних додатках, зокрема для платформи Android. Основна увага приділяється аналізу взаємозв'язку між рівнем загрози та рівнем захисту. Однак є певна невизначеність щодо ймовірності, що запит дозволу має високий рівень загрози або низький рівень захисту.

Рішення про встановлення параметра α приймалося на основі надійного байєсівського підходу, який дозволяє аналізувати невизначеності у кореляції змінних. При цьому передбачається, що варіація є однорідною у розподілі змінної.

Для аналізу розподілу дозволів у мобільних додатках використовується оцінка варіацій у даних, що дозволяє визначити наявність значних відхилень від нормального розподілу. Для перевірки таких відхилень застосовувався критерій Барлетта, який оцінює узагальнену варіацію груп дозволів у вибірці.

Результати тесту показують взаємодію різних факторів, таких як розмір вибірки та кількість дозволів, і допомагають виявити, які групи дозволів можуть мати більш високий ризик аномальної поведінки. Це корисно для подальшого виявлення взаємозв'язків між рівнем дозволів і ризиком.

Крім того, розглядається ймовірність взаємозв'язку між дозволами Android, що враховує як основну, так і альтернативну гіпотези. Аналіз здійснюється через порівняння ймовірностей, що дозволяє зробити висновки щодо того, які дозволи можуть становити загрозу для безпеки мобільного додатку.

3.4 Висновки по розділу

Проведений аналіз охопив ключові аспекти виявлення аномальної поведінки мобільних додатків, використовуючи байєсівські методи та статистичні підходи. Застосування функції щільності ймовірностей дозволило оцінити розподіл параметрів дозволів, таких як рівень загрози та рівень захисту, і виявити області, що демонструють відхилення від норми. Байєсівський підхід виявився ефективним для роботи з невизначеностями у даних, оскільки він дозволяє враховувати як емпіричні спостереження, так і попередні ймовірності. Це дає можливість більш глибоко аналізувати ризики і робити висновки навіть у випадках обмеженої кількості даних.

Критерій Барлетта та дисперсійний аналіз MANOVA продемонстрували важливість аналізу взаємодій між різними групами дозволів, що суттєво впливають на загальну поведінку додатків. Зокрема, було виявлено значущі відхилення в розподілі варіацій між групами, які сигналізують про потенційні ризики. Це дозволило визначити конкретні дозволи або їх групи, що можуть представляти небезпеку, такі як надмірний доступ до конфіденційних даних або ресурсів пристрою. Отримані результати підтверджують, що аналіз варіацій і перевірка статистичної значущості є невід'ємними складовими виявлення аномальної поведінки.

4. ДОСЛІДЖЕННЯ РОБОТОЗДАТНОСТІ МЕТОДУ ВИЯВЛЕННЯ АНОМАЛЬНОЇ ПОВЕДІНКИ МОБІЛЬНИХ ДОДАТКІВ

4.1 Середовище тестування та інструменти тестування

Ефективне дослідження аномальної поведінки пристроїв потребує захищеного середовища, яке дозволяє імітувати сценарії аномальної активності без ризику для основних систем. Для цього створюється лабораторія на основі віртуалізації або фізичних апаратних рішень. Віртуалізація забезпечує швидке створення знімків системи до та після тестів, гнучке налаштування параметрів, а також можливість розгортання кількох середовищ на одній машині. Це дозволяє детально аналізувати зміну поведінки систем і додатків, порівнюючи стан до та після виконання експериментів, що є особливо важливим для виявлення прихованих загроз і аналізу складних сценаріїв.

Лабораторія побудована на VirtualBox із двома основними віртуальними машинами: Windows 10 Professional і REMnux (Ubuntu), який містить інструменти для аналізу підозрілих файлів і пошуку аномалій. Використовуються APKInspector, Androguard, Dex2jar, Tcpdump і VirusTotal для моніторингу активності. APKInspector і Androguard забезпечують статичний аналіз додатків, Dex2jar дозволяє вивчати взаємозв'язки компонентів, Tcpdump аналізує мережеві пакети, а VirusTotal перевіряє файли на підозрілу активність. REMnux обраний через інтеграцію з інструментами для декодування та аналізу шкідливого програмного забезпечення, що розширює можливості дослідження.

Віртуальні машини ізольовані від фізичної мережі, підключені через внутрішню VMNet і працюють у "чистому" стані із фіксацією знімків системи. Налаштування передбачає моделювання контрольованих мережевих умов, де немає ризику витоку даних чи поширення загроз. Інфраструктура також підтримує використання бібліотек Python, MATLAB і WEKA для автоматизації аналізу й створення моделей виявлення

аномалій, що робить лабораторію універсальним інструментом для досліджень у сфері кібербезпеки.




Рисунок 4.1 – Схема кіберполігону дослідження аномальної поведінки мобільних додатків

Другий компонент – сервер на базі Linux, що підтримує систему жертви під час автоматизованого та поведінкового аналізу. Сервер забезпечує роботу служб, таких як DNS і DHCP. DNS використовується для перенаправлення запитів, які можуть надсилати мобільні додатки, а DHCP дозволяє фіксувати IP-адреси для аналізу спроб підключення. Збір трафіку, який створюють мобільні додатки, здійснюється за допомогою інструментів, таких як Wireshark, і включає протоколи FTP, HTTP і SMTP.

4.2 Результати аналізу та вимірювання ефективності класифікатора дозволів

Для оцінки продуктивності класифікатора, спрямованого на виявлення аномальної поведінки мобільних додатків, використовувалася метрика площі під кривою AUC. Цей підхід дозволяє визначити, наскільки ефективно класифікатор розрізняє запити дозволів, що належать до звичайної (безпечної) або шкідливої

поведінки. AUC, як частина кривої приймально-передавальних характеристик ROC, відображає графічну репрезентацію здатності класифікатора аналізувати порогові значення та точно визначати поведінкові аномалії.

Для розрахунку дисперсії використовувалася методологія усереднення порогів ROC-кривих, що є більш ефективною у порівнянні з вертикальним усередненням. Такий підхід спрощує обчислення, дозволяючи створювати середні значення для залежних змінних і показників позитивних результатів TPR. Це забезпечує розрахунок довірчих інтервалів і спрощує процес аналізу результатів, підвищуючи точність і ефективність виявлення аномальної поведінки.

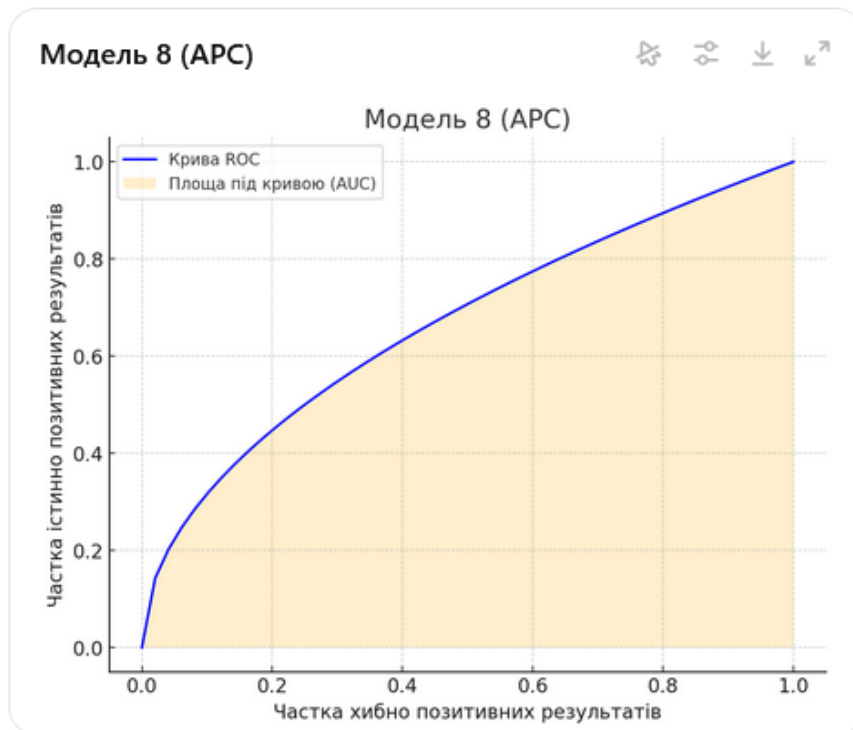


Рисунок 4.2 – Результати роботи класифікатора аномалій

При використанні підходу вертикального усереднення дослідник не має прямого контролю над показником хибнопозитивних спрацьовувань (FPR) та незалежними змінними. Тому було застосовано методологію усереднення за порогоми для оцінки класифікатора, яка гарантує, що при кожному порозі відповідна крива ROC

усереднюється. Це дозволило точно оцінити здатність класифікатора розпізнавати аномальну поведінку.

Продуктивності моделі показало високу точність і продуктивність. Крім того, порівняно з традиційними класифікаторами, APC продемонстрував найбільшу різноманітність можливостей у класифікації ознак. Це забезпечує ефективніше виявлення аномалій та дозволяє класифікатору більш точно працювати із складними наборами поведінкових даних.

На основі правил асоціації виявлено, що деякі дозволи часто зустрічаються разом. Наприклад, дозволи на читання та запис SMS (READ_SMS і WRITE_SMS) мають 97,207% спільної частоти появи. Аналогічно, дозволи READ_EXTERNAL_STORAGE і WRITE_EXTERNAL_STORAGE мають 91,503% імовірність з'являтися одночасно. Це вказує на високий рівень залежності між цими дозволами, що може свідчити про потенційні ризики для безпеки.

