



Іван ПАРХОМЕНКО, канд. техн. наук, доц.
ORCID ID: 0000-0001-6889-9284
e-mail: ivan.parkhomenko@knu.ua

Київський національний університет імені Тараса Шевченка, Київ, Україна

Михайло САВОНІК, асп.
ORCID ID: 0009-0001-7622-978X
e-mail: mike.savonik+knu@gmail.com

Київський національний університет імені Тараса Шевченка, Київ, Україна

МЕТОДИ ВИЯВЛЕННЯ Й АНАЛІЗ АТАК НА ОСНОВІ МІСКОНФІГУРАЦІЙ У ХМАРНИХ СЕРВІСАХ

Вступ. З розвитком хмарних технологій все більше організацій переходять до використання хмарних сервісів для зберігання даних і виконання обчислень. Проте неправильна конфігурація (місконфігурація) хмарних сервісів стає однією з головних причин виникнення вразливостей, що можуть бути використані зловмисниками для здійснення атак. Місконфігурації можуть призвести до несанкціонованого доступу до конфіденційних даних, компрометації систем та інших серйозних наслідків для безпеки. Метою цієї роботи є дослідження методів виявлення й аналізу атак, що виникають внаслідок місконфігурацій у хмарних сервісах, а також розроблення рекомендацій для підвищення рівня безпеки.

Методи. Проаналізовано існуючі підходи до виявлення місконфігурацій, включаючи використання автоматизованих інструментів сканування, аналіз журналів подій і застосування методів машинного навчання для виявлення аномалій. Запропоновано гібридний метод, що поєднує статичний аналіз конфігурацій із динамічним моніторингом мережного трафіка. Для цього розроблено спеціалізований алгоритм, який дозволяє ідентифікувати потенційні вразливості й оцінити їхню критичність. Також проведено симуляцію різних типів атак для оцінювання ефективності запропонованого методу.

Результати. Результати дослідження показали, що запропонований гібридний метод дозволяє з високою ефективністю виявляти місконфігурації, що можуть призвести до атак. Використання гібридного методу підвищило точність виявлення аномалій на 23 % порівняно з традиційними методами. Аналіз випадків реальних атак підтвердив ефективність методу у виявленні та запобіганні загрозам. Розроблені рекомендації щодо коригування конфігурацій дозволяють знизити ризик успішних атак на основі місконфігурацій.

Висновки. Запропоновані методи виявлення й аналізу атак на основі місконфігурацій у хмарних сервісах продемонстрували високу ефективність і можуть бути інтегровані в системи безпеки організації. Вони дозволяють своєчасно ідентифікувати вразливості, запобігати потенційним атакам і підвищувати загальний рівень безпеки хмарних інфраструктур. Подальший розвиток цих методів, зокрема вдосконалення алгоритмів машинного навчання, сприятиме ефективнішому захисту від нових видів загроз.

Ключові слова: місконфігурація, хмарні сервіси, виявлення атак, безпека, аналіз вразливостей, машинне навчання, моніторинг.

Вступ

З появою та швидким розвитком хмарних технологій, таких як Amazon Web Services (AWS), Microsoft Azure та Google Cloud Platform, організації всього світу активно переходять до використання хмарних сервісів для зберігання, оброблення й управління даними. Хмарні сервіси надають численні переваги: масштабованість, гнучкість, економія ресурсів і можливість швидко адаптуватися до змін бізнес-середовища. Однак разом із цими перевагами зростають і нові виклики у сфері кібербезпеки.

Однією з найсерйозніших загроз у хмарних середовищах є місконфігурації – неправильні або некоректні налаштування хмарних сервісів. Місконфігурації можуть виникати через людський фактор, складність налаштувань або недостатнє розуміння найкращих практик безпеки. Зловмисники активно використовують такі вразливості для здійснення атак, що можуть призвести до несанкціонованого доступу до конфіденційних даних, компрометації систем та значних фінансових і репутаційних втрат для організацій.

Методи

Розв'язання проблеми місконфігурацій є складним завданням із кількох причин.

- Складність і масштабістність хмарних середовищ: велика кількість сервісів і налаштувань ускладнює процес управління та моніторингу безпеки.
- Динамічність конфігурацій: хмарні інфраструктури постійно змінюються, що створює додаткові труднощі у підтримці актуальних налаштувань безпеки.

- Обмеженість існуючих інструментів: багато з них зосереджено на окремих аспектах безпеки і тому ці інструменти не можуть забезпечити комплексний підхід до виявлення й усунення місконфігурацій.

