

Міністерство освіти і науки України  
Сумський державний університет  
Навчально-науковий інститут бізнесу, економіки та менеджменту  
Кафедра економічної кібернетики

## КВАЛІФІКАЦІЙНА МАГІСТЕРСЬКА РОБОТА

на тему «МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ КІБЕРАТАК ДЛЯ  
ЕКОНОМІЧНИХ АГЕНТІВ»

Виконала студентка 2 курсу, групи ЕКм.- 91н.а.

Спеціальності 051 «Економіка»  
(«Економічна кібернетика»)

Дятленко А. О.

Керівниця: к.е.н., доцентка Яровенко А.Н.

Суми – 2021рік

## РЕФЕРАТ

# Кваліфікаційної магістерської роботи на тему «МОДЕЛЮВАННЯ ТА ПРОГНОЗУВАННЯ КІБЕРАТАК ДЛЯ ЕКОНОМІЧНИХ АГЕНТІВ»

студентки Дятленко Анни Олексіївни

Актуальність теми, обраної для дослідження, визначається тим, що кожного року суб'єкти господарювання стикаються з протиправними діями зі сторони кіберзлочинності. Саме тому при прогнозуванні збільшення кількості кібератак, суб'єкт зможе збільшити захист в потрібний час.

Метою даного дослідження є розробка математичної моделі прогнозування можливості та кількості кібератак на організації чи підприємства на основі моделей автoregresії та ковзного середнього.

Предметом дослідження виступають методи і моделі для прогнозування часових рядів.

Об'єктом дослідження є кількість кіберподій спрямованих на суб'єктів господарювання.

Для досягнення поставленої мети сформовано наступні задачі дослідження:

- розглянути основні види кібератак та способи захисту;
- проаналізувати сучасний стан кібербезпеки у світі;
- описати підходи до моделювання та прогнозування часових рядів;
- сформулювати вимоги до моделі;
- обрати програмне забезпечення для реалізації моделі;
- побудувати ARIMA модель;
- перевірити її на адекватність;
- спрогнозувати можливу кількість кібератак;

Під час виконання робот були використані такі методи дослідження: аналіз часових рядів, прогнозування на основі моделі автoregresії та ковзного середнього.

Інформаційною базою кваліфікаційної магістерської роботи є Дані з виявлених аналітиками інцидентів від постачальника послуг комп'ютерної безпеки (CSSP) для Міністерства оборони США.

Основний науковий результат роботи полягає у розробці і перевірці на адекватність моделі прогнозування кількості кібератак, що дозволяє отримати інформацію про кількість кібератак на майбутній період.

Ключові слова: кібератака, прогнозування, моделювання.

Зміст кваліфікаційної магістерської роботи викладено на 41 сторінці. Список використаних джерел із 29 найменувань, розміщений на 3 сторінках. Робота містить 3 таблиці, 31 рисунок, а також 2 додатки, розміщених на 3 сторінках.

Рік виконання кваліфікаційної роботи – 2021 рік.

Рік захисту роботи – 2021 рік.

## ЗМІСТ

ВСТУП .....	4
РОЗДІЛ 1 ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ОСНОВИ МОДЕлювання ТА ПРОГНОЗУВАННЯ ВИПАДКІВ КІБЕРАТАК.....	6
1.1 Поняття та основні види кібератак, основні засоби захисту .....	6
1.2 Сучасний стан кібербезпеки у світі .....	8
1.3 Підходи до моделювання та прогнозування кібератак.....	10
РОЗДІЛ 2 РОЗРОБКА МОДЕЛІ ПРОГНОЗУВАННЯ МОЖЛИВИХ ВИПАДКІВ КІБРАТАК.....	12
2.1 Моделі прогнозування часових рядів .....	12
2.2 Формульовання вимог до моделі та опис вхідних змінних .....	15
РОЗДІЛ 3 МОДЕлювання МОЖЛИВИХ ОБСЯГІВ КІБЕРАТАК .....	17
3.1 Аналіз часового ряду .....	17
3.2 Побудова ARIMA моделі .....	22
3.3 Прогнозування кількості кібератак на основі ARIMA моделей .	35
ВИСНОВКИ.....	38
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	39
ДОДАТОК А.....	43
ДОДАТОК Б .....	44

## ВСТУП

З розвитком сучасних інформаційних технологій та повсюдному доступу до них майже в кожному куточку світу, зростає і кількість особистої чи корпоративної інформації, що зберігається на просторах Інтернету. Незважаючи на всі переваги новітніх технологій, вони також надали безмежне поле для розвитку кіберзлочинності, яка вдосконалюється з кожним роком. В час, коли більшість людей працювали, навчалися та спілкувалися онлайн, кібербезпека для кожної окремої особи чи для великої корпорації ще не була актуальніша.

Кіберзлочини ставлять під загрозу фізичну, економічну, соціальну та політичну безпеку. Наразі, коли протиправні дії можливо сковувати навіть не виходячи з власного дому, питання прогнозування та попередження кібератак є дуже актуальним. З подальшим розвитком технологій дане питання не тільки не втратить своєї значимості, а лише зросте.

Основне завдання моделювання та подальшого прогнозування кількості кібератак для суб'єктів господарювання є попередження атак шляхом збільшення захисту в необхідний момент.

Актуальність теми, обраної для дослідження, визначається тим, що кожного року суб'єкти господарювання стикаються з протиправними діями зі сторони кіберзлочинності. Саме тому при прогнозуванні збільшення кількості кібератак, суб'єкт зможе збільшити захист в потрібний час.

Метою даного дослідження є розробка математичної моделі прогнозування можливості та кількості кібератак на організації чи підприємства на основі моделей авто регресії та ковзного середнього.

Предметом дослідження виступають методи і моделі для прогнозування часових рядів.

Об'єктом дослідження є кількість кіберподій спрямованих на суб'єктів господарювання.

Для досягнення поставленої мети сформовано наступні задачі дослідження:

- розглянути основні види кібератак та способи захисту;
- проаналізувати сучасний стан кібербезпеки у світі;
- описати підходи до моделювання та прогнозування часових рядів;
- сформулювати вимоги до моделі;
- обрати програмне забезпечення для реалізації моделі;
- побудувати ARIMA модель;
- перевірити її на адекватність;
- спрогнозувати можливу кількість кібератак;

Результатами дослідження буде сформована модель часового ряду на основі методології ARIMA , яка зможе прогнозувати кількість кібератак для запобігання нанесення збитків підприємству.

## РОЗДІЛ 1 ТЕОРЕТИКО-МЕТОДОЛОГІЧНІ ОСНОВИ МОДЕЛОВАННЯ ТА ПРОГНОЗУВАННЯ ВИПАДКІВ КІБЕРАТАК

### 1.1 Поняття та основні види кібератак, основні засоби захисту

Кібератака - це будь-яка спрямована спроба отримати несанкціонований доступ до комп'ютера, обчислювальної системи або комп'ютерної мережі з метою заподіяння шкоди. Кібератаки мають на меті заподіяння шкоди певному фізичному суб'єкту . юридичній особі чи навіть державі. [1]

Більшість кібератак на сьогодні спрямована на комерційні організації для отримання фінансової вигоди. Простим прикладом є викрадення конфіденційних даних – номерів кредитних карток. Інші фінансово мотивовані атаки покликані вивести з ладу самі комп'ютерні системи, при цьому кіберзлочинці блокують комп'ютери, щоб їх власники та уповноважені користувачі не могли отримати доступ до необхідних їм програм або даних. Також мотивами для правопорушень такого роду може бути помста, радикальний активізм тощо.

Уряди усього світу також беруть участь у кібератаках, при цьому багато національних урядів визнають або підозрюють у розробці та здійсненні нападів на інші країни в рамках постійних політичних, економічних та соціальних суперечок. Ці типи атак класифікуються як кібервійни.

Найпоширеніші види кібератак:

- шкідливе ПЗ. Прикладами такого програмного забезпечення - програми-вимагателі, шпигунські програми та троянські програми. Залежно від типу шкідливого коду, зловмисне програмне забезпечення може використовуватися зловмисниками для викрадення або таємного копіювання конфіденційних даних, блокування доступу до файлів, порушення роботи

системи або приведення системи в непрацездатність;

- фішинг, в якому хакери соціально розробляють повідомлення електронної пошти, щоб спонукати одержувачів відкрити їх. Одержанувачів обманюють завантажити шкідливе програмне забезпечення, що міститься в електронному листі, відкривши вкладений файл або вбудоване посилання;
- DDoS, в якому хакери бомбардують сервери організації великими обсягами одночасних запитів даних, тим самим роблячи сервери не в змозі обробляти будь-які законні запити;
- введення SQL, де хакери вставляють шкідливий код на сервери за допомогою мови програмування Structured Query Language, щоб сервер розкривав конфіденційні дані;
- тунелювання системи доменних імен (DNS), складна атака, при якій зловмисники встановлюють, а потім використовують постійно доступний доступ - або тунель - до систем своїх цілей. Завантаження відбувається, коли людина відвідує веб-сайт, який, у свою чергу, заражає комп’ютер нічого не підозрюючого шкідливим програмним забезпеченням.

Очевидно, що фізичним особам та організаціям кіберзлочини краще попереджувати та якомога мінімізувати, аніж намагатися скоріш позбутися всіх негативних наслідків. Саме тому важливо не нехтувати власною інформаційною безпекою, використовувати всі доступні та необхідні засоби захисту.

Сучасний захист від шкідливих програм може блокувати небезпечні електронні листи та завантаження шкідливих програм з різних веб-сайтів. Брандмауери та проксі-сервери заблокують небезпечні та непотрібні служби. Примусова політика паролів не дозволить користувачам вибирати легкі паролі і блокувати облікові записи після певної кількості невдалих спроб. Для доступу до особливо конфіденційної корпоративної або особливо важливої інформації мають бути передбачені додаткові заходи аутентифікації.

Критично важливим для фактичного виявлення порушення є

можливість відслідковувати всю мережеву активність і аналізувати її для виявлення будь-яких зловмисних або незвичайних дій, а також застосовувати всі доступні засоби захисту та комбінувати їх.

## 1.2 Сучасний стан кібербезпеки у світі

Cybersecurity Ventures (провідний світовий дослідник та видавець, що висвітлює світову кіберекономіку та надійне джерело фактів та даних) - очікує, що глобальні витрати на кіберзлочинність зростатимуть на 15 відсотків на рік протягом наступних п'яти років, досягаючи 10,5 трлн. Дол. США щорічно до 2025 р., порівняно з 3 трлн. Дол. США в 2015 році. Оцінка вартості збитків базується на історичних цифрах кіберзлочинності, включаючи нещодавні темпи зростання за минулий рік, різке збільшення обсягів зловмисних груп та організованої злочинності.

