



ІНФОРМАЦІЙНО-КОМУНІКАЦІЙНІ СИСТЕМИ ТА ТЕХНОЛОГІЇ

<https://doi.org/10.23939/ictee2025.01.001>

ГІБРИДНА МОДЕЛЬ ВИЯВЛЕННЯ МЕРЕЖЕВИХ АНОМАЛІЙ З ВИКОРИСТАННЯМ МАШИННОГО НАВЧАННЯ

М. Климаш [ORCID: 0000-0002-1166-4182], Н. Бальковський [ORCID: 0009-0007-0126-0356], О. Шпур [ORCID: 0000-0001-8156-8017]

Національний університет “Львівська політехніка”, вул. С. Бандери, 12, Львів, 79013, Україна

Відповідальний за рукопис: Назарій Бальковський (e-mail: nazarii.y.balkovskiy@lpnu.ua)

(Подано 25 березня 2025)

Зважаючи на зростання складності кіберзагроз, необхідне розроблення ефективних методів виявлення та класифікації атак у мережевому трафіку. У цьому дослідженні проаналізовано ефективність трьох популярних алгоритмів машинного навчання: Random Forest, який використовують для виявлення аномалій, Support Vector Machines (SVM), що виконує класифікацію кіберзагроз, та автоенкодерів, які застосовують для попередньої обробки даних та глибокого аналізу трафіку. Враховуючи переваги кожного з методів, ми пропонуємо комбіновану модель, яка поєднує можливості цих алгоритмів, підвищуючи ефективність виявлення загроз та оптимізуючи процес класифікації атак. Виконані експерименти демонструють, що запропонований підхід забезпечує збільшення точності виявлення атак на 3–7 % та зменшення часу реагування порівняно з використанням окремих алгоритмів машинного навчання. Окрім того, комбінована модель сприяє оптимізації ресурсів, що є критично важливим фактором для розгортання масштабованих рішень у реальних умовах. Особливу увагу приділено гібридній моделі, яка поєднує автоенкодери та алгоритм Random Forest. Її ефективність підтверджена у тестових середовищах, де продемонстровано кращі результати виявлення мережових аномалій порівняно із застосуванням лише одного алгоритму. Запропонований підхід дає змогу не лише підвищити рівень захисту інформаційних систем, а й забезпечити гнучкість у налаштуванні, завдяки чому модель придатна для широкого спектра кібербезпекових завдань. Отримані результати можна використовувати для вдосконалення методів кіберзахисту, зокрема у сфері захисту критичної інфраструктури, де своєчасне виявлення загроз є ключовим фактором безпеки. Висока ефективність комбінованого підходу підтверджує його доцільність для впровадження у системах моніторингу мережевого трафіку та кібербезпеки загалом.

Ключові слова: кібербезпека, машинне навчання, розподілені системи, алгоритми безпеки, оптимізація, захист інформації, інформаційна безпека, інформаційні системи, цифрові технології, інформація, загрози.

УДК: 621.391

Вступ

Сучасний цифровий світ динамічно розвивається завдяки впровадженню технологій хмарних обчислень, Інтернету речей (IoT) та великих даних, однак зростання цієї цифрової інфраструктури супроводжується дедалі складнішими кібератаками. Особливо вразливими виявляються розподілені

інформаційні системи, які широко застосовують у сферах критичної інфраструктури (енергетика, транспорт, зв'язок), бізнесі та державному управлінні. У таких системах необхідно гарантувати високий рівень конфіденційності, цілісності й доступності даних та сервісів [1].

Останнє десятиліття ознаменувалося справжнім проривом у методах машинного та глибокого навчання, що дає змогу обробляти величезні обсяги даних і виявляти складні закономірності. Такі підходи знайшли застосування й у кібербезпеці: від виявлення аномалій у мережевому трафіку до аналізу загроз соціальної інженерії, із використанням, зокрема, методів обробки природної мови (NLP) [2]. Завдяки цьому вдалося підвищити точність і швидкість виявлення кіберзагроз, що постійно змінюються.

Попри успіхи, масове впровадження машинного навчання у сфері кібербезпеки стикається із низкою викликів:

- Великі обсяг і різноманітність мережевих даних, які потрібно аналізувати в реальному часі.
- Постійна еволюція атак, ураховуючи складні багаторівневі кібератаки та методи соціальної інженерії.
- Необхідність оптимізувати витрати ресурсів (процесорних, мережевих) і забезпечувати масштабованість у розподілених системах [3].

