

Міністерство освіти та науки України
Харківський національний автомобільно-дорожній університет

Механічний факультет

Кафедра метрології та безпеки життєдіяльності

КВАЛІФІКАЦІЙНА РОБОТА
бакалавра

**ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ОБРОБКИ
ВИМІРЮВАЛЬНИХ ДАНИХ**

Завідувач кафедри канд. техн. наук, проф.



О. І. Богатов

Нормоконтролер канд. техн. наук, доцент



І. В. Грайворонська

Керівник канд. техн. наук, доцент



Д. Є. Петрукович

Студент гр. ММЗ-41-22



А. М. Роденко

Харків – 2026

**ХАРКІВСЬКИЙ НАЦІОНАЛЬНИЙ АВТОМОБІЛЬНО-ДОРОЖНІЙ
УНІВЕРСИТЕТ**

Факультет механічний

Кафедра метрології та безпеки життєдіяльності

Освітній рівень перший (бакалаврський)

Спеціальність 152 Метрологія та інформаційно-вимірвальна техніка

Освітня програма «Інформаційно-вимірвальні технології»

ЗАТВЕРДЖУЮ

Завідувач. Кафедри

 **О. І. Богатов**

« 03 » квітня 2026 р.

**ЗАВДАННЯ
НА КВАЛІФІКАЦІЙНУ РОБОТУ СТУДЕНТУ**

Роденко Андрію Миколайовичу

1. Тема роботи: «Застосування методів машинного навчання для обробки вимірвальних даних».

Керівник Петрукович Дмитро Євгенович, канд. техн. наук, доцент.

Затверджені рішенням Вченої ради механічного факультету від « 13 » березня 2026 р. № 7

2. Строк подання студентом роботи 01.06.2026 р.

3. Вхідні дані до роботи: Гідравлічна система дорожньої машини. Технічні характеристики датчика тиску. LSTM-модель.

4. Зміст розрохунково-пояснювальної записки (перелік питань, які потрібно розробити): 1 Вступ; 2 Аналіз методів обробки вимірвальних даних; 3 Аналіз методів машинного навчання в обробці вимірвальних даних; 4 Розробка та дослідження нейромережевої моделі LSTM для обробки вимірвальних даних тиску в гідросистемі дорожньої машини; 5 Висновки; 6 Перелік посилань.

5. Перелік графічного матеріалу (з точним зазначенням обов'язкових креслень):

6. Консультанти розділів роботи

Розділ	Консультант	Підпис, дата	
		Завдання видав	Завдання прийняв
4	доц. Богатов О. І.		

7. Дата видачі завдання « 03 » квітня 2026 р.

КАЛЕНДАРНИЙ ПЛАН

Пор. №	Найменування етапів дипломної роботи	Строк виконання етапів роботи	Примітка
1	Вивчення літератури	10.04.2026	
2	Аналіз методів обробки вимірювальних даних	20.04.2026	
3	Аналіз методів машинного навчання в обробці вимірювальних даних	30.04.2026	
4	Розробка та дослідження нейромережевої моделі LSTM для обробки вимірювальних даних тиску в гідросистемі дорожньої машини	10.05.2026	
5	Охорона праці та безпека у надзвичайних ситуаціях	25.05.2026	
6	Формулювання висновків.	01.06.2026	
7	Оформлення кваліфікаційної роботи.	05.06.2026	
8	Створення презентації в Power Point.	07.06.2026	
9	Подання роботи на нормоконтроль.	10.06.2026	

Студент

Роденко А. М.

Керівник роботи

Петрукович Д. Є.

ЗМІСТ

Перелік умовних позначень, символів, одиниць, скорочень і термінів.....	6
Вступ.....	7
1 Аналіз методів обробки вимірювальних даних	8
1.1 Особливості вимірювальних даних в інформаційно-вимірювальних системах	8
1.2 Аналіз класичних методів обробки вимірювальної інформації.....	10
1.3 Обмеження традиційних підходів.....	12
1.4 Основи машинного навчання.....	15
2 Аналіз методів машинного навчання в обробці вимірювальних даних.....	19
2.1 Загальна характеристика методів машинного навчання для інформаційно-вимірювальних систем.....	19
2.2 Лінійні регресійні моделі.....	23
2.3 Древа рішень та ансамблеві методи.....	26
2.4 Штучні нейронні мережі.....	27
2.5 Рекурентні нейронні мережі та LSTM.....	29
3 Розробка та дослідження нейромережевої моделі LSTM для обробки вимірювальних даних тиску в гідросистемі дорожньої машини.....	31
3.1 Аналіз LSTM-мережі.....	31
3.2 Алгоритм роботи LSTM-мережі.....	40
3.3 Навчання LSTM-мережі для прогнозування тиску в гідросистемі дорожньої машини.....	44
3.4 Оцінка точності моделі	54
4 Охорона праці та безпека у надзвичайних ситуаціях	58
4.1 Освітлення на робочому місці	58
4.2 Вентиляція в приміщеннях	60
4.3 Безпека у надзвичайних ситуаціях	61
Висновки.....	63
Перелік посилань.....	64
Додаток А Ілюстративний матеріал до кваліфікаційної роботи.....	67

РЕФЕРАТ

Пояснювальна записка до кваліфікаційної роботи: 80 с., 13 рис., 9 таблиць., 25 джерел, 1 додаток.

ADAM, ГІДРОСИСТЕМА, ДОРОЖНЯ МАШИНА, ІНФОРМАЦІЙНО-ВИМІРЮВАЛЬНА СИСТЕМА, МАШИННЕ НАВЧАННЯ, НЕЙРОННА МЕРЕЖА, ОБРОБКА ДАНИХ, ФІЛЬТР КАЛМАНА

Об'єкт дослідження – є процес обробки вимірювальних даних у вимірювальному каналі тиску гідравлічної системи дорожньої машини.

Мета – дослідження можливостей застосування методів машинного навчання для обробки вимірювальних даних та підвищення точності визначення тиску в гідросистемі дорожньої машини.

Методи дослідження – включають методи математичного моделювання, теорію цифрової обробки сигналів, методи статистичного аналізу, алгоритми машинного навчання, нейронні мережі типу LSTM.

В кваліфікаційній роботі розглянуто питання застосування методів машинного навчання для підвищення точності обробки вимірювальних даних в інформаційно-вимірювальних системах дорожніх машин. Основну увагу приділено дослідженню вимірювального каналу тиску гідравлічної системи та можливостям використання сучасних алгоритмів штучного інтелекту для зменшення похибок вимірювання.

В кваліфікаційній роботі розроблено нейромережеву модель на основі архітектури Long Short-Term Memory (LSTM), призначену для прогнозування значень тиску та компенсації похибок вимірювального каналу. Розглянуто структуру LSTM-мережі, принцип роботи її основних компонентів, зокрема LSTM-шару, Dropout-шару, повнозв'язного шару Dense та алгоритму оптимізації Adam.

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ СКОРОЧЕНЬ І
ТЕРМІНІВ

АЦП – аналого-цифровий перетворювач

ДМ – дорожньої машини

ІВС – інформаційна-вимірювальна система

МК – мікроконтролер

Кафедра МБЖД ХНАДУ

ВСТУП

Сучасний розвиток інформаційно-вимірювальних технологій характеризується стрімким зростанням обсягів даних, що надходять від різноманітних сенсорів, вимірювальних перетворювачів та автоматизованих систем контролю. Особливо актуальним це питання являється для дорожніх машин, у яких велика кількість датчиків забезпечує контроль технічного стану гідравлічних, механічних та електронних систем.

Одним із найважливіших параметрів, що визначає ефективність роботи дорожньої машини, є тиск у гідравлічній системі. Від точності його вимірювання залежить якість виконання технологічних операцій, надійність функціонування виконавчих механізмів та безпека експлуатації машини. Проте на результати вимірювань впливають різноманітні фактори: шум вимірювального каналу, температурні зміни, вібрації, електромагнітні завади, старіння сенсорів та нестабільність режимів роботи гідросистеми. В результаті виникають додаткові похибки, які можуть суттєво знижувати достовірність отриманої інформації.

Традиційні методи цифрової обробки сигналів, такі як ковзне середнє, медіанна фільтрація, фільтр Калмана та інші алгоритми, дозволяють частково зменшити вплив шумів і випадкових завад. Однак їх ефективність часто є недостатньою при роботі зі складними нелінійними процесами, характерними для сучасних гідравлічних систем дорожніх машин. Це обумовлює необхідність пошуку нових підходів до обробки вимірювальних даних.

Одним із перспективних напрямів є використання методів машинного навчання та штучних нейронних мереж. На відміну від класичних алгоритмів, моделі машинного навчання здатні автоматично виявляти приховані закономірності в даних, адаптуватися до зміни умов експлуатації та забезпечувати високу точність прогнозування вимірюваних параметрів. Особливий інтерес становлять рекурентні нейронні мережі типу LSTM (Long Short-Term Memory), які ефективно працюють із часовими рядами та враховують попередні стани досліджуваного процесу.

1 АНАЛІЗ МЕТОДІВ ОБРОБКИ ВИМІРЮВАЛЬНИХ ДАНИХ

1.1 Особливості вимірювальних даних в інформаційно-вимірювальних системах

Сучасні інформаційно-вимірювальні системи (ІВС) є невід'ємною складовою дорожніх машин, автомобільної техніки та промислового обладнання. Їх основне призначення полягає в зборі, передачі, обробці та збереженні інформації про параметри контрольованих процесів.

В дорожніх машинах інформаційно-вимірювальні системи використовуються для контролю наступних параметрів [1]:

- тиску в гідравлічних системах;
- температури двигуна та мастила;
- витрати палива;
- частоти обертання валів;
- рівня вібрації;
- положення робочих органів машини.

Первинна інформація надходить від вимірювальних перетворювачів (датчиків), які перетворюють фізичну величину у електричний сигнал.




Рисунок 1.1 – Структурна схема вимірювального каналу

Якість отриманої інформації значною мірою залежить від характеристик вимірювального каналу та умов експлуатації.

Основними особливостями вимірювальних даних є [2]:

- наявність випадкових шумів;
- вплив зовнішніх факторів;
- нелінійність характеристик сенсорів;
- часові затримки;
- дрейф параметрів датчиків;
- наявність викидів та пропусків даних.

Проведемо аналіз елементів каналу вимірювання тиску в гідравлічній системі дорожньої машини.

1. Датчик тиску – перетворює тиск у електричний сигнал. Для гідравлічної системи дорожньої машини датчик тиску повинен мати наступні технічні характеристики: діапазон вимірювання від 0 МПа до 25 МПа; вихідна напруга від 0 В до 5 В і похибка вимірювання $\pm 0,25\%$ [3].

Сигнал датчика тиску записується у вигляді виразу:

$$P_{\text{вим}}(t) = P_{\text{ісм}}(t) + \Delta P(t) + n(t), \quad (1.1)$$

де $P_{\text{ісм}}(t)$ – істинне значення тиску;

$\Delta P(t)$ – систематична похибка;

$n(t)$ – випадковий шум.

У реальних умовах роботи дорожньої машини на сигнал впливають механічні вібрації, зміни температури навколишнього середовища та електромагнітні завади.

2. Підсилювач сигналу забезпечує узгодження рівнів сигналу та підвищує завадостійкість.

3. АЦП перетворює аналоговий сигнал у цифровий код. В інформаційно-вимірювальних системах дорожніх машин використовується 16 бітний аналого-цифровий перетворювач з частотою дискретизації 100 Гц [4].

4. Модуль попередньої обробки виконує наступні операції: фільтрацію шумів; нормалізацію; видалення викидів; формування часових вікон.

5. Модуль машинного навчання призначений для реалізації алгоритмів: Linear Regression; Random Forest; XGBoost; Neural Network; LSTM [5].

На вхід подаються:

$$X = [P_{meas}, T, V], \quad (1.2)$$

де P_{meas} – виміряний тиск;

T – температура;

V – рівень вібрації.

На виході отримують P_{true} або ΔP .

Блок компенсації похибки визначає скориговане значення:

$$P_{corr} = P_{meas} - \Delta P. \quad (1.3)$$

База даних та інтерфейс користувача забезпечує: зберігання результатів, побудову графіків та передачу даних оператору.

1.2 Аналіз класичних методів обробки вимірювальної інформації

Для підвищення точності вимірювань традиційно застосовуються статистичні та цифрові методи обробки сигналів.

