

## ДОДАТОК А

Перелік посилань відповідно до наукових досліджень кафедри

2. Kachko O., Bilous N, Semerkov V. Research on methods for secure web applications development // Information Technologies in Innovation Business (ITIB). Proceedings of ITIB, Kharkiv, Ukraine. – 7-9 October 2015. С. 24-27.

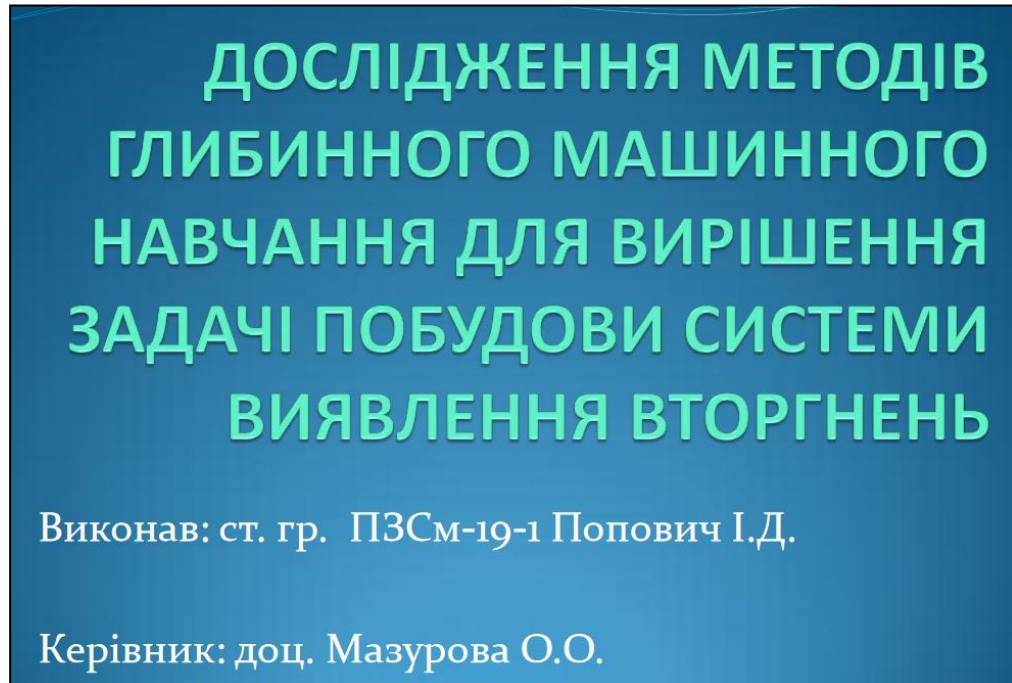
6. Єрохін А., Пашкевич Є. Исследование методов и средств мониторинга серверов // Системи обробки інформації. 2011. №4. С. 188-192.

13. Maksym Bekuzarov, Mariya Shirokopetleva, Oleksandr Samantsov, Oksana Mazurova Neural Network Architecture Editor With Code Generation // Problem of Infocommunications. Science and Technolpgy (PIC S&T'2020), Kharkiv, Ukraine. – 6-9 October 2020 (Scopus). С. 35-39.

14. Мазурова О., Широкопетлева М. Поддержка Проектирования Баз Данных // Інформаційні системи та технології: матеріали міжнар. наук.-техн. конф, Харків, Україна. – 10-15 вересня 2018. С. 319-322.

23. Andrey Arsenov, Igor Ruban, Kyrylo Smelyakov, Anastasiya Chupryna . Evolution of Convolutional Neural Network Architecture in Image Classification Problems // Selected Papers of the XVIII International Scientific and Practical Conference on IT and Security (ITS). Kiyv, Ukraine. 2019. С. 9-10.

ДОДАТОК Б  
Слайди презентації

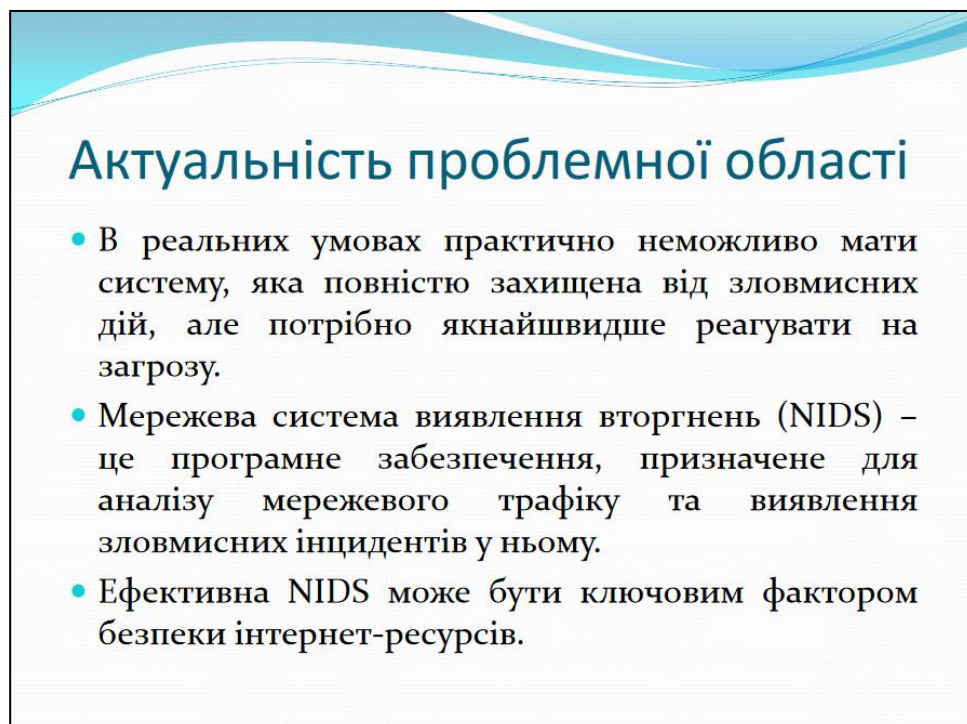


**ДОСЛІДЖЕННЯ МЕТОДІВ  
ГЛИБИННОГО МАШИННОГО  
НАВЧАННЯ ДЛЯ ВИРІШЕННЯ  
ЗАДАЧІ ПОБУДОВИ СИСТЕМИ  
ВИЯВЛЕННЯ ВТОРГНЕНЬ**

Виконав: ст. гр. ПЗСм-19-1 Попович І.Д.

Керівник: доц. Мазурова О.О.

Рисунок Б.1 – Вступний слайд



**Актуальність проблемної області**

- В реальних умовах практично неможливо мати систему, яка повністю захищена від зловмисних дій, але потрібно якнайшвидше реагувати на загрозу.
- Мережева система виявлення вторгнень (NIDS) – це програмне забезпечення, призначене для аналізу мережевого трафіку та виявлення зловмисних інцидентів у ньому.
- Ефективна NIDS може бути ключовим фактором безпеки інтернет-ресурсів.

