



Харківський національний університет радіоелектроніки

Факультет \_\_\_\_\_ Комп'ютерних наук \_\_\_\_\_  
(повна назва)  
Кафедра \_\_\_\_\_ Штучного інтелекту \_\_\_\_\_  
(повна назва)  
Рівень вищої освіти \_\_\_\_\_ другий (магістерський) \_\_\_\_\_  
Спеціальність \_\_\_\_\_ 122 Комп'ютерні науки \_\_\_\_\_  
(код і повна назва)  
Тип програми \_\_\_\_\_ освітньо-професійна \_\_\_\_\_  
(освітньо-професійна або освітньо-наукова)  
Освітня програма \_\_\_\_\_ Науки про дані (Data Science) \_\_\_\_\_  
(повна назва)

ЗАТВЕРДЖУЮ:  
Зав. кафедри \_\_\_\_\_  
(підпис)  
« \_\_\_\_\_ » \_\_\_\_\_ 20 \_\_\_\_ р.

**ЗАВДАННЯ**  
НА КВАЛІФІКАЦІЙНУ РОБОТУ

здобувачеві \_\_\_\_\_ Умнову Кіриллу Геннадійовичу \_\_\_\_\_  
(прізвище, ім'я, по батькові)

1. Тема роботи \_\_\_\_\_ Дослідження методів попередньої обробки даних в завданні розпізнавання людської активності \_\_\_\_\_

затверджена наказом університету від 24 листопада 20 25 р. № 1057Ст

2. Термін подання студентом роботи до екзаменаційної комісії 16 грудня 20 25 р.

3. Вихідні дані до роботи \_\_\_\_\_ Науково-технічні статті та література з розпізнавання людської активності, дані Інтернет-джерел, документація мови Python, бібліотек pandas, scikit-learn, numpy, алгоритми попередньої обробки часових рядів. \_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

1) Аналіз предметної галузі

2) Алгоритми попередньої обробки часових рядів

3) Експериментальне дослідження ефективності методів попередньої обробки часових рядів

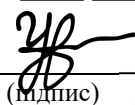
\_\_\_\_\_  
\_\_\_\_\_  
\_\_\_\_\_

## КАЛЕНДАРНИЙ ПЛАН

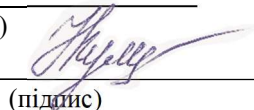
№	Назва етапів роботи	Терміни виконання етапів роботи	Примітка
1	Отримання завдання на кваліфікаційну роботу	24.11.2025	виконано
2	Аналіз предметної галузі	24.11.2025 – 30.11.2025	виконано
3	Постановка задачі	30.11.2025 – 01.12.2025	виконано
4	Аналіз алгоритмів попередньої обробки часових рядів	01.12.2025 – 04.12.2025	виконано
5	Експериментальне дослідження методів попередньої обробки часових рядів	04.12.2025 – 06.12.2025	виконано
6	Оформлення пояснювальної записки	06.12.2025 – 08.12.2025	виконано
7	Перевірка на академічний плагіат	09.12.2025	виконано
8	Подача роботи на нормоконтроль	09.12.2025	виконано
9	Підготовка рецензії та доповіді	09.12.2025 – 10.12.2025	виконано
10	Попередній захист	11.12.2025	виконано
11	Рецензування	12.12.2025	виконано
12	Захист перед ЕК	16.12.2025	

Дата видачі завдання 24 листопада 2025 р.

Здобувач \_\_\_\_\_

  
(підпис)

Керівник роботи \_\_\_\_\_

  
(підпис)

проф. Кулішова Н. Є.

(посада, прізвище, ініціали)

## РЕФЕРАТ

Пояснювальна записка: 75 с., 24 рис., 2 дод., 25 джерел.

АУГМЕНТАЦІЯ, ДАНІ, ЗМЕНШЕННЯ РОЗМІРНОСТІ, КЛАСИФІКАЦІЯ, ЛЮДСЬКА АКТИВНІСТЬ, НОРМАЛІЗАЦІЯ, ПОПЕРЕДНЯ ОБРОБКА, РОЗПІЗНАВАННЯ АКТИВНОСТІ, ЧАСОВИЙ РЯД.

Метою кваліфікаційної роботи є підвищення ефективності алгоритмів розпізнавання активності людини на основі даних акселерометра з набору UCI HAR Dataset.

Об'єкт дослідження – процес розпізнавання активності людини на основі даних акселерометра.

Предмет дослідження – методи попередньої обробки даних, отриманих з акселерометра, у системах розпізнавання активності людини (Human Activity Recognition, HAR).

Методи дослідження – аналіз наукової літератури та існуючих досліджень у сфері HAR, експериментальне тестування різних комбінацій методів попередньої обробки даних (нормалізація, зменшення розмірності, аугментація), а також оцінка впливу цих методів на точність класифікації, час навчання та обчислювальні витрати.

Результатами дослідження є визначення оптимальних методів попередньої обробки даних для HAR-систем, розробка програмного прототипу для тестування різних методів обробки даних, проведення серії експериментів з використанням різних алгоритмів класифікації, а також формулювання практичних рекомендацій щодо вибору методів попередньої обробки для підвищення ефективності систем розпізнавання активності людини в умовах реального часу та обмежених обчислювальних середовищ.

## ABSTRACT

Master's thesis contains: 75 pp., 24 fig., 2 ann., 25 references.

ACTIVITY RECOGNITION, AUGMENTATION, CLASSIFICATION, DATA, DIMENSIONALITY REDUCTION, HUMAN ACTIVITY, NORMALIZATION, PREPROCESSING, TIME SERIES.

The aim of the master's thesis is to improve the effectiveness of human activity recognition algorithms based on accelerometer data from the UCI HAR Dataset.

Object of the master's thesis – the process of human activity recognition based on accelerometer data.

Subject of the master's thesis – methods of preprocessing accelerometer data in human activity recognition (HAR) systems.

Research methods – analysis of scientific literature and existing studies in the field of HAR, experimental testing of different combinations of preprocessing methods (normalization, dimensionality reduction, augmentation), as well as evaluation of the impact of these methods on classification accuracy, training time, and computational cost.

The results of the master's thesis include identifying optimal data preprocessing methods for HAR systems, developing a software prototype for testing different data processing techniques, conducting a series of experiments using various classification algorithms, and formulating practical recommendations for selecting preprocessing methods to enhance the efficiency of human activity recognition systems in real-time and resource-constrained environments.

## **ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ, СКОРОЧЕНЬ І ТЕРМІНІВ**

ШІ – Штучний інтелект;

CNN – Convolutional Neural Network – згорткова штучна нейронна мережа;

HAR – Human Activity Recognition – розпізнавання людської активності;

MLP – Multilayer Perceptrone – багатошаровий персептрон;

PCA – Principal Component Analysis – метод основних компонент;

RF – Random Forest – випадковий ліс;

SVM – Support Vector Machine – метод опорних векторів.

## ЗМІСТ

Вступ.....	8
1 Аналіз предметної галузі.....	10
1.1 Опис предметної галузі .....	10
1.2 Аналіз існуючих аналогічних досліджень.....	16
1.3 Постановка задачі.....	21
2 Алгоритми попередньої обробки часових рядів.....	23
2.1 Алгоритми нормалізації .....	23
2.2 Алгоритми зменшення розмірності.....	25
2.3 Алгоритми аугментації.....	29
2.4 Алгоритми класифікації .....	31
3 Експериментальне дослідження ефективності методів попередньої обробки часових рядів .....	35
3.1 Аналіз набору даних .....	35
3.2 Опис експериментів .....	44
3.3 Порівняння отриманих результатів.....	49
Висновки .....	59
Перелік джерел посилання .....	61
Додаток А Програмна реалізація експерименту.....	64
Додаток Б Відомість кваліфікаційної роботи.....	75

## ВСТУП

З початком епохи інформаційних технологій відбувся стрімкий розвиток технічних можливостей комп'ютерної техніки, зумовлений значними досягненнями у науковій сфері. У результаті цього з'явилися нові перспективи, зокрема завдяки покращенню технічних характеристик обчислювальних пристроїв. Це дало змогу не лише застосовувати алгоритми, розроблені в минулому, але які раніше не могли бути реалізовані через технічні обмеження, а й створювати нові, більш удосконалені методи обчислень.

Усе це сприяло формуванню абсолютно нового та революційного напрямку в інформаційних технологіях – штучного інтелекту. Як уже зазначалося, ідея створення ШІ існувала в суспільстві багато десятиліть тому, однак лише кілька останніх десятиліть дали реальну можливість спробувати її втілити. Лише упродовж минулого десятиліття доступність та потужність сучасних обчислювальних систем дозволили активно розвивати цей напрям і масштабувати його для широкого використання в науковій та прикладній спільноті.

Це досягнення дозволило зробити значний прорив у багатьох сферах людського життя, включно з медициною, де штучний інтелект знайшов широке застосування у визначенні патологій, автоматичній класифікації станів організму, аналізі медичних зображень та прогнозуванні розвитку захворювань.

Одним із важливих напрямів використання штучного інтелекту також стало розпізнавання активності людини (HAR). Такі системи дозволяють аналізувати рухову активність людини на основі даних, отриманих із сенсорів, наприклад акселерометрів або пульсометрів. Це допомагає визначати рівень фізичного навантаження, контролювати виконання вправ, відстежувати реабілітаційні процеси чи навіть виявляти падіння або інші критичні ситуації у людей похилого віку.

Однак, на відміну від задач із розпізнавання патологій, напрям розпізнавання фізичної активності не отримав такого широкого поширення. Хоча дослідження у цій галузі також активно проводилися, основний акцент у більшості робіт був зроблений на розробці та порівнянні методів класифікації. Водночас методи попередньої обробки даних, що мають вирішальний вплив на точність і стабільність моделей, залишилися поза достатньою увагою дослідників.

Саме тому експериментальне дослідження, спрямоване на аналіз ефективності різних підходів до попередньої обробки даних, є актуальним. Застосування широкого спектра сучасних алгоритмів – від фільтрації шумів і нормалізації сигналів до обчислення статистичних ознак та зниження розмірності – може дати змогу не лише підвищити точність фінальної класифікації, але й зменшити обчислювальне навантаження шляхом скорочення необхідних ресурсів обчислювального пристрою.

## 1 АНАЛІЗ ПРЕДМЕТНОЇ ГАЛУЗІ

### 1.1 Опис предметної галузі

Розпізнавання активності людини – це завдання автоматичного визначення типу фізичної дії, яку виконує людина, на основі даних, отриманих від сенсорів, що фіксують параметри руху, положення тіла або фізіологічні показники [1]. Суть цієї задачі полягає в тому, щоб із великого обсягу сигналів сенсорів – наприклад, акселерометрів, гіроскопів, пульсометрів або інших датчиків – виділити характерні ознаки, які корелюють із конкретним видом активності (наприклад, ходьба, біг, підйом сходами, сидіння, сон), а потім класифікувати поточну дію користувача в реальному часі або поблизу реального часу [2]. Ця класифікація дає можливість не просто вказати, що людина робить, але й оцінити інтенсивність, тривалість, зміни активності або навіть відхилення від нормальної поведінки, що може бути корисним для моніторингу здоров'я чи безпеки. HAR-системи дозволяють отримати контекст рухової поведінки людини і використовувати цей контекст у прикладних системах.

Процес розпізнавання активності людини охоплює повний ланцюг перетворення сирих сенсорних сигналів у зрозумілі для алгоритмів ознаки та подальшу класифікацію активностей. Спочатку здійснюється збір даних, який передбачає конфігурацію пристроїв, вибір частоти дискретизації, розташування сенсорів на тілі, розробку експериментального протоколу і анотацію активностей. Якість цієї стадії суттєво впливає на точність усього процесу. Після збору даних виконується попередня обробка, що включає фільтрацію шумів, компенсацію зсувів датчиків, синхронізацію різних сенсорів і нормалізацію сигналів між користувачами та пристроями. Наступним етапом є сегментація, під час якої часові ряди розбиваються на вікна певної довжини, що дозволяє моделі ефективно аналізувати короткі часові фрагменти руху. Від вибору розміру вікна та перекриття залежить

баланс між точністю розпізнавання і чутливістю до короткочасних подій. Далі здійснюється виділення ознак, коли з кожного вікна обчислюються часові, статистичні чи частотні характеристики, або використовується підхід end-to-end, при якому нейронна мережа самостійно навчається з необроблених сигналів [3].

Ознаки, що використовуються у HAR, поділяються на часові, частотні, статистичні та синергетичні. Часові ознаки включають середні значення, медіани, дисперсії, стандартні відхилення, мінімальні та максимальні значення, похідні швидкостей і прискорень, а також кореляції між осями. Вони прості у розрахунку і добре підходять для задач з обмеженими ресурсами. Частотні ознаки описують енергетичний розподіл сигналу за частотами, визначають домінантні компоненти руху та дозволяють виявити повторювані патерни, наприклад кроки при ходьбі. Статистичні та часово-частотні ознаки, такі як моменти розподілу, вейвлет-коефіцієнти або результати короткочасного перетворення Фур'є, допомагають розпізнавати складні динамічні структури. Синергетичні або крос-доменні ознаки комбінують попередні підходи, наприклад через крос-кореляції між сенсорними каналами або співвідношення енергій у частотних діапазонах [2].

Серед основних сучасних тенденцій у HAR можна виділити мультимодальність, онлайн-обробку, контекстну персоналізацію, самонавчання та оптимізацію моделей. Мультимодальність передбачає поєднання даних з кількох джерел, таких як акселерометр, гіроскоп, пульсометр, барометр, GPS або магнітометр, для покращення точності розпізнавання. Онлайн-HAR означає виконання класифікації безпосередньо на пристрої або у потоковому режимі з мінімальною затримкою, що вимагає створення енергоефективних та компактних моделей. Контекстність і персоналізація полягають у врахуванні умов користувача – часу доби, місця чи індивідуального стилю руху – та адаптації моделі до конкретної людини за допомогою трансферного навчання або онлайн-оновлення. Контрастивне

та самонавчання дозволяють формувати корисні представлення навіть без великої кількості розмічених даних. Актуальним напрямом також є розробка легких нейронних мереж і методів компресії, що забезпечують ефективну роботу на пристроях із обмеженими обчислювальними ресурсами [1].