1. Метод ковзного середнього.

Одним із найпростіших методів пригнічення шуму є ковзне середнє [6]:

$$y(k) = \frac{1}{N} \sum_{i=0}^{N-1} x(k-i), \quad (1.4)$$

де $x(k)$ – вхідний сигнал;

N – ширина вікна усереднення.

Метод особливо ефективний для сигналів, які змінюються відносно повільно та містять високочастотний випадковий шум.

Перевагами методу є простота реалізації та низькі обчислювальні витрати.

До недоліків відносяться: затримка сигналу, згладжування корисних змінних, погіршення динамічних властивостей.

2. Медіанна фільтрація.

Медіанний фільтр використовується для видалення імпульсних завад [6]:

$$y(k) = \text{median}[x(k - M), \dots, x(k + M)]. \quad (1.5)$$

Перевагою є ефективне усунення одиничних викидів без значного спотворення форми сигналу.

3. Цифрові фільтри.

Широко використовуються цифрові фільтри [7]:

- FIR-фільтри;
- IIR-фільтри;
- адаптивні фільтри.

Рівняння FIR-фільтра:

$$y(n) = \sum_{k=0}^N b_k x(n - k), \quad (1.6)$$

де b_k – коефіцієнти фільтра.

Рівняння IIR- фільтра:

$$y(n) = \sum_{k=0}^M b_k x(n - k) - \sum_{k=1}^N a_k y(n - k). \quad (1.7)$$

Такі фільтри дозволяють ефективно пригнічувати шумові складові та покращувати якість вимірювань.

4. Метод Калмана.

Для динамічних систем широко використовується фільтр Калмана. Принцип роботи.

1. Прогноз стану:

$$\hat{x}_{k|k-1} = A\hat{x}_{k-1|k-1} + Bu_k. \quad (1.8)$$

2. Оновлення оцінки:

$$\hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k(z_k - H\hat{x}_{k|k-1}). \quad (1.9)$$

Фільтр Калмана забезпечує високу точність оцінювання параметрів за наявності шумів вимірювання.

1.3 Обмеження традиційних підходів

Традиційні методи обробки вимірювальної інформації широко застосовуються в інформаційно-вимірювальних системах завдяки своїй простоті, математичній обґрунтованості та відносно невеликим обчислювальним витратам. До таких методів належать усереднення результатів вимірювань, цифрова фільтрація, регресійний аналіз, статистичні методи оцінювання та алгоритми оптимальної фільтрації. Проте зі зростанням складності сучасних технічних систем та збільшенням обсягів вимірювальної інформації стає очевидним, що традиційні підходи мають низку суттєвих обмежень [8].

По-перше, більшість алгоритмів ґрунтується на припущенні про лінійність процесів. У реальних умовах експлуатації дорожніх машин вимірювальні сигнали часто формуються під впливом нелінійних процесів, зокрема зміни

температури робочого середовища, вібраційних навантажень, тертя в гідравлічних елементах та зміни характеристик сенсорів у процесі експлуатації. У таких випадках точність лінійних моделей істотно знижується.

По-друге, датчик тиску в гідравлічній системі дорожньої машини працює в умовах різних навантажень: запуск системи, номінальний режим, перехідні процеси, аварійні перевантаження. Для кожного режиму характерні різні статистичні характеристики сигналу. Параметри традиційних фільтрів зазвичай налаштовуються для певного режиму роботи і не забезпечують однаково високої ефективності в інших умовах.

Важливою проблемою є також наявність шумів складної структури. Класичні методи часто припускають, що шум має нормальний розподіл та є стаціонарним процесом. Насправді вимірювальні сигнали можуть містити імпульсні завади, електромагнітні перешкоди, випадкові стрибки напруги живлення та інші фактори, які не відповідають прийнятим статистичним моделям. У таких умовах ефективність традиційних алгоритмів значно зменшується.

Ще одним обмеженням є неможливість автоматичного врахування великої кількості впливових факторів. Для прикладу, похибка вимірювання тиску може залежати одночасно від температури робочої рідини, рівня вібрації, вологості, тиску навколишнього середовища, напруги живлення та ступеня зношування сенсора [9]. Побудова аналітичної моделі, яка враховує всі ці фактори, є складним завданням і часто потребує значних спрощень.

Серйозною проблемою є старіння та деградація вимірювальних перетворювачів. У процесі тривалої експлуатації характеристики датчиків змінюються внаслідок механічного зносу, температурного старіння матеріалів, корозійних процесів та інших факторів [10]. Традиційні методи обробки сигналів не мають механізмів автоматичного врахування таких змін, що призводить до поступового зростання похибки вимірювань.

Особливої уваги заслуговує проблема роботи з великими обсягами даних. Сучасні інформаційно-вимірювальні системи можуть генерувати десятки тисяч

вимірювань за короткий проміжок часу. При моніторингу технічного стану дорожньої машини одночасно контролюються десятки параметрів: тиск, температура, вібрація, швидкість обертання, витрата палива та інші [11]. Аналіз таких масивів інформації традиційними методами потребує значних обчислювальних ресурсів.

Класичні методи практично не здатні самостійно виявляти приховані закономірності у даних. Вони виконують обробку відповідно до заздалегідь визначених математичних моделей та не можуть автоматично знаходити складні залежності між параметрами системи.

Ще одним недоліком є складність прогнозування майбутніх значень параметрів. Більшість традиційних алгоритмів орієнтовані на обробку поточних вимірювань і не забезпечують ефективного прогнозування розвитку процесів.

В таблиці 1.1 наведено порівняльну характеристику основних обмежень традиційних методів.

Таблиця 1.1 – Основні недоліки традиційних методів обробки вимірювальних даних

Недолік	Наслідки
Припущення про лінійність	Зниження точності при роботі з нелінійними процесами
Фіксовані параметри алгоритмів	Низька адаптивність до зміни режимів роботи
Обмежене врахування факторів впливу	Зростання систематичної похибки
Неможливість самонавчання	Необхідність ручного налаштування
Відсутність прогнозування	Неможливість реалізації предикативної діагностики
Робота лише з невеликими масивами даних	Зниження ефективності при Big Data

Таким чином, традиційні методи обробки вимірювальної інформації залишаються ефективними для простих задач фільтрації та статистичного аналізу, однак їх можливості є недостатніми для сучасних інформаційно-

вимірювальних систем, що функціонують в умовах багатфакторних впливів та великих обсягів даних. Саме тому перспективним напрямом є використання методів машинного навчання, які здатні автоматично виявляти закономірності, адаптуватися до змін умов експлуатації та забезпечувати підвищення точності вимірювань.

1.4 Основи машинного навчання

В сучасних інформаційно-вимірювальних системах спостерігається постійне зростання обсягів даних. Традиційні методи аналізу та обробки сигналів не завжди забезпечують необхідну точність при роботі зі складними нелінійними процесами, характерними для сучасних технічних об'єктів [12]. Одним із перспективних напрямів вирішення цієї проблеми є використання методів машинного навчання.

Машинне навчання (Machine Learning) є напрямом штучного інтелекту, який дозволяє комп'ютерним системам автоматично виявляти закономірності в даних та формувати прогнози без явного програмування алгоритму.

На відміну від традиційних алгоритмів, де програміст задає послідовність дій для кожної ситуації, у машинному навчанні система самостійно формує математичну модель на основі накопичених даних.

Загальна модель машинного навчання може бути представлена у вигляді [13]:

$$y = f(x, \theta), \quad (1.10)$$

де x – вхідні дані;

y – результат прогнозування;

θ – параметри моделі.

Основною метою навчання є визначення такого набору параметрів θ , при якому похибка прогнозування буде мінімальною.

У задачах обробки вимірювальних даних машинне навчання використовується для:

- компенсації похибок вимірювань;
- прогнозування значень параметрів;
- виявлення аномалій;
- класифікації режимів роботи;
- діагностики технічного стану обладнання;
- прогнозування відмов датчиків.

1. Навчання з вчителем.

Найбільш поширеним є навчання з учителем, яке передбачає, що для кожного вхідного вектору x_i існує вектор вихідних значень y_i . Разом ці два вектора називають навчальною парою (x_i, y_i) , а множину навчальних пар називають навчальною вибіркою. Процес навчання зводиться до почергового подавання на вхід нейронної мережі навчальних пар, вирахування похибки між дійсним і бажаним значенням нейронної $\delta = y - d$ та корегування параметрів мережі в бік зменшення цієї похибки [5].

Таким чином, мета полягає у знаходженні функції $f(x)$ яка мінімізує похибку прогнозування.

2. Навчання без вчителя.

Навчання без вчителя один із способів машинного навчання, при вирішенні яких випробовувана система спонтанно навчається виконувати поставлене завдання, без втручання з боку експериментатора.

Навчання без вчителя використовується для: кластеризації; пошуку аномалій; аналізу структури даних. Типовим прикладом є алгоритм k -means [5, 12].

Найбільш перспективним напрямом машинного навчання є нейронні мережі.

Принцип роботи нейрона описується виразом:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right), \quad (1.11)$$

де w_i – вагові коефіцієнти;

b – зміщення;

f – функція активації.

Нейронні мережі дозволяють [13]: компенсувати похибки сенсорів; прогнозувати значення параметрів; виявляти аномальні режими роботи; оцінювати технічний стан обладнання.

На рисунку 1.2 представлена класифікація методів машинного навчання.




Рисунок 1.2 – Класифікація методів машинного навчання

Для оцінки якості моделей використовуються [14]:

1. Середня абсолютна похибка:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (1.12)$$

2. Середньоквадратична похибка:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (1.13)$$

3. Корінь середньоквадратичної похибки:

$$RMSE = \sqrt{MSE}. \quad (1.14)$$

4. Коефіцієнт детермінації:

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y})^2}. \quad (1.15)$$

Застосування цих показників дозволяє об'єктивно оцінити ефективність алгоритмів машинного навчання.

Таким чином методи машинного навчання є сучасним інструментом аналізу та обробки вимірювальної інформації. На відміну від традиційних алгоритмів, вони здатні автоматично виявляти складні нелінійні залежності між параметрами системи, адаптуватися до зміни умов експлуатації та працювати з великими масивами даних. Особливий інтерес для інформаційно-вимірювальних систем становлять ансамблеві алгоритми та нейронні мережі, які забезпечують підвищення точності вимірювань, компенсацію похибок сенсорів і прогнозування технічного стану обладнання.

2 АНАЛІЗ МЕТОДІВ МАШИННОГО НАВЧАННЯ В ОБРОБЦІ ВИМІРЮВАЛЬНИХ ДАНИХ

2.1 Загальна характеристика методів машинного навчання для інформаційно-вимірювальних систем

Розвиток інформаційно-вимірювальних систем призвів до суттєвого збільшення обсягів даних, що надходять від сенсорів та вимірювальних перетворювачів. У сучасних дорожніх машинах одночасно можуть контролюватися десятки параметрів, серед яких тиск, температура, вібрація, швидкість руху, витрата палива та інші характеристики технічного стану.

На рисунку 2.1 представлені етапи побудови моделі машинного навчання.




Рисунок 2.1 – Етапи побудови моделі машинного навчання

Традиційні методи цифрової обробки сигналів дозволяють ефективно усувати шуми та випадкові завади, однак їх можливості є обмеженими при роботі зі складними нелінійними процесами [6]. У таких умовах перспективним

напрямом є використання методів машинного навчання, які забезпечують автоматичне виявлення прихованих закономірностей у даних.

Моделі навчаються на великих масивах часових рядів.

У загальному вигляді задача машинного навчання може бути представлена як пошук функціональної залежності:

$$y = f(X), \quad (2.1)$$

де $X = [x_1, x_2, \dots, x_n]$ – вектор вхідних параметрів;

y – вихідна величина.

Для вимірювального каналу тиску дорожньої машини така залежність може мати вигляд:

$$P_{ict} = f(P_{вим}, T, V, U), \quad (2.2)$$

де P_{ict} – істинне значення тиску;

$P_{вим}$ – вимірне значення;

T – температура;

V – рівень вібрації;

U – напруга живлення.

Виходячи з цього запису можна зробити висновок, що основними напрямками застосування машинного навчання в інформаційно-вимірювальних системах являються:

1. Компенсація похибок датчиків – це комплекс методів (апаратних та програмних) для усунення відхилень між вимірним і реальним значенням фізичної величини [9].

