

НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
“КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО”

Факультет інформатики та обчислювальної техніки

Кафедра обчислювальної техніки

До захисту допущено:

Завідувач кафедри

Михайло НОВОТАРСЬКИЙ

(підпис)

—_||_2025 р.

Дипломний проєкт

на здобуття ступеня бакалавра

за освітньо-професійною програмою “Комп’ютерні системи та мережі”

спеціальності 123 “Комп’ютерна інженерія”

на тему: Системи виявлення несправностей у промислових комплексах на основі
глибоких автоенкодерів

Виконав: студент 4 курсу, групи ІО-13

(шифр групи)

Ступак Андрій Іванович

(прізвище, ім’я, по батькові)

(підпис)

Керівник ас. Меленчуков М. Є.

(посада, науковий ступінь, вчене звання, прізвище та ініціали)

(підпис)

Консультант(нормоконтроль) асистент кафедри Гончаренко О. О.

(назва розділу)

(посада, вчене звання, науковий ступінь, прізвище та ініціали)

(підпис)

Рецензент

(посада, науковий ступінь, вчене звання, прізвище та ініціали)

(підпис)

Засвідчую, що у цьому дипломному
проєкті немає запозичень з праць інших
авторів без відповідних посилань.

Студент

(підпис)

Київ – 2025 р.

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ
“КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ
імені ІГОРЯ СІКОРСЬКОГО”**

Факультет інформатики та обчислювальної техніки

Кафедра обчислювальної техніки

Рівень вищої освіти – перший (бакалавр)

Освітньо-професійна програма

“Комп’ютерні системи та мережі”

спеціальності 123 “Комп’ютерна інженерія”

ЗАТВЕРДЖУЮ

Завідувач кафедри

Михайло НОВОТАРСЬКИЙ

(підпис)

—_||_____2025 р.

ЗАВДАННЯ

на бакалаврський дипломний проєкт студента

Ступака Андрія Іановича

1. Тема проєкту Система розпізнавання номерних знаків автомобіля на основі методів комп’ютерного зору

керівник проєкту ас. Меленчуков М. Є.
(прізвище, ім’я, по батькові, науковий ступінь, вчене звання)

затверджені наказом по університету від _____

2. Термін здачі студентом закінченого проєкту 05.06.2025

3. Вихідні дані до проєкту див. технічне завдання

4. Зміст розрахунково-пояснювальної записки (перелік питань, які розробляються)

Розділ 1. Аналіз методів виявлення несправностей у промислових системах

Розділ 2. Розробка методики на основі глибоких автоенкодерів

Розділ 3. Реалізація програмної системи для виявлення несправностей

Розділ 4. Експериментальна оцінка ефективності системи

5. Перелік графічного матеріалу (з точним позначенням обов'язкових креслень) алгоритм дії розробленої системи, діаграма класів, структурна модель системи.

6. Консультанта проєкту, з вказівкою розділів проєкту, які до них вносяться

Розділ	Консультант	Підпис, дата	
		Завдання видав	Завдання прийняв
Нормоконтроль	Гончаренко О. О.		

7. Дата видачі завдання «6» жовтня 2024 р.

Календарний план

№ п/п	Найменування етапів дипломного проєкту	Терміни виконання етапів проєкту	Примітки
1.	<i>Затвердження теми роботи</i>	<i>28.01.2025-31.01.2025</i>	
2.	<i>Вивчення та аналіз завдання</i>	<i>01.02.2024-15.02.2025</i>	
3.	<i>Розробка архітектури та загальної структури системи</i>	<i>16.02.2025-18.03.2025</i>	
4.	<i>Розробка структур окремих частин системи</i>	<i>19.03.2025-02.04.2025</i>	
5.	<i>Програмна реалізація системи</i>	<i>03.04.2025-09.05.2025</i>	
6.	<i>Оформлення пояснювальної записки</i>	<i>20.05.2025-02.06.2025</i>	
7.	<i>Захист програмного продукту</i>	<i>02.06.2025</i>	
8.	<i>Передзахист</i>	<i>05.06.2025</i>	
9.	<i>Захист</i>	<i>16.06.2025</i>	

Студент-дипломник _____ СТУПАК Андрій
(підпис)

Керівник проєкту _____ Меленчуков Микита
(підпис)

АНОТАЦІЯ

У кваліфікаційній роботі розглянуто розробку системи виявлення несправностей у промислових комплексах на основі глибоких автоенкодерів, що дозволяє здійснювати діагностику технічного стану обладнання шляхом аналізу сенсорних даних у реальному часі. Проведено дослідження сучасних підходів до детекції аномалій, обґрунтовано вибір нейромережевої архітектури, реалізовано програмну модель системи та виконано експериментальне тестування її ефективності. Отримані результати демонструють високу точність виявлення технічних відхилень, що підтверджує доцільність використання такого підходу в умовах промислової експлуатації.

Ключові слова: виявлення несправностей, автоенкодер, аномалії, глибоке навчання, промислові системи.

ABSTRACT

The qualification thesis addresses the development of a fault detection system for industrial complexes based on deep autoencoders, enabling real-time diagnostics of equipment conditions through sensor data analysis. The study explores modern approaches to anomaly detection, justifies the choice of neural network architecture, implements the software model of the system, and conducts experimental evaluation of its effectiveness. The obtained results demonstrate high accuracy in detecting technical deviations, confirming the feasibility of applying this approach in industrial operation environments.

Keywords: fault detection, autoencoder, anomalies, deep learning, industrial systems.

[illegible]

**ТЕХНІЧНЕ ЗАВДАННЯ
НА ДИПЛОМНИЙ ПРОЄКТ
на тему: «Системи виявлення
несправностей у промислових
комплексах на основі глибоких
автоенкодерів»**

ЗМІСТ

ЗМІСТ	1
1. НАЙМЕНУВАННЯ ТА ОБЛАСТЬ ЗАСТОСУВАННЯ	2
2. ПІДСТАВИ ДЛЯ РОЗРОБКИ.....	2
3. МЕТА ТА ПРИЗНАЧЕННЯ РОЗРОБКИ.....	2
4. ДЖЕРЕЛА РОЗРОБКИ	2
5. ТЕХНІЧНІ ВИМОГИ	2
5.1 Вимоги до розробленого продукту	2
5.2 Вимоги до програмного забезпечення.....	3
5.3 Вимоги до апаратної частини	3
6. ЕТАПИ РОЗРОБКИ.....	3

					ІАЛЦ.467200.003 ТЗ		
Зм.	Арк.	№ докум.	Підпис	Дата			
Розробив		Ступак А. І.			Системи виявлення несправностей у промислових комплексах на основі глибоких автоенкодерів Технічне завдання	Літ.	Аркуш
Перевірив		Меленчуков М. Є.					
						1	3
Н. Контр.		Гончаренко О.О.				КПІ ім. Ігоря Сікорського, ФІОТ, ІО-13	
Затвердив							

1. НАЙМЕНУВАННЯ ТА ОБЛАСТЬ ЗАСТОСУВАННЯ

Дане технічне завдання поширюється на розробку системи виявлення несправностей у промислових комплексах на основі глибоких автоенкодерів. Областю застосування цієї системи є автоматичний моніторинг та діагностика технічного стану обладнання в промислових комплексах, зокрема в енергетиці, металургії, хімічній, нафтогазовій та інших галузях, де необхідне виявлення аномалій у режимі реального часу.

2. ПІДСТАВИ ДЛЯ РОЗРОБКИ

Підставою для розробки системи є завдання на виконання бакалаврського проєкту, по освітньо-професійної програми «Комп'ютерні системи та мережі» спеціальності 123 «Комп'ютерна інженерія», затверджене кафедрою Обчислювальної техніки НТУ України «Київський Політехнічний інститут імені Ігоря Сікорського».

3. МЕТА ТА ПРИЗНАЧЕННЯ РОЗРОБКИ

Метою даного проєкту є розробка системи виявлення несправностей у промислових комплексах на основі глибоких автоенкодерів.

4. ДЖЕРЕЛА РОЗРОБКИ

Джерелом розробки є наукові статті на дану тему, публікації в мережі Інтернет, датасети та відеоматеріали вільного доступу, науково-технічна література.

5. ТЕХНІЧНІ ВИМОГИ

5.1 Вимоги до розробленого продукту

- Можливість виявлення несправностей в промислових комплексах в режимі реального часу за допомогою відео та ідентифікація їхніх номерних знаків з високою точністю.

					ІАЛЦ.467200.003 ТЗ	Арк.
						2
Зм.	Арк.	№ докум.	Підпис	Дата		

- Забезпечення виявлення аномалій в промислових комплексах

5.2 Вимоги до програмного забезпечення

- Python версії 3.9
- Наявність Ultralytics версії 8.2.0 або вище
- Бібліотеки OpenCV(4.9.0) EasyOCR(1.7.0) Pandas (2.2.1)

5.3 Вимоги до апаратної частини

- ЦП не менш ніж Intel Core i5
- Рекомендується використання відеокарти з підтримкою CUDA
- Оперативна пам'ять: мінімум 4 ГБ

6. ЕТАПИ РОЗРОБКИ

Назва етапів виконання	Термін виконання
Затвердження теми роботи	28.01.2025-31.01.2025
Вивчення та аналіз завдання	01.02.2024-15.02.2025
Розробка архітектури та загальної структури системи	16.02.2025-18.03.2025
Розробка структур окремих частин системи	19.03.2025-02.04.2025
Програмна реалізація системи	03.04.2025-09.05.2025
Виправлення помилок	10.05.2025-19.06.2025
Оформлення пояснювальної записки	20.05.2025-02.06.2025

**ПОЯСНЮВАЛЬНА
ЗАПИСКА НА
ДИПЛОМНИЙ ПРОЄКТ
на тему: «Системи виявлення
несправностей у промислових
комплексах на основі глибоких
автоенкодерів»**

ЗМІСТ

ВСТУП.....	3
РОЗДІЛ 1 АНАЛІЗ МЕТОДІВ ВИЯВЛЕННЯ НЕСПРАВНОСТЕЙ У ПРОМИСЛОВИХ СИСТЕМАХ	5
1.1 Промислові комплекси та їх системи моніторингу	5
1.2 Методи виявлення несправностей.....	15
1.3 Автоенкодера як метод аномального аналізу	17
ВИСНОВКИ ДО РОЗДІЛУ	27
РОЗДІЛ 2 РОЗРОБКА МЕТОДИКИ НА ОСНОВІ ГЛИБОКИХ АВТОЕНКОДЕРІВ.....	28
2.1 Формалізація задачі виявлення аномалій	28
2.2 Вибір архітектури автоенкодера.....	35
2.3 Оптимізація параметрів моделі	40
2.4 Джерела даних та методи їх обробки.....	49
2.5 Критерії оцінювання ефективності алгоритму	55
ВИСНОВКИ ДО РОЗДІЛУ	61
РОЗДІЛ 3 РЕАЛІЗАЦІЯ ПРОГРАМНОЇ СИСТЕМИ ДЛЯ ВИЯВЛЕННЯ НЕСПРАВНОСТЕЙ	62
3.1 Архітектура програмного рішення.....	62
3.2 Інтеграція автоенкодера у систему моніторингу	69
3.3 Технології обробки даних у реальному часі	71
3.4 Візуалізація та інтерфейс користувача	72
ВИСНОВКИ ДО РОЗДІЛУ	77
РОЗДІЛ 4 ЕКСПЕРИМЕНТАЛЬНА ОЦІНКА ЕФЕКТИВНОСТІ СИСТЕМИ ..	78
4.1 Набір тестових сценаріїв для перевірки моделі.....	78
4.2 Аналіз продуктивності та точності алгоритму	92
4.3 Порівняння з альтернативними методами.....	93
4.4 Вплив параметрів моделі на якість детекції.....	96
ВИСНОВКИ ДО РОЗДІЛУ	99

					ІАЛЦ.467200.003 ПЗ		
Зм.	Арк.	№ докум.	Підпис	Дата			
Розроб.		Ступак А. І.			Системи виявлення несправностей у промислових комплексах на основі глибоких автоенкодерів Пояснювальна записка	Літ.	Арк.
Перевір.		Меленчуков М. Є.					1
Реценз.							103
Н. Контр.		Гончаренко О. О.				КПІ ім. Ігоря Сікорського, ФІОТ, ІО-13	
Затверд.							

ВИСНОВКИ.....	100
СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ	101
ДОДАТОК А	105
ДОДАТОК Б.....	107
ДОДАТОК В.....	109
ДОДАТОК Г.....	111

ВСТУП

Сучасний стан розвитку промислових систем зумовлює постійну потребу в удосконаленні методів діагностики технічного стану складних об'єктів. У зв'язку з підвищенням рівня автоматизації технологічних процесів та збільшенням складності промислових установок, виникає нагальна необхідність у забезпеченні високої надійності та безпеки їх функціонування. Одним із критично важливих завдань у цьому контексті є своєчасне виявлення відхилень від нормального режиму роботи обладнання, що може свідчити про наявність потенційних несправностей або про загрозу їх виникнення. Традиційні методи контролю та діагностики, які базуються на експертних правилах або статистичному аналізі, часто виявляються недостатньо ефективними при роботі з великомасштабними і високовимірними даними, характерними для сучасних промислових комплексів. Саме тому в останні роки все більшої популярності набувають методи, засновані на застосуванні технологій машинного навчання, зокрема глибокого навчання.

Серед широкого спектра глибоких архітектур особливу увагу привертають автоенкодери — нейронні мережі, здатні ефективно навчатися поданню вхідних даних у стиснутому представленні, зберігаючи суттєві ознаки та структуру. Їх здатність відновлювати вихідні дані з латентного простору надає можливість формалізувати задачу виявлення аномалій як задачу оцінювання відновлювальної похибки. За нормальних умов роботи система навчена точно відтворювати вхідні дані, тоді як при появі нестандартних ситуацій або збоїв, які відрізняються від розподілу навчальних даних, зростає похибка реконструкції, що може слугувати індикатором аномального стану. Таким чином, глибокі автоенкодери постають як перспективний інструмент для безперервного моніторингу та виявлення несправностей в умовах великої кількості сенсорних показників та змінних параметрів середовища.

Актуальність тематики дослідження обумовлена потребою промислових підприємств у високоточної та масштабованій системі технічного нагляду,

					ІАПЦ.467200.003 ПЗ	Арк.
						3
Змн.	Арк.	№ докум.	Підпис	Дата		

здатній в режимі реального часу виявляти відхилення на ранніх етапах, зменшуючи ризик виходу з ладу критично важливих вузлів. Крім того, дослідження підходів до використання глибоких автоенкодерів у задачах технічної діагностики сприяє розвитку нових методологій аналізу даних, що відповідає стратегічним завданням цифровізації та інтелектуалізації промислового виробництва. У цьому контексті об'єктом дослідження виступає процес виявлення несправностей у промислових комплексах, а предметом – застосування глибоких нейронних мереж автоенкодерного типу для автоматизованого аналізу технічного стану обладнання. Метою даної роботи є обґрунтування, розробка та експериментальна перевірка моделі виявлення несправностей на основі глибоких автоенкодерів, яка забезпечує високу чутливість до аномальних відхилень при збереженні низького рівня хибноспрацювань.

Таким чином, дана робота орієнтована на дослідження одного з найбільш перспективних напрямів сучасної прикладної інформатики, що поєднує в собі глибоке навчання, інженерію даних та системний аналіз промислових процесів, і має як теоретичну, так і практичну цінність для подальшого впровадження інтелектуальних систем моніторингу на виробництві.

					ІАПЦ.467200.003 ПЗ	Арк.
						4
Змн.	Арк.	№ докум.	Підпис	Дата		

РОЗДІЛ 1 АНАЛІЗ МЕТОДІВ ВИЯВЛЕННЯ НЕСПРАВНОСТЕЙ У ПРОМИСЛОВИХ СИСТЕМАХ

1.1 Промислові комплекси та їх системи моніторингу

Промислові комплекси формуються на основі глибоких міжгалузевих зв'язків та об'єднання виробничих ланок, які забезпечують повний цикл створення товарів чи надання промислових послуг. Наявність спільних інфраструктурних об'єктів, таких як енергетичні мережі, транспортні вузли та виробничі потужності, сприяє оптимальному розподілу ресурсів і підвищує загальну ефективність господарської діяльності[1]. У таких умовах кожна складова комплексу виконує спеціалізовані завдання, що дає змогу комбінувати різні технологічні процеси та прискорювати темпи інновацій. Взаємозалежність цих виробничих одиниць підсилює конкурентні переваги регіону, роблячи його більш привабливим для інвестицій та сприяючи диверсифікації економіки. Такий формат організації промисловості дає змогу охопити широкий сектор виробництва — від первинної обробки сировини до виготовлення високотехнологічної продукції з високою доданою вартістю, а також поглиблює науково-технічний потенціал завдяки активній взаємодії з науково-дослідними інститутами.

Промислові комплекси також відіграють ключову роль у розвитку територій, де вони розташовані. Висока концентрація підприємств з різних галузей промисловості стимулює формування локальних трудових ринків із підвищеними можливостями працевлаштування, а також сприяє підготовці та перепідготовці спеціалістів, формуючи сталий фундамент для професійного зростання населення. За рахунок реалізації спільних інфраструктурних проєктів у вигляді розбудови доріг, залізничних гілок чи модернізації енергетичних потужностей підвищується якість життя та створюється ефект синергетичного впливу на суміжні сектори. Крім цього, концентрація виробництв одного профілю під одним управлінським контролем дає змогу контролювати витрати, синхронізувати виробничі процеси та краще координувати інноваційну

					ІАЛЦ.467200.003 ПЗ	Арк.
						5
Змн.	Арк.	№ докум.	Підпис	Дата		

діяльність, що в підсумку розширює перспективи для експорту і посилює економічну безпеку країни.

У рамках промислових комплексів спостерігається всебічний розвиток управлінських практик, які спрямовані на досягнення максимальної виробничої продуктивності, забезпечення екологічної безпеки та раціональне використання ресурсів. Унаслідок багаторівневої інтеграції промислових процесів стає можливою оптимізація виробничих ланцюгів, що призводить до підвищення рентабельності продукції та зниження втрат сировини. Значна увага приділяється впровадженню новітніх технологій у сфері автоматизації, цифрового моніторингу та енергоефективності, які підвищують конкурентоспроможність продукції на міжнародних ринках і водночас зменшують негативний вплив на довкілля[2]. Завдяки комплексному підходу до організації виробничих ланок і розподілу відповідальності між учасниками галузевих об'єднань досягається усталений економічний розвиток, що закладає підвалини для поглибленої науково-технічної кооперації та формує потужний промисловий потенціал у глобальному масштабі.

Галузева структура промислових комплексів охоплює сукупність виробничих напрямів, що взаємопов'язані технологічно, економічно та територіально, формуючи єдиний виробничо-економічний організм. Кожна галузь, що входить до складу промислового комплексу, виконує свою спеціалізовану функцію, проте найчастіше ці функції нерозривно пов'язані з діяльністю суміжних галузей, оскільки забезпечення безперервного виробничого циклу вимагає комплексного підходу. Наприклад, металургійна галузь може виступати джерелом сировини для машинобудівних підприємств, тоді як сама металургія залежить від гірничодобувних структур і постачальників енергоносіїв. Така взаємна інтеграція потребує ретельного планування виробничих процесів, транспортно-логістичних операцій та впровадження єдиних стандартів якості, а також передбачає тісну координацію між різними рівнями управління[3]. Важливе місце відводиться науково-дослідним установам, які генерують інноваційні рішення та нові технології, що можуть

					ІАЛЦ.467200.003 ПЗ	Арк.
						6
Змн.	Арк.	№ докум.	Підпис	Дата		

сприяти модернізації окремих галузей і забезпечувати глибшу інтеграцію усередині комплексу. Таким чином, галузева структура формується не лише за принципом спорідненості технологічних процесів, а й з урахуванням економічних і соціальних чинників, що відображається у територіальному розташуванні, доступності ресурсів та потенціалі розвитку суміжних ринків.

Міжгалузеві зв'язки є ключовим чинником конкурентоспроможності та ефективності промислових комплексів, оскільки вони дають змогу об'єднувати різні спеціалізовані виробництва в єдине ціле, забезпечуючи безперервність технологічних циклів та оптимізацію витрат. Завдяки такій взаємодії промислові підприємства мають змогу обмінюватися ресурсами, знаннями, ноу-хау та інноваціями, що часто призводить до створення додаткової вартості та підвищує конкурентні переваги. Зокрема, спільне використання енергетичних чи логістичних інфраструктур знижує експлуатаційні витрати, а узгоджене впровадження стандартів якості та безпеки покращує загальні показники надійності й екологічної відповідальності. Розвинена система міжгалузевих зв'язків також сприяє накопиченню критичної маси кваліфікованих кадрів і наукових ресурсів, що розширює можливості для науково-технічного прогресу та впровадження новітніх технологій у різних виробничих ланках. Оскільки більшість сучасних галузей зазнають глобальних ринкових впливів, перевага має саме комплексний підхід, що передбачає гармонійний розвиток усіх ланок промисловості, де сильне взаємне поєднання галузей формує основу для стійкості економічної системи та її здатності адаптуватися до зміни світової кон'юнктури[4].

Економічне значення промислових комплексів полягає насамперед у формуванні валового внутрішнього продукту, створенні робочих місць та розвитку інфраструктури регіонів. Водночас вони впливають на зростання інвестиційної привабливості, оскільки наявність розвиненої промислової бази свідчить про стабільні економічні умови та готовність до впровадження нових технологій. Завдяки сукупній діяльності підприємств у рамках єдиного комплексу створюється мультиплікативний ефект, що поширюється на суміжні

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		7

галузі та постачальників ресурсів і послуг[5]. Таке розширення виробничої структури не лише підвищує загальні обсяги виготовленої продукції, а й стимулює технологічні інновації, прискорює обіг капіталу та розширює можливості експорту, роблячи економіку країни більш гнучкою і конкурентоспроможною на міжнародній арені. Завдяки поєднанню різних ланок процесу виробництва у межах промислового комплексу економіці надається цілісність і системна збалансованість, що забезпечує швидку адаптацію до змін у глобальному попиті та дає змогу ефективніше використовувати природні й енергетичні ресурси.

Водночас промислові комплекси створюють передумови для появи висококваліфікованих робочих місць і формують потужну освітню базу шляхом взаємодії з науково-дослідними структурами[6]. Залучення значних інвестицій у розбудову таких комплексів сприяє розвитку соціальної інфраструктури регіонів, а також підвищує рівень добробуту населення за рахунок зростання рівня зайнятості та доходів. У свою чергу, це стимулює внутрішній попит і посилює орієнтацію промисловості на якісне та інноваційне виробництво, що є визначальним фактором у контексті довгострокового економічного зростання. Завдяки об'єднанню різногалузевих потужностей у межах одного комплексу з'являється можливість швидко трансформувати асортимент продукції, оперативно реагувати на коливання ринкового середовища та інтегруватися у міжнародні виробничі ланцюги, забезпечуючи стійке економічне зростання і підвищуючи статус країни в глобальній промисловій ієрархії.

Промислові комплекси в сучасних умовах стикаються з широким спектром викликів та ризиків, що пов'язано із швидким темпом технологічного прогресу, глобалізацією ринків і посиленням конкурентних умов[7]. Істотною перепорою на шляху їх ефективного розвитку виступає екологічна складова, адже надмірне споживання ресурсів, високе енергоспоживання і збільшення обсягів промислових відходів зумовлюють критичне навантаження на навколишнє середовище. Водночас наявність застарілих технологічних систем у багатьох виробничих секторах ускладнює модернізацію, оскільки потребує масштабних

					ІАЛЦ.467200.003 ПЗ	Арк.
						8
Змн.	Арк.	№ докум.	Підпис	Дата		

інвестицій у нове обладнання та кардинальних змін у виробничій інфраструктурі. До цього слід додати чинники нестабільності на глобальних ринках, коли коливання світових цін на сировину та посилення конкуренції з боку іноземних виробників створюють додатковий тиск на рентабельність і змушують шукати нові механізми підвищення продуктивності й диференціації продукції. Зміни у структурі споживчого попиту, що зазнає впливу як соціально-економічних, так і технологічних тенденцій, також мають критичне значення, оскільки формують потребу у гнучкій переорієнтації виробничих процесів і адаптації до швидкоплинних ринкових умов.

Зі стрімким впровадженням цифрових технологій зростає ризик кібератак, які здатні паралізувати не лише окремі виробничі лінії, а й цілі ланцюги постачання, що ускладнює забезпечення сталого виробництва та вимагає посиленої уваги до інформаційної безпеки[8]. Також викликом стає нестача висококваліфікованих кадрів: впровадження складних автоматизованих систем управління потребує спеціалістів із відповідним рівнем знань у галузі ІТ, робототехніки й штучного інтелекту. Недостатній рівень підготовки або нездатність до оперативної перепідготовки персоналу може призвести до зниження ефективності виробництва, а також до збільшення виробничих ризиків через помилки при використанні новітнього обладнання. Важливим залишається питання регуляторних бар'єрів і правової бази, коли недосконалість законодавства або часті зміни у податковій та екологічній політиці спричиняють додаткові невизначеності та підвищений рівень ризиків для довгострокових інвестиційних проєктів. Така ситуація поглиблюється загальними геополітичними факторами, що можуть зумовлювати переривання ланцюгів постачання, виникнення торгівельних бар'єрів чи коливання валютних курсів, негативно впливаючи на фінансову стабільність і темпи розвитку промислових комплексів.

Системи моніторингу у промисловій діяльності становлять комплекс організаційно-технічних та програмних рішень, які забезпечують спостереження за функціонуванням виробничих процесів у режимі реального часу, виявлення

					ІАЛЦ.467200.003 ПЗ	Арк.
						9
Змн.	Арк.	№ докум.	Підпис	Дата		

відхилень від встановлених параметрів і прийняття рішень щодо оперативного коригування технологічних операцій. Такі системи передбачають збір, обробку й аналіз інформації, отриманої від сенсорних, аналітичних і керуючих пристроїв, що вбудовуються у виробниче середовище з метою підвищення ефективності та безпеки діяльності. За допомогою безперервного контролю за температурою, тиском, витратами води чи енергії, якістю сировини та рівнем викидів у навколишнє середовище досягається оптимізація витрат, зменшення виробничих ризиків і гарантується дотримання технічних стандартів. У межах промислових систем моніторингу впроваджуються спеціалізовані програмні модулі, що здійснюють інтелектуальний аналіз великих масивів даних, виявляють приховані закономірності та пропонують прогностичні моделі, котрі допомагають унеможливити невинуватені простої або аварійні ситуації.

Застосування сучасних систем моніторингу характеризується інтеграцією вимірювальних сенсорів, електронних датчиків, обчислювальних платформ і хмарних сервісів, які з'єднуються в єдину інфраструктуру в рамках концепції Інтернету речей[9]. Подібна інтеграція дозволяє підвищувати точність збирання інформації про виробничі процеси та оперативно обмінюватися відомостями між різними підрозділами підприємства. Водночас удосконалені алгоритми машинного навчання аналізують багатовимірні дані щодо параметрів технологічних операцій, передбачаючи потенційні відхилення й пропонуючи підлаштування режимів функціонування обладнання, щоб запобігти виникненню дефектів у продукції або зниженню продуктивності. Своєю чергою, це сприяє оптимізації споживання ресурсів, підвищенню якості продукції та стимулює розробку екологічно безпечних рішень, що набувають виняткової актуальності в контексті глобальних вимог до збереження навколишнього середовища.