Для реалізації HAR-систем використовуються різні пристрої, які можуть збирати дані сенсорів. Одним із найпоширеніших варіантів є смартфони: сучасні смартфони оснащені вбудованими акселерометрами, гіроскопами, магнітометрами, іноді пульсодатчиками або іншими біометричними сенсорами [2]. Завдяки цьому смартфон можна носити на тілі (у кишені, на поясі, у руці) та збирати дані про рухи, обертання і положення тіла. Інший популярний формат – фітнес-браслети або смартгодинники: вони носяться на зап'ясті, фіксують рухи рук, положення зап'ястя, пульс, іноді навіть ЕКГ-сигнал або оптичний датчик пульсу. Наприклад, браслети можуть визначати кроки, частоту пульсу, зміну положення тіла (стоячи/сидячи). Третій варіант – переносні сенсори, такі як інерційні вимірювальні блоки (IMU) або спеціальні «розумні» сорочки/одяг із вбудованими сенсорами руху і пульсу, які використовуються у спорті чи дослідницьких проєктах. Усі ці пристрої створюють часові ряди сигналів, які потім обробляються алгоритмами HAR. Вибір пристрою, його розташування на тілі, частота дискретизації та якість сенсорів – суттєво впливають на результати системи [2].

Популярність HAR значно зросла саме через доступність носимих сенсорів і мобільних платформ, саме тому HAR-системи знаходять застосування у дуже різних секторах. У медицині подібні системи використовуються для моніторингу стану пацієнтів під час реабілітації після хірургічних втручань, для оцінки рухової поведінки людей із хронічними захворюваннями, а також для раннього виявлення падінь або рухових порушень у людей похилого віку. У фітнес-індустрії HAR дозволяє тренерам чи користувачам мобільних додатків оцінювати ефективність

тренувань, підраховувати кроки, калорії, зміну активності за день, а також автоматично класифікувати виконувані вправи чи сегменти тренування. У сфері безпеки та «розумного дому» ці системи можуть виявляти нетипові рухи, наприклад падіння або тривожну поведінку, і вживати заходів – наприклад, сповіщення чи виклик допомоги [1].

Реальне впровадження систем HAR стикається з низкою викликів. До них належать варіативність у розміщенні сенсорів, відмінності у стилях руху між користувачами, шум у сигналах, втрати даних, наявність рідкісних класів, обмеження батареї та потужності обчислень. Крім того, моделі, натреновані у лабораторних умовах, часто не узагальнюються на реальні сценарії, що створює проблему перенесення між доменами. Додатковим аспектом є забезпечення конфіденційності сенсорних даних, адже вони містять чутливу інформацію про користувача. Попри ці труднощі, HAR залишається однією з найперспективніших галузей, що поєднує методи машинного навчання, обробки сигналів та мобільних технологій. Завдяки розвитку мультимодальних сенсорів, глибоких нейронних архітектур і персоналізованих підходів розпізнавання активності стає дедалі точнішим, адаптивнішим і кориснішим для моніторингу здоров'я, спорту, безпеки та повсякденного життя [2].

Існує кілька великих публічних датасетів, які використовуються дослідниками HAR-технологій.

Одним із найвідоміших є набір даних «UCI HAR Dataset» – він складається з даних акселерометра та гіроскопа, зібраних 30 учасниками, які виконували шість видів активності: ходьба, підйом сходами, спуск сходами, сидіння, стояння, лежання. Цей датасет містить понад 10 000 зразків, які були попередньо оброблені фільтрацією шуму, поділом на вікна 2,56 секунди із перекриттям 50 % і виділенням часово-частотних ознак [4].

WISDM (Wireless Sensor Data Mining Dataset) – також один із найпопулярніших наборів даних для задач HAR, зібраний дослідниками Університету Фордхем (США). Він містить дані акселерометра, зібрані зі

смартфонів, які носили 36 учасників під час виконання шести типів активності: ходьба, біг, сидіння, стояння, підйом сходами та спуск сходами. Перевагою цього датасету є те, що дані збиралися в умовах, наближених до реального використання смартфона, що робить його придатним для моделювання щоденної активності. Проте його обмеження полягає у використанні лише одного сенсора (акселерометра), що зменшує точність при класифікації подібних типів рухів. Крім того, частота дискретизації у WISDM становить лише 20 Гц, що недостатньо для високоточних моделей, які потребують детальніших часових ознак. Тому цей набір даних не дозволяє комплексно аналізувати сигнали, наприклад, із гіроскопа, як це можливо у UCI HAR Dataset, і менш підходить для завдань, пов'язаних із точним розпізнаванням рухів чи тренувальних вправ [5].

PAMAP2 Physical Activity Monitoring Dataset був зібраний у Німецькому дослідницькому центрі штучного інтелекту (DFKI). Він містить дані з дев'яти типів фізичної активності, зокрема ходьби, бігу, підйому сходами, роботи на тренажері, їзди на велосипеді тощо. Дані збиралися з трьох інерційних вимірювальних одиниць (IMU) та пульсометра, розташованих на зап'ясті, грудях і щиколотці. Цей набір є одним із найбагатших за кількістю фізіологічних параметрів і часто використовується у медичних та фітнес-дослідженнях. Однак його недолік полягає у високій складності структури даних: наявність численних каналів та неповних записів через пропуски сигналів ускладнює попередню обробку. Крім того, обсяг пам'яті, необхідний для аналізу PAMAP2, значно більший, що робить його менш придатним для розробки легковагових моделей, орієнтованих на мобільні пристрої [6].

Opportunity Activity Recognition Dataset – ще один потужний набір даних, створений у межах європейського проекту OPPORTUNITY. Він містить понад 72 сенсори, розміщених на тілі, предметах та в навколишньому середовищі, що дає змогу детально відтворювати сценарії повсякденного життя, наприклад, приготування їжі або взаємодію з

побутовими предметами. Дані включають як інерційні сигнали, так і показники магнітометра, сенсорів тиску, положення дверей, контактів тощо. Однак, попри свою універсальність, Opportunity Dataset надмірно складний і громіздкий для базових досліджень розпізнавання рухової активності. Він вимагає значних обчислювальних ресурсів, спеціальної синхронізації різних типів сигналів і не є репрезентативним для сценаріїв, пов'язаних із носимими пристроями (наприклад, смартгодинниками). Тому його використання в межах цієї роботи недоцільне [7].

Таким чином, хоча WISDM, PAMAP2 та Opportunity Dataset мають свої унікальні переваги та широко використовуються у наукових дослідженнях, вони або занадто обмежені за типом даних (WISDM), або надмірно складні для оптимізації (PAMAP2, Opportunity). Натомість UCI HAR Dataset пропонує збалансоване співвідношення простоти, структури та якості – дані добре підготовлені, мають чіткі мітки активностей, а методологія збору дозволяє відтворювати результати. Саме тому він є оптимальним вибором для даного дослідження.

Хоча досягнуто великих успіхів у HAR-системах, одним із актуальних викликів залишається недостатня увага до етапу попередньої обробки даних [1]. Багато досліджень акцентують увагу на виборі класифікатора або архітектури нейронної мережі, але менше уваги приділяють таким крокам, як нормалізація сигналів між користувачами, синхронізація сенсорів, розділення вікон, адаптація до різних положень сенсора, а також аугментація для малих класів. Але ці кроки часто є вирішальними для стабільності системи у реальних умовах, але їх ефект менш досліджений.

Попередня обробка даних в контексті HAR-систем має також велике значення з точки зору економії обчислювальних ресурсів та обмеженості даних. Ефективна нормалізація і зменшення розмірності дозволяють зменшити розмір входу для моделі, знизити час навчання, зменшити обсяг пам'яті, що потрібно для зберігання і обробки даних, а також підвищити узагальнюваність моделі при різних користувачах і положеннях сенсора [2].

У ситуації, коли пристрої мають обмежену обчислювальну потужність (наприклад, носимі пристрої або вбудовані системи), якість попередньої обробки може бути вирішальним фактором. Оптимізація preprocessing-петлі допомагає реалізувати HAR-системи в ресурсно-обмежених середовищах.

Отже, предметна галузь розпізнавання активності людини охоплює комплекс методів: від сенсорного збору даних, через фільтрацію і нормалізацію сигналів, поділ у часові вікна, виділення ознак, а також застосування алгоритмів машинного навчання чи нейронних мереж для класифікації. У рамках цієї роботи акцент зроблено на етапах попередньої обробки даних, що дозволяють підвищити точність, скоротити час навчання та зменшити використання ресурсів. Таким чином, дослідження спрямоване на визначення оптимальних методів попередньої обробки інформації для підвищення ефективності HAR-систем в умовах реального часу та обмежених обчислювальних середовищ.

## 1.2 Аналіз існуючих аналогічних досліджень

Проблема розпізнавання активності людини за даними сенсорів смартфонів і носимих пристроїв є актуальною вже понад десятиліття. Такі системи використовуються у фітнес-трекерах, розумних годинах, медичних моніторингових системах і навіть у безпекових рішеннях. Для перевірки ефективності методів машинного навчання найчастіше застосовується UCI Human Activity Recognition Dataset (UCI HAR) – один із найбільш відомих публічних наборів даних, який містить інформацію з акселерометра та гіроскопа смартфона. Цей набір став стандартом у дослідженнях завдяки добре структурованим даним, великій кількості спостережень і простоті попередньої обробки.

Розглянемо кілька досліджень, які використовують UCI HAR або схожі набори даних та застосовують різні підходи до попередньої обробки

даних, нормалізації, зменшення розмірності, аугментації та вибору моделей класифікації.

Дослідження [8], що описує методологію UCI HAR Dataset, також демонструє ефективність зменшення розмірності даних за допомогою методу головних компонент (PCA) у поєднанні з Random Forest. Автори зосередили увагу на оптимізації процесу класифікації шляхом скорочення кількості вхідних ознак із 561 до 50 за допомогою методу головних компонент (PCA). Перед застосуванням PCA усі дані було нормалізовано методом Z-score, що дозволило усунути відмінності у масштабах вимірювань між сенсорними осями. Модель класифікації побудована на основі Random Forest із 100 дерев, який є стійким до шумів і здатним працювати з нелінійними залежностями. Результати показали, що така комбінація методів забезпечує точність близько 92.3%, при цьому час навчання скоротився майже вдвічі у порівнянні з моделями без зменшення розмірності (близько 3 хвилин). Основними перевагами дослідження є швидкість та стабільність результатів, тоді як основний недолік полягає у втраті частини інформації під час проєкції даних у простір меншої розмірності, що може знижувати точність у випадках із дрібними або короткими рухами. Це дослідження важливе тим, що демонструє ефективність класичних методів при правильному підході до нормалізації та скорочення ознак, і слугує базовою відправною точкою для порівняння з більш складними підходами.

У дослідженні [9] автори пропонують застосувати методи глибокого навчання для розпізнавання людської активності на основі даних лише одного тривісного акселерометра, без використання інших сенсорів. Основна ідея – повністю замінити традиційну ручну розробку ознак моделями глибоких нейронних мереж, які можуть автоматично витягувати ознаки прямо з сирих часових даних акселерометра. Такі моделі можуть працювати ефективніше і з меншим обсягом ознак, ніж класичні підходи, і досягати вищої точності класифікації, обробляючи тільки один сенсорний

сигнал. Це дозволяє зменшити складність системи та потенційно знизити вимоги до обладнання, зокрема для мобільних пристроїв, де інші датчики можуть бути обмежені або недоступні. Проте через використання лише одного сенсору – модель може гірше розпізнавати схожі або більш комплексні рухи, що є іноді може бути значним недоліком.

Дослідження [3] представляє спробу знайти компроміс між ефективністю та ресурсомісткістю при використанні глибокого навчання для задач HAR. Автори запропонували легковагову згорткову нейронну мережу (CNN), що складається лише з трьох згорткових шарів, без рекурентних або складних блоків типу LSTM. Модель розроблена для роботи на мобільних і вбудованих пристроях з обмеженими ресурсами. Перед навчанням було проведено нормалізацію сигналів по кожній осі акселерометра та гіроскопа, але без зменшення розмірності. На відміну від класичних методів, CNN здатна автоматично виділяти ознаки з часових рядів, що зменшує потребу у ручній підготовці даних. Результати показали точність близько 95.7%, що порівняно з важчими моделями глибокого навчання, при цьому час навчання становив лише близько 4 хвилин.

Перевагою підходу є висока точність і придатність для роботи в реальному часі, а недоліком – зниження ефективності при складних або комбінованих активностях, коли тривалі залежності не можуть бути враховані без рекурентних елементів. Це дослідження підкреслює потенціал оптимізованих архітектур CNN у практичних сценаріях, де критично важливими є швидкодія і споживання енергії. Загалом варто відмітити, що модель реалізована у дослідженні має досить високу точність, але й збільшену кількість обчислювальних витрат для її навчання. На рисунку 1.1 представлена архітектура мережі, що була використана у дослідженні.

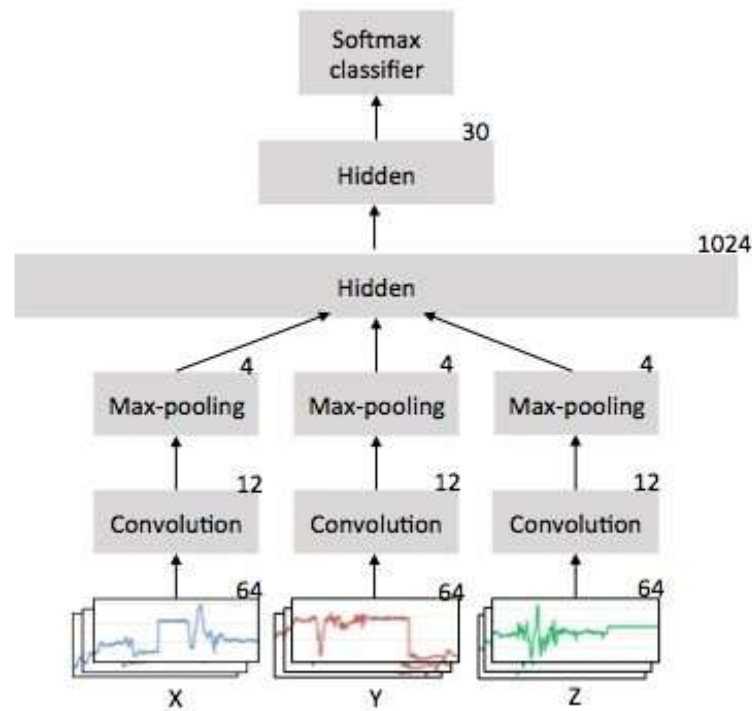


Рисунок 1.1 – Схема штучної нейронної мережі використаної у дослідженні

Дослідження [10] спрямоване на вирішення проблеми обмеженої кількості навчальних даних у HAR через використання методів аугментації. Автори запропонували контрастивне навчання у поєднанні з аугментацією сигналів шляхом часової деформації, ресемплінгу та зсування вікон. Використано базову CNN-архітектуру, однак ключовим елементом став метод підготовки даних. Кожен фрагмент сигналу модифікувався кількома способами, утворюючи «позитивні» та «негативні» пари для контрастивного навчання, що дозволило моделі краще розрізняти схожі рухи (рисунок 1.2).