Витрати на кіберзлочинність включають пошкодження та знищення даних, викрадені гроші, втрату продуктивності, крадіжку інтелектуальної власності, крадіжку персональних та фінансових даних, розкрадання, шахрайство, відновлення та видалення зламаних даних та шкоду репутації. Організовані суб'єкти кіберзлочинності об'єднують зусилля, і ймовірність розкриття та переслідування за оцінками становить 0,05% у США, згідно з Глобальним звітом Світового економічного форуму за 2020 рік.

Характер і частота кібератак, а також масштаби збитків від них також залежить від сфери діяльності і масштабів структури об'єкта нападу[10]. Масштабні наслідки несуть за собою кібератаки на великі виробництва та промислові об'єкти, особливо державного значення, що поме призвести навіть до техногенної катастрофи. Але, як правило, саме малий та середній бізнес стає основною ціллю кіберзлочинців.

Великий удар направлений на такий бізнес-сектор, адже хакери знають, що його власники часто майже не знаються на кібербезпеці або застосовують

спрощені заходи, яких недостатньо. Також хакери користуються тим фактом, що більшість атак залишаються непоміченими.

Для успішної боротьби зі зловмисними намірами надзвичайно важливо, щоб компанії зробили обізнаність, запобігання та кібербезпеку частиною своєї бізнес-культури. Також незахищений малий бізнес є шляхом доступу до зламу більших підприємств. Наприкінці 2013 року, хакери отримали номери кредитних карт 40 мільйонів клієнтів пункту продажів Target, вкравши облікові дані у провайдера контактів Target – HVAC.[11].

Важливо відмітити, що для багатьох представників малого та середнього бізнесу будь-який злом та викрадення і псування даних може обернутися банкротством, адже для відновлення цих комерційних даних необхідна буде велика кількість фінансових та часових ресурсів.

За даними PurpelSec, які постійно доповнюють актуальну світову статистичну інформацію щобо кібербезпеки:

- 43% кібератак націлені на малий бізнес;
- 70% малих підприємств не готові до кібератаки;
- 51% малих підприємств заявляють, що не виділяють жодного бюджету на кібербезпеку;
- 58% жертв шкідливого програмного забезпечення класифікуються як малий бізнес.

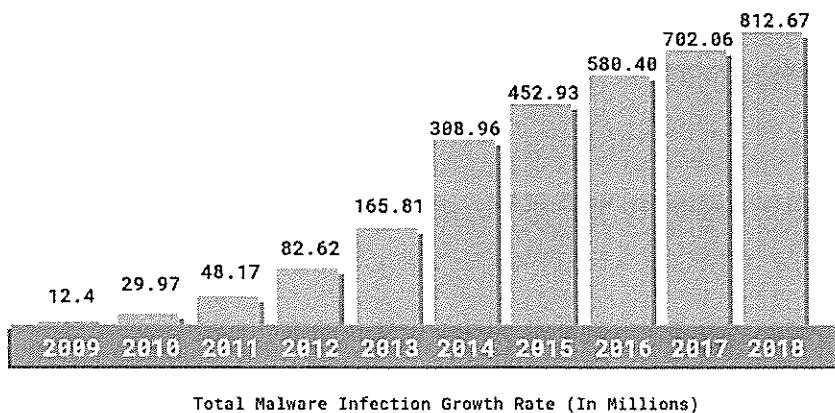


Рисунок 1.1 – Зростання загальна кількість заражень шкідливим програмним забезпеченням зростає протягом десяти років

На рисунку 1.1 зображене постійне зростання кіберзлочинів, а саме зараження шкідливим ПЗ. До типів шкідливих програм належать комп’ютерні віруси, троянські програми, шпигунські програми, програми-вимагателі, рекламні програми, хробаки, шкідливе програмне забезпечення без файлів або гіbridні атаки.

Отже, можемо зробити висновки про розвиток протилежних сил. З одного боку – рівня кіберзлочинності, кіберугруповувань, вдосконалення кіберзлочинів загалом, а з іншого розуміння важливості захисту, прививання культури та систем кібербезпеки. [12]

### 1.3 Підходи до моделювання та прогнозування кібератак

Метод прогнозування складається з послідовності дій, які потрібно зробити для отримання моделі прогнозування. Модель прогнозування – це формалізоване співвідношення, що адекватно описує досліджуваний процес і є базою для отримання прогнозованих значень. Поєднання методу і моделі формує процес моделювання.

Велика кількість систем кібербезпеки ідентифікують загрози через вже відомі прототипи процесів та дій, що вже колись використовувались хакерами. Процес створення нових підходів для зламу інформаційної системи невпинний, а комп’ютерні віруси видозмінюються та розвиваються майже, як біологічні. Саме тому, перевірка однотипних загроз не завжди даватиме очікуваний результат і підходить лише у випадку сконя кібератаки не досить досвідченим шахраєм. В такому випадку корисно буде прогнозувати саме кількість кібератак, для прийняття додаткових дій для забезпечення надійного захисту.

Всі сучасні методи прогнозування можна поділити на дві групи: імовірносні і точкові. В останній час все більше дослідників та науковців звертають свою увагу на імовірнісне прогнозування кібератак. Це можна пояснити тим, що імовірнісні прогнози дозволяють отримати результат не

тільки саме майбутніх подій, а й оцінки їх здійснення. Різновидом імовірнісного прогнозування являється інтервальне прогнозування [13]. Головна ідея такого прогнозування полягає в тому, що прогнозується інтервал (із двох уже заданих інтервалів), у якому може знаходитись майбутнє значення показника на основі оцінок ймовірностей цих подій. Розмежувальна межа інтервалів задається розрахунковим способом, ґрунтуючись на статистичних характеристиках цього показника.

Наприклад, прогнозування може не починатися з уже спостереженої зловмисної події, а скоріше з імовірністю, що дана атака відбудеться, основуючись на вже відомих статистичних даних. Прикладом підходу, заснованого на безперервній моделі, є часові ряди, що представляють собою кількість атак на певну систему або мережу за певний проміжку часу. Потім часовий ряд може бути використаний для прогнозування того, чи станеться атака чи ні, або для прогнозування кількості можливих атак. Удосконалені методи можуть вирахувати типи нападів та характеристики нападників та жертв щоб фахівці з кібербезпеки могли оцінити, який тип 19 атак буде найбільш ймовірним, хто стане нападником та хто має стати жертвою [16].

Таблиця 1.1 – Порівняльна характеристика методів прогнозування

Метод	Переваги	Недоліки
Дослідження часових рядів	Великий вибір способу побудови прогнозу, простота реалізації	Складний вибір моделі
Теорія ігор	Результат високої точності	Кожен гравець повинен знати стратегію супротивника

Отже, для побудови моделі прогнозування можливості кібератак було обрано дослідження часових рядів, через його простоту і способи побудови моделі.

## РОЗДІЛ 2 РОЗРОБКА МОДЕЛІ ПРОГНОЗУВАННЯ МОЖЛИВИХ ВИПАДКІВ КІБРАТАК

### 2.1 Моделі прогнозування часових рядів

Часовий ряд - це послідовність значень досліджуваної ознаки (статистичного показника), впорядкована у хронологічному порядку. Використовують також терміни: ряд динаміки, динамічний ряд. окремі спостереження часового ряду називають його рівнями, або елементами. [18]

Прикладами часових рядів є щомісячна кількість опадів, щорічний прибуток Google, щоденні ціни на акції тощо. На рисунку зображене квартальне виробництво пива в Австралії з 1992 до 2010 року [19]

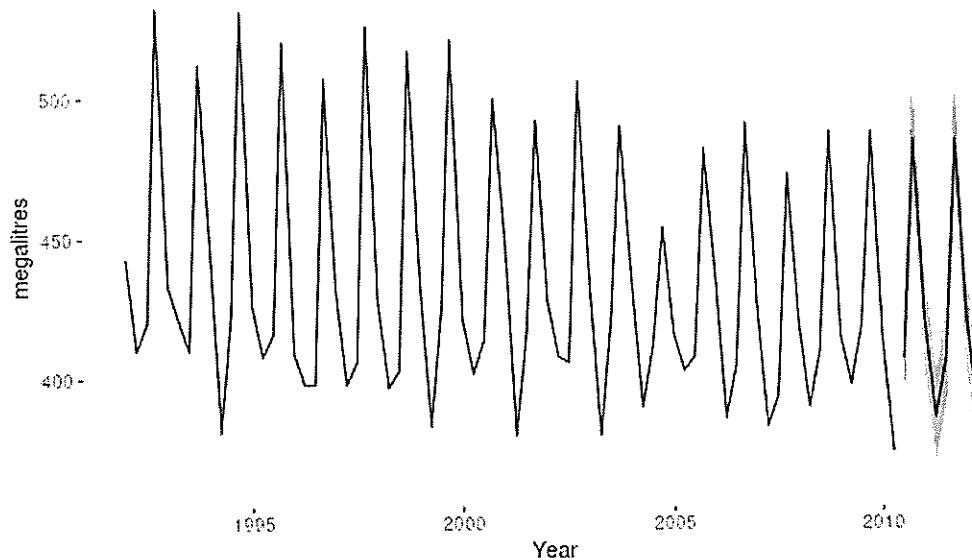


Рисунок 2.1 – Квартальне виробництво пива в Австралії з 1992 до 2010 року

Часовий ряд можна записати у короткому вигляді:

$$y_t, t = 1, 2, 3, \dots n, \quad (2.1)$$

де  $t$  – рівновіддалені моменти спостережень ( година, доба, місяць, рік);

Часовий ряд доцільно використовувати при розрахунках та будувати

математичну модель на його основі, якщо рівні ряду відповідають деяким умовам. Вони мають буди порівняні та однорідні.

Якщо часовий ряд має одинакові одиниці вимірювання, однакову періодичність обліку окремих спостережень, одинаковий ступінь агрегування, обчислюються за однією методикою, такий ряд можна назвати порівняним. Непорівняність часового ряду може бути через безліч причин і її неможливо усунути лише формальними методами.

