

<https://doi.org/10.31891/2307-5732-2025-349-25>
УДК 637.5.02

КИРИК МАР'ЯН

Національний університет "Львівська Політехніка"
<https://orcid.org/0000-0001-9156-9347>
e-mail: marian.i.kyryk@lpnu.ua

ПЛЕСКАНКА НАЗАР

Національний університет "Львівська Політехніка"
<https://orcid.org/0009-0002-2341-5113>
e-mail: nazaraii.m.pleskanka@lpnu.ua

РІЙ АНДРІЙ

Національний університет "Львівська Політехніка"
<https://orcid.org/0009-0005-0252-1533>
e-mail: andrii.i.rii@lpnu.ua

ДОСЛІДЖЕННЯ МОЖЛИВОСТЕЙ ЗАСТОСУВАННЯ МЕТОДУ ISOLATION FOREST ДЛЯ ВИЯВЛЕННЯ АНОМАЛІЙ У МЕРЕЖЕВОМУ ТРАФІКУ

Стаття присвячена дослідженню можливостей застосування методу Isolation Forest для виявлення аномалій у мережевому трафіку. Основний акцент зроблено на ефективності цього підходу для ідентифікації нетипової поведінки, що може свідчити про наявність кіберзагроз, зокрема атак різного типу. Розглянуто процес попередньої обробки даних, включаючи очищення, агрегування та вибір релевантних характеристик трафіку. Проведено налаштування гіперпараметрів моделі з метою підвищення її точності та стійкості до змін у вхідних даних. Додатково оцінено інтерпретованість результатів за допомогою методу SHAP, що дозволяє визначити ключові ознаки, які впливають на рішення моделі. Отримані результати демонструють потенціал Isolation Forest для використання в задачах кібербезпеки та обґрунтовують його переваги у виявленні аномальних патернів трафіку.

Ключові слова: виявлення аномалій, Isolation Forest, мережевий трафік, машинне навчання, кібербезпека, мережева безпека, алгоритми виявлення аномалій, SHAP, TreeSHAP, KernelSHAP.

KYRYK MARIAN

PLESKANKA NAZAR

RIY ANDRIY

Lviv Polytechnic National University

THE POTENTIAL OF THE ISOLATION FOREST METHOD FOR ANOMALY DETECTION IN NETWORK TRAFFIC

The article is dedicated to the use of the Isolation Forest method for anomaly detection in network traffic and explains the results through the SHAP method. As traditional methods for detecting cyber threats, such as signature-based and heuristic approaches, lose their effectiveness due to the increasing volume of data and the complexity of attacks, the use of machine learning methods, such as Isolation Forest, is gaining more significance. Isolation Forest allows for anomaly detection without the need for pre-labelled data, making it a powerful tool for analyzing large and complex datasets. However, this method has limitations in terms of result interpretability. To address this issue, the SHAP method was used, which helps to understand which specific features influence the model's decision.

The article discusses the stages of preprocessing network traffic data, including cleaning, aggregation, and feature selection, which help improve accuracy and reduce noise levels. The CICIDS2017 dataset, which contains real network traffic with cyber threats, including port scanning, was used to test the method. The results showed the effectiveness of the Isolation Forest method in detecting anomalous sessions. Two SHAP approaches were used to explain the results: KernelSHAP and TreeSHAP, both of which assess the impact of each feature on the anomaly score. A comparison of these methods helps identify their strengths and weaknesses in terms of the explainability of anomaly detection results.

Additionally, the article discusses the challenges associated with using Isolation Forest in real-world conditions, particularly the selection of optimal model parameters, which significantly impact the accuracy and effectiveness of anomaly detection. The conclusions drawn can be useful for cybersecurity professionals working on creating effective anomaly detection systems for network traffic and developing new approaches to data analysis in real-world scenarios.

Keywords: anomaly detection, Isolation Forest, network traffic, machine learning, cybersecurity, network security, anomaly detection algorithms, SHAP, TreeSHAP, KernelSHAP.

Постановка проблеми

Зі зростанням обсягу мережевого трафіку та ускладненням атак традиційні методи виявлення загроз, зокрема сигнатурні та евристичні підходи, втрачають ефективність. Їх головний недолік полягає в необхідності попереднього знання про відомі загрози, що унеможливає їх застосування для виявлення нових, невідомих атак. В умовах динамічних змін у мережевому середовищі та поширення шифрованого трафіку виникає потреба у методах, здатних адаптивно аналізувати потоки даних і виявляти аномальні патерни без використання маркованих вибірок [1].