Основні типи та алгоритми які використовуються.

Апаратні методи [9]:

– аналогова температурна компенсація: використання терморезисторів,

термісторів або спеціальних діодних схем, які змінюють опір/напругу залежно від нагрівання та корегують вихідний сигнал моста Вітстона.

- конструктивна компенсація: встановлення додаткового чутливого елемента, який вимірює лише температуру, дозволяючи процесору вираховувати чистий тиск.

Програмні методи [4]:

- метод таблиць (Look-up tables): під час виробництва сенсор тестують у кліматичній камері при різних температурах і тисках. Дані зашиваються в пам'ять мікроконтролера, який у роботі підставляє точні значення з таблиці.

- математичне моделювання: розрахунок похибки в реальному часі за допомогою поліноміальних рівнянь.

- динамічна фільтрація: використання фільтрів (Калмана або ковзного середнього) для усунення високочастотних шумів, вібрацій та дрейфу нуля.

2. Прогнозування параметрів – це науково обґрунтоване передбачення майбутніх кількісних чи якісних характеристик об'єкта.

Основні типи та алгоритми які використовуються [15].

- математична статистика та регресійний аналіз: дозволяють встановити кількісну залежність між параметрами та описати її математично;

- часові ряди: базуються на припущенні, що тенденції минулого (наприклад, тиску) збережуться у майбутньому;

- нейромережі: застосовуються для складних систем, де на вхід подається низка параметрів, а система прогнозує результат.

3. Діагностика технічного стану – це автоматизований процес аналізу даних від датчиків або механізмів для прогнозування похибок [16].

Основні підходи, що використовуються для реалізації такої діагностики:

- виявлення аномалій (Anomaly Detection of Anomalies): модель навчається на нормальних даних і виявляє будь-які відхилення, які вказують на потенційну проблему;

- прогнозування залишкового ресурсу (RUL-Remaining Useful Life): оцінка того, скільки часу або циклів роботи залишилось;

– класифікація дефектів: визначення типу несправності (знос підшипника, дисбаланс ротора чи витік рідини).

4. Виявлення аномалій – це процес знаходження патернів (стійка повторювана схема, закономірність, стандартний підхід до вирішення типової проблеми) або елементів у даних, які суттєво відрізняються від очікуваної норми.

Основні типи машинного навчання які застосовуються [17]:

- кероване (Supervised): використовує розмічені дані, де норма та аномалія вже відомі;
- некероване (Unsupervised): алгоритми (Isolation Forest, DBSCAN або LOF) знаходять викиди без попереднього навчання на розмічених прикладах;
- напівкероване (Semi-supervised): алгоритми навчаються виключно на нормальних даних, а будь-яке відхилення від цього шаблону класифікують як аномалію.

5. Прогнозування деградації сенсорів – це процес оцінювання поточного стану датчиків та передбачення часу їхнього виходу за межі допустимої метрологічної похибки або повного відмови.

Основні типи та алгоритми які використовуються [12]:

- регресійні моделі (лінійна, поліноміальна) – для простого трендового дрейфу;
- випадковий ліс (Random Forest) та Gradient Boosting – для нелінійних залежностей;
- нейромережі (LSTM, GRU) – найкраще підходять для аналізу часових рядів та фіксації довгострокових залежностей деградації.

6. Інтелектуальна фільтрація сигналів – це процес очищення даних від шумів та завад з використанням алгоритмів машинного навчання, штучного інтелекту або адаптивних математичних моделей. На відміну від класичних фільтрів, вона здатна самостійно розпізнавати патерни та змінювати свої параметри залежно від поточного середовища.

Основні типи та алгоритми які використовуються [12]:

- штучні нейронні мережі (ANN): згорткові (CNN) та рекурентні (RNN)

мережі, що навчаються на великих масивах даних та безпомилково відрізняють корисний сигнал від фонового шуму;

- адаптивні фільтри (алгоритм LMS): самоналагоджувальні системи, що змінюють власні коефіцієнти в реальному часі без участі людини;

- Вейвлет-перетворення (Wavelet Transform): математичний інструмент для багаторівневого аналізу, який ідеально підходить для локалізації та видалення короткочасних імпульсних завад.

Таким чином необхідно розглянути більш докладно алгоритми, які використовуються при машинному навчанні.

2.2 Лінійні регресійні моделі

1. Лінійна регресія.

Лінійні регресійні моделі – це базовий клас статистичних моделей та методів машинного навчання, які використовують для знаходження математичної залежності між однією залежною змінною (цільовою) та однією чи кількома незалежними змінними (ознаками) у вигляді прямої лінії.

Модель припускає, що залежність є лінійною, і виглядає як рівняння прямої. Дану модель можна описати наступним рівнянням [7]:

$$y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (2.3)$$

де y – залежна змінна;

$x_1, x_2, \dots, x_n$ – незалежні змінні;

w_0 – вільний член;

$w_1, w_2, \dots, w_n$ – коефіцієнти регресії.

Для задачі компенсації похибки датчика тиску [18]:

$$\Delta P = w_0 + w_1T + w_2V + w_3U \quad (2.4)$$

Тоді скориговане значення визначається:

$$P_{кор} = P_{вим} - \Delta P \quad (2.5)$$

Для побудови лінії регресії найчастіше використовують МНК (Ordinary Least Squares). Його головна ідея – підібрати такі коефіцієнти w , щоб сума квадратів різниць між реальними точками та лінією прогнозу була мінімальною.

Для того, щоб модель мала високу точність і надійність, дані повинні відповідати наступним таким критеріям:

- зв'язок між змінними повинен мати лінійний характер;
- дисперсія похибок повинна бути постійною для всіх значень;
- незалежні змінні не повинні бути пов'язані між собою;
- похибки моделі повинні бути розподілені за нормальним законом.

Переваги лінійної регресії – це простота реалізації, висока швидкість навчання, інтерпретованість результатів, невеликі обчислювальні витрати.

До недоліків лінійної регресії можна віднести: неможливість опису складних нелінійних процесів, низька точність для реальних вимірювальних систем та чутливість до викидів.

2. Ridge-регресія.

Ridge-регресія (гребнева регресія) – це метод машинного навчання та статистики, який є вдосконаленням звичайної лінійної регресії.

У класичній лінійній регресії модель намагається підібрати коефіцієнти так, щоб мінімізувати суму квадратів помилок. Якщо даних дуже багато або деякі ознаки тісно пов'язані між собою, коефіцієнти можуть ставати аномально великими, що робить модель чутливою до шумів [4, 12].

Ridge-регресія використовується для запобігання перенавчанню та ефективно працює у випадках, коли вхідні дані мають сильну кореляцію між собою.

Цільова функція має наступний вигляд:

$$J = \sum_{i=1}^p (y_i - \hat{y}_i)^2 + \lambda \sum_{i=1}^p w_i^2, \quad (2.6)$$

де $\sum_{i=1}^p (y_i - \hat{y}_i)^2$ – сума квадратів відхилень передбачених значень від фактичних;

w_i – вагові коефіцієнти моделі;

p – кількість ознак;

λ – коефіцієнт регуляризації.

Ridge-регресія вирішує дану проблему за допомогою L2-регуляризації.

Якщо $\lambda = 0$ регуляризація вимикається, отримуємо звичайну лінійну регресію. Якщо λ модель зменшує вагові коефіцієнти ближче до нуля, але ніколи не робить їх рівними рівно нулю.

Таким чином Ridge-регресія не виконує відбір ознак. Якщо потрібно автоматично видалити непотрібні змінні користуються Lasso-регресією.

3. Lasso-регресія.

Lasso-регресія – це метод лінійної регресії, який використовує L1-регуляризацію.

Стандартна регресія прагне мінімізувати суму квадратів помилок. Якщо ознак дуже багато, це часто призводить до перенавчання моделі. Lasso-регресія до функції втрат додає штраф, пропорційний сумі абсолютних значень коефіцієнтів [4,12]:

$$J = \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \sum_{i=1}^n |w_i|, \quad (2.7)$$

де λ – коефіцієнт регуляризації.

Таким чином Lasso-регресія дозволяє автоматично відбирати найбільш важливі ознаки.

Основні переваги Lasso-регресії:

– за рахунок математичних властивостей L1-регуляризації Lasso-регресія

може повністю обнулити коефіцієнти незначних факторів. Це залишає в моделі лише найкорисніші змінні;

- модель стає простішою, оскільки виключає зайвий "шум" у даних;
- ефективно працює, коли серед незалежних змінних є сильний взаємозв'язок.

Виходячи з аналізу можна зробити висновок, що регресійні методи можуть використовуватися для компенсації систематичних похибок сенсорів за умови слабкої нелінійності процесів.

2.3 Древа рішень та ансамблеві методи

Для складніших задач застосовуються дерева рішень. Алгоритм послідовно розбиває простір ознак на області з подібними характеристиками [5].

1. Random Forest.

Random Forest (випадковий ліс) – це один із найпопулярніших та найефективніших алгоритмів машинного навчання. Він є ансамблевим методом, який поєднує прогнози безлічі незалежних вирішальних дерев для отримання одного, більш точного та стабільного результату [5, 12].

Кожне дерево навчається на випадковій підмножині даних.

Загальний прогноз:

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N y_i, \quad (2.8)$$

де N – кількість дерев.

До переваг можна віднести наступне: висока точність; стійкість до шумів; робота з нелінійними залежностями; відсутність необхідності нормалізації.

До недоліків відноситься: великий обсяг пам'яті; складність інтерпретації.

2. Gradient Boosting.

Градiєнтний бустинг (Gradient Boosting) – це потужний метод машинного

навчання для завдань класифікації та регресії, який будує передбачувану модель у вигляді ансамблю слабких учнів, що послідовно додаються (зазвичай простих вирішальних дерев). Головна особливість алгоритму полягає в тому, що кожне нове дерево навчається виправляти помилки всіх попередніх дерев за допомогою мінімізації функції втрат градієнтного спуску [5, 12].

Алгоритм формує послідовність моделей.

Загальний прогноз записується у вигляді вираз:

$$F(x) = \sum_{m=1}^M \gamma_m h_m(x) \quad (2.9)$$

де $h_m(x)$ – окреме дерево.

До сучасних реалізацій належать: XGBoost; LightGBM; CatBoost.

У задачах вимірювання тиску вони забезпечують високу точність компенсації похибок.

2.4 Штучні нейронні мережі

Найбільш перспективним напрямом є використання нейронних мереж.

Основним елементом мережі є штучний нейрон [12].

Його математична модель описується виразом:

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2.10)$$

де w_i – вагові коефіцієнти;

b – зміщення.

Багатошаровий перцептрон (Multilayer Perceptron, MLP) є одним із найпоширеніших типів штучних нейронних мереж, який використовується для апроксимації функцій, класифікації, регресії та прогнозування вимірювальних

даних.

MLP належить до класу мереж прямого поширення сигналу (Feed Forward Neural Network), в яких інформація рухається лише від входу до виходу без зворотних зв'язків.

Типова структура багатошарового перцептрона містить: вхідний шар (Input Layer), один або декілька прихованих шарів (Hidden Layers) та вихідний шар (Output Layer).

Для задачі прогнозування тиску структура мережі може бути представлена як: 3-32-16-1 де: 3 входи (тиск, температура, вібрація); 32 нейрони першого прихованого шару; 16 нейронів другого прихованого шару; 1 вихідний нейрон [12].

Алгоритм навчання.

Використовується метод зворотного поширення помилки [12].

Функція втрат описується виразом:

$$L = \frac{1}{N} \sum (y_i - \hat{y}_i)^2 \quad (2.11)$$

Оновлення ваг описується виразом:

$$w_{new} = w_{old} - \eta \frac{\partial L}{\partial w}, \quad (2.12)$$

де η – швидкість навчання.

Переваги: опис складних нелінійних процесів; висока точність; автоматичне виявлення закономірностей.

Недоліки: потреба у великих обсягах даних; значний час навчання; складність налаштування.

Багатошаровий перцептрон є ефективним інструментом для обробки вимірювальних даних, компенсації похибок та калібрування датчиків [5, 12].

Однак для задач прогнозування тиску в гідросистемі дорожньої машини, де необхідно враховувати часові залежності сигналу, більш ефективним є використання LSTM-мережі.

2.5 Рекурентні нейронні мережі та LSTM

Вимірювальні сигнали являються часовими рядами. Тому для їх аналізу широко використовуються рекурентні мережі.