Рисунок Б.2 – Аналіз проблемної області



Рисунок Б.3 – Аналоги

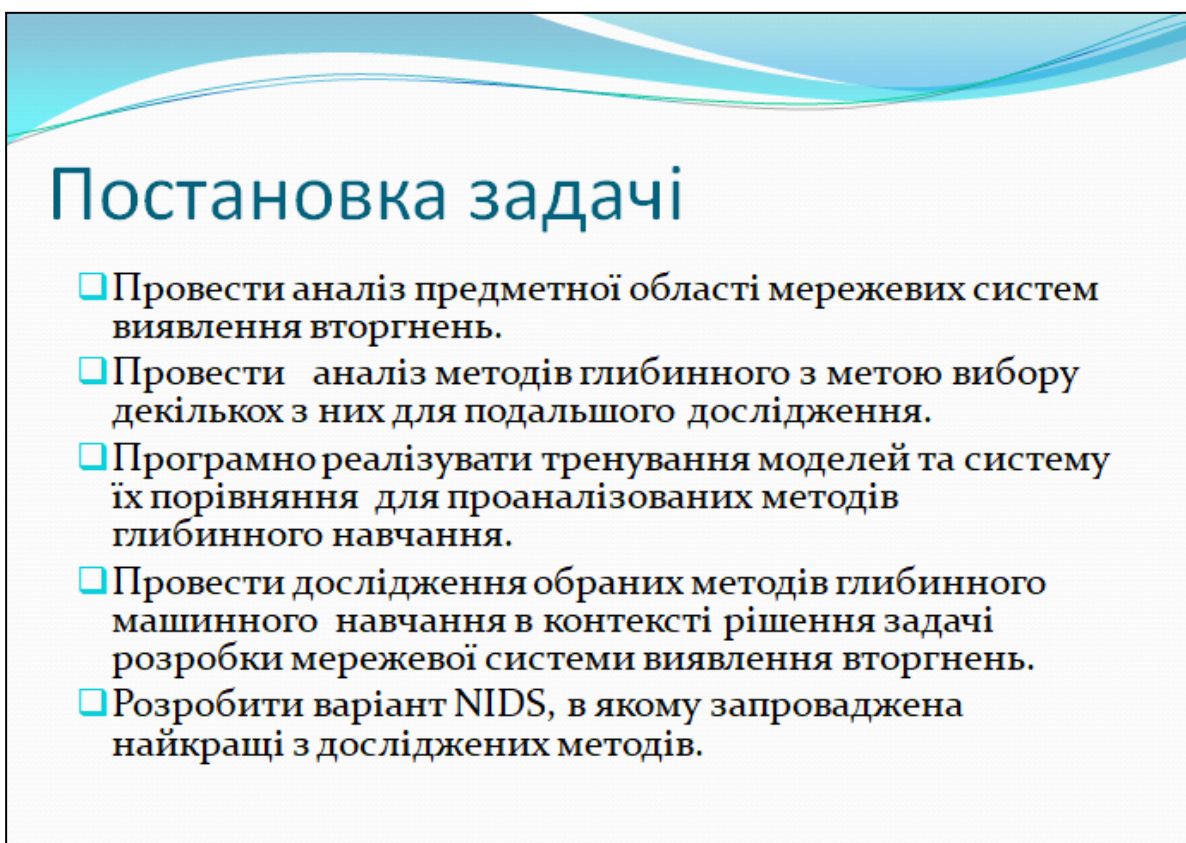


Рисунок Б.4 – Постановка задачі

## Аналіз предметної області

- NIDS читає всі вхідні пакети та шукає будь-які підозрілі зразки. Коли виявляються загрози, виходячи з її серйозності, система може вжити таких дій, як сповіщення адміністраторів або заборона доступу до мережі вихідної IP-адреси.
- Мережева система виявлення вторгнень здебільшого розміщується в стратегічних точках мережі, щоб мати можливість стежити за трафіком, який прямує до або з різних пристроїв цієї мережі.

Рисунок Б.5 – Аналіз проблемної області



Рисунок Б.6 – Методи машинного навчання






Рисунок Б.9 – Дослідження методів: SVM



Рисунок Б.10 – Альтернативний метод

## Планування експерименту

- ❑ Підготування датасету.
- ❑ Тренування моделей.
- ❑ Тестування натренованих моделей на тестових даних.
- ❑ Порівняння результатів.

Рисунок Б.11 – Планування експерименту

## Підготування датасету

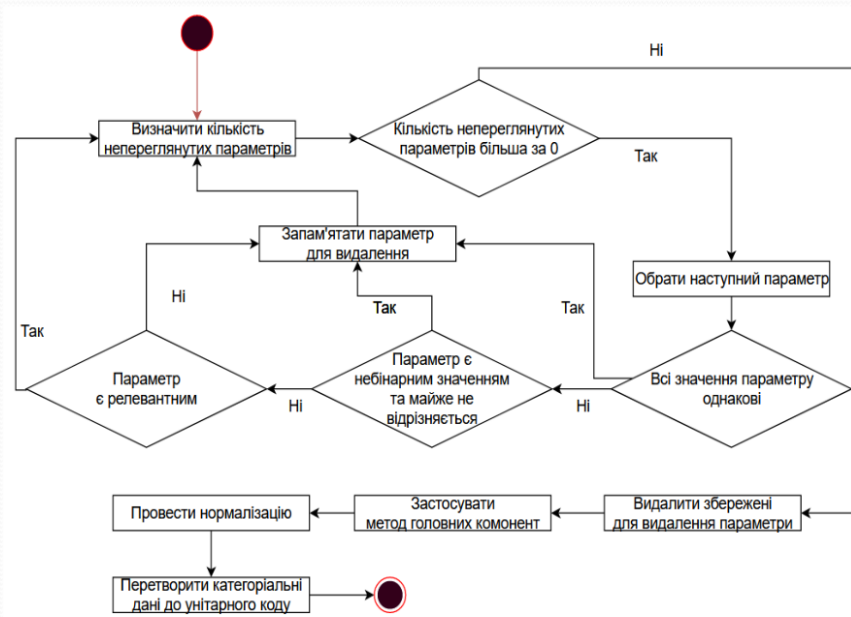


Рисунок Б.12 – Підготування датасету

## Опис датасету

У якості датасету обрано набір даних, розроблений Канадським університетом з кібербезпеки шляхом емуляції атак, та збирання даних мережевого трафіку.

	srv_error_rate	error_rate	srv_error_rate	same_srv_rate	diff_srv_rate	srv_diff_host_rate	dst_host_count	dst_host_srv_count
120	0.0	1.0	1.0	0.08	0.07	0.0	255	20
121	0.0	1.0	1.0	0.07	0.07	0.0	255	19
122	1.0	0.0	0.0	0.03	0.07	0.0	255	8
123	0.0	0.0	0.1	1.00	0.00	0.2	255	250
124	1.0	0.0	0.0	0.02	0.05	0.0	255	8
125	0.0	0.0	0.0	1.00	0.00	0.0	195	10