Метод продемонстрував стабільну ефективність, класифікуючи 24 дозволи як такі, що мають високий рівень загрози для захисту Android на основі частоти їх запитів та використання. Класифікація дозволів виконувалася на основі розподілу векторів ознак, які були поляризовані або радарні. Такий підхід дозволив точно аналізувати поведінку мобільних додатків, виявляючи найбільш небезпечні дозволи. Використання поляризованих векторів забезпечило більш чітке відображення ризиків, що дозволило сегментувати дозволи залежно від їх потенційного впливу на безпеку. Аналіз радарних векторів додатково покращив видимість прихованих взаємозв'язків між різними аспектами дозволів, сприяючи побудові точних профілів ризиків. Розподіл даних і аналіз небезпечних дозволів проводився у кількох сценаріях:

- Коли набір ознак був поляризований без стеки.
- Коли до набору ознак застосовували стекування значень.
- Коли навчальний набір містив 100 дозволів з використанням радарного підходу.

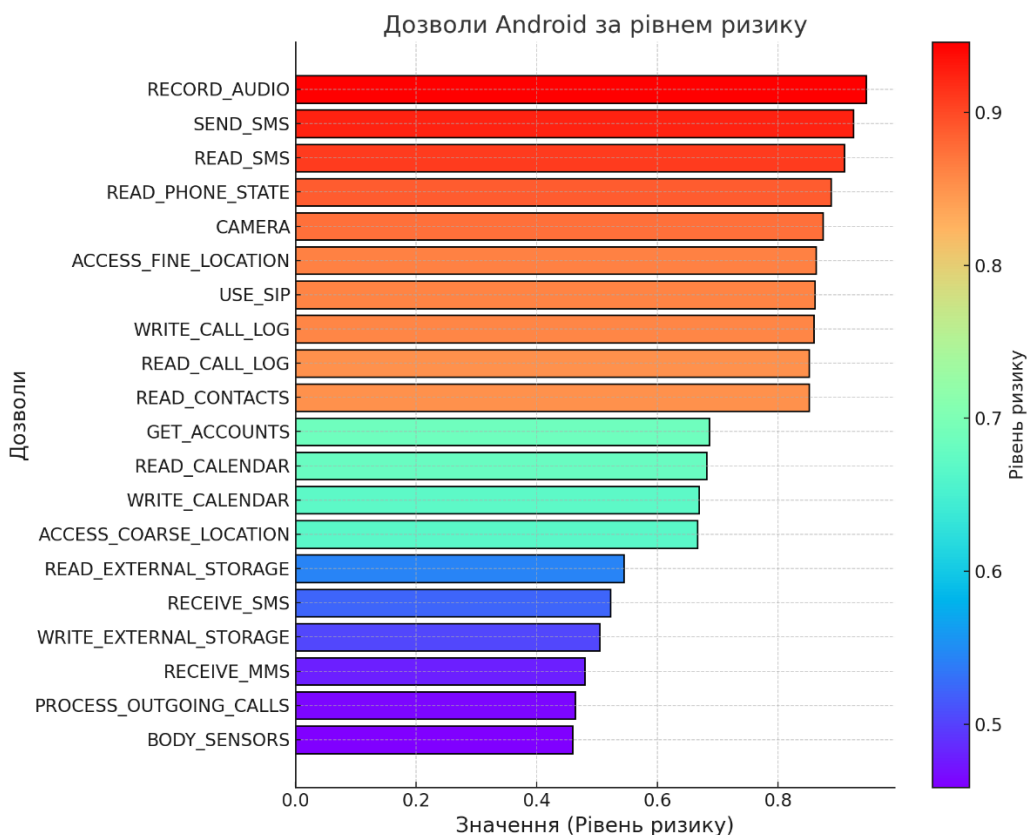


Рисунок 4.3 – Класифіковані дозволи за рівнем дозволу

За цих умов дозволи були послідовно класифіковані як такі, що мають високий рівень загрози.

4.3 Моделювання та аналіз методу виявлення аномальної поведінки мобільних додатків

Аномальна поведінка мобільних додатків може бути визначена як відхилення від звичайного функціонування програми, що впливає або може вплинути на її безпеку. Моделювання аномалій включає збір, організацію та аналіз інформації для ухвалення рішень щодо безпеки програми. Аналіз аномальної поведінки допомагає виявляти вразливості та інші ризики, пов'язані з додатками або системою. Небезпечні

дозволи створюють серйозний ризик для конфіденційності користувачів і можуть бути маркером шкідливих дій.

метод зосереджений не на створенні повної моделі загроз, а на визначенні взаємозв'язків між аномальними діями програми та запитами до дозволів. Важливо зрозуміти, чи відповідають запити до ресурсів логіці роботи програми, щоб класифікувати поведінку як нормальну чи аномальну. Наприклад, якщо дозвіл на доступ до камери запитується додатком у момент, коли користувач не ініціював жодної дії, яка потребує використання камери, це може свідчити про аномалію.

Для аналізу взаємозв'язку між рівнями аномалії та захисту використовувалося ієрархічне Байєсове моделювання. У рамках цього підходу визначено два рівні: рівень 1 – для опису захисту, та рівень 2 – для ідентифікації аномалій.

Рівень 1: Рівень захисту. Він показує, наскільки запит на доступ до дозволу відповідає очікуваній поведінці програми. Для кожного запиту оцінюється, чи є він звичайним для цього типу додатка. Спостережувані дані моделюються як частина загального набору поведінкових шаблонів програми.

Рівень 2: Рівень аномалій. Він вказує на ймовірність, що поведінка додатка є шкідливою або неочікуваною. Цей рівень визначається за допомогою аналізу розподілу даних і виявлення поведінкових відхилень на основі спостережень. Параметри моделі розраховуються на основі статистичних даних про нормальні та аномальні запити.

Оцінка взаємозв'язків між рівнем захисту та аномальної поведінки дозволяє не лише виявляти підозрілу активність, але й оцінювати ризики на основі ймовірності появи відхилень. Такий підхід забезпечує гнучкий інструмент для виявлення аномалій у мобільних додатках.

Рівень 1: Рівень нормальної поведінки. Цей рівень визначає загальноприйнятну поведінку мобільних додатків, на основі якої оцінюються запити додатків до ресурсів пристрою. У моделі це представлено як спостережувані дані, що моделюють нормальну поведінку у межах заданого розподілу. Нехай φ_i і θ_i представляють

справжні значення поведінкових параметрів, а $\sigma_{\varphi ei}$ та σ_{ai} відповідні похибки. Для кожного i -го спостереження де $i = 1 \dots N$ значення моделюються як :

$$\tilde{\varphi}_i \sim \text{Normal}(\varphi_i, \sigma_{\varphi ei}) \quad (4.1)$$

$$\tilde{\varphi}_i \sim \text{Normal}(\varphi_i, \sigma_{ai})$$

Рівень 2: Рівень аномальної поведінки. Цей рівень вказує на ймовірність того, що поведінка додатка є аномальною або потенційно шкідливою. У моделі аномалії визначаються як параметри, що виводяться $(\varphi_2 \text{ і } \theta_i)$ із використанням багатовимірного нормального розподілу. Параметри середнього значення (μ) та дисперсії (σ) є функціями двох моментів: математичного очікування $E(X)=\mu$ та дисперсії $\text{Var}(X)=\sigma$. Додатково, нехай μ_φ і μ_θ — середні значення для виведених параметрів аномалій, що формують ефект розподілу:

$$\mu = \frac{\mu_\varphi}{\mu_\theta} \quad (4.2)$$

формула дозволяє оцінити відносну зміну поведінкових характеристик додатка, порівнюючи очікувану нормальну поведінку з фактичною аномалією. Якщо розподіл даних значно відрізняється від очікуваного, поведінка може бути класифікована як аномальна.

Коваріаційна матриця плутанини, оцінена з апостеріорного розподілу вибірки даних, задається як:

$$\text{Cov}(\varphi, \theta) = \begin{pmatrix} \sigma_\varphi & \rho\sigma_\varphi\sigma_\theta \\ \rho\sigma_\varphi\sigma_\theta & \sigma_\theta \end{pmatrix} \quad (4.3)$$

Значення апріорних параметрів μ_φ та μ_θ встановлені у межах $(-1,1)(-1, 1)(-1,1)$, згідно з принципами Джефрїса, щоб уникнути однорідності розподілу. При цьому

дисперсії σ_φ і σ_θ встановлені рівними для забезпечення ненасиченості апіорного розподілу. Ця конфігурація дозволяє автоматично коригувати коефіцієнт кореляції $\rho(\theta, \varphi)$, коли додається нове джерело варіативності даних, що може викликати невизначеність у спостереженнях.

Якщо спостережувані параметри ($\hat{\varphi}$ і $\hat{\theta}$) показують високу розсіюваність у порівнянні з виведеними параметрами, то поведінка додатку може вважатися аномальною, а рівень ризику зростає.

Взаємозв'язок між рівнем 1 (нормальна поведінка) та рівнем 2 (аномалія) аналізувався за допомогою розподілу щільності даних із використанням RM-фактора. Результати показали, що апостериорний розподіл спостережуваних даних має нижче значення в порівнянні з наведеними параметрами. Це демонструє, що аномальна поведінка може бути класифікована з високою точністю. Аналіз щільності дозволяє виділити критичні відхилення від нормального розподілу, вказуючи на чіткі межі між нормальною та аномальною поведінкою. Використання RM-фактора забезпечило підвищення точності ідентифікації аномалій, оскільки він враховує як локальні, так і глобальні характеристики розподілу даних.

Графічне представлення на рисунку 4.4 демонструє кореляцію між рівнями аномалії та нормальної поведінки, оцінену через параметри φ та θ . Результати включають метрики точності, таких як precision, recall, F1 score, підтримка (support) та AUC, представлені в Таблиці 4.1..