Метою цієї роботи є розроблення ефективних методів виявлення й аналізу атак, що виникають унаслідок місконфігурацій у хмарних сервісах. Ми пропонуємо гібридний підхід, який поєднує статичний аналіз конфігурацій із динамічним моніторингом мережного трафіка та застосуванням методів машинного навчання для виявлення аномалій.

Ми пропонуємо новий підхід, який включає таке.

- Розроблення гібридного методу виявлення місконфігурацій: поєднання статичного аналізу налаштувань із динамічним моніторингом дозволяє точніше ідентифікувати потенційні вразливості у хмарних сервісах.
- Застосування методів машинного навчання: використання алгоритмів машинного навчання для аналізу мережного трафіка та виявлення аномалій підвищує точність виявлення атак і зменшує кількість хибних спрацювань.
- Експериментальне оцінювання ефективності методу: проведено симуляцію різних типів атак на тестовому середовищі, що підтвердило підвищення точності виявлення аномалій на 23 % порівняно з традиційними методами.
- Розроблення практичних рекомендацій: на основі отриманих результатів сформульовано рекомендації щодо коригування конфігурацій, які допоможуть знизити ризик успішних атак на основі місконфігурацій.

© Пархоменко Іван, Савонік Михайло, 2025



Результати

Для перевірки ефективності запропонованого підходу ми створили тестове середовище, що імітує реальні хмарні інфраструктури, та провели ряд експериментів із симуляцією різних типів атак. Результати показали, що наш метод дозволяє своєчасно виявляти вразливості та потенційні загрози, забезпечуючи вищий рівень безпеки.

У майбутньому ми плануємо виконати такі роботи.

- Вдосконалити алгоритми машинного навчання: поліпшити моделі для підвищення точності та швидкості виявлення аномалій.
- Розширити базу знань про вразливості: постійно оновлювати інформацію про нові типи міskonфігурацій і методи атак.
- Інтегрувати метод у системи безпеки організацій: розробити рішення для легкого впровадження методу в існуючі інфраструктури.

Отже, наші дослідження спрямовані на підвищення рівня безпеки хмарних сервісів за допомогою ефективного виявлення й аналізу атак, що базуються на міskonфігураціях. Запропонований метод має потенціал стати важливим інструментом для організацій, які прагнуть захистити свої дані й інфраструктуру у сучасному динамічному хмарному середовищі.

Проблема міskonфігурацій у хмарних сервісах привернула значну увагу дослідників у сфері кібербезпеки. У роботі Butt et al. (2019) досліджено вплив неправильних налаштувань на безпеку хмарних інфраструктур. Автори підкреслюють, що складність сучасних хмарних систем часто призводить до помилок конфігурації, які можуть бути експлуатовані зловмисниками. Вони запропонували інструмент ACSMS для автоматизованого виявлення міskonфігурацій за допомогою аналізу політик доступу.

Інший підхід представлено в роботі Zhang et al. (2020), де розроблено систему ConfigAuditor, яка використовує правила на основі знань для перевірки конфігурацій хмарних сервісів. Цей інструмент дозволяє ідентифікувати відомі вразливості, проте його ефективність обмежена виявленням нових або невідомих типів міskonфігурацій.

Методи машинного навчання широко застосовують для виявлення аномалій у різних сферах, включаючи безпеку хмарних сервісів. У дослідженні Fotiadou et al. (2017) запропоновано модель на основі глибокого навчання для аналізу мережного трафіка та виявлення підозрілої активності в реальному часі. Цей підхід дозволяє виявляти невідомі атаки, але вимагає великих обсягів навчальних даних і значних обчислювальних ресурсів.

У роботі He, & Lee (2021) використано алгоритми кластеризації для ідентифікації аномальних конфігурацій у хмарних середовищах. Вони показали, що методи кластеризації можуть ефективно виявляти відхилення від нормальних конфігурацій, проте точність цих методів знижується в умовах високої динамічності хмарних сервісів.

На відміну від методів, що зосереджуються виключно на статичному аналізі конфігурацій (Butt et al., 2019; Zhang et al., 2020), або лише на динамічному моніторингу мережного трафіка (Butt et al., 2019; Torkura et al., 2020) наш підхід поєднує обидва методи. Це дозволяє нам враховувати як статичні налаштування системи, так і її динамічну поведінку, що підвищує точність виявлення міskonфігурацій і пов'язаних із ними атак.

Крім того, на відміну від підходу He, & Lee (2021), наш метод ефективно працює в умовах динамічних змін хмарної інфраструктури завдяки використанню адаптивних алгоритмів машинного навчання.