Рисунок Б.13 – Опис датасету

## Гіперпараметри моделей

	LSTM	GRU	LSTM-SVM	GRU-SVM
Розмір батчу	256	256	256	256
Кількість клітин	85	90	85	90
Процент відсіву	0.85	0.85	0.8	0.8
Коефіцієнт навчання	1e-6	1e-5	1e-6	1e-5
Кількість епох	5	5	6	6

Рисунок Б.14 – Гіперпараметри моделей

## Середа для тренування

Tool	Tf.keras
CPU	Intel Core i5 9300H
GPU	Nvidia GTX 1660TI
RAM	16GB

Рисунок Б.15 – Середа для тренування

## Результати експерименту

	Точність (%)	Вірні позитивні відповіді (%)	Невірні позитивні відповіді (%)
CNN	95,4	93,6	3,3
LSTM	96,8	94,9	2,5
LSTM+SVM	96,4	95,2	3,1
GRU+SVM	96,1	94,7	2,7

Рисунок Б.16 – Результати експерименту

## Розробка програмної системи

Основний функціонал:

- ❑ перегляд підозрілих подій у системі;
- ❑ сортування подій за різними критеріями;
- ❑ будівлення графіків аномалій у залежності від часу;
- ❑ сповіщення адміністраторів.

Рисунок Б.17 – Розробка програмної системи

## Схема бази даних

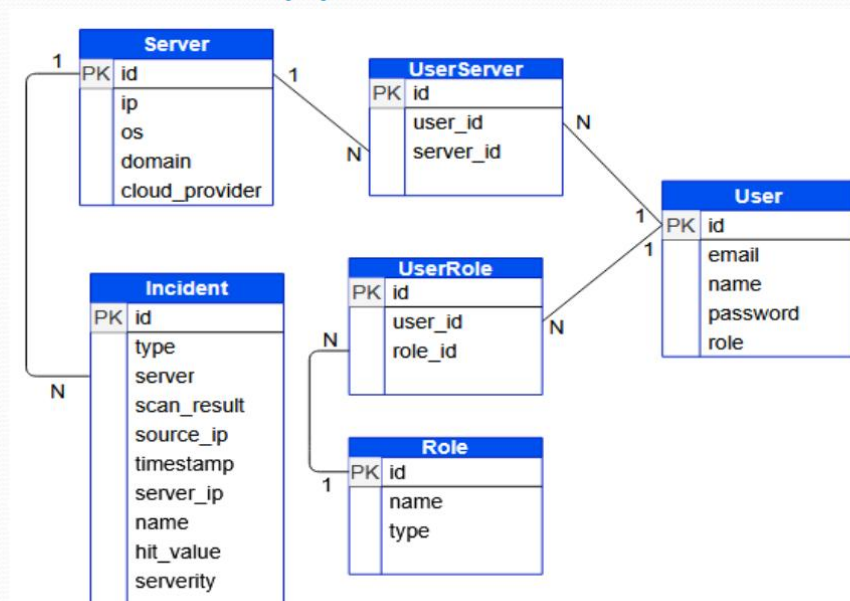


Рисунок Б.18 – Схема бази даних

## Діаграма розгортання

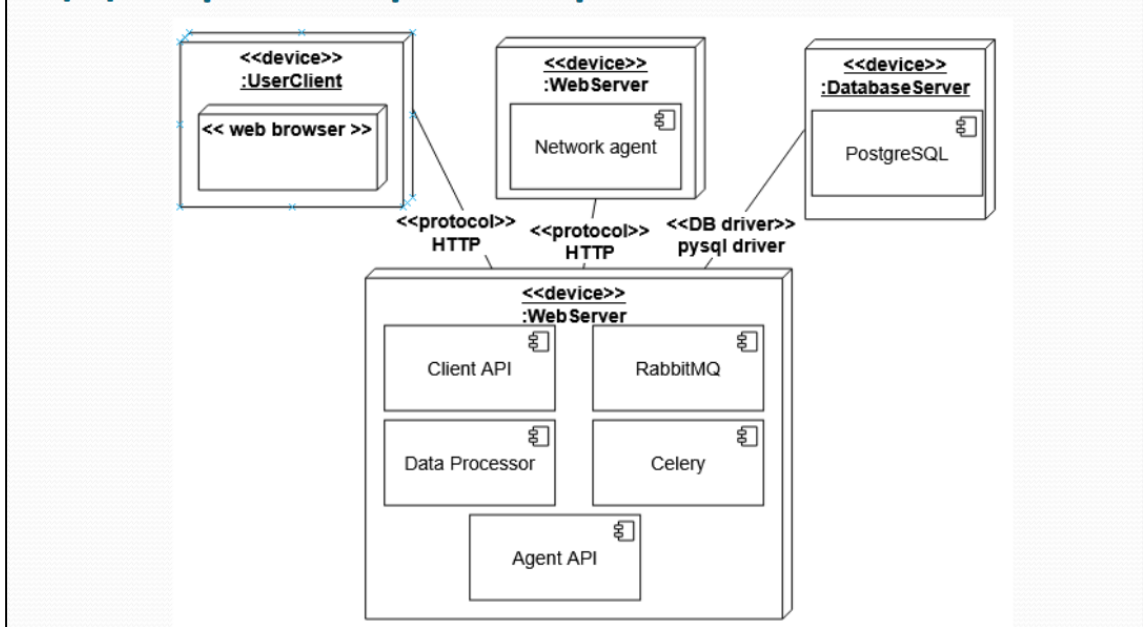


Рисунок Б.19 – Діаграма розгортання

## Діаграма компонентів



Рисунок Б.20 – Діаграма компонентів

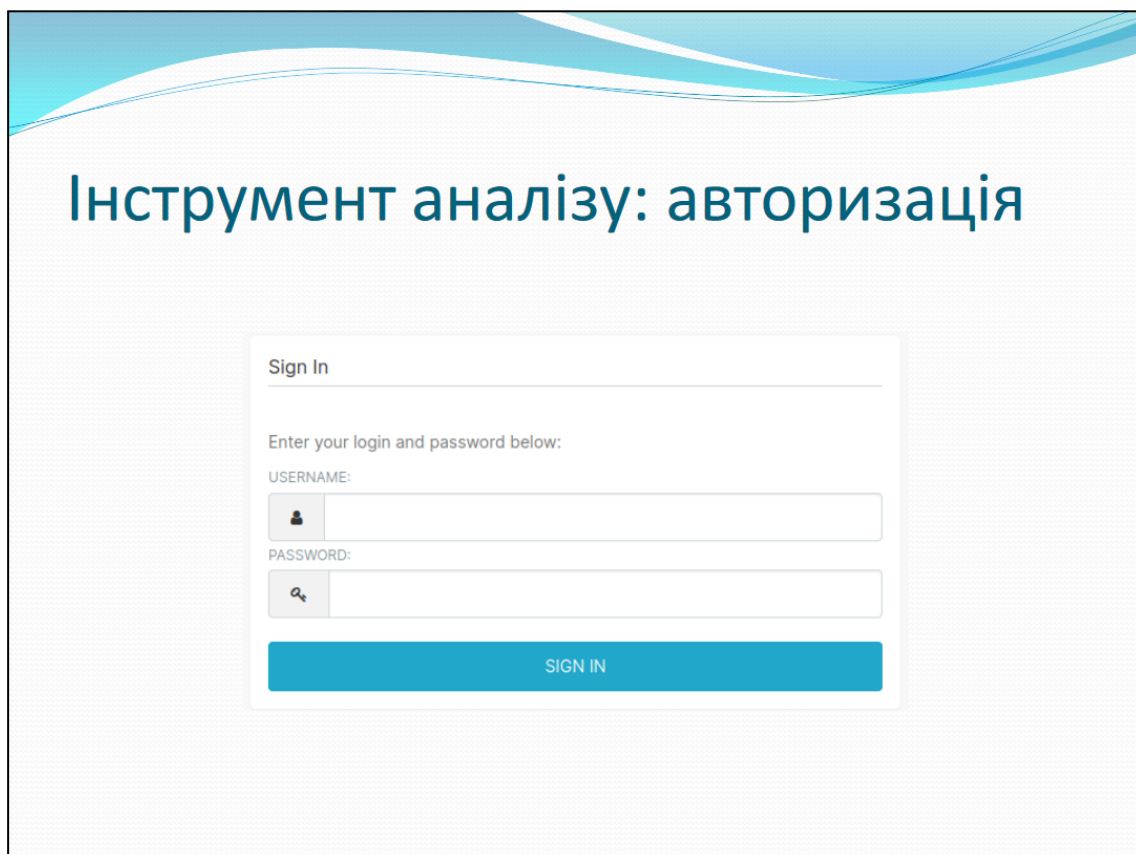


Рисунок Б.21 – Інструмент аналізу: авторизація

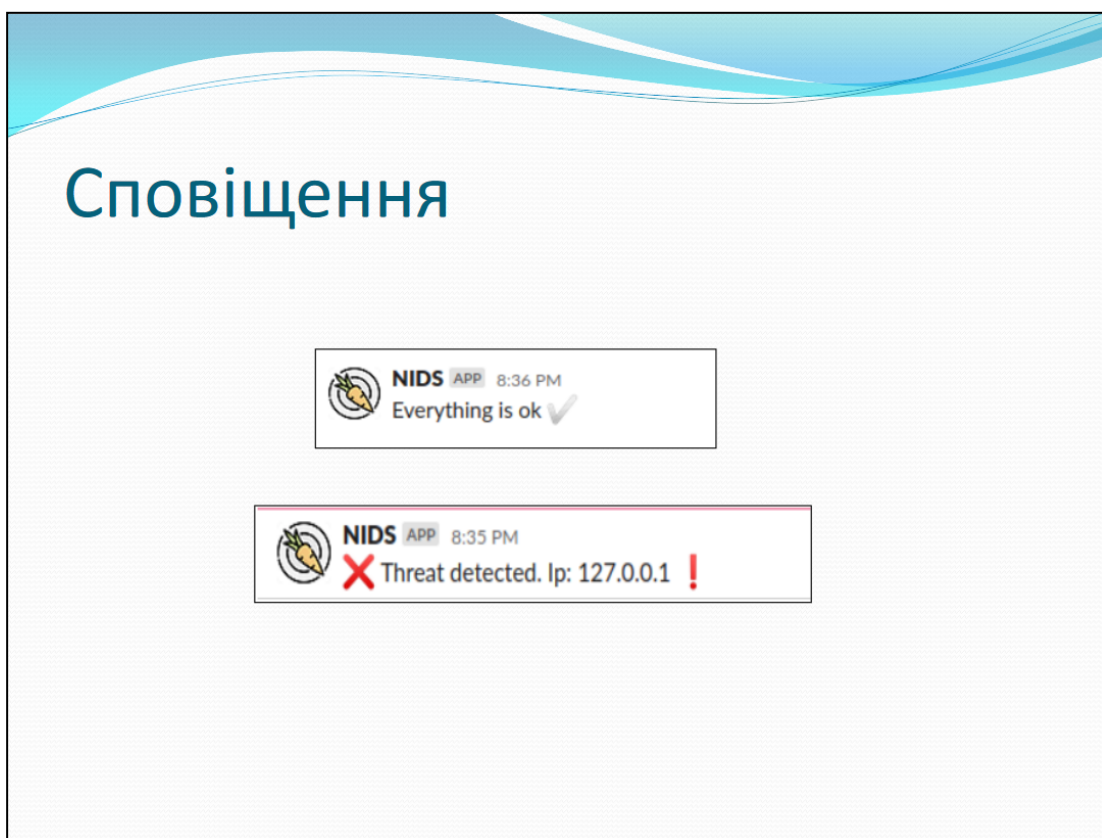


Рисунок Б.22 – Інструмент аналізу: сповіщення



Рисунок Б.23 – Інструмент аналізу: таблиця інцидентів

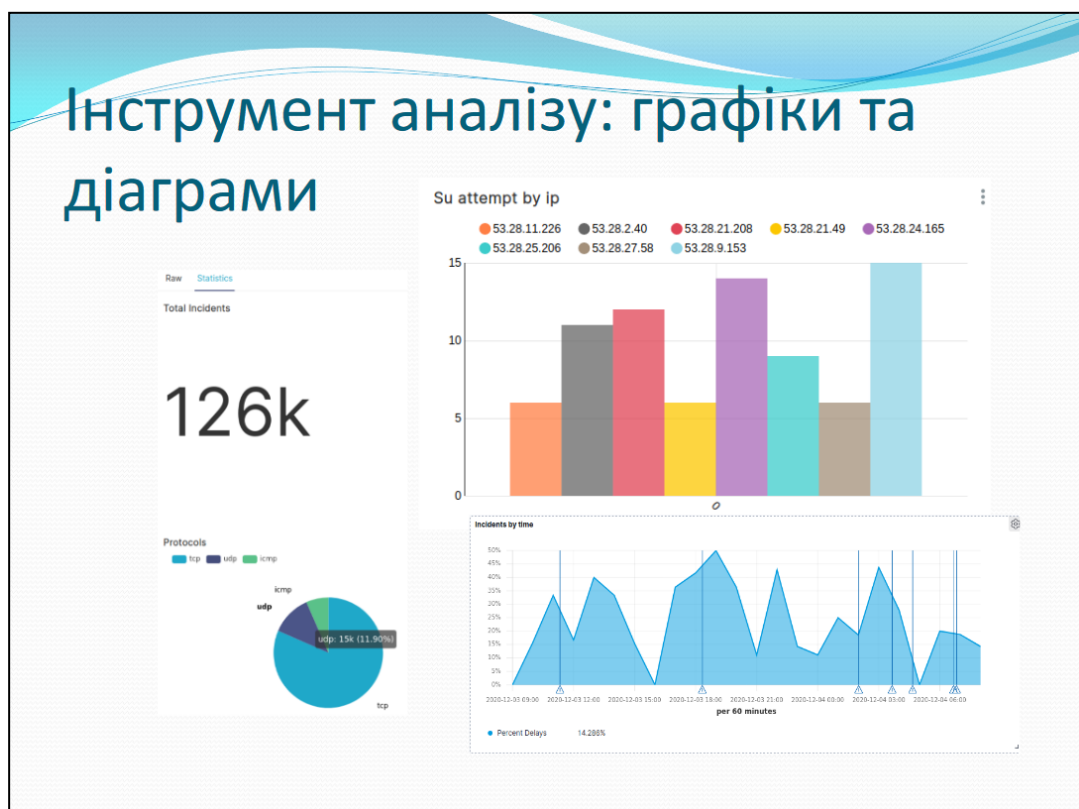


Рисунок Б.24 – Інструмент аналізу: графіки та діаграми

## Висновки

- Запропоновану модель можна використати для побудови NIDS або різноманітних аналізаторів мережі.
- Розроблений прикладний додаток може застосовуватись для моніторингу мережі хмарних серверів, кластерів або локальних мереж та виявлення кібератак різних типів.
- За результатами роботи були опубліковані тези та зроблена доповідь на Молодіжному форумі та конференції «Комп'ютерна інженерія і кібербезпека: досягнення та інновації» 25-27 листопада 2020 року

Рисунок Б.25 – Висновки

## ДОДАТОК В

## Тези доповіді на молодіжний форум

СИСТЕМА ВИЯВЛЕННЯ ВТОРНЕНЬ НА ОСНОВІ МЕТОДІВ  
ГЛИБИННОГО НАВЧАННЯ

Попович І.Д.

Науковий керівник – к.т.н., доцент Мазурова О.О.

Харківський національний університет радіоелектроніки  
(61166, Харків, пр. Науки 14, каф. Програмної інженерії, тел.  
(057) 702-14-46)

e-mail: ivan.porovych@nure.ua, телефон (066) 295-37-10

