

ДОДАТОК А

Графічний матеріал кваліфікаційної роботи

кваліфікаційна робота

Метод виявлення мережних аномалій з використанням машинного навчання

Виконала:
студентка гр. СПМ-23-5
Глоба Є.Ю.

Керівник:
доц. каф. ЕОМ,
к.т.н. Федорченко В.М.

Мета роботи та завдання

2

Метою роботи є розробка, реалізація та експериментальне обґрунтування удосконаленого методу виявлення аномалій у корпоративній мережі, що базується на гібридному нейромережевому підході та здатен забезпечити високу точність, швидкодію й адаптивність в умовах динамічного мережевого середовища.

Об'єктом дослідження є мережевий трафік корпоративної інформаційної системи, який аналізується з метою виявлення аномальної поведінки, що може свідчити про потенційні порушення інформаційної безпеки, такі як кіберзагрози, технічні збої або несанкціоновані дії всередині мережі..

Задачі:

- ❖ проаналізувати сучасні методи виявлення аномалій, включаючи статистичні, сигнатурні, евристичні та алгоритми машинного навчання, з метою виявлення їхніх сильних і слабких сторін;
- ❖ сформулювати вимоги до ефективного методу виявлення аномалій з урахуванням специфіки корпоративного трафіку, масштабованості та реального часу обробки;
- ❖ розробити алгоритм виявлення аномалій на основі гібридної нейромережевої архітектури з урахуванням особливостей попередньої обробки мережевих даних;
- ❖ реалізувати програмний прототип запропонованого методу з використанням сучасних інструментів і бібліотек (зокрема Python, TensorFlow або PyTorch);
- ❖ створити тестове середовище для моделювання нормального та аномального трафіку з метою перевірки ефективності реалізованого рішення;
- ❖ провести експериментальну оцінку методу за критеріями точності, чутливості, швидкодії та витрат ресурсів.

Методи виявлення аномалій			
Сигнаурний аналіз	Статистичні методи	Підходи машинного навчання	Гібридні моделі
Таблиці сигнатур	Аналіз середнього значення	Decision Trees	Signature + ML
Пошук за шаблоном	Аналіз дисперсії	Random Forest	Statistical + ML
Бінарний сигнаурний аналіз	Z-оцінка	Support Vector Machines	Autoencoder + LSTM
Аналіз регулярних виразів	Методи порогового контролю	k-Nearest Neighbors	ML + Rule-Based Systems
Хеш-функції для сигнатур	Індикатори міжквартального розмаху	Naive Bayes	Anomaly + Signature Hybrid IDS
Сигнаури на основі правил	Детектування на основі ковзного вікна	Gradient Boosting	Cluster + Classifier
Сигнаури для IDS/IPS	Байєсівський аналіз	Neural Networks	Statistical Preprocessing + Deep Learning
Порівняння з базою відомих атак	Перевірка гіпотез	Autoencoders	
Контекстний сигнаурний аналіз	Аномалії в часових рядах на основі сезонних статистичних моделей	LSTM	
	Кластеризація на основі щільності	Isolation Forest	
	Метод основних компонент	One-Class SVM	
		DBSCAN	
		Self-Organizing Maps	
		Deep Belief Networks	
		Gaussian Mixture Models	

Порівняльний аналіз існуючих методів

Метод	Переваги
Сигнаурний аналіз	Висока точність для відомих атак; швидкість реагування; простота реалізації
Статистичні методи	Можливість виявляти невідомі аномалії; інтерпретованість результатів; незалежність від баз загроз
Машинне навчання	Адаптивність до змін мережевого середовища; здатність до виявлення прихованих закономірностей
Гібридні моделі	Поєднання переваг сигнаурних та інтелектуальних методів; висока гнучкість і ефективність
Метод	Недоліки
Сигнаурний аналіз	Неможливість виявлення нових або обфускованих атак; потреба в постійному оновленні бази сигнатур
Статистичні методи	Низька ефективність у динамічному середовищі; чутливість до вибору статистичних порогів
Машинне навчання	Високі обчислювальні витрати; складність налаштування і потреба у великих масивах даних
Гібридні моделі	Складна інтеграція; необхідність глибокої експертизи для супроводу; збільшення системних вимог
Метод	Потреба в навчанні
Сигнаурний аналіз	Немає
Статистичні методи	Потрібна початкова побудова статистичних моделей
Машинне навчання	Необхідне навчання на великій кількості даних
Гібридні моделі	Необхідне навчання для інтелектуальної компоненти
Метод	Здатність до виявлення нових атак
Сигнаурний аналіз	Немає
Статистичні методи	Обмежена
Машинне навчання	Висока
Гібридні моделі	Висока

Метод виявлення аномалій. Загальна структура 5

На першому етапі здійснюється **збір вхідних даних**. Джерелами інформації можуть бути сирі пакети мережевого трафіку, NetFlow-записи, журнали доступу, логи систем безпеки, проксі-серверів або SIEM-платформ. Дані мають охоплювати широкий спектр параметрів, зокрема IP-адреси, порти, протоколи, часові мітки, обсяги переданої інформації, кількість з'єднань тощо.