Якщо у часовому ряді відсутні аномальні, нетипові спостереження та викривлення тенденції, його називають однорідним. Під аномальним рівнем розуміють таке значення часового ряду, що не відповідає потенційним можливостям даної економічної системи. Такий аномальний стрибок чи спад може чинити суттєвий вплив на основні характеристики ряду. Причинами аномальних значень можуть бути посилення першого та другого роду. Помилки першого роду, тобто технічні, зустрічаються частіше та потребують виправлення.

Для знаходження таких аномальних рядів використовують різні статистичні методи. Найпопулярнішим з них є модифікований метод Ірвіна. Він базується на порівнянні двох сусідніх значень та розрахунку значення  $\lambda$ , яке знаходиться за формулою 2.2:

$$\lambda_t = \frac{|y_t - y_{t-1}|}{\sigma_y}; t = 2, 3, \dots, n; \quad (2.2)$$

де  $\sigma_y$  – оцінка середньоквадратичного відхилення вибіркового ряду  $y_t$ , яка розраховується з використанням формули (2.3) :

$$\sigma_y = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y})^2 + (y_{t+1} - \hat{y})^2}{2}}; \hat{y} = \frac{y_{t-1} + y_{t+1}}{2}. \quad (2.3)$$

Якщо розрахункові дані  $\lambda$  не перевищують критичні значення, то такі

рівні часового ряду не містять аномалій. Нижче в таблиці 2.1 наведені критичні значення для рівня значущості  $\alpha = 0,05$ .

Таблиця 2.1 – Значення критерію Ірвіна

n	1	2	3	10	30	50	100	400	1000
$\lambda_\alpha$	2	2,8	2,2	1,5	1,2	1,1	1	0,9	0,8

Прогнозування є важливою частиною при управлінні будь-яким бізнесом. Практично все, що робить підприємство, вимагає прогнозування майбутніх потреб, щоб вони могли бути передбачені або заплановані, включаючи продажі, сировину / напівпродукти та робочу силу. Зараз добре розроблені науковцями різні прийоми дослідження часових рядів. Далі зупинимося більш детально на класичних статистично-обґрунтованих підходах – моделях авторегресії.

ARIMA ( $p, d, q$ ) - методика прогнозування, яка проектує майбутні значення серії на основі власної інерції або відсталих значень. Його основне застосування в області короткострокового прогнозування і вимагає щонайменше 40 історичних даних. Дано модель найкраще працює, коли дані демонструють послідовну закономірність у часі з мінімальною кількістю відхилень. Іноді ARIMA, яку іноді називають Бокс-Дженкінсом (за оригінальними авторами), перевершує експоненціальні методи згладжування, коли дані досить довгі та кореляція між минулими спостереженнями стабільна. Якщо дані короткі або дуже мінливі, тоді якийсь метод згладжування може працювати ефективніше.

Частина AR ARIMA вказує на те, що еволюційна змінна, що цікавить, регресується на власних відсталих (тобто попередніх) значеннях:

$p$  - порядок (кількість часових лагів) авторегресивної моделі I (інтегрована диференціація);

$d$  - ступінь різниці (скільки разів дані віднімали минулі значення);

Частина MA вказує на те, що помилка регресії насправді є лінійною комбінацією термінів помилок, значення яких мали місце одночасно та в

різний час у минулому;

q - порядок моделі ковзного середнього.

Рівняння прогнозування ARIMA для стаціонарного часового ряду є рівнянням лінійної регресії, в якому предиктори складаються з лагів залежної змінної та / або лагів помилок прогнозу.

Часовий ряд може включати в себе тренд, сезонну складову, циклічність та випадкову компоненту. Якщо в часовому ряді спостерігається сезонність, використовуємо сезонну декомпозицію. В методі сезонної декомпозиції тренд і циклічну компоненту поєднують. Виділяємо два основних види взаємодії компонент : адитивний та мультиплікативний.

Метод експоненціального згладжування передбачає згладжування кожного рівня часового ряду за допомогою зваженої ковзної середньої. Для розрахунку такої експоненціальної середньої використовується наведена формула 2.6:

$$E_n = W \cdot Y_n + (1 - W) \cdot E_{n-1}. \quad (2.6)$$

де n – параметр згладжування;

$E_n$  – експоненціальна середня в точці n.

## 2.2 Формулювання вимог до моделі та опис вхідних змінних

Модель прогнозування кількості кібератак має відповідати таким основним вимогам:

- 1) адекватність – модель часового ряду має відповідати реальності та враховувати найважливіші ознаки.
- 2) точність – побудований прогноз на основі моделі має бути наближенним до фактичних значень показника. Точність моделі ми перевіримо на останніх кроках, порівнюючи прогнозовані дані з фактичними, відомими.

3) модель має бути проста для розуміння та подальшого її використання. Чим менше менші обчислювальні ресурсні затрати (час та оперативна пам'ять ) на побудову моделі , тим вона краще.

4) актуальність – модель має надавати характеристику досліджуваного об'єкта, який на чинить вагомий вплив на економіку та суспільство.

5) своєчасність – дані часового ряду мають бути актуальними.

Вхідна змінна майбутньої моделі – кількість кібер-подій, що являють собою підтвержені аналітиками прояви шкідливого ПЗ. Дані для розрахунків складаються з виявлених аналітиками інцидентів від великого постачальника послуг комп'ютерної безпеки (CSSP) для Міністерства оборони США. Набір даних включає в себе щотижневі підрахунки кібер-атак приблизно за 7 років.

На рисунку 2.2 зображена концептуальна модель прогнозування кількості кібератак, її вхідні та вихідні дані.

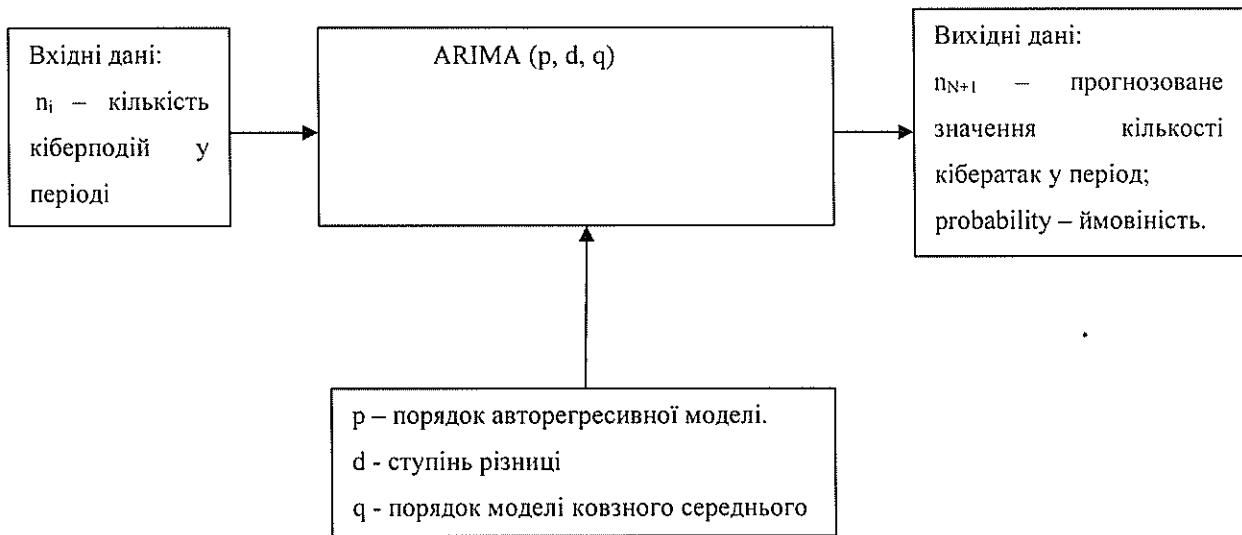


Рисунок 2.2 – Концептуальна модель прогнозування кількості кібератак способом ARIMA

## РОЗДІЛ З МОДЕЛЮВАННЯ МОЖЛИВИХ ОБСЯГІВ КІБЕРАТАК

### 3.1 Аналіз часового ряду

Першим кроком необхідно перевірити ряд на однорідність та стаціонарність.

Найпоширенішим тестом перевірки часового ряду на однорідність є модифікований метод Ірвіна, результати якого наведені на рисунку 3.1. Для розрахунків була обрана програма MS EXCEL.

Модифікований метод Ірвіна						
week	yt	yt	(yt-1)-yt)^2	(yt+1)-yt)^2	$\Sigma$	$\lambda$
1	8	-	-	-	-	-
2	11	5	9	9	18	0,0189
3	2	6,5	20,25	20,25	40,5	0,0567
4	2	1	1	1	2	0,0000
5	0	2,5	0,25	0,25	0,5	0,0126
6	3	2,5	6,25	6,25	12,5	0,0189
7	5	3	0	0	0	0,0126
8	3	5	0	0	0	0,0126
9	5	3	0	0	0	0,0126
10	3	6	1	1	2	0,0126
11	7	2,5	0,25	0,25	0,5	0,0252
12	2	7,5	0,25	0,25	0,5	0,0315
13	8	3	1	1	2	0,0378
14	4	6	4	4	8	0,0252
15	4	4	0	0	0	0,0000
16	4	10,5	42,25	42,25	84,5	0,0000
17	17	6	4	4	8	0,0819
18	8	12	25	25	50	0,0567
19	7	7,5	0,25	0,25	0,5	0,0063
20	7	7	0	0	0	0,0000
21	7	6	1	1	2	0,0000
22	5	6	1	1	2	0,0126

Рисунок 3.1 – Фрагмент перевірки часового ряду на однорідність

Після перевірки було отримано розрахункове значення  $\lambda$  для кожного рівня ряду, яке порівнюємо з табличним значенням (табл. 3.1). Часовий ряд – однорідний та підходить для подальшого аналізу.

Перевірку на стаціонарність проводимо за допомогою статистичного пакету EViews. Дане програмне забезпечення спеціалізується на аналізі економічних даних, моделюванні та прогнозуванні, та має все необхідне для побудови ARIMA-моделі.

Першим кроком завантажуємо початкові дані (рисунок 3.2). Графічна візуалізація часового ряду представлена на рисунку 3.3.