Запровадження систем моніторингу у промисловій сфері має важливе значення для забезпечення конкурентоспроможності підприємства, адже надає змогу вчасно виявляти вузькі місця в технологічному циклі та зменшувати незаплановані простої, пов'язані з поломками обладнання чи дефектами у

					ІАЛЦ.467200.003 ПЗ	Арк.
						10
Змн.	Арк.	№ докум.	Підпис	Дата		

виготовленні. Значна увага приділяється питанням безпеки, оскільки такі системи забезпечують багаторівневий контроль за параметрами, що можуть свідчити про потенційні загрози для працівників або довкілля. Крім того, розробка й використання інформаційних панелей і систем візуалізації дозволяють ефективно координувати роботу виробничих підрозділів, вчасно реагувати на будь-які збої та підтримувати високий рівень стандартів якості[10]. Таким чином, комплексний моніторинг створює інтелектуальне підґрунтя для систематичного вдосконалення всіх ланок промислового процесу, що в підсумку зумовлює підвищення загальної ефективності, стійкості та інноваційного потенціалу виробництва.

Технологічні інструменти для моніторингу в сучасних промислових комплексах охоплюють широкий спектр апаратних і програмних засобів, що спрямовані на безперервне збирання, обробку та аналіз даних про виробничі процеси. Однією з ключових складових є мережа сенсорів, яка інтегрується безпосередньо в обладнання чи розміщується в критичних точках виробничого циклу[11]. Сенсори здатні фіксувати основні технологічні параметри, включно з показниками температури, тиску та вібрації, а також реєструвати кількість шкідливих викидів і спожитих ресурсів. Висока чутливість та швидкість реакції сенсорних пристроїв дозволяють виявляти навіть незначні відхилення від нормативних значень і, як наслідок, оперативно реагувати на потенційні збої. Інформація, зібрана сенсорами, транслюється до спеціалізованих програмних комплексів, де відбувається її попереднє опрацювання, порівняння з встановленими пороговими рівнями та формування сигналів тривоги у разі критичних показників.

Розвинуте аналітичне програмне забезпечення виконує функції виявлення закономірностей і прогнозування можливих відхилень у роботі обладнання чи змінах якісних характеристик продукції. Такі системи можуть ґрунтуватися на методах машинного навчання, що дозволяє моделювати складні залежності й визначати ризики відмови обладнання задовго до виникнення реальних несправностей. Використання алгоритмів штучного інтелекту дає змогу

аналізувати великі масиви даних майже в реальному часі та формувати рекомендації щодо оптимізації технологічних режимів або коригування виробничих параметрів[12]. Це суттєво підвищує рівень автоматизації процесів і ефективність управління, адже персонал отримує детальну інформацію про можливі сценарії розвитку подій і може вчасно вжити профілактичних заходів чи перебудувати виробничий цикл відповідно до змінених умов.

Важливою складовою моніторингових систем є комп'ютеризовані платформи управління, що інтегрують усі технологічні компоненти в єдине віртуальне середовище. Такі платформи можуть контролювати роботу різних систем автоматизації, переглядати показники сенсорів у динаміці та відображати їх у зручному інтерфейсі для операторів. Застосування розподілених обчислень дає змогу отримувати відомості про перебіг виробництва не лише з одного цеху чи підприємства, а й узагальнювати дані з географічно віддалених виробничих майданчиків. У такий спосіб, при великому обсязі продукції та складній структурі виробництва, забезпечується точне та вичерпне уявлення про реальний стан усього промислового комплексу[13]. Це сприяє збереженню єдиного інформаційного простору і дає змогу керівництву приймати стратегічні рішення на основі перевірених й актуальних даних.

Суттєву роль у формуванні високої точності та швидкості моніторингу відіграють протоколи передачі даних і канали зв'язку, що обираються з огляду на вимоги до пропускну здатності, показників безпеки та надійності. У великих промислових комплексах впроваджуються бездротові мережі, що базуються на стандартах Wi-Fi, Zigbee чи LoRaWAN, а також системи провідного зв'язку для передачі критично важливих обсягів інформації. Це дозволяє забезпечити безперервний потік даних від сенсорів до хмарних сховищ або локальних серверів, де здійснюється первинна фільтрація та подальший аналіз. Разом із цим методи криптографічного захисту й механізми аутентифікації зменшують ризики несанкціонованого доступу до системи моніторингу, що має ключове значення для збереження комерційної таємниці та запобігання кібератакам.

У перспективі передбачається подальший розвиток технологічних

					ІАЛЦ.467200.003 ПЗ	Арк.
						12
Змн.	Арк.	№ докум.	Підпис	Дата		

інструментів моніторингу у напрямі інтеграції з концепцією Інтернету речей і розширення можливостей систем машинного навчання. Застосування інтелектуальної обробки даних, що зібрані в реальному часі, може забезпечити динамічне керування всіма параметрами виробничого процесу, а також підвищення продуктивності й зниження витрат на обслуговування обладнання. У результаті, сучасні та перспективні технології моніторингу надають можливість не лише контролювати поточний стан промислових систем, а й ефективно управляти їх майбутнім розвитком, що значно підсилює конкурентні позиції промислових комплексів на внутрішньому та світовому ринках.

Системи моніторингу у промислових комплексах забезпечують суттєве підвищення надійності та ефективності виробничих процесів завдяки можливості безперервного збору, аналізу та оперативної обробки різноманітних даних, що характеризують стан обладнання, якість продукції та показники використання ресурсів. Безперебійна фіксація критичних параметрів і вчасне виявлення відхилень дозволяють уникати непередбачуваних збоїв та простоїв, зменшуючи ймовірність масштабних аварій[14]. Такий підхід забезпечує стабільне функціонування всіх ланок виробничого ланцюга, підвищує показники продуктивності та сприяє формуванню сприятливого інвестиційного клімату, адже поліпшується керованість і прозорість усієї системи.

Впровадження моніторингу дає можливість ефективніше розподіляти ресурси і керувати енергоспоживанням, що особливо важливо в умовах зростання цін на енергоносії та посилення екологічних обмежень. Здійснюючи контроль за рівнем викидів і технологічними параметрами, системи моніторингу сприяють дотриманню норм безпеки та екологічних стандартів, що водночас позитивно позначається на репутації підприємств і полегшує вихід на міжнародні ринки. Завдяки здатності виявляти приховані проблеми у внутрішніх процесах, зокрема завчасні збої в обладнанні, виникає можливість планувати ремонтні роботи оптимально, знижуючи витрати на обслуговування і мінімізуючи простой. Комплексне відстеження всіх етапів виробництва у режимі реального часу дає змогу коригувати управлінські рішення на основі фактичних

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		13

показників, що підвищує гнучкість та адаптивність виробничих процесів до змін у зовнішньому середовищі[15].

Завдяки покращенню взаємодії між різними відділами та автоматизації рутинних процедур, системи моніторингу сприяють формуванню сприятливого середовища для технологічних інновацій, які спираються на системний аналіз даних та прогнозне моделювання. Усунення помилок, що виникають внаслідок людського чинника, забезпечує стабільніше й достовірніше функціонування обліково-аналітичних процесів. Важливим фактором є й посилення рівня безпеки праці, оскільки постійний контроль за критичними параметрами дозволяє вчасно виявляти потенційні загрози для здоров'я працівників і нейтралізувати їх задовго до виникнення аварійних ситуацій. Таким чином, комплексне впровадження систем моніторингу в промислових комплексах стає важливою передумовою для підвищення конкурентоспроможності, формування стійких економічних переваг та дотримання сучасних екологічних вимог.

Перспективи розвитку промислових комплексів у найближчому майбутньому пов'язуються насамперед із поглибленням цифровізації й упровадженням новітніх комп'ютерних технологій, що відкривають нові горизонти для оптимізації виробничих процесів та вдосконалення бізнес-моделей. Очікується підвищення ролі Інтернету речей, оскільки інтегровані мережі датчиків і взаємопов'язаних пристроїв дають змогу оперативно відстежувати усі ключові параметри роботи обладнання та виявляти закономірності, що сприяють підвищенню ефективності. У перспективі зростатиме значення штучного інтелекту та машинного навчання, які здатні аналізувати великі обсяги даних у реальному часі та самонавчатися, передбачаючи потенційні відхилення у виробничих процесах[16]. Таким чином, цифрові рішення дозволять забезпечити глибоке розуміння стану обладнання, оперативне виявлення несправностей і швидку адаптацію технологічного циклу до змін ринкових та технологічних умов. Це стане фундаментом для зниження матеріальних, енергетичних і кадрових витрат, а також для посилення інноваційного потенціалу, який визначатиме конкурентоспроможність

					ІАЛЦ.467200.003 ПЗ	Арк.
						14
Змн.	Арк.	№ докум.	Підпис	Дата		

промислових комплексів на глобальній арені.

Подальша еволюція моніторингових систем безпосередньо корелюватиме з упровадженням «зелених» технологій і розширенням ініціатив сталого розвитку. Значна увага приділятиметься зменшенню техногенного впливу на довкілля, а саме мінімізації викидів, ощадливому використанню ресурсів і покращенню екологічної безпеки виробництва. Використання високоточних сенсорів та інтелектуальних систем обробки інформації дасть змогу вчасно визначати критичні параметри й оптимізувати процеси, аби запобігати надмірному споживанню енергії й зниженню якості продукції[17]. Нагромадження та аналіз великого масиву даних у режимі реального часу усуватимуть ризики виникнення аварійних ситуацій і сприятимуть ухваленню стратегічних управлінських рішень щодо модернізації обладнання та оптимізації виробничих ліній. Зрештою, інтеграція енергоощадних і екологічно безпечних підходів, підкріплених високим рівнем технічного та програмного моніторингу, забезпечуватиме тривале функціонування промислових комплексів з урахуванням економічної доцільності й екологічної відповідальності, формуючи підґрунтя для стабільного розвитку галузі в умовах глобальних викликів.

1.2 Методи виявлення несправностей

Методи виявлення несправностей у сучасних промислових системах спираються на багатовекторний підхід і передбачають аналіз великих обсягів даних задля вчасного розпізнавання ознак аномальної роботи обладнання. В умовах наростаючої складності виробничих процесів і зростання кількості технічних параметрів, що потребують контролю, застосування традиційних статистичних засобів виявляється недостатнім. На передній план виходять нейронні мережі глибокого навчання, зокрема автоенкодери, які здатні ефективно опрацьовувати високорозмірні дані й розкривати приховані закономірності, не доступні для простих методів регресії чи класифікації[18]. Автоенкодери створюють компактне представлення вхідних сигналів,

					ІАЛЦ.467200.003 ПЗ	Арк.
						15
Змн.	Арк.	№ докум.	Підпис	Дата		

навчаючись відтворювати вихідну інформацію через низьковимірне кодування, що допомагає виявляти нехарактерні відхилення та розпізнавати потенційні несправності.

Застосування автоенкодерів у завданнях моніторингу передбачає попереднє навчання моделі на даних, які описують нормальну роботу виробничих систем. У процесі навчання мережа формує внутрішнє відображення патернів регулярної експлуатації, і як наслідок, помилка відновлення даних стає мінімальною. У разі, коли з'являються нові вимірювання з нехарактерною поведінкою або ознаками несправності, реконструктивна помилка автоенкодера істотно зростає[19]. Це дає змогу алгоритмічно фіксувати відхилення, належно реагувати на появу аномальних сигналів і, за потреби, запускати діагностичні процедури, включно з аварійним відключенням чи перевіркою функціональних вузлів. Такий підхід дозволяє автоматизувати більшість рутинних операцій з виявлення можливих ушкоджень, уникаючи людського фактору та мінімізуючи ризики інтерпретаційних помилок.

Ефективність методів на основі автоенкодерів значною мірою залежить від належної підготовки даних та ретельно підібраних архітектур нейронних мереж, що відповідають специфіці промислового застосування. Зокрема, в умовах високочастотного збору даних доцільно застосовувати згорткові або рекурентні автоенкодери, які дають змогу враховувати тимчасові кореляції або просторові особливості у записаних параметрах. Вибір методу активації та регуляризації, а також гіперпараметрів (глибини мережі, кількості нейронів, коефіцієнтів навчання) істотно впливають на здатність автоенкодера розпізнавати аномалії. Для подальшого підвищення точності та зменшення кількості хибних спрацювань застосовують ансамблеві підходи, коли водночас використовується декілька різних модифікацій автоенкодерів, результати яких комбінуються в єдиному рішенні. Накопичення такої моделі з досвідом експлуатації забезпечує плідні умови для безперервного вдосконалення методів у масштабі виробництва й надає змогу розширювати функціонал системи діагностики у відповідь на нові технологічні виклики.

					ІАЛЦ.467200.003 ПЗ	Арк.
						16
Змн.	Арк.	№ докум.	Підпис	Дата		

1.3 Автоенкодери як метод аномального аналізу

Автоенкодери у своїй теоретичній основі являють собою тип глибинних нейронних мереж, що навчаються відтворювати вхідні дані після їх перетворення в компактне представлення (латентний простір)[20]. При цьому мережа поділяється на дві основні частини: енкодер, що зменшує розмірність початкових даних і виділяє найсуттєвіші ознаки, та декодер, який відновлює вхідний сигнал із цього стиснутого представлення. Фундаментальною метою даного підходу є мінімізація різниці між оригінальними даними та їх реконструкцією, що матиме низьке значення у разі, коли латентний простір успішно відображає домінантні характеристики вхідного сигналу. Така сукупність операцій дає змогу автоенкодерам опановувати приховану структуру даних, відсіюючи зайвий шум і зменшуючи розмірність, не втрачаючи при цьому суттєвої інформації про розподіл та внутрішню кореляцію ознак[21].

Для навчання автоенкодера переважно використовується метод зворотного поширення помилки, що за аналогією з іншими глибинними архітектурами передбачає ітеративне коригування вагових коефіцієнтів на основі градієнтів функції втрат. Найчастіше як функцію втрат обирають середньоквадратичну похибку або крос-ентропію, які дають змогу кількісно оцінити різницю між вихідними даними та їх реконструкцією. Зазвичай архітектура автоенкодера має певну симетрію – кількість шарів енкодера та декодера є або однаковою, або близькою, хоча на практиці можуть використовуватися варіації із різними розмірами шарів, особливо тоді, коли необхідно отримати більш узагальнене та інваріантне відображення даних[22]. Таке відображення відкриває шлях до широкого спектра застосувань: від розв’язання задачі зменшення розмірності та очистки шуму в даних до виявлення аномалій у високорозмірних просторах, де класичні лінійні методи часто втрачають ефективність.

З погляду теоретичних засад глибинного навчання автоенкодери можна розглядати як частину ширшого класу архітектур, спрямованих на нелінійне вивчення латентних просторових ознак. Завдяки використанню багат шарових нейронних структур вони здатні ефективно моделювати складні залежності між

величезною кількістю вхідних змінних, водночас відкидаючи другорядні компоненти сигналу. Ця властивість безпосередньо пов'язана із силою універсальної апроксимації, яку мають глибинні мережі: за достатньої кількості нейронів та правильного налаштування гіперпараметрів вони здатні відтворити практично будь-яку безперервну функцію на відповідному проміжку[23]. Окрім того, латентний простір, отриманий на виході енкодера, може слугувати ефективною базою для побудови інших алгоритмів – від простих моделей класифікації або регресії до багаторівневих систем виявлення аномалій, які будують більш складні багатовимірні гіпотези щодо природи відхилень[24]. Зрештою, автоенкодери демонструють потужний потенціал для теоретичних досліджень у галузі навчання представлень, оскільки надають механізм для виявлення та кодування суттєвих характеристик даних у стислому форматі, водночас допомагаючи краще зрозуміти приховані структури великомасштабних вибірок.

Типологія архітектур автоенкодерів охоплює різноманітні модифікації нейронних мереж, які відрізняються за структурою шарів, особливостями кодування та відновлення даних, а також призначенням у рамках загального алгоритмічного процесу. Традиційна, або ж «ванільна», архітектура автоенкодера являє собою послідовність щільно з'єднаних шарів, де розмірність вхідного шару зменшується в напрямку прихованих шарів (енкодер), а згодом симетрично збільшується (декодер), утворюючи своєрідну «пляшкову шийку», яка концентрує найсуттєвіші ознаки даних у стислому вигляді[25]. Такий підхід дозволяє автоматично виокремлювати латентні фактори, що визначають головні характеристики вхідних сигналів, і забезпечує подальшу можливість відновлення початкової інформації. Для більш комплексних завдань, де суттєву роль відіграють просторові або часові кореляції у даних, застосовують згорткові та рекурентні автоенкодери. У першому випадку використовуються згорткові шари, що ефективно опрацьовують багатовимірні структури на кшталт зображень чи сигналів, а у другому – рекурентні блоки, які аналізують послідовні дані та зберігають коротко- і довгострокові залежності у межах часових

рядів[26]. Така типологія дає змогу оптимально адаптувати модель до конкретних особливостей вхідного простору, підвищуючи точність кодування та ефективність обробки.

Окремий напрямок у межах типології автоенкодерів становлять так звані варіаційні моделі, у яких у процесі навчання оптимізується не лише відтворення вихідної вибірки, а й розподіл латентного простору. Тут приховане представлення даних розглядається як імовірнісна величина, а мета навчання полягає у наближенні до цільового розподілу, що дозволяє отримувати більш узагальнені та гнучкі уявлення про структуру вхідних сигналів. Схожим за своєю ідеєю, але з іншим акцентом, є денойзінг-автоенкодер, який вчиться відновлювати початкові дані з їх пошкоджених версій, покращуючи стійкість мережі до шумів або втрат інформації. Поряд з цим, існують ще й спарс-автоенкодери, де на стадії навчання накладаються обмеження на кількість активних нейронів у прихованих шарах, аби сприяти формуванню розріджених представлень і, таким чином, ще глибше виявляти суттєві риси входу[27]. У більш сучасних модифікаціях використовують змагальні мережі (adversarial autoencoders), де автоенкодер змагається з додатковим дискримінатором, забезпечуючи високу якість відновлення даних та водночас контролюючи розподіл у латентному просторі. Така розгалужена типологія архітектур автоенкодерів дає змогу обирати оптимальну стратегію для найрізноманітніших практичних задач, у тому числі для аномального аналізу, зменшення розмірності, денойзингу чи генеративних процесів[28].

Навчання автоенкодерів на нормальних даних становить основу для формування ефективних систем аномального аналізу в промислових і наукових застосуваннях. Згідно з концепцією автоенкодера, нейронна мережа намагається відтворити вхідні дані через низьковимірне кодування та подальше декодування, створюючи проміжне узагальнене уявлення про закономірності вхідного простору[29]. У цьому процесі автоенкодер навчається зіставляти реальні сигнали нормального функціонування обладнання чи процесів із їх відновленою версією, мінімізуючи різницю між вхідними та вихідними даними. Така

попередня обробка дає змогу нейронній мережі «запам'ятати» ті патерни, які притаманні виключно безаварійним режимам роботи, адже будь-які суттєві відхилення від характерної поведінки автоматично призводитимуть до зростання реконструктивної помилки. Це, у свою чергу, дозволяє чітко відокремлювати нормальні зразки від потенційно аномальних без ручного втручання чи специфічної класифікації аномальних патернів[30].

Ключовим чинником успішного навчання автоенкодера на нормальних даних є репрезентативність вибірки та збалансованість усіх характеристик, що відображають стабільну роботу системи. Доцільно включати до навчального набору дані з різних фаз нормального функціонування, а також із періодів планового технічного обслуговування, якщо вони не містять критичних відхилень[33]. Збирання та маркування даних передбачає уважний аналіз виробничих процесів, визначення допустимих коливань параметрів і відсіювання потенційно проблемних записів. Автоенкодер, навчаючись лише на надійних прикладах, виробляє здатність ефективно упізнавати властивості «здорового» стану системи та водночас «ігнорувати» рідкісні прояви, що виходять за межі здобутих ним статистичних правил. Залежно від складності сигналів і їх часових чи просторових залежностей до архітектури автоенкодера додають згорткові або рекурентні шари, які забезпечують глибше виявлення внутрішніх зв'язків між ознаками.

Результатами правильно організованого навчання на нормальних даних є побудова нейронної моделі, здатної з високою точністю відтворювати патерни штатної роботи та оперативно виявляти відхилення, що передбачають потенційні несправності або аварійні ситуації[34]. У практичних застосуваннях це дає змогу значно скоротити час реагування на появу ризикованих сценаріїв, позаяк висока реконструктивна помилка слугує тригером для детальнішої перевірки обладнання чи процесу. Окрім того, такий підхід не вимагає наявності великого набору аномальних прикладів, які зазвичай є нечисленними або нерепрезентативними, що робить метод автоенкодерів на основі нормального навчального набору універсальним та гнучким у контексті різноманітних

					ІАЛЦ.467200.003 ПЗ	Арк.
						20
Змн.	Арк.	№ докум.	Підпис	Дата		

галузей промисловості й науки.

Поняття реконструктивної помилки відіграє центральну роль у методології використання автоенкодерів для задачі аномального аналізу. У найзагальнішому вигляді автоенкодер складається з двох частин: енкодера, що перетворює вхідні дані у стислий вектор, та декодера, який відновлює початкову інформацію з цього векторного представлення. Під час навчання на нормальних вибірках мережа оптимізує свої вагові коефіцієнти таким чином, щоб похибка відновлення була якомога меншою[31]. Ця похибка, зазвичай обчислювана як середньоквадратичне відхилення між вхідними даними та їхнім реконструйованим аналогом, є кількісним відображенням здатності моделі захоплювати ключові особливості та структуру нормальних спостережень. При належному налаштуванні нейронних архітектур та адекватних обсягах навчених даних отримана модель стає чутливою до будь-яких відхилень від патернів, на яких вона тренувалася.

Суть підходу полягає в тому, що після навчання модель демонструє дуже низьку реконструктивну помилку, якщо подається зразок, подібний до тих, що вона вже “бачила” під час тренування. Коли ж на вхід надходять дані, що виходять за межі звичної структури (наприклад, свідчення апаратних несправностей або аномальної поведінки системи), декодер не в змозі коректно відтворити відповідні патерни, що призводить до суттєвого зростання значення реконструктивної помилки[32]. У такий спосіб величину цієї помилки можна розглядати як індикатор наявності або відсутності аномалій у спостереженнях. При цьому важливо правильно встановити граничні значення, що відокремлюють нормальне функціонування від нетипового. Існують різноманітні підходи до визначення таких порогів: статистична оцінка розподілу помилок на тренувальних даних або застосування додаткових методів кластеризації задля відсікання вибірок із високим рівнем відхилення. Отже, метрика реконструктивної помилки перетворюється на простий і водночас ефективний інструмент виявлення аномальних явищ, завдяки якому можливо впроваджувати дієві системи раннього попередження про несправності та

					ІАПЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		21

підвищувати надійність роботи виробничих систем[33].

Система виявлення аномалій на основі автоенкодерів базується на принципі реконструкції вхідних даних та оцінюванні ступеня відхилення між початковим сигналом і відновленим. Автоенкодер, попередньо навчений на великій сукупності даних, що описують нормальний режим функціонування, формує внутрішнє уявлення про характерні риси вхідних зразків. Така модель засвоює характерні статистичні взаємозв'язки між параметрами процесів, умови відхилення яких від загальноприйнятої норми стають індикатором несправності. У контексті промислових систем зібрані з різних сенсорів відомості проходять процедуру передобробки, зокрема фільтрацію та нормалізацію, що забезпечує зменшення шумів та зсувів у вихідних вимірах[34]. На основі очищених даних нейронна мережа будує латентний простір, у якому зберігаються згорнуті вектори низької розмірності. Якщо досліджувані параметри перебувають у межах нормальної варіації, модель здатна адекватно відновлювати початкові дані з мінімальною помилкою.

Особливістю використання автоенкодерів для виявлення аномалій є те, що вони фокусуються виключно на патернах стандартної роботи. Під час навчання не надається інформація про несправні або екстремальні стани, оскільки зазвичай такі дані або відсутні, або є вкрай обмеженими. Система покладається на припущення, що вона зможе належно реконструювати лише ті вхідні приклади, які належать до «нормальної» множини[35]. Якщо ж на вхід надходять значення, нетипові для звичної карти сигнатур, автоенкодер продукує вищу реконструктивну помилку. Це свідчить про ймовірну присутність потенційної аномалії, яку слід додатково проаналізувати методами промислового контролю. На практиці рішення може включати застосування порогового критерію: якщо показник середньоквадратичної різниці або похибки відновлення перевищує визначений рівень, об'єкт чи параметр підлягає подальшій експертизі.

Роль сучасних обчислювальних ресурсів у такій системі є надзвичайно важливою, адже більші промислові комплекси генерують величезні обсяги даних, які потрібно обробляти в режимі, наближеному до реального часу.

					ІАЛЦ.467200.003 ПЗ	Арк.
						22
Змн.	Арк.	№ докум.	Підпис	Дата		

Інтеграція автоенкодерів із хмарними платформами дозволяє розподіляти обчислювальні навантаження, одночасно забезпечуючи єдиний центр аналізу й синхронізоване оновлення моделей. Це відкриває можливість безперервного навчання: мережева система виявлення аномалій із часом здатна підлаштовуватися під зміну параметрів у технологічному циклі, відсіюючи помилкові спрацювання й актуалізуючи критерії оцінки. Результатом такої інтеграції стає не лише підвищений рівень діагностики, а й потенціал раннього передбачення проблем, що дає змогу ухвалювати ефективні рішення з оптимізації виробничих процесів і планування технічного обслуговування[36].

Узгодження алгоритмічних елементів виявлення аномалій з організаційними потребами підприємства також має визначальне значення. Система, що базується на автоенкодерах, потребує чіткого опису процедур реагування, від моніторингу поточного стану сенсорів до комунікації з операторами й відповідними інженерними службами. Існує необхідність у верифікації прогнозованої помилки для виключення хибно позитивних спрацювань, оскільки в деяких випадках незвичні сигнали можуть виникати внаслідок планових змін або коригувань на виробництві. Водночас належний рівень інтерпретації дає змогу виявити не лише очевидні несправності, а й повільні деградаційні процеси, що не завжди фіксуються традиційними методами контролю. Формування надбудови для процесу прийняття рішень забезпечує повноцінний замкнутий цикл контролю якості: від отримання первинної інформації до ухвалення управлінських заходів у разі виявлення відхилень.

Зрештою, застосування автоенкодерів у рамках системи виявлення аномалій надає можливість організувати гнучкий і розширюваний інструмент для підтримання надійності промислових комплексів. Така технологічна концепція у поєднанні з комплексною стратегією управління дозволяє не тільки оперативно реагувати на критичні несправності, а й виявляти відхилення на ранніх етапах. Завдяки здатності до масштабування та періодичного перенавчання мережа залишається актуальною за умов динамічного оновлення обладнання і

					ІАЛЦ.467200.003 ПЗ	Арк.
						23
Змн.	Арк.	№ докум.	Підпис	Дата		

змін у технологічних процесах. Таким чином, система виявлення аномалій, що базується на автоенкодерах, стає фундаментальним елементом безперервного моніторингу і діагностики, підвищуючи конкурентоспроможність виробництва, зменшуючи ризики зупинок та аварій і сприяючи раціональному використанню ресурсів.