Поєднання алгоритмів штучного інтелекту з великими даними дало змогу створювати проактивні рішення, здатні не лише реагувати на атаки, а й передбачати їх на основі виявлення закономірностей у мережевому трафіку. Таке поєднання великих даних, систем штучного інтелекту та машинного навчання забезпечує кібербезпеку, надаючи зацікавленим організаціям можливість ефективніше аналізувати інциденти безпеки і реагувати на них, знижувати ризики й адаптуватися до розвитку кіберзагроз.

У цьому контексті машинне навчання стає одним із перспективних підходів, що дає змогу аналізувати нетривіально великі обсяги трафіку, виявляти аномалії та прогнозувати можливі атаки з високою точністю. Водночас упровадження таких рішень у розподілених системах [4] залишається складним завданням через брак обчислювальних ресурсів, проблеми інтеграції та жорсткі вимоги до часу реагування.

Метою цього дослідження є розроблення гібридної моделі алгоритмів машинного навчання (зокрема Random Forest, SVM та автоенкодерів), яка сприятиме ефективному розгортанню кіберзахисту розподілених систем. У роботі детально проаналізовано популярні методи виявлення мережевих загроз, обґрунтовано їхню інтеграцію та модифікацію для підвищення продуктивності й рівня безпеки. Практична значущість результатів полягає у можливості впровадження описаного підходу у великих корпоративних мережах та середовищах критичної інфраструктури, де надійний кіберзахист є одним із визначальних факторів стабільності [5].

2. Порівняльний аналіз алгоритмів машинного навчання для виявлення аномалій мережевого трафіку

Одним із найпоширеніших методів для виявлення аномалій мережевого трафіку є Random Forest (далі – RF). У дослідженні [1] продемонстровано його ефективність у сценаріях виявлення DDoS-атак завдяки здатності RF обробляти великі обсяги даних із високим рівнем точності. Водночас автори наголошують, що RF потребує значних обчислювальних ресурсів, що потенційно ускладнює роботу в режимі реального часу.

Support Vector Machines (SVM) також широко застосовують у кібербезпеці, зокрема для класифікації атак. У [2] показано, що SVM може успішно розрізняти типи загроз, як-от SQL-ін'єкції та фішингові атаки, із високою точністю. Водночас ефективність SVM істотно залежить від вибору ядра та параметрів.

Серед методів глибокого навчання особливе місце займають автоенкодерів, що здатні аналізувати приховані патерни даних і виявляти нові типи загроз. У роботі [6] продемонстровано, що рівень хибних спрацювань автоенкодерів низький і вони можуть працювати із великими обсягами мережевого трафіку. Однак для їх упровадження необхідні великі обчислювальні ресурси, що може стати проблемою для розподілених систем.

Дедалі більшої популярності набуває комбіноване (гібридне) використання кількох алгоритмів. Зокрема, у [7] описано підхід, згідно із яким RF виконує попередню фільтрацію даних, а автоенкодерів здійснюють поглиблений аналіз. Цей підхід дав змогу зменшити кількість хибних позитивних спрацювань на 15 % порівняно із окремим застосуванням цих методів.

Утім, досі відкритими залишаються питання оптимізації використання ресурсів, масштабованості моделей і адаптивності до нових типів атак. У дослідженні [8] наголошено на важливості розроблення гібридних моделей, які б поєднували переваги різних підходів і забезпечували реальну ефективність у складних мережесевих середовищах.

Random Forest – це ансамблевий метод, який створює декілька дерев рішень і агрегує їхні передбачення. Кожне дерево робить прогноз $h_m(X)$, а остаточний прогноз є середнім значенням (для регресії) або здійснюється більшістю голосів (для класифікації).

$$H_m(X) = \arg \max_y \sum_{m=1}^M I(h_m(X) = y), \quad (1)$$

де M – кількість дерев у лісі; $h_m(X)$ – прогноз із дерева m ; $I()$ – функція-індикатор (підраховує голоси за кожен клас).

RF проводить голосування за найімовірніший клас, що дає змогу досягати високої точності навіть за складних патернів трафіку (рис. 1). Це забезпечує високу точність класифікації навіть у випадку складних і нелінійних залежностей даних [1].




Рис. 1. Блок-схема роботи алгоритму Random Forest

Support Vector Machines (SVM) застосовується для класифікації загроз завдяки здатності створювати оптимальні гіперплощини для розмежування класів. SVM добре працює із невеликими наборами даних і демонструє високу точність у задачах із багатьма характеристиками [2]. На рис. 2 схематично показано формування гіперплощини та принцип поділу вибірки на різні класи (атака / не-атака).