Series: SERIES01 Workfile: E:\views\Eviews\	
View	Proc
Object	Properties
Print	Name
Freeze	Default
	Sort
	Edit -/
	Smpl -/
	AdjL
Series01	
1	8
2	11
3	2
4	2
5	0
6	3
7	5
8	3
9	5
10	3
11	7
12	2
13	8
14	4
15	4
16	4
17	17
18	8
19	7
20	7
21	7
22	7

Рисунок 3.2 – Початкові данні

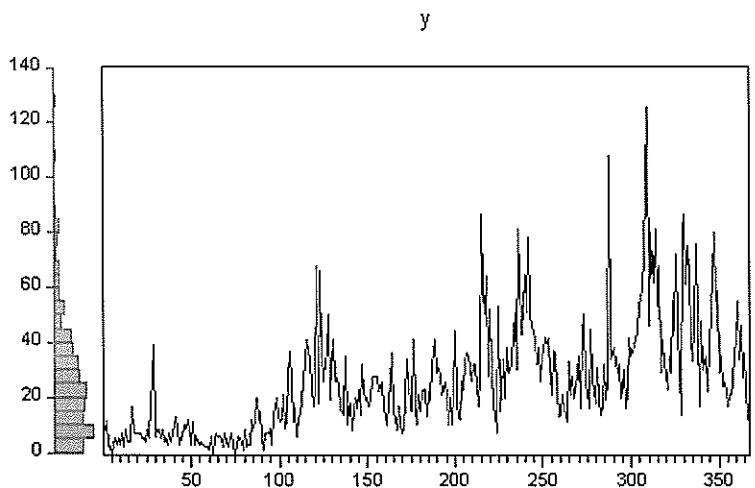


Рисунок 3.3 – Графік часового ряду кількості кібератак

Перш ніж перейти до основної частини моделювання часового ряду, необхідно проаналізувати його на стаціонарність. Під стаціонарними часовими рядами розуміють такі часові ряди, елементи яких є випадковими величинами з постійним математичним очікуванням і постійної дисперсією. Найпоширенішим тестом для перевірки ряду на стаціонарність є розширений

тест Дікі-Фулера. Даний тест проводимо за допомогою вбудованої функції EViews (Unit root test), використаємо 3 тести – з константою, з трендом та константою, та без жодної складової. Отримані дані на рисунку 3.4-3.6.

Null Hypothesis: Y has a unit root Exogenous: None Lag Length: 15 (Automatic - based on AIC, maxlag=16)		
	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.596735	0.4584
Test critical values:		
1 % level	-2.571586	
5 % level	-1.941732	
10 % level	-1.616093	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation  
Dependent Variable: D(Y)  
Method: Least Squares  
Date: 05/26/21 Time: 21:41  
Sample (adjusted): 17 366  
Included observations: 350 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	-0.014369	0.024080	-0.596735	0.5511
D(Y(-1))	-0.661984	0.058745	-11.26886	0.0000
D(Y(-2))	-0.426097	0.067033	-6.356545	0.0000

Рисунок 3.4 – Результати розширеного тесту Дікі-Фулера  
для початкового ряду

Null Hypothesis: Y has a unit root  
Exogenous: Constant  
Lag Length: 15 (Automatic - based on AIC, maxlag=16)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.969873	0.3002
Test critical values:		
1 % level	-3.448835	
5 % level	-2.869581	
10 % level	-2.571122	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation  
Dependent Variable: D(Y)  
Method: Least Squares  
Date: 05/26/21 Time: 21:43  
Sample (adjusted): 17 366  
Included observations: 350 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	-0.094561	0.048004	-1.969873	0.0497
D(Y(-1))	-0.593776	0.068367	-8.685127	0.0000
D(Y(-2))	-0.367021	0.073455	-4.996567	0.0000

Рисунок 3.5 – Результати розширеного тесту Дікі-Фулера з константою для  
початкового ряду

Null Hypothesis: Y has a unit root  
 Exogenous: Constant, Linear Trend  
 Lag Length: 2 (Automatic - based on AIC, maxlag=16)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-5.845028	0.0000
Test critical values:		
1% level	-3.983541	
5% level	-3.422252	
10% level	-3.133975	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation  
 Dependent Variable: D(Y)  
 Method: Least Squares  
 Date: 05/26/21 Time: 21:44  
 Sample (adjusted): 4 366  
 Included observations: 363 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
Y(-1)	-0.335818	0.057454	-5.845028	0.0000
D(Y(-1))	-0.359711	0.061571	-5.842254	0.0000
D(Y(-2))	-0.162484	0.052575	-3.090512	0.0022

Рисунок 3.6 – Результати розширеного тесту Дікі-Фулера з константою та трендом для початкового ряду

За результатом тесту Дікі-Фулера було отримано розрахункові значення та критичні значення t-статистики МакКінона . Порівнявши ці значення отримуємо: за першим та другим тестом ряд не стаціонарний, абсолютна величина розрахункового значення t-статистики більша за абсолютні величини критичного значення при 1 %, 5 %, 10 % рівнях значущості.

Ми не відкидаємо нульову гіпотезу про те, що часовий ряд має одиничний корінь і є нестаціонарним за двома тестами Дікі-Фулера, а також через наявність тренду . Наступним кроком проводимо повторний розширений тест Дікі-Фулера для перших різниць (рис. 3.7), аби перевірити, чи стане ряд стаціонарним.

Null Hypothesis: D(Y) has a unit root  
 Exogenous: None  
 Lag Length: 3 (Automatic - based on AIC, maxlag=4)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-13.28461	0.0000
Test critical values:		
1% level	-2.571383	
5% level	-1.941704	
10% level	-1.616111	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(Y,2)

Method: Least Squares

Date: 05/25/21 Time: 22:17

Sample (adjusted): 6 366

Included observations: 361 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(Y(-1))	-2.234338	0.168190	-13.28461	0.0000
D(Y(-1),2)	0.622476	0.140992	4.414966	0.0000

Рисунок 3.7 – Результати розширеного тесту Дікі-Фулера для перших різниць

За результатом тесту Дікі-Фулера для перших різниць абсолютна величина розрахункового значення t-статистики (-13,285) менша за абсолютні величини критичного значення при 1 %, 5 %, 10 % рівнях значущості. Отже, приймаємо нульову гіпотезу про те, що ряд стаціонарний.

Для попереднього визначення загального вигляду майбутньої ARIMA моделі і кількості лагів для кожної складової, скористаємося графіками автокореляційної і часткової автокореляційної функції показника кількості кабератак. Аналіз рисунку 3.8 показує, що сезонність в даному ряді відсутня, а значущими є перший лаг.

Sample: 1 366  
Included observations: 365

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	-0.451	-0.451	75.001 0.000
		2	-0.016	-0.276	75.098 0.000
		3	0.081	-0.072	77.520 0.000
		4	-0.091	-0.110	80.584 0.000
		5	0.069	-0.012	82.369 0.000
		6	-0.090	-0.106	85.415 0.000
		7	0.055	-0.035	86.567 0.000
		8	-0.000	-0.019	86.567 0.000
		9	-0.082	-0.100	89.094 0.000
		10	0.015	-0.123	89.181 0.000
		11	0.081	0.018	91.645 0.000
		12	-0.059	-0.017	92.982 0.000
		13	-0.033	-0.081	93.390 0.000
		14	-0.051	-0.183	94.395 0.000
		15	0.042	-0.135	95.066 0.000
		16	0.068	0.001	96.858 0.000
		17	-0.044	0.009	97.608 0.000
		18	0.076	0.071	99.825 0.000
		19	-0.074	-0.027	101.94 0.000
		20	-0.105	-0.208	106.22 0.000
		21	0.251	0.104	130.80 0.000
		22	-0.164	-0.005	141.25 0.000
		23	0.040	-0.014	141.87 0.000
		24	0.027	0.006	142.16 0.000
		25	-0.041	0.024	142.81 0.000

Рисунок 3.8 – Графік автокореляційної та часткової автокореляційної функції перших різниць часового ряду

### 3.2 Побудова ARIMA моделі

Першим кроком оцінюємо AR складову за допомогою звичайного методу найменших квадратів. Статистично значущими є перший та другий лаг. Оптимальними лагами для включення в модель є ті, за яких досягається мінімальне значення інформаційного критерію Акайк (AIC).

Включаючи перший лаг, отримаємо результат, вказані на рисунку 3.9. Критерій Акайк = 8,156.

Dependent Variable: D(Y)				
Method: Least Squares				
Date: 05/26/21 Time: 22:18				
Sample (adjusted): 3 366				
Included observations: 364 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.034964	0.746579	0.046832	0.9627
D(Y(-1))	-0.454526	0.047014	-9.667859	0.0000
R-squared	0.205212	Mean dependent var	0.000000	
Adjusted R-squared	0.203017	S.D. dependent var	15.95500	
S.E. of regression	14.24365	Akaike info criterion	8.155979	
Sum squared resid	73443.16	Schwarz criterion	8.177392	
Log likelihood	-1482.388	Hannan-Quinn criter.	8.164490	
F-statistic	93.46750	Durbin-Watson stat	2.244618	
Prob(F-statistic)	0.000000			

Рисунок 3.9 – Результати оцінювання AR-складової при включеному першому лагу

Наступний кроком додаємо другий лаг (рис. 3.10). Критерій Акайк = 8,082. Оптимальним вважається таке значення лагу, при якому досягається найменше значення критерію AIC, а це означає, що оптимальним порядком авторегресії нашої моделі є 2.