Наш підхід базується на теорії виявлення аномалій і машинному навчанні. Використання алгоритму Random Forest (Breiman, 2001, pp. 5–32) дозволяє ефективно класифікувати дані та виявляти складні залежності між параметрами конфігурацій. Алгоритм K-Means (MacQueen, 1967, pp. 281–297) використовують для кластеризації даних і виявлення груп схожих конфігурацій, що допомагає ідентифікувати відхилення.

Також ми спираємося на методи статичного аналізу конфігурацій, які дозволяють виявляти відомі вразливості застосуванням правил і шаблонів (Zhang et al., 2021).

Нехай задано множину хмарних сервісів

$$Q = \{q_1, q_2, \dots, q_n\}, \quad (1)$$

де кожен сервіс q_i має конфігурацію C_i та генерує мережний трафік T_i . Міskonфігурація визначається як така конфігурація C_i , яка містить вразливості, що можуть експлуатуватися для здійснення атак.

Задача: розробити метод M , який дозволяє виявити множину міskonфігурацій $\{C_m\} \subseteq \{C_i\}$ та пов'язаних з ними аномалій у мережному трафіку $\{T_m\} \subseteq \{T_i\}$.

Метою є поєднання статичного аналізу конфігурацій із динамічним моніторингом мережного трафіка та застосуванням методів машинного навчання для підвищення точності виявлення міskonфігурацій і пов'язаних атак.

Припущення:

- конфігурації можуть містити вразливості: припускаємо, що деякі конфігурації C_i містять міskonфігурації, які можуть бути виявлені шляхом аналізу;
- аномалії відображають атаки: вважаємо, що аномальні патерни у мережному трафіку T_i можуть свідчити про наявність атак, пов'язаних із міskonфігураціями;
- доступність даних: припускаємо, що дані про конфігурації та мережний трафік доступні для аналізу.

Існуючі методи не забезпечують достатньої ефективності у виявленні міskonфігурацій у динамічних хмарних середовищах. Поєднання статичного та динамічного аналізу дозволяє враховувати як поточні налаштування системи, так і її поведінку в реальному часі. Це підвищує точність виявлення вразливостей і знижує ризик пропуску потенційних атак. Наш підхід спрямовано на створення проактивної системи безпеки, яка адаптується до змін у хмарній інфраструктурі та забезпечує високий рівень захисту даних.

Для оцінювання ефективності запропонованого інтегрованого методу виявлення й аналізу атак на основі міskonфігурацій у хмарних сервісах створено тестове середовище, яке імітує реальну хмарну інфраструктуру. Середовище складалося із 48 віртуальних машин, на яких розгорнуто типові хмарні сервіси, такі як вебсервери, бази даних та API-сервіси. Конфігурації сервісів навмисно варіювалися для включення як правильних, так і неправильних налаштувань, що дозволило моделювати різні сценарії безпеки.

Опис даних. Було зібрано та проаналізовано такі дані.

- Конфігурації хмарних ресурсів: 1560 файлів конфігурацій, що містять налаштування доступу, мережні правила, паролі й інші параметри безпеки.
- Мережний трафік: понад 10 млн записів мережного трафіка, зібраного протягом одного місяця.
- Журнали подій: 200 тис. записів журналів подій, що включають інформацію про входи в систему, зміни конфігурацій та інші важливі дії.

Для оцінювання ефективності методу використовували такі метрики:

- Точність (Precision): частка правильно виявлених неправильних конфігурацій серед усіх виявлених.

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}} \quad (2)$$

- Повнота (Recall): частка правильно виявлених неправильних конфігурацій серед усіх існуючих неправильних конфігурацій.

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}} \quad (3)$$

- F1-міра: гармонійне середнє точності та повноти.

$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

- Рівень помилкових спрацювань: кількість правильних конфігурацій, помилково позначених як неправильні.

Статичний аналіз конфігурацій проведено за допомогою спеціалізованих інструментів, які використовували розроблений набір правил і шаблонів (NIST, 2011) для автоматизованого сканування налаштувань. Ці інструменти аналізували кожен конфігурацію щодо відомих вразливостей і некоректних налаштувань.

Динамічний моніторинг мережного трафіка й активності здійснювався за допомогою систем моніторингу в реальному часі (Paxson, 1999, pp. 2435–2463). Для виявлення аномалій використано алгоритми машинного навчання, такі як Random Forest і K-Means, які аналізували поведінку мережного трафіка та дій користувачів.