Інтеграція автоенкодерів з іншими алгоритмами машинного навчання дає змогу значно підвищити результативність і надійність процесу виявлення аномалій у різноманітних виробничих середовищах та інформаційних системах. Один із поширених підходів базується на обробці реконструктивної помилки, яка генерується автоенкодером, та подальшій передачі її в якості вхідних ознак до традиційних моделей класифікації, таких як метод опорних векторів або дерево рішень. Завдяки такій комбінації нейронна мережа глибинного навчання виконує роль спеціалізованого екстрактора ознак, що навчається на великих обсягах нормальних даних та виявляє складні патерни, неочевидні для статистичних методів. Водночас більш прості й легкі у налаштуванні алгоритми можуть визначати приналежність об'єкта або ситуації до «аномального» класу, спираючись на той же рівень помилки чи додаткові характеристики, сформовані автоенкодером[37]. Зрештою, такий гібридний підхід здатний забезпечити більш високу точність, адже поєднує глибинну репрезентацію даних із гнучкими правилами класифікації, які можна відносно швидко адаптувати до умов конкретної галузі.

Ще однією ефективною практикою є застосування ансамблевих методів, коли кілька різних автоенкодерів, налаштованих під різні підмножини параметрів чи часові інтервали, генерують незалежні оцінки нормальності даних. Їх подальше агрегування спирається на методи групового прийняття рішень або механізми «voting», що мінімізує помилки одного окремого алгоритму та підвищує надійність системи в цілому. Аналогічно, інтеграція автоенкодерів з алгоритмами кластеризації на кшталт k-means або засобами головних компонент дозволяє попередньо зменшувати розмірність та відокремлювати проблемні ділянки у просторі ознак, перш ніж подавати дані на вхід нейронної мережі. Така

схема сприяє виявленню специфічних груп показників, які чітко сигналізують про виникнення аномальної активності, та у підсумку покращує керованість складних виробничих систем. Таким чином, взаємодоповнююче застосування автоенкодерів з іншими алгоритмами спричиняє синергетичний ефект, який на практиці дає змогу швидше та точніше виявляти й усувати проблеми, що виникають на перетині програмних, технічних і організаційних процесів.

1.4 Постановка задачі дослідження

Актуальність розробки системи виявлення несправностей у промислових комплексах зумовлена високою складністю й багаторівневою структурою виробничих процесів, які безперервно генерують великі обсяги даних про роботу обладнання та стан технологічних ланцюгів. З огляду на зростання темпів автоматизації, виникає потреба у запровадженні методів, здатних своєчасно фіксувати потенційні відхилення чи відмови в реальному часі, щоб запобігати негативним наслідкам для безпеки, ефективності та економічної доцільності виробництва. Традиційні статистичні підходи не завжди дозволяють повноцінно обробляти та аналізувати широкий спектр вимірювань з урахуванням складних внутрішніх залежностей, а спроби ручної інтерпретації даних створюють ризик суб'єктивних помилок і не забезпечують належного рівня оперативності. Відповідно, постає завдання розробки технології, яка здатна не лише приймати й обробляти великі масиви показників із різноманітних сенсорів, а й утримувати високу точність під час реєстрації малопомітних, але критичних ознак несправностей на ранніх етапах.

Використання глибинних автоенкодерів дає змогу суттєво розширити межі детектування аномалій, оскільки вони здатні виявляти приховані закономірності та встановлювати характерні шаблони нормальної роботи, спираючись на багатовимірні представлення процесів. Стандартні методи класифікації чи регресії часто вимагають наявності детально маркованих даних про дефекти, яких може бути недостатньо або вони не завжди доступні у повному обсязі. У випадку з автоенкодерами відповідна модель навчання надана головно

					ІАЛЦ.467200.003 ПЗ	Арк.
						25
Змн.	Арк.	№ докум.	Підпис	Дата		

прикладами нормальних режимів, що особливо корисно в контексті рідкісних відмов, коли історичні дані про несправності обмежені чи неповні. Під час функціонування такий підхід дозволяє виявляти зростання реконструктивної помилки при появі нехарактерних сигналів, які можуть свідчити про наближення відмови. Глибокі автоенкодери демонструють здатність до адаптації й можуть бути доповнені механізмами регуляризації та оптимізації, спрямованими на підвищення точності аналізу для промислових процесів зі складною динамікою та значними коливаннями вхідних параметрів.

З огляду на зазначені передумови, постає проблема побудови й обґрунтування методології автоматизованого виявлення несправностей у багатокомпонентних виробничих системах, де інтелектуальні алгоритми діагностики мають реагувати на найменші відхилення від штатних показників і швидко адаптуватися до змін умов експлуатації. Необхідно розробити архітектуру глибоких автоенкодерів, яка враховує технічну специфіку датчиків, часові кореляції у даних та особливості розподілу шумів. Важливо також сформулювати підхід до оцінювання ефективності, що дозволить кількісно вимірювати здатність алгоритму виявляти рідкісні, але критичні збої в масиві рутинних, стабільних показників. Результати успішного вирішення цієї задачі сприятимуть підвищенню надійності технологічних процесів, зменшенню аварійності та оптимізації витрат, пов'язаних із непередбачуваними простоюваннями виробництва, а також слугуватимуть основою для формування цілісних платформ інтелектуального моніторингу, адаптованих до потреб сучасної промисловості.

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		26

ВИСНОВКИ ДО РОЗДІЛУ

На підставі проведеного у першому розділі аналізу було з'ясовано, що традиційні методи виявлення несправностей у промислових системах мають обмеження щодо обробки високовимірних та неоднорідних даних, що у свою чергу зумовлює актуальність застосування глибоких автоенкодерів як інструменту для автоматизованого та ефективного виявлення аномалій, з урахуванням їх здатності до навчання представлення нормальної поведінки технічних об'єктів і виявлення відхилень на основі реконструкційної помилки.

					ІАПЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		27

РОЗДІЛ 2 РОЗРОБКА МЕТОДИКИ НА ОСНОВІ ГЛИБОКИХ АВТОЕНКОДЕРІВ

2.1 Формалізація задачі виявлення аномалій

У межах проблематики виявлення технічних несправностей на об'єктах промислової інфраструктури ключовим етапом є чітке окреслення тієї категорії інформації, з якою здійснюється подальша обробка, а також типових особливостей середовища, в якому відбувається експлуатація відповідних систем. Під поняттям «предметна область» у цьому контексті слід розуміти сукупність функціональних та фізичних процесів, що відображають стан механізмів, агрегатів, вузлів і обчислювальних блоків, які формують загальний техногенний цикл на виробництві. Кожен з таких об'єктів генерує певну кількість характеристичних параметрів, що реєструються сенсорними системами, які функціонують у режимі реального часу або з дискретним опитуванням. З огляду на це, потік даних, що надходить до системи моніторингу, може бути формалізовано як часова послідовність багатовимірних спостережень, які фіксують динаміку фізичних величин у заздалегідь визначених інтервалах.

Типовою особливістю таких даних є їхня високовимірність, нерівномірність частоти надходження та можливість наявності вхідних шумів, що обумовлює необхідність попередньої математичної обробки та відокремлення неінформативних флуктуацій. У разі детального формалізованого представлення кожен спостережуваний вектор можна інтерпретувати як елемент евклідового простору відповідної розмірності, де кожна координата відображає значення певного технологічного параметра — наприклад, температури в точці з'єднання, електричного струму на контакті, величини коливань у підшипниковому вузлі тощо. Такий формат уніфікує подання незалежно від специфіки обладнання і створює підґрунтя для алгоритмічного аналізу узагальненими методами.

Таким чином, інформаційна модель, яка розглядається в рамках задачі, формується як впорядкована множина вимірюваних векторів, що репрезентують

					ІАЛЦ.467200.003 ПЗ	Арк.
						28
Змн.	Арк.	№ докум.	Підпис	Дата		

стан об'єкта у часовій динаміці, де кожна наступна реалізація є потенційним носієм як нормативного, так і відхиленого функціонування. З огляду на множинність джерел інформації та неоднорідність технічних процесів, важливим є збереження інваріантності представлення до типу сенсора, що фіксує значення, а також адаптація до змін робочих режимів, які не завжди марковані явно. Це визначає потребу в такому способі формалізації, який би одночасно був достатньо абстрактним для генералізації, але й чутливим до локальних відхилень у поведінці системи.

У контексті застосування глибоких нейронних архітектур до задач технічної діагностики одним із фундаментальних підходів до виявлення атипових спостережень виступає трактування виявлення аномалій як задачі неперервної реконструкції. Сутність такого формулювання ґрунтується на припущенні про існування латентного структурного узгодження між вхідним простором ознак, що репрезентують нормальний функціональний стан системи, та відповідним відображенням цього простору, яке здатне бути відтвореним за допомогою навченої моделі. Йдеться про те, що система, що перебуває в режимі штатної експлуатації, продукує патерни даних, для яких існує внутрішня регулярність, що піддається формалізації у вигляді зниженої розмірності латентного простору, який відображає основні динамічні характеристики без суттєвих втрат інформаційного наповнення.

На цьому підґрунті задача реконструкції зводиться до пошуку такого перетворення вхідного вектора стану, яке мінімізує різницю між вхідними даними та їх проєкцією, відновленою на основі латентного представлення. У випадку застосування автоенкодерів таке перетворення здійснюється за допомогою двох послідовних функціональних операторів — енкодера, що здійснює відображення вхідного багатовимірного вектора до зниженої репрезентації, та декодера, який апроксимує обернене перетворення. Навчання моделі відбувається шляхом поступової адаптації параметрів цих операторів з урахуванням критерію мінімізації реконструкційної похибки. У загальному випадку застосовується евристична функція втрат, побудована на основі міри

					ІАЛЦ.467200.003 ПЗ	Арк.
						29
Змн.	Арк.	№ докум.	Підпис	Дата		

відхилення між вхідним вектором та реконструйованим аналогом, зокрема середньоквадратичне відхилення, що має аналітичну зручність та інтерпретативну прозорість для подальшої оцінки.

Ключовим моментом формалізації є те, що реконструкційна здатність моделі розглядається як індикатор належності спостереження до множини нормальних режимів. Якщо при подачі нового зразка модель демонструє істотно вищу похибку відновлення порівняно з середнім значенням, отриманим на навчальному наборі, то такий зразок інтерпретується як потенційно аномальний. З огляду на це, задача детектування зводиться до виявлення зразків, для яких значення реконструкційної похибки перевищує заздалегідь визначений або статистично обґрунтований поріг. Це дозволяє трансформувати задачу класифікації зразків на нормальні та аномальні у задачу безнаглядного аналізу відхилень без необхідності залучення явних міток, що особливо цінне в умовах обмеженого доступу до репрезентативних наборів даних про відмови або нестандартні режими роботи.

Під час підготовки даних для подальшого навчання глибокої нейронної моделі, зокрема автоенкодера, вирішальним кроком є впорядкування структури вхідних ознак та приведення їх до уніфікованого масштабу. Така процедура не лише забезпечує математичну коректність обчислень, а й створює передумови для ефективної адаптації вагових коефіцієнтів моделі до статистичних характеристик вхідного потоку. У промислових системах дані мають тенденцію до високої розмірності, неоднорідності та наявності параметрів з істотно різними фізичними одиницями виміру. Внаслідок цього значення, що відповідають за температурний режим, можуть на декілька порядків відрізнятися від електричних або механічних величин, а така невідповідність призводить до дисбалансу у фазовому просторі моделі, де значення одних компонент можуть домінувати над іншими, штучно знижуючи їх внесок в обчислення функції втрат.

У зв'язку з цим доцільним вважається впровадження операцій стандартизації або нормалізації ознак. Якщо обрана методика передбачає приведення до середнього нульового значення та одиничного стандартного

					ІАПЦ.467200.003 ПЗ	Арк.
						30
Змн.	Арк.	№ докум.	Підпис	Дата		

відхилення, то кожна компонента багатовимірного вектора перетворюється відповідно до формули 2.1:

$$z_i = \frac{x_i - \mu_i}{\delta_i}, \quad (2.1)$$

де μ_i та δ_i — математичне сподівання та середньоквадратичне відхилення відповідної ознаки. Така трансформація дозволяє створити умови, за яких модель навчається на ознаках зі збалансованими статистичними характеристиками, знижуючи ймовірність передчасної сходимості до локального мінімуму через числову нестабільність або переорієнтацію на окремі компоненти вхідного простору.

Іншою поширеною методикою є приведення до інтервалу $[0, 1]$, що особливо доцільно при використанні активаційних функцій, чутливих до масштабів вхідних значень, зокрема у випадку застосування сигмоїдальних або гіперболічних тангенс-функцій. За цієї методики для кожної компоненти визначається мінімальне та максимальне значення, на підставі яких виконується масштабування. У межах машинного навчання така процедура є не лише технічним кроком, а актом трансформації початкового фазового простору до топологічно узгодженого з функціональним простором відображень моделі, що сприяє підвищенню загальної узгодженості обчислювальних процесів.

Таким чином, побудова простору ознак передбачає не лише технічну агрегацію первинних даних у формалізовану структуру вхідного вектору, але й концептуальну перебудову цього простору шляхом вибору релевантних компонент, виключення надлишкових або корельованих параметрів, а також перетворення вектора спостережень у числову конфігурацію, що узгоджується з геометричними властивостями латентного простору моделі. В результаті забезпечується стабільність навчання, поліпшення збіжності оптимізаційного процесу та збереження чутливості до відхилень, які можуть вказувати на присутність несправностей у досліджуваному технічному середовищі.

У межах побудови ефективної системи виявлення аномалій у промислових об'єктах особливу увагу необхідно зосередити на концептуальній структурі автоенкодера як ключового елемента, що здійснює компресію та подальшу

реконструкцію багатовимірних спостережень. В основі архітектурного підходу лежить ідея безвтратного вилучення характерних закономірностей із даних про нормальний режим функціонування технічного обладнання з наступною спробою їх точного відтворення. Формалізуючи означену задачу, доцільно розглядати двоетапну модель, яка складається із функціонально розмежованих компонентів: першою є кодувальна частина, яка здійснює нелінійне проєктування вхідного векторного простору у зменшене латентне представлення з нижчою розмірністю, другою – декодувальний блок, що відновлює початкову конфігурацію даних із стисненого відображення.

Нехай $x \in R^d$ репрезентує початкове спостереження, отримане з потоку сенсорних вимірювань. Тоді відображення $E:R^d \rightarrow R^k$ задає процес занурення в латентний простір, де $k \ll d$, що дозволяє виявити внутрішні структурні залежності між ознаками, які не завжди очевидні в початковому вимірі. Латентний вектор $z=E(x)$ виступає результатом застосування послідовності афінних перетворень, збагачених функціями активації типу ReLU або tanh, які формують багаторівневе відображення, що відображає глибоку внутрішню структуру вхідних даних. Декодувальний модуль, представлений функцією $D:R^k \rightarrow R^d$, реалізує зворотне перетворення, намагаючись реконструювати $\hat{x}=D(z)=D(E(x))$, де результат відтворення слугує критерієм для подальшої оцінки нормальності об'єкта спостереження.

В основі навчального процесу лежить прагнення до мінімізації функціоналу помилок реконструкції, що слугує мірою невідповідності між початковим вектором і його реконструкцією. Найбільш уживаною у цьому контексті є функція середньоквадратичної втрати, яка набирає вигляду $L(x, \hat{x}) = \|x - \hat{x}\|_2^2$, що дозволяє визначити ступінь відхилення за евклідовою метрикою. У разі переважання таких відхилень над певним статистично або емпірично встановленим порогом, робиться припущення про наявність нетипової ситуації, що з великою ймовірністю може свідчити про початок деградації системного елементу чи приховану технічну несправність.

Особливістю глибоких автоенкодерів, що відрізняє їх від класичних

					ІАЛЦ.467200.003 ПЗ	Арк.
						32
Змн.	Арк.	№ докум.	Підпис	Дата		

лінійних аналогів, є можливість багат шарового відображення з адаптивним коригуванням параметрів під час оптимізації. Завдяки цьому модель здатна моделювати складні, багатозв'язні залежності, характерні для фізичних і технологічних процесів, які зазнають динамічних змін у часі. Таким чином, глибока архітектура автоенкодера не лише дозволяє формувати стиснене представлення вхідних ознак, але й забезпечує високий рівень дискримінативної здатності при виявленні відхилень, що мають внутрішню структурну природу, а не обумовлені випадковим шумом.

Після завершення етапу навчання глибокого автоенкодера на репрезентативній вибірці нормальних технічних станів об'єкта, виникає потреба в точному формулюванні процедури інтерпретації результатів реконструкції для визначення наявності аномального спостереження. Ця процедура передбачає впровадження формалізованого критерію, який дає змогу розмежувати нормальні та потенційно несправні технічні стани на підставі величини похибки відновлення. Під цією похибкою розуміється числове значення функціоналу, що характеризує відстань між вхідним вектором стану системи та його реконструкцією, отриманою після проходження крізь модель, яка апроксимує латентний простір. Зазвичай використовується евклідова метрика або середньоквадратична похибка, однак обрану метрику слід узгоджувати з типом вхідних даних та поведінковими характеристиками моделі.

У зв'язку з неможливістю заздалегідь фіксувати граничне значення функції втрат, що б стало універсальним орієнтиром для будь-якої конфігурації моделі чи характеристик об'єкта, необхідно здійснити процедуру адаптивного встановлення порогового рівня. Такий поріг інтерпретується як числова межа, за перевищення якої вхідний вектор класифікується як такий, що не належить до множини нормально функціонуючих станів. Розв'язання цієї задачі часто зводиться до статистичного аналізу розподілу значень помилки реконструкції на валідаційній підмножині, що репрезентує лише безаномальні приклади. На підставі цієї емпіричної множини обчислюється апроксимація розподілу ймовірностей, яка в подальшому використовується для визначення квантільного

рівня – наприклад, 95-го або 99-го процентиля, що забезпечує відсікання аномалій з наперед визначеною чутливістю[40].

В окремих випадках може бути застосований підхід, що базується на припущенні про нормальний розподіл похибок реконструкції. В такому разі поріг обчислюється як математичне сподівання плюс кілька стандартних відхилень, що відповідає обраному рівню довіри. Цей спосіб дозволяє здійснювати оцінювання навіть за обмеженої кількості зразків, проте вимагає попередньої перевірки припущення про гаусівську природу розподілу[41]. Варто зазначити, що вибір методу встановлення порогового значення повинен враховувати чутливість до хибнопозитивних та хибнонегативних спрацьовувань, з огляду на критичність наслідків помилкової класифікації для відповідної галузі застосування.

Таким чином, процес формалізації критерію виявлення аномалії передбачає побудову числової характеристики, яка через механізм порівняння з адаптивно визначеним граничним значенням забезпечує прийняття рішення щодо відповідності нового технічного стану до класу нормальних чи аномальних. Такий підхід є математично обґрунтованим та практично релевантним у задачах діагностики стану складних технічних систем у промисловому середовищі.

Оцінювання результативності моделей виявлення аномалій, побудованих на основі глибоких автоенкодерів, становить окремий складник формалізованої постановки задачі, який опосередковує межу між експериментальною валідністю системи та її потенціалом до реального впровадження в умови техногенно-інтенсивного середовища. Проблематика оцінювання ускладнюється відсутністю повного набору прецедентів відхилень у багатьох прикладних сценаріях, що вимагає або апроксимаційного моделювання, або побудови статистичних гіпотез для визначення функціонального порогу, за яким починається зона відхилення від нормативної реконструктивної поведінки. У випадку наявності валідаційної вибірки з відміченими зразками некоректного функціонування технічного об'єкта, доцільно використовувати адаптований

інструментарій із арсеналу машинного навчання, зокрема параметри обчислювального узагальнення здатності моделі до диференціації між номінальними і нетиповими зразками. З-поміж таких числових характеристик найбільш інформативними постають F-міра, що поєднує показники охоплення та специфічності у гармонійне середнє, та показник площі під ROC-кривою, котрий індикує стабільність здатності моделі до розмежування класів при змінних порогах.

Коли відсутній доступ до апіорної класифікації прикладів, методологія перевірки ефективності передбачає побудову емпіричного розподілу відновлювальних втрат, які виникають на основі аналізу вибірки з номінальними характеристиками. Цей розподіл слугує базисом для визначення адаптивного порогу шляхом, наприклад, статистичного квантування або використання параметрів довірчих інтервалів, що дозволяє уникати необхідності прямих порівнянь із бінарними мітками[42]. У подібних випадках відбувається непряма оцінка функціональної корисності мережевої структури, яка реалізує механізм латентної компресії, здатної відтворювати лише ті структури, котрі не порушують внутрішню когерентність простору ознак.

Важливим теоретико-прикладним аспектом є також урахування характеру розподілу помилок, зокрема його асиметрії, хвостових властивостей та наявності мульти-модальних відгалужень. Зазначені властивості можуть істотно змінювати критерії, за якими формується оцінка узагальненої чутливості моделі, і водночас потребують додаткової уваги при обґрунтуванні достовірності спрацьовування на відхилення. Таким чином, процедура кількісної верифікації не може зводитись до одного узагальненого індикатора і має розглядатися як сукупність взаємопов'язаних етапів аналітичного аналізу розподілу реакцій моделі на широкий спектр тестових ситуацій.

2.2 Вибір архітектури автоенкодера

Архітектура автоенкодера представлена на рисунку 2.1.

					ІАЛЦ.467200.003 ПЗ	Арк.
						35
Змн.	Арк.	№ докум.	Підпис	Дата		

Архітектура глибокого автоенкодера




Рисунок 2.1 – Архітектура автоенкодера

У структурі глибокого автоенкодера, призначеного для виявлення аномалій у промислових комплексах, вхідний шар виконує функцію первинного прийому та структурного нормування векторів ознак, що надходять із сенсорної підсистеми технічного об'єкта[43]. З формальної точки зору, вхідний шар є початковим вузлом нейронної мережі, розмірність якого строго відповідає

кількості інформативних параметрів, що характеризують поточний технічний стан об'єкта у фіксований момент часу. Позначимо цю розмірність як dd , що означає, що вхідний шар складається з dd нейронів, кожен із яких отримує значення однієї ознаки із багатовимірного простору вхідних спостережень.

Вхідний вектор, поданий у шар, формується в результаті попередньої обробки первинних даних, що включає етапи очищення, нормалізації та, за потреби, перетворення в часові вікна або агреговані статистики[44]. Таким чином, у шар надходить репрезентативна проекція поточної конфігурації об'єкта, вже позбавлена шумів та структурних артефактів. Нейрони цього шару не мають жодних нелінійних активацій, оскільки його завдання — лише передати інформацію до наступного шару без модифікацій, забезпечуючи цілісне перенесення значущих патернів, притаманних системі, що моніториться.

Інтерпретаційно, вхідний шар є перетворенням реального технічного сигналу на внутрішньо модельний вектор у форматі, який здатен бути оброблений через подальшу послідовність шарів, спрямованих на навчання стислої латентної репрезентації нормальної поведінки системи[45]. Його логічна завершеність виявляється у тому, що будь-яке перекручення на цьому етапі порушує адекватність відтворення, а відтак — знижує здатність автоенкодера до чіткого відмежування аномальних станів у фазі тестування.

Прихований шар 1 в архітектурі глибокого автоенкодера виконує роль початкового етапу зменшення розмірності та вилучення найсуттєвіших характеристик із вхідних даних. Його основне призначення полягає в тому, щоб трансформувати високорозмірний вхідний вектор у більш компактне подання, зберігаючи при цьому важливу інформацію, релевантну для подальшого навчання. Цей шар отримує сигнали безпосередньо з вхідного шару і передає їх далі до наступного шару в енкодерній частині[46]. На цьому рівні відбувається початкове виділення латентних ознак, які у сукупності знижують надмірність, властиву початковим спостереженням. Архітектурно це реалізується через набір нейронів меншої кількості, ніж у вхідному шарі, з метою реалізації ефекту компресії. У контексті задачі виявлення аномалій цей шар дозволяє усунути

другорядні особливості, зосереджуючи обробку на типових структурах у даних. Його конфігурація обирається експериментально з урахуванням складності вхідного простору та необхідного ступеня узагальнення.

Прихований шар 2 у структурі глибокого автоенкодера виконує роль проміжної трансформаційної ланки між першим рівнем стискання та латентним простором. Його функціональне призначення полягає у подальшій дистиляції ознак, що вже були попередньо трансформовані першим прихованим шаром. На цьому етапі здійснюється ще глибше виявлення внутрішніх кореляцій між параметрами вхідного сигналу, що дозволяє поступово зменшити розмірність представлення без втрати релевантної інформації, необхідної для подальшого відновлення. Структурно цей шар містить меншу кількість нейронів, ніж попередній, що сприяє вичлененню більш абстрактних характеристик об'єкта, які вже не мають прямої відповідності до початкових ознак, але містять узагальнене уявлення про закономірності вхідного простору. Завдяки цьому формується умовно компактне представлення даних, яке сприяє ізоляції нетипових патернів у подальшій фазі аналізу відхилень.

У структурі автоенкодера латентний простір виконує роль центральної прихованої репрезентації вхідних даних, що формується шляхом поступової компресії інформації на етапі проходження через послідовні шари енкодера. Цей проміжний простір, розташований між останнім шаром кодувальної частини та першим рівнем декодера, є результатом навчання моделі відокремлювати лише ті властивості сигналу, які мають вирішальне значення для його реконструкції[47]. Латентна репрезентація не відображає повної деталізації первинного сигналу, однак у ній зосереджено стислий опис характерних патернів або статистичних залежностей, які система змогла виявити як найбільш регулярні. Саме з цього простору здійснюється відновлення початкових вхідних характеристик, що дозволяє судити про наявність аномалії шляхом порівняння між реконструйованим і фактичним вектором. У контексті глибокої архітектури латентний простір візуально представлений як найвужче місце у схемі, що відображає зменшення обсягу переданої інформації, і підкреслює його значення

як інформаційного вузла, де концентрується сутність нормального функціонування системи.

Прихований шар 3 у структурі глибокого автоенкодера виконує роль початкового етапу декодування, тобто процесу зворотного відновлення даних із стисненої репрезентації, отриманої в латентному просторі. Його основне функціональне призначення полягає у поступовому розгортанні інформації, закодованої в компактному представленні, у напрямку до початкової розмірності вхідного сигналу[48]. Цей шар приймає на вхід вектор зі зменшеним числом ознак, який містить узагальнену інформацію про нормальні зразки, і починає процес його трансформації у багатовимірний простір, що наближається до вихідної структури даних. Архітектурно цей компонент повторює логіку енкодерної частини, але в оберненому порядку, відновлюючи поступово втрачений обсяг інформації через застосування відповідних нелінійних перетворень. У контексті виявлення аномалій ефективність прихованого шару 3 полягає в тому, що саме на цьому етапі виявляються труднощі реконструкції для зразків, які відхиляються від очікуваної внутрішньої структури — отже, слабкість відновлення стає свідченням потенційної несправності або аномального відхилення.

Прихований шар 4 у структурі глибокого автоенкодера виконує функцію передостаннього етапу реконструкції даних перед виведенням результату. Його роль полягає у поступовому розгортанні стислої інформації, що надійшла з латентного простору через попередні шари, до такого представлення, яке наближене до початкового вхідного вектору[49]. У цьому шарі мережа починає відновлювати складні залежності між ознаками, які були згорнуті на етапі кодування. Таким чином, прихований шар 4 є ключовим для відтворення проміжних структурних ознак сигналу, які є передумовою до точного відновлення вхідних даних. Він також слугує узгоджувальною ланкою між абстрактною інформацією латентного простору та деталізованим вихідним шаром. Його розмір, як правило, симетричний до відповідного шару на боці енкодера, що забезпечує структурну збалансованість всієї мережі.