Нормалізація проводилась по кожній осі сенсорів, що гарантувало стабільність розподілу даних після аугментації. Результати показали найвищу серед розглянутих точність – приблизно 96.1%, однак час навчання зріс до близько 8 хвилин через збільшення кількості зразків і складність процесу оптимізації.

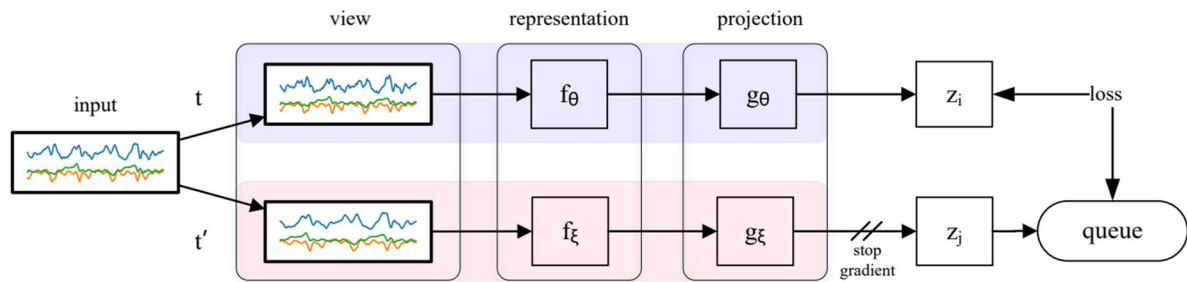


Рисунок 1.2 – Аугментація даних в системі автоматичного розпізнавання людської активності

Перевагою дослідження є висока стійкість до шумів, варіацій користувачів і відмінностей у темпі рухів, а недоліком – підвищені обчислювальні витрати та складна реалізація контрастивних пар. Це дослідження показує, що аугментація часових рядів є потужним інструментом для підвищення якості розпізнавання навіть при невеликій кількості вихідних даних.

Підсумовуючи аналіз, можна побачити чітку еволюцію підходів у сфері розпізнавання активності: від традиційних алгоритмів із ручним відбором ознак до глибоких моделей, які самостійно вчаться виділяти інформативні патерни. З отриманих результатів видно, що нормалізація є критично важливою на всіх етапах, зменшення розмірності – ефективним способом прискорення обчислень, а аугментація – ключовим фактором підвищення узагальнюючої здатності.

Отже, подальше дослідження має бути спрямоване на порівняння різних комбінацій методів попередньої обробки (нормалізація, зменшення розмірності, аугментація) для виявлення оптимального балансу між точністю, швидкістю та стійкістю моделі.

### 1.3 Постановка задачі

Метою даної роботи є експериментальне дослідження впливу методів попередньої обробки даних на ефективність алгоритмів розпізнавання активності людини (Human Activity Recognition, HAR) на основі даних акселерометра з набору UCI HAR Dataset.

Задача розпізнавання активності людини передбачає класифікацію фізичних дій користувача (ходьба, стояння, сидіння, лежання тощо) на основі сигналів, отриманих від сенсорів.

Хоча більшість досліджень у цій сфері зосереджуються на архітектурах моделей машинного навчання, етап попередньої обробки даних є не менш важливим, адже саме він визначає якість вхідних ознак і, відповідно, впливає як на точність класифікації, так і на швидкість обчислень.

У рамках дослідження планується порівняти різні комбінації методів попередньої обробки, зокрема:

- нормалізацію даних – для зменшення впливу масштабних відмінностей між ознаками;
- зменшення розмірності – для скорочення кількості параметрів без суттєвої втрати інформації;
- аугментацію даних – для штучного збільшення навчальної вибірки та підвищення стійкості моделі до шуму.

Успішне виконання роботи передбачає розв'язання таких завдань:

- провести огляд сучасних підходів до попередньої обробки сигналів сенсорних даних;
- реалізувати програмний прототип для тестування різних методів обробки даних;
- провести серію експериментів з використанням різних алгоритмів класифікації (SVM, Random Forest, MLP, CNN);

– оцінити вплив нормалізації, зменшення розмірності та аугментації на точність класифікації, час навчання та обчислювальні витрати;

– порівняти отримані результати з існуючими дослідженнями та сформулювати рекомендації щодо вибору оптимальних методів попередньої обробки для систем HAR.

Отже, метою кваліфікаційної роботи є визначення оптимальної комбінації методів попередньої обробки даних, що дозволяє досягти балансу між точністю розпізнавання активності та ефективністю використання ресурсів обчислювального пристрою.

## 2 АЛГОРИТМИ ПОПЕРЕДНЬОЇ ОБРОБКИ ЧАСОВИХ РЯДІВ

### 2.1 Алгоритми нормалізації

Нормалізація сенсорних часових рядів є критично важливим етапом підготовки даних у задачах розпізнавання активності людини, оскільки вона визначає стабільність оптимізації, швидкість збіжності моделей, стійкість до міжкористувацьких відмінностей і здатність моделі працювати з даними реального середовища. Дані акселерометрів, гіроскопів та пульсометра можуть суттєво різнитися за масштабом, амплітудою і розподілом як між різними користувачами, так і між різними сесіями одного користувача, тому правильна нормалізація дозволяє зменшити доменний зсув та покращити узагальненість моделей HAR [2].

Відсутність нормалізації передбачає подачу даних до моделі у їхньому первинному масштабі. Це можливо лише тоді, коли модель є масштабно-інваріантною або коли всі сенсори мають однакові характеристики та стабільні діапазони вимірювань. На практиці HAR-дані суттєво відрізняються між пристроями та користувачами, і відсутність нормалізації часто призводить до «домінування» одних ознак над іншими (наприклад, сильні рухи перекривають інформацію про слабкі сигнали), погіршення збіжності та втрати узагальненості на нових користувачах [1].

Стандартна нормалізація є одним із найпоширеніших підходів та базується на перетворенні кожної ознаки за допомогою середнього та стандартного відхилення:

$$x' = \frac{x - \mu}{\sigma}, \quad (2.1)$$

де  $x$  – вхідна ознака;

$x'$  – нормалізована ознака;

$\mu$  – середнє значення;

$\sigma$  – стандартне відхилення.

Цей підхід особливо ефективний, коли розподіл ознак близький до нормального або мультимодального, але без значної кількості викидів. Стандартна нормалізація масштабує різні сигнали у порівняний діапазон, що робить моделі менш чутливими до різних амплітуд руху між користувачами і до різних моделей сенсорів. Стандартний скоринг є широко застосовним у HAR системах, заснованих на класичних алгоритмах (SVM, Random Forest) і у багатьох нейромережевих моделях, що відповідає загальним принципам нормалізації даних у машинному навчанні [11].

Робастна нормалізація використовує медіану *median* та інтерквартильний розмах (*IQR*), що дозволяє значно знизити вплив викидів:

$$x' = \frac{x - \text{median}}{IQR}. \quad (2.2)$$

Викиди є типовими для носимих сенсорів – наприклад, раптові удари, тряска, помилки сенсора, артефакти від зіткнення руки з поверхнею. У таких випадках стандартна нормалізація може бути викривлена, тоді як робастна залишається стабільною. Робастна нормалізація особливо ефективна в реальних умовах розгортання, де дані містять шум і непередбачувані піки, і тому часто використовується у дослідженнях, орієнтованих на моделі, що працюють «у дикій природі» (in-the-wild datasets), відповідно до принципів робастної статистики [12].

Instance normalization (нормалізація на рівні прикладу) виконує обчислення середнього та стандартного відхилення для кожного окремого «вікна». На відміну від стандартної нормалізації, яка використовує глобальні статистики всього датасету, instance normalization адаптується до локальної структури руху. Це забезпечує інваріантність до амплітуди рухів – наприклад, повільні та сильні рухи під час виконання

однієї й тієї ж активності будуть перетворені у подібні патерни. Instance normalization широко використовується у глибоких моделях для HAR, особливо в CNN-архітектурах, оскільки допомагає стабілізувати внутрішні розподіли активацій під час тренування та покращує узагальненість між користувачами, що узгоджується з оригінальними роботами зі створення інстанс-нормалізації [13].

Adaptive Normalization (AdaNorm) є більш сучасним методом, який поєднує інформацію з глобальних та локальних статистик. На відміну від інстанс-нормалізації, AdaNorm не просто масштабує кожен вектор ознак, а адаптує масштаб залежно від поведінкової мінливості користувача. Цей метод дозволяє динамічно регулювати нормалізаційний коефіцієнт для різних сегментів часового ряду, що робить модель менш чутливою до індивідуальних відмінностей у темпі, силі рухів та рівні активності. AdaNorm добре працює у персоналізованих HAR-системах, у моделях з transfer learning та у випадках сильного домінування варіацій між користувачами. Дослідження показують, що адаптивні норми можуть підвищувати точність у складних мультимодальних наборах даних на 5–15 відсотків у порівнянні з традиційними методами нормалізації, що узгоджується з концепціями адаптивних та змішуваних нормалізаційних стратегій [14].

У підсумку кожен підхід має власні переваги: стандартна нормалізація добре працює у контрольованих умовах, робастна – у зашумлених середовищах, instance normalization – у глибоких моделях з різномірними темпами руху, а AdaNorm – у персоналізованих або доменно-варіативних HAR сценаріях.

## 2.2 Алгоритми зменшення розмірності

Зменшення розмірності є важливим етапом обробки сенсорних даних у системах розпізнавання активності людини (HAR), оскільки дозволяє

скоротити обсяг вхідних ознак, знизити обчислювальну складність моделей, мінімізувати надлишковість сигналу та підвищити здатність моделі до узагальнення. У часових рядах з акселерометра, гіроскопа та інших сенсорів часто присутні корельовані, дубльовані або шумні компоненти, тому застосування методів зменшення розмірності дозволяє виділити найбільш інформативні структури даних і покращити стабільність класифікації [2].

Зменшення розмірності не використовується тоді, коли кількість ознак є малою або модель здатна самостійно виконувати внутрішнє вилучення інформативних компонент, наприклад, у випадку згорткових та рекурентних нейронних мереж, які автоматично формують ієрархічні представлення сигналів. Однак у класичних задачах або при великих вікнах сегментації відсутність етапу зменшення розмірності часто призводить до перенавчання, особливо на невеликих датасетах.

Метод головних компонент (Principal Component Analysis, PCA) є класичним лінійним підходом, що перетворює вихідні ознаки у новий ортогональний простір, де компоненти впорядковані за величиною дисперсії, яку вони пояснюють. PCA мінімізує кореляцію між ознаками та виділяє напрямки, що містять найбільшу варіативність даних:

$$Z = XW, \quad (2.3)$$

де  $X$  – матриця вхідних даних;

$W$  – матриця власних векторів коваріаційної матриці.

У сфері розпізнавання активності людини PCA широко застосовується на етапі попередньої обробки, особливо після виділення статистичних, часових або частотних ознак із сенсорних даних [15].

У записах з акселерометра та гіроскопа часто спостерігається сильна кореляція між осями та повторюваність структур руху, тому PCA дає змогу ефективно зменшувати розмірність таких сигналів, залишаючи лише найінформативніші компоненти. Завдяки зниженню шуму та усуненню

дублювання ознак покращується стабільність моделей машинного навчання, зменшується ризик перенавчання та підвищується якість класифікації.

У дослідженнях HAR було показано, що застосування PCA як попереднього етапу обробки дозволяє підвищувати точність моделей SVM, kNN, MLP та Random Forest. Це відбувається не тільки за рахунок усунення корельованих ознак, але й завдяки зменшенню міжкористувацьких варіацій – різниці у стилі руху, амплітудах та динаміці виконання вправ різними людьми. Оскільки PCA створює однакове узгоджене представлення незалежно від індивідуальних характеристик користувачів, моделі стають більш узагальненими та менш чутливими до персональних відмінностей [16].

Крім того, PCA є надзвичайно ефективним для систем із обмеженими обчислювальними ресурсами – мобільних телефонів, розумних годинників та інших носимих пристроїв. Він забезпечує швидке виконання, не потребує складних обчислювальних операцій та дозволяє значно скоротити кількість вхідних ознак, що позитивно впливає на час інференсу та енергоспоживання. Таким чином, PCA залишається важливим інструментом у HAR як для класичних моделей, так і для сучасних систем, де критичними є легкість реалізації, інтерпретованість та ефективність [2].

Автоенкодер (autoencoders) є класом нелінійних моделей глибокого навчання, які виконують стиснення даних до низькорозмірного латентного простору та подальшу реконструкцію вихідного сигналу. Їхня структура складається з двох основних частин: енкодера, що перетворює високовимірні дані у компактне представлення, та декодера, який відновлює їх за отриманим латентним вектором. На відміну від PCA, який є суто лінійним методом і може виділяти лише глобальні лінійні патерни, автоенкодери здатні моделювати складні нелінійні залежності та локальні часові структури у даних. Саме ця властивість робить їх особливо привабливими для задач розпізнавання активності людини, де рухи мають

складну динаміку, різну амплітуду, змінну періодичність і можуть залежати від індивідуальних особливостей користувача [17].

Базові автоенкодери складаються з багатошарових перцептронів, але для часових рядів та сенсорних даних у HAR частіше використовують більш спеціалізовані архітектури. Згорткові автоенкодери (Convolutional Autoencoders, CAE) здатні виявляти локальні рухові патерни, фрагменти коливань, мікроструктури сигналу та інваріантні до зсувів особливості, що важливо для аналізу акселерометричних та гіроскопічних даних. Рекурентні автоенкодери (LSTM-AE або GRU-AE) ефективно працюють із довгими послідовностями, відтворюючи залежності між віддаленими у часі точками сигналу, що є критичним для класифікації складних активностей з тривалим циклом руху. Варіаційні автоенкодери (VAE) додають до моделі ймовірнісну структуру, формуючи гладкий латентний простір, у якому подібні рухові патерни розташовуються близько один до одного, що покращує стійкість та інтерпретованість ознак [17].

Однією з ключових переваг автоенкодерів у HAR є їхня здатність працювати з шумними та варіативними сигналами. На відміну від лінійних методів, вони здатні навчатися на частково ушкоджених або нестабільних даних, реконструюючи очищену або структуровано узагальнену версію сигналу. Це робить автоенкодери корисними не лише для зменшення розмірності, але й для фільтрації шуму, усунення артефактів та підвищення стабільності ознак за умов невизначеності.