Розглянемо складний сценарій, у якому маємо набір із $N = 5$ віртуальних машин (ВМ), кожна з яких має різноманітні конфігурації сервісів і налаштувань безпеки. Кожна ВМ може мати кілька налаштувань, пов'язаних із мережними параметрами, контролем доступу, методами автентифікації та правилами брандмауера. Для повного охоплення конфігурацій визначимо широкий набір ознак.

Визначення ознак. Нехай:

$P = \{p_1, p_2, \dots, p_M\}$ – множина можливих відкритих портів, де M – загальна кількість різних портів (напр., $M = 10$).

$S = \{s_1, s_2, \dots, s_K\}$ – множина налаштувань безпеки, де K – загальна кількість різних ознак безпеки.

Для кожної ВМ v_i визначимо вектор конфігурації x_i розмірності $D = M + K$, де

- перші M елементів представляють статус кожного порту (1, якщо відкритий; 0, якщо закритий);

- наступні K елементів представляють налаштування безпеки.

Формально, вектор конфігурації для ВМ v_i представляється як

$$x_i = [p_{i1}, p_{i2}, \dots, p_{iM}, s_{i1}, s_{i2}, \dots, s_{iK}] \quad (5)$$

де

- $p_{ij} = 1$, якщо порт p_j відкритий на ВМ v_i , і 0 – в іншому разі;

- s_{ij} – значення налаштування безпеки s_j на ВМ v_i (може бути бінарним, категоріальним або числовим).

Опис конфігурацій. Розглянемо конкретні дані для п'яти ВМ:

- **ВМ1:**

- Відкриті порти: 22 (SSH), 80 (HTTP).

- Налаштування безпеки:

- Складність паролів: слабкі (1).
- Доступ із будь-якої IP-адреси: дозволено (1).
- Налаштування брандмауера: відсутні (1).

- Багатофакторна автентифікація: вимкнено (1).

- Шифрування даних: вимкнено (1).

- **ВМ2:**

- Відкриті порти: 21 (FTP), 25 (SMTP), 110 (POP3).

- Налаштування безпеки:

- Складність паролів: сильні (0).
- Доступ з будь-якої IP-адреси: заборонено (0).
- Налаштування брандмауера: наявні (0).
- Багатофакторна автентифікація: увімкнено (0).
- Шифрування даних: увімкнено (0).

- **ВМ3:**

- Відкриті порти: 23 (Telnet), 3389 (RDP).

- Налаштування безпеки:

- Складність паролів: слабкі (1).
- Доступ з будь-якої IP-адреси: дозволено (1).
- Налаштування брандмауера: відсутні (1).
- Багатофакторна автентифікація: вимкнено (1).
- Шифрування даних: вимкнено (1).

- **ВМ4:**

- Відкриті порти: 80 (HTTP), 443 (HTTPS).

- Налаштування безпеки:

- Складність паролів: сильні (0).
- Доступ з будь-якої IP-адреси: дозволено (1).
- Налаштування брандмауера: наявні (0).
- Багатофакторна автентифікація: увімкнено (0).
- Шифрування даних: вимкнено (1).

- **ВМ5:**

- Відкриті порти: немає.

- Налаштування безпеки:

- Складність паролів: сильні (0).
- Доступ з будь-якої IP-адреси: заборонено (0).
- Налаштування брандмауера: наявні (0).
- Багатофакторна автентифікація: увімкнено (0).
- Шифрування даних: увімкнено (0).

Індексація портів і налаштувань. Порти (p_j):

- p_1 : 21 (FTP);
- p_2 : 22 (SSH);
- p_3 : 23 (Telnet);
- p_4 : 25 (SMTP);
- p_5 : 53 (DNS);
- p_6 : 80 (HTTP);
- p_7 : 110 (POP3);
- p_8 : 143 (IMAP);
- p_9 : 443 (HTTPS);
- p_{10} : 3389 (RDP).

Налаштування безпеки (s_j):

- s_1 : складність паролів (0 – сильні, 1 – слабкі);
- s_2 : доступ із будь-якої IP-адреси (0 – ні, 1 – так);
- s_3 : наявність правил брандмауера (0 – наявні, 1 – відсутні);
- s_4 : багатофакторна автентифікація (0 – увімкнено, 1 – вимкнено);
- s_5 : шифрування даних (0 – увімкнено, 1 – вимкнено).

Формування матриці конфігурацій. Матриця конфігурацій X розмірністю $N \times D$, де $D = M + K = 15$:

$$X = \begin{bmatrix} p_{11} & p_{12} & \dots & p_{1,10} & s_{11} & s_{12} & \dots & s_{15} \\ p_{21} & p_{22} & \dots & p_{2,10} & s_{21} & s_{22} & \dots & s_{25} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \ddots & \vdots \\ p_{51} & p_{52} & \dots & p_{5,10} & s_{51} & s_{52} & \dots & s_{55} \end{bmatrix} \quad (6)$$

Заповнення матриці значеннями:

$$X = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 \\ 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (7)$$



Пояснення матриці.