Security of cloud based servers is one of the most important aspects of modern web-applications. Intrusion detection systems are effective instruments to detect incoming threats to be able to react in a proper way. Rapid artificial intelligence technology growing provides a great opportunity to make intrusion detection systems more efficient. In order to analyze the effectiveness of different deep learning approaches, created a web tool that used pretrained models to solve intrusion detection system task.

Безпека хмарних додатків є одним з найважливіших завдань, яке розв'язується у ході проектування сучасних веб-систем. В найкращому варіанті необхідно розробити систему, яка повністю захищена від зловмисників. Але в реальному випадку це неможливо. Тому, щоб своєчасно реагувати, потрібно якнайшвидше визначити загрозу.

Система виявлення вторгнень (англ. Intrusion detection system — IDS) — це тип програмного забезпечення, призначеного для автоматичного сповіщення адміністраторів, коли хтось чи щось намагається порушити інформаційну систему через зловмисні дії або через порушення правил безпеки [1].

IDS може містити один або кілька типів виявлення вторгнень: на основі визначення підписів та на основі визначення аномалій [2]. IDS на основі підписів відстежує мережевий трафік на предмет підозрілих зразків у пакетах даних, підписів відомих вторгнень у мережу, щоб виявити та усунути напади та компроміси [2]. Це досягається за допомогою використання бази даних відомих типів вторгнень та шаблонів даних, що дозволяє IDS на основі підписів швидко ідентифікувати вторгнення та розпочати відповідний хід дій.

В свою чергу IDS на основі аномалій використовує властивості системи у звичайному стані, щоб відстежувати, чи відбувається незвична чи підозріла діяльність [2]. Цей метод вимагає підготовки, оскільки для базової підготовки моделі потрібно, щоб IDS дізнався про ваші схеми використання, і це робить його органічним, евристичним підходом до виявлення вторгнень. Перевага IDS на основі аномалій полягає в тому, що він є більш гнучким та потужним, ніж IDS на основі підписів, для якої необхідна існуюча база даних зловмисного трафіку.

Окре, була поставлена задача дослідити підходи, які можна використати для створення системи виявлення вторгнень на основі аномалій, побудувати модель, яка базується на обраних підходах та програмно реалізувати її в складі прикладного додатку, призначеного для виявлення аномальної активності в мережі у реальному часі.