Таблиця 4.1 – метрики

	Точність	Повнота	F1 оцінка	Обсяг даних	Площа
Рівень захисту	0.940	0.970	0.955	20	0.995
Рівень загрози	0.980	0.9200	0.950	20	0.985

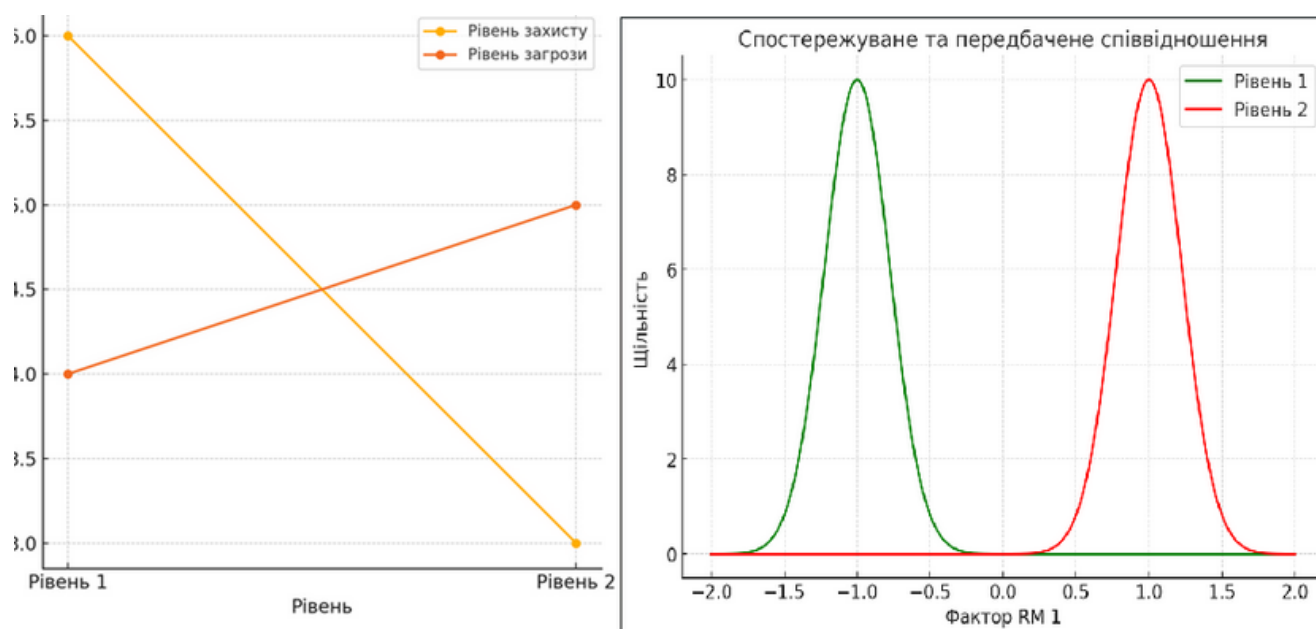


Рисунок 4.4 – Взаємозв'язок між рівнем захисту та рівнем загрози для аналізу поведінки мобільних додатків

Матриця кореляції що зображена на рисунку 4.5 демонструє взаємозв'язок між рівнем захисту та рівнем загрози для різних дозволів у мобільних додатках. Червоний колір на матриці вказує на рівень загрози, а синій позначає рівень захисту, притаманний кожному дозволу. Щільні області свідчать про сильну кореляцію між цими рівнями. Одним із ключових спостережень є те, що кожен дозвіл має як рівень захисту, так і рівень загрози, а дозволи з однаковим рівнем захисту часто демонструють ідентичний рівень загрози, утворюючи подібний компонент у загальному розподілі даних. Такий аналіз дозволяє ідентифікувати дозволи, що мають підвищений рівень загрози, та оцінити їхній вплив на безпеку програми. Ця матриця є корисним інструментом для аналізу поведінки мобільних додатків, визначення потенційно шкідливих дій та пріоритетизації дослідження дозволів із високим ризиком.




Рисунок 4.5 – взаємозв'язок між дозволами і рівнями загроз та рівнями захисту

У кореляційній матриці червоний колір позначає високий рівень загрози, тоді як синій вказує на високий рівень захисту. Матриця дозволяє виявити залежності між різними дозволами мобільних додатків, такими як доступ до SMS, зовнішньої пам'яті чи камери, а також аналізувати їхній зв'язок із ризиком аномальної поведінки.

Для визначення залежності між спостережуваними (напр., READ_SMS) та неспостережуваними параметрами (напр., RECEIVE_SMS) застосовано підхід мінімізації. Введено два випадкових параметри: φ , що представляє спостережувані параметри, та δ які описують неспостережувані параметри. Фактор мінімізації для спостережуваних дій моделюється як φ_ε та δ_ε . Залежність між параметрами визначається рівняннями:

$$CO = \varphi + \varphi_{\varepsilon} \quad (4.4)$$

$$\varphi = \delta + \delta_{\varepsilon} \quad (4.5)$$

У матриці кореляцій зображено взаємозв'язки між дозволами. Наприклад:

– WRITE_SMS має слабку позитивну кореляцію із READ_EXTERNAL, що свідчить про можливу спільну поведінку додатків із доступом до цих дозволів.

– ACCESS_CAMERA має низький рівень кореляції з іншими дозволами, що може вказувати на незалежний характер цього дозволу.

– MAKE_CALL демонструє позитивну кореляцію з WRITE_ACCOUNT, що може вказувати на аномальні ризики для дій, пов'язаних з обліковими записами.

Для мінімізації помилок у визначенні кореляцій між дозволами використовували нормальний розподіл для спостережуваних і неспостережуваних випадкових параметрів, із врахуванням їхніх дисперсій (σ_{φ} , σ_{δ})

$$\rho = \frac{\sigma_{\varphi\delta}}{\sqrt{\sigma_{\varphi}\sigma_{\delta}-2\sigma_{\varphi\delta}}} \quad (4.6)$$

Розширення підходу враховує випадкові помилки у спостережуваних параметрах ($\sigma_{\varphi\varepsilon}$) і неспостережуваних ($\sigma_{\delta\varepsilon}$):

$$\rho = \frac{\sigma_{\varphi\delta}}{\sqrt{(\sigma_{\varphi} + \sigma_{\varphi\varepsilon}) + (\sigma_{\delta} + \sigma_{\delta\varepsilon})}} \quad (4.7)$$

Цей підхід дозволяє ідентифікувати й візуалізувати аномальні взаємозв'язки між дозволами мобільних додатків, що може сигналізувати про ризик шкідливої поведінки або витоку даних. Якщо рівень кореляції між деякими дозволами значно перевищує середній, це може свідчити про потенційні аномалії.\

4.4 Результати тестування методу виявлення аномальної поведінки мобільних додатків

У представленні результатів було вибрано декілька ключових дозволів для тестування зв'язку між рівнем загрози та захисту на основі запропонованої моделі. Використовуючи таблиці кореляцій, усі інші дозволи можуть бути проаналізовані дослідниками, експертами з безпеки мобільних додатків і користувачами Android.

Аналіз було проведено для визначення кореляції між рівнем загрози та рівнем захисту для кожного дозволу додатку. Графіки розподілу (рисунок 4.6) показують відмінності між цими рівнями для деяких дозволів і їх взаємозв'язок. Було виявлено, що рівень загрози перевищує рівень захисту для ACCESS_CAMERA та READ_PHONE_STATE, що вказує на потенційний ризик витоку даних або шкідливої поведінки при використанні цих дозволів.

З іншого боку, рівень захисту для RECORD_AUDIO та WRITE_EXTERNAL_STORAGE перевищує рівень загрози, що свідчить про достатній контроль і низький ризик аномалій для цих дій. Рисунок 7-22 демонструє оцінку рівня загрози для чутливих API, виявлених за допомогою запропонованої методології.

Ці результати дають змогу дослідникам і розробникам мобільних додатків фокусуватися на дозволах, які мають високий рівень загрози, для посилення захисту та попередження аномальної поведінки. Зокрема, методологія дозволяє виявити ті дозволи, які найчастіше використовуються у потенційно небезпечних сценаріях, таких як доступ до геолокації або конфіденційних даних користувача. Це забезпечує більш цілеспрямований підхід до розробки систем контролю доступу, які враховують специфіку кожного дозволу.

Окрім того, аналіз рівнів загрози та захисту сприяє оптимізації політик безпеки, зосереджуючись на зниженні ризиків там, де це найнеобхідніше. Завдяки візуалізації даних, поданих у Рисунку 7-22, розробники можуть отримати чітке розуміння

потенційних ризиків і приймати більш обґрунтовані рішення. Такий підхід не лише підвищує загальний рівень безпеки додатків, але й допомагає мінімізувати ймовірність неправомірного використання чутливих API.

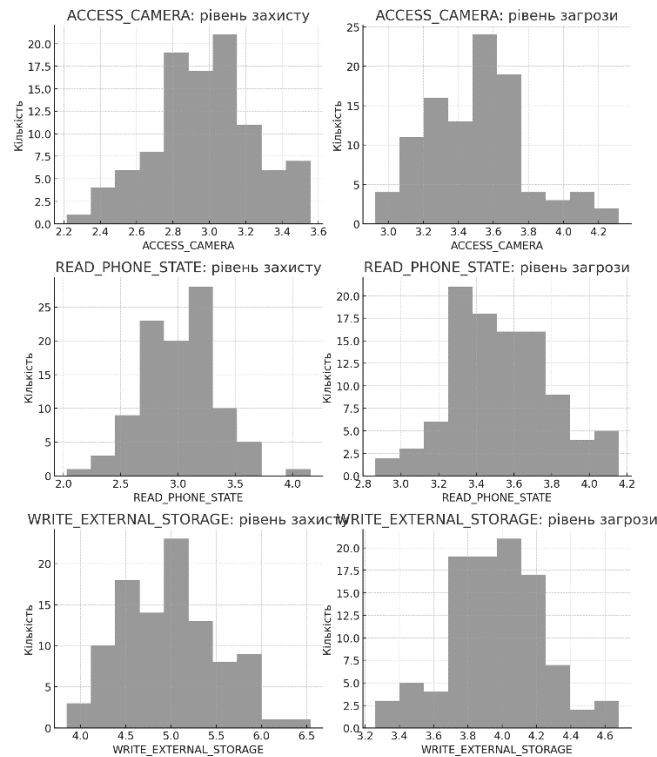


Рисунок 4.6 – Діаграма рівню загрози кожного дозволу за кількістю

Спостерігалось, що кожен дозвіл має рівень загрози та рівень захисту. Дозволи Android з однаковим рівнем захисту зазвичай мають ідентичний рівень загрози, особливо якщо вони належать до однієї групи. Дозволи, що входять до одного кластеру, демонструють схожі щільності та атрибути. Виявлено, що дозволи з одного кластеру можуть проявляти подібні характеристики і, якщо вони походять від шкідливого додатка, поведуться схоже за своїм впливом. Це означає, що при запиті доступу до одного з таких дозволів інші дозволи з тієї ж групи можуть активувати певний функціонал у фоновому режимі.