Вихідний шар у структурі глибокого автоенкодера виконує функцію відновлення початкового векторного представлення вхідних даних на основі інформації, стисненої у латентному просторі[50]. Його основне призначення полягає у реконструкції вхідного сигналу після проходження через кілька рівнів зниження розмірності та подальшої декомпресії. В архітектурному плані цей шар має ту саму розмірність, що й вхідний, оскільки відновлений вектор повинен відтворювати усі ознаки, на основі яких здійснювалось первинне подання об'єкта. Він є завершальним елементом у послідовності обчислювального шляху, що починається з подання початкового вектора, проходить через глибокі внутрішні шари енкодера та декодера і завершується спробою відтворити інформаційний зміст на виході. У технічному сенсі, вихідний шар повертає реконструйований приклад, з яким у подальшому порівнюється реальний вхід, аби обчислити ступінь відхилення як індикатор аномальності.

2.3 Оптимізація параметрів моделі

В основі процедурного механізму налаштування глибоких автоенкодерів для задач виявлення несправностей у складних технічних системах лежить чітко сформульований критерій, який обумовлює спрямованість навчального процесу, забезпечуючи систематичне зменшення кількісного відхилення між вхідними спостереженнями та результатами реконструкції. Така цільова функція, що виконує роль функціонального ядра у всьому алгоритмі оптимізації, слугує індикатором успішності побудови внутрішнього представлення, здатного відтворити ключові ознаки номінального режиму без втрати релевантності інформації. Її семантика не обмежується лише формальним обчисленням різниці між векторами, а виходить за межі елементарного числення, охоплюючи також концептуальну мету розмежування аномальних патернів через неспроможність моделі здійснити адекватне відновлення таких входів.

На відміну від задач класифікації, де мета полягає у максимізації відповідності між передбаченням і відомою міткою, у випадку автоенкодерів відсутність міток зміщує акцент до аналізу реконструктивної похибки як

					ІАПЦ.467200.003 ПЗ	Арк.
						40
Змн.	Арк.	№ докум.	Підпис	Дата		

основного сигналу для оцінки продуктивності моделі[51]. Такий підхід не лише відповідає специфіці безнаглядного навчання, але й забезпечує інтерпретованість результатів у контексті аномалій, які постають як значущі винятки у спектрі відновних відхилень. Водночас цільова функція повинна володіти властивістю диференційовності, аби гарантувати коректну реалізацію методів чисельного мінімізації та забезпечити сталість градієнтного потоку у глибоких шарах мережі, що, своєю чергою, зумовлює стабільну збіжність параметрів у просторі вагових коефіцієнтів.

Тим самим, вибір конкретної форми цільової функції, такої як середньоквадратичне відхилення, обумовлений не лише її математичною зручністю, а й здатністю підкреслити віддаленість спостережень від їх прогнозованого еквіваленту, збільшуючи внесок великих відхилень у загальну помилку[54]. У випадку задач, де характеристики вхідних сигналів суттєво різняться за масштабами або типом розподілу, доцільною виявляється модифікація функції втрат шляхом введення вагових коефіцієнтів або трансформаційних операцій, які враховують внутрішню структуру даних. Таким чином, цільова функція у системі глибокого автоенкодера виступає не лише інструментом оптимізації, а й засобом концептуального формування здатності моделі до семантичного узагальнення поведінки технічного об'єкта в нормальному режимі з метою подальшого виявлення його атипових станів.

Параметризація архітектурної складності нейронної мережі, яка реалізує функціональність автоенкодера, постає як складне багатовимірне завдання, що охоплює визначення не лише кількості рівнів обробки інформації, а й розміру кожного з них з урахуванням специфіки вхідного представлення та очікуваного рівня латентної абстракції. Збільшення глибини передбачає впровадження додаткових послідовних трансформаційних блоків, кожен з яких потенційно здатен витягати дедалі більш узагальнені закономірності зі структурно неоднорідного простору ознак. Проте така експансія архітектури супроводжується істотним зростанням параметричної складності, що вимагає не лише розширення обчислювальних ресурсів, а й ускладнює пошук стабільного

розв'язку під час оптимізації, сприяючи формуванню переобтяжених моделей із потенційно низькою здатністю до узагальнення[52].

У свою чергу, вибір кількості нейронів на кожному рівні є визначальним чинником для конфігурації пропускну здатності й деталізації подання інформації у межах окремого шару. Перехід від вхідного простору до внутрішньої репрезентації потребує поступового зменшення розмірності з метою конденсації найбільш релевантних рис об'єкта спостереження. Однак надмірне стискання може призводити до втрати критично важливої інформації, що проявляється у різкому зниженні точності реконструкції. У протилежному випадку — при збереженні великої кількості одиниць активації на кожному шарі — модель виявляється схильною до простого копіювання вхідних векторів, уникаючи справжнього узагальнення[53]. Отже, знаходження оптимального співвідношення між глибиною та шириною кожного шару є завданням, яке вирішується емпірично з урахуванням апріорних знань про структуру даних, а також через серію чисельних експериментів із подальшим контролем ефективності на основі валідаційних сценаріїв.

Таким чином, параметризація структури автоенкодера не повинна трактуватись як механічне завдання вибору числових значень, а радше як цілісний процес архітектурного моделювання, що вимагає поєднання аналітичної інтуїції, статистичного аналізу й ітеративного наближення до такої конфігурації, яка забезпечить не лише ефективну реконструкцію нормального функціонування, а й контрастну реакцію у випадку спостереження структурно нетипових вхідних векторів.

У контексті побудови глибоких нейромережових архітектур, орієнтованих на реконструктивне відтворення багатовимірних структур вхідних даних, надзвичайно суттєвим чинником, що визначає якість внутрішнього перетворення та здатність мережі до адекватної репрезентації латентних залежностей, виступає тип обраної функції активації, яка реалізується на рівні кожного прихованого шару. Саме через механізм активацій здійснюється введення обчислювальної нелінійності, що забезпечує мережі змогу моделювати складні кореляційні

					ІАЛЦ.467200.003 ПЗ	Арк.
						42
Змн.	Арк.	№ докум.	Підпис	Дата		

патерни, недоступні для лінійних перетворень. Таким чином, вибір конкретної активаційної функції фактично означає обмеження класу функцій, які здатна апроксимувати модель, що, у свою чергу, прямо впливає на здатність розпізнавати структурні відхилення у вхідному сигналі та, як наслідок, виявляти аномальні конфігурації у даних, отриманих зі складного технічного середовища.

Необхідність ретельного підходу до вибору функціональної нелінійності зумовлюється різними властивостями кожної з потенційно застосовуваних активацій. Зокрема, широке застосування знаходить модифікована лінійна одиниця, яка дозволяє уникнути проблеми затухаючого градієнта, одночасно забезпечуючи ефективну обробку позитивно визначених сигналів. Проте, за певних умов, такий підхід призводить до деградації частини нейронів, що повністю втрачають здатність до оновлення вагових коефіцієнтів. У відповідь на ці виклики розроблено низку альтернативних функцій, що зберігають активність нейронних елементів у розширеному інтервалі вхідних значень або адаптуються до статистичних властивостей вибірки в процесі навчання. Деякі з них володіють гладкими похідними, що позитивно позначається на стабільності оптимізаційного процесу та дозволяє уникати різких змін у градієнтному ландшафті.

В умовах обробки нормалізованих та потенційно симетричних сигналів, актуальним є також використання активацій, що допускають двобічне відображення з нульовою серединою, що сприяє рівномірнішому розподілу інформаційного навантаження серед вузлів. Такий підхід дозволяє зменшити зміщення градієнтного спуску і пришвидшити збіжність оптимізаційної процедури. Водночас, при побудові симетричних автоенкодерів, коли структура енкодера дзеркально відображається у декодері, може виникати потреба у застосуванні узгоджених функціональних форм, що забезпечують одноманітність відгуку системи на широкому спектрі збурень. У цьому контексті функція активації стає не лише засобом нелінійного збагачення, але й компонентом, що бере участь у формуванні латентного простору як такого, визначаючи його топологічні властивості та здатність до виявлення відхилень,

які не спостерігалися в процесі навчання.

Таким чином, активаційна функція не повинна розглядатися як технічний елемент з фіксованими параметрами, а натомість як адаптивний інструмент, що забезпечує обчислювальну пластичність і визначає якість семантичного відображення вхідних характеристик у внутрішньому представленні. Її вибір вимагає глибокого розуміння взаємозв'язку між статистичними особливостями даних, архітектурною конфігурацією автоенкодера та поставленою задачею виявлення аномалій на рівні низькорівневих змін у динаміці технологічних процесів.

Процес встановлення відповідної розмірності латентного простору в архітектурі глибокого автоенкодера передбачає не лише евристичне визначення кількості нейронів у центральному шарі, а й обґрунтоване балансування між здатністю моделі до стискання інформації та її відтворення без спотворень структури вхідного сигналу. Прийняття рішення щодо обсягу представлення у вузькому рівні відображення повинно базуватися на попередньому аналізі внутрішньої кореляції ознак, ступеня надлишковості вихідного векторного простору та вимог до збереження релевантних характеристик процесу. У разі занадто агресивного зменшення розмірності латентного коду відбувається втрата критичних інформаційних патернів, що веде до деградації якості реконструкції, особливо у випадках складної динаміки сигналів або присутності неявних взаємозв'язків між атрибутами. Натомість надлишкова ємність стислого простору зумовлює перенесення паразитних шумових компонентів із навчальної вибірки, спричиняючи зниження контрастності між відхиленнями та типовими спостереженнями.

Оптимізаційна процедура, яка виконується у рамках цього етапу, потребує реалізації багаторазового навчання моделей із різними параметрами латентного шару та подальшого емпіричного порівняння отриманих результатів за метриками реконструктивної точності й чутливості до аномальних спотворень. Такий підхід дозволяє емпірично виділити область, у якій рівень стиснення забезпечує достатню фільтрацію несуттєвих коливань без шкоди для

					ІАЛЦ.467200.003 ПЗ	Арк.
						44
Змн.	Арк.	№ докум.	Підпис	Дата		

відображення основної структури даних. У процесі аналізу варто також враховувати топологічну цілісність простору стислого представлення, перевіряючи, чи зберігається безперервність та відстань між точками у зменшеному вимірі у порівнянні з вихідними характеристиками. При цьому застосовуються візуалізаційні методики з використанням метрик кластеризації, які дозволяють виявити спотворення або зміщення латентного розподілу у напрямках, що не відповідають фактичному стану об'єкта моніторингу.

Результатом цього етапу є фіксація кількості вузлів у внутрішньому представленні, яка забезпечує найвищу чутливість автоенкодера до слабовиражених змін технічного стану при збереженні низького рівня хибнопозитивних реконструкцій. Отримане значення параметра латентного простору в подальшому застосовується як сталий архітектурний елемент під час фінального тренування моделі на повному обсязі нормальних даних для гарантування її стійкості та узагальненості в умовах експлуатації.

Вибір алгоритму оптимізації та відповідних гіперпараметрів здійснювався на основі попереднього аналізу динаміки збіжності моделі та властивостей ландшафту функції втрат. Враховуючи складну топологію простору параметрів глибокої нейронної мережі, обрано метод адаптивної оптимізації Adam, що забезпечує стійку та передбачувану мінімізацію при наявності градієнтів, близьких до нуля або різко змінних у напрямку. Значення початкової швидкості навчання встановлено рівним $\eta=0,001$, оскільки саме цей показник демонстрував найменше коливання функціоналу на валідаційній множині без спотворень структури латентного простору. У структурі самого оптимізатора використано параметри $\beta_1=0,9$, $\beta_2=0,999$, що є типовими для систем із високою чутливістю до зміни ваг у глибоких шарах і достатньою інерцією для згладжування флуктуацій градієнтів.

Кількість епох навчання було зафіксовано на рівні 150, при цьому реалізовано механізм фіксації найкращого варіанту вагової конфігурації за значенням втрат на валідаційній підмножині. Розмір мініпакета (batch size) обрано рівним 64 для досягнення балансу між точністю наближення градієнта на

					ІАЛЦ.467200.003 ПЗ	Арк.
						45
Змн.	Арк.	№ докум.	Підпис	Дата		

кожному кроці оптимізації та ефективністю використання обчислювальних ресурсів. Додатково введено обмеження на норму градієнта для уникнення вибухового зростання параметрів, що могло б призвести до розриву навчального процесу. Усі гіперпараметри були підібрані експериментальним шляхом на основі результатів попередніх серій тренувань та фіксації поведінки функції втрат на кожному кроці. Зафіксовані параметри не піддавались подальшій зміні впродовж основного циклу навчання, що забезпечило стабільність відтворюваних результатів та дозволило уникнути додаткових джерел стохастичних коливань у результатах валідації.

У процесі тренування глибокого автоенкодера для виявлення аномалій у промислових системах було реалізовано механізми регуляризації, які структурно інтегруються у функціональну архітектуру моделі як обмеження, спрямовані на запобігання надмірному пристосуванню до варіативності навчального набору. Було застосовано L2-нормування ваг, що дозволяє стабілізувати поведінку параметрів у просторі рішень шляхом введення штрафної компоненти до функції втрат. Такий підхід забезпечує стримування збільшення модульних значень вагових коефіцієнтів, знижуючи ймовірність того, що модель буде надмірно чутливою до дрібних флуктуацій у вхідних векторах. У контексті виявлення технічних несправностей, де відсутність чітко мічених аномалій посилює ризик генералізаційного колапсу, цей метод довів свою ефективність у збереженні латентної репрезентації з високою узагальнювальною здатністю.

Додатково у структуру декодера було інтегровано шари Dropout з імовірністю занулення нейронів, підбраною емпірично на основі попередніх спроб навчання. Цей методика передбачає стохастичне виключення частини одиниць під час кожного етапу прямого поширення сигналу, що симулює неповноту інформаційного представлення та змушує модель адаптуватися до умов непередбачуваної відсутності ознак. Завдяки цьому вдалося зменшити залежність від надлишково специфічних шляхів проходження сигналу та сприяти формуванню узагальненого підходу до реконструкції вхідного простору. Впровадження регуляризаційних механізмів сприяло також

					ІАЛЦ.467200.003 ПЗ	Арк.
						46
Змн.	Арк.	№ докум.	Підпис	Дата		

вирівнюванню розподілу відновлювальних втрат, що дозволило уникнути локальної чутливості до випадкових коливань параметрів без потреби у зовнішньому додатковому фільтруванні. Таким чином, структурна оптимізація з використанням регуляризації виявилася необхідною умовою досягнення високого рівня стійкості моделі під час аналізу складних технологічних сигналів.

В рамках оптимізації архітектури глибокого автоенкодера, що застосовується для виявлення структурних аномалій у багатовимірних наборах технічних показників, валідація моделі на даних зі штучно варійованим рівнем шумового навантаження виступає не факультативною, а системоутворювальною ланкою, яка забезпечує перевірку функціональної придатності мережевої конфігурації до роботи в умовах реального інформаційного середовища. Створення вибірки із контрольованими параметрами викривлення здійснюється через модуляцію вхідного сигналу — з використанням додавання гаусівських або імпульсних збурень у заздалегідь обраних інтервалах ознак із дотриманням рівномірності варіації. Це дозволяє реконструювати умови потенційних сенсорних відмов, деградацій каналів зв'язку або паразитного зміщення калібрування вимірювального обладнання, які є типовими чинниками зниження достовірності вхідної інформації у промислових об'єктах.

Під час перевірки моделі на сформованому наборі здійснюється вимірювання реакції мережі у вигляді зміни величини функціоналу відновлення, при цьому вектор реконструйованих значень підлягає зіставленню з оригінальним, ще до внесення деформацій. У разі адекватної конфігурації глибини, ширини шарів та обраної стратегії регуляризації, рівень чутливості автоенкодера до малих збурень має залишатись стабільним у межах прийнятного порогу, що демонструє здатність моделі фіксувати лише ті зразки, які справді порушують латентну структуру даних, властиву нормальним режимам функціонування. Результати аналізу фіксуються у вигляді кривих деградації точності реконструкції залежно від інтенсивності шуму, що дозволяє побудувати емпіричну залежність між рівнем впливу викривлень та внутрішньою стійкістю архітектури. У підсумку, на підставі отриманих даних здійснюється коригування

					ІАЛЦ.467200.003 ПЗ	Арк.
						47
Змн.	Арк.	№ докум.	Підпис	Дата		

гіперпараметрів із подальшим повторним навчанням моделі, що приводить до виведення її у зону оптимального функціонального балансу між здатністю до генералізації та збереженням точності при обробці реальних, злегка деформованих даних.

Раннє припинення тренування реалізується як інструмент стримування поглиблення адаптації моделі до випадкових коливань навчального розподілу, що виникають у процесі поступового зменшення функціональної похибки на навчальних даних. Методика передбачає ретельне відстеження поведінки обраної валідаційної метрики, значення якої розраховується після завершення кожного етапу повного проходження даних через архітектуру мережі, тобто після завершення епохи. Зафіксоване припинення покращення показника на перевірочній множині протягом фіксованого числа послідовних ітерацій трактується як сигнал до завершення оптимізації вагових коефіцієнтів. У цьому випадку модель повертається до стану, зафіксованого на момент останнього мінімального значення функції контролю, що гарантує використання конфігурації з найвищим ступенем узагальнення. При цьому безальтернативно застосовується механізм збереження проміжного стану нейронної мережі після кожної епохи, за умови коли значення функції валідації покращується.

Важливо зазначити, що ключовим чинником ефективності даного підходу є адекватність обраної валідаційної метрики, яка повинна бути узгоджена зі специфікою задачі реконструкції. Для систем виявлення аномалій на основі автоенкодера доцільно використовувати функціонал помилки відновлення на перевірочному наборі, оскільки саме він найбільш чутливо відображає здатність мережі зберігати структурну відповідність виходу до еталонного вхідного вектора. Фіксоване значення параметра *patience*, що визначає кількість епох, протягом яких допускається відсутність покращення, підбирається емпірично з урахуванням складності мережі та розміру навчального набору. Реалізація раннього припинення не лише знижує ризик деградації обчислювальної точності при тестуванні на нових зразках, але й значно скорочує загальний час навчання, що є особливо важливим при роботі з глибокими структурами та великими

					ІАЛЦ.467200.003 ПЗ	Арк.
						48
Змн.	Арк.	№ докум.	Підпис	Дата		

обсягами сенсорних даних.

2.4 Джерела даних та методи їх обробки

У техногенних умовах функціонування виробничих об'єктів інформаційні потоки, що становлять основу діагностичного аналізу, формуються внаслідок безперервного зчитування параметрів технологічних процесів за допомогою фізичних сенсорів, вбудованих у критичні вузли обладнання. Джерела цих даних репрезентують широкий спектр фізичних величин, що включають, зокрема, показники тиску, температури, вібраційних характеристик, швидкості обертання, струмових навантажень та логічних станів виконавчих механізмів. Інформація надходить із систем автоматичного регулювання, електромеханічних контролерів, блоків реєстрації телеметрії та елементів системи SCADA, які перебувають у постійній взаємодії з об'єктом керування. Передача даних здійснюється за протоколами промислової автоматизації, включаючи MODBUS, OPC UA, PROFIBUS та інші, що передбачають стандартизовану структуру повідомлень і дозволяють реалізовувати моніторинг у режимі реального часу.

Особливістю такого середовища є відсутність гарантійної рівномірності частоти дискретизації між різними каналами вимірювання, що обумовлює потребу у синхронізації інформаційних потоків перед проведенням будь-яких аналітичних дій. Більшість сенсорів генерують дані з високою щільністю у часі, що забезпечує виявлення швидкоплинних динамічних процесів, проте водночас створює суттєве навантаження на підсистеми обробки та зберігання. Формат первинних записів зазвичай не має ознак попередньої обробки, містить службову інформацію, а також інколи зазнає впливу електромагнітних перешкод, що знижує достовірність окремих фрагментів. Слід окремо зазначити, що значна частина сигналів, які надходять з аналогових каналів, потребує оцифрування з фіксованою точністю, де похибки квантованого подання мають тенденцію накопичення при подальшій багатошаровій обробці.

Таким чином, сукупність джерел, що забезпечує формування вхідного масиву для моделей реконструктивного типу, не є однорідною ні за типом

					ІАЛЦ.467200.003 ПЗ	Арк.
						49
Змн.	Арк.	№ докум.	Підпис	Дата		

переданої інформації, ні за параметрами її генерації. Це передбачає необхідність формування гнучкої, адаптивної стратегії попередньої підготовки, здатної перетворити динамічний потік неструктурованих вимірювань у стабільну та інформативну множину об'єктів для подальшого аналізу на предмет наявності латентних відхилень у роботі обладнання.

Попередній етап обробки інформаційних послідовностей, отриманих із промислових сенсорних систем, передбачає обов'язкове усунення неструктурованих відхилень, що не відображають реального фізичного стану контрольованого об'єкта. Ініціація цієї процедури обумовлена тим, що в умовах виробничого середовища сигнали часто містять неконтрольовані збурення, спричинені електричними імпульсами, механічними вібраціями, періодичними коливаннями напруги, контактними замиканнями або помилками дискретизації. Ці артефакти зазвичай проявляються у вигляді імпульсних сплесків, різких розривів, хибних плато або випадкових піків, які при прямому поданні на модель викривлюють статистичну структуру вхідного простору та дестабілізують процес формування репрезентативних ознак. Усунення подібних дефектів виконується шляхом застосування згладжувальних фільтраційних методів, адаптованих до характеру вхідного сигналу, без зміщення центральної тенденції та зі збереженням низькочастотного інформативного вмісту. Серед ефективних підходів використовуються фільтри типу ковзного середнього, які забезпечують симетричне згортання у заданому вікні, медіанні перетворення з фокусуванням на усунення одиничних викидів, а також вейвлет-методи з багатоетапною декомпозицією сигналу в частотній області для відсікання високочастотних шумів при збереженні локальних особливостей. Застосування таких фільтрацій не лише дозволяє знизити ймовірність помилкового маркування коректних спостережень як аномальних, а й підвищує стабільність навчального процесу автоенкодера, запобігаючи адаптації до нехарактерних для системи імпульсів. Результатом цього етапу є стабілізований потік векторів, вільний від техногенних артефактів, який зберігає цілісну топологію фізичних параметрів і є придатним для подальшої нормалізації, сегментування та побудови навчальних

					ІАЛЦ.467200.003 ПЗ	Арк.
						50
Змн.	Арк.	№ докум.	Підпис	Дата		

множин.

Процес вирівнювання часових рядів та інтерполяції відсутніх значень становить необхідну складову підготовки вхідного набору даних для забезпечення цілісності інформаційної структури, на якій функціонує модель реконструктивного типу. У межах технічних систем моніторингу, інтегрованих у промислові комплекси, втрата окремих спостережень трактується не як виняток, а як закономірність, обумовлена техногенними, програмними чи електромагнітними збуреннями. У результаті спостерігається розрив у послідовності, що призводить до порушення когерентності часових залежностей, на яких ґрунтується логіка обробки. Для усунення таких викривлень впроваджується процедура реконструкції відсутніх компонентів, яка реалізується без припущення про їх нульовість або усереднення, натомість передбачається побудова значень на основі локальних контекстів, що безпосередньо прилягають до втрачених позицій.

Інтерполяційний підхід базується на фіксованому припущенні про неперервність поведінки параметра в межах локального інтервалу, де обчислення значення втраченого спостереження відбувається з урахуванням щільності та послідовності сусідніх точок. Найбільш придатними до реалізації в умовах обмеженого обсягу є лінійні методи з побудовою сегменту за двома граничними значеннями, хоча в окремих випадках доцільно впроваджувати інтерполяцію за кубічними сплайнами, що дозволяє зберегти гладкість другого порядку та відтворити плавну динаміку сигналу. Незалежно від обраного способу, застосування процедури інтерполяції супроводжується постійною перевіркою фізичної правдоподібності відновлених значень, для уникнення штучного внесення статистичних аномалій у модельну репрезентацію. Крім того, визначення допустимої щільності втрат, за якої ще доцільно відновлювати сигнал, виконується на підставі аналізу гістограми інтервалів відсутності, із фіксацією порогового значення тривалості розриву.

У разі, коли значення не відновлюються, а ігноруються, вхідна множина втрачає структуру, що унеможлиблює формування повноцінного векторного

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		51

подання, яке необхідне для подачі в автоенкодер. Тому саме процедура інтерполяції виявляється критичною передумовою цілісного представлення часової послідовності, її безперервності та внутрішньої логіки, що, у свою чергу, прямо визначає здатність глибокої моделі до реконструкції, а відтак — до розмежування між нормальними і відхиленими режимами функціонування складної технічної системи.

У процесі побудови надійної системи виявлення аномальних режимів функціонування технічних об'єктів ключовим кроком перед подачею вхідних даних до архітектури глибокого автоенкодера є приведення числових характеристик усіх наявних ознак до єдиного масштабу вимірювання. Такий підхід дозволяє усунути вплив дисбалансу, що виникає унаслідок різної природи величин, які фіксуються різними сенсорами в межах однієї промислової одиниці, зокрема температурними перетворювачами, струмовими модулями, давачами тиску чи вібраційними акселерометрами. Будь-яка з таких ознак у своєму первинному вигляді характеризується різнорідним числовим діапазоном, що зумовлює неоднакову вагу впливу на механізми обчислення втрат у процесі тренування нейронної мережі. У разі відсутності уніфікації більші значення домінують у метриках реконструкції, тоді як менш виражені показники залишаються майже не врахованими в процесі оновлення вагових коефіцієнтів.

З цією метою запроваджується попереднє числове перетворення кожного векторного компонента за допомогою процедур нормалізації. Конкретний вибір методу залежить від статистичних характеристик кожної ознаки. У випадку симетричного розподілу з обмеженим числовим розмахом застосовується стандартизація з приведенням до нульового математичного сподівання та одиничного стандартного відхилення, що дозволяє забезпечити симетрію відносно центру координат. Для показників, у яких відсутня симетричність або присутні викиди, що зсувають центр мас, ефективнішим є масштабування на основі мінімального та максимального значення, що зводить величину кожної ознаки до інтервалу $[0, 1]$ без порушення відносної структури варіацій. Після цього вектор ознак трансформується у числове представлення, яке рівновагово

					ІАЛЦ.467200.003 ПЗ	Арк.
						52
Змн.	Арк.	№ докум.	Підпис	Дата		

подається на вхідну частину нейромережевої структури без переваги жодного з компонентів.

Результатом такої трансформації є вирівняна просторово-масштабна модель вхідного сигналу, що забезпечує однакову чутливість до змін кожної координати у вхідному просторі. Це критично важливо для задач виявлення відхилень, оскільки навіть незначне відхилення в ознаці, що має малий абсолютний масштаб, після нормалізації може виявитися інформативним з точки зору моделі. Таким чином, уніфікація розмірностей і коректна нормалізація дозволяють уникнути викривлень у процесі навчання та гарантують справедливе представлення усіх наявних джерел інформації, що у підсумку покращує якість виявлення аномалій за допомогою автоенкодерних структур.

