

**НАЦІОНАЛЬНИЙ ТЕХНІЧНИЙ УНІВЕРСИТЕТ УКРАЇНИ  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ  
імені ІГОРЯ СІКОРСЬКОГО»  
Інститут прикладного системного аналізу  
Кафедра штучного інтелекту**

До захисту допущено  
В. о. завідувача кафедри  
Олена ЧУМАЧЕНКО  
«\_\_» \_\_\_\_\_ 20\_\_ р.

**Дипломна робота  
на здобуття ступеня бакалавра  
за освітньо-професійною програмою «Системи і методи штучного  
інтелекту» спеціальності 122 «Комп'ютерні науки»  
на тему: «Дистанційний безконтактний метод визначення деяких  
біосигналів людини з відео-потoku»**

Виконав:  
студент IV курсу, групи КІ-92 Коваль Максим Дмитрович

Науковий керівник:  
к.т.н., доцент Барановська Леся Валеріївна

Науковий консультант:  
к.т.н., доцент Тимошенко Юрій Олександрович

Консультант з економічного розділу:  
доцент кафедри ТПЕ, к.е.н. Рощина Надія Василівна

Консультант з нормоконтролю:  
фахівець першої категорії кафедри ШІ Гончарук Максим Миколайович

Рецензент:  
доцент, к.т.н. ФПМ, каф. прикладної математики Маслянюк Павло Павлович

Засвідчую, що у цій дипломній роботі  
немає запозичень з праць інших авторів  
без відповідних посилань.

Київ – 2023 року

**Національний технічний університет України  
«КИЇВСЬКИЙ ПОЛІТЕХНІЧНИЙ ІНСТИТУТ імені ІГОРЯ  
СІКОРСЬКОГО»**

**Інститут прикладного системного аналізу**

**Кафедра штучного інтелекту**

Рівень вищої освіти – перший (бакалаврський)

Спеціальність – 122 «Комп'ютерні науки»

Освітньо-професійна програма «Системний аналіз і управління»

ЗАТВЕРДЖУЮ

Завідувача кафедри

О.Л. ТИМОЩУК

«\_\_\_» \_\_\_\_\_ 20\_\_ р.

### ЗАВДАННЯ

**на дипломну роботу студенту Коваль Максиму Дмитровичу**

1. Тема роботи «Дистанційний безконтактний метод визначення деяких біосигналів людини з відео-потоків», керівник роботи доцент, кандидат технічних наук Барановська Леся Валеріївна, затверджені наказом по університету від «\_\_\_» \_\_\_\_\_ 20\_\_ р. № \_\_\_\_\_

2. Термін подання студентом роботи

3. Вихідні дані до роботи: набір даних МІМІС-Ш, мова програмування Python та додаткові до неї бібліотеки

4. Зміст роботи: 1. Дослідження актуальності теми серцево-судинних захворювань; 2. Глибинне навчання; 3. Розробка та аналіз моделі апроксимації деяких біосигналів людини з сигналу фотоплетизмограми завдяки глибинному машинному навчанню.

5. Перелік ілюстративного матеріалу (із зазначенням плакатів, презентацій тощо): рисунки з підписами, презентація.

6. Консультанти розділів роботи

Розділ	Прізвище, ініціали та посада консультанта	Підпис, дата	
		завдання видав	завдання прийняв
Економічний	Рощина Н. В., доцент кафедри ТПЕ		

7. Дата видачі завдання \_\_\_\_\_

## Календарний план

№ з/п	Назва етапів виконання дипломної роботи	Термін виконання етапів роботи	Примітка
1	Формулювання тематики дослідження	28.02.2023	Виконано
2	Аналіз актуальності задачі стосовно тематики дослідження	31.03.2023	Виконано
3	Підготовка першого розділу	15.04.2023	Виконано
4	Підготовка другого розділу	30.04.2023	Виконано
5	Розробка програмного продукту	15.05.2023	Виконано
6	Підготовка третього розділу	20.05.2023	Виконано
7	Підготовка економічної частини	31.05.2023	Виконано
8	Оформлення розділів відповідно до нормоконтролю	9.06.2023	Виконано
9	Підготовка презентації для захисту	9.06.2023	Виконано
10	Оформлення дипломної роботи загалом	9.06.2023	Виконано

Студент

Максим КОВАЛЬ

Керівник

Леся БАРАНОВСЬКА

## РЕФЕРАТ

Дипломна робота: 86 с., 7 табл., 23 рис., 1 додаток, 19 джерел.

### АНАЛІЗ ФОТОПЛЕТИЗМОГРАМИ, АПРОКСИМАЦІЯ, ГЛИБОКІ НЕЙРОННІ МЕРЕЖІ, МАШИННЕ НАВЧАННЯ.

Об'єкт дослідження – застосування фотоплетизмографії в охороні здоров'я.