Наведемо формулу класифікації:

$$y' = \text{sign} \left(\sum_{i=1}^n a_i y_i K(x_i, x) + b \right), \quad (2)$$

де y' – передбачений клас; y_i – клас мітки (1 або -1); x_i – дані навчальної вибірки; $K(x_i, x)$ – вибраний метод ядра; b – зміщення (bias).




Рис. 2. Блок-схема роботи алгоритму SVM

*Автоенкодер*и (метод глибинного навчання) використовують для аналізу мережевого трафіку. Вони дають змогу автоматично виявляти приховані патерни в даних, що може бути корисним для виявлення нових типів загроз, які не мають чітких сигнатур [6].




Рис. 3. Блок-схема роботи автоенкодерів

Зважаючи на переваги та недоліки кожного алгоритму, зосередимось на комбінованому застосуванні Random Forest (RF), Support Vector Machines (SVM) та автоенкодерів, щоб перевірити, чи дає такий підхід змогу істотно підвищити точність і швидкість виявлення загроз у розподілених системах.

3. Розроблення гібридної моделі виявлення мережеских аномалій

За результатами дослідження наведених алгоритмів запропоновано гібридну модель машинного навчання із використанням автоенкодера для кодування великого обсягу мережеских даних та Random Forest для класифікації мережеского трафіку (рис. 4). Оскільки для гібридної моделі потрібне тільки попереднє опрацювання результатів (енкодер), то декодер не використовується. Головним завданням автоенкодера (енкодера) є попереднє опрацювання мережеских пакетів із метою виявлення головних особливостей кожного пакета та зменшення об'ємності даних. Оптимізовані дані мережеских пакетів надалі передаються на вхід Random Forest, який вже здійснює безпосередню класифікацію пакетів на основі попередньо виділених ключових деталей пакетів. У результаті збільшується швидкість алгоритму Random Forest, оскільки об'ємність даних істотно зменшується за рахунок використання автоенкодера. Точність виявлення аномалій теж підвищується завдяки відкиданню незначущих частин мережеского трафіку.




Рис. 4. Запропонована гібридна модель виявлення мережеских аномалій

4. Дослідження ефективності роботи гібридної моделі виявлення мережеских аномалій

Ефективність запропонованої моделі виявлення загроз досліджуватимемо на основі загальновідомих критеріїв оцінювання показників ефективності виявлення мережеских аномалій:

Точність (Accuracy) – загальна частка правильно класифікованих зразків серед усіх зразків у наборі даних.

$$Accuracy = \frac{TN + TP}{TP + TN + FP + FN},$$

де TP (true positive) – правильне передбачення “атаки”; TN (true negative) – правильне передбачення “нормального” трафіку; FP (false positive) – хибне передбачення “атаки”; FN (false negative) – хибне передбачення “нормального трафіку”.

Прецизійність (Precision) – наскільки часто прогноз атаки є достовірним.

$$Precision = \frac{TP}{TP + FP}.$$

Повнота (Recall) – скільки із усіх реальних атак вибрана модель змогла виявити

$$Recall = \frac{TP}{TP + FN}.$$

F1-оцінка (F1-Score) – балансна оцінка між точністю та прецизійністю

$$F1 = 2 \frac{Precision * Recall}{Precision + Recall}$$

Дослідження здійснено на операційній системі MacOS із використанням мови програмування Python. Основні характеристики робочої станції:

- ОЗП – 32 GB.
- Відеопам'ять – спільна пам'ять із ОЗП.
- Процесор – Apple Silicon M1 Ultra.
- Версія ОС – macOS Sequoia 15.1.1.

Для аналізу алгоритмів SVM, Autoencoders та Random Forest у дослідженні використано мову Python та спеціалізовані бібліотеки:

- tensorflow – бібліотека для глибокого навчання та побудови нейронних мереж. Застосовується для створення та тренування моделі на основі автоенкодерів (Autoencoders);
- scikit-learn (sklearn) – модуль машинного навчання, котрий містить алгоритми регресії, кластеризації та класифікації. Використовується для реалізації методу опорних векторів (SVM) та випадкового лісу (Random Forest).

Вибрані бібліотеки дають змогу ефективно здійснювати навчання моделей, використовуваних у дослідженні, працювати з великими обсягами даних та виконувати аналіз результатів тренування моделей. Схему навчання і тестування запропонованої моделі наведено на рис. 5.