Дослідження проводилися в області штучного інтелекту. Досягнення у цьому напрямку активно застосовуються у багатьох галузях, у тому числі і в галузі безпеки програмного забезпечення. Для розв'язання задачі виявлення аномалій існує багато методів класичного машинного навчання, такі як нейронні мережі (ANN), Support vector machines (SVM), Naive-Bayesian (NB), Random Forests (RF), Self-Organized Maps (SOM). Наразі активно використовують більш ефективний підхід глибинного навчання. Зокрема, значимі рекурентні нейронні мережі (RNN), а також більш специфічні Long short-term memory (LSTM) та Gated recurrent unit (GRU) [3].

Головна перевага архітектури LSTM над звичайними рекурентними нейронними мережами в тому, що вона може обробляти довготривалі залежності у даних. Це стало можливим завдяки додаванню до однієї мережі додаткових шарів, які регулюють потік інформації до мережевої клітинки.

GRU створений для вирішення тієї ж проблеми, що LSTM, але її однією мережі має на один шар менше. Крім того, GRU має можливість повторювати останні вихідні дані при переході до наступної ітерації мережі. Це робить її більш ефективною, ніж LSTM, в деяких випадках, зокрема, на даних з малою розміру.

У даній роботі проаналізовано методи Long short-term memory та Gated recurrent unit у контексті задачі навчання для побудови IDS на основі аномалій та реалізовано демонстраційну систему виявлення вторгнень, яка базується на натренованих моделях, побудованих за допомогою обраних методів:

- перегляд підозрілих подій у системі;
- відображення статусу підозрілих на аномалію подій;
- сортування подій за різними критеріями;
- будівництво графіків аномалій у залежності від часу.

У якості технології для тренування моделей було використано мову Python та фреймворк для глибинного навчання TensorFlow. Для написання прикладного додатку було використано Python-фреймворк aiohttp на базі асинхронно написаного API для натренованих моделей та нереляційну базу даних MongoDB у якості базового сховища даних. Також було використано Vue.js для побудови веб-клієнту системи моніторингу.

Запропоновані моделі може бути використано для побудови IDS або різноманітних аналізаторів мережі. Розроблений прикладний додаток може бути використано для моніторингу мережі різних хмарних серверів, кластерів, або локальних мереж та виявлення різноманітних кібератак.