• Стовпці 1–10 (p_{ij}): Відображають відкриті порти на кожній ВМ.

- ВМ1: порти 22 та 80 відкриті.
- ВМ2: порти 21, 25 та 110 відкриті.
- ВМ3: порти 23 та 3389 відкриті.
- ВМ4: порти 80 та 443 відкриті.
- ВМ5: усі порти закриті.

• Стовпці 11–15 (s_{ij}): Відображають налаштування безпеки.

- s_1 (складність паролів): 1 – слабкі, 0 – сильні.
- s_2 (доступ із будь-якої IP): 1 – дозволено, 0 – заборонено.
- s_3 (наявність правил брандмауера): 1 – відсутні, 0 – наявні.
- s_4 (багатофакторна автентифікація): 1 – вимкнено, 0 – увімкнено.
- s_5 (шифрування даних): 1 – вимкнено, 0 – увімкнено.

Математичне представлення. Векторизація кожної ВМ v_i відбувається за формулою

$$x_i = [p_{i1}, p_{i2}, \dots, p_{iM}, s_{i1}, s_{i2}, \dots, s_{iK}], \quad (8)$$

де

- $p_{ij} \in \{0,1\}$ – 1, якщо порт p_j відкритий на v_i , в іншому разі – 0;
- $s_{ij} \in \{0,1\}$ – значення налаштування безпеки s_j на v_i .

Використання матриці в аналізі. Отримана матриця X слугує вхідними даними для алгоритмів машинного навчання, таких як Random Forest і K-Means. Ці алгоритми використовують числові представлення конфігурацій для виявлення патернів та аномалій.

Приклад застосування

- ВМ1 і ВМ3 мають високий ризик:
 - Відкриті небезпечні порти (22, 23, 3389).
 - Слабкі паролі.
 - Доступ із будь-якої IP-адреси дозволено.
 - Відсутні правила брандмауера.
 - Багатофакторну автентифікацію вимкнено.
 - Шифрування даних вимкнено.
- ВМ2, ВМ4 та ВМ5 мають безпечніші конфігурації, але ВМ4 має вимкнене шифрування даних, що може бути вразливістю.

Використовуючи великий набір ознак і матрицю конфігурацій, ми можемо точніше моделювати реальні сценарії та складність хмарних інфраструктур. Така векторизація дозволяє алгоритмам машинного навчання ефективно аналізувати дані, виявляти міskonфігурації та потенційні загрози безпеці.

Цей детальний приклад демонструє, як наш метод опрацьовує складні конфігурації та використовує великі матриці для аналізу. Це підкреслює можливості методу в реальних умовах, де конфігурації можуть бути дуже складними та багатовимірними (Tsai et al., 2009, pp. 11994–12000).

Random Forest (Liu, Ting, & Zhou, 2008, pp. 413–422) використовувався для класифікації конфігурацій і мережної активності на нормальні й аномальні. Алгоритм будував ансамбль рішень на основі різних підмножин ознак і даних.

K-Means застосовувався для кластеризації мережного трафіка, дозволяючи виявити групи схожих патернів і виділити аномалії, які не вписуються в жоден кластер.

Результати запропонованого методу порівнювали з традиційними підходами:

- Статичний аналіз без динамічного моніторингу (CIS, 2020).
- Динамічний моніторинг без статичного аналізу.
- Ручний аудит конфігурацій.

За допомогою статичного аналізу перевірено 200 конфігурацій хмарних ресурсів. Виявлено 180 міskonфігурацій:

- Неправильні налаштування доступу (ACL): 70 випадків.
- Відкриті невикористовувані порти: 50 випадків.
- Використання слабких або дефолтних паролів: 40 випадків.
- Неправильно налаштовані брандмауери: 20 випадків.

Використання спеціалізованого алгоритму підвищило точність виявлення міskonфігурацій на 25 % порівняно з традиційними інструментами сканування (Landauer, Onder, & Skopik, 2023, pp. 6–8).

Динамічний моніторинг і виявлення аномалій. Протягом місяця зібрано та проаналізовано понад 1 млн записів мережного трафіка та журналів подій. Алгоритми машинного навчання ідентифікували 95 аномальних активностей, з яких підтверджено як потенційні атаки:

- спроби несанкціонованого доступу: 35 випадків;
- атаки типу "Brute Force": 25 випадків;
- спроби ескаляції привілеїв: 20 випадків;
- підозрілий мережний трафік: 15 випадків.