Рис. 5. Схему навчання та тестування моделей

У ході дослідження здійснено навчання декількох моделей на основі алгоритмів машинного навчання для класифікації мережевого трафіку із використанням набору даних CICIDS 2017 [10]. У набір увійшли попередньо оброблені CSV-файли. Кожен запис містить характеристики мережевого з'єднання та відповідну мітку класу (BENIGN або ATTACK).

На першому етапі навчання кожного алгоритму здійснювалось окремо:

- *SVM* – розмежування звичайного (нормального) та шкідливого трафіку.
- *Random Forest* – покращення класифікації за рахунок багатьох дерев рішень.
- *Autoencoder* – нейронна мережа, яка навчалася реконструювати вхідні дані, виявляючи відхилення у шкідливому трафіку.

Після навчання кожного алгоритму виконано тестування на основі тестового набору даних. Наступний крок – детальний аналіз отриманих результатів, який допоможе з’ясувати ефективність розробленої гібридної моделі в умовах реального використання.

4.1. Результати тестування моделі на основі Random Forest

Random Forest вибрано як базовий алгоритм для першого етапу тестування завдяки його високій ефективності в задачах класифікації мережевого трафіку. Отримані результати наведено у табл. 1.

Таблиця 1

Розраховані метрики оцінки моделі на основі Random Forest

Точність (Accuracy)	Прецизійність (Precision)	Повнота (Recall)	F1-оцінка (F1-Score)
92,13 %	91,08 %	99,99 %	95,33 %

З табл. 1 бачимо, що модель на основі Random Forest показує непогані результати передбачення виду мережевого трафіку. Середній час опрацювання одного мережевого пакета 760,40 нс.




Рис. 6. Матриця помилок для моделі на основі Random Forest





Рис. 7. Криві точності оцінювання вхідного трафіку Random Forest



Матриця помилок свідчить, що модель на основі Random Forest показує хороші результати із невеликою кількістю хибних прогнозів.

На рис. 7 наведено криві точності (ROC-криві), отримані в результаті тестування моделі на основі алгоритму Random Forest для оцінювання вхідного мережевого трафіку. Як видно з графіка, модель забезпечує високу ефективність класифікації, що підтверджується площею під ROC-кривою (AUC), близькою до одиниці. Це свідчить про те, що алгоритм Random Forest успішно розрізняє нормальний і шкідливий трафік із високим ступенем точності. Варто зазначити, що крива швидко наближається до верхнього лівого кута графіка. Це ознака високої чутливості та специфічності моделі, а отже, і її ефективності у виявленні аномалій та кіберзагроз у мережевому трафіку.

На рис. 8 подано гістограму розподілу оцінок класифікації, отриманих у результаті тестування моделі Random Forest. Як видно із графіка, більшість оцінок моделі концентруються біля високих значень (близько 0,9–1,0), що свідчить про впевненість алгоритму в своїх прогнозах та високий рівень точності класифікації мережевого трафіку. Водночас невелика кількість оцінок у нижчому діапазоні (0,4–0,6) вказує на існування окремих випадків, коли модель стикається з труднощами у чіткому визначенні класу трафіку. Це відкриває потенційні напрями для подальшої оптимізації алгоритму з метою зменшення таких неоднозначних класифікацій.




Рис. 8. Гістограма оцінок моделі на основі Random Forest

4.2. Результати тестування моделі на основі SVM

Наступним етапом експерименту було оцінювання ефективності алгоритму Support Vector Machines (SVM), який застосовують для класифікації мережевого трафіку на нормальний та шкідливий. Вибір цього алгоритму зумовлений його високою точністю у класифікації наборів даних із великою кількістю характеристик. Основні метрики, отримані за результатами тестування SVM-моделі на наборі даних CICIDS 2017, наведено у табл. 2.

Таблиця 2

Розраховані метрики оцінки моделі на основі SVM

Точність (Accuracy)	Прецизійність (Precision)	Повнота (Recall)	F1-оцінка (F1-Score)
84,61 %	85,91 %	96,71 %	90,99 %

Як видно з табл. 2, модель демонструє доволі високі результати, однак порівняно з моделлю Random Forest точність нижча. Це свідчить про наявність деяких обмежень алгоритму SVM під час роботи з великим обсягом різноманітного мережевого трафіку. Середній час опрацювання одного мережевого пакета – **255,50 μ s**.