Dependent Variable: D(Y)				
Method: Least Squares				
Date: 05/26/21 Time: 22:25				
Sample (adjusted): 4 366				
Included observations: 363 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.079369	0.719819	0.110263	0.9123
D(Y(-1))	-0.580417	0.050757	-11.43524	0.0000
D(Y(-2))	-0.278979	0.050777	-5.494248	0.0000
R-squared	0.266646	Mean dependent var	0.024793	
Adjusted R-squared	0.262571	S.D. dependent var	15.97000	
S.E. of regression	13.71402	Akaike info criterion	8.082945	
Sum squared resid	67706.78	Schwarz criterion	8.115130	
Log likelihood	-1464.054	Hannan-Quinn criter.	8.095738	
F-statistic	65.44749	Durbin-Watson stat	2.034181	
Prob(F-statistic)	0.000000			

Рисунок 3.10 - Результати оцінювання AR-складової першого порядку

Мінімальне значення критерію Акайк було досягнуто для специфікації такого виду:

$$D(Y) = m + \alpha_1 D(Y(-1)) + \alpha_2 D(Y(-2)); \quad (3.1)$$

Процедура пошуку оптимального порядку МА-складової моделі ARIMA аналогічна процедурі визначення оптимального порядку AR - складової. На цьому етапі до вже визначеної AR-складової поступово додають MA(q)-складові та розраховують значення Шварц-критерію. Модель, яка має найменше значення критерію – претендент для подальшого аналізу. Мінімальне значення критерію Шварца – 8,127 (рисунок 3.11), досягається для загальної специфікації моделі в EViews :

$$D(Y) C D(Y(-1)) D(Y(-2)) RESIDES(-1); \quad (3.2)$$

Dependent Variable: D(Y) Method: Least Squares Date: 05/26/21 Time: 22:38 Sample (adjusted): 5 366 Included observations: 362 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.081843	0.720588	0.113578	0.9096
D(Y(-1))	-0.323934	0.182228	-1.777633	0.0763
D(Y(-2))	-0.162160	0.094419	-1.717447	0.0868
RESID01(-1)	-0.279011	0.190036	-1.468198	0.1429
R-squared	0.271250	Mean dependent var		0.024862
Adjusted R-squared	0.265144	S.D. dependent var		15.99210
S.E. of regression	13.70903	Akaike info criterion		8.084975
Sum squared resid	67281.64	Schwarz criterion		8.127977
Log likelihood	-1459.380	Hannan-Quinn criter.		8.102070
F-statistic	44.41747	Durbin-Watson stat		2.008643
Prob(F-statistic)	0.000000			

Рисунок 3.11 – Результати оцінювання МА-складової першого порядку

Dependent Variable: D(Y)  
 Method: Least Squares  
 Date: 05/26/21 Time: 22:38  
 Sample (adjusted): 5 366  
 Included observations: 362 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.081843	0.720588	0.113578	0.9096
D(Y(-1))	-0.323934	0.182228	-1.777633	0.0763
D(Y(-2))	-0.162160	0.094419	-1.717447	0.0868
RESID01(-1)	-0.279011	0.190036	-1.468198	0.1429
R-squared	0.271250	Mean dependent var	0.024862	
Adjusted R-squared	0.265144	S.D. dependent var	15.99210	
S.E. of regression	13.70903	Akaike info criterion	8.084975	
Sum squared resid	67281.64	Schwarz criterion	8.127977	
Log likelihood	-1459.380	Hannan-Quinn criter.	8.102070	
F-statistic	44.41747	Durbin-Watson stat	2.008643	
Prob(F-statistic)	0.000000			

Рисунок 3.12 – Результати оцінювання МА-складової другого порядку

Оцінивши всі варіанти, найоптимальнішим буде AR-складова 2-го порядку, а МА-складова першого порядку. Константу виключаємо з моделі, адже вона не значуча. На рисунку 3.13 відображені результати оцінювання ARIMA-моделі, де  $p = 2$ ,  $d = 1$ ,  $q = 1$ .

Dependent Variable: D(Y)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/26/21 Time: 22:58  
 Sample: 2 366  
 Included observations: 365  
 Convergence achieved after 35 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	0.282655	0.048309	5.851014	0.0000
AR(2)	0.198866	0.049480	4.019089	0.0001
MA(1)	-0.922956	0.027651	-33.37874	0.0000
SIGMASQ	177.5636	5.979614	29.69483	0.0000
R-squared	0.298699	Mean dependent var	0.008219	
Adjusted R-squared	0.292871	S.D. dependent var	15.93384	
S.E. of regression	13.39892	Akaike info criterion	8.041858	
Sum squared resid	64810.72	Schwarz criterion	8.084596	
Log likelihood	-1463.639	Hannan-Quinn criter.	8.058843	
Durbin-Watson stat	2.047142			
Inverted AR Roots	.61		-.33	
Inverted MA Roots	.92			

Рисунок 3.12 – Результати оцінювання ARIMA моделі (2,1,1)

Основна специфікація ARIMA моделі (2,1,1):

$$D(Y) AR(Y(-1)) AR(Y(-2)) MA(-1); \quad (3.3)$$

Наступним кроком необхідно перевірити якість побудованої моделі. Для того, щоб модель вважалась адекватною, необхідно, щоб залишки оціненого фінального рівняння були білим шумом. Для перевірки скористаємося корелограмами та тестом Дікі-Фулера (рис 3.13-3.14). Як можна побачити з графіку автокореляції (рис 3.13) всі її коефіцієнти статистично не значущі, отже, попередньо можна зробити висновок про стаціонарність залишків.

Перевірка залишків на білий шум на основі тесту Дікі-Фулера (рис. 3.14) показує відсутність одиничного кореня, тобто залишки стаціонарні. Таким чином, залишки оціненої моделі можна вважати білим шумом, а модель адекватною.

Після перевірки залишків на стаціонарність, побудуємо та проаналізуємо гістограму та показники нормальності розподілу залишків, отримаємо такі основні значення:

- Probability менше за 0,05, у свою чергу це свідчить про те, що гіпотеза про нормальність розподілу відкидається.
- Коефіцієнт асиметрії (Skewness) більш нуля, відслідковується правостороння асиметрія, тобто позитивні залишки переважають над негативними. Звідси можемо зробити висновок, що в кількості кібератак частіше спостерігались різкі підйоми, ніж різки аналогічні спади.
- Коефіцієнт ексцесу (Kurtosis) більше 3 – розподіл гостроверхий. Це означає, що в даному розподілі є виражене ядро щільності розподілу, всередині якого діапазон коливань залишків не значний і розсіяне «гало», де розкид коливань величини залишків досить значний. З точки зору передбачення кількості кібератак, таких характер розподілу означає, що 99% прогноз буде лише при дуже великому рівні надійності.

Date: 05/25/21 Time: 23:48	Sample (adjusted): 2 366	Included observations: 365 after adjustments	Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob.
					1 -0.029	-0.029	0.3193	0.572
					2 -0.040	-0.040	0.8974	0.638
					3 0.123	0.121	6.4663	0.091
					4 -0.003	0.002	6.4705	0.167
					5 0.042	0.052	7.1314	0.211
					6 -0.045	-0.058	7.8841	0.247
					7 0.034	0.037	8.3274	0.305
					8 -0.017	-0.032	8.4325	0.392
					9 -0.103	-0.090	12.432	0.190
					10 -0.001	-0.019	12.432	0.257
					11 0.056	0.061	13.633	0.254
					12 -0.078	-0.060	15.946	0.194
					13 -0.103	-0.097	19.976	0.096
					14 -0.073	-0.096	22.005	0.079
					15 0.051	0.053	22.985	0.084
					16 0.087	0.114	25.871	0.056
					17 0.007	0.047	25.890	0.076
					18 0.053	0.039	26.978	0.079
					19 -0.088	-0.112	29.976	0.052
					20 -0.038	-0.051	30.522	0.062
					21 0.220	0.202	49.351	0.000
					22 -0.061	-0.049	50.812	0.000
					23 0.013	0.016	50.881	0.001
					24 0.042	0.012	51.566	0.001
					25 -0.020	0.002	51.723	0.001
					26 0.008	-0.031	51.748	0.002
					27 -0.009	-0.010	51.783	0.003
					28 0.049	0.030	52.738	0.003
					29 -0.090	-0.057	55.937	0.002
					30 -0.078	-0.012	58.385	0.001
					31 0.074	0.053	60.595	0.001
					32 -0.023	-0.067	60.802	0.002
					33 -0.039	-0.029	61.400	0.002
					34 -0.030	-0.006	61.753	0.002
					35 -0.060	-0.021	63.227	0.002
					36 0.120	0.127	69.042	0.001

Рисунок 3.13 – Корелограма залишків моделі

Augmented Dickey-Fuller test statistic			
Test critical values:		1% level	-2.571366
		5% level	-1.941701
		10% level	-1.616113

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation  
Dependent Variable: D(RESID02)  
Method: Least Squares  
Date: 05/25/21 Time: 23:54  
Sample (adjusted): 5 366  
Included observations: 362 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID02(-1)	-0.935764	0.094167	-9.937325	0.0000
D(RESID02(-1))	-0.088246	0.075475	-1.169213	0.2431
D(RESID02(-2))	-0.123577	0.052650	-2.347138	0.0195
R-squared	0.520177	Mean dependent var	-0.053813	
Adjusted R-squared	0.517504	S.D. dependent var	19.16341	
S.E. of regression	13.31128	Akaike info criterion	8.023353	
Sum squared resid	63611.27	Schwarz criterion	8.055605	
Log likelihood	-1449.227	Hannan-Quinn criter.	8.036174	
Durbin-Watson stat	1.991455			

Рисунок 3.14 – Результати перевірки залишків моделі на білий шум

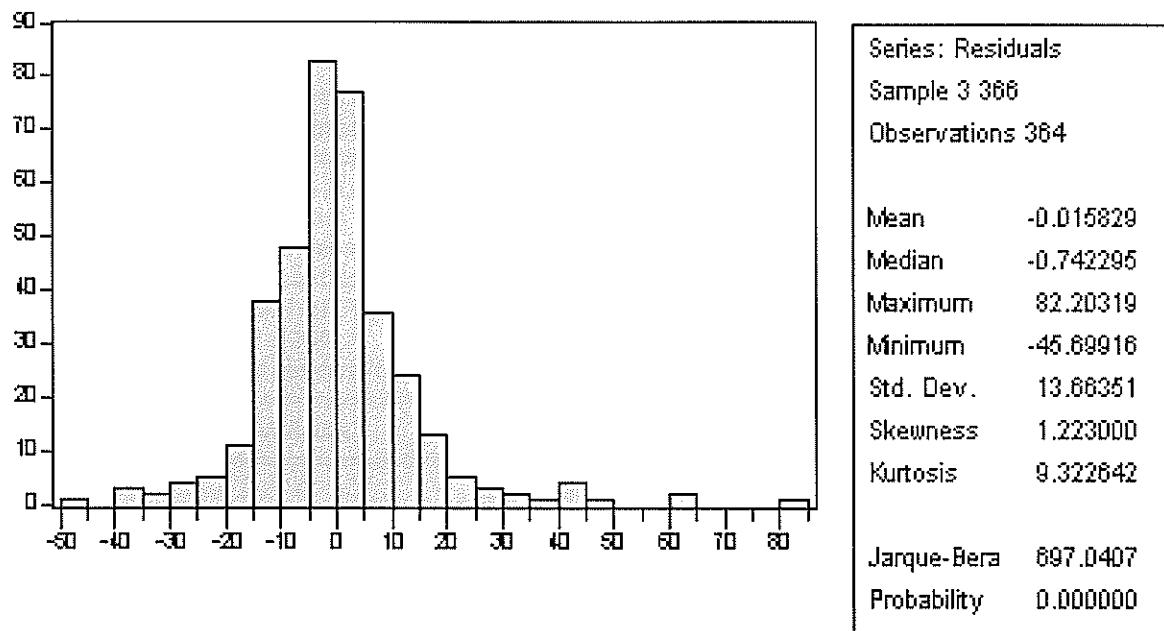


Рисунок 3.15 – Результати тестування на нормальний розподіл залишків

Перевіряємо нульову гіпотезу про те, що не існує зв'язку між дисперсією залишків вихідного рівняння і незалежними змінними, тобто залишки гомоскедастичні. Однією з важливих передумов МНК є передумова про гомоскедастичність залишків, тобто про сталість дисперсії залишкових членів рівняння регресії. Виконання цієї передумови (поряд з іншими) забезпечує хороші якості обраних оцінок моделі методом найменших квадратів.