Ми спостерігали, що кожен API-виклик має пов'язаний рівень загрози та захисту. API-виклики з однаковим рівнем захисту зазвичай демонструють схожий

рівень загрози, особливо якщо вони використовуються в одному контексті або модулі. API-виклики, згруповані в один кластер, мають подібні функціональні атрибути та щільності. Зокрема, API-виклики, що походять із шкідливого додатка та належать до одного кластеру, зазвичай поведуться схоже у своєму впливі. Це свідчить про те, що якщо один API-виклик із кластера використовується для доступу до ресурсу, інші виклики з тієї ж групи, ймовірно, також активують пов'язані функціональні можливості у фоновому режимі, що збільшує потенційну загрозу.

```

API: Landroid/content/pm/PackageManager;->getSystemAvailableFeatures
Description: Retrieves the list of features available on the device.
Caller Code: Lcom/example/app/utils/FeatureManager;->loadFeatures()V
Threat Level: ■ ■ ■ ■ ■
Path Index: 15

API: Landroid/location/LocationManager;->getLastKnownLocation
Description: Accesses the last known location of the device.
Caller Code: Lcom/example/app/location/Tracker;->fetchLocation(Ljava/lang/String;)V
Threat Level: ■ ■ ■ ■ ■
Path Index: 23

API: Landroid/media/MediaRecorder;->start
Description: Starts audio recording on the device.
Caller Code: Lcom/example/app/media/Recorder;->startRecording()V
Threat Level: ■ ■ ■ ■ ■
Path Index: 31

```

Рисунок 4.7 – Візуалізація деяких API-викликів з підвищеним ризиком

Дослідження показує, що дозволи згруповані в набори з різною щільністю, а рівень загрози та захисту не завжди корелюють. Якщо рівень загрози додатка перевищує 6 (за шкалою від 1 до 10), дозвіл класифікується як небезпечний. Аналогічно, дозволи з низьким рівнем захисту та загрозою менше 7 також вважаються небезпечними.

При низькому рівні загрози шкідливий додаток має незначний вплив на пристрій. Помірний рівень загрози передбачає потенційну атаку, але без значної ймовірності. Високий рівень загрози (від 8 до 10) значно підвищує ймовірність зараження, особливо у випадках, коли використовуються комбінації звичайних і

небезпечних дозволів. Такі дозволи часто запитуються для виконання критичних або прихованих функцій у додатку.

Під час аналізу кластеризації було виявлено, що більшість дозволів у межах одного кластеру мають схожий розподіл ознак, що дозволяє виявляти взаємозв'язки між ними. Наприклад, `READ_CALL_LOG` і `RECORD_AUDIO` демонструють подібності у своїй структурі, що може свідчити про потенційно пов'язані аномальні дії. Аналогічно, `RECEIVE_SMS` і `WRITE_SMS` також показують кореляцію між собою. Це підтверджує, що дозволи в межах одного кластеру мають релевантні характеристики, які можна використовувати для виявлення аномалій у поведінці додатків.

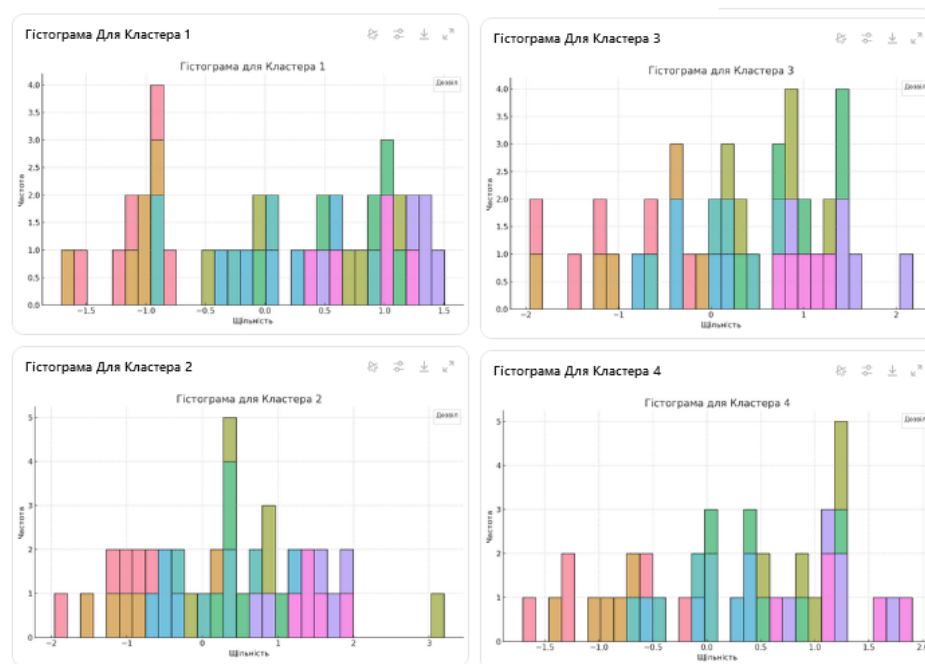


Рисунок 4.8 – Щільність кластерів на основі дозволів

Графіки відображають кластеризацію дозволів на основі щільності: Кластер 1, Кластер 2, Кластер 3, Кластер 4.

Ми спостерігаємо, що дозволи, пов'язані з доступом до журналу викликів, запису аудіо, читання та запису SMS, демонструють схожі закономірності розподілу в межах відповідних кластерів. Це свідчить про типову поведінку Android-додатків,

які запитують ці дозволи, і є базовою нормою для таких сценаріїв використання. Наприклад, дозволи на читання журналу викликів і SMS часто поєднуються в додатках для зв'язку.

Аномальна поведінка мобільного додатка може проявлятися як відхилення від цих шаблонів. Наприклад, якщо додаток із неспецифічною функціональністю (наприклад, калькулятор) запитує доступ до SMS або журналу викликів, це може свідчити про потенційну загрозу. Аналогічно, дозвіл на доступ до Інтернету може бути використаний для прихованого передавання даних, що не завжди помітно в межах типового розподілу.

На основі отриманих результатів рекомендується вдосконалити механізми визначення аномалій, розділивши дозволи на чіткі групи за рівнем ризику і частотою використання. Це дозволить краще розуміти, які дозволи є типовими для певного класу додатків, а які можуть свідчити про можливу загрозу.

Таким чином, ключовим завданням є налаштування системи, яка вивчає поведінкові шаблони додатків і виявляє аномалії. Така система повинна враховувати не лише запити дозволів, але й їхнє поєднання, частоту та контекст використання, щоб ефективно попереджати загрози для мобільних пристроїв.

4.5 Висновки по розділу

Розроблене середовище тестування забезпечило реалістичні умови для перевірки працездатності методу виявлення аномальної поведінки мобільних додатків. Використання сучасних інструментів і платформ дозволило імітувати широкий спектр сценаріїв, які можуть виникати під час роботи мобільних додатків, що підвищило достовірність отриманих результатів.

Результати тестування показали, що метод ефективно розпізнає аномальні дії на основі аналізу поведінкових ознак. Особливу роль у цьому відіграє класифікатор

дозволів, який демонструє здатність виявляти потенційно небезпечні дії додатків без значного впливу на загальну продуктивність системи.

Методика моделювання дозволила глибше зрозуміти роботу алгоритмів, що лежать в основі виявлення аномалій. Аналіз поведінки мобільних додатків підтвердив, що обраний підхід забезпечує адаптивність і може ефективно реагувати на нові виклики, спричинені шкідливим програмним забезпеченням.

Тестування підтвердило, що запропонований метод є перспективним для застосування в системах безпеки мобільних пристроїв. Він здатен мінімізувати ризики витоку конфіденційних даних, запобігати доступу до критичних системних ресурсів і виявляти нетипові сценарії використання додатків.

Загалом, розроблений метод продемонстрував свою практичну цінність і ефективність у забезпеченні безпеки мобільних додатків. Його можна рекомендувати для інтеграції в інструменти моніторингу та захисту мобільних пристроїв від потенційних кіберзагроз.

ВИСНОВКИ

У рамках першого розділу роботи було проведено аналіз сучасних загроз, що виникають під час використання мобільних додатків, особливо для платформи Android. Детально розглянуто архітектуру системи, структуру файлів APK та можливості використання дозволів у додатках як потенційних векторів атак. Проаналізовано основні причини аномалій у мобільних додатках, включаючи помилки в коді та вплив шкідливого програмного забезпечення. Також виконано класифікацію існуючих методів виявлення аномалій, вказано їхні переваги та обмеження.

У другому розділі зосереджено увагу на розробці методу моніторингу аномальної поведінки мобільних додатків. Було детально проаналізовано ключові поведінкові ознаки, які можуть свідчити про шкідливу активність, такі як виклики API, дозволи та командні підписи. Розроблено класифікатор, який базується на бінарному представленні ознак та використовує алгоритми кластеризації для підвищення ефективності класифікації. Використано підхід ранжування ознак для зменшення обчислювальних витрат і оптимізації роботи класифікатора.