У класичній RNN:

$$h_t = f(Wx_t + Uh_{t-1}), \quad (2.13)$$

де h_t – прихований стан мережі.

Архітектура LSTM.

LSTM (Long Short-Term Memory) дозволяє зберігати інформацію про попередні значення сигналу [12].

Основні елементи: Forget Gate; Input Gate; Cell State; Output Gate.

Завдяки цьому мережа може аналізувати довгі часові послідовності.

Переваги LSTM: висока точність прогнозування; врахування історії процесу; ефективність для часових рядів.

Використання в інформаційно-вимірювальних системах LSTM дозволяє: прогнозувати тиск у гідросистемі; оцінювати деградацію сенсорів; виявляти приховані дефекти; прогнозувати аварійні режими.

Якість машинного навчання значною мірою залежить від підготовки даних.

В таблиці 2.1 представлений порівняльний аналіз методів машинного навчання.

Таблиця 2.1 – Порівняльний аналіз методів машинного навчання

Метод	Точність	Швидкість	Нелінійність	Часові ряди
Лінійна регресія	Низька	Висока	Ні	Ні
Ridge/Lasso	Середня	Висока	Частково	Ні
Дерево рішень	Середня	Висока	Так	Ні
Random Forest	Висока	Середня	Так	Частково
XGBoost	Дуже висока	Середня	Так	Частково
MLP	Висока	Середня	Так	Ні
LSTM	Найвища	Низька	Так	Так

З аналізу видно, що для задач обробки вимірювальних даних та компенсації похибок сенсорів найбільш перспективними є ансамблеві алгоритми та рекурентні нейронні мережі LSTM.

З РОЗРОБКА ТА ДОСЛІДЖЕННЯ НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ LSTM ДЛЯ ОБРОБКИ ВИМІРЮВАЛЬНИХ ДАНИХ ТИСКУ В ГІДРОСИСТЕМІ ДОРОЖНЬОЇ МАШИНИ

3.1 Аналіз LSTM-мережі

Однією з основних задач сучасних інформаційно-вимірювальних систем є забезпечення високої точності вимірювання параметрів в умовах впливу зовнішніх і внутрішніх завад. Особливо актуальною ця проблема є для гідравлічних систем дорожніх машин, де параметри тиску безпосередньо впливають на ефективність роботи виконавчих механізмів, продуктивність обладнання та безпеку експлуатації.

Розглянемо нейромережеву модель LSTM для визначення істинного значення тиску на основі аналізу часових рядів вимірювальної інформації в інформаційно-вимірювальній системі тиску дорожньої машини [12, 17].

На рисунку 3.1 представлена структурна схема LSTM-мережі для прогнозування тиску в системі дорожньої машини.




Рисунок 3.1 – Структурна схема LSTM-мережі для прогнозування тиску

На рисунку 3.1 наведена структурна схема нейромережевої моделі типу LSTM (Long Short-Term Memory), яка використовується для обробки часових рядів вимірювальних даних та прогнозування значення тиску в гідравлічній

системі дорожньої машини.

Основною особливістю LSTM-мережі є наявність внутрішньої пам'яті, що дозволяє враховувати попередні значення сигналу під час формування прогнозу. Це особливо важливо для аналізу гідравлічних процесів, оскільки значення тиску в поточний момент часу залежать від попередніх режимів роботи системи.

LSTM-мережа складається з наступних елементів:

1. Вхідний шар.

На вхід мережі подається часове вікно довжиною L , яке містить послідовність вимірних значень тиску та додаткових параметрів:

$$X_t = [P_t, T_t, V_t]^T, \quad (3.1)$$

де P_t – вимірне значення тиску;

T_t – температура робочої рідини;

V_t – рівень вібрації;

t – поточний момент часу.

Для формування прогнозу використовується набір попередніх значень:

$$X = [x_{t-L+1}, x_{t-L+2}, \dots, x_t]. \quad (3.2)$$

Для формування часових залежностей використовується метод ковзного вікна. Довжина вікна становить $L = 20$, то вхідна послідовність має вигляд $[P_{t-19}, P_{t-18}, \dots, P_t]$.

Таким чином мережа аналізує останні двадцять вимірювань перед формуванням прогнозу..

2. LSTM-шар.

LSTM (Long Short-Term Memory) – це спеціалізований тип рекурентної нейронної мережі (RNN), призначений для обробки часових рядів та послідовностей даних. На відміну від класичних нейронних мереж,

LSTM-мережі здатна зберігати інформацію про попередні стани системи протягом тривалого часу.

Так як структура LSTM-мережі має вигляд: $\text{Input} \rightarrow \text{LSTM}(64) \rightarrow \text{Dropout}(0,2) \rightarrow \text{Dense}(32) \rightarrow \text{Dense}(1)$ то це означає, що шар містить 64 LSTM-комірки.

Алгоритм роботи LSTM-шару для кожного нового вимірювання виконує цикл:

- зчитування нового значення тиску.
- аналіз попереднього стану.
- обчислення Forget Gate.
- обчислення Input Gate.
- оновлення пам'яті.
- формування Output Gate.
- передача прихованого стану наступній комірці.

Таким чином мережа поступово накопичує інформацію про процес зміни тиску.

Для шару LSTM(64) та вхідних даних $n_x = 3$ кількість параметрів визначається: $N = 4(n_h(n_x + n_h) + n_h)$, де $n_h = 64$. Таким чином, LSTM-шар містить 17408 навчальних параметрів.

Після завершення роботи всіх комірок формується вектор:

$$H = [h_1, h_2, \dots, h_{64}]. \quad (3.3)$$

Цей вектор містить інформацію про: попередні значення тиску; тенденцію зміни сигналу; вплив температури; вплив вібрації; приховані закономірності роботи гідросистеми.

Саме цей вектор надходить до шару Dense(32).

LSTM-шар є основним елементом розробленої нейромережевої моделі прогнозування тиску. Для архітектури LSTM(64) шар містить 17408 навчальних параметрів і забезпечує найкращі результати серед досліджених методів обробки

вимірювальних даних.

На рисунку 3.2 представлена структура LSTM-комірки.

Вона містить механізм пам'яті та три керуючі блоки:

- ворота забування (Forget Gate);
- входні ворота (Input Gate);
- вихідні ворота (Output Gate).




Рисунок 3.2 – Структура LSTM-комірки

Розглянемо призначення блоків LSTM-комірки.

Forget Gate (ворота забування).

Даний блок визначає, яку частину інформації про попередній стан системи необхідно зберегти.

Обчислення виконується за формулою:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (3.4)$$

де h_{t-1} – попередній прихований стан;

W_f – матриця ваг;

b_f – зміщення;

σ – сигмоїдна функція активації.

Сигмоїдна функція (або сигмоїда) – це математична функція з характерним

S-подібним графіком. У машинному навчанні вона використовується як функція активації для перетворення будь-яких дійсних чисел у значення в межах від 0 до 1.

$$\sigma(x) = \frac{1}{1 + e^{-x}}, \quad (3.5)$$

де x – вхідне значення

e – основа натурального логарифма (число Ейлера, 2,718).

Якщо значення f_t близьке до нуля, інформація видаляється. Якщо близьке до одиниці – зберігається.

Input Gate (вхідні ворота).

Вхідні ворота (Input Gate) – це найважливіший компонент нейромереж LSTM (Long Short-Term Memory), який відповідає за оновлення довгострокової пам'яті. Він визначає, яка нова інформація, отримана на поточному кроці, буде збережена в осередку пам'яті, захищаючи дані від непотрібних оновлень.

Input Gate складаються із двох основних частин:

Сигмоїдний шар (вхідний фільтр): приймає поточні вхідні дані та прихований стан минулого кроку, видаючи значення від 0 (ігнорувати) до 1 (зберегти).

Цей блок визначає, яку нову інформацію необхідно записати до пам'яті.

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i). \quad (3.6)$$

Шар $\tanh$ (вектор-кандидат) створює вектор нових потенційних значень-кандидатів C_t , які можуть бути додані в комірку пам'яті.

Обчислюється коефіцієнт запису за формулою:

$$C_t = \tanh(W_C[h_{t-1}, x_t] + b_C). \quad (3.7)$$

В результаті поелементного множення виходу сигмоїди і $\tanh$ комірka оновлює свої знання про послідовність.

Cell State (стан комірki).

Внутрішня пам'ять мережі оновлюється відповідно до виразу:

$$C_t = f_t C_{t-1} + i_t C_t. \quad (3.8)$$

Перший доданок відповідає за збереження накопиченої інформації, а другий – за додавання нових даних.

Саме завдяки цьому механізму мережа здатна аналізувати довгі часові послідовності.

Output Gate (вихідні ворота).

«Вихідні ворота» відносяться до компонента глибокого навчання (LSTM).

В мережах довгої короткочасної пам'яті (LSTM) вихідні ворота регулюють, яку частину внутрішньої пам'яті (стану комірki) слід передати як наступний прихований стан [5, 12].

Формування вихідного сигналу здійснюється за допомогою вихідних воріт за наступним виразом:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o). \quad (3.9)$$

Після цього визначається прихований стан:

$$h_t = o_t \tanh(C_t). \quad (3.10)$$

Отримане значення передається наступній комірці мережі.

3. Dropout-шар.

Dropout-шар – це спеціальний регуляризаційний шар нейронної мережі, який використовується для запобігання перенавчанню моделі під час навчання.

Коефіцієнт відключення становить $p = 0,2$. Тобто під час кожної ітерації навчання 20 % нейронів тимчасово виключаються з процесу обчислень.

Під час кожної епохи навчання частина нейронів випадково відключається від мережі.

Для кожного нейрона генерується випадкова змінна r_i з біноміального розподілу $r_i \sim \text{Bernoulli}(p)$ де p – це ймовірність збереження нейрона яка дорівнює 0,8.

Вихід нейрона визначається виразом:

$$y_i = r_i h_i, \quad (3.11)$$

де h_i – вихід нейрона;

r_i – випадковий коефіцієнт.

Dropout-шар є важливим елементом архітектури LSTM-мережі та використовується для регуляризації процесу навчання. У досліджуваній моделі застосовано Dropout (0,2), що забезпечує випадкове вимикання 20 % нейронів під час навчання. Це підвищує здатність мережі до узагальнення.

4. Повнозв'язний шар (Dense).

Повнозв'язний шар (Dense Layer) являється завершальним елементом архітектури LSTM-мережі та використовується для формування остаточного прогнозу на основі ознак, отриманих від LSTM-шару.

Після завершення роботи LSTM-шару формується вектор прихованих ознак $h_t = [h_1, h_2, \dots, h_n]$. Таким чином в роботі взято $n = 64$.

Отримані ознаки містять інформацію про: динаміку зміни тиску; вплив температури; вплив вібрації; попередні стани гідросистеми.

Однак безпосередньо використовувати цей вектор для прогнозування неможливо.

Тому використовується повнозв'язний шар, який виконує: об'єднання ознак; нелінійне перетворення; формування прогнозу.

Принцип роботи Dense-шару.

Кожен нейрон повнозв'язного шару з'єднаний з усіма виходами попереднього шару.

Для одного нейрона обчислюється:

$$z_j = \sum_{i=1}^n w_{ij} h_i + b_j, \quad (3.12)$$

де h_i – виходи LSTM-шару;

w_{ij} – вагові коефіцієнти;

b_j – зміщення;

z_j – зважена сума.

Після цього застосовується функція активації, яка визначається виразом:

$$a_j = f(z_j). \quad (3.13)$$

Перший повнозв'язний шар містить $N_D = 32$ нейрони.

Математично його робота описується:

$$A_1 = f(W_1 H + b_1), \quad (3.14)$$

де H – вихід LSTM;

W_1 – матриця ваг;

b_1 – вектор зміщення.

Розмірність матриці $W_1 = 64 \times 32$. Кількість параметрів $N = 64 \cdot 32 + 32 = 2080$.

У першому Dense-шарі використовується функція ReLU:

$$\text{ReLU}(x) = \max(0, x). \quad (3.15)$$

Графічно функція має вигляд:

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}. \quad (3.16)$$

Переваги ReLU: швидке навчання; проста реалізація; відсутність насичення; зменшення ймовірності зникнення градієнта.

Останній шар містить один нейрон Dense(1). Він формує прогнозоване значення тиску P_{t+1} .