Одним із таких підходів є алгоритм Isolation Forest, який демонструє високу ефективність у виявленні аномалій, оскільки працює за принципом ізоляції нетипових зразків шляхом рекурсивного розбиття простору ознак. Його ключова перевага — здатність функціонувати без необхідності великих обсягів попередньо анотованих даних, що робить його особливо цінним для аналізу мережевого трафіку з високою варіативністю [2]. Проте практичне застосування цього алгоритму у сфері кібербезпеки має суттєве обмеження: низьку інтерпретованість рішень. Адміністратори систем безпеки можуть

отримувати індикатори аномальної активності, однак їм складно зрозуміти, які саме ознаки вплинули на класифікацію певного трафіку як потенційно шкідливого. Це ускладнює процес прийняття рішень щодо реагування на загрози та підвищує ризик помилкових спрацьовувань.

Для вирішення цієї проблеми актуальним є використання методів пояснюваного машинного навчання, зокрема підходу SHAP (Shapley Additive Explanations), який дозволяє оцінити вплив кожної ознаки на рішення моделі. Інтеграція SHAP із Isolation Forest сприятиме підвищенню прозорості та обґрунтованості ухвалених алгоритмом рішень, що є критично важливим для систем моніторингу кібербезпеки. У цьому контексті в дослідженні ставляться такі завдання:

1. Виконати попередню обробку мережевого трафіку, включаючи очищення даних, видалення нерелевантних атрибутів та нормалізацію ознак для покращення якості аналізу.
2. Оцінити ефективність алгоритму Isolation Forest у виявленні аномалій у різних сценаріях мережевого трафіку.
3. Дослідити можливості використання методу SHAP для пояснення рішень Isolation Forest.
4. Порівняти різні підходи до обчислення SHAP-значень, зокрема KernelSHAP і TreeSHAP, для оцінки їх ефективності в інтерпретації аномалій.
5. Провести емпіричний аналіз продуктивності розробленого підходу та оцінити його застосовність у реальних умовах експлуатації систем кібербезпеки.

Розв'язання цих завдань дозволить покращити точність та пояснюваність методів виявлення аномалій у мережевому трафіку, що сприятиме їх ефективному впровадженню в практичні системи кіберзахисту.

Аналіз досліджень та публікацій

У сучасних дослідженнях виявлення аномалій у мережевому трафіку алгоритм Isolation Forest активно розглядається як потужний інструмент для кібербезпеки. Цей метод показав свою ефективність у високимірних даних, не потребуючи попередньої інформації про розподіл ознак, що зробило його важливим для аналізу мережевого трафіку та виявлення кіберзагроз [3]. Це дослідження стало основою для численних подальших робіт, що досліджують застосування Isolation Forest у різних контекстах кібербезпеки.

Один з напрямків досліджень стосується застосування цього методу в програмно-конфігурованих мережах (SDN), де Isolation Forest продемонстрував високу ефективність, досягнувши AUC-ROC 0.94. В цьому контексті важливою є здатність алгоритму працювати з великими обсягами трафіку та адаптуватися до змін мережевих політик в реальному часі, що є критичним для SDN [4]. Крім того, акцент зроблено на необхідності попередньої обробки даних для зменшення шуму, що підвищує точність виявлення аномалій. Дослідники також вивчали можливість комбінування Isolation Forest з іншими методами попередньої обробки для покращення ефективності алгоритму. Інші дослідники звернули увагу на поєднання Isolation Forest з методом кластеризації K-Means для підвищення точності виявлення аномалій. Така комбінація дозволила ефективно групувати схожі зразки даних, що покращило здатність алгоритму ізолювати аномальні точки, особливо в середовищах з численними схожими, але легітимними патернами [5]. Оптимізація параметрів кластеризації сприяла значному зниженню рівня хибнопозитивних спрацьовувань та підвищенню загальної точності моделі.