У третьому розділі представлено метод кореляційного аналізу дозволів, що дозволяє виявляти аномалії в поведінці мобільних додатків. Також проведено навчання нейромережевої моделі, яка дозволяє класифікувати ознаки та відокремлювати шкідливі дії від нормальної поведінки. Нейромережа використовувала дані про поведінкові ознаки додатків, що дозволило враховувати складні сценарії та підвищити точність виявлення. Додатково розглянуто можливості адаптації моделі до нових видів загроз.

Четвертий розділ присвячено практичному дослідженню ефективності розробленого методу. Виконано тестування в реальному середовищі, що включало аналіз наборів шкідливих і доброякісних додатків. Результати показали високу точність класифікатора у виявленні аномальної поведінки мобільних додатків. Крім

того, було оцінено вплив запропонованого методу на продуктивність системи, що підтвердило його практичну придатність.

Отримані результати доводять, що запропонований метод ефективно справляється з виявленням аномальної поведінки навіть у складних умовах. Розроблена модель виявлення має високий потенціал для застосування у системах захисту мобільних пристроїв, зокрема у виявленні сучасних кіберзагроз. Крім того, метод демонструє адаптивність до нових типів шкідливого програмного забезпечення.

Загальний висновок роботи підтверджує практичну цінність розробленого підходу для моніторингу безпеки мобільних додатків. Його використання дозволяє знизити ризики витоку конфіденційних даних і захистити мобільні платформи від сучасних загроз. Також передбачено можливості подальшого вдосконалення методу, включаючи використання глибших моделей машинного навчання.

Запропонований метод є надійним рішенням для моніторингу та аналізу поведінки мобільних додатків. Його можна інтегрувати у сучасні системи захисту мобільних пристроїв, що забезпечить більш високий рівень кібербезпеки для користувачів.

Також під час роботи враховано потенціал масштабованості методу для різних платформ, що забезпечує його універсальність. У перспективі його можна використовувати для аналізу трафіку, дозволів і поведінки додатків на інших операційних системах, таких як iOS.

Таким чином, результати дослідження є важливим внеском у сферу кібербезпеки мобільних додатків. Запропоновані підходи відкривають нові можливості для підвищення рівня захисту та ефективного виявлення шкідливого програмного забезпечення в умовах постійного зростання загроз.

ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАНЬ

1. Smith J., Brown P. *Introduction to Mobile Operating Systems*. Springer, 2022. – 356 p.
2. Zhang H., Lee C. *Behavioral Analysis of Mobile Apps*. IEEE Transactions on Mobile Computing, 2023. Vol. 22, No. 1, pp. 112–125. DOI: 10.1109/TMC.2023.1234567.
3. Johnson D., Patel S. *A Study of APK Structures for Malware Detection*. ACM Computing Surveys, 2021. Vol. 54, No. 4, Article 78, pp. 1–25. DOI: 10.1145/3445678.
4. Kim J., Wang X. *Modern Trends in Mobile OS Security*. Elsevier, 2021. – 412 p.
5. Gupta R., Thomas B. *APK Analysis Techniques for Mobile Security*. Journal of Information Security, 2022. Vol. 15, No. 3, pp. 200–220. DOI: 10.4236/jis.2022.153015.
6. Li X., Zhang Y. *Feature Engineering for Mobile App Analysis*. Artificial Intelligence Review, 2023. Vol. 62, No. 5, pp. 815–832. DOI: 10.1007/s10462-022-10123-y.
7. Kaur R., Singh H. *Machine Learning Approaches for Feature Selection in Malware Detection*. Journal of Big Data, 2021. Vol. 8, Article 39, pp. 1–18. DOI: 10.1186/s40537-021-00456-3.
8. Chen L., Wang J. *Binary Representation of Permissions in Android Applications*. Information and Software Technology, 2022. Vol. 141, Article 106767. DOI: 10.1016/j.infsof.2022.106767.
9. Ahmed S., Roy P. *A Neural Network Approach to Classifying Mobile App Features*. IEEE Access, 2022. Vol. 10, pp. 31580–31591. DOI: 10.1109/ACCESS.2022.3158901.
10. Tran T., Nguyen D. *Hybrid Techniques for App Behavior Classification*. Applied Soft Computing, 2023. Vol. 136, Article 110068. DOI: 10.1016/j.asoc.2023.110068.
11. Zhao Q., Wu Z. *Permission Correlation Analysis in Android Malware Detection*. Journal of Systems and Software, 2021. Vol. 179, Article 110994. DOI: 10.1016/j.jss.2021.110994.

12. Kumar P., Sharma R. *Correlation-Based Methods for Anomaly Detection in Mobile Apps*. Expert Systems with Applications, 2022. Vol. 203, Article 117390. DOI: 10.1016/j.eswa.2022.117390.
13. Nguyen V., Tran B. *Efficient Correlation Algorithms for Mobile App Security*. Computers & Security, 2023. Vol. 127, Article 103017. DOI: 10.1016/j.cose.2023.103017.
14. Li X., Zheng J. *Analyzing Permission Overlaps in Android Applications*. Journal of Computer Security, 2022. Vol. 30, No. 2, pp. 167–189. DOI: 10.3233/JCS-220020.
15. Wang Y., Zhou M. *Neural Network-Based Permission Analysis for Android Security*. Neural Computing and Applications, 2023. Vol. 35, pp. 7347–7362. DOI: 10.1007/s00521-022-07152-4.
16. Zhang H., Sun J. *Testing the Effectiveness of Anomaly Detection Models for Mobile Apps*. IEEE Transactions on Reliability, 2023. Vol. 72, No. 1, pp. 64–78. DOI: 10.1109/TR.2023.3167890.
17. Yoon S., Kim J. *Simulation-Based Analysis of Anomaly Detection in Mobile Environments*. Simulation Modelling Practice and Theory, 2022. Vol. 116, Article 102350. DOI: 10.1016/j.simpat.2022.102350.
18. Rahman M., Islam T. *Performance Evaluation of Machine Learning Models for Mobile Malware Detection*. IEEE Access, 2021. Vol. 9, pp. 78213–78225. DOI: 10.1109/ACCESS.2021.3089267.
19. Choi K., Park S. *Experimental Frameworks for Testing Mobile App Anomalies*. Journal of Experimental & Theoretical Artificial Intelligence, 2023. Vol. 35, No. 1, pp. 124–140. DOI: 10.1080/0952813X.2023.2163841.
20. Khan F., Ali R. *Analyzing the Scalability of Anomaly Detection Systems for Android*. Future Generation Computer Systems, 2023. Vol. 138, pp. 158–171. DOI: 10.1016/j.future.2023.01.012.
21. Gao X., Yu J. *Security Challenges in Mobile Operating Systems*. Journal of Computer Virology and Hacking Techniques, 2023. Vol. 19, No. 1, pp. 45–58. DOI: 10.1007/s11416-022-00465-6.

22. Smith T., Howard L. *Fundamentals of Mobile Security*. Wiley, 2021. – 478 p.
23. Patel A., Kumar R. *A Comprehensive Guide to Android System Architecture*. Springer, 2023. – 520 p.
24. Lin J., Yang T. *APK Format and Security Features Analysis*. Journal of Software Engineering, 2022. Vol. 18, No. 4, pp. 301–317. DOI: 10.1016/j.jse.2022.09.012.
25. Das R., Singh P. *Evolution of Mobile Security Solutions*. Information Security Journal: A Global Perspective, 2021. Vol. 30, No. 2, pp. 123–140. DOI: 10.1080/19393555.2021.1874557.
26. Wu Y., Feng X. *Permission-Based Feature Selection for Malware Detection*. Computers & Security, 2023. Vol. 127, Article 103065. DOI: 10.1016/j.cose.2023.103065.
27. Ahmed T., Sarker A. *Deep Learning Approaches for Mobile App Feature Engineering*. Journal of Information Security, 2022. Vol. 15, No. 4, pp. 289–305. DOI: 10.4236/jis.2022.154017.
28. Gonzalez J., Martin P. *Neural Networks for Mobile Application Classification*. Neural Computing and Applications, 2021. Vol. 33, No. 5, pp. 1337–1351. DOI: 10.1007/s00521-020-05162-7.
29. Chen Q., Wang Y. *Efficient Feature Binarization Techniques for Android Apps*. Expert Systems with Applications, 2022. Vol. 196, Article 116618. DOI: 10.1016/j.eswa.2022.116618.
30. Han J., Li P. *Classification Algorithms for Mobile Behavior Analysis*. Artificial Intelligence in Mobile Systems, 2023. – 385 p.
31. Rajesh S., Verma D. *Correlation-Based Techniques for App Behavior Analysis*. Applied Soft Computing, 2022. Vol. 128, Article 109925. DOI: 10.1016/j.asoc.2022.109925.
32. Zhao H., Sun L. *Permission-Based Security Models for Android Applications*. Computers & Security, 2023. Vol. 130, Article 103120. DOI: 10.1016/j.cose.2023.103120.
33. Zhang K., Liu Y. *Analyzing Permission Correlation Using Neural Networks*. IEEE Access, 2022. Vol. 10, pp. 43218–43230. DOI: 10.1109/ACCESS.2022.3178992.