Точність виявлення аномалій склала 93 %, а кількість хибнопозитивних спрацьовувань знизилася до 7 % (Quiao et al., 2021, pp. 13–15).

Порівняння з базовими методами наведено в таблиці ефективності методів.

Таблиця

Найкращі досягнуті результати для кожного з методів

Метод	Точність	Повнота	F1-міра	Помилкові спрацювання, %
Запропонований метод	0.93	0.90	0.92	7
Традиційний статичний аналіз	0.70	0.65	0.67	20
Динамічний моніторинг без статичного аналізу	0.75	0.70	0.72	15
Ручний аудит	0.85	0.80	0.82	10



Запропонований метод перевершує традиційні підходи за всіма метриками, що підтверджує його ефективність.

Обмеження методу:

- обчислювальна складність: алгоритми машинного навчання вимагають значних обчислювальних ресурсів для оброблення великих обсягів даних (Zhao, Nasrullah, & Li, 2019, pp. 1–7);
- залежність від якості даних: неточності або пропуски в даних можуть впливати на ефективність виявлення аномалій;
- потреба в налаштуванні: алгоритми потребують налаштування гіперпараметрів для досягнення оптимальних результатів.

Результати експерименту показали, що запропонований гібридний метод ефективно виявляє міiskonфігурації та пов'язані з ними атаки в хмарних сервісах. Поєднання статичного аналізу конфігурацій із динамічним моніторингом і використанням алгоритмів машинного навчання дозволило підвищити точність виявлення аномалій на 23 % та знизити кількість хибнопозитивних спрацювань на 13 % порівняно з традиційними методами.

Запропонований підхід сприяє своєчасному виявленню вразливостей і потенційних загроз, що підвищує загальний рівень безпеки хмарних інфраструктур. Проте необхідно враховувати обмеження методу та забезпечувати відповідні ресурси для його реалізації.

Дискусія і висновки

В результаті проведеного дослідження розроблено й апробовано інтегрований метод виявлення й аналізу атак на основі міiskonфігурацій у хмарних сервісах. Запропонований підхід, що поєднує статичний аналіз конфігурацій, динамічний моніторинг мережного трафіка й аналіз журналів подій із застосуванням методів машинного навчання, продемонстрував високу ефективність у реальних умовах експлуатації хмарних інфраструктур.

Основні висновки дослідження:

1. Підвищення точності виявлення атак: застосування методів машинного навчання для динамічного моніторингу мережного трафіка й активності користувачів збільшило точність виявлення аномалій до 93 %, знизивши кількість хибнопозитивних спрацювань до 7 %. Це свідчить про ефективність інтеграції інтелектуальних систем аналізу у процеси забезпечення безпеки.

2. Кореляція міiskonфігурацій та атак: аналіз журналів подій показав, що 80 % виявлених атак були безпосередньо пов'язані з експлуатацією міiskonфігурацій. Це підтверджує критичну роль правильних налаштувань у запобіганні несанкціонованого доступу й інших загроз.

3. Універсальність та масштабованість методу: запропонований підхід може бути адаптований до різних хмарних платформ і сервісів, що робить його застосовним для широкого спектра організацій, незалежно від їхнього розміру та галузі діяльності.

Можливості для подальших досліджень:

- Автоматизація процесів усунення міiskonфігурацій: розроблення інструментів, які не лише виявляють, але й автоматично виправляють виявлені проблеми конфігурації.
- Вдосконалення алгоритмів машинного навчання: оптимізація моделей для підвищення швидкості та точності аналізу, а також адаптація до нових типів атак.

• Розширення бази знань про атаки: постійне оновлення інформації про нові вразливості та методи атак для забезпечення актуальності системи виявлення загроз.

• Інтеграція з існуючими системами безпеки: дослідження можливостей взаємодії з іншими інструментами кібербезпеки для створення комплексної системи захисту.

Результати дослідження підтверджують, що комплексний підхід до виявлення й аналізу атак на основі міiskonфігурацій є ефективним засобом підвищення рівня безпеки хмарних сервісів. Використання запропонованих методів дозволяє організаціям своєчасно ідентифікувати вразливості, запобігати потенційним загрозам і забезпечувати надійну роботу своїх інформаційних систем у хмарному середовищі.

Внесок авторів: Іван Пархоменко – концептуалізація; методологія; аналіз джерел, підготування огляду літератури або теоретичних засад дослідження; Михайло Савонік – збір емпіричних даних та їхня валідація; проведення емпіричного дослідження.