У роботі [6] дослідники показали, як метод SHAP може бути використаний для інтерпретації результатів деревових моделей у кібербезпеці. Завдяки цьому підходу можна точно визначати важливі ознаки, які впливають на класифікацію аномалій, що є важливим для прийняття рішень адміністраторами безпеки. Використання SHAP дозволяє покращити прозорість рішень моделей, що є необхідним для їх ефективного застосування в реальних умовах кіберзахисту.

Автори публікації [7] провели експериментальне поєднання Isolation Forest з автоенкодерами для виявлення складних аномалій, таких як DDoS-атаки. Така інтеграція дозволила значно поліпшити виявлення складних патернів у мережевому трафіку, що в результаті підвищило точність виявлення аномалій, зокрема при обробці великих обсягів даних. У статті [8] автори дослідили методи виявлення аномалій у DNS-запитах та запропонували підхід, що поєднує Isolation Forest, One-Class SVM і K-means. Вони протестували свою модель на CAIDA Passive DNS Dataset, досягнувши 92% точності у класифікації нормальних і аномальних запитів. Дослідження підтвердило ефективність методу для моніторингу трафіку та виявлення атак, таких як DNS тунелювання та DDoS.

Таким чином, хоча Isolation Forest є ефективним інструментом для виявлення аномалій, більшість досліджень спрямовані на підвищення точності моделей. Інтеграція з методами, такими як SHAP і K-Means, дозволяє не лише покращити ефективність алгоритму, а й забезпечити прозорість рішень, що є необхідним для інтеграції таких моделей у реальні системи кібербезпеки.

Формулювання цілей статті

Метою роботи є: підвищення прозорості та інтерпретованості алгоритму Isolation Forest при виявленні аномалій у мережевому трафіку шляхом використання методу SHAP для пояснення результатів моделі.

Виклад основного матеріалу

Аномалії в мережевому трафіку — це незвичні або підозрілі відхилення від нормальної активності, що можуть вказувати на системні збої, зловмисні дії чи інші небажані події. Вони можуть

проявлятися в різних формах: точкові аномалії — це окремі записи, що суттєво відрізняються від інших, наприклад, великі затримки між пакетами; контекстуальні аномалії залежать від ситуації, в якій вони виникають; колективні аномалії утворюються через групу подій, що разом викликають нестандартну активність. Такі аномалії можуть свідчити про різні види атак, як-от Port Scanning, Botnet, Brute Force, Web Attack, а також DoS/DDoS-атаки, спрямовані на перевантаження та виведення з ладу систем.

Для виявлення таких відхилень ефективно застосовується метод Isolation Forest. Цей алгоритм дозволяє виявляти аномалії в великих наборах даних, ізолюючи їх через побудову дерев ізоляції. Isolation Forest не потребує попереднього маркування даних і є корисним у випадках, коли аномалії важко прогнозувати. Аномальні об'єкти, як правило, знаходяться в екстремальних ділянках даних, що дозволяє їх швидше ізолювати. Побудова дерева включає випадковий вибір ознаки та значення для поділу, після чого дані розподіляються на два вузли, і процес повторюється до досягнення умови (один екземпляр або максимальна глибина). Такий підхід дозволяє точніше відображати варіації даних, оскільки аномалії ізолюються швидше завдяки екстремальним значенням.

Використовуючи всі дерева в моделі, можна розрахувати аномальну оцінку для кожного об'єкта за формулою:

$$s(x, n) = 2 \frac{-E[f(x)]}{c(n)} \quad (1)$$

де: $f(x)$ — довжина шляху об'єкта x в дереві ізоляції; $E[f(x)]$ — це середня довжина шляху об'єкта в усіх деревах моделі; $c(n)$ - нормувальне значення, яке залежить від розміру вибірки n . Ця нормалізація необхідна, оскільки, якщо кількість об'єктів у дереві збільшується (тобто розмір вибірки більший), довжина шляхів для всіх об'єктів також зростає.

Маючи аномальну оцінку для кожного об'єкта можна легко знайти аномалії з відповідною точністю. Для пояснення аномалій використовують SHAP (SHapley Additive exPlanations), який оцінює вплив змін ознак на аномальний бал, з адаптацією для Isolation Forest через KernelSHAP (внесок в бал) і TreeSHAP (внесок у середню довжину шляху), забезпечуючи детальний аналіз аномальності.