**Список використаних джерел:** 1. Michael Sikorski, Andrew Hoing, Practical Malware Analysis. – No Strach Press, 2018. – 802 с.; ил. 2. Stefan Axelsson. Intrusion Detection Systems: A Survey and Taxonomy. – Department of Computer Engineering Chalmers University of Technology Göteborg, Sweden, 2015. – 27 с.; ил.; 3. Raghavendra Chalapaty, Sanjay Chawla. Deep Learning for Anomaly Detection: A Survey. – University of Sydney, 2019. – 48 с.; ил.

## ДОДАТОК Г

## Тези на конференцію «Комп'ютерна інженерія: досягнення та інновації»

УДК 004.02:004.056.5

І.Д. Попович  
студент Факультету комп'ютерних наук,  
Харківський національний університет  
радіоелектроніки

### ДОСЛІДЖЕННЯ МЕТОДІВ ГЛИБИННОГО МАШИННОГО НАВЧАННЯ ДЛЯ ВИРІШЕННЯ ЗАДАЧ ПОВУДОВИ СИСТЕМИ ВИЯВЛЕННЯ ВТОРГНЕНЬ

Забезпечення інформаційної безпеки є одним з найважливіших завдань, яке розв'язується у ході проектування сучасних систем [1]. В реальних умовах практично неможливо мати систему, яка повністю захищена від зловмисних дій, але вона повинна хоча б своєчасно реагувати, а для цього акційніше визначати загрозу.

Мережева система виявлення вторгнень (англ. Network Intrusion detection system – NIDS) – це програмне забезпечення, призначене для аналізу мережевого трафіку та виявлення зловмисних інцидентів у ньому [2]. NIDS поділяють на системи, які базуються на основі підписів та на основі аномалій. Перші вистежують мережевий трафік на предмет підозрілих зразків у пакетах даних за допомогою бази даних підписів відомих вторгнень у мережу [2]. NIDS на основі аномалій використовують за допомогою методів машинного навчання. Для розв'язання задачі виявлення аномалій звичайному стані, щоб вистежувати, чи відбувається незвичайна або підозріла діяльність. Формально NIDS на основі аномалій виконує функцію класифікації трафіку на шкідливий і звичайний [2]. Завдання класифікації досить ефективно вирішують за допомогою методів машинного навчання. Для розв'язання задачі виявлення аномалій існує багато методів класичного машинного навчання, такі як нейронні мережі, байєсівські мережі, метод опорних векторів тощо. Наразі, активно використовують більш ефективні підходи глибокого навчання, зокрема нейронні мережі.

Отже, було поставлено завдання дослідити методи машинного навчання, зокрема різні типи архітектур нейронних мереж, а саме, награтувати моделі, визначити їх оптимальні параметри на основі даних для навчання, та порівняти їх ефективність. Найбільш ефективні моделі використати для створення системи виявлення вторгнень.

Для проведення дослідження були обрані архітектури наступних мереж: згортоква нейрона мережа (англ. Convolutional neural network – CNN), рекурентна нейронна мережа (англ. Recurrent neural network – RNN), а саме її різновиди: довга короткочасна пам'ять (англ. Long short-term memory – LSTM) та керуючий рекурентний блок (англ. Gated recurrent unit – GRU) [3].

Особливістю методу CNN полягає у тому, що за основу береться матрична операція, яка називається згорткою – спеціалізований вид лінійних операцій [3]. CNN зазвичай використовують для вирішення завдань класифікації зображень, але в випадку спеціальної обробки даних перед тренуванням та при використанні особливий оптимізації ця архітектура може бути використана для виявлення аномалій.

Нейронні мережі, які засновані на архітектурі LSTM активно використовуються для аналізу природної мови [3]. Клітинна LSTM запам'ятовує значення через довільні інтервали часу, тому такі мережі також добре підходять для класифікації, обробки та виявлення аномалій на основі даних часових рядів, оскільки важливі події можуть виникати через невеличкі проміжки. Тобто LSTM може досить ефективно вирішувати завдання виявлення зловмисного трафіку у мережі.

Архітектура GRU фактично є більш простою версією LSTM, але її однією перевагою має на увазі менше [3]. Це дозволяє отримати більш високі результати у випадку, якщо кількість інформації є порівняно невеликою, а у випадку аналізу мережевого трафіку зазвичай доступні дані за період до одного тижня.

Також було вирішено дослідити доцільність використання комбінації підходів LSTM та методу SVM, який був використаний у якості класифікатора.

У якості даних було обрано набір даних, розроблений Канадським університетом з кібербезпеки [4] шляхом емуляції найбільш поширених атак, та збірники даних мережевого трафіку вироблених п'яти днів у стандартному форматі pcap. Для подальшого його використання для тренування моделей, даних було перетворено до формату XML. З XML файлів вилучено параметри мережі та сконвертовано до масиву, а також застосовано операцію one hot encoding [3] для отримання бінарних значень параметру (прибутний або ні). Отримані дані було розподілено на частини для тренування та для тесту. У ході роботи кожна модель натренована за допомогою методу градієнтного спуску на першій частині даних, тобто були отримані оптимальні ваги параметрів нейронної мережі, а після цього протестовано на другій частині даних. Ефективність моделей визначалася за допомогою наступних критеріїв:

- точність – процент правильно визначених вторгнень;
  - вірні позитивні відповіді – процент правильно визначених аномалій;
  - невірні позитивні відповіді – процент неправильно визначених аномалій.
- В ході дослідження отримано результати, які наведені у таблиці 1.

Таблиця 1 – Результати дослідження

	Точність (%)	Вірні позитивні відповіді (%)	Невірні позитивні відповіді (%)
CNN	95,4	93,6	3,3
LSTM	96,8	94,9	2,5
GRU	96,4	95,2	3,1
LSTM+SVM	96,1	94,7	2,7

Отримані результати дозволяють зробити висновки, що архітектура GRU та LSTM є ефективнішими за CNN. При цьому LSTM показує дещо більш високу точність, але GRU має менше невірних позитивних відповідей. Комбінація методів LSTM + SVM значно не покращила ефективність мережі.

На базі отриманих результатів для реалізації було обрано модель на архітектурі GRU, за допомогою якої реалізовано демонстраційну систему виявлення вторгнень. Розроблена система забезпечує наступний функціонал: перегляд підозрілих подій у системі, відображення статусу підозрілих на аномалію подій, сортування подій за різними критеріями, будування графіків аномалій у залежності від часу, тощо.

Запропоновану модель можна використати для побудови NIDS або ринкоманітних аналізаторів мережі. Розроблений прикладний додаток може застосовуватися для моніторингу мережі хмарних серверів, кластерів або локальних мереж та виявлення кібератак різних типів.