Предмет дослідження – методи обробки деяких біосигналів з відео потоку для отримання безконтактної фотоплетизмограми.

Мета роботи – розробка програмного забезпечення для визначення показників безконтактної фотоплетизмограми, зокрема систолічного та діастолічного артеріального тиску.

Актуальність – розробка неінвазійних дистанційних діагностичних програм для моніторингу серцево-судинної системи людини.

Ця робота досліджує та аналізує методи вивчення біосигналів людини з використанням фотоплетизмограми, які є найпоширенішими, і використовує методи машинного навчання для розв'язання проблем регресії.

Подальший розвиток предмету дослідження – оптимізація апроксимації артеріального тиску, виходячи з сигналу фотоплетизмограми.

## **ABSTRACT**

Thesis: 86 pages, 7 tables, 23 figures, 1 appendix, 19 sources.

**PHOTOPLETHYSMOGRAM ANALYSIS, APPROXIMATION, DEEP NEURAL NETWORKS, MACHINE LEARNING.**

The object of research is the use of photoplethysmography in health care.

The subject of the research is the methods of processing some biosignals from the video stream to obtain a non-contact photoplethysmogram.

The purpose of the work is to develop software for determining non-contact photoplethysmogram indicators, in particular systolic and diastolic blood pressure.

The relevance is the development of non-invasive remote diagnostic programs for monitoring the human cardiovascular system.

This work explores and analyzes the methods of studying human biosignals using photoplethysmogram, which are the most common, and uses machine learning techniques to solve regression problems.

Further development of the subject of research can involve the optimization of approximation of blood pressure based on the photoplethysmogram signal.

## ЗМІСТ

ВСТУП .....	8
РОЗДІЛ 1. ДОСЛІДЖЕННЯ ПРЕДМЕТНОЇ ОБЛАСТІ.....	10
1.1. Мета та завдання дослідження .....	10
1.2. Об'єкт та предмет дослідження .....	11
1.3. Актуальність дослідження .....	12
1.3.1. Харчування .....	15
1.3.2. Низька фізична активність.....	16
1.3.3. Зовнішні чинники .....	18
1.3.4. Погані звички .....	19
1.3.5. Високий артеріальний тиск.....	20
1.4. Наукова новизна дослідження .....	21
1.5. Практична цінність дослідження .....	21
1.6. Особливості предметної області дипломної роботи .....	26
1.7. Висновки .....	28
РОЗДІЛ 2. ОПИС СПОСОБУ ВИРІШЕННЯ ЗАДАЧІ.....	29
2.1. Артеріальний тиск. Його види та вимір ззовні. ....	29
2.2. Метод розв'язку задачі .....	32
2.3. Оцінка якості розв'язку задачі.....	36
2.4. Висновок .....	38
РОЗДІЛ 3. ОПИС РОЗРОБЛЕНИХ АЛГОРИТМІВ ТА ПРОГРАМНИХ МОДУЛІВ .....	39
3.1. Структура підходу .....	39
3.2. Виявлення обличчя на відео-поточі.....	41

3.3. Виділення регіонів інтересу.....	43
3.4. Зняття показників фотоплетизмограми з регіонів інтересу .....	44
3.5. Тренувальні дані та їх обробка .....	45
3.6. Апроксимуюча мережа.....	48
3.7. Уточнювальна мережа .....	50
3.8. Побудова мереж .....	53
3.8.1. Вибір придатних для вирішення задачі моделей.....	53
3.8.2. Вибір функцій втрат .....	54
3.8.3. Дослідження кількості згорткових шарів.....	55
3.8.4. Тренування моделей .....	56
3.8.5. Результати виміру артеріального тиску.....	57
3.9. Експеримент .....	59
<b>РОЗДІЛ 4 ФУНКЦІОНАЛЬНО-ВАРТІСНИЙ АНАЛІЗ</b>	
<b>ПРОГРАМНОГО ПРОДУКТУ .....</b>	<b>62</b>
4.1 Постановка задачі проектування.....	62
4.2 Обґрунтування функцій програмного продукту.....	63
4.3 Обґрунтування системи параметрів програмного продукту .....	66
4.4 Аналіз експертного оцінювання параметрів .....	70
4.5 Аналіз рівня якості варіантів реалізації функцій.....	74
4.6 Економічний аналіз варіантів розробки ПП .....	75
4.7 Вибір кращого варіанту ПП техніко-економічного рівня .....	82
4.8 Висновки до четвертого розділу .....	83
<b>ПЕРЕЛІК ПОСИЛАНЬ .....</b>	<b>84</b>