Для демонстрації роботи Isolation Forest із SHAP був обраний датасет CICIDS2017, що містить мережеві потоки з позначеннями нормального трафіку та атак. Цей набір даних є стандартом для аналізу аномалій у мережах, оскільки відображає реальні кіберзагрози, включаючи Port Scanning, Brute Force та Botnet [9]. Він відповідає реальному трафіку корпоративних мереж, що робить його придатним для навчання та тестування моделей машинного навчання в контексті кібербезпеки. Тому цей набір є важливою основою для оцінки алгоритмів у галузі.

На етапі попередньої обробки даних було видалено непотрібні ознаки (наприклад, номер порту та тип протоколу), а також очищено дані від пропущених значень (3.2% записів) та дублюючих значень. Для нехарактерних значень, пов'язаних з екстремальними величинами, було застосовано заміну на середні значення. Мережевий трафік був агрегований на рівні сеансів із обчисленням статистичних показників, що дозволило сформувати структурований набір даних, який містить 2 743 912 записів і 51 ознаку. Всі числові ознаки були стандартизовані, що забезпечило рівноцінний внесок кожної ознаки в модель. Подібний підхід використовувався в [10], де стандартизація ознак допомогла покращити точність виявлення аномалій у двоетапній системі XIDS-IDS. Після обробки було знижено шум на 12% і збережено ключові патерни, підтверджуючи ефективність підходу.

Модель Isolation Forest була налаштована з параметрами: $n_estimators = 100$, $max_samples = 256$, $contamination = 0.02$, $random_state = 42$.

Параметр $n_estimators = 100$ визначає кількість дерев у моделі. Це значення вибрано для досягнення оптимального балансу між стабільністю та ефективністю: після 100–200 дерев приріст точності є незначним, тому використання 100 дерев забезпечує стабільність результатів, водночас зменшуючи обчислювальні витрати.

Параметр $max_samples = 256$ визначає максимальну кількість записів, що використовуються для побудови кожного дерева. Такий розмір вибірки дозволяє ефективно ізолювати аномалії, знижуючи навантаження на пам'ять і пришвидшуючи навчання моделі, водночас зберігаючи здатність до виявлення аномальних точок.

Параметр $contamination = 0.02$ задає очікувану частку аномалій у наборі даних. Значення 2% обрано на основі емпіричних даних, оскільки в більшості реальних сценаріїв частка аномальних точок є відносно малою. Це налаштування допомагає мінімізувати кількість хибних спрацьовувань і підвищити загальну точність моделі.

Параметр $random_state = 42$ забезпечує відтворюваність результатів, задаючи початкове значення генератора випадкових чисел для ініціалізації випадкових процесів, таких як вибір підмножин даних для побудови дерев. Це дозволяє отримати однакові результати при кожному запуску моделі на тих самих даних, що важливо для порівняння налаштувань.

Експериментальні результати показали, що обрані параметри забезпечують високу ефективність виявлення аномалій, зокрема, значення $AUC-ROC = 0.95$, що перевищує $AUC = 0.90$, отримане при меншій кількості дерев. У підсумку модель виявила 50 415 аномальних сеансів (приблизно 1.84% від загальної кількості), що підтверджується графіком аномальних балів на рис. 1.




Рис.1. Розподіл аномальних та нормальних записів у мережевому трафіку

Для з'ясування причин аномалій, виявлених моделлю Isolation Forest, застосовано два підходи SHAP: KernelSHAP і TreeSHAP. Порівняння цих методів наведено в таблиці нижче.

Таблиця 1

Результати порівняння KernelSHAP та TreeSHAP

Критерій	KernelSHAP	TreeSHAP
Швидкість	Повільний (для 500 записів потрібно ~20 хв)	Швидкий (для 10,000 записів потрібно менше 1 сек)
Інтерпретація	Аналізує аномальний бал	Аналізує середню довжину шляху
Обмеження	Висока обчислювальна складність	Не підтримує пряму інтерпретацію аномального балу

KernelSHAP є універсальним методом, що добре працює з різними моделями, але його обчислювальна складність зростає при великій кількості записів, що ускладнює роботу з великими наборами даних (наприклад, для 500 записів обробка може зайняти до 20 хвилин) [7]. Натомість TreeSHAP оптимізований для моделей дерев, як-от Isolation Forest, і має значно вищу швидкість обчислень — обробка 10 000 записів займає менше ніж одну секунду. Інтерпретація результатів також різна: KernelSHAP аналізує аномальний бал, що дає загальне уявлення про поведінку моделі, а TreeSHAP фокусується на середній довжині шляху, що є більш специфічним для алгоритмів на основі дерева. Однак TreeSHAP не підтримує прямий аналіз аномального балу, що може бути обмеженням для деяких задач.