Далі відбувається **попередня обробка**, яка включає очищення від шумів і пошкоджених записів, нормалізацію масштабів числових значень, обчислення похідних характеристик і агрегацію даних до рівня потоків або з'єднань. У цьому ж модулі формується вектор ознак, придатний для подачі на вхід моделі машинного навчання.


Наступний етап передбачає **побудову профілю "нормальної" поведінки** на основі історичних або довірених даних. За допомогою навчання без учителя (unsupervised learning), як-от автоенкодерів або кластеризації, створюється модель, яка відтворює характерну структуру типового трафіку. У разі гібридного підходу до цієї моделі можуть бути додані рекурентні компоненти (LSTM), які враховують часову залежність подій.

У процесі **реального функціонування системи** нові вхідні дані аналізуються на відповідність побудованій моделі. Визначальною ознакою аномалії є значення похибки реконструкції або класифікаційна оцінка, що виходить за межі допустимого порогу. При перевищенні цього порогу трафік вважається підозрілим, формується інцидент, який може бути переданий до системи реагування або для ручного перегляду.

Додатково реалізується **модуль логуювання та моніторингу**, який фіксує виявлені аномалії, записує статистику роботи, генерує звітність та забезпечує візуалізацію результатів.

Фінальним етапом є **динамічне оновлення поведінкового профілю**, що базується на повторному навчанні моделі із застосуванням нових даних, які підтверджено як "безпечні". Це дозволяє системі адаптуватися до змін у користувацьких шаблонах, зміни графіку роботи, появи нових сервісів або технологій доступу без втрати чутливості до загроз.

Вибір підходу на основі гібридної нейромережевої архітектури 6



Критерії ефективності методу

Критерій	Опис
Точність класифікації	Загальна здатність правильно класифікувати трафік як нормальний або аномальний
Чутливість	Здатність виявити всі істинні аномалії (мінімізує хибнонегативні спрацювання)
Прецизійність	Точність серед виявлених аномалій (мінімізує хибнопозитивні спрацювання)
F1-міра	Гармонійне середнє між показниками точності та повноти
AUC-ROC	Узагальнена здатність моделі відокремлювати класи незалежно від порогу
Час реакції	Час між появою аномалії та її виявленням
Пропускна здатність	Кількість оброблених зразків за одиницю часу
Масштабованість	Можливість масштабування моделі до більших обсягів даних
Ресурсна ефективність	Здатність моделі працювати на обмежених ресурсах
Стійкість до змін	Здатність адаптуватися до нових умов без перенавчання
Узагальнювальна здатність	Стійкість моделі до нових сценаріїв і здатність узагальнювати знання

Архітектура системи виявлення аномалій у корпоративній мережі



Вибір програмних засобів



Фрагмент коду програми. Процес навчання

```

import pandas as pd
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
from sklearn.metrics import roc_curve, auc, confusion_matrix, ConfusionMatrixDisplay
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Input, Dense
from tensorflow.keras.optimizers import Adam
import matplotlib.pyplot as plt
import seaborn as sns

# filepath_sans
def generate_data():
    np.random.seed(42)
    n_normal = 1000
    n_anomalous = 50
    normal_data = {
        "duration": np.random.exponential(2.0, n_normal),
        "src_bytes": np.random.normal(100, 50, n_normal),
        "dst_bytes": np.random.normal(250, 60, n_normal),
        "count": np.random.randint(1, 20, n_normal),
        "srv_count": np.random.randint(1, 15, n_normal),
        "same_srv_rate": np.random.uniform(0.5, 1.0, n_normal),
        "diff_srv_rate": np.random.uniform(0.0, 0.2, n_normal),
        "dst_host_count": np.random.randint(10, 100, n_normal),
        "dst_host_srv_count": np.random.randint(5, 100, n_normal),
        "dst_host_same_srv_rate": np.random.uniform(0.0, 1.0, n_normal),
        "label": [0]*n_normal
    }
    anomalous_data = {
        "duration": np.random.exponential(10.0, n_anomalous),
        "src_bytes": np.random.normal(1000, 200, n_anomalous),
        "dst_bytes": np.random.normal(30, 15, n_anomalous),
        "count": np.random.randint(10, 100, n_anomalous),
        "srv_count": np.random.randint(20, 60, n_anomalous),
        "same_srv_rate": np.random.uniform(0.0, 0.3, n_anomalous),
        "diff_srv_rate": np.random.uniform(0.7, 1.0, n_anomalous),
        "dst_host_count": np.random.randint(200, 255, n_anomalous),
        "dst_host_srv_count": np.random.randint(100, 255, n_anomalous),
        "dst_host_same_srv_rate": np.random.uniform(0.0, 0.4, n_anomalous),
        "label": [1]*n_anomalous
    }
    df = pd.concat([pd.DataFrame(normal_data), pd.DataFrame(anomalous_data)], ignore_index=True)
    return df.sample(frac=1.0, random_state=1).reset_index(drop=True)

# 1. Data
df = generate_data()
X = df.drop(columns=["label"]).values
y = df["label"].values
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y, test_size=0.3, random_state=42)
X_train_norm = X_train[y_train == 0]

# 2. Autoencoder
input_dim = X_train.shape[1]
input_layer = Input(shape=(input_dim,))
encoded = Dense(6, activation='relu')(input_layer)
encoded = Dense(6, activation='relu')(encoded)
decoded = Dense(6, activation='relu')(encoded)
output_layer = Dense(input_dim, activation='linear')(decoded)
autoencoder = Model(inputs=input_layer, outputs=output_layer)
autoencoder.compile(optimizer=Adam(learning_rate=0.001), loss='mse')
history = autoencoder.fit(X_train_norm, X_train_norm, epochs=50, batch_size=32,