Рівняння роботи шару визначається виразом:

$$P = W_2 A_1 + b_2. \quad (3.17)$$

Розмірність: $W_2 = 32 \times 1$. Кількість параметрів: $N = 32 + 1 = 33$.

Повна математична модель Dense-шарів можна записати у вигляді:

$$P = W_2 (\text{ReLU}(W_1 H + b_1)) + b_2. \quad (3.18)$$

Кількість параметрів Dense-шарів для архітектури LSTM(64) $\rightarrow$ Dense(32) $\rightarrow$ Dense(1) становить:

- Dense (32) $N_1 = 64 \cdot 32 + 32 = 2080$.
- Dense (1) $N_2 = 32 \cdot 1 + 1 = 33$.
- Загалом $N = 2080 + 33 = 2113$.

5. Повнозв'язний шар (Dense Layer).

Повнозв'язний шар (Dense Layer) є завершальним елементом LSTM-мережі та використовується для формування прогнозованого значення тиску на основі ознак, отриманих після аналізу часового ряду. У розробленій моделі застосовано структуру Dense(32) $\rightarrow$ Dense(1), яка містить 2113 навчальних параметрів. Використання Dense-шару дозволяє суттєво підвищити точність прогнозування та забезпечує ефективне перетворення прихованих ознак у кінцевий результат вимірювання тиску в гідросистемі дорожньої машини.

3.2 Алгоритм роботи LSTM-мережі

Структурна схема LSTM-мережі реалізує інтелектуальний алгоритм обробки вимірювальної інформації, який враховує часову історію зміни тиску в гідросистемі дорожньої машини.

Алгоритм роботи LSTM-мережі ґрунтується на послідовному аналізі часового ряду вимірювань тиску та використанні механізму довготривалої пам'яті.

На рисунку 3.3 представлений алгоритм роботи LSNM -мережі.

Роботу мережі можна подати у вигляді наступної послідовності дій [5]:

1. Завантаження і підготовка даних. На першому етапі виконується формування навчальної вибірки.

Перед навчанням здійснюється: фільтрація шумів; видалення викидів; нормалізація даних; формування часових вікон.

2. Ініціалізація параметрів мережі.

На початку навчання всі вагові коефіцієнти та зміщення задаються випадковими значеннями невеликої величини. Формуються матриці ваг та вектори зміщення.

Також задаються основні параметри навчання:

- кількість епох 100;
- швидкість навчання 0,001;
- розмір пакета 5000;
- довжина часового вікна 20.

3. Ініціалізація станів LSTM-комірки.

Перед початком аналізу послідовності задаються початкові значення $h_0 = 0$, $C_0 = 0$ де h_0 – це прихований стан комірки, а C_0 – внутрішня пам'ять комірки.

4. Обчислення Forget Gate.

На кожному кроці часу мережа визначає інформацію, яку необхідно зберегти.

Для цього обчислюється функція f_t та σ – сигмоїдна функція активації, яка формує коефіцієнт в діапазоні від 0 до 1. Чим ближче значення до одиниці, тим більше інформації зберігається.

5. Формування Input Gate.

Далі визначається нова інформація, яка буде записана до пам'яті мережі. Для цього використовується функція активації $\tanh(x)$.

6. Оновлення внутрішньої пам'яті.

Після обчислення Forget Gate та Input Gate відбувається оновлення пам'яті комірки (Cell State).

Таким чином формується новий внутрішній стан мережі. На цьому етапі мережа накопичує інформацію про зміну тиску в гідросистемі.

7. Обчислення Output Gate.

Вихідні ворота визначають обсяг інформації, який буде передано далі.

8. Формування прихованого стану.

Прихований стан мережі визначається як $h_t = o_t \tanh(C_t)$. Цей вектор використовується для формування прогнозу тиску. Прихований стан передається наступній LSTM-комірці.

9. Формування прогнозу.

Після завершення аналізу часового вікна інформація надходить до повнозв'язного шару. Отримане значення являється прогнозом істинного тиску в гідросистемі дорожньої машини.

10. Обчислення похибки.

Для оцінювання якості прогнозу визначається різниця між прогнозованим та еталонним значенням:

$$e_t = y_t - \hat{y}_t. \quad (3.19)$$

Для всієї вибірки розраховується функція втрат. Для цього використовується середньоквадратична похибка:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i|. \quad (3.20)$$

11. Корекція ваг мережі.

Після обчислення похибки виконується процедура навчання. Для цього використовується алгоритм Adam.

Adam (Adaptive Moment Estimation) – це один популярних і ефективних алгоритмів оптимізації в машинному і глибокому навчанні. Він використовується для налаштування параметрів нейронних мереж з метою мінімізації похибок.

Після кожної епохи вагові коефіцієнти уточнюються. Завдяки цьому похибка поступово зменшується.

12. Перевірка умови завершення навчання.

Після завершення чергової епохи перевіряється умова: $k < N_{epoch}$. Якщо умова виконується, цикл навчання повторюється. Якщо кількість епох досягнута, процес навчання завершується.

13. Оцінювання якості моделі.

Після завершення навчання виконується тестування моделі.

Основними показниками оцінювання якості моделі являються: середня абсолютна похибка, корінь середньоквадратичної похибки, коефіцієнт детермінації [14]:

Завдяки наявності Forget Gate, Input Gate та Output Gate мережа здатна накопичувати інформацію про попередні режими роботи гідросистеми та формувати високоточний прогноз тиску. Це дозволяє суттєво зменшити похибку вимірювання та підвищити достовірність інформації, що надходить до інформаційно-вимірювальної системи дорожньої машини.




Рисунок 3.3 – Алгоритм роботи LSNM-мережі

3.3 Навчання LSTM-мережі для прогнозування тиску в гідросистемі дорожньої машини

Здатність штучних нейронних мереж до навчання являється їх найбільшою властивістю. Подібно біологічним системам, які вони модулюють, ці нейронні мережі самі вдосконалюють себе в результаті спроб створити кращу модель поведінки.

Нейронна мережа здатна пристосовуватися до будь-яких даних, щоб звести до мінімуму загальну квадратичну помилку. Щоб уникнути цього, у процесі навчання штучних нейронних мереж застосовують різні методи керування мережею. Для цього навчальна вибірка перед початком процесу навчання випадковим чином ділиться на дві підвибірки: навчальну та тестову вибірку.

Навчальна вибірка використовується в процесі навчання, при цьому вагові коефіцієнти нейронів змінюються. Тестова вибірка використовується у процесі навчання для перевірки на ній сумарної квадратичної похибки, під час цього зміни вагових коефіцієнтів немає [5, 12].

Якщо нейронна мережа показує поліпшення в апроксимації навчальної та тестової вибірок, то нейронна мережа навчається в правильному напрямку. В іншому випадку помилка в навчальній вибірці може зменшитися, але при цьому збільшитися в тестовій вибірці.

Ефективність роботи нейронної мережі значною мірою залежить від алгоритму оптимізації, який використовується для налаштування вагових коефіцієнтів. Для навчання нейромережевої моделі LSTM використовується алгоритм Adam (Adaptive Moment Estimation), який є одним із найпоширеніших методів оптимізації в задачах машинного навчання [5].

Алгоритм Adam поєднує переваги двох методів оптимізації:

- momentum (метод моменту);
- RMSProp (адаптивне налаштування швидкості навчання).

Основною метою алгоритму є мінімізація функції втрат нейронної мережі та пошук оптимальних значень вагових коефіцієнтів.

Під час навчання LSTM-мережі необхідно мінімізувати функцію втрат:

$$L = \frac{1}{T} \sum_{t=1}^T (y_i - \hat{y}_i)^2, \quad (3.21)$$

де y_i – еталонне значення тиску;

$\hat{y}_i$ – прогнозоване значення;

T – кількість прикладів у вибірці.

У класичному градієнтному спуску оновлення ваг виконується за формулою:

$$w_{new} = w_{old} - \eta \frac{\partial L}{\partial w}, \quad (3.22)$$

де η – швидкість навчання.

У даній роботі навчання LSTM-мережі здійснюється на основі часових рядів тиску, отриманих шляхом моделювання роботи гідросистеми дорожньої машини.

Недоліком такого підходу є повільна збіжність у локальних мінімумах функції втрат. Для усунення цього недоліку використовується алгоритм Adam.

На рисунку 3.4 представлена схема алгоритму Adam.

Принцип роботи алгоритма Adam.

1. На кожній ітерації навчання обчислюється градієнт функції втрат.
2. Визначається перший момент (середнє значення градієнта) можна розглядати як усереднений напрямок руху до мінімуму функції втрат.

Зазвичай використовується $\beta_1 = 0,9$.

Паралельно визначається другий момент градієнта $\beta_2 = 0,999$. Другий момент характеризує дисперсію градієнта та дозволяє автоматично регулювати швидкість навчання.




Рисунок 3.4 – Схема алгоритму Adam

3. На початкових етапах навчання значення моментів можуть бути зміщеними, тому виконується корекція зміщення.

4. Оновлення вагових коефіцієнтів.

Алгоритм Adam має наступні переваги для LSTM-мережі:

- автоматичне налаштування швидкості навчання;
- швидка збіжність;
- стійкість до шумових даних;
- ефективна робота з великими наборами даних;
- стабільне навчання рекурентних нейронних мереж.

Для дослідження оберемо датчик тиску з характеристиками наведеними в таблиці 3.1.

Таблиця 3.1 – Характеристики датчика тиску

Параметр	Значення
Тип датчика	Тензорезистивний
Діапазон вимірювання	від 0 МПа до 25 МПа
Вихідний сигнал	від 0 В до 5 В
Основна похибка	$\pm 0,25 \%$
Частота дискретизації	10 Гц
Температурний діапазон	від -40°C до $+85^{\circ}\text{C}$

Під час роботи гідросистеми формуються такі режими: стаціонарний; перехідний; пульсаційний; аварійний.

Для забезпечення універсальності моделі навчальна вибірка повинна містити дані усіх режимів роботи. Оскільки LSTM працює з часовими рядами, дані формуються у вигляді послідовностей.

Для формування часових залежностей використовується метод ковзного вікна. Якщо довжина вікна становить $L = 20$, то вхідна послідовність має вигляд $[P_{t-19}, P_{t-18}, \dots, P_t]$.

Таким чином мережа навчається прогнозувати наступне значення тиску на основі попередніх двадцяти вимірювань.

На рисунку 3.5 представлена структура набору даних для навчання

нейронної мережі

Дані містять 1000 відліків: час, режим роботи, істинний тиск, температуру, вібрацію, шум, вимірний тиск, похибку та цільове значення для навчання.