Приклад інтерпретації аномалії з використанням KernelSHAP показано на діаграмі водоспаду, наведеної на рис. 2. Графік водоспаду відображає, як кожна окрема ознака вплинула на кінцевий прогноз моделі. На горизонтальній осі показано базовий рівень аномальності, а кожен стовпчик відображає зміни, внесені відповідною ознакою в оцінку моделі. Якщо значення ознаки знижує оцінку моделі, стовпчик буде червоним, а якщо збільшує – синім. Таким чином, цей графік дозволяє визначити, які параметри найбільше вплинули на класифікацію мережевого з'єднання як аномального.




Рис. 2. Графік водоспаду для аномалії, визначеної за допомогою KernelSHAP

Аномалія з балом $f(x) = -0.032$ була визначена моделлю завдяки впливу кількох ключових ознак, зокрема “Fwd IAT Min” та “Fwd IAT Total”, які мають значення 117000000 (117 секунд) і знизили аномальний бал на 0.03 кожна. “Fwd IAT Min” визначає мінімальний інтервал часу між двома послідовними пакетами, що були надіслані від клієнта до сервера, а “Fwd IAT Total” — це загальний час, що пройшов між першим і останнім пакетом у потоці в тому ж напрямку. Оскільки ці два параметри мають однакові значення, це вказує на те, що було надіслано лише один пакет, і відповідь від сервера не надійшла. Відсутність інших пакетів для розподілу інтервалу часу призводить до однакових значень цих параметрів. Таке співпадіння значень “Fwd IAT Min” та “Fwd IAT Total” є типовим для атак типу Port Scanning, коли атакуючий перевіряє доступність окремих портів сервера, надсилаючи один запит для кожного порту й не отримуючи відповіді. Це дозволяє припустити, що високе значення цих ознак є ознакою аномальної поведінки в мережі.

Більшість інших ознак, пов'язаних із IAT (затримками між пакетами), також спричинили незначне зниження балу моделі на 0.02. Високі значення IAT зазвичай вказують на великі затримки між пакетами, що є типовим для Port Scanning. У нормальному трафіку затримки зазвичай менші.

Для порівняння на рис. 3 наведено діаграму водоспаду для нормального випадку. У цьому випадку значення функції $f(x)$ є додатним і становить 0.255, а його математичне сподівання $E[f(x)]$ дорівнює 0.203. Це свідчить про те, що для нормального зразка модель оцінює ймовірність аномалії як низьку, що відповідає очікуваній поведінці системи.




Рис. 3. Графік водоспаду для нормального випадку, визначеного за допомогою KernelSHAP

Приклад інтерпретації аномалії за допомогою TreeSHAP показано на рис. 4. TreeSHAP використовує середню довжину шляху для оцінки аномальності екземплярів. У цьому випадку значення $f(x) = 6.869$ вказує на те, що даний екземпляр ізолюється відносно швидше, ніж інші, оскільки це значення менше за середнє значення $E[f(x)] = 14.493$. Чим менша довжина шляху, тим швидше екземпляр ізолюється, що є характеристикою аномальності. Це означає, що екземпляр має високий потенціал бути аномальним, оскільки швидка ізоляція є типовою ознакою рідкісних і нестандартних ситуацій у даних.