```

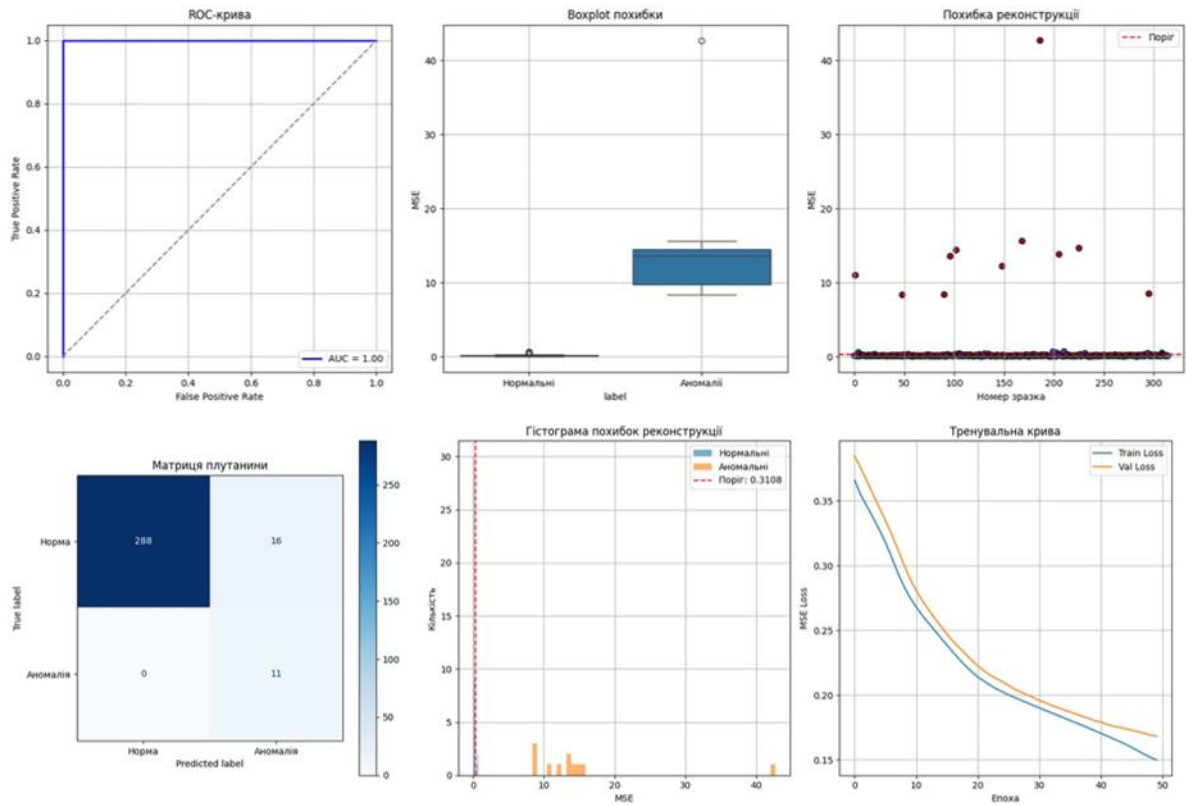
```

Epoch 26/50
20/20 — 0s 5ms/step - loss: 0.1970 - val_loss: 0.2075
Epoch 27/50
20/20 — 0s 7ms/step - loss: 0.1991 - val_loss: 0.2044
Epoch 28/50
20/20 — 0s 5ms/step - loss: 0.2036 - val_loss: 0.2024
Epoch 29/50
20/20 — 0s 5ms/step - loss: 0.1998 - val_loss: 0.2001
Epoch 30/50
20/20 — 0s 5ms/step - loss: 0.1873 - val_loss: 0.1983
Epoch 31/50
20/20 — 0s 5ms/step - loss: 0.1878 - val_loss: 0.1958
Epoch 32/50
20/20 — 0s 5ms/step - loss: 0.1834 - val_loss: 0.1941
Epoch 33/50
20/20 — 0s 5ms/step - loss: 0.1845 - val_loss: 0.1919
Epoch 34/50
20/20 — 0s 5ms/step - loss: 0.1839 - val_loss: 0.1903
Epoch 35/50
20/20 — 0s 5ms/step - loss: 0.1828 - val_loss: 0.1885
Epoch 36/50
20/20 — 0s 7ms/step - loss: 0.1813 - val_loss: 0.1869
Epoch 37/50
20/20 — 0s 5ms/step - loss: 0.1800 - val_loss: 0.1852
Epoch 38/50
20/20 — 0s 5ms/step - loss: 0.1748 - val_loss: 0.1835
Epoch 39/50
20/20 — 0s 5ms/step - loss: 0.1753 - val_loss: 0.1822
Epoch 40/50
20/20 — 0s 5ms/step - loss: 0.1718 - val_loss: 0.1801
Epoch 41/50
20/20 — 0s 5ms/step - loss: 0.1751 - val_loss: 0.1792
Epoch 42/50
20/20 — 0s 5ms/step - loss: 0.1724 - val_loss: 0.1772
Epoch 43/50
20/20 — 0s 5ms/step - loss: 0.1630 - val_loss: 0.1760
Epoch 44/50
20/20 — 0s 5ms/step - loss: 0.1615 - val_loss: 0.1751
Epoch 45/50
20/20 — 0s 5ms/step - loss: 0.1722 - val_loss: 0.1739
Epoch 46/50
20/20 — 0s 5ms/step - loss: 0.1586 - val_loss: 0.1727
Epoch 47/50
20/20 — 0s 5ms/step - loss: 0.1604 - val_loss: 0.1716
Epoch 48/50
20/20 — 0s 5ms/step - loss: 0.1541 - val_loss: 0.1705
Epoch 49/50
20/20 — 0s 5ms/step - loss: 0.1516 - val_loss: 0.1691
Epoch 50/50