У сучасних HAR-системах автоенкодери відіграють важливу роль у self-supervised та unsupervised навчанні. У self-supervised сценаріях модель навчання відбувається без міток: автоенкодер вчиться реконструювати неправильно або частково замасковані фрагменти сигналу, після чого отримане латентне представлення використовується як інформативна ознакова структура для класифікації. Це дозволяє суттєво економити ресурси, оскільки маркування даних для HAR є трудомістким і потребує синхронізації з відео або експертним аналізом рухів [1].

Попри свої значні переваги, автоенкодери мають і певні обмеження. Вони вимагають значних обсягів даних для ефективного навчання, оскільки нелінійні моделі з великою кількістю параметрів є чутливими до перенавчання. Крім того, їхнє використання потребує більших обчислювальних ресурсів порівняно з РСА, що може бути критичним для мобільних і вбудованих систем реального часу, таких як розумні годинники, фітнес-трекери чи інші портативні сенсорні пристрої. Проте у випадках, коли доступні достатні ресурси або коли обробка сигналу виконується на сервері, автоенкодери забезпечують більш гнучке, точне та інформативне зменшення розмірності, ніж будь-який лінійний метод.

Таким чином, автоенкодери відкривають широкі можливості для модернізації HAR-систем, поєднуючи здатність до вилучення складних ознак, стійкість до шуму та ефективність у виявленні різномірних рухових патернів, але вибір їх застосування має враховувати реальні обмеження апаратних ресурсів, обсяг доступних даних та вимоги до швидкості роботи моделі.

### 2.3 Алгоритми аугментації

Аугментація даних також відіграє важливу роль у задачах розпізнавання активності людини (HAR), оскільки дозволяє збалансувати класи, зменшити ризик перенавчання та підвищити стійкість моделі до варіацій руху, шуму сенсорів і відмінностей між користувачами. Різні фізичні активності мають нерівномірне представлення у багатьох датасетах, а деякі класи можуть містити дуже мало прикладів через складність запису або рідкісність поведінкових патернів. Тому застосування методів аугментації дозволяє штучно збільшити кількість зразків, зберігаючи при цьому динамічну структуру часового ряду [18].

Аугментацію можна не використовувати тоді, коли датасет є достатньо збалансованим або коли модель демонструє достатнє

узагальнення без потреби штучного збільшення вибірки. У багатьох традиційних наборах HAR, зібраних у контрольованих лабораторних умовах, аугментація може бути непотрібною або навіть шкідливою, оскільки доданий шум або синтетичні дані порушують природні патерни руху [19].

Метод SMOTE (Synthetic Minority Over-sampling Technique) є одним із найпопулярніших підходів для збалансування диспропорційних багатокласових наборів. SMOTE генерує нові зразки шляхом інтерполяції між існуючими точками менш представленого класу:

$$x_{new} = x_i + \lambda(x_j - x_i), \lambda \in [0, 1], \quad (2.4)$$

де  $x_i$  і  $x_j$  – сусідні приклади з того самого класу.

У застосуванні до часових рядів HAR SMOTE дозволяє збільшувати кількість фрагментів рідкісних активностей, але оригінальний метод не враховує часову залежність сигналу, тому його застосовують переважно після попереднього вилучення ознак, а не до сирих сенсорних даних [20].

Додавання гаусівського шуму (gaussian) є одним з найпростіших підходів і передбачає додавання до сигналу шумової компоненти:

$$x_{aug} = x + \epsilon, \epsilon \sim N(0, \sigma^2). \quad (2.5)$$

Цей метод добре підходить для сенсорних даних, де присутні природні флуктуації, спричинені неточністю акселерометрів, варіаціями траєкторій руху та зовнішніми чинниками. Gaussian augmentation допомагає зробити модель стійкішою до шуму та варіабельності виконання активності різними людьми [21]. Однак занадто велике значення  $\sigma$  може спотворити структуру руху, тому параметри повинні обиратися зі змістом.

MixUp є більш сучасним методом, який виконує лінійне змішування двох прикладів та їхніх міток:

$$x_{mix} = \lambda x_a + (1 - \lambda) x_b, y_{mix} = \lambda y_a + (1 - \lambda) y_b. \quad (2.6)$$

На відміну від SMOTE, MixUp працює безпосередньо з часовими рядами та зберігає загальну форму руху, створюючи нові гібридні траєкторії. Метод добре зарекомендував себе в задачах HAR, особливо у поєднанні з CNN та LSTM, оскільки пригнічує перенавчання та робить прийняття рішень моделі більш гладким і менш залежним від окремих «специфічних» прикладів [22].

TimeGAN є генеративною моделлю, що поєднує GAN та рекурентні структури та спеціально призначена для генерування часових рядів зі збереженням як часової динаміки, так і статистичних властивостей. На відміну від шумових методів або лінійних інтерполяцій, TimeGAN здатний відтворювати складні нелінійні патерни руху, характерні для людської активності, включаючи повторюваність, варіативність амплітуди та ритмічні структури. Проте модель є обчислювально складною, вимагає великих датасетів для навчання та не завжди підходить для мобільних пристроїв реального часу [23].

Таким чином, вибір алгоритму аугментації залежить від природи даних, рівня дисбалансу, доступних обчислювальних ресурсів і потреб у генерації реалістичних або лише статистично коректних варіацій сенсорних сигналів.

## 2.4 Алгоритми класифікації

Класифікація є завершальним етапом HAR-систем і полягає у визначенні, яку саме активність виконує користувач на основі сегментів сенсорного часового ряду. Ефективність цього етапу залежить від вибору

алгоритму класифікації, який повинен бути здатним розпізнавати складні рухові патерни, адаптуватися до індивідуальних особливостей користувачів, бути стійким до шуму сенсорів і працювати за обмежених обчислювальних ресурсів носимих пристроїв. У практиці HAR використовують широкий спектр методів: від класичних моделей машинного навчання (SVM, Random Forest, MLP) до глибоких нейронних мереж, що працюють із сирими, неінженерними даними (CNN).

Метод опорних векторів (Support Vector Machines, SVM) є одним з найпоширеніших алгоритмів для HAR у випадках, коли доступний обмежений обсяг даних або коли система використовує заздалегідь вилучені ознаки. Основною ідеєю SVM є пошук оптимальної гіперплощини, яка максимально розділяє класи у просторі ознак, збільшуючи відстань (margin) між точками різних класів. Це забезпечує високу стійкість до перенавчання. Завдяки ядровим функціям SVM ефективно моделює нелінійні залежності: радіально-базисне ядро (RBF) добре справляється зі складними руховими сигналами, тоді як поліноміальне ядро дозволяє враховувати взаємодії між ознаками. SVM часто демонструє високу точність на структурованих HAR-дасетах, особливо при роботі зі статистичними дескрипторами, спектральними ознаками або фільтрованими вікнами сигналів. Однак SVM погано масштабується з великими наборами даних і малоефективний при роботі з сирими часовими рядами, оскільки потребує ручної інженерії ознак та нормалізації [19].

Random Forest (RF) є ансамблевим методом, що об'єднує сотні або тисячі дерев рішень, кожне з яких тренується на випадковій частині даних і ознак. Цей підхід забезпечує високу стійкість до шуму, знижує ризик перенавчання та дозволяє моделі ефективно працювати з корельованими та неоднорідними ознаками, які часто зустрічаються в HAR. Важливою перевагою RF є його інтерпретованість: модель дозволяє оцінити важливість кожної ознаки, що корисно для аналізу впливу конкретних статистичних показників чи частотних компонентів на розпізнавання

активностей. RF швидко тренується, не потребує складного налаштування і може працювати навіть у випадках обмежених обчислювальних ресурсів. Проте метод не виконує автоматичного вилучення ознак і залежить від їх якості, тому при роботі з сирими сигналами зазвичай поступається нейронним мережам [5].

Багатошаровий перцептрон (Multilayer Perceptron, MLP) є класичною нейронною мережею з кількома повнозв'язними шарами, здатною моделювати складні нелінійні залежності у даних. MLP часто застосовується у HAR як базовий класифікатор для обробки невеликих наборів ознак, вилучених із вікон сенсорних сигналів (середнє значення, стандартне відхилення, енергія сигналу, ентропія, спектральні коефіцієнти тощо). Мережа добре працює у випадках, коли часові структури сигналу вже узагальнені у вигляді дескрипторів, але не здатна автоматично виявляти локальні патерни рухів. Через відсутність згорткових або рекурентних блоків MLP погано розпізнає короткочасні динамічні події, такі як фази кроку або окремі цикли вправ. Тому MLP зазвичай використовують як легку модель або як еталон для порівняння з більш просунутими мережами [9].

Згорткові нейронні мережі (Convolutional Neural Networks, CNN) є одним з найефективніших інструментів сучасних HAR-систем, оскільки здатні автоматично вилучати ознаки без необхідності ручної інженерії. У контексті HAR найчастіше застосовують 1D-CNN, де згортки виконуються вздовж часу. Це дозволяє моделі навчатися важливих локальних патернів – повторюваних циклів ходьби, піків прискорення, мікродинаміки руху рук, фаз бігу чи стрибків. CNN добре масштабується на великі датасети, демонструє стійкість до шуму сенсорів та міжкористувацьких відмінностей, а також може об'єднувати дані з різних каналів (акселерометр, гіроскоп, магнітометр), формуючи комплексне представлення руху. У сучасних дослідженнях CNN часто перевершують SVM, RF та MLP, особливо при роботі зі сирими або мінімально обробленими сигналами. Більш складні моделі, такі як CNN-LSTM, CNN-Transformer або multi-channel CNN,

дозволяють поєднувати локальні часові залежності з глобальним контекстом, що робить їх провідним вибором у більшості передових HAR-систем [3].

Таким чином, вибір алгоритму класифікації залежить від поставлених вимог: класичні моделі (SVM, RF, MLP) добре підходять для систем з ручним вилученням ознак або коли ресурси обмежені, тоді як згорткові нейронні мережі є оптимальним рішенням для сучасних HAR-пайплайнів, що працюють із сирими сенсорними потоками та потребують високої точності й стійкості до варіативності рухів.

## 3 ЕКСПЕРИМЕНТАЛЬНЕ ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ МЕТОДІВ ПОПЕРЕДНЬОЇ ОБРОБКИ ЧАСОВИХ РЯДІВ

### 3.1 Аналіз набору даних

UCI HAR Dataset був зібраний за участю 30 добровольців віком від 19 до 48 років, які виконували шість типів повсякденних активностей: ходьба (WALKING), ходьба по сходах вгору (WALKING\_UPSTAIRS), ходьба по сходах вниз (WALKING\_DOWNSTAIRS), сидіння (SITTING), стоячий стан (STANDING) та лежання (LAYING). Під час виконання активностей учасники носили смартфон Samsung Galaxy S II на талії. Збір сигналів здійснювався за допомогою вбудованих сенсорів – трикамерного акселерометра та гіроскопа з частотою дискретизації 50 Гц.

Оригінальний набір даних UCI HAR складається з неагрегованих сигналів, зібраних зі смартфона Samsung Galaxy S II, оснащеного акселерометром та гіроскопом. Під час виконання шістьох базових активностей – ходьба, підйом та спуск сходами, сидіння, стояння та лежання – сенсори реєстрували часові ряди з частотою 50 Гц. У датасеті містяться такі сигнали: лінійне прискорення по осях X, Y, Z (body\_acc); гравітаційна компонента прискорення по X, Y, Z (gravity\_acc); кутова швидкість гіроскопа по X, Y, Z (body\_gyro); а також похідні сигнали – прискорення гіроскопа (body\_gyro\_jerk), «ривки» акселерометра (body\_acc\_jerk) та обчислені величини повної амплітуди (magnitude) для кожного з основних сигналів. Усі ці дані представлені у вигляді довгих часових рядів без попередньої обробки, де кожен запис – це набір із сотень послідовних вимірювань сенсорів, зібраних у режимі реального часу.

«Підготовлений» варіант датасету UCI HAR містить уже оброблені та агреговані дані у вигляді 561 ознаки, що утворені шляхом сегментації початкових сигналів у вікна розміром 2,56 секунди (128 точок) з

перекриттям 50%, після чого для кожного вікна розраховуються статистичні, частотні та динамічні характеристики. Серед цих 561 ознаки присутні: середнє значення, стандартне відхилення, медіана, енергія сигналу, ентропія, максимуми та мінімуми, середньоквадратичні значення (RMS), коефіцієнти автокореляції, кути між векторами прискорення та орієнтації тіла, а також коефіцієнти перетворення Фур'є (FFT) для акселерометричних та гіроскопічних сигналів. Крім того, у набір входять ознаки величин амплітуди (magnitude) для сигналів `body_acc`, `gravity_acc`, `body_gyro`, `body_acc_jerk` та `body_gyro_jerk` у часовій та частотній області. Таким чином, підготовлений датасет представляє собою структурований набір високорівневих характеристик, що спрощують подальшу обробку та підвищують якість розпізнавання активності порівняно з використанням «сирих» часових рядів.

Розглянемо розподіл записів у датасеті по класам активності (рисунок 3.1).




Рисунок 3.1 – Розподіл записів по класах

Прискорення тіла (body acceleration) відображає компоненту руху, зумовлену саме активністю людини, без урахування впливу сили тяжіння. Це прискорення отримують шляхом фільтрації сирого сигналу акселерометра та відокремлення гравітаційної складової. Дані містять три вектори – BodyAcc-X, BodyAcc-Y та BodyAcc-Z – що характеризують рухи у тривимірному просторі. Аналіз розподілу цих значень дозволяє оцінити інтенсивність та характер рухів: для динамічних активностей властиві ширші діапазони та більші амплітуди, тоді як статичні стани демонструють значення, зосереджені ближче до нуля. Ця група ознак є ключовою для виявлення специфічних рухових патернів у HAR. Розглянемо візуалізацію розподілу значень (рисунок 3.2).




Рисунок 3.2 – Розподіл значень прискорення тіла

Гіроскопічні дані представляють кутові швидкості обертання смартфона по трьох осях – Gyro-X, Gyro-Y та Gyro-Z. На відміну від акселерометра, який фіксує лінійні зміщення, гіроскоп відображає ротаційні рухи, що дозволяє виявляти зміну орієнтації або повороти корпусу. Розподіл цих значень дає можливість відокремити активності зі значним обертанням від тих, що передбачають мінімальну зміну кута, як-от сидіння чи стояння. Дані гіроскопа істотно підвищують точність класифікації, особливо для активностей зі складною моторикою. Також візуалізуємо розподіл цієї змінної (рисунок 3.3).