#### Список використаних джерел:

1. Бобало Ю.Я. Інформаційна безпека / Ю.Я. Бобало, І.В. Горбатий, М.Д. Киселівчик, А.П. Болдиря та ін. – Львів: Львівська політехніка, 2019. – 580 с.
2. Newman B. Computer Security, Protecting Digital Resources. – New York: Jones & Bartlett Learning, 2009. – 326 p.
3. Rajendrantha Chalapathy, Sanjay. Deep Learning for Anomaly Detection: A Survey. – University of Sydney, 2019. – 48 с. – <http://www.unb.ca/cic/datasets/> (дата звернення: 29.10.2020).
4. Canadian Institute for Cybersecurity dataset URL: <http://www.unb.ca/cic/datasets/> (дата звернення: 29.10.2020).

Науковий керівник: – кандидат технічних наук, доцент Маурина О.О., доцент кафедри програмної інженерії Харківського національного університету радіоелектроніки.

ДОДАТОК Д  
Лістінг коду

```
import glob
import json
import logging
import os
import time

import request

logger = logging.getLogger(__name__)

ENDPOINT = 'http://127.0.0.1:10000'
BASE_DIR = os.getenv('BASE_DIR')
POS_FILEPATH = os.join(BASE_DIR, 'pos.json')

def send_pcap(pcap_filepath):
    with open(pcap_filepath) as pcap_file:
        request.post(ENDPOINT, data=pcap_file)

def get_last_ts():
    with open(POS_FILEPATH) as pos_file:
        data = json.load(pos_file)
        return data['ts']
```

```
def save_last_ts():
    ts = time.time()
    with open(POS_FILEPATH, 'w') as pos_file:
        json.dump({'ts': ts}, pos_file)

def send_files():
    ts = get_last_ts()
    pcap_files = os.path.join(f'{BASE_DIR}', '*.cap')
    for filepath in glob.glob(pcap_files):
        if os.path.getmtime(filepath) > ts:
            send_pcap(filepath)
    save_last_ts()

def main():
    send_files()

if __name__ == '__main__':
    main()

const propTypes = {
  depth: PropTypes.number.isRequired,
  editMode: PropTypes.bool.isRequired,
  gridComponent: componentShape.isRequired,
  handleComponentDrop: PropTypes.func.isRequired,
```

```

isComponentVisible: PropTypes.bool.isRequired,
resizeComponent: PropTypes.func.isRequired,
setDirectPathToChild: PropTypes.func.isRequired,
width: PropTypes.number.isRequired,
};

```

```

const defaultProps = {};

```

```

class DashboardComponent extends Component {
  constructor(props) {
    super(props);
    this.state = {
      Resizing: false,
      rowGuideTop: null,
    };
  }

  setGridRef(ref) {
    this.grid = ref;
  }

  handleResizeStart({ ref, direction }) {
    let rowGuideTop = null;
    if (direction === 'bottom' || direction === 'bottomRight') {
      rowGuideTop = this.getRowGuidePosition(ref);
    }

    this.setState(() => ({
      Resizing: true,
      rowGuideTop,

```

```

    ));
  }

```

```

handleResize({ ref, direction }) {
  if (direction === 'bottom' || direction === 'bottomRight') {
    this.setState(() => ({ rowGuideTop: this.getRowGuidePosition(ref) }));
  }
}

```

```

handleResizeStop({ id, widthMultiple: width, heightMultiple: height }) {
  this.props.resizeComponent({ id, width, height });

```

```

    this.setState(() => ({
      Resizing: false,
      rowGuideTop: null,
    }));
  }

```

```

handleTopDropTargetDrop(dropResult) {
  if (dropResult) {
    this.props.handleComponentDrop({
      ...dropResult,
      destination: {
        ...dropResult.destination,
        index: 0,
      },
    });
  }
}

```

```

handleChangeTab({ pathToTabIndex }) {
  this.props.setDirectPathToChild(pathToTabIndex);
}

render() {
  const {
    gridComponent,
    handleComponentDrop,
    depth,
    editMode,
    width,
    isComponentVisible,
  } = this.props;

  const columnPlusGutterWidth =
    (width + GRID_GUTTER_SIZE) / GRID_COLUMN_COUNT;

  const columnWidth = columnPlusGutterWidth - GRID_GUTTER_SIZE;
  const { Resizing, rowGuideTop } = this.state;

  return width < 150 ? null : (
    <div className="dashboard-grid" ref={this.setGridRef}>
      <div className="grid-content" data-test="grid-content">
        {}
        {editMode && (
          <DragDroppable
            component={gridComponent}
            depth={depth}
            parentComponent={null}
            index={0}

```

```

orientation="column"
onDrop={this.handleTopDropTargetDrop}
className="empty-droptarget"
editMode
>
  {{{ dropIndicatorProps }} =>
    dropIndicatorProps && (
      <div className="drop-indicator drop-indicator--bottom" />
    )
  }
</DragDroppable>
)}}

```

```

{gridComponent.children.map((id, index) => (
  <Component
    key={id}
    id={id}
    parentId={gridComponent.id}
    depth={depth + 1}
    index={index}
    availableColumnCount={GRID_COLUMN_COUNT}
    columnWidth={columnWidth}
    isComponentVisible={isComponentVisible}
    onResizeStart={this.handleResizeStart}
    onResize={this.handleResize}
    onResizeStop={this.handleResizeStop}
    onChangeTab={this.handleChangeTab}
  />
)}}

```

```

{}
{editMode && gridComponent.children.length > 0 && (
  <DragDroppable
    component={gridComponent}
    depth={depth}
    parentComponent={null}
    index={gridComponent.children.length}
    orientation="column"
    onDrop={handleComponentDrop}
    className="empty-droptarget"
    editMode
  >
    {{{ dropIndicatorProps }} =>
      dropIndicatorProps && (
        <div className="drop-indicator drop-indicator--top" />
      )
    }
  </DragDroppable>
)}}

```

```

{Resizing &&
  Array(GRID_COLUMN_COUNT)
    .fill(null)
    .map((_, i) => (
      <div
        key={`column-grid-${i}`}
        className="column-grid"
        style={{
          left: i * GRID_GUTTER_SIZE + i * columnWidth,
          width: columnWidth,

```

```

        }}
    />
    ))}

{Resizing && rowGuideTop && (
  <div
    className="row-grid"
    style={{
      top: rowGuideTop,
      width,
    }}
  />
)}
</div>
</div>
);
}
}

class DatabaseRestApi(RestAPI):
    datamodel = SQLInterface(Database)

    @expose("/", methods=["POST"])
    def post(self) -> Response:
        if not request.is_json:
            return self.response_400(message="Request is not JSON")
        try:
            item = self.add_model_schema.load(request.json)
        except ValidationError as error:
            return self.response_400(message=error.messages)

```

```

try:
    new_model = CreateDatabaseCommand(g.user, item).run()
    item["sqlalchemy_uri"] = new_model.sqlalchemy_uri
    return self.response(201, id=new_model.id, result=item)
except DatabaseCreateFailedError as ex:
    return self.response_422(message=str(ex))