Формування навчального середовища для моделі глибокого автоенкодера потребує чітко регламентованої процедури розподілу на множини з різним функціональним призначенням. Навчальна вибірка створюється шляхом ретельного відбору фрагментів даних, що відображають виключно штатні режими функціонування цільового об'єкта без присутності будь-яких відхилень або порушень. Такий підхід забезпечує побудову латентного простору, чутливого до прихованих закономірностей лише нормативного характеру, що є критично важливим для задачі виявлення структурної невідповідності. Під час формування валідаційної множини відбувається збереження статистичної схожості з навчальною, однак її склад використовується не для зміни вагових коефіцієнтів, а винятково для оцінки здатності моделі до узагальнення. Це дозволяє своєчасно фіксувати момент деградації ефективності та здійснити припинення тренування згідно з визначеною стратегією ранньої зупинки. Тестова підмножина, натомість, охоплює ширший спектр варіативності, включаючи як очікувані відхилення, так і невідомі раніше патерни, що дозволяє оцінити реакцію автоенкодера на відмінності від апріорно відомих сценаріїв.

Процедура поділу виконується з дотриманням певних пропорцій, які регламентуються з урахуванням обсягу початкового масиву. Частка прикладів, призначених для навчання, як правило, є домінантною, що обґрунтовується

					ІАЛЦ.467200.003 ПЗ	Арк.
						53
Змн.	Арк.	№ докум.	Підпис	Дата		

необхідністю надання моделі достатнього обсягу даних для коректного формування внутрішньої репрезентації. Розмежування може здійснюватися у випадковий спосіб із забезпеченням рівномірного покриття всього діапазону спостережень, однак у задачах часової природи доцільним визнається хронологічний підхід, який дозволяє уникнути інформаційного перетікання між множинами. Під час реалізації подібного підходу ранні сегменти застосовуються для навчання, проміжні — для валідації, а пізніші — для тестування, що імітує реальну експлуатаційну ситуацію, де модель аналізує нові, раніше не бачені дані. Такий методологічний підхід гарантує, що результати оцінки моделі є репрезентативними, достовірними та піддаються інтерпретації в межах завдань промислової діагностики.

Формування вхідних векторів за принципом ковзного вікна становить обов'язковий етап структуризації даних для подання у глибоку нейронну модель, орієнтовану на обробку часових рядів у межах задачі автоматизованого виявлення відхилень у промисловому середовищі. На основі первинного неперервного потоку спостережень, кожне з яких є багатовимірним відображенням поточного стану технологічного об'єкта, здійснюється фрагментація сигналу на послідовності фіксованої довжини, які представляють контекстно насичені інтервали функціонування системи. Для кожної часової позиції будується векторний блок, що містить значення обраної кількості попередніх спостережень, розміщених у строгому часовому порядку. Розмір вікна встановлюється експериментально, виходячи із властивостей домену — з урахуванням внутрішньої інерційності об'єкта, швидкості динаміки змін та часових кореляційних структур. Зсув ковзного вікна відбувається дискретно на одиницю часу, що забезпечує перекриття між сусідніми фрагментами та водночас дозволяє не втрачати змістовну цілісність між подіями, розміщеними на межах фрагментації. Таким чином досягається підвищення чутливості моделі до транзитивних змін режиму роботи обладнання, що неможливо при обробці ізольованих вимірів. Побудовані вектори розглядаються як цілісні патерни поведінки системи за визначений часовий інтервал, а отже створюється

формально пов'язана вхідна множина, яка зберігає внутрішню логіку розвитку процесу. Це дозволяє моделі не лише відтворювати миттєвий стан системи, а й враховувати послідовні відхилення, що призводять до накопичення аномального ефекту. У такий спосіб забезпечується просторово-часова прив'язка кожного фрагмента до реального технічного контексту, що й становить основу для подальшого навчання автоенкодера.

2.5 Критерії оцінювання ефективності алгоритму

Аналіз розподілу помилки реконструкції становить ключову процедуру верифікації адекватності функціонування автоенкодера в умовах непрямого контролю за точністю результатів. У контексті задачі виявлення техногенних відхилень основне припущення полягає в тому, що мережа, навчена виключно на репрезентативних зразках нормального режиму, повинна із високою точністю відтворювати вхідні дані, які відповідають знайомим їй патернам, натомість будь-яка суттєва структурна аномалія призводить до зростання відновлювальної похибки. Побудова щільності розподілу відстаней між початковим вектором і його реконструйованим аналогом дозволяє сформулювати емпіричну основу для подальшого виокремлення порогових значень. Для цього використовується багатовимірне зведення сукупності втрат у форму одновимірного функціоналу, що обчислюється на валідаційному наборі, сформованому виключно з очікувано нормативних сигналів. Одержаний розподіл може набувати форми гаусового, експоненціального чи іншого асиметричного профілю, залежно від складності мережевої структури, ступеня стиску латентного простору та динамічних властивостей даних.

Визначення статистичних характеристик цього розподілу — таких як середнє, дисперсія, квантільні межі та довірчі інтервали — становить підґрунтя для побудови критерію прийняття рішення про наявність аномалії. Порогове значення визначається не як довільно обране, а як аналітично виведене на основі припущення про допустимий рівень помилкових позитивних спрацьовувань. Вибір методики встановлення порогу базується на апіорному знанні про

					ІАЛЦ.467200.003 ПЗ	Арк.
						55
Змн.	Арк.	№ докум.	Підпис	Дата		

характер розподілу похибок та інженерних обмеженнях щодо максимально припустимого ризику. Особливої уваги потребують хвостові значення розподілу, оскільки саме вони містять потенційно аномальні випадки, які ще не були включені до навчального набору, але можуть проявитися в реальному середовищі експлуатації. Візуалізація щільності розподілу та його кумулятивної форми надає додаткові підстави для якісного аналізу поведінки моделі та є підґрунтям для встановлення детермінованих меж між зонами номінального функціонування та простором потенційних відхилень. У такий спосіб розподіл помилки реконструкції виступає не лише джерелом кількісного оцінювання, але й фундаментом для побудови інтерпретованого механізму прийняття рішень у системах моніторингу промислових об'єктів.

Чутливість моделі до аномальних зразків у межах задачі виявлення відхилень трактується як здатність алгоритмічної конструкції забезпечити повноту виявлення порушень у функціонуванні технічної системи шляхом фіксації максимальної кількості дійсних випадків відхилення. Цей критерій набуває критичного значення у контексті застосування в промисловому середовищі, де пропущене спрацювання системи контролю здатне призвести до прогресуючого зниження технологічної стійкості, деградації технічного об'єкта або незворотних наслідків у виробничому циклі. У формалізованому описі чутливість визначається як відношення кількості коректно виявлених аномальних фрагментів до загальної кількості істинно відхилених зразків, зафіксованих у контрольному наборі. Значення показника, що тяжіє до одиниці, свідчить про високий ступінь реактивності моделі на навіть незначні порушення внутрішньої структури ознак, яка не може бути реконструйована автоенкодером з прийнятним рівнем точності.

У процесі моделювання даний показник аналізується не ізольовано, а у взаємозв'язку з іншими характеристиками поведінки алгоритму, зокрема зі специфічністю, адже гіпертрофована чутливість за відсутності відповідної селективності може створити умови для перенавантаження системи хибними спрацюваннями. Втім, з урахуванням вимог до надійності виявлення

					ІАЛЦ.467200.003 ПЗ	Арк.
						56
Змн.	Арк.	№ докум.	Підпис	Дата		

потенційно небезпечних станів, саме чутливість є пріоритетною метрикою на етапі первинного налаштування порогових меж і добору архітектурних параметрів. У реальному експериментальному середовищі оптимізація даного критерію реалізується шляхом підбору конфігурацій латентного простору та адаптації стратегії раннього припинення навчання, що дозволяє уникнути як надмірної компресії, так і втрати інформативних аномальних закономірностей. Таким чином, максимізація чутливості стає стрижневим напрямом оцінки здатності глибокої мережі до виконання задачі інтелектуального контролю за відхиленнями в умовах невизначеності та варіативності вхідних сигналів.

Показник специфічності, що використовується як критерій ефективності в задачах виявлення аномалій, репрезентує кількісну міру здатності алгоритмічної моделі коректно ідентифікувати зразки, які належать до множини нормальних станів, не відносячи їх до класу відхилень. У контексті застосування глибокого автоенкодера для обробки даних з промислових сенсорів цей параметр набуває особливого значення, оскільки хибне спрацювання у відповідь на коректний сигнал призводить до втрати довіри до системи контролю, перевантаження технічного персоналу хибними повідомленнями та потенційної втрати продуктивності через ініціацію непотрібних процедур безпеки. Під час аналітичної оцінки специфічності виконується зіставлення кількості правильно розпізнаних нормальних зразків до загального обсягу прикладів, що не містять аномальних ознак, причому вхідна інформація подається на модель у знеособленому вигляді, без надання контексту або ознак приналежності до певного технічного стану.

Поведінка автоенкодера оцінюється через порівняння реконструйованих векторів з оригінальними, а рішення про належність до класу нормальних формується на основі порогового значення похибки відновлення. Надмірно низький поріг призводить до втрати специфічності, тоді як надто високий — до пропуску істотних відхилень, тому визначення критичного значення повинне ґрунтуватися на емпіричних дослідженнях або апріорному аналізі розподілу помилок реконструкції на еталонному наборі. Досягнення високої специфічності

					ІАЛЦ.467200.003 ПЗ	Арк.
						57
Змн.	Арк.	№ докум.	Підпис	Дата		

вимагає від моделі не просто відтворення структури вхідних сигналів, а побудови латентного простору, в якому закономірності номінального функціонування відображаються компактно, а будь-яке відхилення від цієї структури автоматично інтерпретується як невідповідність. У такий спосіб забезпечується функціональна стійкість системи до випадкових флуктуацій, збереження цілісності інтерпретації та обґрунтованість прийнятих рішень у межах автоматизованого технічного моніторингу.

Використання F1-міри як основного критерію балансування оцінки ефективності алгоритму виявлення відхилень ґрунтується на прагненні одночасно врахувати здатність моделі виявляти рідкісні нетипові випадки та її стриманість у генеруванні хибних попереджень. Такий показник є результатом узгодження двох окремих характеристик — точності та повноти, кожна з яких поодиночі не надає вичерпного уявлення про повноцінну продуктивність класифікатора в умовах дисбалансу класів, що є типовим для задач промислової діагностики. З метою забезпечення непрямой оцінки взаємодії між істинно позитивними спрацьовуваннями та помилковими класифікаціями нормальних зразків, обчислюється гармонійне середнє вказаних величин, що знижує вплив крайніх значень та компенсує переважання однієї з компонент. Унаслідок цього досягається узагальнена метрика, яка симетрично реагує на зміну обох параметрів і дозволяє здійснювати комплексну валідацію роботи моделі на критично важливих етапах. Практичне застосування такого підходу передбачає постійне відстеження F1-значення на валідаційній вибірці з метою коригування архітектурних параметрів та оптимізації критеріїв прийняття рішення, що, у свою чергу, сприяє формуванню надійного інструменту контролю технічного стану в умовах непередбачуваних відхилень. У цьому контексті F1-міра не розглядається як просто обчислювана величина, а трактується як невід’ємна частина методології оцінювання достовірності поведінки нейронної мережі в контексті складного технологічного середовища.

Показник, що характеризується площею під ROC-кривою, репрезентує собою числову оцінку здатності алгоритму до відокремлення об’єктів різних

					ІАЛЦ.467200.003 ПЗ	Арк.
						58
Змн.	Арк.	№ докум.	Підпис	Дата		

класів, зокрема в контексті виявлення аномальних спостережень серед загальної маси нормальних прикладів. В основі методу лежить побудова функціональної залежності між часткою правильно класифікованих позитивних випадків та відсотком хибнопозитивних спрацьовувань при послідовному варіюванні порогу прийняття рішення. В межах машинного навчання ROC-крива інтерпретується як континуум діагностичних рішень, що дозволяє не фіксувати одне конкретне значення порогового параметра, а оцінити поведінку моделі у широкому спектрі граничних умов. Обчислення площі під кривою (AUC) відображає інтегральну якість прийняття рішень — чим ближче значення AUC до одиничної величини, тим ефективніше здійснюється ранжування вхідних прикладів за ступенем їх віддаленості від умовно нормального шаблону.

При оцінюванні глибоких автоенкодерів у задачах безнаглядного виявлення відхилень, де модель не має прямого доступу до явних міток класів у процесі навчання, розрахунок AUC-ROC проводиться на окремо сформованій тестовій множині, що містить заздалегідь визначені аномальні приклади. Для кожного з них визначається величина відновлювальної похибки, яка надалі інтерпретується як оцінка ризику належності до аномального стану. Ці оцінки сортуються, і на їх основі формується крива залежності між істинно позитивними й хибнопозитивними реакціями на змінному порозі. Методика дозволяє уніфіковано представити якість моделі в єдиному числовому значенні, яке не залежить від конкретної конфігурації метрики втрат, масштабування ознак чи способу нормалізації вхідного сигналу. Саме тому застосування AUC-ROC у контексті систем технічного моніторингу вважається методологічно обґрунтованим способом оцінки здатності моделі до структурного розмежування режимів функціонування без впливу суб'єктивних параметрів.

Обчислювальна ефективність алгоритму виявлення аномалій на основі глибокого автоенкодера розглядається як невід'ємний аспект його функціональної придатності для інтеграції в середовища з жорсткими часовими обмеженнями на обробку сенсорної інформації. У ході практичного впровадження проводиться вимірювання кількох характеристик, що разом

визначають здатність моделі реагувати на зміни технічного стану системи з достатньою оперативністю. До таких характеристик належать тривалість прямого проходження одного вхідного прикладу через нейронну архітектуру, загальна кількість параметрів, що потребують збереження у пам'яті обчислювального пристрою, стабільність градієнтного потоку під час навчання, а також швидкість збіжності оптимізаційного процесу у межах фіксованої кількості епох.

Для цілей оцінювання використовуються заміри в системному середовищі з наперед заданою апаратною конфігурацією, яка репрезентує типову платформу, на якій здійснюватиметься експлуатація. Зокрема, визначається середній час інференції при поданні фрагментованих входів у режимі квазіреального часу, а також аналізується використання центрального та графічного процесорів під навантаженням упродовж серії вхідних викликів. У разі перевищення критичного порогу за часом реакції, архітектура автоенкодера зазнає модифікацій шляхом зменшення глибини або розрядності внутрішніх шарів, без погіршення здатності до генералізації. Крім того, розглядається вплив розміру латентного простору на оперативність виконання, оскільки надмірне ускладнення внутрішнього представлення призводить до суттєвого зростання обчислювальних витрат.

Після завершення етапу навчання фіксується кількість епох, необхідна для досягнення стабільного значення валідаційної похибки, що дозволяє судити про поведінку алгоритму під час збіжності. Визначення такого роду метрик забезпечує надійне обґрунтування вибору моделі не лише за якісними показниками розпізнавання, але й з огляду на її придатність до впровадження у системи автоматизованого технічного нагляду, де надмірна затримка сигналу від моделі є неприйнятною з точки зору виробничої безпеки та ефективного реагування. Таким чином, обчислювальна ефективність розглядається як інтегральна характеристика, що визначає придатність алгоритму до реального часу в умовах обмежених ресурсів.

ВИСНОВКИ ДО РОЗДІЛУ

У другому розділі дипломної роботи було здійснено поетапне обґрунтування методики побудови системи виявлення несправностей із застосуванням глибоких автоенкодерів, що дозволило сформулювати цілісну концепцію автоматизованої діагностики для промислових середовищ. Розпочато з формалізації задачі як проблеми детекції аномалій у багатовимірних часових рядах, що відображають технічний стан промислових об'єктів. Обґрунтовано вибір архітектури глибокого автоенкодера з урахуванням складності даних і необхідності збереження структурних зв'язків між спостереженнями у часовому просторі. Встановлено доцільність використання ковзного вікна з частковим перекриттям для збереження послідовності ознак та посилення чутливості моделі до мікродинаміки змін у роботі обладнання. Показано вплив кількості прихованих шарів і нейронів на здатність мережі реконструювати нормальні зразки з низькою похибкою, тоді як надмірне спрощення архітектури призводить до втрати суттєвих характеристик і зниження точності. Також досліджено методи попередньої обробки даних, включаючи нормалізацію, сегментацію та виключення шумів, що є критично важливими для коректного навчання моделі. Визначено підхід до оптимізації гіперпараметрів, зокрема функцій втрат, розміру латентного простору та режиму регуляризації, що забезпечує баланс між узагальненням і точністю. Особливу увагу приділено розробці метрик оцінювання ефективності: реконструкційна похибка, середньоквадратичне відхилення та порогові значення, які визначають допустимі межі нормальної поведінки. У підсумку, запропонована методика дозволяє здійснювати адаптивне, ресурсоефективне та високоточне виявлення технічних відхилень у промислових умовах, що закладає основу для наступного етапу – реалізації програмної системи на її базі.

					ІАПЦ.467200.003 ПЗ	Арк.
						61
Змн.	Арк.	№ докум.	Підпис	Дата		

РОЗДІЛ 3 РЕАЛІЗАЦІЯ ПРОГРАМНОЇ СИСТЕМИ ДЛЯ ВИЯВЛЕННЯ НЕСПРАВНОСТЕЙ

3.1 Архітектура програмного рішення

Архітектура програмного рішення представлено на рисунку 3.1.




Рисунок 3.1 – Архітектура програмного рішення

Модуль збору даних виконує ключову роль у забезпеченні первинного надходження сировинної інформації, що є необхідною умовою для подальшого аналізу стану промислового комплексу. Він інтегрується з різноманітними джерелами даних, зокрема сенсорами, системами SCADA та іншими пристроями контролю, що дозволяє здійснювати збір інформації у режимі реального часу з

високою точністю та достовірністю. Принципи функціонування модуля базуються на використанні оптимізованих мережевих протоколів та алгоритмів обробки, що забезпечують безперебійний потік даних навіть у разі зростання складності та обсягів інформації. Завдяки гнучкій архітектурі, модуль легко адаптується до різних технологічних середовищ і дозволяє інтегрувати дані з численних датчиків, що використовують різноманітні стандарти передачі даних.

Ефективність даного підсистемного рішення полягає у здатності проводити попередню обробку отриманих сигналів, що включає попередню нормалізацію, фільтрацію та агрегацію, з метою забезпечення подальшої точності аналізу на наступних етапах обробки. Реалізація функціоналу збору даних здійснюється за допомогою високопродуктивних апаратних засобів і програмних рішень, що гарантують мінімальні затримки при передачі інформації та забезпечують безперебійність роботи всієї системи. Системна інтеграція модуля з іншими компонентами архітектури сприяє забезпеченню централізованого зберігання, аналізу та обробки даних, що дозволяє оперативно виявляти відхилення від нормального стану об'єкта контролю та своєчасно ініціювати процеси реагування на можливі несправності.

Модуль попередньої обробки виконує критично важливу роль у забезпеченні високої якості вхідних даних для подальшої роботи системи, оскільки саме на цьому етапі здійснюється базова обробка сировинних сигналів, отриманих із численних сенсорних пристроїв та SCADA-систем, що дозволяє мінімізувати вплив шумів, артефактів та інших перешкод. Обробка даних проводиться за допомогою математичних та статистичних методів, спрямованих на згладжування сигналів, корекцію систематичних похибок та вилучення аномальних значень, що можуть виникнути внаслідок зовнішніх впливів або збоїв в апаратній частині. Ретельна нормалізація вхідних даних забезпечує їх однорідність, що є запорукою успішної роботи наступних алгоритмів машинного навчання, зокрема глибокого автоенкодера, який зосереджується на виявленні відхилень від встановленого нормального стану об'єкта контролю.

У процесі попередньої обробки даних велика увага приділяється

					ІАЛЦ.467200.003 ПЗ	Арк.
						63
Змн.	Арк.	№ докум.	Підпис	Дата		

синхронізації інформації, що надходить із різних джерел, що дозволяє забезпечити коректне відображення часових послідовностей та встановити надійні взаємозв'язки між різними параметрами технологічного процесу. Завдяки застосуванню адаптивних алгоритмів фільтрації та інтерполяції, модуль не лише відсейовує небажані шумові компоненти, але й дозволяє запобігти втраті важливої інформації, що може бути суттєвою для аналізу несправностей. Крім того, інтеграція з базою даних дозволяє зберігати як початкові сировинні дані, так і результати проміжної обробки, що сприяє подальшому вдосконаленню алгоритмів та оптимізації процесів управління технологічними комплексами. Таким чином, модуль попередньої обробки забезпечує фундамент для створення стабільного та достовірного набору даних, необхідного для точного аналізу та виявлення потенційних аномалій у складних промислових системах.

Модуль вилучення ознак являє собою фундаментальний компонент системи, що відповідає за трансформацію сировинних даних у більш компактну, але інформаційно насичену форму, придатну для подальшої обробки в рамках аналізу аномалій. У цьому модулі здійснюється комплексний аналіз вхідних сигналів з метою виділення критичних параметрів, що характеризують нормальний режим роботи промислового комплексу, а також виявлення латентних закономірностей, які можуть свідчити про потенційні відхилення. Процес вилучення ознак включає застосування методів нормалізації, стандартизації та зниження розмірності, що дозволяють усунути вплив шуму та зменшити надлишковість інформації, забезпечуючи при цьому збереження суттєвих індикаторів поведінки системи. Використання алгоритмів машинного навчання, зокрема методів аналізу головних компонентів та кореляційного аналізу, дозволяє адаптивно підійти до обробки різнорідних даних, що надходять з численних сенсорних пристроїв, та забезпечити точне відображення критичних ознак. Отримані в результаті вилучення ознаки слугують як основа для навчання глибокого автоенкодера, який моделює нормальний функціональний стан об'єкта, і стають ключовим елементом для подальшого виявлення аномальних патернів, що можуть свідчити про несправності у роботі промислового

комплексу.

Модуль глибокого автоенкодера є фундаментальним компонентом інтелектуальної системи виявлення несправностей у промислових комплексах, реалізованим на базі глибоких нейронних мереж, що дозволяють здійснювати ефективне вилучення представницьких ознак із багатовимірних даних. У даній архітектурі реалізовано класичну схему автоенкодера, що складається з енкодерної частини, яка виконує нелінійне стиснення вхідних сигналів до компактного латентного простору, та декодерної частини, що здійснює відновлення оригінальних даних із цього представлення. Завдяки такому підходу забезпечується не лише зменшення розмірності даних, а й виділення ключових характеристик нормального стану функціонування об'єкта, що дозволяє на основі реконструкційної помилки визначати відхилення від норми, що сигналізують про потенційні несправності. Процес навчання модуля здійснюється за допомогою алгоритмів стохастичного градієнтного спуску з адаптивною оптимізацією параметрів, що забезпечує мінімізацію функції втрат, спрямованої на точне відтворення вхідних даних, і дозволяє моделі адаптуватися до змін у розподілі даних за умов високої динаміки промислового середовища.

Обчислювальна ефективність модуля підтримується за рахунок використання сучасних апаратних засобів паралельної обробки даних та оптимізованих бібліотек для роботи з глибокими нейронними мережами, що сприяє інтеграції модулю у режимі реального часу. Під час роботи застосовуються методи регуляризації, які зменшують ризик перенавчання та сприяють загальній узагальнюючій здатності моделі, що особливо важливо при аналізі великого обсягу високорозмірних даних з різних сенсорних джерел. Завдяки цьому модуль глибокого автоенкодера виступає як ключовий аналітичний компонент, що забезпечує оперативну і точну ідентифікацію аномальних патернів, що можуть вказувати на критичні відхилення у функціонуванні промислового комплексу, що в свою чергу дозволяє приймати своєчасні управлінські рішення щодо запобігання або усунення несправностей.

Модуль виявлення аномалій є невід'ємною частиною загальної архітектури

					ІАЛЦ.467200.003 ПЗ	Арк.
						65
Змн.	Арк.	№ докум.	Підпис	Дата		

системи, що здійснює аналіз даних, отриманих від модуля глибокого автоенкодера, з метою виявлення відхилень від еталонного нормального функціонування промислового комплексу. Функціонування цього компоненту ґрунтується на аналізі реконструкційної помилки, яка являє собою різницю між вихідними даними та їхньою реконструкцією, отриманою в результаті навчання моделі на репрезентативних даних нормальної роботи. Завдяки застосуванню комплексних статистичних методів і алгоритмів машинного навчання, модуль здатний ідентифікувати нехарактерні відхилення, що можуть свідчити про потенційні несправності, при цьому враховуючи як систематичні закономірності, так і випадкові флуктуації в даних.

У рамках реалізації даного компонента здійснюється адаптивна оцінка порогових значень, що дозволяє оперативно реагувати на зміну умов експлуатації об'єкта та мінімізувати кількість хибних спрацьовувань. Механізми аналізу, що використовуються в модулі, враховують специфічні особливості технологічних процесів, що виявляються через динамічні зміни в структурі даних, а також вплив зовнішніх факторів, що можуть впливати на процес виробництва. Інтеграція модулю виявлення аномалій у загальну систему забезпечує можливість проведення аналізу в режимі реального часу, що є критично важливим для забезпечення оперативного реагування на виникнення несправностей. У результаті застосування гібридних методів, що поєднують традиційні підходи статистичного аналізу із сучасними алгоритмами глибокого навчання, досягається висока точність і ефективність моніторингу, що сприяє своєчасному виявленню аномалій та оптимізації подальших рішень щодо управління технологічними процесами.

Модуль генерації повідомлень являє собою інтегральну складову архітектури системи виявлення несправностей, що реалізує процес інтерпретації результатів аналізу, отриманих від модуля виявлення аномалій, з метою перетворення структурованої інформації про відхилення від нормального режиму роботи об'єкта в оперативні сповіщення. Науковий підхід до реалізації цього компоненту базується на застосуванні алгоритмічних моделей

					ІАЛЦ.467200.003 ПЗ	Арк.
						66
Змн.	Арк.	№ докум.	Підпис	Дата		

класифікації, що дозволяють аналізувати значення реконструкційної помилки, отриманої в результаті роботи глибокого автоенкодера, та визначати критичність виявлених аномалій. Система здійснює синхронізований обмін даними між аналітичними модулями, використовуючи стандартизовані протоколи, що забезпечує сумісність з існуючими SCADA-системами та іншими елементами інфраструктури управління, таким чином, забезпечуючи своєчасну обробку інформації та передачу повідомлень для подальшого реагування.

Функціональна логіка модуля ґрунтується на застосуванні адаптивних алгоритмів, що дозволяють враховувати динаміку зміни параметрів об'єкта дослідження, а також на оптимізації порогових значень, за якими відбувається класифікація подій як критичних чи попереджувальних. В ході розробки реалізовано механізми перевірки достовірності отриманих даних, що дозволяє знизити ризик хибного спрацювання та підвищити точність прогнозування аварійних ситуацій. Генеровані повідомлення містять детальну інформацію про тип та масштаб виявленої аномалії, а також рекомендації щодо подальших дій, що базуються на аналізі історичних даних та моделюванні потенційних сценаріїв розвитку подій. Цей підхід забезпечує комплексне управління процесами моніторингу та прогнозування, сприяє своєчасному виявленню критичних відхилень і дозволяє забезпечити безперервну та безпечну експлуатацію промислових комплексів.