Рис. 4. Графік водоспаду для аномалії, визначеної за допомогою TreeSHAP

Аномалія, що була виявлена у даному потоці даних, має значний негативний вплив від кількох ключових ознак, зокрема “Fwd IAT Min”, “Bwd IAT Mean” та “Bwd IAT Min”. Значення цих параметрів ($f(x) = -0.95$, $f(x) = -0.76$ та $f(x) = -0.74$ відповідно) вказують на те, що ці ознаки знижують

ймовірність нормальної поведінки потоку, скорочуючи шлях ізоляції екземпляра. Це означає, що модель швидше класифікує потік як аномальний через значне зниження значень цих параметрів. “Fwd IAT Min” (мінімальний інтервал між пакетами, відправленими від клієнта до сервера), “Bwd IAT Mean” (середній інтервал для потоку зворотного напрямку) та “Bwd IAT Min” (мінімальний інтервал для потоку зворотного напрямку) є показниками, що характеризують затримки між пакетами. Високі значення цих затримок вказують на нестандартну поведінку мережевого трафіку, що є типовим для аномальних ситуацій, таких як Port Scanning або інші атаки, що порушують нормальні інтервали між пакетами. Зниження значень цих ознак прискорює процес класифікації потоку як аномального, що відповідає очікуванням щодо типових аномалій у мережевому трафіку.

Результати досліджень запропонованого методу.

У процесі аналізу мережевого трафіку методом Isolation Forest було виявлено 50 415 аномальних сеансів, що становить приблизно 1.84% від загальної вибірки. Основними аномаліями виявилися атаки Port Scanning, Brute Force та Botnet, що підтверджується характерними відхиленнями аномальних балів. Використання SHAP для пояснення результатів показало відмінності між підходами KernelSHAP і TreeSHAP у контексті інтерпретації аномального трафіку.

TreeSHAP продемонстрував високу ефективність завдяки швидкій обробці даних та природній сумісності з деревовими алгоритмами [11]. Його використання дало змогу оперативно аналізувати великі обсяги мережевого трафіку, виокремлюючи ключові ознаки, важливі для класифікації аномалій. Водночас KernelSHAP, хоч і забезпечував детальнішу інтерпретацію впливу кожної ознаки на аномальний бал, вимагав значно більше обчислювальних ресурсів. Через високу обчислювальну складність цей метод не придатний для використання в режимі реального часу.

Отримані результати підтверджують, що Isolation Forest є ефективним методом виявлення аномалій у мережевому трафіку, здатним розпізнавати складні патерни аномальної активності без попереднього навчання на мічених даних [12]. Використання SHAP-аналізу забезпечує розширене пояснення виявлених аномалій, що є важливим для підвищення прозорості рішень та адаптації методу до специфічних сценаріїв загроз. Для аналізу потоків у реальному часі рекомендовано TreeSHAP через його швидкодію, тоді як KernelSHAP доцільно використовувати для глибокого аналізу критичних інцидентів.

Висновки

У результаті проведеного дослідження, використання методу Isolation Forest для виявлення аномалій у мережевому трафіку довело свою ефективність у розпізнаванні складних патернів аномальної активності, зокрема атак типу DoS та Brute Force. Завдяки здатності без попереднього маркування виявляти відхилення в даних, цей метод показав значні переваги у порівнянні з традиційними підходами. Важливим аспектом дослідження є застосування SHAP для інтерпретації результатів, що дозволило не лише виявити аномалії, а й забезпечити прозорість рішень за допомогою детального пояснення внеску кожної ознаки у формування аномальних балів.

Емпіричний аналіз, проведений на датасеті CICIDS2017, підтвердив ефективність Isolation Forest у реальних умовах, а порівняння двох варіантів SHAP — KernelSHAP і TreeSHAP — продемонструвало переваги кожного підходу для різних задач: KernelSHAP забезпечує глибокий аналіз, тоді як TreeSHAP вирізняється високою швидкодією і придатний для реального часу. Варто зазначити, що метод Isolation Forest є вразливим, якщо атака розподілена між багатьма джерелами (DDoS). Однак при комбінації підходів Isolation Forest та TreeSHAP достовірність виявлення такого роду атак в режимі реального часу значно зростає, а кількість помилок класифікації мінімізується, що є критично важливим для систем кібербезпеки. Загалом, результати свідчать про важливість комбінування потужних алгоритмів виявлення аномалій із методами інтерпретації, що значно підвищує їх ефективність у забезпеченні безпеки мережевих систем.