```

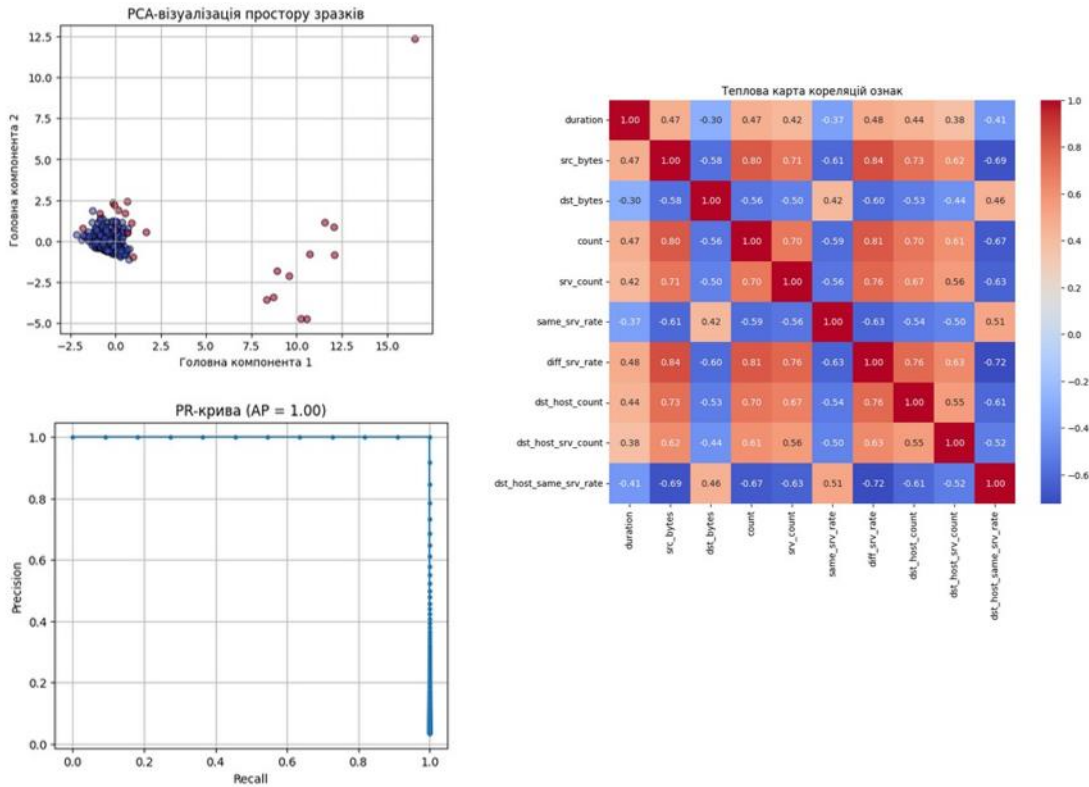
Результати роботи

11



Результати роботи

12



АПРОБАЦІЯ

Є. Ю. Глоба¹, В. Р. Смірнов¹, М. С. Нараєвський¹
¹Харківський національний технічний університет радіоелектроніки, Харків, Україна