Модуль інтерфейсу користувача є інтегральною частиною загальної архітектури системи, що забезпечує взаємодію між кінцевим оператором та аналітичними підсистемами, зосередженими на виявленні несправностей у промислових комплексах. Він реалізований із застосуванням сучасних технологій візуалізації даних, що дозволяє надавати комплексну інформацію про поточний стан об'єкта моніторингу у режимі реального часу. Завдяки інтуїтивно зрозумілому графічному відображенню результатів аналізу, що отримуються з глибокого автоенкодера та модулів вилучення ознак, система забезпечує високу точність діагностики аномалій, що дозволяє оперативно реагувати на відхилення від нормального режиму експлуатації. Архітектурне рішення передбачає

					ІАЛЦ.467200.003 ПЗ	Арк.
						67
Змн.	Арк.	№ докум.	Підпис	Дата		

розмежування функціональних компонентів інтерфейсу, які відповідають за відображення аналітичних панелей, графіків, індикаторів та повідомлень про несправності, що інтегровані з централізованою базою даних для збереження та обробки історичних даних. Такий підхід дозволяє забезпечити масштабованість та адаптивність системи, що відповідає високим вимогам до надійності та оперативності у промислових умовах, а також сприяє підвищенню якості прийняття рішень шляхом надання детальної інформації про технічний стан об'єкта контролю. Реалізація модуля інтерфейсу користувача здійснюється з урахуванням принципів модульності, що дозволяє зменшити час відгуку системи та спростити інтеграцію додаткових функціональних можливостей у майбутньому.

Модуль бази даних виступає ключовим елементом інтегрованої системи виявлення несправностей, забезпечуючи збереження, обробку та аналіз як сировинних даних, так і результатів проміжних етапів обчислювального процесу. Його функціональна спрямованість передбачає централізоване зберігання інформації, що надходить із численних сенсорних пристроїв та систем SCADA, з подальшим забезпеченням її доступності для навчання моделей глибокого автоенкодера, аналізу реконструкційної помилки та виявлення аномалій. Інтеграція даного модуля з іншими компонентами системи здійснюється шляхом використання єдиних протоколів взаємодії, що гарантують узгодженість даних на всіх етапах обробки, забезпечуючи при цьому високий рівень відновлюваності інформації навіть у разі збою апаратного чи програмного забезпечення.

Архітектурне рішення модуля бази даних формується з урахуванням сучасних вимог до масштабованості, високої продуктивності та безперервності обслуговування в режимі реального часу, що дозволяє ефективно управляти великими обсягами даних, отриманих із промислових комплексів. Реалізація цього модуля базується на концепції розподіленої обробки інформації, що забезпечує паралельне виконання транзакцій та оптимізує процес індексації, пошуку та агрегації даних. Таке рішення сприяє як оперативному доступу до

					ІАЛЦ.467200.003 ПЗ	Арк.
						68
Змн.	Арк.	№ докум.	Підпис	Дата		

даних для аналізу поточного стану об'єкта, так і збереженню історичних записів, необхідних для ретроспективного аналізу та прогнозування майбутніх аномалій. Застосування передових методів шифрування та механізмів контролю доступу гарантує захист конфіденційної інформації, що є надзвичайно важливим аспектом у системах, де достовірність та безпека даних мають першорядне значення.

Розробка модуля бази даних здійснюється з урахуванням принципів модульності та сумісності з різноманітними форматами даних, що дозволяє інтегрувати структуровані та неструктуровані дані в єдине сховище. Забезпечення цілісності даних, їх резервне копіювання та можливість швидкого відновлення у разі виникнення аварійних ситуацій є невід'ємними характеристиками цього підходу. Таким чином, модуль бази даних стає не лише сховищем інформації, а й потужним аналітичним інструментом, що сприяє оптимізації роботи системи виявлення несправностей через забезпечення точного та оперативного моніторингу, а також підтримки процесів машинного навчання, спрямованих на своєчасне прогнозування та запобігання аварійних ситуацій у промислових комплексах.

3.2 Інтеграція автоенкодера у систему моніторингу

Інтеграція автоенкодера в систему моніторингу представлена на рисунку 3.2.




Рисунок 3.2 – Інтеграція автоенкодера в систему моніторингу

Діаграма послідовності демонструє інтеграцію глибокого автоенкодера у систему моніторингу промислового процесу, що забезпечує послідовну обробку даних з метою виявлення аномалій та оперативного реагування на відхилення від нормального функціонування об'єкта. Початкове джерело, представлене SCADA або аналогічною системою, надсилає сировинні дані до модуля попередньої обробки, де здійснюється нормалізація та очищення інформації для усунення шумів і потенційних спотворень, що можуть впливати на точність подальшого аналізу. Результати попередньої обробки направляються до модуля виділення ознак, який забезпечує вибір релевантних характеристик, що слугують основою для подальшої реконструкції даних у глибокому автоенкодері. Цей модуль виконує процес реконструкції, одночасно обчислюючи реконструкційну помилку, яка виступає критерієм для виявлення відхилень від норми, що є центральним завданням системи моніторингу.

Обчислені значення реконструкційної помилки надходять до модуля аналізу аномалій, де проводиться порівняння отриманих показників з встановленими пороговими значеннями для визначення ступеня невідповідності поточного стану системи очікуваним нормальним параметрам. У разі перевищення допустимого порогу модуль аналізу аномалій генерує сповіщення, яке передається назад до системи SCADA для оперативного реагування на потенційні несправності. Паралельно з цим відбувається систематичний запис усіх даних, що проходять через етапи попередньої обробки, вилучення ознак, реконструкції та аналізу, у централізовану базу даних, що забезпечує збереження як поточних, так і історичних записів для подальшого ретроспективного аналізу та оптимізації процесів моніторингу. Така інтеграційна схема забезпечує злагоджену взаємодію компонентів системи, підвищуючи ефективність виявлення аномалій та забезпечуючи своєчасну реакцію на зміни в режимах роботи промислових комплексів, що є критично важливим для підтримання безперебійного та безпечного функціонування об'єкта.

					ІАЛЦ.467200.003 ПЗ	Арк.
						70
Змн.	Арк.	№ докум.	Підпис	Дата		

3.3 Технології обробки даних у реальному часі

Технології обробки даних у реальному часі становлять основу сучасних інформаційних систем, що забезпечують негайний аналіз безперервно надходячої інформації та прийняття оперативних рішень на її базі. Сучасні підходи до обробки даних у режимі реального часу базуються на принципах розподілених обчислень, паралелізму та ін-меморі обробки, що дозволяє суттєво зменшити затримки між надходженням даних та їх аналізом. Завдяки цьому здійснюється негайна інтерпретація інформації, що надходить з різних джерел, таких як сенсорні мережі, пристрої SCADA чи інші системи збору даних, що є критично важливим для моніторингу та управління складними технологічними процесами. Використання платформ, орієнтованих на потокову обробку даних, таких як Apache Kafka, Apache Flink, Spark Streaming та інших, забезпечує високий рівень масштабованості та відмовостійкості систем, що дозволяє ефективно працювати з великими обсягами даних навіть у випадку збоїв окремих компонентів. Інтеграція таких технологій із сучасними протоколами обміну інформацією сприяє створенню єдиної архітектури, у якій дані надходять, обробляються та аналізуються в режимі реального часу, що забезпечує оперативну адаптацію системи до змін умов експлуатації та сприяє точнішому прогнозуванню майбутніх тенденцій. Використання ін-меморі обчислень дозволяє зменшити час реакції системи, що є важливим фактором для підтримання високої якості управління критичними процесами у сфері автоматизації, фінансових ринків, телекомунікацій та інших галузей, де оперативна обробка даних є ключовим елементом безперебійної роботи. У результаті, технології обробки даних у реальному часі забезпечують синхронізацію процесів збору, аналізу та збереження інформації, що створює умови для прийняття стратегічних рішень на основі комплексного аналізу даних, а також для оперативного реагування на динамічні зміни в середовищі експлуатації технологічних систем.

3.4 Візуалізація та інтерфейс користувача

Для реалізації системи було обрано датасет, що представлений на рисунку 3.3.

Equipment Anomaly Data

	temperature	pressure	vibration	humidity	equipment	location	faulty
1	58.18018003931781	25.02927765103301	0.6065162172245139	45.694907104076414	Turbine	Atlanta	0.0
2	75.74071220894001	22.95401759548667	2.3380947537510077	41.867406792614915	Compressor	Chicago	0.0
3	71.35859424081657	27.27683031893662	1.3891983049086754	58.95440890948324	Turbine	San Francisco	0.0
4	71.61698526704753	32.24292130393475	1.7706896863176191	40.56513821185597	Pump	Atlanta	0.0
5	66.50683203881802	45.19747079743589	0.34539798929557564	43.253794756433095	Pump	New York	0.0
6	49.5109594501023	76.42672868018283	4.809297752752174	20.269692247772895	Compressor	New York	1.0
7	66.90350286011939	45.530758700156156	1.5483453514434098	64.8049215266908	Compressor	Houston	0.0
8	148.92336873207364	22.214121367591716	0.10981888071321333	39.944953294698905	Turbine	San Francisco	1.0
9	50.403298761202244	45.39989897809707	2.231717827130497	43.06766663283053	Pump	Houston	0.0
10	63.88614752611372	33.80291244598566	1.1392796250848973	41.795515332279166	Compressor	Atlanta	0.0
11	53.07043185804615	44.105202647740946	2.0716521371650067	47.45874176809897	Compressor	New York	0.0
12	141.26030984408388	54.23905839448483	2.7256907331768128	86.39046563060697	Pump	Atlanta	1.0
13	68.49162288433304	45.43867810655463	1.1950486465253989	59.989678353166205	Compressor	Houston	0.0
14	84.71170327493608	44.08496468393181	1.3594029939012853	47.56097051399158	Turbine	San Francisco	0.0
15	83.73658545162958	53.44757268774192	1.6430079038173124	25.5250485765034	Turbine	New York	0.0
16	81.66370545669253	21.75488511863934	1.2024155004624104	47.006730267041156	Compressor	Atlanta	0.0

Рисунок 3.3 – Структура датасету

Цей набір даних містить змодельовані дані, що імітують моніторинг у реальному часі роботи різного промислового обладнання, зокрема турбін, компресорів і насосів [54]. Кожен рядок у наборі відповідає окремому спостереженню, яке фіксує ключові параметри, такі як температура, тиск, вібрація та вологість. Також у наборі міститься інформація про тип обладнання, місце його розташування та про те, чи класифікується обладнання як несправне.

Датасет містить такі стовпці:

- temperature: показник температури на момент спостереження (в градусах Цельсія).
- pressure: показник тиску на момент спостереження (у барах).
- vibration: рівень вібрації (у нормалізованих одиницях).

- humidity: відсоткове значення вологості, зафіксоване в місці розташування обладнання.
- equipment: тип промислового обладнання, яке підлягає моніторингу (наприклад, турбіна, компресор, насос).
- location: географічне розташування обладнання (назва міста).
- faulty: бінарний індикатор (0 = справне, 1 = несправне), що вказує на технічний стан обладнання – чи воно працює нормально, чи потребує обслуговування.

Використаний у дослідженні набір даних створено фахівцем D. N. Kumars у процесі моделювання сценаріїв функціонування промислового обладнання з метою формалізації задачі виявлення технічних несправностей на основі телеметричних вимірювань. В основі цього набору лежить концепція генерації синтетичних часових рядів, які імітують поведінку агрегатів у нормальному стані, на етапах деградації та у фазі критичних відмов. Передбачено реєстрацію ряду фізичних параметрів, характерних для об'єктів промислової автоматики, зокрема температури, тиску, вібрації, вологості, швидкості обертання та ін., які є ключовими індикаторами технічного стану систем.

Дані були змодельовані на основі експертних правил, що враховують типові характеристики змін параметрів у часі при нормальній та аномальній роботі технічних систем. Таким чином, кожен запис у наборі є симуляцією телеметричної сесії з окремого пристрою, що працює в умовах контрольованого навантаження. Стан кожного пристрою еволюціонує з часом, а відповідні зміни у вимірюваних параметрах дозволяють імітувати прояви деградації, вібраційних аномалій або порушень гідравлічних та теплових режимів.

Ініціатор створення цього набору мав на меті забезпечити відкритий, структурований ресурс для тестування алгоритмів технічної діагностики, прогнозування стану обладнання, побудови моделей цифрових двійників та апробації методів машинного навчання, зокрема в задачах виявлення аномалій. Створений набір охоплює кілька типів обладнання (насоси, компресори, турбіни), що забезпечує його адаптивність до широкого спектру

експериментальних сценаріїв. Попри симульовану природу, дані мають ознаки реалістичності та зберігають статистичні властивості, характерні для систем фактичного моніторингу.

Датасет, який містить вимірювання параметрів роботи обладнання, є суттєвим інструментом для дослідження та розробки систем виявлення несправностей у промислових комплексах із застосуванням алгоритмів глибокого навчання. У контексті роботи, спрямованої на розробку моделей прогнозування аномалій із використанням автоенкодерів, даний набір даних дозволяє здійснити аналіз як нормального режиму функціонування обладнання, так і відхилень, що можуть свідчити про потенційні несправності. Завдяки репрезентативності та структурованості даних, що охоплюють широкий спектр параметрів роботи, датасет дозволяє проводити комплексну попередню обробку, включаючи очищення, нормалізацію та вилучення релевантних ознак, що є критично важливими кроками для подальшої реконструкції даних глибоким автоенкодером. Такий підхід сприяє точному визначенню порогових значень реконструкційної помилки, що дозволяє ефективно відокремлювати нормальні режими роботи від аномальних станів.

Використання цього датасету у роботі сприяє розробці інтегрованої системи моніторингу, здатної у режимі реального часу здійснювати аналіз потоків даних, отриманих із сенсорних пристроїв та SCADA-систем, та оперативно реагувати на потенційні відхилення від норми. Ретельний аналіз статистичних властивостей даних та визначення їх кореляційних залежностей дозволяє створити надійну базу для тренування моделі, що здатна прогнозувати несправності на основі виявлених аномалій. Таким чином, датасет `equipment_anomaly_data.csv` у контексті розробки систем виявлення несправностей виступає як основа для створення ефективною та масштабованою технології моніторингу, що забезпечує високу точність та оперативність у прийнятті управлінських рішень щодо підтримання безпеки та стабільності роботи промислових комплексів.

Інтерфейс застосунку представлено на рисунку 3.4.

					ІАЛЦ.467200.003 ПЗ	Арк.
						74
Змн.	Арк.	№ докум.	Підпис	Дата		




Рисунок 3.4 – Інтерфейс застосунку

Інтерфейс застосунку розроблено з урахуванням сучасних вимог до інтерактивності та зручності користування, що дозволяє ефективно вирішувати задачу виявлення аномалій у промислових комплексах. Він реалізований із використанням стандартної бібліотеки Tkinter, що забезпечує легкість адаптації, сумісність із різними операційними системами та можливість налаштування сучасного дизайну за допомогою стилізації кольорів та шрифтів, властивих програмам майбутнього покоління. Головна особливість інтерфейсу полягає у комплексній інтеграції процесу навчання моделі з моментальним відображенням її динаміки у вигляді інтерактивних графіків та прогрес-бару, що дозволяє користувачу в режимі реального часу спостерігати за зниженням функції втрат на тренувальному та валідаційному наборах, таким чином забезпечуючи прозорість алгоритмів та можливість своєчасної діагностики процесу навчання.

Застосунок вирішує проблему виявлення аномалій шляхом інтегрованого підходу, який об'єднує навчання моделі автоенкодера з можливістю тестування її ефективності на даних, що надаються користувачем. Після завершення процесу тренування, який супроводжується візуальним індикатором та графічною побудовою динаміки втрат, активується функціонал тестування, який дозволяє завантажити CSV-файл із даними. Завантажені дані піддаються попередній обробці та масштабуванню за допомогою того ж алгоритму, що і при навчанні,

що забезпечує сумісність і коректність обчислень. Результати прогнозування моделі, отримані за рахунок обчислення реконструкційної помилки, відображаються як у текстовій формі, так і у вигляді графіка розподілу помилок, що дає змогу наочно оцінити якість відтворення нормальних шаблонів та виявити потенційні аномалії.

Таким чином, інтерфейс застосунку виступає як інтегроване рішення, яке не лише демонструє процес навчання моделі, але й забезпечує зручний механізм тестування та візуального аналізу результатів, що сприяє оперативному виявленню відхилень у роботі обладнання.

					<i>ІАЛЦ.467200.003 ПЗ</i>	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		76

ВИСНОВКИ ДО РОЗДІЛУ

У третьому розділі було реалізовано архітектурну й програмну інфраструктуру системи виявлення несправностей, що дало змогу інтегрувати методи глибокого навчання з механізмами збору, обробки та візуалізації даних у режимі реального часу. Була детально спроектована модульна архітектура системи, яка передбачає взаємодію між компонентами збору даних, глибокого автоенкодера, блоками аналізу реконструкційної похибки та виведення результатів, з урахуванням вимог до швидкодії, масштабованості та стійкості до втрат зв'язку з сенсорами. Продемонстровано, що реалізація системи в середовищі Python з використанням сумісних бібліотек дозволяє забезпечити гнучкість розгортання у промислових умовах, зокрема в середовищах SCADA. Інтеграція автоенкодера здійснювалася таким чином, щоб модель могла працювати в потоковому режимі з мінімальною затримкою, що підтверджено результатами вимірювання часу інференції та стабільності реконструкції у квазіреальному часі. Водночас було розроблено базовий графічний інтерфейс користувача, що дозволяє відображати рівень технічної аномальності у вхідних потоках даних, забезпечуючи інтуїтивну інтерпретацію результатів для інженерного персоналу. Таким чином, у розділі досягнуто практичного втілення теоретичної моделі з другого розділу та продемонстровано її придатність до застосування в умовах реального виробничого середовища.

					ІАЛЦ.467200.003 ПЗ	Арк.
						77
Змн.	Арк.	№ докум.	Підпис	Дата		

РОЗДІЛ 4 ЕКСПЕРИМЕНТАЛЬНА ОЦІНКА ЕФЕКТИВНОСТІ СИСТЕМИ

4.1 Набір тестових сценаріїв для перевірки моделі

Для перевірки системи було створено тестові дані, що представлені на рисунку 4.1.

	timestamp	sensor1	sensor2	sensor3	sensor4	sensor5
1	2025-04-07 12:00:00	0.5	0.7	0.6	0.8	0.75
2	2025-04-07 12:01:00	0.52	0.69	0.61	0.82	0.77
3	2025-04-07 12:02:00	0.49	0.71	0.59	0.78	0.76
4	2025-04-07 12:03:00	1.2	0.7	0.6	0.8	0.75
5	2025-04-07 12:04:00	0.5	0.7	0.6	0.8	0.75
6	2025-04-07 12:05:00	0.5	1.5	0.6	0.8	0.75
7	2025-04-07 12:06:00	0.5	0.7	3.0	0.8	0.75
8	2025-04-07 12:07:00	0.5	0.7	0.6	0.1	0.75
9	2025-04-07 12:08:00	0.5	0.7	0.6	0.8	2.0
10	2025-04-07 12:09:00	0.5	0.7	0.6	0.8	0.75
11	2025-04-07 12:10:00	0.3	0.7	0.6	0.8	0.75
12	2025-04-07 12:11:00	0.5	0.2	0.6	0.8	0.75
13	2025-04-07 12:12:00	0.5	0.7	0.6	1.2	0.75
14	2025-04-07 12:13:00	0.5		0.6	0.8	0.75

Рисунок 4.1 – Тестові дані для тестування системи

CSV-файл представляє собою ретельно сконструйований набір тестових даних, що відображають роботу системи сенсорного моніторингу у промислових умовах. Файл містить часові мітки та п'ять числових показників, які відповідають вимірюванням з окремих сенсорів (sensor1, sensor2, sensor3, sensor4, sensor5). Дані зібрані протягом невеликого періоду часу, що дозволяє

дослідити як нормальну роботу обладнання, так і ситуації, що свідчать про потенційні аномалії та несправності. Кожен рядок файлу містить часову мітку, яка вказує на точний момент збирання даних, а наступні стовпці містять числові значення, що характеризують параметри роботи сенсорів. Такий підхід дозволяє аналізувати динаміку змін параметрів у часі та виявляти різкі відхилення від нормальних значень.

На початкових рядках даного набору даних спостерігаються показники, що знаходяться в досить стабільних межах. Наприклад, у першому, другому та третьому рядках значення `sensor1` коливаються навколо 0.50, `sensor2` – близько 0.70, `sensor3` – приблизно 0.60, `sensor4` – близько 0.80, а `sensor5` – близько 0.75. Таке розподілення значень свідчить про нормальний режим роботи обладнання, коли всі параметри знаходяться в очікуваних межах, що характерно для стабільного процесу. Цей базовий режим роботи є критично важливим, оскільки він слугує базовим еталоном для подальшого порівняння з відхиленнями, які можуть сигналізувати про несправності.

Далі, у четвертому рядку, спостерігається суттєве відхилення для першого сенсора (`sensor1`), де його значення зростає до 1.20. Таке різке зростання може бути пов'язане з несподіваними коливаннями або збоєм у роботі конкретного елемента обладнання. Аналіз такого роду відхилень дозволяє моделі виявляти потенційні аномалії, що є критично важливим для попередження аварійних ситуацій. Після цього рядка повернення до нормальних значень у п'ятому рядку демонструє, що збої можуть бути короткочасними, проте їх своєчасне виявлення дозволяє виявити і локалізувати проблему.

У шостому рядку спостерігається ще одне відхилення – цього разу аномальне значення стосується другого сенсора (`sensor2`), де показник зростає до 1.50. Це свідчить про те, що не тільки один сенсор може сигналізувати про потенційні несправності, а й різні сенсори в комплексі можуть відображати різні аспекти роботи системи. Зміни у `sensor2` можуть вказувати на коливання температури, напруги або іншого важливого параметру, що впливає на загальну роботу обладнання.

Сьомий рядок демонструє ще одне суттєве відхилення, цього разу для третього сенсора (sensor3), де його значення піднімається до 3.00, що значно перевищує нормальний діапазон. Такий викид може бути пов'язаний з раптовою аномалією, спричиненою, наприклад, несправністю сенсора або зовнішнім впливом, що змушує вимірювання виходити за межі звичних значень. Аналіз таких даних є ключовим для виявлення критичних змін, адже велика реконструкційна помилка при відновленні нормального стану може бути індикатором серйозної несправності.

У восьмому рядку, хоча більшість показників зберігаються на рівні нормальних значень, sensor4 має значення 0.10, що значно нижче очікуваного рівня. Це може свідчити про зниження ефективності роботи конкретного компонента або про його несправність. Зниження значення може бути пов'язане з механічними чи електричними проблемами, тому таке відхилення варто враховувати при подальшому аналізі роботи системи.

У дев'ятому рядку спостерігається аномальне значення для sensor5, де показник зростає до 2.00, що також є значущим відхиленням від базового рівня 0.75. Таке підвищення може свідчити про перегрів, підвищену навантаженість або інший критичний стан, що потребує оперативного реагування. Виявлення таких аномалій є важливим для забезпечення безпеки обладнання та своєчасного попередження аварійних ситуацій.

Далі, у десятому рядку даних, показники повертаються до більш стабільних значень, що відповідають нормальному режиму роботи. Однак, у наступних рядках спостерігаються поступові відхилення. Наприклад, у одинадцятому рядку sensor1 має значення 0.50, проте sensor2 падає до 0.20. Таке різке зниження може вказувати на нестабільність роботи системи або на наявність зовнішніх впливів, які можуть впливати на показники сенсора. Зниження може бути зумовлено як технічними несправностями, так і екстремальними умовами експлуатації.

У дванадцятому рядку даних sensor4 демонструє значення 1.20, що знову є відхиленням від нормального діапазону, що може бути ознакою перевантаження

					ІАЛЦ.467200.003 ПЗ	Арк.
						80
Змн.	Арк.	№ докум.	Підпис	Дата		

або аномалій в роботі системи охолодження обладнання. Відзначення таких показників дозволяє виявити потенційні проблеми ще на ранніх етапах, що є особливо важливим для системи моніторингу, орієнтованої на своєчасне реагування.

Найцікавішим залишається тринадцятий рядок, у якому sensor2 має значення NaN, тобто відсутність даних. Пропущені значення можуть виникати через збої у передачі інформації, несправності обладнання або помилки у збиранні даних. Виявлення таких випадків є важливим для тестування стійкості алгоритмів попередньої обробки, адже необхідно або заповнити пропуски за допомогою методів інтерполяції, або адаптувати модель для роботи з неповними даними. У сучасних системах моніторингу важливо враховувати такі сценарії, оскільки вони часто виникають у реальних умовах експлуатації, і правильне їх оброблення дозволяє знизити ризики хибного сигналізування про несправності.

Загалом, цей набір тестових даних має велике значення для комплексної оцінки роботи системи виявлення аномалій. Він не лише імітує нормальний режим експлуатації, коли всі сенсори показують стабільні та очікувані значення, але й демонструє різноманітні сценарії відхилень – як різкі підвищення, так і зниження окремих параметрів, а також випадки пропущених даних. Такий підхід дозволяє випробувати модель автоенкодера, розроблену для виявлення аномалій, у реалістичних умовах, що включають не лише ідеальні, але й проблемні ситуації.

Важливість цього тестового набору полягає у можливості перевірити, наскільки ефективно модель здатна виявляти нетипову поведінку обладнання. При тренуванні моделі використовується нормальний діапазон показників як базовий стандарт, що дозволяє встановити пороги для реконструкційної помилки. Коли нові дані, отримані з цього тестового набору, обробляються за допомогою вже навченої моделі, система аналізує відхилення від базових патернів. Різкі зміни, викиди або пропуски в даних спричиняють збільшення реконструкційної помилки, що може бути інтерпретовано як сигнал про можливу аномалію або несправність. Таким чином, тестові дані є незамінним


					ІАЛЦ.467200.003 ПЗ	Арк.
						81
Змн.	Арк.	№ докум.	Підпис	Дата		

інструментом для перевірки якості моделі, її здатності розпізнавати відхилення та своєчасно сигналізувати про потенційні проблеми в роботі обладнання.

Крім того, даний набір даних є важливим для розробки алгоритмів попередньої обробки, оскільки він містить як стабільні, так і аномальні значення. Наявність пропущених даних змушує розробників впроваджувати методи їх заповнення або ігнорування, що сприяє створенню більш надійних і стійких моделей. В умовах реального застосування обладнання часто стикається з непередбаченими ситуаціями, тому тестування алгоритмів на таких даних дозволяє підвищити загальну стійкість системи моніторингу.

Отже, описаний набір тестових даних, що містить часові мітки та показники роботи п'яти сенсорів, є надзвичайно корисним для розробки, тестування та оптимізації системи виявлення аномалій. Він дозволяє не лише моделювати нормальну роботу обладнання, але й враховувати різноманітні аномалії, що можуть виникати у реальних умовах експлуатації, забезпечуючи таким чином своєчасне попередження аварійних ситуацій та підвищення безпеки промислових комплексів.

Для тестування цих даних модель необхідно навчити (рис.4.2).