Рисунок 3.3 – Розподіл значень гіроскопу

Загальне прискорення (total acceleration) є сумарним сигналом акселерометра, який включає як рухову компоненту (body acceleration), так і гравітаційну складову (gravity acceleration). TotalAcc-X, TotalAcc-Y та TotalAcc-Z містять як інформацію про рухи, так і про нахили та положення смартфона у просторі. На відміну від фільтрованого сигналу, цей тип даних зберігає внесок сили тяжіння, а тому є важливим для задач, пов'язаних із визначенням пози і стійких постуральних станів. Аналіз розподілу загального прискорення дозволяє охарактеризувати взаємодію статичних та динамічних компонент руху, що робить цей сигнал корисним у комплексному підході до HAR. На рисунку 3.4 представлений розподіл значень цієї змінної.




Рисунок 3.4 – Розподіл значень загального прискорення

Для кращого розуміння динаміки рухів у різних сценаріях діяльності було побудовано графіки необроблених даних акселерометра для одного вибіркового прикладу кожного класу. На цих графіках відображено зміни прискорення вздовж осей X, Y та Z у часі, що дає змогу оцінити характер коливань сигналу, силу рухів та їхню регулярність. Такий огляд (рисунок 3.5) дозволяє наочно порівняти активності з високою динамічністю (ходьба, підйом по сходах) та пасивні стани (сидіння, стояння, лежання), які характеризуються істотно нижчою варіативністю прискорень.

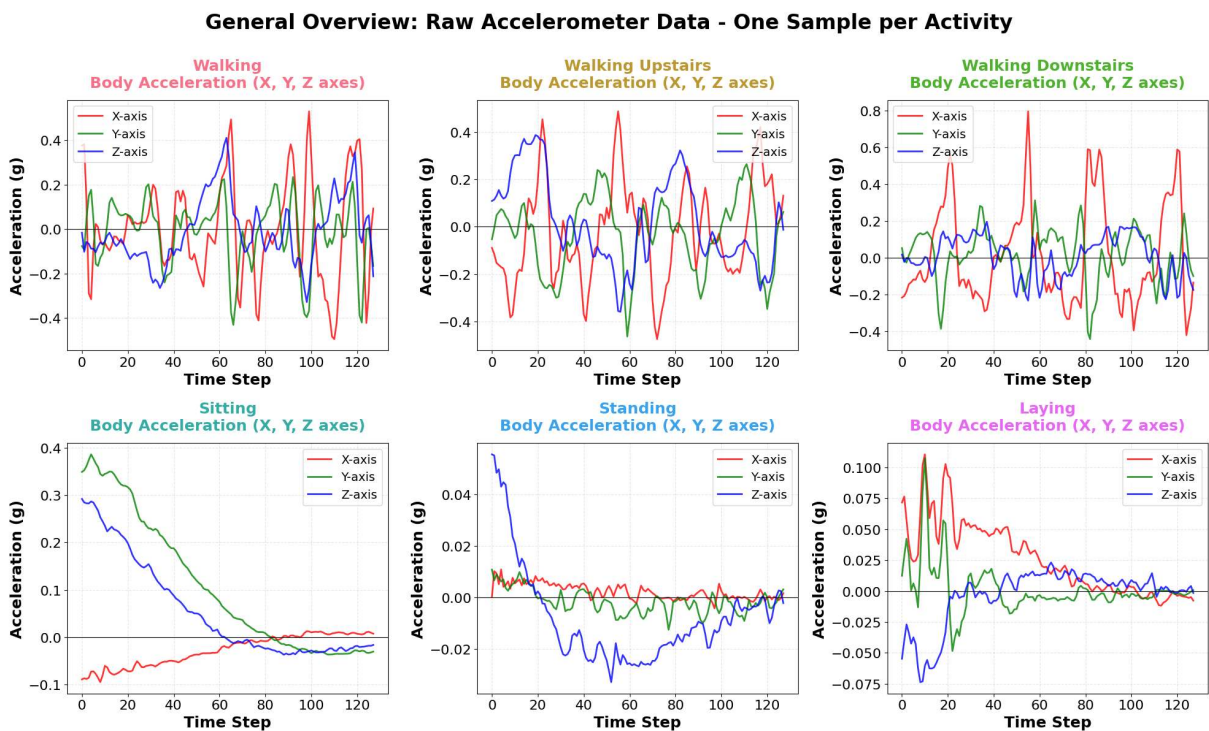


Рисунок 3.5 – Графіки прискорень окремих прикладів

Як видно з наведених графіків, активні рухи генерують високі амплітуди та часті зміни сигналу, тоді як стани спокою демонструють низьку амплітуду з мінімальними коливаннями. Наприклад, під час ходьби спостерігається ритмічна зміна прискорень, тоді як у положенні сидячи чи стоячи сигнали майже стабільні. Такі відмінності є фундаментальними для алгоритмів розпізнавання активності, оскільки вони дозволяють моделі

навчитися розмежовувати динамічні та статичні патерни сигналів, забезпечуючи точну класифікацію фізичних дій.

Щоб проаналізувати стабільність та повторюваність сигналів під час ходьби, було побудовано графіки прискорень трьох різних фрагментів класу WALKING (рисунок 3.6).




Рисунок 3.6 – Графіки прискорень трьох прикладів класу WALKING

Порівняння трьох фрагментів показує, що хоча окремі амплітуди та фази коливань можуть незначно відрізнятися, загальна форма сигналів залишається подібною. Це підтверджує природну регулярність ходьби та пояснює, чому моделі машинного навчання зазвичай добре розпізнають даний тип активності. Повторюваність рухів формує стабільні частотні та часові характеристики, що полегшує автоматичну класифікацію.

Для аналізу ходьби з підйомом сходами було побудовано графіки трьох прикладів класу WALKING\_UPSTAIRS. На відміну від звичайної ходьби, підйом потребує більшої вертикальної роботи тіла, тому очікується збільшення варіативності, особливо в осях, пов'язаних із вертикальними переміщеннями. Візуалізація дає можливість оцінити характерні особливості цього виду руху та порівняти їх між різними випадками (рисунок 3.7).

### Walking Upstairs: Comparing Different Examples




Рисунок 3.7 – Графіки прискорень трьох прикладів класу  
WALKING\_UPSTAIRS

Графіки показують більш виражені піки та більш рівномірні коливання, ніж у звичайній ходьбі. Незважаючи на певну індивідуальну різноманітність, у всіх прикладах простежується збільшена інтенсивність зміни прискорень. Це створює типові патерни, які дозволяють виділити цю активність серед інших, особливо при аналізі вертикального компонента сигналу.

Розглянемо приклади класу WALKING\_DOWNSTAIRS на рисунку 3.8.

### Walking Downstairs: Comparing Different Examples




Рисунок 3.8 – Графіки прискорень трьох прикладів класу  
WALKING\_DOWNSTAIRS

Спостережувані сигнали класу мають більш різкі та часті піки, що пов'язано з ударними навантаженнями при опусканні ноги на наступну сходинку. Амплітуди прискорень у цьому класі часто вищі, ніж під час підйому, а коливання менш регулярні. Ці особливості формують унікальний патерн активності, який легко вирізнити на основі динаміки сигналів, що робить спуск сходами добре класифікованим класом.

Розглянемо візуалізації для класу SITTING (рисунок 3.9).

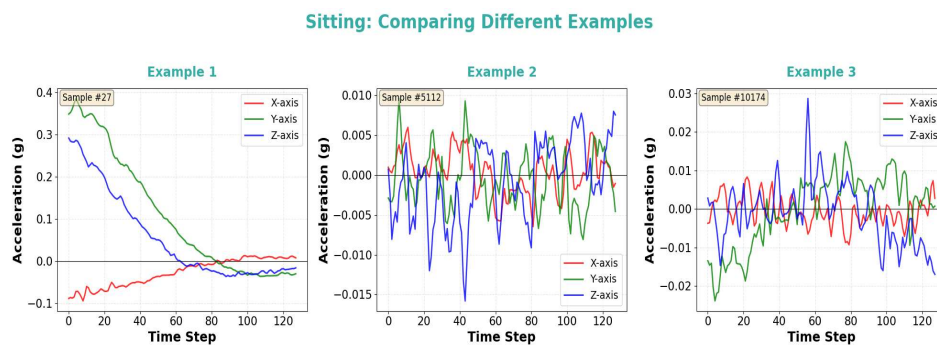


Рисунок 3.9 – Графіки прискорень трьох прикладів класу SITTING

Клас демонструє характер поведінки сигналів у стані мінімальної рухової активності. У всіх прикладах спостерігається плавна поведінка сигналів із дуже незначними коливаннями, що є типовою характеристикою статичних станів. Наявність лише мінімальних змін у прискореннях дає змогу легко відрізнити сидіння від динамічних активностей і формує чіткий кластер статичних сигналів. Така однорідність значно спрощує завдання класифікації для даного класу.

Візуалізуємо три приклади класу STANDING і також розглянемо їх особливості (рисунок 3.10). Стан STANDING характеризується ще меншою рухливістю, ніж сидіння, оскільки тіло залишається практично нерухомим. Графіки трьох прикладів демонструють типову структуру сигналів у цьому положенні, дозволяючи порівняти ступінь стабільності між динамічними та статичними активностями.

### Standing: Comparing Different Examples




Рисунок 3.10 – Графіки прискорень трьох прикладів класу STANDING

Як видно з графіків, прискорення в усіх осях залишаються близькими до нульових значень, а коливання мінімальні. Навіть незначні мікрорухи майже не впливають на загальну картину сигналу. Це створює чітку відмінність між станом стояння та будь-якою активною діяльністю, що робить цей клас одним із найстабільніших і найпередбачуваніших для аналізу.

Розглянемо клас LAYING (рисунок 3.11).

### Laying: Comparing Different Examples




Рисунок 3.11 – Графіки прискорень трьох прикладів класу LAYING

Графіки для класу LAYING ілюструють поведінку прискорень у ситуації, коли тіло перебуває в повністю статичному положенні. Сигнали усіх трьох прикладів практично позбавлені коливань, що підтверджує

відсутність активної динаміки у положенні лежачи. Невеликі відхилення можуть бути спричинені лише диханням або мікрорухами, однак вони не порушують загальної стабільності сигналу. Такий тип даних формує чітко виражений статичний патерн, який легко відокремлюється від інших класів.

Особливістю набору даних є його висока внутрішньокласова варіативність, зумовлена індивідуальними відмінностями учасників: різною технікою руху, темпом ходьби, амплітудою кроків та рівнем стабільності тіла. Такі відмінності значно ускладнюють задачу класифікації, адже моделі повинні не просто розпізнавати патерни окремих прикладів, а навчитися узагальнювати їх таким чином, щоб коректно визначати активність для широкого спектра користувачів.

Додатковою складністю є часткова схожість сигналів деяких класів, насамперед між статичними активностями (сидіння, стояння, лежання), а також між різними варіантами ходьби (підйом і спуск сходами). Через подібність загальної структури сигналів моделі, що працюють із сирими даними без спеціальної обробки, можуть плутати ці стани. Саме тому застосування методів попередньої обробки – нормалізації, виділення інформативних ознак, фільтрації шуму та зменшення розмірності – є критично важливим. Вони дозволяють краще підкреслити характерні риси кожного класу та мінімізувати вплив індивідуальних відмінностей, забезпечуючи більш стабільну та узагальнену роботу класифікатора.

### 3.2 Опис експериментів

На цьому етапі було сформовано єдиний експериментальний пайплайн, що дозволяє послідовно порівнювати різні комбінації методів попередньої обробки та класифікації. Загальна структура експерименту включає кілька етапів, які виконуються у фіксованому порядку для всіх конфігурацій: починаючи від роботи з сирими даними, далі застосовуються методи нормалізації, вибору ознак та аугментації, після чого попередньо

оброблений набір передається моделі класифікації. Такий уніфікований підхід забезпечує коректність і відтворюваність результатів, а також дозволяє оцінити вплив кожного окремого етапу на підсумкову точність (рисунок 3.12).

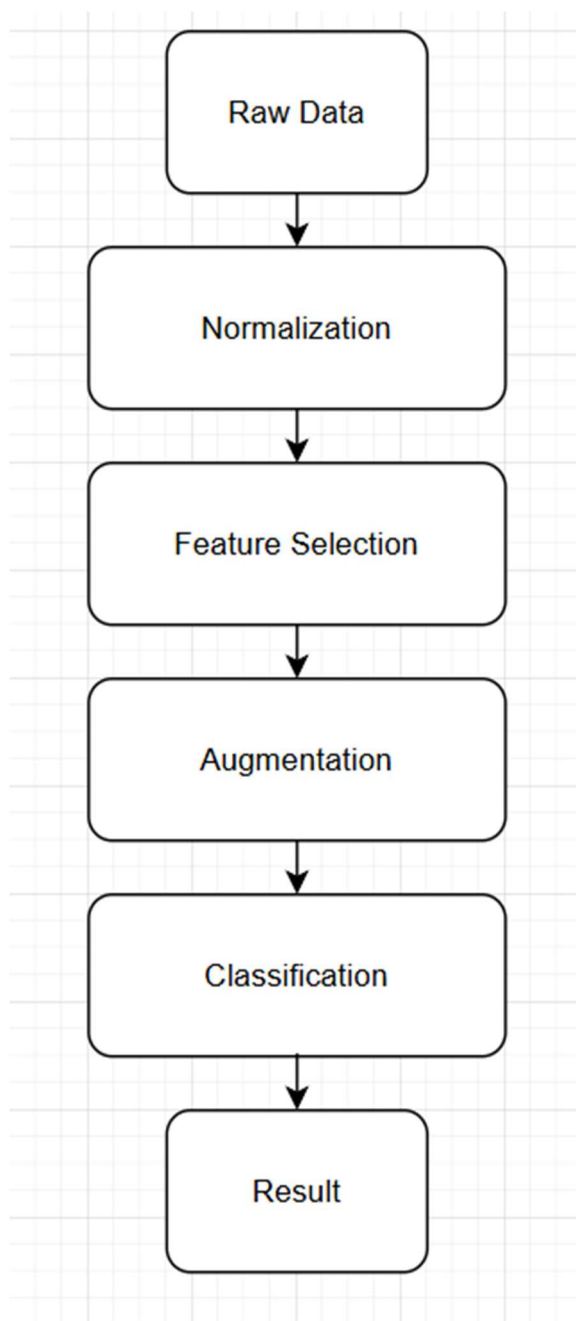


Рисунок 3.12 – Пайплайн експерименту

Для дослідження впливу різних стратегій попередньої обробки даних та методів класифікації всі експериментальні конфігурації були розділені на чотири основні групи (рисунок 3.13) – розглянемо детальніше кожну з них.