МЕТОД ВИЯВЛЕННЯ АНОМАЛІЙ В КОРПОРАТИВНІЙ МЕРЕЖІ

Анотація. Актуальність. На сучасному етапі розвитку інформаційних технологій та цифрової економіки корпоративні мережі є критично важливим компонентом бізнес-інфраструктури. Ефективна функціонування корпоративних мереж забезпечує безпеку роботи підприємств, високу продуктивність працівників та обробку конфіденційної інформації. Однак з ростом складності та масштабу мережних структур зростає й кількість загроз, серед яких особливу небезпеку становлять аномальні події, що можуть бути ознаками кібератаки, витоку даних, технічних збоїв або інших потенційно шкідливих ситуацій. Актуальність дослідження полягає в тому, що головні метри виявлення аномалій в мережах дозволяють максимізувати точність та швидкість у реальних умовах експлуатації. Тому необхідно розробити та вдосконалити методи, які здатні ефективно адаптуватися до мінливих умов функціонування мереж і надавати точні результати в режимі реального часу. Метою дослідження є розробка та оптимізація алгоритму виявлення аномалій в корпоративній мережі на основі моделі автоенкодера, який дозволяє ефективно ідентифікувати відхилення від нормального мережевого трафіку без потреби в попередньому знанні даних. Результати дослідження. У процесі дослідження було згенеровано дані, які імітують активність мережі. Після навчання нейронної мережі на нормальних даних спостерігається чітка роздільна класа за критерієм пошкодження реконструкції. Гістограми та кореліаційні аналізи на ньому показують, що вихідні дані мають певні характеристики, які можна використовувати для виявлення аномалій. Крім того, результати дослідження, що використовують автоенкодер для побудови моделі нормального мережевого трафіку, дозволяють точно та надійно виявляти аномалії в корпоративній мережі, навіть за відсутності знань про події. Запропонований підхід може бути інтегрований у систему моніторингу безпеки для виявлення потенційно шкідливих історій в режимі реального часу. Висновки. На основі моделі автоенкодера було реалізовано підхід, який дозволяє будувати помірковані профілі нормального мережевого трафіку та виявляти аномалії, чітко розділяючи нормальні і аномальні трафіки за допомогою реконструкції, а також спільність навчання мережі. Окремі результати підтверджують достовірність використання глибоких мереж для автоматичного моніторингу корпоративної безпеки, а запропонований метод може бути успішно застосований у реальних умовах експлуатації IT-інфраструктури для виявлення аномалій безпеки в режимі реального часу.

Ключові слова: корпоративна мережа, виявлення аномалій, корпоративна мережа, мережевий трафік, автоенкодер, машинне навчання, кібербезпека, реконструкція пошкодження, навчання без вчитання, нейронна мережа, профілювання поведінки, інформаційна безпека.

Вступ

Постановка проблеми. Сучасні корпоративні мережі є невід'ємною складовою цифрової інфраструктури будь-якої компанії, виконуючи над її розміру та сфери діяльності. Вони забезпечують ключові процеси, такі як передача інформації, підтримка операційних та управлінських систем, взаємодія між підрозділами, а також зв'язують вимоги до клієнтів та партнерів. В умовах постійного зростання обсягу передаваних і оброблюваних даних, а також ускладнення топологій мереж, зростає ризик виникнення небезпечних ситуацій, пов'язаних з витоком інформації, кібератаками, порушеннями безпеки тощо. Тому важливо розробити ефективні методи виявлення аномалій в мережах, які здатні адаптуватися до мінливих умов функціонування мереж і надавати точні результати в режимі реального часу. Метою дослідження є розробка та оптимізація алгоритму виявлення аномалій в корпоративній мережі на основі моделі автоенкодера, який дозволяє ефективно ідентифікувати відхилення від нормального мережевого трафіку без потреби в попередньому знанні даних. Результати дослідження. У процесі дослідження було згенеровано дані, які імітують активність мережі. Після навчання нейронної мережі на нормальних даних спостерігається чітка роздільна класа за критерієм пошкодження реконструкції. Гістограми та кореліаційні аналізи на ньому показують, що вихідні дані мають певні характеристики, які можна використовувати для виявлення аномалій. Крім того, результати дослідження, що використовують автоенкодер для побудови моделі нормального мережевого трафіку, дозволяють точно та надійно виявляти аномалії в корпоративній мережі, навіть за відсутності знань про події. Запропонований підхід може бути інтегрований у систему моніторингу безпеки для виявлення потенційно шкідливих історій в режимі реального часу. Висновки. На основі моделі автоенкодера було реалізовано підхід, який дозволяє будувати помірковані профілі нормального мережевого трафіку та виявляти аномалії, чітко розділяючи нормальні і аномальні трафіки за допомогою реконструкції, а також спільність навчання мережі. Окремі результати підтверджують достовірність використання глибоких мереж для автоматичного моніторингу корпоративної безпеки, а запропонований метод може бути успішно застосований у реальних умовах експлуатації IT-інфраструктури для виявлення аномалій безпеки в режимі реального часу.