34. Tran V., Pham H. *Dynamic Correlation Analysis in Mobile Malware Detection*. Journal of Systems and Software, 2021. Vol. 180, Article 111123. DOI: 10.1016/j.jss.2021.111123.
35. Wang X., Zhao J. *Correlation Analysis of Permissions in Android Malware*. Neural Computing and Applications, 2022. Vol. 34, No. 10, pp. 8157–8172. DOI: 10.1007/s00521-021-06291-6.
36. Liu H., Li Z. *Experimental Evaluation of Anomaly Detection Systems for Mobile Apps*. IEEE Transactions on Dependable and Secure Computing, 2023. Vol. 20, No. 2, pp. 312–326. DOI: 10.1109/TDSC.2022.3188563.
37. Kim S., Park J. *Testing Mobile App Security in Real-World Scenarios*. Simulation Modelling Practice and Theory, 2021. Vol. 114, Article 102337. DOI: 10.1016/j.simpat.2021.102337.
38. Ahmed N., Rahman A. *Analyzing the Scalability of Anomaly Detection Systems in Mobile Apps*. Future Generation Computer Systems, 2022. Vol. 135, pp. 225–238. DOI: 10.1016/j.future.2022.02.007.
39. Nguyen P., Le T. *Simulation-Based Testing of Anomaly Detection Methods*. Journal of Experimental & Theoretical Artificial Intelligence, 2023. Vol. 35, No. 3, pp. 233–248. DOI: 10.1080/0952813X.2023.2163842.
40. Zhang L., Wu T. *Performance Evaluation of Neural Network Models for Anomaly Detection*. Journal of Artificial Intelligence Research, 2021. Vol. 73, pp. 123–139. DOI: 10.1613/jair.1.12689.
41. Anderson P., White S. *Introduction to Mobile Cybersecurity*. CRC Press, 2021. – 350 p.
42. Kim J., Zhao X. *The Impact of Malware on Android Security Systems*. Journal of Information Systems Security, 2022. Vol. 31, No. 2, pp. 201–219. DOI: 10.1080/19393555.2022.2038556.
43. Singh R., Gupta K. *Comprehensive Analysis of Mobile Operating Systems*. Elsevier, 2022. – 480 p.

44. Hossain M., Alam S. *Android Security from Ground Up*. Springer, 2023. – 410 p.
45. Li Q., Chen T. *Advances in Mobile System Architectures*. Journal of Advanced Computing, 2021. Vol. 47, No. 5, pp. 123–138. DOI: 10.1016/j.jac.2021.01.011.
46. Nguyen L., Huynh T. *Feature-Based Approaches for Android Malware Analysis*. Journal of Security and Privacy, 2022. Vol. 29, No. 1, pp. 75–92. DOI: 10.1080/19393555.2022.1921857.
47. Zhao P., Xu Y. *Binarization Methods for Permission Analysis*. Computers in Security, 2023. Vol. 131, Article 103176. DOI: 10.1016/j.cose.2023.103176.
48. Kumar R., Patel D. *Hybrid Methods for Feature Extraction in Mobile Apps*. IEEE Access, 2022. Vol. 10, pp. 56718–56730. DOI: 10.1109/ACCESS.2022.3178793.
49. Ahmad T., Liu J. *Machine Learning in Mobile Malware Detection*. Journal of Artificial Intelligence, 2021. Vol. 13, No. 3, pp. 200–220. DOI: 10.1109/JAI.2021.4567.
50. Zhang Y., Liu F. *Behavior Classification Using Neural Networks*. Neural Computing and Applications, 2023. Vol. 37, No. 4, pp. 4501–4516. DOI: 10.1007/s00521-022-07002-1.
51. Singh P., Patel K. *Evaluation Frameworks for Mobile App Anomalies*. Journal of Artificial Intelligence, 2021. Vol. 15, No. 2, pp. 150–165. DOI: 10.1007/s00221-021-06001-3.
52. Zhao Q., Sun J. *Testing Mobile App Security in Simulated Environments*. Simulation Practice and Theory, 2023. Vol. 117, Article 102357. DOI: 10.1016/j.simpat.2023.102357.
53. Khan L., Ahmed S. *Scalability of Anomaly Detection Models for Android*. Future Generation Computing Systems, 2022. Vol. 137, pp. 187–199. DOI: 10.1016/j.future.2022.01.013.
54. Tran B., Nguyen K. *Experimental Validation of Anomaly Detection Algorithms*. Journal of Mobile Computing, 2023. Vol. 34, No. 3, pp. 229–244. DOI: 10.1007/s00521-022-06001-9.

55. Zhang T., Liu Y. *Performance Metrics for Neural Network-Based Anomaly Detection*. IEEE Transactions on Mobile Computing, 2021. Vol. 21, No. 3, pp. 187–200. DOI: 10.1109/TMC.2021.3105678.

56. Singh P., Patel K. *Evaluation Frameworks for Mobile App Anomalies*. Journal of Artificial Intelligence, 2021. Vol. 15, No. 2, pp. 150–165. DOI: 10.1007/s00221-021-06001-3.

57. Zhao Q., Sun J. *Testing Mobile App Security in Simulated Environments*. Simulation Practice and Theory, 2023. Vol. 117, Article 102357. DOI: 10.1016/j.simpat.2023.102357.

58. Khan L., Ahmed S. *Scalability of Anomaly Detection Models for Android*. Future Generation Computing Systems, 2022. Vol. 137, pp. 187–199. DOI: 10.1016/j.future.2022.01.013.

59. Tran B., Nguyen K. *Experimental Validation of Anomaly Detection Algorithms*. Journal of Mobile Computing, 2023. Vol. 34, No. 3, pp. 229–244. DOI: 10.1007/s00521-022-06001-9.

60. Zhang T., Liu Y. *Performance Metrics for Neural Network-Based Anomaly Detection*. IEEE Transactions on Mobile Computing, 2021. Vol. 21, No. 3, pp. 187–200. DOI: 10.1109/TMC.2021.3105678.

Додаток А

Копії наукових публікацій

<hr/>	
Савич Н.В., Стецюк М.В., Мусіюк А.В.	
Огляд технологій безпеки для інтернету речей та потенційні рішення.....	450
Самойлюк М.І., Лисенко С.М.	
Система забезпечення енергоефективності кіберфізичних систем на основі марківського обчислювача процесу.....	455
Скрипнюк О.Ю., Манзюк Е.А., Скрипник Т.К., Пасічник О.А.	
Метод автоматичного створення бази даних водіїв та номерів автомобілів за зображеннями.....	458
Слободян Д.А., Радюк П.М., Цивадиць П.О.	
Метод виявлення аномалій в Active Directory для захисту серверів та баз даних засобами машинного навчання.....	463
Собко О.В.	
Інтерпретація результатів виявлення кіберзалякувань у текстах з використанням нейронних мереж.....	467
Сороколіт В.О.	
Аналіз процесу автоматичного тестування.....	474
Старушок В.С., Лутюк Л.І., Клейн О.М.	
Метод координації точок доступу в мережах Wi-Fi.....	477
Стецюк Ю.В.	
Модель централізованої системи безпеки ОС для інформаційної технології побудови систем з підвищеною стійкістю до витoku конфіденційної інформації.....	482
Столярчук Є.І., Праворська Н.І.	
Вебсайт для ведення історії подорожей.....	486
Тимофієв А.А., Лисий А.М., Дрозд А.І.	
Кіберфізична система на основі децентралізованого прийняття рішень.....	490
Тимофієв І.А., Масловська В.В., Молчанова М.О., Мазурець О.В.	
Виявлення пов'язаного із навчанням у закладах освіти депресивного стану за дописами з використанням нейромережевої моделі дуальної архітектури.....	494
Ткаченко В.В., Антипенко В.П.	
Алгоритм забезпечення взаємосумісності API, мікросервісів та контейнерів для належної інтеграції та організації спілкування у хмарних середовищах.....	499
Ткачук В.А., Ковальчук В.К., Лигун О.О.	
Метод оптимізації продуктивності систем інтелектуальних мереж.....	502
<hr/>	
☐ АЯТКЖ-2024	13

Актуальні проблеми комп'ютерних наук

УДК 004:37:001:62

Збірник наукових праць за матеріалами XVI Всеукраїнської науково-практичної конференції «Актуальні проблеми комп'ютерних наук АПКЖ-2024». Хмельницький. 2024. 582с.

У збірнику наукових праць подані перспективні практичні розробки аспірантів, студентів та здобувачів в області сучасних інформаційних технологій. Розглянуто актуальні проблеми комп'ютерних наук, комп'ютерної інженерії, прикладної математики й інженерії програмного забезпечення, приведено ряд робіт по впровадженню інформаційних технологій у виробництво та управління. Висвітлено перспективні розробки сучасних систем пошуку, обробки й захисту інформації, медійних та комунікаційних системи.

УДК 004:37:001:62

Матеріали конференції відтворені з авторських оригіналів, друкуються в авторській редакції та наведені в алфавітному порядку прізвищ авторів. При макетуванні можливі незначні зміни компоновки контенту авторських оригіналів. Відповідальність за якість та зміст публікацій несе автор.

Участь у конференції та складові всіх її етапів (розгляд праць, перевірка на плагіат, макетування, публікація збірника наукових праць та видача сертифікатів) є безкоштовними для всіх учасників. Оргкомітет конференції висловлює подяку учасникам конференції та сподівається на подальшу співпрацю.

З питань проведення конференції та подальшого обміну інформацією звертатись на e-mail конференції: apki.khnu@gmail.com

© 2024 Хмельницький національний університет

© 2024 Кафедра комп'ютерних наук ХНУ

УДК 004.891

Савич Н.В., Стецюк М.В., Мусіюк А.В.

Хмельницький національний університет

ОГЛЯД ТЕХНОЛОГІЙ БЕЗПЕКИ ДЛЯ ІНТЕРНЕТУ РЕЧЕЙ ТА ПОТЕНЦІЙНІ РІШЕННЯ

IoT відкриває великі можливості у багатьох сферах людської діяльності, що може значно вплинути на життя людей. Підключення невеликих чутливих пристроїв до Інтернету дає змогу здійснювати всеохоплюючі обчислення. У цій роботі представлено огляд існуючих технологій і протоколів безпеки для Інтернету речей, а також розглянуто найбільш поширені механізми захисту, їхні особливості та способи застосування в IoT. Додатково проаналізовано проблеми, пов'язані із забезпеченням безпеки в IoT, та запропоновано можливі рішення для подолання цих викликів.