Процес навчання моделі автоенкодера розпочинається з підготовки вхідних даних, що зазвичай включає нормалізацію або масштабування, видалення пропусків і, за потреби, формування тренувального та валідаційного піднаборів. На основі цих підготовлених даних відбувається ініціалізація мережі, яка складається з енкодера та декодера, що разом утворюють автоенкодер. Енкодер послідовно зменшує розмірність вхідного вектора, відображаючи його в простір прихованих ознак, а декодер, у свою чергу, намагається відновити початковий вектор із цього стислого представлення. На початковому етапі ваги та зсуви нейронів ініціалізуються невеликими випадковими числами, що дозволяє мережі почати навчання з певного початкового стану. Потім виконується компіляція моделі з обраним оптимізатором, наприклад Adam, та функцією втрат, такою як середньоквадратична похибка, що обчислює різницю між вихідними значеннями та відновленими. Під час кожного проходу даних через мережу (форвард-прохід) обчислюються передбачення на виході, порівнюються з фактичними вхідними значеннями, а потім розраховується функція втрат. Після цього алгоритм оптимізації коригує ваги мережі за допомогою зворотного поширення помилки (бекпропагації), під час якого градієнти обчислюються для кожного параметра мережі, щоб зменшити загальну похибку. Такий процес повторюється на кожній ітерації, що називається епохою. У межах кожної епохи відбувається також оцінка на валідаційному піднаборі, де обчислюється валідаційна втрата, яка дає змогу відстежити, наскільки добре модель узагальнює інформацію за межами тренувальних прикладів. Якщо валідаційна втрата починає зростати, це може бути індикатором перенавчання, що спонукає або скоротити кількість епох, або впровадити механізми регуляризації.

У процесі навчання кожна епоха супроводжується детальною фіксацією поточних значень втрати на тренуванні та на валідації, які в реальному застосунку відображаються на графіку. Така візуалізація дає змогу відстежити динаміку збіжності, аналізувати відмінності між двома типами втрат та оперативно приймати рішення щодо оптимізації гіперпараметрів. Якщо,

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		83

наприклад, тренувальна втрата невинно знижується, а валідаційна втрата залишається стабільно низькою, це свідчить про успішне навчання моделі та адекватне відтворення вхідних зразків. Водночас, якщо валідаційна втрата почне помітно зростати, а тренувальна продовжить знижуватися, це сигналізує про перенавчання: модель запам'ятовує деталі тренувального набору та погано узагальнює їх на нових даних. Щоб уникнути цього, часто застосовують ранню зупинку (early stopping), яка припиняє навчання, коли валідаційна втрата перестає зменшуватися протягом кількох послідовних епох. По завершенні навчання автоенкодер зберігається у файл, що дозволяє згодом швидко завантажити його та виконувати реконструкцію нових зразків. У режимі реального часу такі реконструкції слугують для виявлення аномалій: якщо мережа навчилася відтворювати нормальні приклади з малою помилкою, то будь-яке суттєве відхилення вказуватиме на те, що модель зіткнулася з нетиповим прикладом, що має бути класифікований як потенційно аномальний. Таким чином, детальне відстеження показників тренувальної та валідаційної втрат, а також своєчасне застосування зупинки навчання унеможливлюють перенавчання та сприяють формуванню узагальненої моделі, здатної надійно розпізнавати відхилення від нормального режиму роботи у промислових середовищах.

Після навчання моделі її було застосовано на тестових даних (рис.4.3).




Рисунок 4.3 – Візуалізація реконструкційної помилки

У представленому графіку відображено розподіл реконструкційної помилки по зразках, що були подані на вхід навченій моделі автоенкодера. На осі абсцис позначено номери зразків, а на осі ординат – величину помилки, яка свідчить про те, наскільки успішно модель відтворює вхідні дані. Загальний характер кривої демонструє, що більшість зразків мають досить низькі значення помилки, які коливаються на рівні близько 0.02–0.03. Такий діапазон зазвичай вважається типовим для ситуацій, коли вхідні дані відповідають «нормальному» режиму роботи обладнання, а автоенкодер здатен коректно відтворювати ці дані на основі патернів, засвоєних під час навчання. Однак, на одному зі зразків (приблизно посередині або ближче до другої половини вибірки) спостерігається різкий сплеск реконструкційної помилки, що сягає значення понад 0.20, у той час як довколишні зразки знову повертаються до нижчих значень. Такий різкий стрибок є ключовим маркером потенційної аномалії, оскільки свідчить про те, що модель не змогла належним чином відтворити структуру даних цього конкретного зразка, а отже, він суттєво відрізняється від решти прикладів, які

вважаються «нормальними».

Аби зрозуміти причини появи такого сплеску, слід розглянути специфіку тестових даних, які були описані раніше. У файлі `sensor_data.csv` міститься п'ять сенсорних показників (`sensor1`–`sensor5`) і часові мітки, що відображають момент знімання показників. При цьому перші кілька зразків мають досить стабільні значення, які мало відрізняються одне від одного. Зокрема, `sensor1`, `sensor2`, `sensor3`, `sensor4` і `sensor5` демонструють плавні коливання навколо певних базових рівнів, що можна інтерпретувати як нормальний режим роботи обладнання. У такій ситуації автоенкодер, що був навчений на подібних патернах, здатен успішно відтворити їх із низькою реконструкційною помилкою. Однак у подальших рядках датасету можуть з'являтися суттєві відхилення в одному чи кількох сенсорах. Наприклад, різке зростання показника `sensor3` або зниження `sensor4`, або ж викид у `sensor5`, що може бути спричинений перегрівом, підвищеною вібрацією, порушенням у роботі електронної схеми чи будь-яким іншим фактором, що виводить систему з нормального стану. Коли модель стикається з такими значеннями, які не відповідають її уявленням про «норму», виникає складність у реконструкції, і помилка суттєво зростає.

У конкретному випадку, відображеному на графіку, найбільш імовірною причиною різкого сплеску є або поява екстремального значення в одному із сенсорів, або сукупне відхилення одразу кількох сенсорів від їхніх типових діапазонів. Якщо в тестовому наборі даних фігурує, наприклад, значення `sensor3` = 3.00, тоді модель, яка звикла бачити `sensor3` у діапазоні 0.50–1.00 (умовно кажучи), відтворить цей зразок із великою помилкою, оскільки він виявиться далеким від усього, чого вона навчилася раніше. Аналогічно, якщо в одному з рядків `sensor4` падає до 0.10, коли всі інші зразки тримаються на рівні 0.80, це може спричинити невідповідність патернам «нормального» функціонування. Такий самий ефект має і поява NaN-значення, якщо воно не було оброблене належним чином або ж суттєво впливає на структуру даних.

З точки зору підприємства, що використовує таку систему моніторингу, виявлення подібних сплесків реконструкційної помилки є сигналом для більш

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		86

ретельної діагностики обладнання або технологічного процесу. Уявімо, що сенсор3 відображає тиск у трубопроводі, а сенсор4 – температуру в системі охолодження. Різке зростання тиску може бути викликане блокуванням клапана або несправністю насоса, тоді як різке зниження температури вказуватиме на збій у функціонуванні теплообмінника. Якщо ці події відбуваються одночасно, система автоенкодера, що навчилася на нормальних патернах взаємозв'язку між тиском і температурою, побачить цей зразок як «нетиповий» і сформує високу реконструкційну помилку. Виявлення такого відхилення дає змогу оперативно відреагувати та провести технічний огляд обладнання, перш ніж проблема спричинить масштабніший збій, зупинку виробництва або загрозу безпеці працівників.

Слід також підкреслити, що одиничний сплеск не завжди означає катастрофічну несправність. Інколи це може бути одинична хибна тривога, пов'язана з тимчасовим збоєм у передачі даних або перешкодами в мережі зв'язку між сенсорами та центром обробки. Однак, якщо аналогічні сплески повторюються з певною періодичністю або починають з'являтися частіше, це є вагомим приводом для проведення детальнішого аналізу, оскільки може свідчити про наростаючу несправність або тенденцію до перевищення безпечних параметрів роботи. У такому випадку підприємство може ухвалити рішення про позапланову зупинку обладнання для його профілактичного обслуговування або принаймні вжити заходів із посиленого моніторингу.

Інший важливий момент полягає в тому, що графік реконструкційної помилки допомагає інженерам та операторам не лише визначити факт наявності аномалії, а й оцінити її відносний масштаб. Якщо помилка зростає незначно, скажімо, з 0.03 до 0.05, це може свідчити про помірне відхилення від нормальних умов роботи, що, можливо, не вимагає негайної реакції. Проте, коли спостерігається стрибок до 0.25 чи 0.30, це є індикатором суттєвої різниці між очікуваним і фактичним станом системи, що, ймовірно, вимагає термінових заходів. У промислових процесах навіть незначні відхилення можуть перерости у критичні ситуації, якщо їх вчасно не усунути, тому подібні аналітичні

					ІАЛЦ.467200.003 ПЗ	Арк.
						87
Змн.	Арк.	№ докум.	Підпис	Дата		

інструменти відіграють ключову роль у забезпеченні безперервної та безпечної роботи виробничих ліній.

Зіставлення показників реконструкційної помилки з даними про реальні події на підприємстві також може допомогти у формуванні системи експертних правил чи тригерів. Наприклад, якщо історично відомо, що показник реконструкційної помилки вище 0.15 завжди пов'язаний із перевищенням робочої температури обладнання, система може автоматично надсилати сповіщення або запускати процедуру аварійного відключення у разі, коли помилка перевищує цей поріг. Такий підхід спирається на те, що автоенкодер успішно навчається відтворювати патерни нормальної роботи і починає «помилятися» тільки тоді, коли стикається з нетиповими зразками. З погляду керівництва підприємства це означає мінімізацію позапланових простоїв, оскільки завдяки системі виявлення аномалій можна запобігти значним пошкодженням обладнання.

Водночас важливо пам'ятати, що інколи аномалія може виникати через сукупність малих змін у різних сенсорах, а не через одиничний різкий викид у якомусь одному показнику. Якщо, наприклад, `sensor1`, `sensor2` і `sensor3` одночасно відхиляються від своїх типових значень, але кожне з цих відхилень не настільки велике, щоб одразу викликати підозру, модель усе одно може побачити «комбіновану» аномалію, оскільки сукупна картина не відповідатиме тим взаємозв'язкам, які вона вивчила. Це також може призвести до високої реконструкційної помилки та подальшого стрибка на графіку. Така здатність виявляти складні взаємозалежності робить автоенкодери одним із провідних інструментів для аналізу багатовимірних даних, де кожен сенсор відображає окремий аспект функціонування промислової системи.

Для підприємства такий підхід є особливо корисним, оскільки допомагає вчасно реагувати на потенційні проблеми, що ще не стали критичними, але можуть перерости у серйозні несправності. У разі, якщо автоенкодер під час навчання добре опанував патерни «здорового» стану обладнання, він швидко вкаже на сукупні відхилення, навіть якщо жоден сенсор окремо не виходить за

					ІАЛЦ.467200.003 ПЗ	Арк.
						88
Змн.	Арк.	№ докум.	Підпис	Дата		

свої нормальні межі. Це дозволяє інженерам проводити профілактичне обслуговування і оптимізувати графік ремонтних робіт, зменшуючи при цьому витрати на ліквідацію наслідків аварій і простої виробничих ліній.

Варто також зазначити, що поодинокі сплески на графіку реконструкційної помилки можуть бути результатом зовнішніх чинників, таких як короткочасне коливання електроживлення, коливання тиску у магістралях, людський фактор під час керування обладнанням, або навіть програмні збої у системах передачі даних. Тому процес аналізу даних має передбачати не лише виявлення фактів аномалій, а й контекстну оцінку, чому вони виникають. Часто у промислових умовах використовується поєднання даних з різних джерел – не лише з внутрішніх сенсорів, але й із зовнішніх інформаційних систем, що відстежують стан мережевого обладнання, історію ремонтів, інформацію про навантаження тощо. Синхронізація цих джерел дає змогу більш об'єктивно оцінити, чи пов'язаний викид реконструкційної помилки з реальною проблемою в обладнанні, чи це просто одноразова похибка вимірювального пристрою.

Якщо повернутися до графіка, де видно один чітко виражений пік і низку точок із мінімальною помилкою, слід підкреслити, що це ідеальний приклад для демонстрації сили та корисності методів машинного навчання, зокрема автоенкодерів, у сфері промислової діагностики. Звичайні методи статистичного контролю, що зосереджені на перевірці кожного сенсора окремо, можуть пропустити складні взаємозалежності між кількома показниками. Натомість автоенкодер розглядає вхідні дані в комплексі, відстежуючи мультимірні зв'язки між різними сенсорами, й завдяки цьому здатен виявляти нетипові стани навіть за відсутності очевидних одиничних аномальних значень.

Для подальшого удосконалення системи можна впровадити процедуру динамічного визначення порогів, коли поріг реконструкційної помилки не є статичним числом, а адаптується відповідно до поточної статистики. Наприклад, якщо середня помилка в нормальному режимі роботи коливається між 0.02 і 0.03, а стандартне відхилення становить 0.005, можна встановити гнучкий поріг, наприклад три стандартні відхилення від середнього. Тоді все, що перевищує цю

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		89

межу, одразу стає предметом підвищеної уваги. Такий підхід дозволяє враховувати зміни в роботі обладнання з часом, а також розширення чи модернізацію технологічних ліній, при яких «норма» може зсуватися.

Окрім того, підприємство може інтегрувати систему з іншими модулями, наприклад, модулями планування ремонтів (Computerized Maintenance Management System – CMMS) або ERP-системами (Enterprise Resource Planning). Завдяки цьому, коли система моніторингу фіксує сплеск реконструкційної помилки, в ERP-системі може автоматично створюватися завдання для відповідного відділу, а CMMS отримує сигнал про необхідність позачергового технічного обслуговування конкретної машини чи лінії. Така інтеграція сприяє кращій координації підрозділів на підприємстві та швидшому прийняттю рішень щодо подальших дій.

Не слід забувати і про те, що іноді аномалії можуть свідчити не лише про несправності обладнання, а й про зміни у характеристиках сировини або процесів. Якщо, наприклад, підприємство переробляє різні види сировини, і один із сенсорів відображає в'язкість, то поява нетипових значень може вказувати на відхилення у хімічному складі сировини. Вчасне виявлення такої ситуації дозволяє уникнути випуску неякісної продукції чи пошкодження обладнання, яке не розраховане на подібні зміни. Зрештою, такий системний підхід допомагає оптимізувати як внутрішні технологічні процеси, так і логістику чи закупівлі сировини, знижуючи загальні витрати і водночас підвищуючи якість кінцевого продукту.

Описана візуалізація реконструкційної помилки є інструментом, що значно полегшує роботу інженерів і аналітиків. Замість того, щоб вручну переглядати сотні чи тисячі рядків таблиці з сенсорними показниками, можна відразу побачити, в яких точках часу або в яких зразках відбулися відхилення. Це також полегшує співставлення даних із журналами обслуговування чи журналами подій, де фіксуються помилки операторів, перебої в електроживленні чи інші інциденти. З огляду на це, графік із вираженим піком є найкращим підтвердженням того, що модель змогла виділити незвичайний зразок і

					ІАЛЦ.467200.003 ПЗ	Арк.
						90
Змн.	Арк.	№ докум.	Підпис	Дата		

підкреслити його як потенційну проблему, яка вимагає аналізу та дій.

З погляду ефективності, така система здатна суттєво заощадити кошти підприємства завдяки зниженню кількості аварійних зупинок, оскільки виявлення проблеми ще на стадії її зародження дозволяє замінити зношені деталі чи відрегулювати технологічні параметри до того, як виникне більш серйозна поломка. Це також знижує ризик травматизму працівників, оскільки несправне обладнання може становити загрозу для безпеки персоналу. Зрештою, своєчасна діагностика та профілактичне обслуговування ведуть до підвищення загальної продуктивності підприємства та поліпшення якості продукції, що, у свою чергу, посилює конкурентні позиції компанії на ринку.

Загалом, різкий стрибок реконструкційної помилки на одному зразку на графіку, що показує «Розподіл реконструкційної помилки по зразках», означає, що у даному конкретному випадку вхідні сенсорні дані істотно відрізняються від очікуваних, і модель автоенкодера не здатна відтворити їх із низькою похибкою. Це відхилення трактується як аномалія, яка може бути викликана несправністю обладнання, некоректними показниками сенсорів, збоями у системах постачання енергії чи сировини, програмними помилками або будь-якими іншими зовнішніми чинниками. Для підприємства виявлення такого піку є важливим маркером для подальших дій: від швидкої перевірки обладнання до детального аналізу причин появи аномалії та розробки плану усунення потенційної проблеми. Систематичне застосування подібних інструментів моніторингу та аналізу забезпечує ефективне управління ризиками, скорочення непродуктивних витрат та підвищення рівня безпеки.

Таким чином, даний графік, що містить переважно низькі значення реконструкційної помилки і один виразний пік, є ілюстрацією типового сценарію застосування автоенкодера в задачі виявлення аномалій. Низькі значення помилки свідчать про відповідність більшості зразків тим патернам, які модель вивчила як норму, тоді як різке зростання помилки сигналізує про появу нетипового зразка, що не вписується в засвоєні закономірності. Для підприємства це означає, що модель успішно диференціює нормальні стани від

					ІАЛЦ.467200.003 ПЗ	Арк.
						91
Змн.	Арк.	№ докум.	Підпис	Дата		

потенційно небезпечних, створюючи основу для своєчасної реакції та ефективної експлуатації промислових комплексів.

4.2 Аналіз продуктивності та точності алгоритму

Аналіз продуктивності та точності алгоритму проводиться на основі резюме тестових результатів, отриманих у процесі застосування моделі автоенкодера для виявлення аномалій у сенсорних даних. Застосування моделі відзначилося високою здатністю коректно реконструювати дані, що відповідають нормальному режиму роботи обладнання, що підтверджується низькими значеннями реконструкційної помилки для більшості тестових зразків. Середнє значення реконструкційної помилки, що обчислювалося на валідаційному піднаборі, становило приблизно 0.02–0.03, що свідчить про високу точність відтворення нормальних патернів. При цьому стандартне відхилення помилки було невеликим, що вказує на сталість роботи алгоритму та його здатність узагальнювати патерни нормального функціонування, не допускаючи значних розбіжностей між окремими зразками.

Проте під час тестування на даних, що містять аномалії, було виявлено суттєве зростання реконструкційної помилки, що перевищувала встановлений поріг, розрахований на основі статистичних характеристик нормального режиму роботи. Високе значення помилки в окремих зразках дозволяє розглядати їх як потенційні аномалії, що потребують оперативного реагування. Такий підхід засновано на принципі, за яким автоенкодер, навчившись відтворювати дані, що відповідають нормальному стану, автоматично видає високі значення помилки для даних, які суттєво відрізняються від тренувального набору.

Аналіз продуктивності алгоритму також включає оцінку швидкодії його роботи в режимі реального часу. Під час тестування система демонструвала стабільну обчислювальну ефективність, що є критичним фактором для застосування у промислових умовах, де кожна секунда може бути вирішальною для запобігання аварійним ситуаціям. Час обробки даних, що включає етапи нормалізації, прогнозування та візуалізації результатів, відповідає сучасним

					ІАЛЦ.467200.003 ПЗ	Арк.
						92
Змн.	Арк.	№ докум.	Підпис	Дата		

вимогам до оперативності, що дозволяє системі виявляти аномалії практично в режимі реального часу.

На основі проведених тестувань було встановлено, що алгоритм демонструє високу точність при роботі з даними, які відповідають нормальному стану обладнання, а також ефективно ідентифікує аномальні зразки, що мають значно більшу реконструкційну помилку. Окрім того, точність алгоритму була перевірена шляхом порівняння отриманих результатів із незалежними вимірюваннями та експертними оцінками, що дозволило підтвердити його здатність адекватно реагувати на відхилення. Результати тестування свідчать про те, що запропонована модель може бути впроваджена в систему моніторингу для оперативного виявлення несправностей у виробничих процесах, що дозволяє підприємству своєчасно реагувати на потенційні загрози, оптимізувати процеси технічного обслуговування та знижувати ризики аварійних зупинок.

Таким чином, проведений аналіз продуктивності та точності алгоритму засвідчує його ефективність як засобу для виявлення аномалій у багатовимірних даних, що дозволяє досягти високої якості діагностики та сприяє підвищенню загальної безпеки та надійності технологічних процесів на підприємстві.

4.3 Порівняння з альтернативними методами

Альтернативним методом було обрано алгоритм Isolation Forest з кількох ключових причин, що стосуються як ефективності, так і практичних аспектів застосування в реальних умовах. По-перше, ізоляційний ліс є безкерівковим методом, який не вимагає попередньої маркованої інформації для навчання. Він базується на ідеї, що аномальні зразки за своєю суттю є рідкісними та віддаленими від основної маси даних, тому їх ізоляція відбувається швидше за рахунок випадкових поділів простору даних. Цей підхід дозволяє ефективно відокремити аномалії від нормальних зразків без складної оптимізації, як це має місце в глибоких автоенкодерах.

По-друге, Isolation Forest демонструє високу обчислювальну ефективність, оскільки не вимагає тривалого процесу навчання нейронної мережі. Завдяки

					ІАЛЦ.467200.003 ПЗ	Арк.
						93
Змн.	Арк.	№ докум.	Підпис	Дата		

своїй алгоритмічній простоті, він швидко обробляє великі обсяги даних, що є надзвичайно важливим для реального застосування на підприємствах, де час реакції може мати критичне значення. Крім того, цей метод має меншу чутливість до вибору гіперпараметрів, що спрощує його налаштування та інтеграцію у існуючі системи моніторингу.

Ще однією важливою перевагою є інтерпретованість результатів. Isolation Forest генерує аномальний бал для кожного зразка, що дозволяє чітко визначити поріг, нижче якого зразки класифікуються як аномальні. Така структура результатів полегшує візуальний аналіз та подальшу інтеграцію з системами прийняття рішень, адже керівники підприємств можуть швидко оцінити масштаб проблеми та прийняти відповідні заходи.

Таким чином, обрання Isolation Forest як альтернативного методу дозволяє забезпечити швидке, ефективне та інтерпретоване виявлення аномалій, що є критично важливим для своєчасного реагування на несправності у виробничих процесах та підвищення безпеки й надійності технологічних систем.

На рисунку 4.4 представлені результати виявлення аномалій цим методом.




Рисунок 4.4 – Аномалії в даних виявлені алгоритмом Isolation Forest

На поданій гістограмі відображено розподіл аномальних балів, обчислених алгоритмом IsolationForest, що дає змогу оцінити, наскільки кожен зразок відхиляється від загальної сукупності даних. По осі абсцис позначено

обчислений аномальний бал, а по осі ординат – кількість зразків, які відповідають цьому діапазону значень. Вертикальна пунктирна лінія вказує порогове значення, нижче якого зразки вважаються потенційно аномальними, оскільки IsolationForest визначає, що їх ізоляція потребує меншої кількості поділів. Такий підхід дозволяє швидко відокремити ті зразки, які суттєво виходять за межі нормального режиму. Завдяки цьому видно групування більшості прикладів у зоні праворуч від порогу, що інтерпретується як нормальна поведінка, тоді як меншість, яка опинилася ліворуч від порогу, вважається аномальною. Така візуалізація надає оперативну можливість оцінити, як саме розподілені аномалії у тестовому наборі, та вказує на їхню ймовірну природу як рідкісних та віддалених точок, які алгоритм виявляє за допомогою ізоляційних дерев.

Попри високу швидкодію та простоту налаштувань, метод IsolationForest має обмежену здатність урахувувати складні нелінійні залежності між численними ознаками, що може бути критично важливим для промислових процесів із багатьма взаємопов'язаними сенсорами. У цьому контексті підхід на основі глибоких автоенкодерів вважається більш корисним та кращим, оскільки нейронна мережа здатна вивчати приховані закономірності у багатовимірних даних і виявляти аномалії навіть за умов складних взаємозалежностей між ознаками. Коли автоенкодер навчається реконструювати нормальні зразки, він ефективно засвоює багатовимірні патерни нормальної роботи та виявляє відхилення шляхом підвищеної реконструкційної помилки. Такий підхід краще враховує дрібні зміни у кількох сенсорах одночасно, що в сукупності можуть свідчити про наближення несправності, тоді як алгоритм IsolationForest може розглядати такі відхилення недостатньо суттєвими, якщо кожен із показників окремо не виходить за межі типової зони. Таким чином, з огляду на складність та багатовимірність промислових процесів, глибокі автоенкодери надають більш гнучкий та потужний інструмент виявлення аномалій, що має вирішальне значення для забезпечення надійності та безпеки виробничих систем.

					ІАЛЦ.467200.003 ПЗ	Арк.
						95
Змн.	Арк.	№ докум.	Підпис	Дата		

4.4 Вплив параметрів моделі на якість детекції

Вплив параметрів моделі на якість детекції в глибоких автоенкодерах є критично важливим аспектом, що визначає здатність моделі точно реконструювати нормальні зразки та виявляти аномалії через збільшення реконструкційної помилки. Ретельний вибір архітектури моделі дозволяє досягти оптимального балансу між здатністю моделі навчатися складним залежностям у багатовимірних даних і її узагальнюючою здатністю, що є ключовим для розрізнення нормальних і аномальних станів.

Одним із основних параметрів є кількість шарів (глибина мережі) і кількість нейронів у кожному шарі. Збільшення кількості шарів дозволяє моделі краще відображати нелінійні залежності у вхідних даних, що характерно для складних технологічних процесів. Проте надмірна глибина може призвести до перенавчання або зникнення градієнтів, що негативно впливає на якість реконструкції. Оптимальна архітектура повинна бути обрана експериментальним шляхом, враховуючи як складність задачі, так і обчислювальні ресурси. Зокрема, занадто великий розмір латентного простору може призвести до того, що модель просто запам'ятовуватиме вхідні зразки, а не виділятиме суттєві патерни, що знизить контрастність реконструкційної помилки між нормальними зразками і аномаліями.

Коефіцієнт навчання (learning rate) є ще одним важливим параметром. Невеликий коефіцієнт може спричинити повільну збіжність і, як наслідок, недостатньо точну оптимізацію ваг, тоді як занадто великий – викликати нестабільність навчання або перетренованість моделі. Емпіричний підбір learning rate допомагає знайти оптимальне значення, яке забезпечує ефективну мінімізацію функції втрат. Водночас, застосування методів регуляризації (наприклад, L1, L2, dropout) дозволяє запобігти перенавчанню, сприяючи більшій узагальнювальній здатності моделі. Надмірна регуляризація може призвести до втрати важливої інформації, тоді як її відсутність – до запам'ятовування шумів та нехарактерних патернів.

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		96

Активаційні функції, такі як ReLU, Leaky ReLU або tanh, визначають, як модель опрацьовує нелінійність в даних. Використання функції ReLU сприяє швидшій збіжності, проте може призвести до «мертвих» нейронів, якщо частина з них не активується. Leaky ReLU або tanh можуть забезпечити більш збалансований розподіл активацій, що впливає на здатність моделі відтворювати складні залежності. Крім того, застосування batch normalization може підвищити стабільність навчання, зменшуючи внутрішні зміщення розподілу даних між шарами і дозволяючи використовувати більші коефіцієнти навчання без ризику виникнення числових нестабільностей.

На рисунку 4.5 представлено результат тестування моделі з гіршими параметрами навчання.