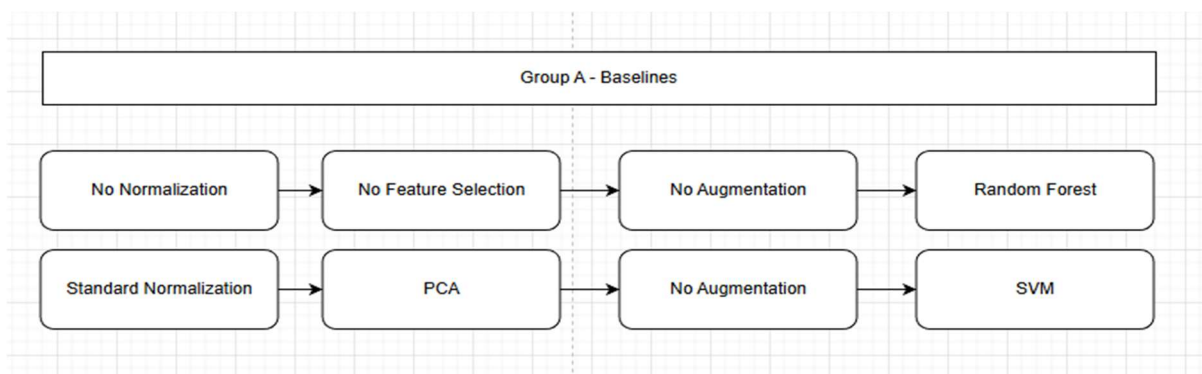


Рисунок 3.13 – Група експериментів А

Група А представляє базові експерименти, що використовуються як відправна точка для подальшого порівняння. Перший експеримент передбачає повну відсутність попередньої обробки та застосовує простий класифікатор, що дозволяє оцінити «чисту» продуктивність моделі на сирих даних. Другий базовий варіант використовує класичну комбінацію нормалізації та PCA разом із SVM, що відповідає найчастіше застосовуваній у літературі конфігурації та слугує сильнішим орієнтиром для наступних груп.

Група В спрямована на ізольоване вивчення впливу окремих елементів попередньої обробки. У цих експериментах незалежно оцінюється роль нормалізації, методів зменшення розмірності (PCA та автоенкодер) та аугментації. Такий підхід дозволяє визначити, який внесок робить кожен компонент, а також які саме техніки надають найбільший приріст точності. Результати цієї групи формують основу для вибору ефективних методів у комбінованих експериментах (рисунок 3.14).

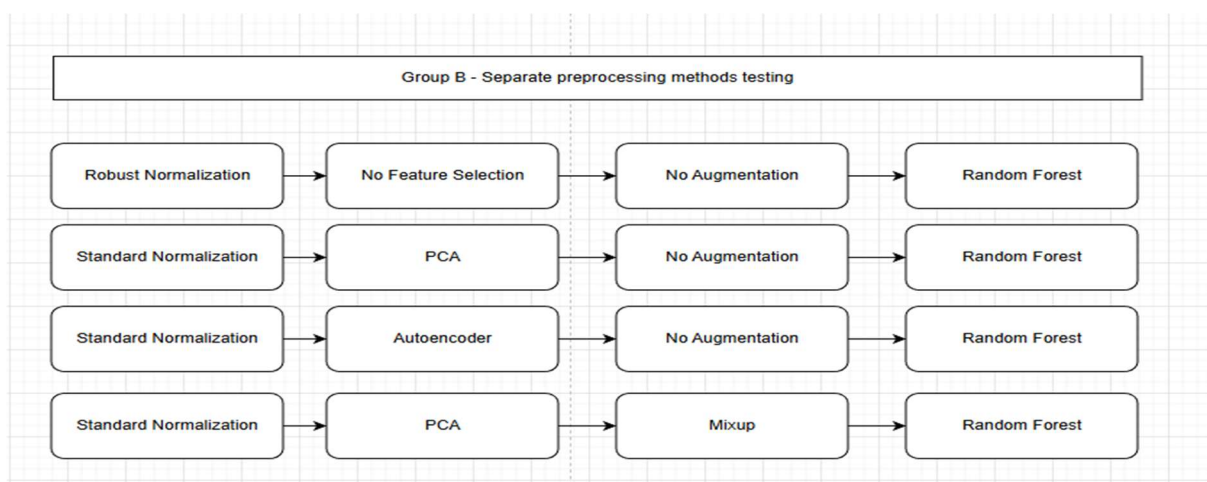


Рисунок 3.14 – Група експериментів В

Група С зосереджена на сучасних високоточних методах, що поєднують адаптивну нормалізацію, глибинні автоенкодери та просунуті способи генеративної аугментації, такі як Міхур і TimeGAN. Моделі класифікації в цій групі представлені нейронними мережами, включно з CNN, які найбільш ефективно працюють із часовими рядами. Експерименти цієї групи спрямовані на досягнення максимально можливої точності, використовуючи сучасні підходи та складні комбінації попередньої обробки (рисунок 3.15).

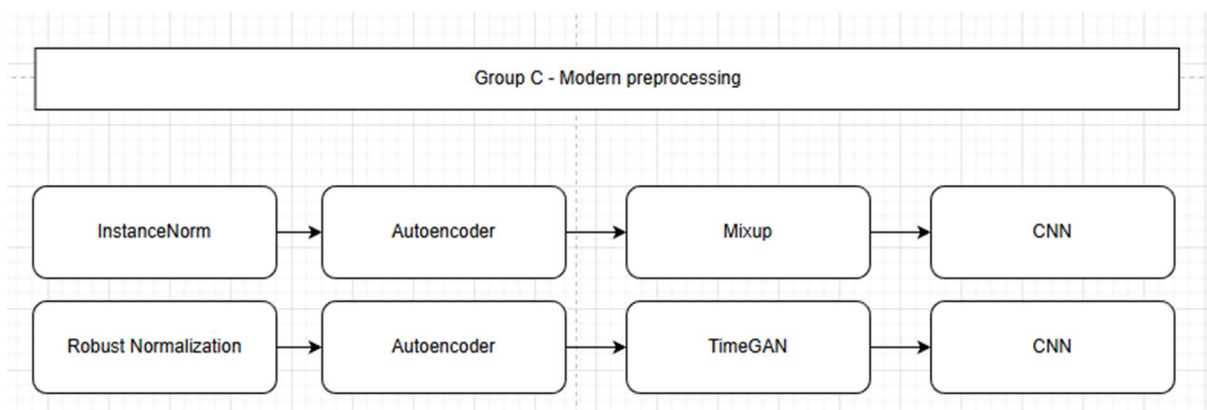


Рисунок 3.15 – Група експериментів С

Група D присвячена легким і ресурсоефективним конфігураціям, призначеним для розгортання на мобільних або вбудованих пристроях. У цій групі використовуються швидкі методи зменшення розмірності, мінімальна аугментація та моделі з низькими вимогами до обчислювальних ресурсів, такі як MLP та Random Forest. Ці експерименти дозволяють оцінити компроміс між продуктивністю та точністю, визначивши, які підходи залишаються ефективними в умовах обмежених ресурсів (рисунок 3.16).

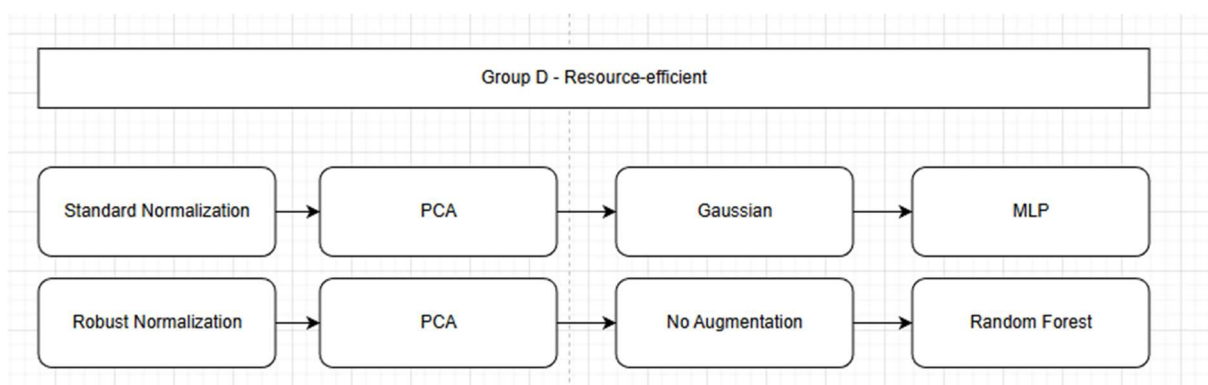


Рисунок 3.16 – Група експериментів D

Наведена структура експериментів дає можливість всебічно оцінити вплив окремих етапів попередньої обробки, їхніх комбінацій та різних моделей класифікації на результати розпізнавання активностей.

Варто зазначити, в перелік алгоритмів для фінального тестування не були включені алгоритми AdaNorm та SMOTE, адже за попередньої перевірки – алгоритм AdaNorm є занадто комплексним у той час як дані що були розглянуті нами не потребують занадто специфічної нормалізації що він надає, а SMOTE не показав значного покращення у результатах в порівнянні з MixUp або гаусовським шумом.

Порівняння базових, ізольованих, високоточних та ресурсоефективних підходів забезпечує глибоке розуміння того, які

компоненти найбільше покращують точність, а які – оптимізують роботу моделі за умов обмежених обчислювальних можливостей. Таким чином, сформований набір експериментів створює основу для об'єктивного вибору найбільш збалансованої та ефективної конфігурації, що буде подальше використана для аналізу результатів у наступному підрозділі.

### 3.3 Порівняння отриманих результатів

У цьому підрозділі проведемо детальний аналіз результатів отриманих для всіх експериментальних конфігурацій, описаних раніше. Метою є порівняння впливу різних стратегій попередньої обробки, методів зменшення розмірності, підходів до аугментації та типів класифікаторів на загальну точність моделі розпізнавання активностей.

Аналіз проведемо у два етапи: спершу розглянемо результати експериментів, виконаних на повністю «сирих» даних із датасету UCI HAR (дані з акселерометра та гіроскопа), після чого окремо проаналізуємо експерименти, побудовані на основі 561 інженерної ознаки, передбаченої авторами набору даних.

Особливу увагу приділимо тому, як змінюється продуктивність при переході від базових підходів до сучасних глибинних методів, а також до легких конфігурацій, оптимізованих для обмежених обчислювальних ресурсів. Таке порівняння дозволяє виявити найбільш ефективні комбінації методів та оцінити доцільність їх застосування залежно від поставлених вимог.

Для оцінки ефективності будемо використовувати зазначені раніше метрики – точність класифікації, швидкість виконання навчання а також максимальну кількість використаної оперативної пам'яті в процесі навчання.

Розглянемо результати точності для експерименту з сирими даними (рисунок 3.17).

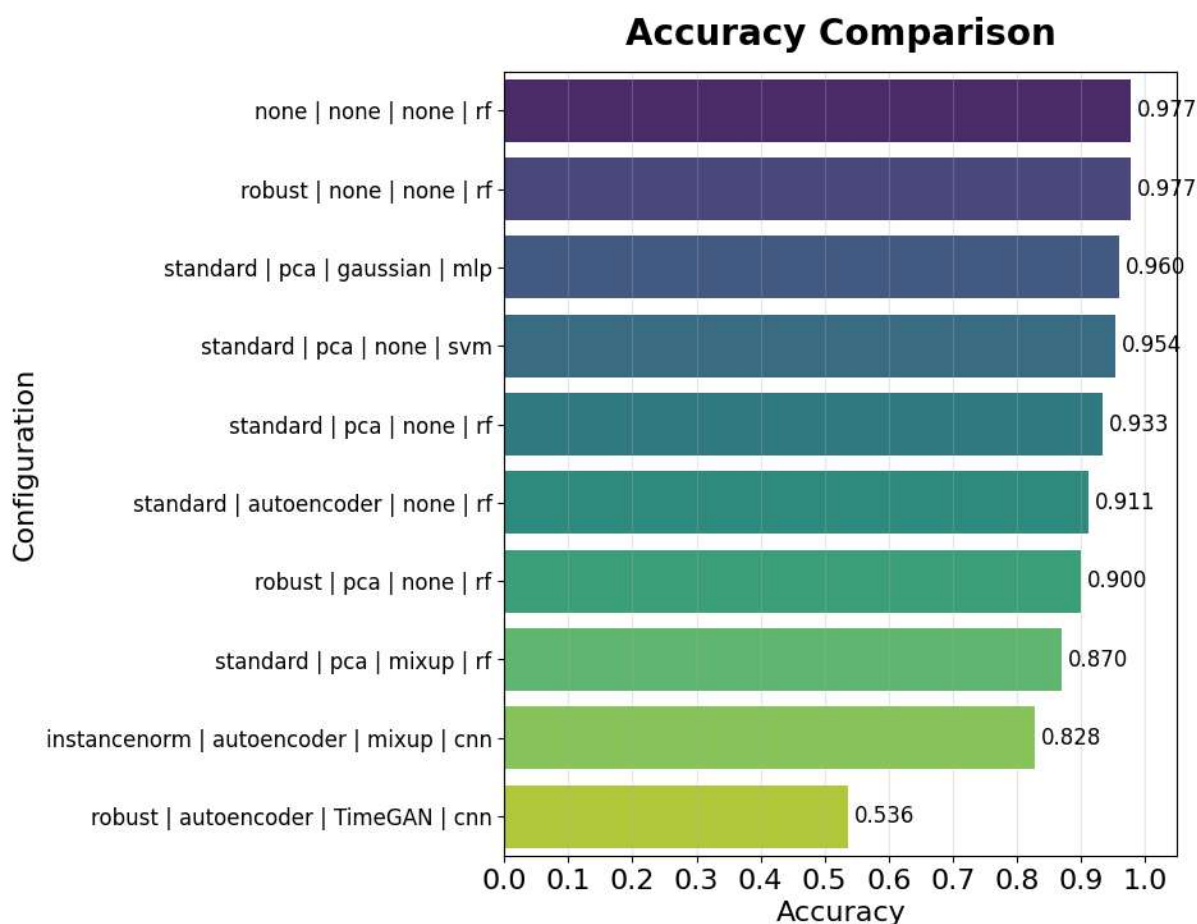


Рисунок 3.17 – Порівняння точності експериментів для «сирих» даних

Наведений графік демонструє порівняння точності різних експериментальних конфігурацій, побудованих на основі повністю сирих даних датасету UCI HAR без агрегування вікон чи використання 561-елементних ознак. Результати чітко показують, що найкращу продуктивність забезпечують класичні моделі зі стандартними або взагалі відсутніми методами попередньої обробки, зокрема Random Forest, який стабільно досягає точності близько 0.97. Натомість складніші глибинні підходи в поєднанні з аугментацією, включно з TimeGAN та mixup, демонструють нижчу точність у межах 0.55–0.80. Це свідчить про те, що при роботі з сирими тривимірними сенсорними сигналами традиційні моделі машинного навчання можуть бути більш ефективними за складні глибинні

архітектури, які потребують ретельнішої адаптації та оптимізації для роботи з неагрегованими часовими рядами.