Література

1. Zhang, T., Wang, Y., & Li, J. (2023). An ensemble framework for network anomaly detection using Isolation Forest and autoencoders. *IEEE Transactions on Information Forensics and Security*, 18, 345–359.
2. Kim, H., Lee, J., & Park, S. (2024). An optimized Isolation Forest-based intrusion detection system for heterogeneous and streaming data. *Journal of Cybersecurity and Privacy*, 3(1), 112–129.
3. Liu, F. T., Ting, K. M., & Zhou, Z. H. (2008). Isolation Forest. In *Proceedings of the 2008 Eighth IEEE International Conference on Data Mining*.
4. Nguyen, V. T., & Pham, Q. H. (2023). Application of Isolation Forest for anomaly detection in software-defined networks. In *Proceedings of the International Conference on Advanced Computing and Communication Systems*.
5. Ahmed, M., & Khan, M. S. (2021). A hybrid approach for anomaly detection using Isolation Forest and K-Means clustering. *International Journal of Computer Applications*.
6. Zhou, X., & Wang, S. (2024). Interpretability of tree-based models in cybersecurity: A SHAP-based approach. *Cybersecurity Journal*.

7. Patel, R., & Desai, M. (2022). Hybrid machine learning models for intrusion detection: A comparative study with Isolation Forest. *Future Generation Computer Systems*, 135, 357–372.
8. Кльоц, Ю., Мостовий, С., Сікорський, П., & Остапчук, І. (2024). Система виявлення аномалій у DNS-запитах. *Вісник Хмельницького національного університету. Серія: Технічні науки*, 345(6(2)), 141–148.
9. Kim, H., Lee, J., & Park, S. (2024). XI2S-IDS: An explainable intelligent 2-stage intrusion detection system. *Journal of Cybersecurity and Privacy*, 3(1), 25.
10. Sharafaldin, I., et al. (2018). Toward generating a new intrusion detection dataset and intrusion traffic characterization. In *Proceedings of ICISSP*.
11. Yang, J. (2021). Fast TreeSHAP: Accelerating SHAP value computation for trees. *arXiv preprint*, arXiv:2109.09847.
12. Choi, D., & Kim, S. (2023). Web traffic anomaly detection using Isolation Forest. *Journal of Network and Computer Applications*, 202, 103325.

References

1. Zhang, T., Wang, Y., & Li, J. (2023). An ensemble framework for network anomaly detection using Isolation Forest and autoencoders. *IEEE Transactions on Information Forensics and Security*, 18, 345–359.
2. Kim, H., Lee, J., & Park, S. (2024). An optimized Isolation Forest-based intrusion detection system for heterogeneous and streaming data. *Journal of Cybersecurity and Privacy*, 3(1), 112–129.
3. Liu, F. T., Ting, K. M., & Zhou, Z. H. (2008). Isolation Forest. In *Proceedings of the 2008 Eighth IEEE International Conference on Data Mining*.
4. Nguyen, V. T., & Pham, Q. H. (2023). Application of Isolation Forest for anomaly detection in software-defined networks. In *Proceedings of the International Conference on Advanced Computing and Communication Systems*.
5. Ahmed, M., & Khan, M. S. (2021). A hybrid approach for anomaly detection using Isolation Forest and K-Means clustering. *International Journal of Computer Applications*.
6. Zhou, X., & Wang, S. (2024). Interpretability of tree-based models in cybersecurity: A SHAP-based approach. *Cybersecurity Journal*.
7. Patel, R., & Desai, M. (2022). Hybrid machine learning models for intrusion detection: A comparative study with Isolation Forest. *Future Generation Computer Systems*, 135, 357–372.
8. Klots, Yu., Mostovyi, S., Sikorskyi, P., & Ostapchuk, I. (2024). Systema vyivlennia anomalii u DNS-zapytakh. *Herald Khmelnytskoho natsionalnoho universytetu. Serii: Tekhnichni nauky*, 345(6(2)), 141–148.
9. Kim, H., Lee, J., & Park, S. (2024). XI2S-IDS: An explainable intelligent 2-stage intrusion detection system. *Journal of Cybersecurity and Privacy*, 3(1), 25.
10. Sharafaldin, I., et al. (2018). Toward generating a new intrusion detection dataset and intrusion traffic characterization. In *Proceedings of ICISSP*.
11. Yang, J. (2021). Fast TreeSHAP: Accelerating SHAP value computation for trees. *arXiv preprint*, arXiv:2109.09847.
12. Choi, D., & Kim, S. (2023). Web traffic anomaly detection using Isolation Forest. *Journal of Network and Computer Applications*, 202, 103325.