Рис. 9. Матриця помилок для моделі на основі SVM





Рис. 10. Криві точності оцінювання вхідного трафіку

На рис. 9 наведено матрицю помилок (confusion matrix) для моделі на основі алгоритму SVM, що демонструє кількість правильних та хибних класифікацій мережевого трафіку. Як видно з матриці, модель загалом добре справляється із виявленням шкідливого трафіку, однак, порівняно з Random Forest, помітно більше хибних класифікацій. Зокрема, модель частіше класифікує нормальний трафік як шкідливий (хибно позитивні прогнози), що може призводити до додаткових витрат ресурсів на перевірку таких помилкових спрацювань. Цей результат свідчить про

необхідність подальшої оптимізації параметрів моделі або додаткової передобробки даних для зменшення кількості помилок такого типу.

На рис. 10 наведено ROC-криві, які ілюструють ефективність моделі на основі алгоритму SVM у класифікації мережевого трафіку. Криві свідчать про достатньо високу здатність моделі розрізняти нормальний і шкідливий трафік, що підтверджується високим значенням площі під кривою (AUC). Водночас помітно, що, порівняно з результатами алгоритму Random Forest, ROC-криві для SVM розташовані трохи нижче, що свідчить про більшу кількість хибних передбачень та нижчу загальну ефективність моделі. Це також узгоджується з отриманими раніше метриками точності та прецизійності. Вказане підтверджує необхідність додаткового налаштування параметрів моделі SVM для подальшого підвищення її ефективності.




Рис. 11. Гістограма оцінок моделі на основі SVM

Гістограма показує, що модель на основі SVM робить чіткі прогнози щодо шкідливості трафіку.

4.3. Результати тестування моделі на основі Autoencoders

На третьому етапі експериментального дослідження модель протестовано на основі автоенкодерів (Autoencoders). Вибір цієї моделі зумовлений її здатністю ефективно виявляти приховані закономірності у великих масивах даних, що теоретично дає змогу виявляти нові, раніше невідомі типи кіберзагроз. Проте, як продемонстрували результати тестування, наведені нижче, ефективність автоенкодерів для загальної класифікації різних типів атак у наборі даних CICIDS 2017 виявилася істотно нижчою порівняно із попередніми моделями.

Таблиця 3

Розраховані метрики оцінки моделі на основі автоенкодера

Точність (Accuracy)	Прецизійність (Precision)	Повнота (Recall)	F1-оцінка (F1-Score)
38,33 %	66,97 %	45,85 %	54,43 %

Як видно з наведених значень, у моделі значно нижчі показники ефективності порівняно з алгоритмами Random Forest і SVM. Особливо низьким є показник точності (Accuracy), що свідчить про низьку загальну здатність автоенкодерів правильно класифікувати різноманітні типи мережевого трафіку в цьому наборі даних. Середній час опрацювання одного мережевого пакета становить 20,17 μ s, що достатньо швидко, однак не компенсує низьку точність класифікації. Отримані результати вказують на те, що автоенкодер найефективніше застосовувати у вузькоспеціалізованих сценаріях із обмеженим переліком загроз, а не для загального виявлення широкого спектра атак.

Проаналізувавши матрицю помилок, можна зробити висновок, щоб автоенкодер погано підходить для загального аналізу мережевого трафіку із метою виявлення різних типів атак.

Автоенкодер повинен бути натренованим для виявлення конкретного типу атак, а оскільки тестовий набір даних містить інформацію про різні види атак, то модель на основі автоенкодера не може впоратись із завданням.

Крива точності оцінювання вкотре показує, що автоенкодер не підходить для класифікації загальних типів атак та повинен бути натренований для виявлення кожного виду атак окремо. На графіку простежується низька здатність чітко розмежовувати ці класи, про що свідчить істотне перекриття між нормальним та шкідливим трафіком.




Рис. 12. Матриця помилок для моделі на основі автоенкодера




Рис. 13. Крива точності оцінювання трафіку моделі на основі автоенкодера




Рис. 14. Гістограма корекції помилок моделі на основі автоенкодера

Велика кількість випадків потрапляє в зону невизначеності (середні значення прогнозу), що призводить до частих хибних класифікацій. Отримані дані підтверджують, що автоенкодер потребує додаткового тренування або спеціалізованої адаптації під конкретні типи загроз, оскільки в загальному випадку демонструє недостатньо високий рівень розпізнавання мережових аномалій.