Ключові слова: корпоративна мережа, виявлення аномалій, корпоративна мережа, мережевий трафік, автоенкодер, машинне навчання, кібербезпека, реконструкція пошкодження, навчання без вчитання, нейронна мережа, профілювання поведінки, інформаційна безпека.

вимоги адаптації до мінливих умов експлуатації, а також відсутності ефективності при роботі з великими обсягами даних у реальному часі. Ці виклики стимулюють пошук нових підходів і методів, що дозволять ефективно виявляти та класифікувати аномалії в корпоративних мережах.

Аналіз останніх досліджень і публікацій.

У сучасному науково-практичному середовищі проблема виявлення аномалій у корпоративних мережах стала одним з найбільш обговорюваних аспектів кібербезпеки та інформаційної безпеки. Розвиток мережевої інфраструктури, зростаючий обсяг трафіку, поширення хмарних сервісів і віддалених робіт значно ускладнюють завдання виявлення загроз у реальному часі. Саме тому останнім часом ставлять складним питанням інтересу до методів виявлення аномалій на основі глибокого навчання, зокрема використанням автоенкодерів, рекурсивних нейронних мереж та інших архітектур.

Важливі методи, наприклад, сигнатурний аналіз, добре працюють у певних умовах, але виявляють лише обмежену кількість аномалій. У випадку ж нечітких меж між нормальними та аномальними даними, статистичні методи та автоматичне побудовані профілі нормальних поведінок.

Стаття [1] присвячена огляду сучасних методів виявлення без знання для виявлення аномалій у великих даних. У ній розглядаються досягнення в галузі обробки та аналізу даних, які привели до виникнення великої кількості висхідних систем. Стаття підкреслює важливість надійності знань із таких даних, окремі виявлення аномалій або аномалій, що можуть сигналізувати про пошкодження, порушення чи інші події.

В роботі [2] автори проводять порівняння класичних алгоритмів машинного навчання і роблять висновок, що гібридні методи (об'єднання класичних і фізичних ознак) переважають по точності базові методи.

Особливу увагу приділяють методам глибокого навчання, зокрема автоенкодерам, LSTM-моделі та рекурсивним нейронним мережам. Вони дозволяють моделювати складну часову структуру мережевого трафіку та виявляти аномалії без необхідності знати попередній стан мережі.

У дослідженні [3] описано Keras – систему, що використовує автоенкодер для виявлення аномалій на основі Flow-дані. Вона працює в реальному часі і високо обчислювально складно, що робить її придатною для корпоративних мереж.

Стаття [4] присвячена огляду сучасних підходів

до виявлення аномалій в мережах. Авторі пропонують новий підхід, який використовує для виявлення таких аномалій. Зокрема, розглядається метод машинного навчання, глибокого навчання, машинного навчання.

Також зазначається проблема обсягу даних, який впливає на швидкість обробки даних, а також розширюється кількість вибору даних, які мають різноманітність і пропонують створити нові сценарії на основі реального корпоративного трафіку.

Метою роботи є розробка удосконаленого методу виявлення аномалій у корпоративних мережах, який базується на суміші підходів з фізики машинного навчання та глибокого навчання. Запропонований метод має забезпечити високу точність, швидкодію, адаптивність до динамічних змін умов і високий рівень захисту спрацювань, що є критично важливим для оперативного прийняття рішень та забезпечення надійності функціонування інформаційних систем підприємств.

Основний матеріал

Проблема виявлення аномалій у корпоративних мережах уже давно є предметом наукового дослідження в галузі інформаційної безпеки. У рамках підходу до її вирішення застосовуються як класичні методи аналізу даних, так і сучасні алгоритми машинного навчання та глибокого навчання [5]. Основна мета таких методів полягає у тому, щоб часом виявити невідомі поведінки в мережевому трафіку, які потенційно можуть свідчити про атаку, або про критичні відхилення в роботі системи. У цьому контексті важливою є здатність системи адекватно реагувати на зміни в активності мережі, навіть за відсутності знань сигнатурних загроз.

Традиційні методи, зокрема сигнатурний аналіз [7], ґрунтуються на виявленні як відомої поведінки, так і нових ознак, що з'являються у базі даних сигнатур. Вони ефективні в аналізі відомих загроз, однак повільно реагують на нові, раніше невідомі форми атак, особливо такі, як нові типи атак машинного навчання. Крім того, сигнатурні системи вимагають постійного оновлення баз даних і часто створюють велике навантаження на систему безпеки через велику кількість правил.

У порівнянні сигнатурних методів, анормаліорозпізнавальні методи ґрунтуються на побудові моделей «нормального» поведінки мережі, а відхилення від цієї моделі вказують на потенційно шкідливі події. Порівняння класичного підходу з використанням підтримки і може бути маркованими аномаліями. Такі методи використовують методи аналізу або набору статистик, проте вони здатні виявляти

Глоба Є. Ю., Смірнов В. Р., Нараєвський М. С. Метод виявлення аномалій в корпоративній мережі Системи управління, навігації та зв'язку, вип.3. Полтава, 2025. С. 154-158.