В нашому випадку гіпотеза про гомоскедастичність залишків приймається, адже показник  $\text{Obs}\cdot R^2$  менше прийнятого рівня значущості. Такі дані отримали за допомогою тесту Уайта в пакеті EViews (рис. 3.16).

Тест Дікі-Фулера (рис.3.18) для других різниць часового ряду зазначає, що ряд стаціонарний, адже розрахункове значення менше, ніж табличне. Отже, наступним кроком побудуємо модель з такими ж складовими AR та MA для других різниць, адже є вірогідність, що така модель краще описуватиме у.

## Heteroskedasticity Test: White

F-statistic	263.3695	Prob. F(10,353)	0.0000
Obs*R-squared	319.4882	Prob. Chi-Square(10)	0.0000
Scaled explained SS	1299.545	Prob. Chi-Square(10)	0.0000

Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 05/27/21 Time: 15:42

Sample: 3 366

Included observations: 364

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	75.14853	10.51813	7.144664	0.0000
GRADF_01^2	25.26117	2.319053	10.89288	0.0000
GRADF_01*GRADF_02	24.68379	3.188909	7.740511	0.0000
GRADF_01*GRADF_03	56805.09	5837.969	9.730283	0.0000
GRADF_01*GRADF_04	280386.7	28653.41	9.785459	0.0000
GRADF_02^2	6.142150	1.909769	3.216173	0.0014
GRADF_02*GRADF_03	24492.15	4479.353	5.467788	0.0000
GRADF_02*GRADF_04	120701.0	21502.48	5.613354	0.0000
GRADF_03^2	34489202	3409470.	10.11571	0.0000
GRADF_03*GRADF_04	3.40E+08	33590833	10.11122	0.0000
GRADF_04^2	0.00E+00	0.0000000	0.00000	0.0000

Рисунок 3.16 – Результати тесту Уайта на гетероскедатичність залишків моделі

Null Hypothesis: D(Y,2) has a unit root

Exogenous: None

Lag Length: 16 (Automatic - based on AIC, maxlag=16)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-10.05182	0.0000
Test critical values:		
1% level	-2.571643	
5% level	-1.941740	
10% level	-1.616087	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(Y,3)

Method: Least Squares

Date: 05/26/21 Time: 23:30

Sample (adjusted): 20 366

Included observations: 347 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D(Y(-1),2)	-21.46783	2.135715	-10.05182	0.0000
D(Y(-1),3)	18.92107	2.111808	8.959653	0.0000
D(Y(-2),3)	17.15005	2.056997	8.337422	0.0000
D(Y(-3),3)	15.42138	1.974985	7.808350	0.0000
D(Y(-4),3)	13.73784	1.871882	7.339049	0.0000
D(Y(-5),3)	12.14347	1.748804	6.943874	0.0000
D(Y(-6),3)	10.57879	1.607293	6.581744	0.0000

Рисунок 3.17 - Результати розширеного тесту Дікі-Фулера для других різниць

Date: 05/26/21 Time: 23:36

Sample: 1 366

Included observations: 364

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	-0.648	-0.648	154.18 0.000
		2	0.114	-0.528	158.97 0.000
		3	0.096	-0.319	162.35 0.000
		4	-0.118	-0.312	167.48 0.000
		5	0.114	-0.157	172.29 0.000
		6	-0.106	-0.188	176.51 0.000
		7	0.070	-0.151	178.34 0.000
		8	0.008	-0.045	178.37 0.000
		9	-0.062	-0.028	179.82 0.000
		10	0.011	-0.147	179.87 0.000
		11	0.070	-0.076	181.72 0.000
		12	-0.057	-0.007	182.96 0.000
		13	0.016	0.065	183.06 0.000
		14	-0.040	-0.027	183.66 0.000
		15	0.024	-0.145	183.89 0.000
		16	0.045	-0.114	184.66 0.000
		17	-0.077	-0.129	186.95 0.000
		18	0.090	-0.009	190.09 0.000
		19	-0.036	0.142	190.59 0.000
		20	-0.136	-0.156	197.70 0.000
		21	0.267	0.020	225.38 0.000
		22	-0.216	0.037	243.61 0.000
		23	0.076	0.020	245.86 0.000
		24	0.019	0.004	246.00 0.000
		25	-0.051	0.028	247.03 0.000

Рисунок 3.19 - Графік автокореляційної та часткової автокореляційної функції других різниць часового ряду

Основна специфікація ARIMA моделі (2,2,1):

$$D(Y, 2) AR(Y(-1)) AR(Y(-2)) MA(-1); \quad (3.3)$$

Якщо звернути увагу на значення  $R^2$ , очевидно, що його значення більше для моделі ARIMA (2,2,1). Така модель краще описує фактичні дані, але MA-складова не значуща, тому побудуємо модель, виключаючи MA-складову, ARIMA (2,2,0).

Dependent Variable: D(Y,2)  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/26/21 Time: 23:39  
 Sample: 3 366  
 Included observations: 364  
 Failure to improve objective (non-zero gradients) after 24 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
AR(1)	-0.577150	0.040391	-14.28904	0.0000
AR(2)	-0.275710	0.042737	-6.451310	0.0000
MA(1)	-0.999999	42.78601	-0.023372	0.9814
SIGMASQ	186.1789	208.5105	0.892900	0.3725
R-squared	0.746784	Mean dependent var	-0.076923	
Adjusted R-squared	0.744674	S.D. dependent var	27.15296	
S.E. of regression	13.72033	Akaike info criterion	8.107214	
Sum squared resid	67769.13	Schwarz criterion	8.150040	
Log likelihood	-1471.513	Hannan-Quinn criter.	8.124235	
Durbin-Watson stat	2.038820			
Inverted AR Roots	- .29+.44i	- .29-.44i		
Inverted MA Roots	1.00			

Рисунок 3.20 – Результати оцінювання ARIMA моделі (2,2,1)

Dependent Variable: Y  
 Method: ARMA Maximum Likelihood (OPG - BHHH)  
 Date: 05/28/21 Time: 04:44  
 Sample: 1 366  
 Included observations: 366  
 Convergence achieved after 23 iterations  
 Coefficient covariance computed using outer product of gradients

Variable	Coefficient	Std. Error	t-Statistic	Prob.
D	-0.453785	0.034366	-13.20449	0.0000
AR(1)	0.795524	0.000175	4558.843	0.0000
AR(2)	0.204451	0.001133	180.4002	0.0000
SIGMASQ	175.8300	7.153254	24.58042	0.0000
R-squared	0.552555	Mean dependent var	25.41530	
Adjusted R-squared	0.548846	S.D. dependent var	19.85046	
S.E. of regression	13.33315	Akaike info criterion	8.036655	
Sum squared resid	64353.78	Schwarz criterion	8.079307	
Log likelihood	-1466.708	Hannan-Quinn criter.	8.053604	
Durbin-Watson stat	2.004225			
Inverted AR Roots	1.00	- .20		

Рисунок 3.21 – Результати оцінювання ARIMA моделі (2,2,0)

Основна специфікація ARIMA моделі (2,2,1):

$$D(Y, 2) AR(Y(-1)) AR(Y(-2)); \quad (3.4)$$

Перевірка залишків на білий шум на основі тесту Дікі-Фулера (рис. 3.22) показує відсутність одиничного кореня, тобто залишки стаціонарні. Таким чином, залишки оціненої моделі можна вважати білим шумом, а модель адекватною.

Date: 05/28/21 Time: 04:57

Sample: 1 366

Included observations: 347

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1	-0.026	-0.026	0.2298
		2	-0.054	-0.055	1.2648
		3	0.094	0.091	4.3623
		4	-0.034	-0.033	4.7757
		5	0.040	0.049	5.3397
		6	-0.060	-0.072	6.6244
		7	0.027	0.037	6.8761
		8	-0.028	-0.045	7.1493
		9	-0.112	-0.096	11.665
		10	-0.007	-0.028	11.682
		11	0.027	0.030	11.954
		12	-0.122	-0.117	17.367
		13	-0.129	-0.132	23.365
		14	-0.113	-0.145	28.046
		15	0.046	0.038	28.811
		16	0.073	0.079	30.772
		17	0.024	0.058	30.978
		18	0.057	0.036	32.174
		19	-0.070	-0.081	34.009
		20	-0.018	-0.041	34.131
		21	0.255	0.236	58.225
		22	-0.052	-0.059	59.235
		23	0.018	0.020	59.354
					0.000

Рисунок 3.22 – Корелограма залишків моделі

Null Hypothesis: RESID02 has a unit root  
 Exogenous: None  
 Lag Length: 16 (Automatic - based on AIC, maxlag=16)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-4.213897	0.0000
Test critical values:		
1% level	-2.571998	
5% level	-1.941787	
10% level	-1.616056	

\*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation  
 Dependent Variable: D(RESID02)  
 Method: Least Squares  
 Date: 05/28/21 Time: 04:57  
 Sample (adjusted): 18 347  
 Included observations: 330 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
RESID02(-1)	-1.004127	0.238289	-4.213897	0.0000
D(RESID02(-1))	-0.019700	0.230141	-0.085600	0.9318
D(RESID02(-2))	-0.056289	0.219779	-0.256118	0.7980
D(RESID02(-3))	0.083719	0.207650	0.403174	0.6871
D(RESID02(-4))	0.057860	0.197324	0.293223	0.7695

Рисунок 3.23 – Результати перевірки залишків моделі на білий шум

Після перевірки залишків на стаціональність, побудували гістограму та показники нормальності розподілу залишків. Показники свідчать, що аналогічно до моделі (2,1,1), про нормальність розподілу відкидається, відслідковується правостороння асиметрія, розподіл гостроверхий.