4.4. Результат тестування гібридної моделі (Autoencoders + RF)

Завершальним етапом експериментального дослідження стало тестування гібридної моделі, яка поєднує переваги автоенкодерів та алгоритму Random Forest. Враховуючи результати попередніх тестувань, саме таке комбінування алгоритмів було вибрано з метою оптимізації процесу класифікації мережевого трафіку: автоенкодер виконує попереднє опрацювання та стиснення вхідних даних, а Random Forest – безпосередню класифікацію аномалій. Нижче наведено результати тестування цієї гібридної моделі, що демонструють істотне поліпшення показників порівняно з окремими алгоритмами та підтверджують ефективність запропонованого підходу.

Таблиця 4

Розраховані метрики оцінки гібридної моделі

Точність (Accuracy)	Прецизійність (Precision)	Повнота (Recall)	F1-оцінка (F1-Score)
97,33 %	97,73 %	98,98 %	98,35 %

Результати тестування гібридної моделі (автоенкодер + Random Forest), наведені в табл. 4, демонструють помітне покращення ключових показників ефективності порівняно з використанням лише алгоритму Random Forest. Зокрема, точність (Accuracy) зросла до 97,33 %, а прецизійність (Precision) досягла 97,73 %, що свідчить про істотне зменшення кількості хибних спрацьовувань під час класифікації шкідливого трафіку. Показник F1-оцінки (F1-Score), що враховує баланс між точністю і повнотою, також значно покращився та досяг 98,35 %, підтверджуючи загальну ефек-

тивність гібридного підходу. Хоча повнота (Recall) дещо знизилась до 98,98 % через збільшення кількості помилкових класифікацій нормального трафіку як шкідливого, цей компроміс виправданий завдяки істотному підвищенню загальної точності та прецизійності. Окрім цього, гібридна модель продемонструвала високу швидкодію із середнім часом оброблення одного мережевого пакета 12,24 μ s, що підкреслює її придатність для застосування у реальних умовах із високою інтенсивністю трафіку.




Рис. 15. Матриця помилок для комбінованої моделі





Рис. 16. Криві точності оцінювання вхідного трафіку гібридної моделі

Матриця помилок (*confusion matrix*) для комбінованої моделі, що поєднує автоенкодер і Random Forest, наведена на рис. 15, демонструє суттєве покращення порівняно з результатами, отриманими із використанням лише алгоритму Random Forest. Як видно з графіка, гібридна модель точніше класифікує шкідливий трафік: кількість правильно виявлених атак зросла з 250 577 (для Random Forest) до 378 284. Також істотно зменшилась кількість хибних виявлень шкідливого трафіку (false positive) – з 166 980 до 39 273 випадків, що свідчить про підвищену прецизійність моделі.

Однак важливо звернути увагу й на збільшення кількості нормального трафіку, помилково класифікованого як шкідливий (*false negative*) – з 153 до 17 438. Це підкреслює необхідність додаткових налаштувань порога класифікації або оптимізації моделі, щоб зменшити кількість таких помилок у реальних умовах. Загалом, матриця помилок підтверджує значний потенціал гібридної моделі у підвищенні точності та надійності виявлення кіберзагроз.

На рис. 16 подано ROC-криві, що ілюструють точність класифікації мережевого трафіку гібридною моделлю (автоенкодер + Random Forest). Графік свідчить про дуже високий рівень ефективності запропонованого підходу, що підтверджується близькістю ROC-кривої до верхнього лівого кута (і, відповідно, високим значенням площі під кривою – AUC). Це вказує на здатність моделі чітко й надійно розмежовувати нормальний та аномальний мережевий трафік. Водночас, хоча загальна точність моделі висока, певна кількість помилок залишається, зокрема помилкове виявлення нормального трафіку як шкідливого. Це потребує подальшого налаштування моделі для зниження рівня таких хибних спрацювань, що дасть змогу зробити її ще ефективнішою та придатною для використання у реальних мережесевих середовищах.

На рис. 17 наведено гістограму розподілу оцінок гібридної моделі (автоенкодер + Random Forest) під час класифікації мережевого трафіку. Графік чітко демонструє покращення якості прогнозування: більшість оцінок моделі концентруються в крайніх областях (близько 0 або 1), що свідчить про високу впевненість моделі у своїх рішеннях щодо класифікації трафіку. Кількість проміжних або невизначених прогнозів істотно зменшилась порівняно з попередніми результатами окремих алгоритмів, підтверджуючи ефективність гібридного підходу в чіткому виявленні мережесевих аномалій.

Узагальнювальні результати досліджень наведено в табл. 5, де порівняно ключові показники роботи окремих алгоритмів (Random Forest, SVM, автоенкодер) та запропонованої комбінованої моделі.