ВИСНОВКИ

У результаті виконаного дослідження було розроблено та експериментально апробовано новий підхід до виявлення аномалій у корпоративному мережевому середовищі, що базується на гібридній нейронмережовій архітектурі з використанням автоенкодера, доповненого компонентами LSTM. Такий підхід дозволяє ефективно моделювати нормальну поведінку мережевого трафіку, виявляючи відхилення на основі похібки реконструкції без необхідності маркованих даних. Ретельний аналіз існуючих методів від сигнатурного аналізу до глибоких моделей машинного навчання дозволив обґрунтувати вибір саме гібридного підходу як найбільш придатного для роботи в умовах динамічного й неоднорідного середовища сучасних інформаційних систем.

Було створено архітектуру програмного прототипу, що включає модулі збору, обробки, аналізу, моніторингу та адаптації, реалізовані мовою Python із використанням сучасних бібліотек, зокрема Scapy, Pandas, Scikit-learn, TensorFlow та Loguru. Особливу увагу було приділено аспектам адаптації до змін у мережі, зокрема через механізми оновлення профілю поведінки на основі довірених даних та використання потокової обробки трафіку. Експериментальне тестування прототипу, проведене на стилізованому наборі даних, продемонструвало високу точність моделі в задачах розпізнавання аномальної активності. Графічні результати, зокрема ROC-крива, гістограми та матриця плутаннини, засвідчили, що система має відмінну здатність до відокремлення нормальної та підозрілої поведінки навіть за умов слабкої апіорної інформації та відсутності маркування. Висока площа під ROC-кривою (AUC = 1.00), низька частка хибнопозитивних спрацювань та стабільність навчання свідчать про добру узагальнювальну здатність та надійність розробленої моделі.

Таким чином, розроблений метод підтвердив свою ефективність як у теоретичному обґрунтуванні, так і в практичній реалізації. Він поєднує точність виявлення, адаптивність до нових умов, низьку залежність від маркованих даних і здатність до роботи в реальному часі. Це робить його перспективним рішенням для впровадження в інфраструктуру кіберзахисту корпоративних мереж, де актуальною є потреба у безперервному моніторингу, ранньому виявленні загроз і мінімізації ризиків безпеки. Подальші дослідження можуть бути зосереджені на вдосконаленні методів самонавчання, інтеграції з SIEM-платформами, а також на масштабуванні архітектури для роботи з великими розподіленими системами в реальному середовищі.

ДОДАТОК Б

Програмний код

Б.1 Встановлення бібліотек

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
from sklearn.model_selection import train_test_split
from sklearn.metrics import roc_curve, auc, confusion_matrix,
ConfusionMatrixDisplay
from tensorflow.keras.models import Model
from tensorflow.keras.layers import Input, Dense
from tensorflow.keras.optimizers import Adam
import matplotlib.pyplot as plt
import seaborn as sns
```

Б.2 Генерація даних

```
def generate_data():
    np.random.seed(42)
    n_normal = 1000
    n_anomalous = 50
    normal_data = {
        "duration": np.random.exponential(2.0, n_normal),
        "src_bytes": np.random.normal(300, 50, n_normal),
        "dst_bytes": np.random.normal(250, 60, n_normal),
        "count": np.random.randint(1, 20, n_normal),
        "srv_count": np.random.randint(1, 15, n_normal),
        "same_srv_rate": np.random.uniform(0.5, 1.0, n_normal),
        "diff_srv_rate": np.random.uniform(0.0, 0.2, n_normal),
        "dst_host_count": np.random.randint(10, 100, n_normal),
        "dst_host_srv_count": np.random.randint(5, 100,
n_normal),
        "dst_host_same_srv_rate": np.random.uniform(0.6, 1.0,
n_normal),
        "label": [0]*n_normal
    }
    anomalous_data = {
        "duration": np.random.exponential(10.0, n_anomalous),
        "src_bytes": np.random.normal(1000, 200, n_anomalous),
        "dst_bytes": np.random.normal(30, 15, n_anomalous),
        "count": np.random.randint(30, 100, n_anomalous),
        "srv_count": np.random.randint(20, 60, n_anomalous),
        "same_srv_rate": np.random.uniform(0.0, 0.3,
n_anomalous),
```

```

        "diff_srv_rate": np.random.uniform(0.7, 1.0,
n_anomalous),
        "dst_host_count": np.random.randint(200, 255,
n_anomalous),
        "dst_host_srv_count": np.random.randint(100, 255,
n_anomalous),
        "dst_host_same_srv_rate": np.random.uniform(0.0, 0.4,
n_anomalous),
        "label": [1]*n_anomalous
    }
    df = pd.concat([pd.DataFrame(normal_data),
pd.DataFrame(anomalous_data)], ignore_index=True)
    return df.sample(frac=1.0,
random_state=42).reset_index(drop=True)