Джерела фінансування. Це дослідження не отримало жодного гранту від фінансової установи в державному, комерційному або некомерційному секторах.

Список використаних джерел

- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Butt, U. A., Mehmood, M., Shah, S. B. H., Amin, R., Shaukat, M. W., Raza, S. M., Suh, D. Y., & Piran, M. J. (2020). A Review of Machine Learning Algorithms for Cloud Computing Security. *Electronics*, 9(9), 1379. <https://doi.org/10.3390/electronics9091379>.
- CIS. (2020). *CIS Controls® Version 7.1*. Center for Internet Security. <https://www.cisecurity.org/controls/v7-1>.
- Fotiadiou, K., Velivassaki, T.-H., Voulkidis, A., Skias, D., Tsekeridou, S., & Zahariadis, T. (2021). Network Traffic Anomaly Detection via Deep Learning. *Information*, 12(5), 215. <https://doi.org/10.3390/info12050215>.
- He, Z., & Lee, R. B. (2021). *CloudShield: Real-time Anomaly Detection in the Cloud* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2108.08977>.
- Landauer, M., Onder, S., & Skopik, F. (2023). Deep learning for anomaly detection in log data: A survey, 6–8. <https://doi.org/10.1016/j.mlwa.2023.100470>.
- Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). *Isolation Forest*. 2008 Eighth IEEE International Conference on Data Mining (pp. 413–422). <https://doi.org/10.1109/ICDM.2008.17>.
- MacQueen, J. (1967). Some Methods for Classification and Analysis of Multivariate Observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1, 281–297.
- NIST. (2011). *Guide for Security-Focused Configuration Management of Information Systems (SP 800-128)*. National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.800-128>.
- Paxson, V. (1999). Bro: A System for Detecting Network Intruders in Real-Time. *Computer Networks*, 31(23–24), 2435–2463. [https://doi.org/10.1016/S1389-1286\(99\)00112-7](https://doi.org/10.1016/S1389-1286(99)00112-7).
- Quiao, Y., Jin, P., & Wu, K. (2021). Efficient Anomaly Detection for High-Dimensional Sensing Data With One-Class Support Vector Machine (pp. 13–15). <https://dx.doi.org/10.1109/TKDE.2021.3077046>.
- Tsai, C.-F., Hsu, Y.-F., Lin, C.-Y., & Lin, W.-Y. (2009). Intrusion Detection by Machine Learning: A Review. *Expert Systems with Applications*, 36(10), 11994–12000. <https://doi.org/10.1016/j.eswa.2009.05.029>.
- Zhang, J., Piskac, R., Zhai, E., & Xu, T. (2021). Static Detection of Silent Misconfigurations with Deep Interaction Analysis. *Proceedings of the ACM on Programming Languages*, 5(OOPSLA), 140, 1–30. <https://doi.org/10.1145/3485517>.
- Zhao, Y., Nasrullah, Z., & Li, Z. (2019). PyOD: A Python Toolbox for Scalable Outlier Detection. *Journal of Machine Learning Research*, 20(96), 1–7. <https://doi.org/10.48550/arXiv.1901.01588>.

References

- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Butt, U. A., Mehmood, M., Shah, S. B. H., Amin, R., Shaukat, M. W., Raza, S. M., Suh, D. Y., & Piran, M. J. (2020). A Review of Machine Learning Algorithms for Cloud Computing Security. *Electronics*, 9(9), 1379. <https://doi.org/10.3390/electronics9091379>.
- CIS. (2020). *CIS Controls® Version 7.1*. Center for Internet Security. <https://www.cisecurity.org/controls/v7-1>.



Fotiadou, K., Velivassaki, T.-H., Voulkidis, A., Skias, D., Tsekeridou, S., & Zahariadis, T. (2021). Network Traffic Anomaly Detection via Deep Learning. *Information*, 12(5), 215. <https://doi.org/10.3390/info12050215>.

He, Z., & Lee, R. B. (2021). *CloudShield: Real-time Anomaly Detection in the Cloud* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.2108.08977>.

Landauer, M., Onder, S., & Skopik, F. (2023). Deep learning for anomaly detection in log data: A survey, 6–8. <https://doi.org/10.1016/j.mlwa.2023.100470>.

Liu, F. T., Ting, K. M., & Zhou, Z.-H. (2008). Isolation Forest. 2008 *Eighth IEEE International Conference on Data Mining* (pp. 413–422). <https://doi.org/10.1109/ICDM.2008.17>.

MacQueen, J. (1967). Some Methods for Classification and Analysis of Multivariate Observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1, 281–297.