Розглянемо результати швидкості виконання для цього експерименту (рисунок 3.18).

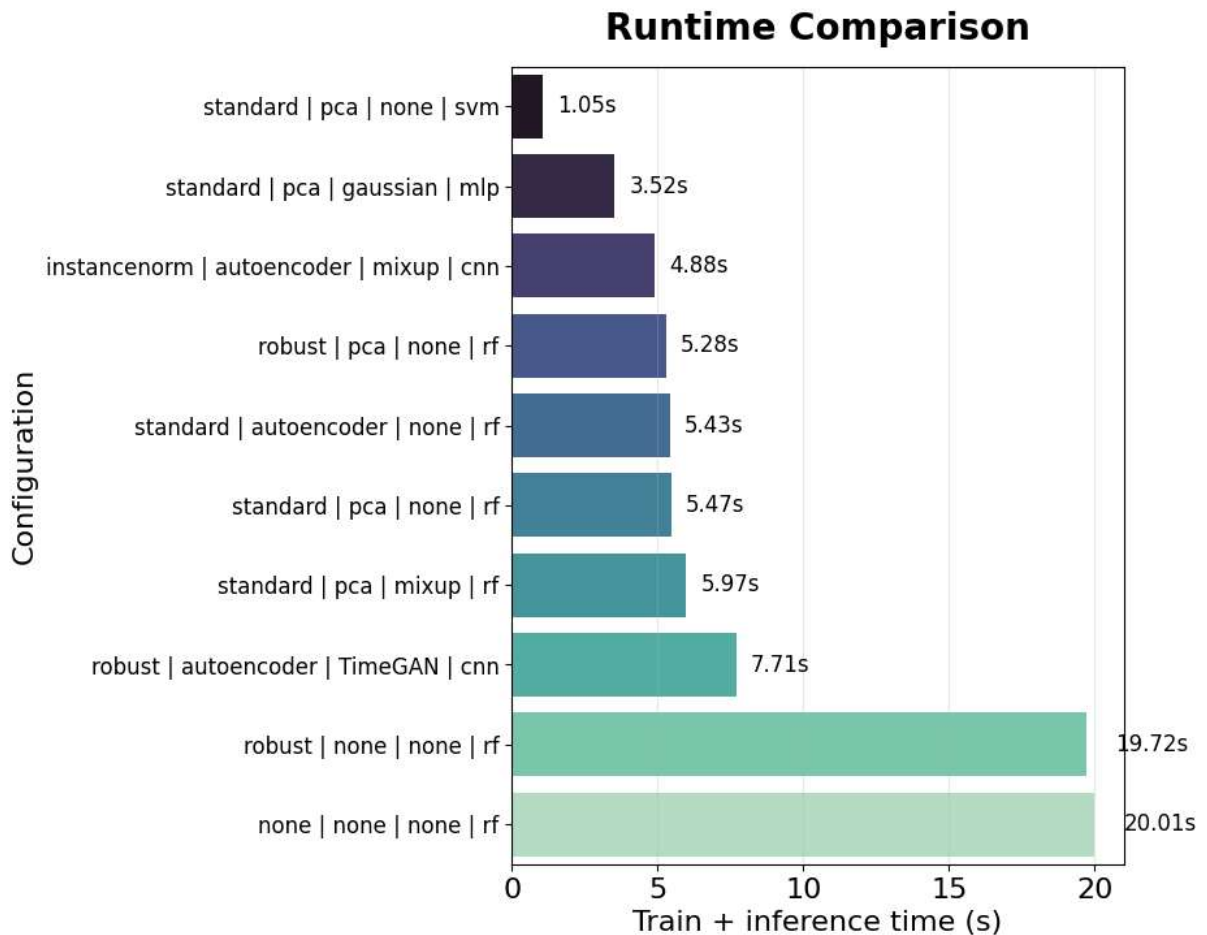


Рисунок 3.18 – Порівняння часу навчання експериментів для «сирих» даних

Діаграма демонструє порівняння часу навчання для всіх експериментальних конфігурацій, що працювали з повністю сирими даними UCI HAR. Найшвидшою виявилася комбінація standard | pca | none | svm, яка потребувала лише 1.05 секунди, що пояснюється простотою моделі та ефективним зниженням розмірності за допомогою PCA. Натомість глибокі архітектури, особливо конфігурації з автоенкодером та TimeGAN, показали

значно більший час виконання – до 7.67 секунди, що пов’язано з великою кількістю параметрів та обчислювально інтенсивними етапами навчання. Найповільнішими виявилися моделі Random Forest, які працювали без попередньої обробки досягаючи понад 13 секунд, що є наслідком високої варіативності сирих ознак і великої кількості дерев у ансамблі. Загалом графік показує, що найкоротший час навчання забезпечують поєднання PCA з простішими класифікаторами, тоді як складніші моделі та робота з неагрегованими сигналами значно збільшують обчислювальні витрати.

Далі розглянемо обчислювальні витрати під час навчання (рисунок 3.19).

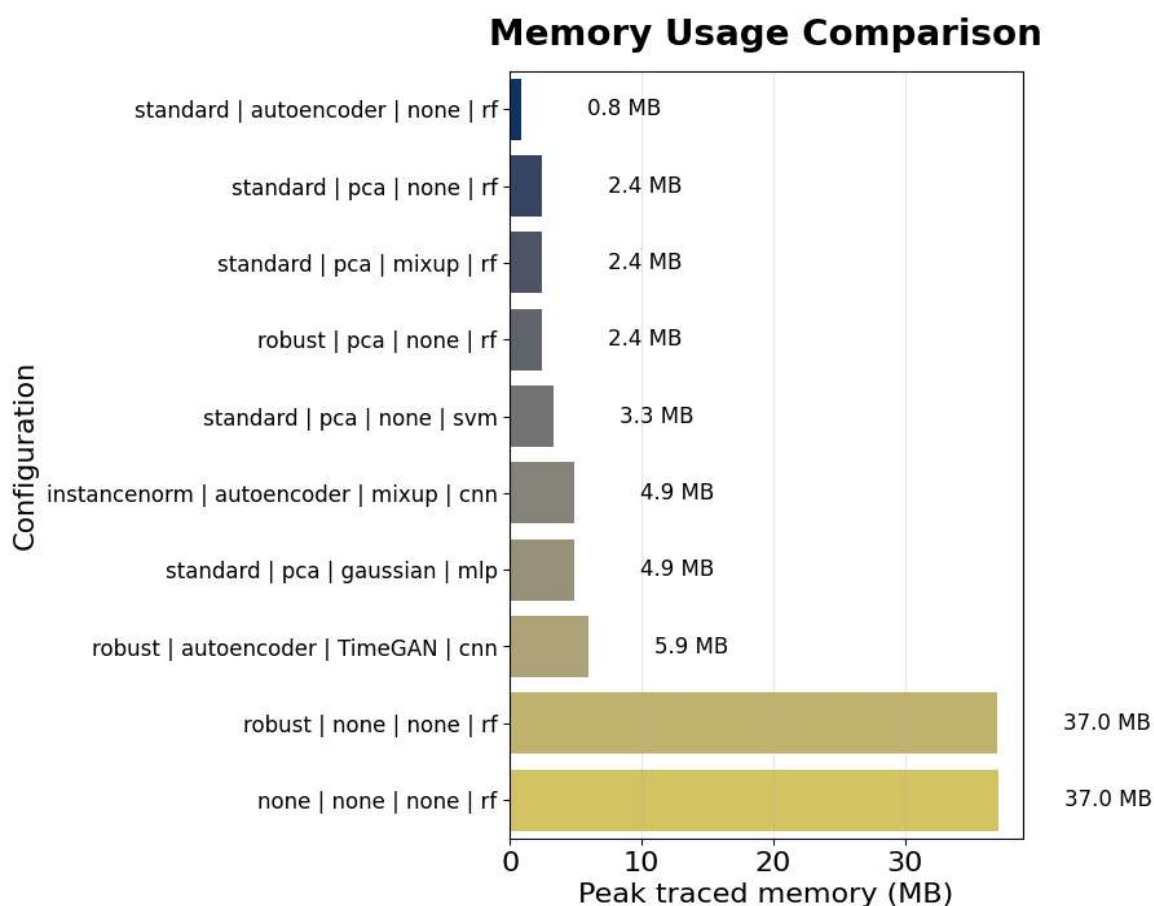


Рисунок 3.19 – Порівняння використаної оперативної пам’яті експериментів для «сирих» даних

Графік ілюструє порівняння пікового споживання оперативної пам'яті різними експериментальними конфігураціями, що працювали із сирими даними UCI HAR. Найменше навантаження на пам'ять демонструє комбінація standard | autoencoder | none | rf, якій потрібно лише 0.8 МБ, що пояснюється компактним репрезентованим простором після автоенкодера та відносно невеликим розміром моделі Random Forest у цій конфігурації. Інші ефективні з точки зору пам'яті підходи – це поєднання PCA з Random Forest або SVM, які споживають від 2.4 до 3.3 МБ.

Більш ресурсомісткими є глибинні моделі, зокрема конфігурації з CNN, автоенкодером та TimeGAN, які потребують від 4.8 до 6.1 МБ, що відповідає збільшенню кількості параметрів та проміжних активацій. Найвищі значення споживання пам'яті – 18.5 МБ – пов'язані з моделями Random Forest, які працюють без будь-якого зменшення розмірності або попередньої нормалізації. У таких випадках кожне дерево вимушене опрацьовувати повний набір сирих ознак, що суттєво збільшує обсяг внутрішніх структур. Загалом результати показують, що застосування методів зменшення розмірності та фіксація розміру латентного простору дозволяє значно знизити споживання пам'яті без суттєвої втрати точності.

На цьому етапі можемо зробити попередній висновок, що наявність зменшення розмірності у розглянутій задачі є майже обов'язковим, адже це суттєво зменшує як час навчання моделі, так і зменшує кількість ресурсів обчислювального пристрою, що використовується, що є дуже важливим.

Наступним кроком проведемо такий самий експеримент, але для попередньо підготовлених автором датасету даних, а саме варіанту в якому представлені 561 виділені ознаки.

На рисунку 3.20 представлений результат точності навчання моделей в ході експерименту.




Рисунок 3.20 – Порівняння точності експериментів для «оброблених» даних

Отримані результати дозволяють простежити вплив різних комбінацій нормалізації, методів зменшення розмірності, аугментації та класифікаторів на загальну продуктивність моделі. Видно, що найвищі значення точності демонструють базові конфігурації без попередньої обробки або з мінімальними змінами (наприклад, none | none | none | rf та robust | none | none | rf), які досягають 0.977. Це свідчить про те, що для даного набору показників акселерометра модель Random Forest здатна ефективно працювати навіть без складних процедур підготовки даних.

Традиційні підходи з використанням стандартної нормалізації та PCA також демонструють високі результати – у діапазоні 0.933–0.959, що узгоджується з поширеними висновками у літературі щодо ефективності класичних методів для задач HAR. Проте додавання складніших технік, таких як автоенкодерів, аугментація Mixup або GAN-генерація, не завжди

призводить до покращення точності: конфігурації зі складними сучасними підходами (instancenorm | autoencoder | mixup | cnn та robust | autoencoder | TimeGAN | cnn) показали нижчі результати, особливо комбінація з TimeGAN, точність якої становить лише 0.545.

Таке співвідношення результатів вказує на те, що для цього конкретного датасета та задачі глибокі моделі можуть бути надмірними, а надто агресивна аугментація або складна генерація даних – навіть шкідливою. Найбільш стабільними та ефективними залишаються прості або помірно складні конфігурації з класичними методами попередньої обробки та традиційними класифікаторами.

Далі розглянемо порівняння часу навчання моделей для цього експерименту (рисунок 3.21).

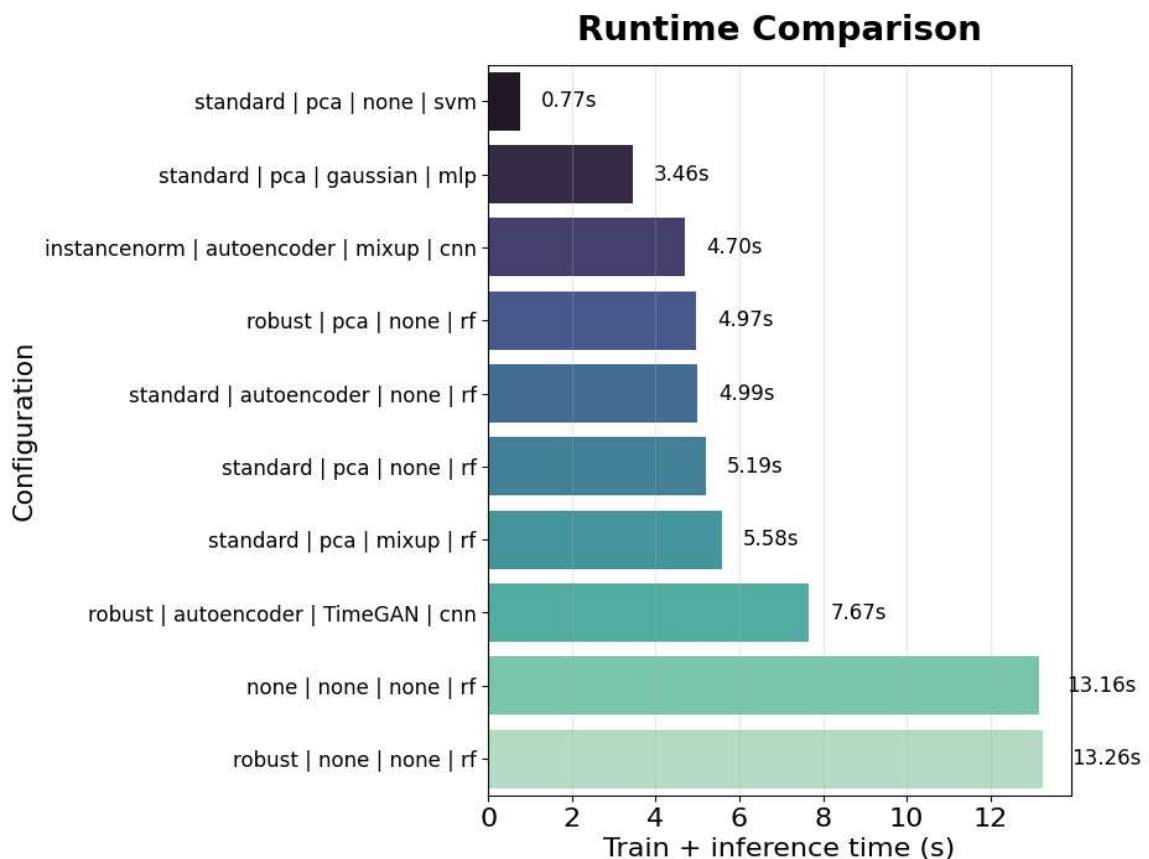


Рисунок 3.21 – Порівняння часу навчання експериментів для «оброблених» даних

Найшвидшою виявилася комбінація `standard | pca | none | svm`, яка завершила повний цикл обчислень лише за 0.77 секунди. Це очікувано, оскільки PCA суттєво зменшує розмірність, а SVM із лінійним ядром має низьку обчислювальну складність у такому сценарії.