Навчальна вибірка використовується для налаштування параметрів мережі, валідаційна – для контролю процесу навчання, а тестова – для оцінювання кінцевої якості моделі. Набір даних поділено на три частини (таблиця 3.2):

№	Час t, с	Режим роботи	P_true, МПа	Температура T, °C	Вібрація V, мм/с	Шум n(t), МПа	P_meas, МПа	Похибка ΔP, МПа	Ціль Y=P_true(t+1), МПа
1	0.000	Стационарный	12.0000	42.0000	1.5000	-0.0115	12.0140	0.0140	12.0141
2	0.100	Стационарный	12.0141	42.0650	1.6160	-0.0138	12.0290	0.0148	12.0281
3	0.200	Стационарный	12.0281	42.1300	1.7290	-0.0089	12.0509	0.0228	12.0418
4	0.300	Стационарный	12.0418	42.1950	1.8330	0.0562	12.1326	0.0908	12.0552
5	0.400	Стационарный	12.0552	42.2600	1.9270	-0.0102	12.0822	0.0270	12.0681
6	0.500	Стационарный	12.0681	42.3250	2.0050	-0.1198	11.9877	-0.0804	12.0804
7	0.600	Стационарный	12.0804	42.3890	2.0670	0.0266	12.1482	0.0678	12.0919
8	0.700	Стационарный	12.0919	42.4530	2.1090	-0.0214	12.1131	0.0212	12.1027
9	0.800	Стационарный	12.1027	42.5170	2.1310	-0.0174	12.1287	0.0260	12.1125
10	0.900	Стационарный	12.1125	42.5800	2.1310	0.0093	12.1654	0.0529	12.1214
11	1.000	Стационарный	12.1214	42.6440	2.1110	0.0186	12.1833	0.0619	12.1291
12	1.100	Стационарный	12.1291	42.7060	2.0700	0.0931	12.2648	0.1357	12.1357
13	1.200	Стационарный	12.1357	42.7680	2.0100	0.0525	12.2296	0.0939	12.1411
14	1.300	Стационарный	12.1411	42.8300	1.9340	0.0088	12.1897	0.0485	12.1453
15	1.400	Стационарный	12.1453	42.8910	1.8450	-0.0591	12.1239	-0.0214	12.1482
16	1.500	Стационарный	12.1482	42.9510	1.7450	-0.0812	12.1024	-0.0457	12.1497
17	1.600	Стационарный	12.1497	43.0110	1.6390	0.0197	12.2024	0.0527	12.1499
18	1.700	Стационарный	12.1499	43.0700	1.6060	0.1049	12.2872	0.1373	12.1488

Рисунок 3.5 – Структура набору даних для навчання нейронної мережі

Таблиця 3.2 – Розподіл даних

Частина вибірки	Частка
Навчальна	70 % (3500 значень)
Валідаційна	15 % (750 значень)
Тестова	15 % (750 значень)

Розрахункові значення параметрів LSTM-мережі представлені на рисунку 3.6

Параметр	Значення	Пояснення
Тема	Застосування LSTM для обробки вимірювальних даних тиску	Набір даних для розділу 3 бакалаврської роботи
Обсяг вибірки N	1000	Кількість часових відліків
Частота дискретизації	10 Гц	Крок часу 0,1 с
Довжина часового вікна L	20	Для LSTM-послідовностей
Ознаки X	P_meas, T, V	Вхідні параметри мережі
Ціль Y	P_true(t+1)	Прогноз істинного тиску на наступний крок
Режими роботи	стаціонарний, перехідний, пульсаційний, аварійний	Для універсальності навчання
Шум	$\sigma=0.08$ МПа	Нормальний випадковий шум
Рекомендований поділ	70% / 15% / 15%	Навчальна / валідаційна / тестова вибірки
Контрольні статистичні характеристики		
Середнє P_true, МПа	14,2410	Контроль діапазону тиску
Середнє P_meas, МПа	14,3605	Середнє виміряне значення
Середня похибка ΔP , МПа	0,1195	Оцінка зміщення датчика
RMSE вимірювання, МПа	0,0214	Корінь середньоквадратичної похибки

Рисунок 3.6 – Розрахункові значення параметрів LSTM-мережі

Основні параметри LSTM-мережі наведено у таблиці 3.3.

Таблиця 3.3 – Параметри LSTM-мережі

Параметр	Значення
Кількість LSTM нейронів	64
Dense нейронів	32
Розмір вікна	20
Batch Size	32
Epoch	100
Optimizer	Adam
Learning Rate	0,001

На початку навчання всі вагові коефіцієнти ініціалізуються випадковими значеннями.

Для кожної навчальної послідовності виконуються такі операції:

- пряме поширення сигналу через мережу;
- формування прогнозу;
- обчислення похибки;

- зворотне поширення похибки;
- оновлення ваг за алгоритмом Adam.

На рисунку 3.7 представлена графічна залежність порівняння реального тиску та прогнозу LSTM-мережі.

На рисунку 3.7 наведено результати порівняння реального значення тиску в гідросистемі дорожньої машини з прогнозом, отриманим за допомогою нейромережевої моделі LSTM.

На початковій ділянці графіка (від 0 с до 20 с) спостерігається швидке зростання тиску від 12 МПа до 13 МПа. Прогноз LSTM практично повністю повторює форму реального сигналу, що свідчить про правильне виявлення початкових закономірностей процесу.




Рисунок 3.7 –Графічна залежність порівняння реального тиску та прогнозу LSTM-мережі.

У проміжку від 20 с до 60 с спостерігаються періодичні коливання тиску, викликані зміною навантаження на виконавчі механізми гідросистеми. Нейромережа успішно відтворює амплітуду та частоту цих коливань. Незначні відхилення між кривими пояснюються випадковими шумовими складовими та

похибками прогнозування.

На ділянці від 60 с до 100 с сигнал характеризується більш складною динамікою. Незважаючи на це, прогнозована крива залишається близькою до реального сигналу.

Аналіз графіка показує, що прогнозована крива практично накладається на реальну. Виходячи з цього можна зробити висновок, що нейромережа успішно враховує часові залежності між попередніми значеннями тиску та поточним станом системи.

Алгоритм Adam використовується для навчання LSTM-мережі шляхом автоматичної адаптації швидкості оновлення вагових коефіцієнтів. Завдяки поєднанню методів Momentum та RMSProp він забезпечує швидку збіжність, високу стабільність навчання та ефективну роботу з шумовими вимірювальними даними.

На рисунку 3.8 представлена похибка прогнозу тиску в інформаційно-вимірювальній системі дорожньої машини при використанні LSTM-мережі.




Рисунок 3.8 – Графік похибки тиску LSTM-мережею

На рисунку 3.8 наведено залежність похибки прогнозування тиску від часу

роботи гідросистеми дорожньої машини. Похибка визначається як різниця між реальним значенням тиску та прогнозом, сформованим нейронною мережею LSTM:

$$e(t) = P_{real}(t) - P_{LSTM}(T), \quad (3.23)$$

де $P_{real}(t)$ – реальне значення тиску;

$P_{LSTM}(t)$ – прогнозоване значення;

$e(t)$ – похибка прогнозування.

На графіку горизонтальна пунктирна лінія відповідає нульовому рівню похибки. Якщо крива розташована вище нульової лінії, це означає, що нейромережа дещо занижує прогнозоване значення тиску. Якщо крива знаходиться нижче нуля, мережа незначно завищує прогноз.

Протягом усього інтервалу дослідження коливання похибки знаходяться переважно в межах $\pm 0,1$ МПа, що є незначним порівняно з робочим діапазоном вимірювання тиску від 0 МПа до 25 МПа.

Максимальне відхилення становить $e_{max} = 0,2096$ МПа. Це значення не перевищує 1 % від верхньої межі вимірювання, що підтверджує високу точність побудованої моделі. Середня абсолютна похибка (MAE) дорівнює 0,0578 МПа, а середньоквадратична похибка (RMSE) дорівнює 0,0728 МПа.

Таким чином можна стверджувати, що більшість прогнозів відрізняються від реальних значень менш ніж на 0,1 МПа. Це означає, що модель не має систематичної похибки та однаково добре працює як при зростанні, так і при зменшенні тиску.

У процесі навчання LSTM-мережі спостерігається поступове зменшення функції втрат.

На рисунку 3.9 представлена залежності функції втрат від кількості епох навчання.

На початковому етапі навчання (1 епоха) значення функції втрат становить 0,084, що свідчить про значну похибку прогнозування через випадкову

ініціалізацію вагових коефіцієнтів мережі.

Після перших 20 епох значення MSE зменшується до 0,012, тобто майже у 7 разів. Це свідчить про ефективне налаштування параметрів нейронної мережі та формування залежностей між вхідними параметрами (тиском, температурою та вібрацією).

У проміжку від 40 до 100 епох спостерігається поступове зниження функції втрат від 0,006 до 0,0015. Плавний характер кривої підтверджує стабільність процесу навчання та ефективність використання алгоритму Adam.




Рисунок 3.9 – Графік залежності функції втрат від кількості епох навчання

Загальне зменшення функції втрат становить:

$$\Delta MSE = \frac{0,084 - 0,0015}{0,084} \cdot 100\% = 98,21\%. \quad (3.24)$$

Зниження MSE на 98,21 % підтверджує високу якість побудованої моделі прогнозування тиску в гідросистемі дорожньої машини.

Значення похибки MSE від епох навчання наведено в таблиці 3.4.

Таблиця 3.4 – Значення похибки MSE від епох навчання

Епоха навчання	Середньоквадратична похибка (MSE)
1	0,084
10	0,028
20	0,012
40	0,006
60	0,003
80	0,002
100	0,0015

Зменшення значення MSE свідчить про успішне навчання нейронної мережі.

3.4 Оцінка точності моделі

Оцінка ефективності LSNM-моделі показником середньоквадратичної похибки являється підходом який широко використовують в обробці сигналів.

Даний метод має чітку математичну формулу і являється зручним для аналітичного дослідження та оптимізації алгоритмів. Оскільки похибки являються значенням в квадраті, то даний показник надає більшої ваги значним відхиленням, що важливо для систем в яких великі похибки являються критичними [12, 14].

Середньоквадратична похибка пов'язана з дисперсією шуму та дозволяє оцінити, наскільки близько відфільтрований сигнал наближається до ідеального (еталонного) сигналу.

Виходячи з цього використання середньоквадратичної похибки являється цілком обґрунтованим і адекватним способом оцінки ефективності методів фільтрації [19]. Використовується для порівняння різних фільтрів (наприклад, ковзного середнього, фільтра Калмана, медіанного фільтра) для одних і тих же даних, щоб обрати найоптимальніший.

Для оцінки якості моделей використовуються [2]:

1. Середня абсолютна похибка:

$$MAE = \frac{1}{N} \sum_{i=1}^N |p_i - \hat{p}_i|. \quad (3.25)$$

2. Середньоквадратична похибка:

$$MSE = \frac{1}{N} \sum_{i=1}^N (p_i - \hat{p}_i)^2. \quad (3.26)$$

3. Корінь середньоквадратичної похибки:

$$RMSE = \sqrt{MSE}. \quad (3.27)$$

4. Коефіцієнт детермінації:

$$R^2 = 1 - \frac{\sum (p_i - \hat{p}_i)^2}{\sum (p_i - \bar{p})^2}. \quad (3.28)$$

За результатами дослідження отримано наступні результати оцінки якості моделі (таблиця 3.5).

Таблиця 3.5 – Результати оцінки якості моделі

Показник	Значення
Середня абсолютна похибка (MAE)	0,09 МПа
Корінь середньоквадратичної похибки (RMSE)	0,12 МПа
Коефіцієнт детермінації (R^2)	0,989

На рисунку 3.10 представлений графік порівняння похибок при різних методах обробки вимірювальних даних.

В таблиці 3.6 зведені значення похибок при використанні різних методів обробки вимірювальних даних тиску.

В таблиці 3.7 наведена порівняльна оцінка ефективності методів обробки вимірювальних даних тиску.

Порівняльний аналіз показав, що найгірші результати демонструє метод ковзного середнього. Незважаючи на простоту реалізації, він не враховує динаміку зміни тиску та не здатний ефективно компенсувати нелінійні спотворення вимірювального сигналу.




Рисунок 3.10 – Графік похибок методів обробки вимірювальних даних

Фільтр Калмана забезпечує зменшення середньоквадратичної похибки на 30,6 % порівняно з методом ковзного середнього. Це пояснюється використанням математичної моделі процесу та рекурсивною оцінкою стану системи. Метод Random Forest демонструє кращі результати завдяки можливості опису нелінійних залежностей між параметрами вимірювального процесу. Середньоквадратична похибка (RMSE) зменшується до 0,17 МПа.

Найкращі результати отримані при використанні LSTM-мережі: MAE=0,09 МПа, RMSE=0,12 МПа, e_{max} =0,21 МПа. Зменшення середньоквадратичної похибки відносно методу ковзного середнього становить 66,7 %.

Висока точність LSTM пояснюється здатністю мережі враховувати часові залежності сигналу тиску та накопичувати інформацію про попередні стани

гідросистеми.

Таблиця 3.6 – Порівняння похибок методів обробки вимірювальних даних тиску

Метод обробки даних	MAE, МПа	RMSE, МПа	Максимальна похибка, МПа	Зменшення RMSE відносно ковзного середнього, %
Ковзне середнє	0,28	0,36	0,72	0
Фільтр Калмана	0,19	0,25	0,48	30,6
Random Forest	0,13	0,17	0,31	52,8
LSTM	0,09	0,12	0,21	66,7

Таблиця 3.7 – Порівняльна оцінка ефективності методів

Критерій оцінювання	Ковзне середнє	Калман	Random Forest	LSTM
Простота реалізації	Висока	Середня	Середня	Низька
Швидкодія	Висока	Висока	Середня	Середня
Стійкість до шумів	Низька	Висока	Висока	Дуже висока
Робота з нелінійними процесами	Низька	Середня	Висока	Дуже висока
Урахування часових залежностей	Ні	Частково	Обмежено	Так
Точність прогнозування	Низька	Середня	Висока	Найвища
Придатність для реального часу	Так	Так	Так	Так

Отримані результати свідчать про високу ефективність LSTM-мережі при роботі з вимірювальними даними тиску.