Рис. 17. Гістограма оцінок гібридної моделі

Таблиця 5

Порівняльна таблиця ефективності алгоритмів та моделі

Модель / Метрика	Точність (Accuracy), %	Прецизійність (Precision), %	Повнота (Recall), %	F1-оцінка (F1-Score), %	Час опрацювання пакету
Random Forest	84,61	85,91	96,71	90,99	760,40 ns
SVM	94,15	98,80	98,6	97,75	255,50 μ s
Автоенкодер	38,33	66,97	45,85	54,43	20,17 μ s
Гібридна	97,33	97,73	98,98	98,35	12,24 μs

Аналіз отриманих результатів показує, що запропонована комбінована модель значно перевершує окремі алгоритми за точністю виявлення аномалій і класифікації загроз. Точність виявлення аномалій у межах комбінованої моделі досягла 97,33 %, що на 3–9 % більше, ніж у разі використання тільки одного з алгоритмів, таких як Random Forest або SVM. Це підтверджує, що поєднання різних методів дає змогу компенсувати обмеження кожного з них і забезпечити надійніший захист від кіберзагроз. Важливою перевагою є також зниження рівня хибних спрацювань, оскільки кожен алгоритм робить свій внесок у фільтрацію помилкових сигналів, підвищуючи загальну точність моделі [12].

Запропонований комбінований підхід демонструє високу ефективність порівняно з окремими алгоритмами. Підвищена точність виявлення аномалій та загроз є основною перевагою, яка робить модель надійнішою для використання у реальних умовах. Однак варто зазначити, що для реального застосування в умовах великих розподілених систем необхідно враховувати можливі обмеження, пов'язані із обчислювальними витратами. Водночас, завдяки інтеграції методів попередньої обробки даних, таких як автоенкодер, можна знизити ці витрати, одночасно зберігши високу точність і ефективність роботи.

Висновки

Штучний інтелект і машинне навчання розширюють межі кібербезпеки, відкриваючи шлях до вагомих досягнень та можливостей, стаючи стійкішими з кожною атакою та здатними виявляти, захищати й ліквідувати збитки від кібератак без втручання людини. Крім того, штучний інтелект і машинне навчання відіграватимуть ключову роль у пошуку загроз, допомагаючи фахівцям із кібербезпеки у превентивному виявленні загроз. Замість того, щоб реагувати на порушення, системи безпеки передбачатимуть і нейтралізуватимуть загрози, формуючи проактивне середовище кібербезпеки.

У результаті дослідження розроблено та протестовано комбіновану модель для виявлення аномалій і класифікації загроз у розподілених інформаційно-комунікаційних системах. Модель поєднує алгоритми машинного навчання, зокрема Random Forest, Support Vector Machines (SVM) та автоенкодера, що дало змогу істотно підвищити точність виявлення загроз порівняно з використанням кожного із алгоритмів окремо.

Запропоновану модель можна ефективно застосовувати для захисту розподілених інформаційно-комунікаційних мереж, серед яких системи Інтернету речей (IoT), хмарні інфраструктури, а також для виявлення складних кібератак, таких як DDoS або SQL-ін'єкції. Подальша оптимізація алгоритмів і адаптація до конкретних типів загроз дасть змогу істотно знизити витрати ресурсів і забезпечити більшу гнучкість.