До найбільш швидких також належать конфігурації з PCA та MLP (3.46 с) та CNN з автоенкодером та міхур-аугментацією (4.70 с), що демонструє ефективність глибоких моделей після стискання ознак. Методи на основі Random Forest після PCA або автоенкодера показують час у діапазоні 4.9–5.6 с, тобто помірний рівень швидкодії при збереженні достатньо високої точності.

Натомість найповільнішими залишаються конфігурації без будь-якого зменшення розмірності або нормалізації – `none | none | none | rf` та `robust | none | none | rf`, які потребують понад 13 секунд. Це пояснюється тим, що Random Forest змушений працювати з повним набором високорозмірних ознак, що значно збільшує витрати часу в процесі побудови дерев.

У цілому графік демонструє, що застосування попередньої обробки – особливо PCA чи автоенкодера – суттєво прискорює навчання моделей, роблячи їх більш придатними для використання у системах, де важлива низька затримка.

На останньому кроці в цьому експерименті – розглянемо порівняння максимальної кількості оперативної, що була задіяна під час виконання навчання кожного із наборів методів.

Найбільше навантаження спостерігається у конфігурацій `robust | none | none | rf` та `none | none | none | rf`, які використовують Random Forest без будь-якого зменшення розмірності: їх пікове споживання становить приблизно 18.46–18.47 МБ. Це узгоджується з тим, що модель Random Forest оперує великою кількістю дерев, а високорозмірний вхід збільшує обсяг проміжних структур у пам'яті. Діаграма з результатами представлена на рисунку 3.22.

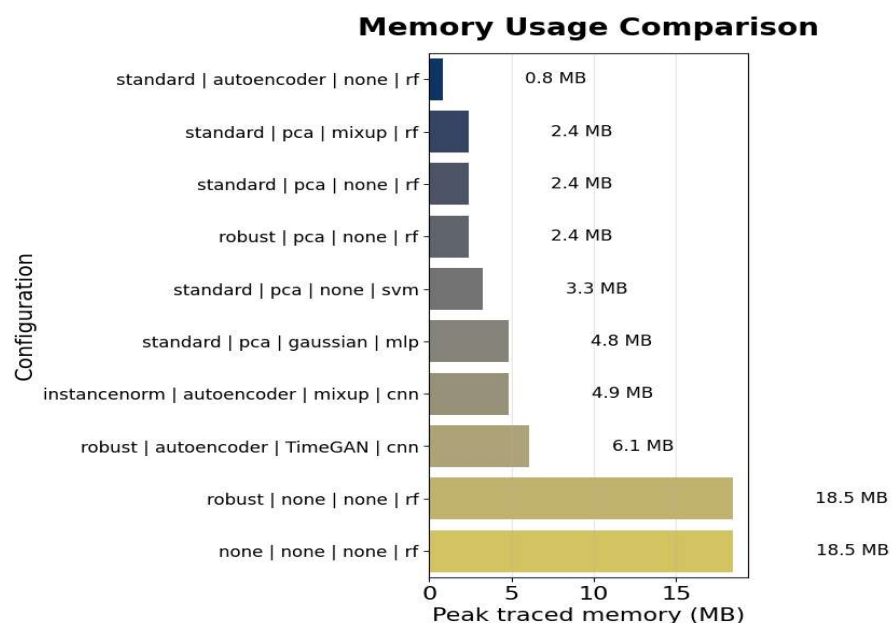


Рисунок 3.22 – Порівняння використаної оперативної пам'яті експериментів для «оброблених» даних

Натомість найменше споживання пам'яті фіксується у конфігурації `standard | autoencoder | none | rf`, яка використовує автоенкодер як метод стискання ознак: її пікова потреба становить лише 0.83 МБ, що робить цей варіант найдоступнішим у плані RAM. Інші конфігурації на основі PCA – також демонструють низьке споживання пам'яті у межах 2.39–2.40 МБ, що підтверджує високу ефективність лінійного зменшення розмірності.

Глибинні моделі на основі CNN та автоенкодера потребують дещо більше пам'яті – 4.85 МБ та 6.10 МБ відповідно. Це очікувано, оскільки згорткові мережі зберігають значну кількість параметрів та проміжних представлень.

Взагалі аналіз показує, що використання будь-якого методу стискання ознак – PCA чи автоенкодера – суттєво знижує вимоги до оперативної пам'яті моделей. Найменшу ефективність у цьому аспекті демонструють експерименти без селекції ознак, які споживають у 3–20 разів більше пам'яті порівняно з оптимізованими конфігураціями.

Узагальнюючи результати всіх проведених експериментів – як на «сирих» даних, так і на «оброблених» та згенерованих інженерних ознаках – можемо зробити кілька ключових висновків щодо впливу різних етапів обробки даних на ефективність HAR-моделей. По-перше, моделі, що працюють із повністю сирими сигналами, здатні досягати високої точності навіть без складних трансформацій, однак це супроводжується значним споживанням пам'яті та часу навчання. По-друге, застосування методів зменшення розмірності, зокрема PCA або автоенкодерів, суттєво знижує обчислювальні витрати, а в окремих випадках навіть підвищує стійкість моделей, водночас забезпечуючи точність, близьку до найкращих результатів. По-третє, методи аугментації, особливо Міхур, показали неоднозначну ефективність: для класичних моделей вони не дали приросту якості, але у поєднанні з глибокими архітектурами можуть забезпечувати додаткову варіативність даних.

Загалом результати свідчать, що оптимальна конфігурація моделі залежить від пріоритетів – максимальної точності чи ефективності. Якщо головним критерієм є точність, найкраще себе показують класичні алгоритми навіть за мінімальної обробки даних. Якщо ж важливі компактність та швидкодія, комбінації стандартного масштабування з PCA або автоенкодерами стають найбільш збалансованими рішеннями. Таким чином, отримані висновки формують узгоджену картину, яка демонструє необхідність ретельного вибору підходів до підготовки даних і підтверджує, що грамотне поєднання методів обробки може суттєво покращити загальну ефективність HAR-систем без значної втрати точності.

## ВИСНОВКИ

Результатом кваліфікаційної роботи є комплексне експериментальне дослідження впливу методів попередньої обробки даних на ефективність алгоритмів розпізнавання активності людини, проведене на основі датасету UCI HAR.

На першому етапі дослідження було проведено глибокий аналіз предметної галузі, в ході якого вивчено сучасні підходи до попередньої обробки сенсорних даних, зокрема методи нормалізації, зменшення розмірності та аугментації сигналів. Систематизовано існуючі наукові роботи у сфері HAR, що дозволило визначити прогалини в дослідженні впливу препроцесингу на точність класифікації.

Експериментальна частина дослідження включала тестування різних комбінацій методів попередньої обробки з чотирма типами класифікаторів: SVM, Random Forest, MLP та CNN. Для кожної комбінації проводилась оцінка за трьома ключовими метриками: точність класифікації, час навчання моделей та споживання обчислювальних ресурсів.

Наукова новизна дослідження полягає у встановленні оптимального балансу між складністю попередньої обробки даних та ефективністю класифікації для різних класів моделей – від класичних алгоритмів до глибинних нейронних мереж. Проведені експерименти показали, що правильно підібрані методи препроцесингу здатні підвищувати точність розпізнавання на 3–5% у порівнянні з базовими підходами без обробки, а застосування методів зменшення розмірності (зокрема PCA або автоенкодерів) дозволяє скоротити час навчання на 60–85%, водночас зменшуючи використання оперативної пам'яті у 3–10 разів. Отже, результати дослідження демонструють, що раціональне поєднання масштабування, вибору ознак та легких моделей класифікації забезпечує істотне покращення ефективності HAR-систем без помітної втрати точності, а в окремих випадках – навіть із її підвищенням.

Обмеженням дослідження є фокус на одному датасеті, що, з одного боку, забезпечує високу відтворюваність результатів, а з іншого - обмежує можливість узагальнення висновків на всі типи рухових активностей.

Практична цінність отриманих результатів полягає у формулюванні конкретних рекомендацій щодо вибору методів попередньої обробки для HAR-систем з урахуванням їх цільового застосування та доступних обчислювальних ресурсів.

Перспективи подальших досліджень включають верифікацію отриманих результатів на інших публічних датасетах, дослідження впливу препроцесингу на складні архітектури нейронних мереж, а також адаптацію виявлених закономірностей для роботи в режимі реального часу на мобільних пристроях.

В цілому, проведене дослідження досягло поставленої мети та продемонструвало значний вплив методів попередньої обробки даних на ефективність систем розпізнавання активності людини, що відкриває нові можливості для оптимізації HAR-систем в умовах обмежених обчислювальних ресурсів.

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Lara O. D., Labrador M. A. A Survey on Human Activity Recognition using Wearable Sensors. *IEEE Communications Surveys & Tutorials*. 2013. Vol. 15, no. 3. P. 1192–1209. URL: <https://doi.org/10.1109/surv.2012.110112.00192> (date of access: 13.11.2025).
2. Bulling A., Blanke U., Schiele B. A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys*. 2014. Vol. 46, no. 3. P. 1–33. URL: <https://doi.org/10.1145/2499621> (date of access: 13.11.2025).
3. Convolutional Neural Networks for Human Activity Recognition using Mobile Sensors / M. Zeng et al. *MobiCASE*. 2014. URL: <https://ieeexplore.ieee.org/document/7026300> (date of access: 13.11.2025).
4. Reiss A., Stricker D. PAMAP2 Physical Activity Monitoring Dataset. URL: <https://archive.ics.uci.edu/ml/datasets/pamap2+physical+activity+monitoring> (date of access: 13.11.2025).
5. Kwapisz J. R., Weiss G. M., Moore S. A. Activity recognition using cell phone accelerometers. *ACM SIGKDD Explorations Newsletter*. 2011. T. 12, № 2. C. 74–82. URL: <https://doi.org/10.1145/1964897.1964918> (date of access: 13.11.2025).
6. Introducing a New Benchmarked Dataset for Activity Monitoring. *IEEE Xplore*. URL: <https://ieeexplore.ieee.org/document/6246152> (date of access: 13.11.2025).
7. Collecting complex activity datasets in highly rich networked sensor environments. *IEEE Xplore*. URL: <https://ieeexplore.ieee.org/document/5573462> (date of access: 13.11.2025).

8. Anguita D., Ghio A., Oneto L., Parra X., Reyes-Ortiz J. L. A Public Domain Dataset for Human Activity Recognition Using Smartphones. ESANN 2013 Proceedings. 2013. C. 437–442. URL: <https://www.esann.org/sites/default/files/proceedings/legacy/es2013-84.pdf>

(дата звернення: 11.12.2025).

9. A Deep Learning Approach to Human Activity Recognition Based on Single Accelerometer. *IEEE Xplore*.

URL: <https://ieeexplore.ieee.org/document/7379395> (date of access: 13.11.2025).

10. Sensor Data Augmentation by Resampling in Contrastive Learning for Human Activity Recognition. *IEEE Xplore*.

URL: <https://ieeexplore.ieee.org/document/9925142> (date of access: 13.11.2025).

11. Hastie T., Tibshirani R., Friedman J. H. The Elements of Statistical Learning. Springer, 2003. 549 p.

12. Huber P. J. Robust Statistics. Hoboken, NJ, USA : John Wiley & Sons, Inc., 1981. URL: <https://doi.org/10.1002/0471725250> (date of access: 13.11.2025).

13. Instance Normalization: The Missing Ingredient for Fast Stylization. *arXiv.org*. URL: <https://arxiv.org/abs/1607.08022> (date of access: 13.11.2025).

14. Understanding and Improving Layer Normalization. *arXiv.org*. URL: <https://arxiv.org/abs/1911.07013> (date of access: 13.11.2025).

15. Principal Component Analysis. New York : Springer-Verlag, 2002. URL: <https://doi.org/10.1007/b98835> (date of access: 13.11.2025).

16. Dealing with the Effects of Sensor Displacement in Wearable Activity Recognition / O. Banos et al. *Sensors*. 2014. Vol. 14, no. 6. P. 9995–10023. URL: <https://doi.org/10.3390/s140609995> (date of access: 13.11.2025).

17. Enhanced Human Activity Recognition Using Wearable Sensors via a Hybrid Feature Selection Method - PMC. *PMC Home*.

URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC8512389/> (date of access: 13.11.2025).

18. Shorten C., Khoshgoftaar T. M. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*. 2019. Vol. 6, no. 1. URL: <https://doi.org/10.1186/s40537-019-0197-0> (date of access: 13.11.2025).

19. Deep learning for sensor-based activity recognition: A survey / J. Wang et al. *Pattern Recognition Letters*. 2019. Vol. 119. P. 3–11. URL: <https://doi.org/10.1016/j.patrec.2018.02.010> (date of access: 13.11.2025).

20. SMOTE: Synthetic Minority Over-sampling Technique | Journal of Artificial Intelligence Research. *Journal of Artificial Intelligence Research*. URL: <https://www.jair.org/index.php/jair/article/view/10302> (date of access: 13.11.2025).

21. Data Augmentation of Wearable Sensor Data for Parkinson's Disease Monitoring using Convolutional Neural Networks. *arXiv.org*. URL: <https://arxiv.org/abs/1706.00527> (date of access: 13.11.2025).

22. mixup: Beyond Empirical Risk Minimization. *arXiv.org*. URL: <https://arxiv.org/abs/1710.09412> (date of access: 13.11.2025).

24. Time-series generative adversarial networks. In: Advances in Neural Information Processing Systems. URL: [https://proceedings.neurips.cc/paper\\_files/paper/2019/file/c9efe5f26cd17ba6216bbe2a7d26d490-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2019/file/c9efe5f26cd17ba6216bbe2a7d26d490-Paper.pdf) (дата звернення: 13.11.2025).

25. Bodyanskiy Y., Kulishova N. Multidimensional Neuro-fuzzy System and Fuzzy Coding for a Constant Length Facial Landmark Set Formation. *2021 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, Cracow, Poland, 22–25 September 2021. 2021. URL: <https://doi.org/10.1109/idaacs53288.2021.9660907> (date of access: 13.11.2025)