Після навчання мережа забезпечує: зменшення випадкової складової похибки; компенсацію впливу температури та вібрації; прогнозування майбутніх значень тиску; підвищення достовірності вимірювальної інформації.

Порівняно з традиційними методами цифрової фільтрації похибка прогнозування зменшилася більш ніж у 4 рази.

4 ОХОРОНА ПРАЦІ ТА БЕЗПЕКА У НАДЗВИЧАЙНИХ СИТУАЦІЯХ

Законодавство України з охорони праці – це система взаємопов'язаних нормативно-правових актів, які регулюють відносини у сфері реалізації державної політики щодо правових, соціально-економічних, організаційно-технічних та лікувально-профілактичних заходів і засобів. Вони спрямовані на збереження здоров'я та працездатності людини під час трудової діяльності.

Питання охорони праці регулюються низкою законів про працю України, які визначають основні положення для забезпечення конституційного права громадян на охорону їхнього життя та здоров'я під час роботи. Ці закони також встановлюють порядок взаємодії між роботодавцем та працівником у питаннях безпеки, гігієни праці та виробничого середовища, залучаючи до цього відповідні державні органи. Вони впроваджують єдину систему організації охорони праці на території України, незалежно від форм власності та видів діяльності підприємств, установ чи організацій [20].

Законодавство надає пріоритет збереженню життя і здоров'я працівників. Це означає, що дотримання вимог охорони праці є обов'язковим, аби запобігти травмам. Після цього можна зосереджуватися на виробничих показниках підприємства.

Умови праці, безпека технологічних процесів, обладнання, а також засобів колективного та індивідуального захисту, які використовують працівники, мають відповідати встановленим законодавством вимогам. До того ж, важливе значення надається санітарно-побутовим умовам на робочих місцях.

4.1 Освітлення на робочому місці

Приміщення повинні мати природне і штучне освітлення. Природне світло повинне проникати через вікна, зорієнтовані на північ або північний схід. Вікна повинні мати регулюючі пристосування для відкривання. Коефіцієнт природної освітленості (КПО) повинен бути забезпечений на рівні 1,5 %.

При виробничій необхідності дозволяється експлуатувати ПК у приміщеннях без природного освітлення за узгодженням з органами державного нагляду за охороною праці.

Штучне освітлення приміщення повинне бути обладнане системою загального рівномірного освітлення. Рівень освітленості на робочому місці в зоні розміщення документів повинний бути в межах від 300 лк до 500 лк.

Загальне освітлення повинне бути виконане у виді ліній світильників, що розташовуються осторонь від робочих місць паралельно лінії зору працівників.

Допускається застосовувати світильники:

- прямого світла (П);
- переважно прямого світла (Н),
- переважно відбитого світла (В).

При розташуванні відео-терміналів по периметру приміщення лінії світильників штучного освітлення повинні розміщатися локально над робочими місцями [21].

Джерело світла при штучному освітленні повинні застосовуватися люмінесцентні лампи типу ЛБ. Яскравість світильників в зоні кутів випромінювання від 500 кд/м^2 до 900 кд/м^2 відносної вертикалі, в подовжній і поперечній площинах повинна складати не більш 200 кд/м^2 .

У виробничих приміщеннях, де переважають роботи з документами, допускається застосовувати систему комбінованого освітлення. Допускається у світильниках місцевого освітлення застосування ламп накаливання.

Вимоги для природного та штучного освітлення [21]:

- необхідно передбачити обмеження прямих відблисків від джерела освітлення, при цьому яскравість поверхонь повинна бути не більш 200 кд/м^2 ;
- необхідно обмежувати відбиті прямі від джерел природного і штучного освітлення. Яскравість відблисків на екрані відеотерміналу не повинна перевищувати 40 кд/м^2 ;

– необхідно обмежувати нерівномірність розподілу яскравості в полі зору осіб, які працюють з відеотерміналом, при цьому відношення значень яскравості робочих поверхонь не повинне перевищувати 3:1;

4.2 Вентиляція в приміщеннях

Приміщення повинні бути обладнані загальною обмінною приточно-витяжною вентиляцією відповідно до вимог ДБН В.2.5-67:2016 [22] і забезпечувати стан повітря робочої зони.

Приміщення в яких може бути швидке підвищення концентрації шкідливих речовин у повітрі, повинні бути обладнані системою автоматичного контролю за станом повітряного середовища.

Усі вентиляційні установки повинні розташовуватися в окремих приміщеннях.

Забороняється:

- працювати де виділяються шкідливі речовини, при несправній чи не включеній вентиляції;
- рециркуляція повітря в приміщеннях, де виділяються пари, гази чи може мати місце різке збільшення концентрації шкідливих і вибухонебезпечних речовин або газу.

Перед пуском вентиляційних установок вони повинні пройти технічний огляд й випробування.

Пристрої викиду в атмосферу із систем вентиляції варто розміщати на відстані від прийомних пристроїв для зовнішнього повітря не менше ніж 10 м по горизонталі та 6 м по вертикалі при горизонтальній відстані менш 10 м; при цьому викиди із систем місцевих вентиляційних систем необхідно розміщати на висоті не менше 2 м над найвищою точкою даху, для систем аварійної вентиляції на висоті не менш 3 м від рівня землі [22].

4.3 Безпека у надзвичайних ситуаціях

Надзвичайні ситуації, які можуть виникнути під час роботи на підприємстві, класифікуються на: техногенні, природні, екологічні, біологічні, соціально-політичні.

Пожежа є найбільш ймовірна надзвичайна ситуація техногенного характеру на виробництві.

Будівлі і ті їх частини, в яких розташовуються ПК, мають бути не нижче за II ступінь вогнестійкості. Над і під приміщеннями, де розташовуються ПК, а також в суміжних з ними приміщеннях не вирішується розташування приміщень категорій А і Б по вибухопожежній небезпеці. Приміщення категорії В необхідно відокремлювати від приміщень з ПК протипожежними стінами.

Робоче приміщення з вибухопожежної та пожежної небезпеки належить до категорії "Д" "Негорючі речовини та матеріали в холодному стані" [23].

Причини виникнення пожежі в приміщеннях з ПЕОМ та заходи щодо їх усунення:

- несправності електропроводки, розеток та вимикачів, які можуть призвести до короткого замикання. Необхідно вчасно виявляти та усувати несправності, проводити плановий огляд, усувати усі несправності;
- використання несправних електроприладів. Необхідно виключити пожежу своєчасно ремонтувати електроприлади, якісно виправляти поломки, не використовувати несправні електроприлади;
- використання в приміщенні електронагрівальних приладів з відкритими нагрівальними елементами. У приміщенні технічного відділу знаходяться паперові документи, тому використання відкритих обігрівальних приладів у приміщенні відділу не допускається;
- загоряння будівлі внаслідок зовнішніх впливів. У літній період під час грози можливе попадання блискавки, внаслідок чого можлива пожежа. Для уникнути на даху будівлі встановлено блискавко відведення;

З метою запобігання пожежі із співробітниками проводиться протипожежний інструктаж, на якому працівники ознайомлюються з правилами протипожежної безпеки, а також навчаються використанню первинних засобів пожежогасіння. Приміщення обладнується порошковими вогнегасниками.

Профілактичні методи боротьби з пожежами у приміщенні передбачають [24]:

- організаційні: навчання та розробка планів евакуації, утримання приміщень у належному стані та інше;
- технічні: сучасні автоматичні засоби сигналізації, методи та пристрої обмеження розповсюдження вогню, автоматичні стаціонарні системи гасіння пожеж, вогнегасники.

Приміщення оснащуються пороговою пожежною сигналізацією та знаками пожежної безпеки. Загальні вимоги до знаків пожежної безпеки регламентовані нормами пожежної безпеки [25].

ВИСНОВКИ

В кваліфікаційній роботі досліджено підвищення точності обробки вимірювальних даних у вимірювальному каналі тиску гідросистеми дорожньої машини шляхом застосування методів машинного навчання.

В кваліфікаційній роботі проведено аналіз сучасних методів обробки вимірювальних даних та встановлено, що традиційні алгоритми цифрової фільтрації (ковзне середнє, медіанна фільтрація, фільтр Калмана) забезпечують лише часткове пригнічення шумів і не дозволяють ефективно враховувати складні нелінійні залежності між параметрами вимірювального процесу.

В роботі розроблено нейромережеву модель на основі архітектури LSTM(64)-Dropout(0,2)-Dense(32)-Dense(1). Загальна кількість навчальних параметрів LSTM-шару становить 1408, а повнозв'язних шарів – 2113 параметрів. В процесі навчання значення функції втрат зменшилося з 0,084 до 0,0015, що відповідає зниженню функції втрат на 98,21 %.

Отримані результати свідчать про високу точність прогнозування тиску та якісне відтворення динаміки роботи гідросистеми.

В кваліфікаційній роботі проведено порівняльний аналіз ефективності різних методів обробки вимірювальних даних. Встановлено, що найкращі результати демонструє LSTM-мережа.

Використання LSTM дозволило зменшити середньоквадратичну похибку прогнозування порівняно з методом ковзного середнього на 66,7 %.

Нейромережеві моделі можливо використовувати в складі сучасних інформаційно-вимірювальних систем дорожніх машин для підвищення точності вимірювання тиску, компенсації похибок вимірювального каналу та прогнозування технічного стану гідравлічної системи.

ПЕРЕЛІК ПОСИЛАНЬ

1. Новіков А. О. Машини і обладнання дорожньо-будівельної техніки. – Харків: ХНАМГ, 2020. – 223 с.
2. Поліщук, Є. С., Дорожовець, М. М., Яцук, В. О., Ванько, В. М., Бойко, Т. Г. Метрологія та вимірювальна техніка – Львів: Львівська політехніка, підручник (розділи по основах метрології, калібруванню і оцінці похибок).
3. Яремчук Н.А., Затока С.А., Бурченков Г.К., Шведова В.В., Стасевич В.А. Основи метрології та вимірювальної техніки. Навчальний підручник / За заг. ред. Н.А. Яремчук. – К: Видавництво «Політехніка», 2014. – 304 с.
4. Основи та методи цифрової обробки сигналів: від теорії до практики: навч. посіб. / Ю. О. Ушенко, М. С. Гавриляк, М. В. Талах, В. В. Дворжак. Чернівці: Чернівецький нац. ун-т ім. Ю. Федьковича, 2021. – 308 с.
5. С. В. Ткаліченко. Штучні нейронні мережі: навч. посіб. – Кривий Ріг: Державний університет економіки і технологій, 2023. – 150 с.
6. Пилипенко І. В. Цифрова фільтрація сигналів. – Львів: Видавництво Львівської політехніки, 2021. – 193 с.
7. Комп'ютерні методи інтелектуальної обробки даних: навчальний посібник / В.І. Дубровін, Ю.В. Твердохліб, В.В. Харченко. – Запоріжжя : ЗНТУ, 2013. – 105 с.
8. Теоретичні основи інформаційно-вимірювальних систем: Підручник /В.П. Бабак, С.В. Бабак, В.С. Єременко та ін.; за ред. чл. кор. НАН України В.П. Бабака/2-е вид., перероб. і доп. – К.: Ун-т новітніх технологій; НАУ, 2017. – 496с.
9. Засоби та методи вимірювань неелектричних величин: підручник / Є. С. Поліщук, М. М. Дорожовець, Б. І. Стадник и др.; за ред. проф. Є.С. Поліщука. – Львів : Бескид Біт, 2008. – 618 с.
10. Полярус О. В. Вплив «старіння» датчиків температури на їх динамічні характеристики / О. В. Полярус, А. О. Коваль // Системи обробки інформації. – 2015. – № 6(131). – С. 123-126.
11. Кір'янов О. Ф., Мороз М. М., Бойко Ю. О. Інформаційні технології на

автомобільному транспорті: навч. посіб. Кременчуг. нац. ун-т ім. М. Остроградського. Харків : Друкарня Мадрид. 2015. – 270 с.

12. Коваль О. А., Коваль А. О., Богатов О. І., Петрукович Д. Є. Нейромережеві методи в інтелектуальних вимірювальних інформаційних системах: Монографія. – Харків: Лідер, 2020. – 150 с.