Рисунок 4.5 – Візуалізація реконструкційної помилки моделі з погіршеними параметрами

На наведеному графіку ілюструється розподіл реконструкційної помилки для моделі з погіршеними параметрами, де в енкодері використовується мінімальна кількість нейронів. Якщо порівняти цю візуалізацію з результатами більш оптимальної (глибшої) архітектури автоенкодера, можна побачити суттєві відмінності у поведінці та стабільності реконструкції. У випадку оптимальної

моделі з достатньою кількістю шарів і ширшим латентним простором, більшість нормальних зразків зазвичай дають низьку та відносно рівномірну реконструкційну помилку, а різкі стрибки спостерігаються переважно тоді, коли зустрічаються аномальні або незвичні дані. Це свідчить про здатність моделі «запам'ятовувати» та адекватно відтворювати характерні патерни нормального режиму роботи.

На відміну від цього, у моделі з погіршеними параметрами реконструкційна помилка має більш значні коливання навіть для, здавалося б, типових зразків. Причиною є надмірне стискання латентного простору: модель не здатна кодувати всі суттєві особливості вхідних даних, що призводить до втрати важливої інформації та підвищення загального рівня похибки. На графіку це виявляється як різкі скачки, коли деякі зразки відтворюються гірше, а інші – трохи краще, проте загальний діапазон коливань лишається високим. У результаті така модель менш надійно відрізняє аномальні дані від нормальних, оскільки відхилення у помилці може зростати не лише при появі справді нетипових прикладів, а й через те, що модель просто не «запам'ятала» достатньо патернів нормальної поведінки.

Таким чином, порівняльний аналіз двох підходів засвідчує, що зменшення кількості нейронів у прихованих шарах і надмірна простота архітектури автоенкодера значно знижують точність реконструкції та збільшують розкид помилок навіть у межах нормальних зразків. На практиці це означає, що для системи моніторингу важко розрізняти реальні аномалії від «шумів» у даних. У свою чергу, більш складна та глибока мережа дає змогу гнучкіше обробляти багатовимірні дані, краще розпізнавати внутрішні закономірності й утримувати низький рівень помилки для коректних зразків.

ВИСНОВКИ ДО РОЗДІЛУ

У четвертому розділі дипломної роботи було проведено всебічну експериментальну оцінку ефективності розробленої системи виявлення несправностей, що функціонує на основі глибокого автоенкодера. Основну увагу зосереджено на створенні тестового набору сценаріїв, який охоплював як типові, так і аномальні режими функціонування промислових сенсорних систем, що дозволило змодельовати різні види поведінкових відхилень. Виявлено, що модель демонструє високу здатність до виявлення аномалій на основі реконструкційної похибки, причому найбільш ефективними виявилися налаштування з помірною складністю архітектури та добре збалансованим латентним простором. У ході порівняння з іншими методами — включаючи класичні статистичні підходи та моделі підтримки векторів — автоенкодерна система засвідчила вищу точність, стійкість до шумів та здатність до генералізації, що особливо важливо для складних реальних умов. Здійснено також аналіз впливу гіперпараметрів на результати — зокрема, глибини мережі, розміру вікна аналізу, нормалізації та функції втрат — що дозволило окреслити оптимальні конфігурації для практичного застосування. У результаті підтверджено, що розроблена система є надійним інструментом для детекції несправностей у промислових середовищах, здатним до роботи в реальному часі з високим рівнем узагальнення навіть на обмежених або зашумлених наборах даних.

ВИСНОВКИ

У ході дослідження було здійснено глибокий аналіз можливостей застосування глибоких автоенкодерів для задач виявлення несправностей у промислових комплексах, що дозволило обґрунтувати доцільність використання даних моделей як ефективного інструмента для автоматизованого контролю технічного стану обладнання. Використання автоенкодерів, зокрема варіаційних та глибоких варіантів, забезпечувало здатність до вивчення прихованих закономірностей у багатовимірних виробничих даних, які є недоступними для традиційних методів діагностики. У результаті моделі продемонстрували високу чутливість до відхилень від нормальної поведінки систем, що дозволяло не лише ідентифікувати вже наявні несправності, але й виявляти аномальні стани, які могли передувати критичним поломкам.

Проведене моделювання підтвердило, що автоенкодери, навчені на нормальних режимах функціонування, були здатні з високою точністю реконструювати типовий профіль поведінки системи, тоді як при подачі на вхід даних, що містили аномалії, похибка реконструкції суттєво зростала, сигналізуючи про наявність несправності. Такий підхід забезпечив гнучке, адаптивне та ненаглядне навчання моделей, що суттєво знижувало вимоги до попередньо маркованих даних і підвищувало ефективність аналізу у реальних умовах виробництва. Застосування автоенкодерів також сприяло покращенню інтерпретованості результатів завдяки використанню механізмів латентного простору, у якому стали можливими виявлення кластерів нормальної та аномальної поведінки.

На основі одержаних результатів було зроблено висновок, що впровадження систем виявлення несправностей на основі глибоких автоенкодерів може істотно підвищити надійність і безпеку функціонування промислових комплексів. Це стало можливим завдяки здатності таких систем до роботи в реальному часі, високій точності прогнозування технічного стану та гнучкості щодо типу використовуваних сенсорних даних.

					ІАПЦ.467200.003 ПЗ	Арк.
						100
Змн.	Арк.	№ докум.	Підпис	Дата		

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Goodfellow I. J., Shlens J., Szegedy C. Explaining and Harnessing Adversarial Examples : тези доповіді // International Conference on Learning Representations (ICLR 2015). – 2015.
2. Lindqvist B., Izmailov R. Minimax Defense against Gradient-based Adversarial Attacks. – 2020.
3. Ortega-Fernandez I., Sestelo M., Burguillo J. C., Piñón-Blanco C. Network intrusion detection system for DDoS attacks in ICS using deep autoencoders // Wireless Networks. – 2024. – Том 30. – С. 5059–5075.
4. Xu W., Evans D., Qi Y. Feature Squeezing Mitigates and Detects Carlini/Wagner Adversarial Examples. – 2017.
5. Ayub M. A., Johnson W. A., Talbert D. A., Siraj A. Model Evasion Attack on Intrusion Detection Systems using Adversarial Machine Learning // Proceedings of the 54th Annual Conference on Information Sciences and Systems (CISS). – 2020.
6. Biggio B., Corona I., Maiorca D., Nelson B., Šrndić N., Laskov P., Giacinto G., Roli F. Evasion attacks against machine learning at test time. – 2017.
7. Papernot N., McDaniel P., Wu X., Jha S., Swami A. Distillation as a Defense to Adversarial Perturbations against Deep Neural Networks // Proceedings of the IEEE Symposium on Security and Privacy. – 2016. – С. 582–597.
8. Tran N. N., Sarker R., Hu J. An Approach for Host-Based Intrusion Detection System Design Using Convolutional Neural Network.
9. Atighetchi M., Webb J., Greenstadt R., Mayhew M. Behavior-Based Access Control – Needs, Benefits, and Concepts // Military Communications Conference (MILCOM), Orlando, Florida. – 2012.
10. Segall J., Mayhew M., Atighetchi M., Greenstadt R. Assessing Trustworthiness in Collaborative Environments // Proceedings of the Cyber Security and Information Intelligence Research Workshop. – 2012.
11. Atighetchi M., Mayhew M. J., Greenstadt R., Adler A. Developing and Validating Statistical Cyber Defenses // IEEE Software Technology Conference

					ІАЛЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		101

(STC). – 2013.

12. Adler A., Mayhew M. J., Cleveland J., Atighetchi M. User Selection of Clusters and Classifiers in BBAC // International Conference on Intelligent User Interfaces (IUI), Workshop on Interactive Machine Learning. – 2013.

13. Segall J., Greenstadt R. The Illiterate Editor: Metadata-driven Revert Detection in Wikipedia // Joint International Symposium on Wikis and Open Collaboration (WikiSym + OpenSym). – 2013.

14. Cleveland J., Mayhew M. J., Adler A., Atighetchi M. Scalable Machine Learning Framework for Behavior-Based Access Control // IEEE International Symposium on Resilient Cyber Systems (ISRCS). – 2013.

15. Adler A., Mayhew M. J., Cleveland J., Atighetchi M., Greenstadt R. Using Machine Learning for Behavior-Based Access Control: Scalable Anomaly Detection on TCP Connections and HTTP Requests // Military Communications Conference (MILCOM). – 2013.

16. Atighetchi M., Mayhew M. J., Greenstadt R., Adler A. Problems and Mitigation Strategies for Developing and Validating Statistical Cyber Defenses // CrossTalk – The Journal of Defense Software Engineering. – 2014. – Том 27, № 2.

17. Overdorf R., Dutko T., Greenstadt R. Blogs and Twitter Feeds: A Stylometric Environmental Impact Study // Privacy Enhancing Technologies Symposium (PETS). – 2014.

18. Hu N., Tian Z., Lu H., Du X., Guizani M. A multiple-kernel clustering based intrusion detection scheme for 5G and IoT networks // International Journal of Machine Learning and Cybernetics. – 2021. – Том 12. – С. 153–165.

19. Kim J., Kim J., Kim H., Shim M., Choi E. CNN-Based Network Intrusion Detection against Denial-of-Service Attacks // Electronics. – 2020. – Том 9, №. 6. – Стаття 916.

20. Alomari O., Othman Z. A. Bees algorithm for feature selection in network anomaly detection // Journal of Applied Sciences Research. – 2012. – Том 8. – С. 1748–1756.

21. Anantvalee T., Wu J. A survey on intrusion detection in mobile ad hoc

					<i>ІАЛЦ.467200.003 ПЗ</i>	Арк.
						102
Змн.	Арк.	№ докум.	Підпис	Дата		

networks // In: Wireless/mobile network security. – Springer-Verlag, 2007. – C. 170–196.

22. Axelsson S. Intrusion detection systems: a survey and taxonomy. – Chalmers University of Technology, Technical Report 99-15. – 2000. – C. 1–27.

23. Bace R., Mell P. Intrusion detection systems. – National Institute of Standards and Technology, Technical Report 800-31. – 2001.

24. Boyer R. S., Moore J. S. A fast string searching algorithm // Communications of the ACM. – 1977. – Том 20. – C. 762–772.

25. Cabrera J. B. D., Gosar J., Lee W., Mehra R. K. On the statistical distribution of processing times in network intrusion detection // 43rd IEEE Conference on Decision and Control. – 2004. – C. 75–80.

26. Carbone M., Lee W., Zamboni D. Taming virtualization // IEEE Security and Privacy. – 2008. – Том 6. – C. 65–67.

27. Chung Y. Y., Wahid N. A hybrid network intrusion detection system using simplified swarm optimization (SSO) // Applied Soft Computing. – 2012. – Том. 12. – C. 3014–3022.

28. Couture M. Real time intrusion prediction based on optimized alerts with hidden Markov model // Journal of Networks. – 2012. – Том 7. – C. 311–321.

29. Debar H., Dacier M., Wespi A. Towards a taxonomy of intrusion detection systems // Computer Networks. – 1999. – Том 31. – C. 805–822.

30. Debar H., Dacier M., Wespi A. A revised taxonomy for intrusion-detection system // Annals of Telecommunications. – 2000. – Том 55. – C. 361–378.

31. Delgado N., Gates Q., Roach S. A taxonomy and catalog of runtime software-fault monitoring tools // IEEE Transactions on Software Engineering. – 2004. – Том 30. – C. 859–872.

32. Denning D. E. An intrusion-detection model // IEEE Transactions on Software Engineering. – 1987. – ТомSE-13. – C. 222–232.

33. Elshoush H. T., Osman I. M. Alert correlation in collaborative intelligent intrusion detection systems – a survey // Applied Soft Computing. – 2011. – Том 11. – C. 4349–4365.

34. Estevez-Tapiador J. M., Garcia-Teodoro P., Diaz-Verdejo J. E. Anomaly detection methods in wired networks: a survey and taxonomy // Computer Communications. – 2004. – Tom 27. – C. 1569–1584.

35. Farooqi A. H., Khan F. A., Wang J., Lee S. A novel intrusion detection framework for wireless sensor networks // Personal and Ubiquitous Computing. – 2012.

36. Fragkiadakis A. G., Tragos E. Z., Tryfonas T., Askoxylakis I. G. Design and performance evaluation of a lightweight wireless early warning intrusion detection prototype // EURASIP Journal on Wireless Communications and Networking. – 2012. – Article 73. – C. 1–18.

37. Garcia-Teodoro P., Diaz-Verdejo J., Macia-Fernandez G., Vazquez E. Anomaly-based network intrusion detection: techniques, systems and challenges // Computers & Security. – 2009. – Tom 28. – C. 18–28.

38. Garfinkel T., Rosenblum M. A virtual machine introspection based architecture for intrusion detection // Network and Distributed Systems Security Symposium. – 2003.

39. Goyal N., Ormont J., Smith R., Sankaralingam K., Estan C. Signature matching in network processing using SIMD/GPU architectures. – University of Wisconsin-Madison, Technical Report 1628. – 2008.

40. Ho C.-Y., Lai Y.-C., Chen I.-W., Wang F.-Y., Tai W.-H. Statistical analysis of false positives and false negatives from real traffic with intrusion detection/prevention systems // IEEE Communications Magazine. – 2012. – Tom 50. – C. 146–154.

41. Horng S.-J., Su M.-Y., Chen Y.-H., Kao T.-W., Chen R.-J., Lai J.-L., Perkasa C. D. A novel intrusion detection system based on hierarchical clustering and support vector machines // Expert Systems with Applications. – 2011. – Tom 38. – C. 306–313.

42. Jiang W., Yang Y.-H. E., Prasanna V. K. Scalable multi-pipeline architecture for high performance multi-pattern string matching // 24th IEEE International Parallel and Distributed Processing Symposium. – 2010. – C. 1–12.

43. Jones A. K., Sielken R. S. Computer system intrusion detection: a survey. –

University of Virginia, Technical Report. – 2000.

44. Kabiri P., Ghorbani A. A. Research on intrusion detection and response: a survey // International Journal of Network Security. – 2005. – Том 1. – С. 84–102.

45. Kantzavelou I., Katsikas S. A game-based intrusion detection mechanism to confront internal attackers // Computers & Security. – 2010. – Том 29. – С. 859–874.

46. Kartit A., Saidi A., Bezzazi F., Marraki M. E., Radi A. A new approach to intrusion detection system // Journal of Theoretical and Applied Information Technology. – 2012. – Том 36. – С. 284–289.

47. Kolias C., Kambourakis G., Maragoudakis M. Swarm intelligence in intrusion detection: a survey // Computers & Security. – 2011. – Том 30. – С. 625–642.

48. Kourai K., Chiba S. HyperSpector: virtual distributed monitoring environments for secure intrusion detection // First ACM/USENIX International Conference on Virtual Execution Environments. – 2005. – С. 197–207.

49. Krugel C., Toth T. A survey on intrusion detection systems. – Technical University of Vienna, Technical Report TUV-1841-00-11. – 2000. – С. 22–33.

50. Krutz R. L., Vines R. D. Cloud security: a comprehensive guide to secure cloud computing. – Indianapolis: Wiley, 2010.

51. Lazarevic A., Kumar V., Srivastava J. Managing cyber threats: issues, approaches, and challenges. – New York: Springer-Verlag, 2005.

52. Le D., Wang H. An effective memory optimization for virtual machine-based systems // IEEE Transactions on Parallel and Distributed Systems. – 2011. – Том 22. – С. 1705–1713.

53. Li Y., Xia J., Zhang S., Yan J., Ai X., Dai K. An efficient intrusion detection system based on support vector machines and gradually feature removal method // Expert Systems with Applications. – 2012. – Том 39. – С. 424–430.

54. Kaggle. URL: <https://www.kaggle.com/datasets/dnkumars/industrial-equipment-monitoring-dataset/data>(дата звернення: 01.04.2025).


ДОДАТОК А

Системи виявлення несправностей у промислових комплексах на основі
глибоких автоенкодерів

Принципова схема

Аркушів 1

Київ – 2025



Основна мета цієї схеми — візуально відобразити логіку прийняття рішення про наявність технічної несправності на основі аналізу вхідних параметрів. Вона показує, як система:

1. Отримує дані від сенсорів.
2. Виконує попередню обробку (нормалізацію, фільтрацію).
3. Приймає рішення, чи ці дані придатні для аналізу.
4. Передає допустимі дані в автоенкодер.
5. Розраховує похибку реконструкції.
6. Порівнює похибку з граничним порогом.
7. У разі перевищення — позначає як аномалію та надсилає сигнал тривоги.
8. У разі нормального функціонування — зберігає результат у лог.


ДОДАТОК Б

Системи виявлення несправностей у промислових комплексах на основі
глибоких автоенкодерів

Функціональна схема

Аркушів 1

Київ – 2025



Інтерпретація блоків:

Датчики — збирають показники (температура, вібрація, струм тощо) з обладнання.

Збір даних — забезпечує агрегацію та передачу сенсорної інформації.

Попередня обробка — фільтрує, нормалізує та приводить дані до стандартного вигляду.

Модуль автоенкодера — виконує глибоке кодування/декодування для виявлення відхилень.

Аналіз похибки — визначає ступінь відхилення (реконструктивна помилка).

Рішення — на основі аналізу вирішує, чи є аномалія, та інформує або зберігає.

Оператор — отримує сигнал для ручного втручання (за потреби).

База даних — зберігає результати для подальшого аналізу, звітності або візуалізації.

ДОДАТОК В

**Системи виявлення несправностей у промислових комплексах на основі
глибоких автоенкодерів**

Структурна схема

Аркушів 1

Київ – 2025



Пояснення елементів:

Модуль завантаження даних

Відповідає за отримання сенсорних або збережених даних з реального об'єкта чи з бази. Це може включати зчитування з API, файлів журналу або потоків телеметрії.

Модуль автоенкодера

Виконує глибинне кодування та реконструкцію даних. Це ядро нейронної мережі, яка навчається на нормальних зразках і обчислює похибку реконструкції. Його призначення — виявлення нестандартних відхилень на основі порівняння з внутрішньою моделлю норми.

Модуль виявлення несправностей

Приймає результати від автоенкодера (зокрема значення реконструктивної похибки) і на їх основі ухвалює рішення: чи є поточна ситуація аномальною. У разі виявлення несправності — цей модуль ініціює відповідь: наприклад, запис у лог, тривогу або взаємодію з оператором.

ДОДАТОК Г

**Системи виявлення несправностей у промислових комплексах на основі
глибоких автоенкодерів**

Лістинг програмного коду

Аркушів 4

Київ – 2025

```

import tkinter as tk
from tkinter import ttk, filedialog, messagebox
import threading
import sqlite3
import pandas as pd
import numpy as np
import matplotlib
matplotlib.use("TkAgg")
import matplotlib.pyplot as plt
from matplotlib.backends.backend_tkagg import FigureCanvasTkAgg
from sklearn.preprocessing import MinMaxScaler
import tensorflow as tf
from tensorflow.keras.models import Model, load_model
from tensorflow.keras.layers import Input, Dense
from tensorflow.keras.callbacks import Callback
import queue

# Глобальна черга для передачі даних про прогрес навчання
progress_queue = queue.Queue()

# Кастомний callback, що відправляє інформацію про завершення кожної епохи у чергу
class ProgressCallback(Callback):
    def on_epoch_end(self, epoch, logs=None):
        progress_queue.put((epoch + 1, logs.get('loss'), logs.get('val_loss')))

# Функція ініціалізації бази даних SQLite та створення таблиці логів навчання
def init_db():
    conn = sqlite3.connect('anomaly_app.db')
    cursor = conn.cursor()
    cursor.execute('''
        CREATE TABLE IF NOT EXISTS training_logs (
            id INTEGER PRIMARY KEY AUTOINCREMENT,
            epoch INTEGER,
            loss REAL,
            val_loss REAL,
            timestamp DATETIME DEFAULT CURRENT_TIMESTAMP
        )
    ''')
    conn.commit()
    return conn

# Функція запису даних про навчання у базу даних
def log_training(epoch, loss, val_loss):
    conn = init_db()
    cursor = conn.cursor()
    cursor.execute("INSERT INTO training_logs (epoch, loss, val_loss) VALUES (?, ?, ?)", (epoch, loss, val_loss))
    conn.commit()
    conn.close()

# Функція, що виконується у окремому потоці та займається навчанням моделі
def train_model(data, input_dim, finish_callback):
    # Побудова моделі автоенкодера
    input_layer = Input(shape=(input_dim,))
    encoded = Dense(32, activation='relu')(input_layer)
    encoded = Dense(16, activation='relu')(encoded)
    decoded = Dense(32, activation='relu')(encoded)
    decoded = Dense(input_dim, activation='sigmoid')(decoded)
    autoencoder = Model(inputs=input_layer, outputs=decoded)
    autoencoder.compile(optimizer='adam', loss='mse')

    # Ініціалізація кастомного callback для оновлення прогресу
    progress_cb = ProgressCallback()

```

					ІАПЦ.467200.003 ПЗ	Арк.
Змн.	Арк.	№ докум.	Підпис	Дата		1

```

# Навчання моделі з використанням валідаційного набору даних
history = autoencoder.fit(data, data,
                           epochs=100,
                           batch_size=32,
                           validation_split=0.2,
                           callbacks=[progress_cb],
                           verbose=0)

# Збереження навченої моделі у файл
autoencoder.save('trained_autoencoder.h5')

# Виклик callback про завершення навчання із передачею історії втрат
finish_callback(autoencoder, history.history['loss'],
history.history['val_loss'])

# Клас графічного інтерфейсу, реалізованого на базі Tkinter
class App:
    def __init__(self, master):
        self.master = master
        master.title("Anomaly Detection App 2025")
        master.geometry("1000x750")
        master.configure(bg="#F0F8FF")

        self.training_loss = []
        self.validation_loss = []
        self.training_finished_flag = False

        # Кнопка для запуску навчання моделі
        self.train_button = ttk.Button(master, text="Розпочати навчання",
command=self.start_training)
        self.train_button.pack(pady=10)

        # Прогрес-бар для відображення процесу навчання
        self.progress_bar = ttk.Progressbar(master, orient="horizontal",
length=400, mode="determinate", maximum=100)
        self.progress_bar.pack(pady=10)

        # Мітка для відображення статусу навчання
        self.status_label = tk.Label(master, text="Статус: Очікування запуску
навчання", bg="#F0F8FF", font=("Segoe UI", 14))
        self.status_label.pack(pady=10)

        # Інтеграція Matplotlib для побудови графіка динаміки навчання
        self.figure = plt.Figure(figsize=(8, 4), dpi=100)
        self.ax = self.figure.add_subplot(111)
        self.ax.set_title("Динаміка навчання автоенкодера")
        self.ax.set_xlabel("Епоха")
        self.ax.set_ylabel("Втрата")
        self.canvas = FigureCanvasTkAgg(self.figure, master)
        self.canvas.get_tk_widget().pack(pady=10)

        # Кнопка для тестування моделі з власними даними
        self.test_button = ttk.Button(master, text="Тестувати модель з власними
даними", command=self.test_with_user_data, state="disabled")
        self.test_button.pack(pady=10)

        # Мітка для відображення результатів прогнозування
        self.result_label = tk.Label(master, text="", bg="#F0F8FF", font=("Segoe
UI", 14))
        self.result_label.pack(pady=10)

        # Завантаження та попередня обробка даних із CSV файлу (навчальний набір)
        self.data, self.scaler = self.load_data()
        self.input_dim = self.data.shape[1]

```

					ІАЛЦ.467200.003 ПЗ	Арк.
						2
Змн.	Арк.	№ докум.	Підпис	Дата		

```

# Запуск періодичної перевірки черги оновлень
self.master.after(100, self.check_queue)

def load_data(self):
    data = pd.read_csv('equipment_anomaly_data.csv')
    data_values = data.select_dtypes(include=[np.number]).values
    scaler = MinMaxScaler()
    data_scaled = scaler.fit_transform(data_values)
    return data_scaled, scaler

def start_training(self):
    self.train_button.config(state="disabled")
    self.status_label.config(text="Статус: Навчання запущено")
    # Запуск процесу навчання у окремому потоці
    threading.Thread(target=train_model, args=(self.data, self.input_dim,
self.training_finished), daemon=True).start()

def check_queue(self):
    try:
        while True:
            epoch, loss, val_loss = progress_queue.get_nowait()
            self.training_loss.append(loss)
            self.validation_loss.append(val_loss)
            progress_percent = int((epoch / 100) * 100)
            self.progress_bar['value'] = progress_percent
            self.status_label.config(text=f"Епоха: {epoch} | Втрата:
{loss:.4f} | Валідаційна втрата: {val_loss:.4f}")
            log_training(epoch, loss, val_loss)
            self.update_plot()
    except queue.Empty:
        pass
    if not self.training_finished_flag:
        self.master.after(100, self.check_queue)

def update_plot(self):
    self.ax.clear()
    self.ax.plot(range(1, len(self.training_loss) + 1), self.training_loss,
label="Втрата на тренуванні")
    self.ax.plot(range(1, len(self.validation_loss) + 1),
self.validation_loss, label="Втрата на валідації")
    self.ax.set_title("Динаміка навчання автоенкодера")
    self.ax.set_xlabel("Епоха")
    self.ax.set_ylabel("Втрата")
    self.ax.legend()
    self.canvas.draw()

def training_finished(self, model, training_loss, validation_loss):
    self.training_finished_flag = True
    self.status_label.config(text="Статус: Навчання завершено")
    self.test_button.config(state="normal")

def test_with_user_data(self):
    # Використання діалогу для вибору файлу з даними користувача
    file_path = filedialog.askopenfilename(title="Виберіть CSV файл з
тестовими даними", filetypes=[("CSV Files", "*.csv")])
    if not file_path:
        return
    try:
        user_data = pd.read_csv(file_path)
        data_values = user_data.select_dtypes(include=[np.number]).values
        # Масштабування даних за допомогою того ж scaler, що використовувався
при навчанні
        data_scaled = self.scaler.transform(data_values)

```

					ІАПЦ.467200.003 ПЗ	Арк.
						3
Змн.	Арк.	№ докум.	Підпис	Дата		

```

except Exception as e:
    messagebox.showerror("Помилка", f"Не вдалося завантажити дані:\n{e}")
    return

# Завантаження навченої моделі з параметром compile=False для уникнення
проблем десеріалізації
model = load_model('trained_autoencoder.h5', compile=False)
reconstructed = model.predict(data_scaled)
reconstruction_error = np.mean(np.square(data_scaled - reconstructed),
axis=1)
errors_str = ", ".join([f"{e:.4f}" for e in reconstruction_error])

# Відображення результатів у текстовій формі
self.result_label.config(text="Реконструкційна помилка: " + errors_str)

# Відображення графіка розподілу реконструкційної помилки
self.show_error_plot(reconstruction_error)

def show_error_plot(self, errors):
    # Створення нового вікна для візуалізації графіка
    plot_window = tk.Toplevel(self.master)
    plot_window.title("Графік реконструкційної помилки")
    plot_window.geometry("800x600")
    fig = plt.Figure(figsize=(8, 6), dpi=100)
    ax = fig.add_subplot(111)
    ax.plot(range(1, len(errors) + 1), errors, marker='o', linestyle='-')
    ax.set_title("Розподіл реконструкційної помилки по зразках")
    ax.set_xlabel("Номер зразка")
    ax.set_ylabel("Реконструкційна помилка")
    canvas = FigureCanvasTkAgg(fig, master=plot_window)
    canvas.get_tk_widget().pack(fill=tk.BOTH, expand=True)
    canvas.draw()

if __name__ == "__main__":
    root = tk.Tk()
    app = App(root)
    root.mainloop()

```