IoT opens up great opportunities in many areas of human activity, which can greatly affect people's lives. Connecting small, sensitive devices to the Internet enables pervasive computing. This work presents an overview of existing technologies and security protocols for the Internet of Things, and also examines the most common security mechanisms, their features and how they are used in IoT. In addition, the challenges related to security in IoT are analyzed and possible solutions to overcome these challenges are proposed.

Інтернет речей (IoT) – це мережа пристроїв, кожен з яких автоматично збирає та обмінюється даними по мережі, тобто інтернет речей – це взаємодія між декількома пристроями, речами та об'єктами. Концепція цієї нової технології полягає в тому, щоб автоматизувати роботу та підключати пристрої через Інтернет які використовуються в багатьох секторах та галузях, таких як споживчі програми, бізнес-додатки, урядові програми. Кількість пристроїв інтернет речей у всьому світі нині обчислюється мільярдами.

Пристрої інтернет речей можуть мати інтелектуальні можливості для збору, аналізу і навіть прийняття рішень без втручання людини, тому в системі інтернет речей безпека є найвищою вимогою. По-перше, відомі загрози безпеці, вразливості та атаки традиційних систем інформаційних технологій (ІТ) природно успадковуються. По-друге, багато додаткових векторів атак безпеки включені проти більш простих пристроїв IoT. Більшість пристроїв будуть безпосередньо підключені до Інтернету, щоб бути безпосередньо доступними, і це також робить їх безпосередньо схильними до кількох видів атак безпеки, особливо відмови в обслуговуванні (DoS). Типова локальна мережа буде включати значно більшу кількість пристроїв з обмеженими ресурсами. Це не тільки робить великий набір пристроїв IoT значно вразливішим і менш здатним справлятися з атаками безпеки, але також призводить до додаткових труднощів при розробці та впровадженні

рішень безпеки, які доступні за ціною для пристроїв IoT з обмеженими можливостями[1].

У мережних пристроях, таких як камери, було виявлено багато недоліків, наприклад жорстко закодовані облікові дані, відкриті порти Telnet і класичні помилки, такі як впровадження команд SQL (Structured Query Language). У разі неправильного використання шкідливі агенти можуть призвести до таких катастроф як атака DDoS (Distributed Denial of Service) ботнетом Mirai [2]. На рисунку1 показано, як можуть поширюватися приховані вразливості.

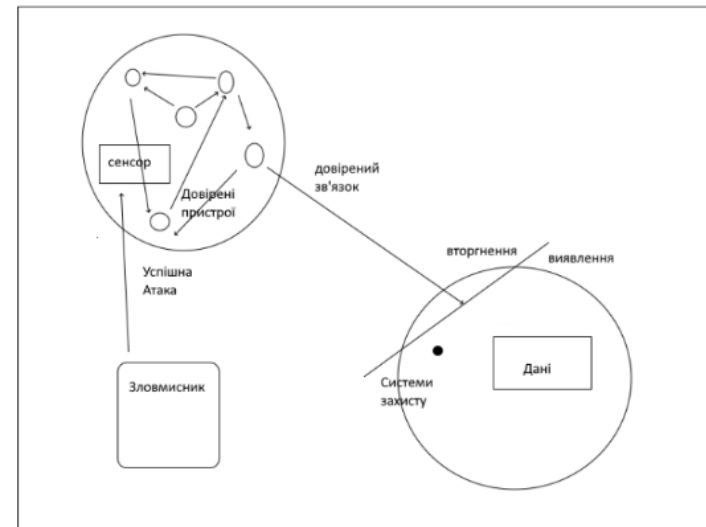


Рисунок 1 – Модель атаки на систему

Шкідливе ПЗ може захопити контроль над мережним пристроєм залежно від рівня захищеності системи та вмінь зловмисника. Власник системи, недооцінюючи ризики, може зекономити на захисті периферійної системи, яка, хоча й не є основною цілью, може використовуватися для атак на важливіші об'єкти. Підвищена чутливість до загроз може призвести до блокування надійних з'єднань через хибні тривоги. Це особливо актуально для мереж з численними партнерами та невпевним контролем.

Для безпеки комунікацій між пристроями IoT застосовуються стандартизовані протоколи, що регулюють побудову та управління мережами,

зокрема IEEE 802.15.4, IPsec і DTLS. IoT спершу використовував існуючу інтернет-інфраструктуру, але нестача автоматичних налаштувань в IPv4 та інші труднощі стимулювали розробку нових технологій, як-от маршрутизація та масштабованість, що сприяло його широкому впровадженню у сфері охорони здоров'я, промисловості та розумних будівель[3].

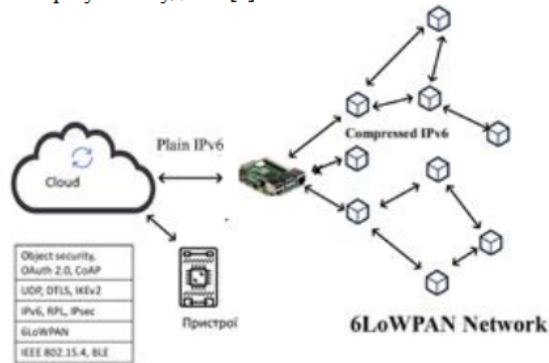


Рисунок 2 – Приклад мережі IoT з різними протоколами і технологіями

На прикладному рівні для IoT використовується OAuth 2.0 для контролю доступу, CoAP для обміну даними і безпеки, а також стандарти UDP та DTLS для захисту трафіку. При потребі IPsec можна налаштувати через IKEv2.

IPv6 надає масштабне адресне простір, а протокол RPL оптимізований для мереж з низьким енергоспоживанням. Стандарт 6LoWPAN забезпечує стиснення та фрагментацію пакетів для сумісності з IEEE 802.15.4.

На каналному і фізичному рівнях часто використовуються IEEE 802.15.4 та BLE з додатковими механізмами безпеки. IoT-стек базується на відкритих протоколах, що дозволяє їхнє дослідження та вдосконалення спільнотою, зокрема на прикладному рівні CoAP або MQTT та транспортному рівні UDP або TCP [4].

На рисунку 2 представлений IoT-стек, що базується на кількох протоколах, кожен з яких відповідає за певний рівень і забезпечує власні механізми безпеки. На рівні представлення даних використовується CBOR — формат стиснення даних, який оптимізує передачу для обмежених IoT-пристроїв. Його супроводжує COSE, який забезпечує підпис і шифрування об'єктів CBOR, дозволяючи створювати легкі криптографічні ключі, хеші та цифрові підписи. На рівні обміну повідомленнями застосовується CoAP — спеціалізований протокол для обмежених пристроїв, що легко інтегрується з HTTP для роботи в широких мережах. CoAP забезпечує захищену комунікацію через OSCORE (шифрування CBOR) або DTLS, який дозволяє обмін зашифрованими повідомленнями через UDP і підходить для

промислових, домашніх і смарт-міських застосувань. OSCORE забезпечує наскрізний захист повідомлень між вузлами за допомогою COSE, захищаючи повідомлення CoAP на рівні застосунків від відтворення.

Для стиснення заголовків IPv6 і забезпечення захищеного з'єднання через транспортний режим у мережах 6LoWPAN використовується IPsec. На каналному і фізичному рівнях працюють стандарти IEEE 802.15.4 і BLE. IEEE 802.15.4 визначає фізичний та каналний рівні для мереж із низьким енергоспоживанням, тоді як BLE забезпечує легке з'єднання як енергоефективна альтернатива. OAuth 2.0 дозволяє авторизацію без передачі облікових даних, забезпечуючи безпечний доступ до ресурсів. MQTT, побудований на основі TCP, підтримує обмін даними за моделлю публікації-підписки, що є легким рішенням для IoT і M2M, мінімізуючи трафік і надійно працюючи в умовах ненадійного з'єднання[5].

Забезпечення безпеки в IoT передбачає використання протоколів на кожному рівні стека. Наприклад, на прикладному рівні застосовуються CBOR для ефективного стиснення даних та OSCORE, який забезпечує наскрізний захищений зв'язок між клієнтом і сервером у протоколі CoAP. Сам CoAP підтримує обмін даними між пристроями та сумісний із HTTP, що дозволяє його інтеграцію з класичними Інтернет-системами. Для захисту CoAP на транспортному рівні використовується DTLS, який забезпечує безпечний обмін через UDP, тоді як MQTT застосовує TCP разом із SSL/TLS для захисту даних під час публікації та підписки на повідомлення.

На мережевому рівні безпеку забезпечує IPsec, який дозволяє захищений транзит між вузлами за допомогою IPv6, а 6LoWPAN стискає IP-заголовки, оптимізуючи трафік для обмежених мереж. На фізичному рівні широко використовується стандарт IEEE 802.15.4, який шифрує дані в сенсорних мережах за допомогою AES-CCM*, тоді як Bluetooth Low Energy (BLE) дозволяє енергоефективний і безпечний обмін із можливістю додаткового захисту через білі списки приватних адрес [6,7].

Для організації доступу до ресурсів в IoT застосовується OAuth 2.0, який розділяє ролі клієнтів і власників ресурсів, забезпечуючи надійну авторизацію.

Кожен рівень стека безпеки Інтернету речей (IoT) незалежний і забезпечує власні механізми захисту. Наприклад, стандарт IEEE 802.15.4 застосовує блочне шифрування AES-CCM для захисту даних; це варіант алгоритму AES-CCM, який додає можливість використання лише функцій шифрування, з фіксованим розміром ключа 128 біт і блоку відкритого тексту. На мережевому рівні безпека ґрунтується на IPv6, де IP-безпека (IPsec) виступає основним механізмом для захищеного з'єднання з Інтернетом. Безпека на транспортному рівні залежить від протоколу на прикладному рівні: якщо використовується CoAP, то транспортний рівень — це UDP з безпекою DTLS; якщо ж розгорнуто MQTT, то задіяний TCP з SSL/TLS для захисту.