```

```
@expose("/<int:pk>", methods=["PUT"])
```

```
def put(self, pk: int) -> Response:
```

```

try:
    changed_model = UpdateDatabaseCommand(g.user, pk, item).run()
    item["sqlalchemy_uri"] = changed_model.sqlalchemy_uri
    return self.response(200, id=changed_model.id, result=item)
except DatabaseUpdateFailedError as ex:
    return self.response_422(message=str(ex))

```

```
@expose("/<int:pk>", methods=["DELETE"])
```

```
def delete(self, pk: int) -> Response:
```

```

try:
    DeleteDatabaseCommand(g.user, pk).run()
    return self.response(200, message="OK")
except DatabaseDeleteError as ex:
    return self.response_422(message=str(ex))

```

```
@expose("/<int:pk>/table/<table_name>/<schema_name>/", methods=["GET"])
```

```
def table_metadata(
```

```
    self, database: Database, table_name: str, schema_name: str
```

```
) -> Response:
```

```
    self.incr_stats("init", self.table_metadata.__name__)
```

```

try:
    table_info = metadata(database, table_name, schema_name)
except SQLAlchemyError as ex:
    self.incr_stats("error", self.table_metadata.__name__)
    return self.response_422(error_msg_from_exception(ex))
self.incr_stats("success", self.table_metadata.__name__)
return self.response(200, **table_info)

```

```

@expose("/<int:pk>/select_star/<table_name>/", methods=["GET"])
def select_star(
    self, database: Database, table_name: str, schema_name: Optional[str] = None
) -> Response:
    self.incr_stats("init", self.select_star.__name__)
    try:
        result = database.select_star(
            table_name, schema_name, latest_partition=True, show_cols=True
        )
    except NoSuchTableError:
        self.incr_stats("error", self.select_star.__name__)
        return self.response(404, message="Table not found on the database")
    self.incr_stats("success", self.select_star.__name__)
    return self.response(200, result=result)

```

```

@expose("/test_connection", methods=["POST"])
def test_connection(
    self,
) -> Response:
    if not request.is_json:
        return self.response_400(message="Request is not JSON")
    try:

```

```

    item = DatabaseConnection().load(request.json)
except ValidationError as error:
    return self.response_400(message=error.messages)
try:
    TestConnection(g.user, item).run()
    return self.response(200, message="OK")
except (NoModuleError, ModuleNotFoundError):
    driver_name = make_url(item.get("sqlalchemy_uri")).drivername
    return self.response(
        400,
        message=_("Could not load database driver: { }").format(driver_name),
        driver_name=driver_name,
    )
except DatabaseUnsafeError as ex:
    return self.response_422(message=ex)
except DBAPIError:
    logger.warning("Connection failed")
    return self.response(
        500,
        message=_("Connection failed, please check your connection settings"),
    )
except Exception as ex:
    return self.response_400(
        message=_(
            "Unexpected error occurred, please check your logs for details"
        )
    )
)

import logging
import os

```

```
import random
import time
from pathlib import Path

from scapy.all import AsyncSniffer, wrpcap

logger = logging.getLogger(__name__)

TIMEOUT = 10
MAX_NONCE = 120

PCAP_DIR = os.getenv('PCAP_DIR', '.')

class Sniffer:
    def __init__(self, iface):
        self.base_dir = Path(PCAP_DIR)
        self._sniffer = AsyncSniffer(
            iface=iface,
            prn=Sniffer.save_pcap,
            count=0
        )

    @classmethod
    def save_pcap(cls, pkt):
        ts = int(time.time())
        nonce = random.randint(0, MAX_NONCE)
        filename = f'pkt-{{ts}}-{{nonce}}.cap'
        wrpcap(filename, pkt)
```

```
def __enter__(self):
    self.base_dir.mkdir(parents_ok=True, exist_ok=True)
    self._sniffer.start()

def __exit__(self, exc_ty, exc_val, tb):
    self._sniffer.stop()

def main():
    with Sniffer(iface='docker0'):
        while True:
            logger.info('Sniffing ...')
            time.sleep(TIMEOUT)

if __name__ == '__main__':
    main()
```

## ДОДАТОК Е

### Відгук керівника роботи

#### ВІДГУК

на атестаційну роботу магістра,

Поповича Івана Дмитровича, гр. ПЗСм-19-1

(спеціальність – Інженерія програмного забезпечення,  
освітньо-професійна програма – Програмне забезпечення систем).

**Тема: «Дослідження методів глибинного машинного навчання для  
вирішення задачі побудови системи виявлення вторгнень»**

**Структура атестаційної роботи:** 6 розділів, с., 27 рис., 6 додатків.

Інтернет-технології з кожним роком стають все більш важливою частиною повсякденного життя людини. Тому актуальність проблеми забезпечення інформаційної безпеки збільшується швидкими темпами. З розвитком технологій з'являються нові можливості та інструменти для проведення кібератак, що в свою чергу активізує процес розробки нових засобів захисту та навпаки.

Дана робота містить результати дослідження методів глибинного машинного навчання, а саме різновидів рекурентної нейронної мережі, яке проводилося шляхом проведення серії експериментів на самостійно опрацьованому наборі даних, що містить результати емуляції найбільш поширених атак. Робота спрямована на вирішення практичної задачі створення програмної мережевої системи виявлення вторгнень на базі досліджених методів глибинного машинного навчання.

У ході виконання атестаційної роботи магістра було проведено аналіз проблемної області; визначено мету та задачі дослідження, вимоги до програмного продукту, розглянуто методи машинного навчання та запропоновано альтернативний метод вирішення задачі, натреновано та досліджено розроблені моделі. Також було проведено аналіз та моделювання предметної області, розроблена схема бази даних, спроектована архітектура мережевої системи виявлення вторгнень. Отримані теоретичні та експериментальні результати дозволили створити програмну систему, яка може застосовуватись для моніторингу мережі хмарних серверів, кластерів або локальних мереж та виявлення кібератак різних типів.

Магістрант провів досить детальний аналіз наукових робіт вітчизняних і зарубіжних вчених, в яких розглядаються практичні і теоретичні питання в області інформаційної безпеки, архітектури програмних систем та мереж, машинного навчання. Записка написана грамотно, вимоги стандартів дотримані. Результати роботи досить повно відображені в пояснювальній записці та на слайдах презентації. За результатами атестаційної роботи зроблено доповіді на Молодіжному форумі та конференції «Комп'ютерна інженерія і кібербезпека: досягнення та інновації». Робота виконана самостійно, достатньо оригінальна, містить малий процент плагіату.

Вважаю, що магістрант гр. ПЗСм-19-1 Попович І.Д. готовий до самостійної інженерної діяльності. Атестаційну роботу можна подати до захисту в ЕК за спеціальністю 121-«Інженерія програмного забезпечення», освітньо-професійною програмою «Програмне забезпечення систем».

Керівник атестаційної роботи магістра  
к т.н., доц. каф. ПІ: \_\_\_\_\_

Мазурова О.О.

« 10 » грудня 2020 р.