Список використаних літературних джерел

- [1] U. Islam, A. Muhammad, R. Mansoor, M. S. Hossain, I. Ahmad, E. T. Eldin, J. A. Khan, A. U. Rehman, and M. Shafiq, "Detection of Distributed Denial of Service (DDoS) Attacks in IoT Based Monitoring System of Banking Sector Using Machine Learning Models," *Sustainability*, vol. 14, no. 14, p. 8374, Jul. 2022, doi: 10.3390/su14148374
- [2] C. Liu, J. Yang, and J. Wu, "Web intrusion detection system combined with feature analysis and SVM optimization," *EURASIP Journal on Wireless Communications and Networking*, vol. 2020, no. 1, pp. 1–14, doi: 10.1186/s13638-019-1591-1
- [3] W. Song, M. Beshley, K. Przysupka, H. Beshley, O. Kochan, A. Pryslupskyi, D. Pieniak, and J. Su, "A Software Deep Packet Inspection System for Network Traffic Analysis and Anomaly Detection," *Sensors*, vol. 20, no. 6, p. 1637, Mar. 2020, doi: 10.3390/s20061637
- [4] M. M. Klymash and M. M. Panchenko, "Packet Delay Monitoring System in Software-Configured Telecommunication Networks," in *Proc. of the International Scientific and Technical Conference "Telecommunications Perspectives"*, 2016. (In Ukrainian)
- [5] E. Pantelidis, G. Bendiab, S. Shiaeles, and N. Kolokotronis, "Insider Detection Using Deep Autoencoder and Variational Autoencoder Neural Networks," in *Proc. 2021 IEEE Int. Conf. on Cyber Security and Resilience (CSR)*, Rhodes, Greece, Jul. 2021, pp. 155–160, doi: 10.1109/CSR51186.2021.9527954
- [6] Z. S. Mahdi, R. M. Zaki, and L. Alzubaidi, "Advanced hybrid techniques for cyberattack detection and prevention," *Security and Privacy*, vol. 7, no. 2, pp. e471, 2024, doi: 10.1002/spy2.471
- [7] M. Injadat, A. Moubayed, A. B. Nassif, and A. Shami, "Multi-Stage Optimized Machine Learning Framework for Network Intrusion Detection," *IEEE Transactions on Network and Service Management*, Jun. 2021, vol. 18, no. 2, pp. 1803–1816, , doi: 10.1109/TNSM.2020.3014929
- [8] CICIDS 2017 Dataset, Canadian Institute for Cybersecurity, University of New Brunswick. [Online]. Available: <https://www.unb.ca/cic/datasets/ids-2017.html> (accessed: 10.03.2025).
- [9] P. Prakriti, "Cyber threat detection using machine learning," *Int. J. Sci. Res. Eng. Manag. (IJSREM)*, Apr. 2024, vol. 4, no. 4, pp. 1–6, doi: 10.55041/IJSREM36799
- [10] I. Khlevna and B. Koval, "Parallel and distributed machine learning techniques for anomaly detection systems," in *Proc. of the Int. Workshop on Cybersecurity Providing in Information and Telecommunication Systems (CPITS 2023)*, CEUR Workshop Proc., vol. 3624, pp. 131–138. [https://ceur-ws.org/Vol-3624/Paper_16.pdf]
- [11] H. Kamal and M. Mashaly, "Enhanced hybrid deep learning models-based anomaly detection method for two-stage binary and multi-class classification of attacks in intrusion detection systems," *Algorithms*, vol. 18, no. 2, p. 69, Feb. 2025, doi: 10.3390/a18020069
- [12] H. Torabi, "Practical autoencoder-based anomaly detection by using vector reconstruction error in cloud computing networks," *Cybersecurity*, vol. 5, no. 1, p. 9, 2022, doi: 10.1186/s42400-022-00134-9
- [13] E. E. Abdallah, W. Eleisah, and A. F. Otoom, "Intrusion detection systems using supervised machine learning techniques: A survey," *Procedia Computer Science*, vol. 201, pp. 125–132, 2022, doi: 10.1016/j.procs.2022.03.029

HYBRID MODEL OF NETWORK ANOMALIES DETECTION USING MACHINE LEARNING

Mykhailo Klymash, Nazar Balkovskyi, Olha Shpur

Lviv Polytechnic National University, 12, S. Bandery str., Lviv, 79013, Ukraine

The increasing complexity of cyber threats requires the development of effective methods for detecting and classifying attacks in network traffic. This study analyzes the effectiveness of three popular machine learning algorithms: Random Forest, which is used for anomaly detection, Support Vector Machines (SVM), which performs cyber threat classification, and autoencoders, which are used for data preprocessing and deep traffic analysis. Considering each method's advantages, a combined model is proposed that combines the capabilities of these algorithms, increasing the efficiency of threat detection and optimizing the attack classification process. The experiments demonstrate that the proposed approach increases attack detection accuracy by 3–7 % and reduces response time compared to using individual machine learning algorithms. In addition, the combined model contributes to resource optimization, which is a critical factor for deploying scalable solutions in real-world conditions. Special attention is paid to the hybrid model that combines autoencoders and the Random Forest algorithm. Its effectiveness has been confirmed in test environments, where better results in detecting network anomalies were demonstrated compared to the use of only one algorithm. The proposed approach allows not only to increase the level of protection of information systems, but also to provide flexibility in configuration, which makes the model suitable for use in a wide range of cybersecurity tasks. The results obtained can be used to improve existing cyber protection methods, in particular in the field of critical infrastructure protection, where timely detection of threats is a key security factor. The high efficiency of the combined approach confirms its feasibility for implementation in network traffic monitoring systems and cybersecurity in general.

Keywords: *cybersecurity, machine learning, distributed systems, security algorithms, optimization, information protection, information security, information systems, digital technologies, information, threats.*