# 1. Дані
df = generate_data()
X = df.drop(columns=["label"]).values
y = df["label"].values
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y,
test_size=0.3, random_state=42)
X_train_norm = X_train[y_train == 0]

# 2. Автоенкодер
input_dim = X_train.shape[1]
input_layer = Input(shape=(input_dim,))
encoded = Dense(8, activation='relu')(input_layer)
encoded = Dense(4, activation='relu')(encoded)
decoded = Dense(8, activation='relu')(encoded)
output_layer = Dense(input_dim, activation='linear')(decoded)
autoencoder = Model(inputs=input_layer, outputs=output_layer)
autoencoder.compile(optimizer=Adam(learning_rate=0.001),
loss='mse')
history = autoencoder.fit(X_train_norm, X_train_norm, epochs=50,
batch_size=32,
                                shuffle=True, validation_split=0.1,
verbose=1)

```

Б.3 Виявлення аномалій та візуалізація

```

X_test_pred = autoencoder.predict(X_test)
mse = np.mean(np.square(X_test - X_test_pred), axis=1)
threshold = np.percentile(mse[y_test == 0], 95)
predictions = (mse > threshold).astype(int)
fpr, tpr, _ = roc_curve(y_test, mse)
roc_auc = auc(fpr, tpr)
error_df = pd.DataFrame({'MSE': mse, 'label': y_test})

plt.figure(figsize=(18, 12))

```

```

plt.subplot(2, 3, 1)
plt.plot(fpr, tpr, color='blue', lw=2, label=f'AUC =
{roc_auc:.2f}')
plt.plot([0, 1], [0, 1], color='gray', linestyle='--')
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('ROC-крива')
plt.legend()
plt.grid(True)

plt.subplot(2, 3, 2)
sns.boxplot(x='label', y='MSE', data=error_df)
plt.xticks([0, 1], ['Нормальні', 'Аномалії'])
plt.title("Boxplot похибки")
plt.grid(True)

plt.subplot(2, 3, 3)
plt.scatter(range(len(mse)), mse, c=y_test, cmap='coolwarm',
edgecolors='k')
plt.axhline(y=threshold, color='red', linestyle='--',
label='Попіг')
plt.title("Похибка реконструкції")
plt.xlabel("Номер зразка")
plt.ylabel("MSE")
plt.legend()
plt.grid(True)

plt.subplot(2, 3, 4)
cm = confusion_matrix(y_test, predictions)
disp = ConfusionMatrixDisplay(confusion_matrix=cm,
display_labels=["Норма", "Аномалія"])
disp.plot(ax=plt.gca(), cmap='Blues', values_format='d')
plt.title("Матриця плутанини")
plt.grid(False)

plt.subplot(2, 3, 5)
plt.hist(mse[y_test == 0], bins=50, alpha=0.6,
label="Нормальні")
plt.hist(mse[y_test == 1], bins=50, alpha=0.6,
label="Аномальні")
plt.axvline(threshold, color='red', linestyle='--',
label=f'Попіг: {threshold:.4f}')
plt.title("Гістограма похибок реконструкції")
plt.xlabel("MSE")
plt.ylabel("Кількість")
plt.legend()
plt.grid(True)

plt.subplot(2, 3, 6)
plt.plot(history.history['loss'], label='Train Loss')
plt.plot(history.history['val_loss'], label='Val Loss')
plt.title('Тренувальна крива')

```

```
plt.xlabel('Епоха')
plt.ylabel('MSE Loss')
plt.legend()
plt.grid(True)

plt.tight_layout()
plt.show()
```

Б.4 Додатковий аналіз результатів

```
# --- PCA-візуалізація простору ознак ---
from sklearn.decomposition import PCA
pca = PCA(n_components=2)
X_pca = pca.fit_transform(X_test)
plt.figure(figsize=(6, 5))
plt.scatter(X_pca[:, 0], X_pca[:, 1], c=predictions,
            cmap='coolwarm', alpha=0.6, edgecolors='k')
plt.title("PCA-візуалізація простору зразків")
plt.xlabel("Головна компонента 1")
plt.ylabel("Головна компонента 2")
plt.grid(True)
plt.show()
# --- Precision-Recall крива ---
from sklearn.metrics import precision_recall_curve,
average_precision_score

precision, recall, _ = precision_recall_curve(y_test, mse)
avg_precision = average_precision_score(y_test, mse)

plt.figure(figsize=(6, 5))
plt.plot(recall, precision, marker='.')
plt.title(f'PR-крива (AP = {avg_precision:.2f})')
plt.xlabel('Recall')
plt.ylabel('Precision')
plt.grid(True)
plt.show()
# --- Теплова карта кореляцій ознак ---
plt.figure(figsize=(10, 8))
sns.heatmap(pd.DataFrame(X, columns=df.columns[:-1]).corr(),
            annot=True, fmt=".2f", cmap="coolwarm")
plt.title("Теплова карта кореляцій ознак")
plt.show()
```