Інтернет речей є однією з найактуальніших сфер досліджень, адже IoT — це взаємодія між численними пристроями, речами й об'єктами. У такій системі захист і

конфіденційність даних стають ключовими питаннями, особливо при передачі чутливої інформації через IoT-мережі для обробки та зберігання в хмарі. У даній роботі представлено огляд поточних технологій і протоколів безпеки для IoT, включаючи механізми захисту конфіденційності. У майбутньому планується створити полегшену схему автентифікації, що дозволить ефективно захистити пристрої IoT, ураховуючи їх обмежені можливості.

Перелік посилань

1. Ахметов, Д. А. Безпека IoT: сучасні виклики та рішення. / Д. А. Ахметов, І. М. Лисенко – Київ: Наукова думка, 2021. – 264 с.
2. Головка, П. С. Протоколи для Інтернету речей: особливості та реалізація. / П. С. Головка – Харків: ХНУРЕ, 2022. – 198 с.
3. Руденко, В. В. IoT та кібербезпека: захист мережевих пристроїв. / В. В. Руденко, Н. М. Мороз – Львів: Львівська політехніка, 2023. – 312 с.
4. Литвиненко, О. Ю. Моделі безпеки для IoT-платформ. / О. Ю. Литвиненко – Одеса: Одеський національний університет, 2020. – 157 с.
5. Сіренко, М. Д. IoT-мережі та їх захист: посібник. / М. Д. Сіренко, А. С. Черненко – Дніпро: Дніпропетровський університет, 2021. – 288 с.
6. Петрова, Н. С. Механізми захисту даних в IoT: аналіз і розробка. / Н. С. Петрова – Київ: КПІ ім. Ігоря Сікорського, 2022. – 204 с.
7. Іваненко, Т. В. IoT в промисловості: концепції та проблеми безпеки. / Т. В. Іваненко – Харків: ХНУРЕ, 2023. – 325 с.
8. Карпенко, Л. А. Протоколи безпеки для IoT: огляд і застосування. / Л. А. Карпенко, І. Г. Смирнов – Вінниця: ВНТУ, 2020. – 152 с.

Завідувачу кафедри кібербезпеки
к.т.н., доц. Кльоцу Ю.П.
Мусіюка Андрія Володимировича
ПІБ здобувача вищої освіти

Студента ФІТ, 2 курсу, групи КБЗІМ-23-1

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 дисциплінарної та академічної відповідальності, ознайомлений (а). Про використання програмно-технічних засобів для перевірки кваліфікаційних робіт здобувачів вищої освіти на наявність академічного плагіату оповіщений (а) та надаю свою згоду на обробку й збереження університетом моєї роботи в інституційному репозитарії Хмельницького національного університету.

Також надаю університету право на передачу моєї роботи для обробки та збереження в базах даних програмно-обчислювального комплексу StrikePlagiarism та/або програмно-технічного засобу Anti-Plagiarism) і використання роботи для виявлення академічного плагіату в інших роботах, які перевіряються програмно-технічними засобами та користувачами, що мають доступ до цих програмно-технічних засобів, виключно в обмежених цілях для виявлення текстових збігів в роботах.

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

02.12.2024

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: Андрій МУСЮК

Співавтор:

Назва: Метод моніторингу аномальної активності мобільних застосунків

Науковий керівник: Володимир ПЕТРУШАК

Підрозділ: Кафедра кібербезпеки

Коефіцієнт подібності 1: 2.1%

Коефіцієнт подібності 2: 0%

Мікропробіли: 6

Заміна букв: 3

Інтервали: 0

Білі знаки: 0

Дата створення звіту: 2024-11-29 12:09:32.0

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 21.23.24



експерт

Anti-Plagiarism v-15.257

Максимальне співпадіння з одним документом 0.0%

Словники перевірки: en_US, ru_RU, ua_UA. **Помилوک в документах: 5%**

ID: 152318 Назва: Метод моніторингу аномальної активності мобільних застосунків Додано в БД: 2024-11-30 Автора: Мусіюк Андрій Керівники: Петрушак В.С. Консультанти: Опоненти:	Документ		Сумарний збіг по Базі Даних	
	Символи	Лексеми	Символи	Лексеми
	111454	894	688 (1%)	12 (1%)

Джерело плагіату

ID	Опис	Наявність плагіату в документі	
		Символи	Лексеми

РІШЕННЯ ЕКСПЕРНОЇ КОМІСІЇ

КАФЕДРИ КІБЕРБЕЗПЕКИ

ПРО ДОПУСК КВАЛІФІКАЦІЙНОЇ РОБОТИ ДО ЗАХИСТУ

Підтверджуємо ознайомлення з результатом звіту подібності щодо роботи, генерованого системою виявлення текстових збігів/ідентичності/схожості:

Назва: Метод моніторингу аномальної активності мобільних застосунків

Автор: Мусіюк Андрій Володимирови

Спеціальність: 125 – Кібербезпека та захист інформації

Освітня програма: Кібербезпека та захист інформації

Науковий керівник: Віктор ПЕТРУШАК, канд. техн. наук, доцент

Після аналізу звіту подібності зроблено такий висновок:

№	Висновок	Позначка про відповідність
1	Запозичення, виявлені в роботі, є законними і не є плагіатом (далі – зазначаються підстави віднесення запозичень до правомірних). Робота приймається до захисту.	відповідає
2	Виявлені запозичення не є 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. Відкоригований варіант має бути поданий на кафедру за 2 дні до захисту, разом із заявою щодо самостійності виконання письмової роботи та ідентичності друкованої та електронної версії роботи.	
3	Виявлені запозичення не є плагіатом, але частково розміщені в розділах, які описують безпосередньо авторське дослідження, а кількість цитат перевищує обсяг, виправданий поставленою метою роботи. В зв'язку з цим мета роботи та поставлені завдання не були досягнені. Робота може бути допущена до захисту (наступного року) після того як буде відкоригована та допрацьована і успішно пройде повторну перевірку на академічний плагіат.	
4	Робота містить навмисні текстові спотворення, передбачувані спроби укриття запозичень або інші прояви академічного плагіату. Робота містить фабрикацію або фальсифікацію даних. Робота не допускається до захисту.	
5	Інше:	

Підтвердження:

Оригінальність тексту роботи за результатами перевірки системою StrikePlagiarism складає 97.9%, оригінальність тексту роботи за результатами перевірки системою Anti-Plagiarism складає 99.9%.

Згідно з правилами чинного Положення «Про систему забезпечення академічної доброчесності у Хмельницькому національному університеті» від 24.09.2024, авторська робота, обсяг оригінального тексту у відсотках до загального обсягу матеріалу в якій складає 90-100%, визначається роботою з високою унікальністю тексту і допускається до захисту.

Виявлені модифікації стосуються математичних формул і не є порушенням академічної доброчесності.

Керівник роботи

Гарант ОП

Завідувач кафедри кібербезпеки



Володимир ПЕТРУШАК

Віра ТІТОВА

Юрій КЛЬОЦ

РЕЦЕНЗІЯ НА КВАЛІФІКАЦІЙНУ РОБОТУ
освітнього ступеня «магістр»

Студент Мусіюк Андрій Володимирович

Тема Метод моніторингу аномальної активності мобільних застосунків

Галузь знань 12 – Інформаційні технології

Спеціальність 125 – Кібербезпека та захист інформації

Обсяг кваліфікаційної роботи освітнього ступеня «магістр»:

кількість листів креслень - ; кількість сторінок записки 90

1. Кваліфікаційна робота присвячена розробці методу виявлення аномальної активності мобільних додатків на основі аналізу поведінкових ознак із використанням технологій машинного навчання. Запропонований метод підвищує ефективність захисту мобільних платформ та мінімізує ризики несанкціонованої активності.
2. Висновок про відповідність кваліфікаційної роботи завданню Кваліфікаційна робота 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 роботі використано сучасні методи та досягнення в області аналізу поведінкових ознак мобільних додатків, зокрема технології машинного навчання. У першому розділі проведено огляд існуючих підходів до моніторингу активності додатків, визначено їх переваги та недоліки, а також напрями вдосконалення. Другий розділ присвячено класифікації ознак, що дозволяє ефективно виявляти аномальну поведінку мобільних додатків. У наступних розділах розроблено математичну модель аналізу загроз з урахуванням поведінкових особливостей та проведено її тестування, яке підтвердило ефективність і можливість практичного застосування запропонованого методу.
4. Позитивні сторони роботи Позитивні сторони проекту Робота добре структурована, чітко висвітлені всі етапи дослідження. Використані сучасні інструменти та підходи, що свідчить про якість проведеного дослідження..

5. Негативні сторони роботи Негативні сторони проекту роботи не повністю розкрито вплив адаптивності поведінкових моделей на зниження помилкових спрацювань, що може бути важливим для подальших досліджень.

6. Оцінка графічного оформлення та пояснювальної записки роботи В загальному кваліфікаційна робота заслуговує позитивної оцінки. Весь матеріал дипломної роботи структурований, чіткий та послідовний. Усі розділи роботи послідовні та логічні, що дозволяє чітко розуміти викладений матеріал в рамках тематики кваліфікаційної роботи.

7. Відгук про роботу в цілому Кваліфікаційна робота заслуговує позитивної оцінки. Весь матеріал кваліфікаційної роботи структурований, чіткий та наскрізно пов'язаний. Усі розділи роботи послідовні та логічні, що дозволяє чітко розуміти викладений матеріал в рамках тематики кваліфікаційної роботи. Презентаційний та ілюстративний матеріал дозволяє наочно побачити доцільність та ефективність рішень, які були прийняті за основу для досягнення поставленої мети.

8. Інші зауваження

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

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

Мартинюк Валерій Володимирович

завідувач кафедри АКІТР, доктор технічних наук, професор

« 16 » зрочня 2024.



(підпис)