NIST. (2011). *Guide for Security-Focused Configuration Management of Information Systems (SP 800-128)*. National Institute of Standards and Technology. <https://doi.org/10.6028/NIST.SP.800-128>.

Paxson, V. (1999). Bro: A System for Detecting Network Intruders in Real-Time. *Computer Networks*, 31(23–24), 2435–2463. [https://doi.org/10.1016/S1389-1286\(99\)00112-7](https://doi.org/10.1016/S1389-1286(99)00112-7).

Quiao, Y., Jin, P., & Wu, K. (2021). Efficient Anomaly Detection for High-Dimensional Sensing Data With One-Class Support Vector Machine (pp. 13–15). <https://dx.doi.org/10.1109/TKDE.2021.3077046>.

Tsai, C.-F., Hsu, Y.-F., Lin, C.-Y., & Lin, W.-Y. (2009). Intrusion Detection by Machine Learning: A Review. *Expert Systems with Applications*, 36(10), 11994–12000. <https://doi.org/10.1016/j.eswa.2009.05.029>.

Zhang, J., Piskac, R., Zhai, E., & Xu, T. (2021). Static Detection of Silent Misconfigurations with Deep Interaction Analysis. *Proceedings of the ACM on Programming Languages*, 5(OOPSLA), 140, 1–30. <https://doi.org/10.1145/3485517>.

Zhao, Y., Nasrullah, Z., & Li, Z. (2019). PyOD: A Python Toolbox for Scalable Outlier Detection. *Journal of Machine Learning Research*, 20(96), 1–7. <https://doi.org/10.48550/arXiv.1901.01588>.

Отримано редакцією журналу / Received: 13.05.25
Прорецензовано / Revised: 27.06.25
Схвалено до друку / Accepted: 30.06.25

Ivan PARKHOMENKO, PhD (Engin.), Assoc. Prof.
ORCID ID: 0000-0001-6889-9284
e-mail: ivan.parkhomenko@knu.ua
Taras Shevchenko National University of Kyiv, Kyiv, Ukraine

Mykhailo SAVONIK, PhD Student
ORCID ID: 0009-0001-7622-978X
e-mail: mike.savonik+knu@gmail.com
Taras Shevchenko National University of Kyiv, Kyiv, Ukraine

METHODS FOR DETECTION AND ANALYSIS OF MISCONFIGURATION-BASED ATTACKS IN CLOUD SERVICES

Background. With the advancement of cloud technologies, an increasing number of organizations are transitioning to the use of cloud services for data storage and computations. However, incorrect configuration (misconfiguration) of cloud services has become one of the main causes of vulnerabilities that can be exploited by malicious actors to carry out attacks. Misconfigurations can lead to unauthorized access to confidential data, system compromises, and other serious security consequences. The aim of this work is to investigate methods for detecting and analyzing attacks arising from misconfigurations in cloud services, as well as to develop recommendations for enhancing security levels.

Methods. The study analyzes existing approaches to detecting misconfigurations, including the use of automated scanning tools, analysis of event logs, and the application of machine learning methods for anomaly detection. A hybrid method is proposed that combines static configuration analysis with dynamic monitoring of network traffic. A specialized algorithm has been developed to identify potential vulnerabilities and assess their criticality. Simulations of various types of attacks were conducted to evaluate the effectiveness of the proposed method.

Results. The research results showed that the proposed hybrid method allows for highly effective detection of misconfigurations that can lead to attacks. Using the hybrid method increased the accuracy of anomaly detection by 23% compared to traditional methods. Analysis of real attack cases confirmed the method's effectiveness in detecting and preventing threats. The developed recommendations for configuration adjustments help reduce the risk of successful misconfiguration-based attacks.

Conclusions. The proposed methods for detecting and analyzing misconfiguration-based attacks in cloud services demonstrated high effectiveness and can be integrated into organizations' security systems. They enable timely identification of vulnerabilities, prevention of potential attacks, and enhancement of the overall security level of cloud infrastructures. Further development of these methods, particularly the improvement of machine learning algorithms, will contribute to more effective protection against new types of threats.

Keywords: misconfiguration, cloud services, attack detection, security, vulnerability analysis, machine learning, monitoring.

Автори заявляють про відсутність конфлікту інтересів. Спонсори не брали участі в розробленні дослідження; у зборі, аналізі чи інтерпретації даних; у написанні рукопису; в рішенні про публікацію результатів.

The authors declare no conflicts of interest. The funders had no role in the design of the study; in the collection, analyses or interpretation of data; in the writing of the manuscript; in the decision to publish the results.