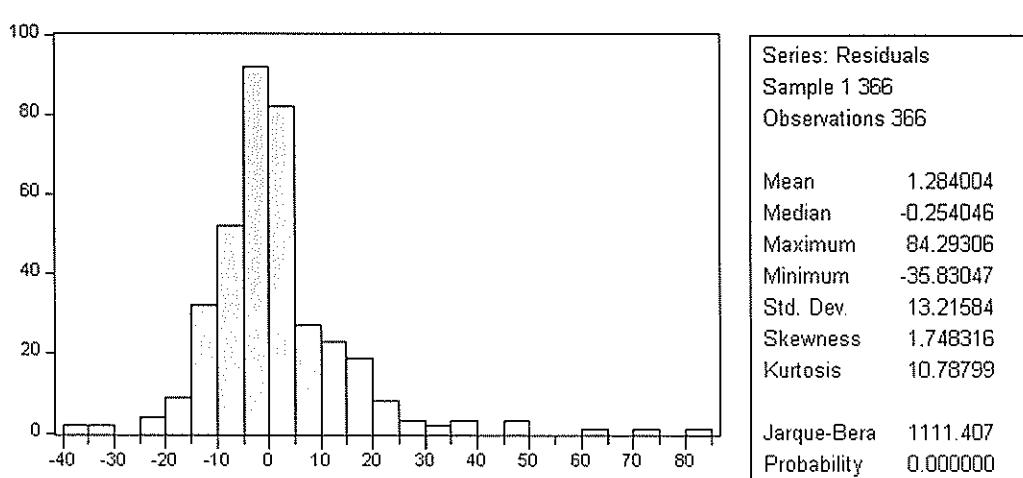


Рисунок 3.23– Результати тестування на нормальній розподіл залишків

В випадку моделі (2,2,0) гіпотеза про гомоскедастичність залишків приймається, адже показник Obs·R<sup>2</sup> менше прийнятого рівня значущості. Такі дані отримали за допомогою тесту Уайта в пакеті EViews (рис. 3.24).

#### Heteroskedasticity Test: White

F-statistic	3357.372	Prob. F(10,355)	0.0000
Obs*R-squared	362.1705	Prob. Chi-Square(10)	0.0000
Scaled explained SS	1826.424	Prob. Chi-Square(10)	0.0000

#### Test Equation:

Dependent Variable: RESID^2

Method: Least Squares

Date: 05/28/21 Time: 05:26

Sample: 1 366

Included observations: 366

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	20.69130	3.428748	6.034652	0.0000
GRADF_01^2	-0.340602	0.420796	-0.809421	0.4188
GRADF_01*GRADF_02	1.009815	0.209933	4.810174	0.0000
GRADF_01*GRADF_03	2.001881	0.423154	4.730861	0.0000
GRADF_01*GRADF_04	-422.6285	141.6083	-2.984490	0.0030
GRADF_02^2	-0.001300	0.000585	-2.221174	0.0270
GRADF_02*GRADF_03	-0.004990	0.007380	-0.676181	0.4994
GRADF_02*GRADF_04	691.0429	40.27479	17.15820	0.0000
GRADF_03^2	0.011156	0.012434	0.897215	0.3702
GRADF_03*GRADF_04	1357.436	81.36404	16.68349	0.0000
GRADF_04^2	-47698.33	23660.49	-2.015948	0.0446
R-squared	0.989537	Mean dependent var	175.8300	

Рисунок 3.24 – Результати тесту Уайта на гетероскедатичність залишків моделі

### 3.3 Прогнозування кількості кібератак на основі ARIMA моделей

В цьому розділі побудуємо прогнози на основі двох моделей різного порядку різниць, які були побудовані та проаналізовані в попередньому розділі. Для начальної виборки обираємо 95% від початкових даних.

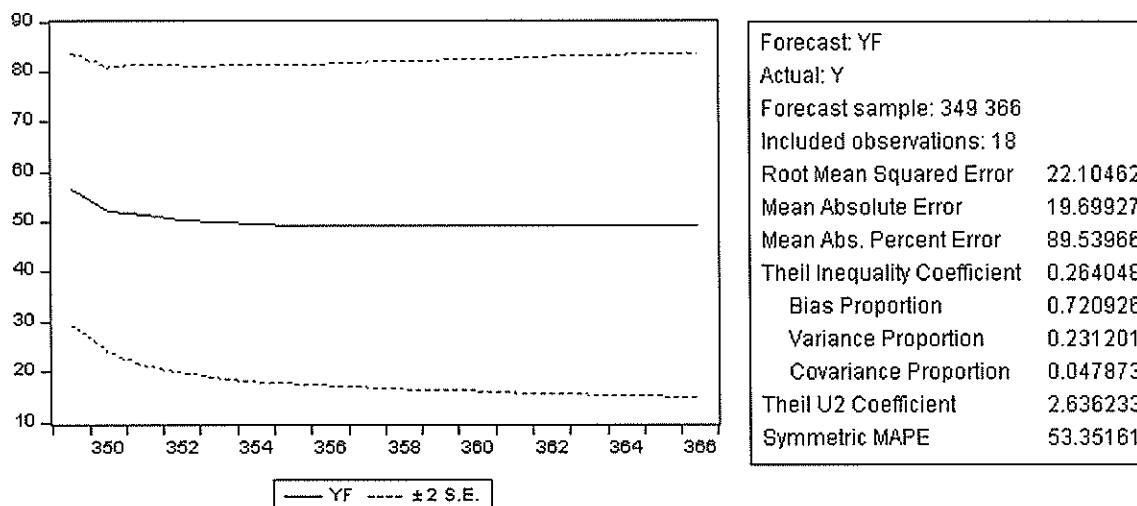


Рисунок 3.25 – Графічне зображення прогнозу моделі (2,1,1)

346	50.00000
347	80.00000
348	58.03503
349	57.48124
350	53.32073
351	52.07775
352	50.97732
353	50.44845
354	50.10247
355	49.91099
356	49.79530
357	49.72860
358	49.68918
359	49.66619
360	49.65268
361	49.64478
362	49.64015
363	49.63743
364	49.63584
365	49.63491
366	49.63436

Рисунок 3.26 - Прогнозні значення моделі (2,1,1)

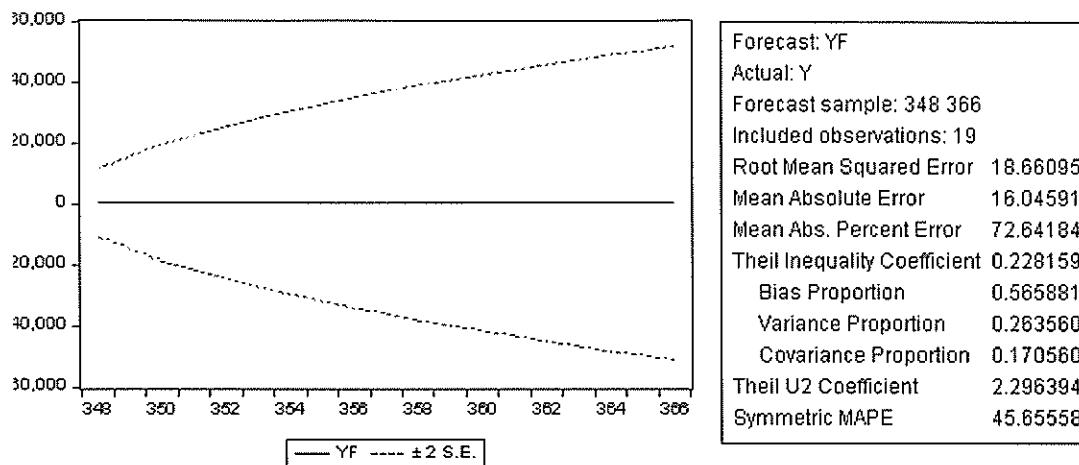


Рисунок 3.28 – Графічне зображення прогнозу моделі (2,2,0)

	Actual
346	50.00000
347	80.00000
348	54.50287
349	54.17475
350	51.26023
351	49.90900
352	48.76009
353	47.87956
354	47.14460
355	46.51880
356	45.97181
357	45.48528
358	45.04621
359	44.64541
360	44.27609
361	43.93312
362	43.61256
363	43.31130
364	43.02685
365	42.75719
366	42.50066

Рисунок 3.26 - Прогнозні значення моделі (2,1,1)

Результати прогноза двох моделей дужі схожі, перевіряємо їх з фактичними даними, тобто з 5% виборки

Можна зробити висновки, що отримана нами ARIMA модель не

досить точно прогнозує значення в межах одного періоду. Вона не є придатною для довгострокового прогнозування, оскільки не враховує значних коливань кількості кібератак, які можуть відбуватися без впливу очевидних чинників, проте її можна успішно застосовувати для короткострокових прогнозів

## ВИСНОВКИ

Дане дослідження базувалось на побудові ARIMA моделі для прогнозування кількості кібератак для суб'єктів господарювання. Під час виконання дипломної роботи були виконані такі основні завдання:

- розглянуті основні види кібератак та засоби захисту від них;
- проаналізовані методологія побудови ARIMA моделей часових рядів;
- визначені основні вимоги до моделі;
- проведений аналіз часового ряду;
- побудовані та проаналізовані ARIMA моделі різних порядків різниць та обрана найоптимальніша;

Для побудови моделі використовувалась статистична програма EViews, адже містить весь необхідний інструментарій.

Для створення прогнозної моделі було обрано ARIMA моделі порядку (2,1,1) та (2, 2, 0). Для підвищення точності та якості прогнозу було додатково обрано методи згладження для обробки початкових даних.

Другий розділ дипломної роботи містить детальний аналіз процесу побудови моделей. Зокрема, в даному розділі проведений математичний опис моделей, використаних при моделюванні прогнозів. Другий розділ було завершено описом підготовкою часового ряду для побудови моделей.

В третьому розділі роботи була описана реалізація моделей прогнозування кількості кібератак на економічних агентів. Після побудови моделей була проаналізована їх якість на даних, що не брали участь у прогнозуванні. Візуальний огляд показав, що прогнозні значення досить не досить точно та якісно описують тенденцію зміни кількості кібератак. Отже, необхідно у подальших роботах розглядати додаткові методи прогнозування часових рядів.