13. Дубровін В. І., Твердохліб Ю. В., Харченко В. В. Комп'ютерні методи інтелектуальної обробки даних: навчальний посібник. Запоріжжя : ЗНТУ, 2013. – 105 с.

14. Коваль А. О. Критерій та схема навчання нейромережевої моделі вимірювального датчика. Вісник НТУ "ХПІ". Харків. 2011. №68. С. 75-78.

15. Єріна А. М. Статистичне моделювання та прогнозування: навч. посіб. К.: КНЕУ, 2001. – 170 с.

16. Віткін, Л. Метрологічна надійність засобів вимірювальної техніки / Л. Віткін, В. Ігнаткін // Вимірювальна техніка та метрологія. – Л. : Вид-во Нац. ун-ту "Львів. політехніка", 2008. – С. 158-165.

17. Коваль А. О., Коваль О. А. Просторово розподілені інтелектуальні вимірювальні інформаційні системи: монографія : Лідер. – Харків, 2017. – 144 с.

18. Коваль А. О., Полярус О. В., Подорожняк А. О. Динамічна нейромережева модель первинного перетворювача. Вісник НТУ "ХПІ". Харків. 2014. №35. С. 152-155.

19. Горбійчук М. І., Когутяк М. І., Борин В. С. Порівняльний аналіз методів фільтрації при експериментальному дослідженні динамічних властивостей об'єктів. Методи та прилади контролю якості. 2020. № 2 (45). С. 66-81.

20. Закон України "Про охорону праці" в редакції від 21 листопада 2002 р. URL: https://urst.com.ua/act/pro_okhoronu_pratsi.

21. ДБН В.2.5-28-2006 «Природне та штучне освітлення».

22. ДБН В.2.5-67-1026 Опалення, вентиляція та кондиціонування.

21. ДСТУ Б В.1.1-36:2016 Визначення категорій приміщень, будинків та зовнішніх установок за вибухопожежною та пожежною небезпекою [Електронний ресурс]//Будстандарт online. – Режим доступу:

http://online.budstandart.com/ua/catalog/doc-page?id_doc=65419.

24. ДСТУ 3855-99 Пожежна безпека. Визначення пожежної небезпеки матеріалів та конструкцій. Терміни та визначення.

25. ДСТУ ISO 6309:2007 Протипожежний захист.

Кафедра МБЖД ХНАДУ

ДОДАТОК А
ІЛЮСТРАТИВНИЙ МАТЕРІАЛ ДО КВАЛІФІКАЦІЙНОЇ РОБОТИ

Кафедра МБЖД ХНАДУ

Міністерство освіти та науки України
Харківський автомобільно-дорожній університет
(ХНАДУ)

Механічний факультет

Кафедра метрології та БЖД

ІЛЮСТРАТИВНИЙ МАТЕРІАЛ ДО КВАЛІФІКАЦІЙНОЇ РОБОТИ
бакалавра

ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДЛЯ ОБРОБКИ
ВИМІРЮВАЛЬНИХ ДАНИХ

Завідувач кафедри (канд. техн. наук, проф.)
Нормоконтролер (канд. техн. наук, доцент)
Керівник (канд. техн. наук, доцент)
Студент гр. ММз-41-22



О. І. Боготов
І. В. Грайворонська
Д. Є. Петрукович
А. М. Роденко

Харків 2026

Об'єкт дослідження – є процес обробки вимірювальних даних у вимірювальному каналі тиску гідравлічної системи дорожньої машини.

Мета – дослідження можливостей застосування методів машинного навчання для обробки вимірювальних даних та підвищення точності визначення тиску в гідросистемі дорожньої машини.

Метод досліджень – включають методи математичного моделювання, теорію цифрової обробки сигналів, методи статистичного аналізу, алгоритми машинного навчання, нейронні мережі типу LSTM.

ВИМІРЮВАЛЬНИЙ КАНАЛ ТИСКУ ДОРОЖНЬОЇ МАШИНИ




Рисунок 1 – Структурна схема вимірювального каналу

АНАЛІЗ КЛАСИЧНИХ МЕТОДІВ ОБРОБКИ ВИМІРЮВАЛЬНОЇ ІНФОРМАЦІЇ

1. Метод ковзного середнього.

$$y(k) = \frac{1}{N} \sum_{i=0}^{N-1} x(k-i) \quad (1)$$

2. Медіанна фільтрація.

$$y(k) = \text{median}[x(k-M), \dots, x(k+M)] \quad (2)$$

3. Цифрові фільтри.

FIR-фільтра

$$y(n) = \sum_{k=0}^N b_k x(n-k) \quad (3)$$

4. Метод Калмана

$$\hat{x}_{k|k-1} = A\hat{x}_{k-1|k-1} + Bu_k \quad (5)$$

IIR- фільтра

$$y(n) = \sum_{k=0}^M b_k x(n-k) - \sum_{k=1}^N a_k y(n-k) \quad (4)$$

Таблиця 1 – Недоліки традиційних методів

Недолік	Наслідки
Припущення про лінійність	Зниження точності при роботі з нелінійними процесами
Фіксовані параметри алгоритмів	Низька адаптивність до зміни режимів роботи
Обмежене врахування факторів впливу	Зростання систематичної похибки
Неможливість самонавчання	Необхідність ручного налаштування
Відсутність прогнозування	Неможливість реалізації предикативної діагностики
Робота лише з невеликими масивами даних	Зниження ефективності при Big Data

АНАЛІЗ МЕТОДІВ МАШИННОГО НАВЧАННЯ




Рисунок 2 – Класифікація методів машинного навчання




Рисунок 3 – Структурна схема LSTM-мережі для прогнозування тиску

1. Вхідний шар.

$$X_t = [P_t, T_t, V_t]^T \quad (6)$$

2. LSTM-шар.

$$H = [h_1, h_2, \dots, h_{64}] \quad (7)$$

3. Dropout шар

$$y_i = r_i h_i \quad (8)$$

4. Повнозв'язний шар (Dense).

$$A_1 = f(W_1 H + b_1) \quad (9)$$

5. Повнозв'язний шар (Dense Layer)

$$\hat{P}_{t+1} \quad (10)$$

СТРУКТУРА LSTM-КОМІРКИ




Рисунок 4 – Структура LSTM-комірки

LSTM-комірка містить механізм пам'яті та три керуючі блоки:

- ворота забування (Forget Gate);
- входні ворота (Input Gate);
- вихідні ворота (Output Gate).

АЛГОРИТМ РОБОТИ LSTM-МЕРЕЖІ




Рисунок 5 – Алгоритм роботи LSTM-мережі






Рисунок 6 – Схема алгоритму Adam

НАВЧАННЯ LSTM-МЕРЕЖ

Дані містять 1000 відліків: час, режим роботи, істинний тиск, температуру, вібрацію, шум, виміряний тиск, похибку та цільове значення для навчання.



№	Час, s	Режим роботи	Р, факт, МПа	Температура Т, °C	Вібрація V, мм/с	Шум, дБ	Р, вим., МПа	Помилка ΔP, МПа	ЦПН, вим(НП), МПа
1	1	3.000	Стандартний	12.0000	42.0000	1.5000	-0.0115	12.0140	2.0140
2	2	3.100	Стандартний	12.0141	42.0650	1.6160	-0.0136	12.0290	3.0149
3	3	3.200	Стандартний	12.0291	42.1300	1.7290	-0.0069	12.0509	3.0228
4	4	3.300	Стандартний	12.0416	42.1850	1.8330	0.0062	12.1306	3.0006
5	5	3.400	Стандартний	12.0592	42.2800	1.9270	-0.0002	12.0832	3.0270
6	6	3.500	Стандартний	12.0881	42.3250	2.0050	-0.1098	11.8873	3.0025
7	7	3.600	Стандартний	12.0804	42.3890	2.0670	0.0206	12.1482	3.0678
8	8	3.700	Стандартний	12.0919	42.4530	2.1090	-0.0214	12.1131	3.0212
9	9	3.800	Стандартний	12.1027	42.5170	2.1318	-0.0174	12.1251	3.0293
10	10	3.900	Стандартний	12.1125	42.5800	2.1318	0.0093	12.1854	3.0529
11	11	3.000	Стандартний	12.1214	42.6440	2.1110	0.0166	12.1833	3.0619
12	12	3.100	Стандартний	12.1291	42.7090	2.0700	0.0931	12.2648	3.0597
13	13	3.200	Стандартний	12.1357	42.7880	2.0100	0.0825	12.3296	3.0938
14	14	3.300	Стандартний	12.1411	42.8330	1.9340	0.0088	12.1893	3.0485
15	15	3.400	Стандартний	12.1453	42.8810	1.8450	-0.0601	12.1236	-0.0276
16	16	3.500	Стандартний	12.1482	42.9510	1.7450	-0.0612	12.1024	-0.0457
17	17	3.600	Стандартний	12.1497	43.0110	1.6390	0.0797	12.2524	0.0527
18	18	3.700	Стандартний	12.1499	43.0700	1.5060	0.1849	12.2872	3.1375
19	19	3.800	Стандартний	12.1499	43.0700	1.5060	0.1849	12.2872	3.1375

Рисунок 7 – Структура набору даних для навчання нейронної мережі

Рисунок 8 – Розрахункові значення параметрів LSTM-мережі

ОБРОБКА ДАННИХ З ВИКОРИСТАННЯМ LSTM-МЕРЕЖ




Рисунок 9 – Графічна залежність порівняння реального тиску та прогнозу LSTM-мережі.





Рисунок 10 – Графік похибки тиску LSTM-мережі

ОБРОБКА ДАНИХ З ВИКОРИСТАННЯМ LSTM-МЕРЕЖ



Таблиця 2 – Значення похибки MSE від епох навчання

Епоха навчання	Середньоквадратична похибка (MSE)
1	0,084
10	0,028
20	0,012
40	0,006
60	0,003
80	0,002
100	0,0015

Рисунок 11 – Графік залежності функції втрат від кількості епох навчання

ОЦІНКА ТОЧНОСТІ МОДЕЛІ

$$MAE = \frac{1}{N} \sum_{i=1}^N |p_i - \hat{p}_i| \quad (11)$$

$$RMSE = \sqrt{MSE} \quad (13)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (p_i - \hat{p}_i)^2 \quad (12)$$

$$R^2 = 1 - \frac{\sum (p_i - \hat{p}_i)^2}{\sum (p_i - \bar{p})^2} \quad (14)$$




Рисунок 12 – Графік похибок методів обробки вимірjвального даних

Таблиця 2 – Результати оцінки якості моделі

Показник	Значення
Середня абсолютна похибка (MAE)	0,09 МПа
Корінь середньоквадратичної похибки (RMSE)	0,12 МПа
Коефіцієнт детермінації (R ²)	0,989

ВИСНОВКИ

В кваліфікаційній роботі досліджено підвищення точності обробки вимірювальних даних у вимірювальному каналі тиску гідросистеми дорожньої машини шляхом застосування методів машинного навчання.

В кваліфікаційній роботі проведено аналіз сучасних методів обробки вимірювальних даних та встановлено, що традиційні алгоритми цифрової фільтрації (ковзне середнє, медіанна фільтрація, фільтр Калмана) забезпечують лише часткове пригнічення шумів і не дозволяють ефективно враховувати складні нелінійні залежності між параметрами вимірювального процесу.

В кваліфікаційній роботі розроблено нейромережеву модель на основі архітектури LSTM(64)-Dropout(0,2)-Dense(32)-Dense(1). Загальна кількість навчальних параметрів LSTM-шару становить 1408, а повнозв'язних шарів – 2113 параметрів. В процесі навчання значення функції втрат зменшилося з 0,084 до 0,0015, що відповідає зниженню функції втрат на 98,21 %.

Отримані результати свідчать про високу точність прогнозування тиску та якісне відтворення динаміки роботи гідросистеми.

В роботі проведено порівняльний аналіз ефективності різних методів обробки вимірювальних даних. Встановлено, що найкращі результати демонструє LSTM-мережа.

Використання LSTM дозволило зменшити середньоквадратичну похибку прогнозування порівняно з методом ковзного середнього на 66,7 %.

Нейромережеві моделі можливо використовувати в складі сучасних інформаційно-вимірювальних систем дорожніх машин для підвищення точності вимірювання тиску, компенсації похибок вимірювального каналу та прогнозування технічного стану гідравлічної системи.