24.05.2021

## СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Віруси і шкідливі програми / TREND MICRO 2017. URL: <http://docs.trendmicro.com/ru-ru/smb/worry-free-business-security-90-sp1-agent-help/about/understanding-threat/viruses-and-malware.aspx>
2. Козьменко О. В. Економко-математичні методи та моделі (економетрика): навчальний посібник / О. В. Козьменко, О. В. Кузьменко. – Суми : Університетська книга, 2014. – 406 с.
3. Присенко Г. В. Прогнозування соціально-економічних процесів: навчальний посібник / Г. В. Приценко, Є. І Равікович — К.:КНЕУ, 2005. — 378 с.
4. Экономико-математические методы и прикладные модели: Учеб. пособие для вузов / Под ред. В. В. Федосеева. — М.: ЮНИТИ, 2000.
5. Кобелев Н. Б. Практика применения экономико-математических методов и моделей: Учебно-практическое пособие. — М.: ЗАО Финстатинформ, 2000.
6. Чумаченко Д. І. Математичні моделі та методи прогнозування епідемічних процесів: монографія / Д. І. Чумаченко, Т. О. Чумаченко. – Харків: ТОВ "Планета-Прінт", 2020. – 180 с
7. Крюков Ю. А. ARIMA – модель прогнозирования значений трафика / Ю. А. Крюков, Д. В. Чернягин. // ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ И ВЫЧИСЛИТЕЛЬНЫЕ СИСТЕМЫ. – 2011. – №2. – С. 41–49.
8. Про рішення Ради національної безпеки і оборони України від 27 січня 2016 р. "Про Стратегію кібербезпеки України": Указ Президента України. Урядовий кур'єр, № 52, 2016.
9. Функції захисту персональних даних покладено на уповноваженого. [Електронний ресурс]. Режим доступу: <http://www.ombudsman.gov.ua/ua/page/zpd/>.
- 10 . Шинкаренко А. Ю. Кібербезпека як один з механізмів забезпечення

стабільного розвитку економіки в Україні [Електронний ресурс] / А. Ю. Шинкаренко, О. В. Ставицький. – 2019. – Режим доступу до ресурсу: 102862-Текст статті-217650-1-10-20170530.pdf

11. Дубов Д. В. Стратегічні аспекти кібербезпеки України / Дмитро Володимирович Дубов. // Стратегічні пріоритети. – 2013. – №4. – С. 125–126.

12. 2021 Cyber Security Statistics The Ultimate List Of Stats, Data & Trends [Електронний ресурс] // purplesec.us. – 2021. – Режим доступу до ресурсу: <https://purplesec.us/resources/cyber-security-statistics/>

13. A Report on the Current State of Cybersecurity [Електронний ресурс] // theceoviews.com. – 2020. – Режим доступу до ресурсу: <https://theceoviews.com/a-report-on-the-current-state-of-cybersecurity/>.

14. Krakovsky Y. M Applied aspects of application of interval forecasting of dynamic indicators in system analysis / Y. M. Krakovsky , A. N. Luzgin –Modern technology. System analysis. Modeling, 2017, no. 2/

16. Husak M. Survey of Attack Projection, Prediction, and Forecasting in Cyber Security URL:  
[https://www.researchgate.net/publication/327449459\\_Survey\\_of\\_Attack\\_Projection\\_Prediction\\_and\\_Forecasting\\_in\\_Cyber\\_Security](https://www.researchgate.net/publication/327449459_Survey_of_Attack_Projection_Prediction_and_Forecasting_in_Cyber_Security)

17. Методы прогнозирования. [URL:  
<http://statsoft.ru/solutions/tasks/forecast/>

18 Прогнозування та аналіз часових рядів. Методичні вказівки до практичних занять та самостійної роботи студентів спеціальності 051«Економіка» освітня програма «Економічна кібернетика», «Економічнааналітика» / Укл.: Юрченко М. Є. – Чернігів: ЧНТУ, 2018. – 88 с.

19. Лук'яненко І. Г. Економетрика. Теорія та практика / І. Г. Лук'яненко,Л. І. Краснікова. — К. : Знання, 1998 — 493 с.

20. Dickey–Fuller test. [Електронний ресурс]. – Режим доступу до ресурсу: [https://en.wikipedia.org/wiki/Dickey%20Fuller\\_test](https://en.wikipedia.org/wiki/Dickey%20Fuller_test)

21. ADF — Augmented Dickey Fuller Test. [Електронний ресурс]. – Режим доступу до ресурсу:

<https://www.statisticshowto.datasciencecentral.com/adfaugmented-dickey-fuller-test/>

22. Unit Root & Augmented Dickey-Fuller (ADF) Test. [Електронний ресурс]. – Режим доступу до ресурсу: [http://www.ams.sunysb.edu/~zhu/ams586/UnitRoot\\_ADF.pdf](http://www.ams.sunysb.edu/~zhu/ams586/UnitRoot_ADF.pdf)
23. Bollerslev T. Generalized Autoregressive Conditional Heteroscedasticity / T. Bollerslev // Journal of Econometrics. – 1986. – Vol. 31. – P. 307–327.
24. Caner M. Threshold Autoregression with a Unit Root / M. Caner, B. Hansen // Econometrica. – 2001. – Vol. 69. – P. 1555–1596.
25. Charemza W. W. New Direction in Econometric Practice / W. W. Charemza, D. F. Deadman. – Brookfield : Edward Eglar, 1992. – 343 p.
26. Davidson R. Problems with the Estimation of Moving Average Processes /R. Davidson // Journal of Econometrics. – 1981. – № 16. – P. 295–310.
27. Davidson R. Several Tests for Model specification in the Presence of Alternative Hypothesis / R. Davidson, J. MacKinnon // Econometrica. – 1981. – Vol. 49. – P. 781–793.
28. Choudhry, T., Hassan, S.S. and Shabi, S. (2015) Relationship between Gold and Stock Markets during the Global Financial Crisis: Evidence from Nonlinear Causality Tests. International Review of Financial Analysis, 41, 247-256.
29. Adhikari R. An Introductory Study on Time Series Modeling and Forecasting [Текст] / Adhikari R. – Riga: LAP Lambert Academic Publishing, 2013. – 76 p.

## ДОДАТКИ

## ДОДАТОК А

### SUMMARY

Diatlenko A.O. Modeling and forecasting possibility the number of cyberattacks for business entities. – Masters-level Qualification Thesis. Sumy State University, Sumy, 2021.

Cyber attacks (types and their essence), methods and models of forecasting the number of cyberattacks were studied. The main purpose of the study is to build a model for predicting the potential volume of cyberattacks on businesses.

Keywords: cyberattack, forecasting, modeling, time series.

### АНОТАЦІЯ

Дятленко А.О. Моделювання та прогнозування можливості кібератак на суб'єкти господарювання. – Кваліфікаційна магістерська робота. Сумський державний університет, Суми, 2021р.

В даній роботі було досліджені кібератаки (види та їх сутність), методи і моделі прогнозування кількості кібератак. Основною метою дослідження є побудова моделі прогнозування кількості кібератак на суб'єкти господарювання.

Ключові слова: кібератака, моделювання, прогнозування, часові ряди.

## ДОДАТОК Б

Таблиця Б-1 – Початкові

Тиждень	Кількість атак														
1	8	51	11	101	12	151	17	201	18	251	42	301	37	351	35
1	1	52	3	102	21	152	19	202	13	252	40	302	38	352	24
2	2	53	6	103	9	153	27	203	12	253	42	303	42	353	25
4	2	54	4	104	12	154	28	204	26	254	28	304	43	354	22
5	0	55	3	105	29	155	28	205	23	255	21	305	54	355	17
6	3	56	4	106	37	156	22	206	33	256	37	306	55	356	21
7	5	57	3	107	26	157	24	207	36	257	36	307	60	357	21
8	3	58	2	108	11	158	25	208	35	258	23	308	71	358	25
9	5	59	2	109	16	159	16	209	31	259	13	309	126	359	36
10	3	60	1	110	6	160	13	210	26	260	14	310	46	360	40
11	7	61	6	111	13	161	10	211	32	261	21	311	80	361	55
12	2	62	0	112	14	162	18	212	32	262	16	312	68	362	34
13	8	63	5	113	19	163	25	213	17	263	13	313	62	363	46
14	4	64	7	114	26	164	36	214	28	264	11	314	81	364	27
15	4	65	6	115	34	165	14	215	87	265	33	315	53	365	36
16	4	66	6	116	41	166	13	216	58	266	21	316	68	366	11
1	1	67	5	117	33	167	8	217	50	267	28	317	29		
18	8	68	2	118	24	168	17	218	64	268	20	318	41		
19	7	69	7	119	17	169	10	219	28	269	23	319	32		
20	7	70	4	120	23	170	7	220	52	270	35	320	29		
21	7	71	2	121	68	171	9	221	31	271	16	321	23		
22	5	72	5	122	18	172	19	222	16	272	43	322	35		
23	5	73	7	123	66	173	34	223	15	273	50	323	29		
24	4	74	3	124	37	174	16	224	7	274	24	324	55		
25	8	75	0	125	26	175	15	225	53	275	23	325	44		
26	5	76	3	126	33	176	41	226	15	276	16	326	72		
1	1	77	6	127	36	177	16	227	22	277	45	327	45		
2	2	78	4	128	50	178	10	228	34	278	27	328	14		
3	3	79	1	129	19	179	21	229	20	279	22	329	81		
30	6	80	8	130	33	180	15	230	38	280	18	330	87		
31	8	81	2	131	41	181	22	231	29	281	31	331	61		
32	8	82	3	132	26	182	23	232	32	282	19	332	75		

## Продовження табл. Б1

33	5	83	3	133	27	183	23	233	44	283	14	333	66
34	8	84	12	134	24	184	13	234	51	284	16	334	42
35	4	85	9	135	16	185	22	235	30	285	32	335	33
36	5	86	12	136	14	186	19	236	81	286	19	336	46
37	3	87	20	137	35	187	32	237	64	287	26	337	76
38	7	88	12	138	10	188	36	238	43	288	108	338	47
39	4	89	15	139	16	189	41	239	53	289	34	339	17
40	1	90	6	140	18	190	29	240	65	290	38	340	48
41	3	91	1	141	8	191	31	241	51	291	33	341	30
42	9	92	7	142	15	192	28	242	78	292	29	342	33
43	3	93	7	143	20	193	21	243	51	293	32	343	35
44	6	94	7	144	16	194	25	244	46	294	20	344	22
45	6	95	9	145	23	195	21	245	44	295	23	345	40
46	0	96	3	146	14	196	10	246	42	296	30	346	50
47	9	97	14	147	32	197	20	247	32	297	16	347	80
48	2	98	20	148	22	198	10	248	38	298	21	348	55
49	8	99	14	149	19	199	22	249	26	299	42	349	59
50	3	100	11	150	20	200	44	250	34	300	35	350	29