## ВСТУП

За останні 70 років, тривалість життя людей на Землі збільшилася приблизно на 26 років, на даний момент становлячи близько 72 років (відповідно до дослідження проведеного Інститутом метрик здоров'я у Сієтлі, Вашингтон). Цей прогрес було досягнуто завдяки досягненням у сучасній медицині, соціальному розвитку, оптимізації робочих ресурсів та виробничих процесів. Протягом останніх 40 років було досягнуто значних успіхів у боротьбі з хворобами, такими як менінгіт (зменшення смертності на 40%), захворюваннями легень (зменшення смертності на 25%), кишковими інфекціями (зменшення смертності на 28%), гепатитом (зменшення на 14%), малярією (зменшення на 25%), туберкульозом (зменшення на 26%) та іншими. Проте, незважаючи на ці досягнення, за останні десятиліття серцево-судинні захворювання залишаються найпоширенішою причиною смерті, і масштаб цієї проблеми є надзвичайно серйозним. З 1991 року по 2019 рік кількість смертей від серцево-судинних захворювань по всьому світу зросла на 50%, а саме, з 12 мільйонів на рік до 19 мільйонів. Проблема серцево-судинних захворювань існує вже протягом тривалого періоду, і хоча були спроби спостереження та реабілітації таких пацієнтів, наявні підходи вимагають перегляду через їх невідповідність сучасним вимогам, що призводить до постійного зростання смертності. У наші часи людство перебуває в епоху новітніх технологій та штучного інтелекту, і це може знайти широке відображення в сфері медицини.

У традиційній практиці, люди зазвичай звертаються до лікаря, коли вони мають конкретні скарги, що свідчать про вже розвинену хворобу, яку можна було б уникнути. В серцевій сфері, порушення можуть бути органічного походження (зумовлені тканинними або судинними ушкодженнями) або функціонального характеру (порушення роботи серця, що можуть виникати без органічних змін, але можуть спричинити такі зміни, якщо не виявити їх

своєчасно). Систематичний моніторинг біологічних сигналів у реальному часі дозволяє вчасно виявляти функціональні зміни в роботі серця, спричинені стресом, захворюваннями, несправним способом життя або індивідуальними особливостями пацієнта, та надавати своєчасну допомогу потребуючим, перш ніж виникнуть серйозні органічні ускладнення. Збір та аналіз цих біосигналів здійснюються за допомогою звичайних математичних алгоритмів обробки сигналів та алгоритмів машинного навчання.

## РОЗДІЛ 1. ДОСЛІДЖЕННЯ ПРЕДМЕТНОЇ ОБЛАСТІ

### 1.1. Мета та завдання дослідження

Метою даної дипломної роботи є розробка та впровадження дистанційного безконтактного методу для визначення деяких біосигналів людини з відео-потoku. Основною метою є створення ефективного та зручного інструменту, який дозволить безперешкодно збирати та аналізувати біосигнали, не потребуючи фізичного контакту з пацієнтом.

З метою досягнення поставленої цілі передбачені наступні завдання:

1. Ревізія та аналіз існуючих методів: Провести докладний огляд літератури та наукових досліджень, що стосуються визначення біосигналів з відео-потoku. Вивчити переваги та обмеження різних методів, що використовуються в даній сфері.

2. Вибір підходу до визначення біосигналів: На основі ревізії існуючих методів визначення біосигналів, обрати підхід, який буде найбільш відповідати поставленій меті. Розробити стратегію для дистанційного та безконтактного збору біосигналів з відео-потoku.

3. Розробка алгоритмів обробки відео-потoku: Розробити алгоритми, які дозволять витягти біосигнали з відео-потoku, забезпечуючи надійність та точність визначення. Дослідити різні підходи до обробки зображень, виявлення руху та виділення релевантних ділянок для аналізу біосигналів.

4. Розробка алгоритмів аналізу біосигналів: Розробити алгоритми для аналізу та інтерпретації отриманих біосигналів. Встановити зв'язок між отриманими сигналами та станом здоров'я або фізіологічними показниками людини.

5. Валідація та експерименти: Провести експериментальні дослідження, щоб перевірити ефективність та надійність запропонованого

методу. Зібрати відео-потоки з добровільних учасників, порівняти результати визначення біосигналів з результатами стандартних методів.

б. Аналіз результатів та висновки: Оцінити досягнення поставлених цілей та висунути висновки щодо ефективності та можливостей запропонованого дистанційного безконтактного методу визначення біосигналів. Визначити перспективи подальшого розвитку та застосування даної технології.

## **1.2. Об'єкт та предмет дослідження**

Об'єктом дослідження є біосигнали людини, які є важливими фізіологічними показниками стану організму. Біосигнали можуть включати серцевий ритм, артеріальний тиск та рівень стресу. Визначення цих біосигналів з великою точністю та надійністю є ключовим завданням у медицині для діагностики, моніторингу та лікування різних захворювань.

Предметом дослідження є розробка та застосування дистанційного безконтактного методу для визначення цих біосигналів з відео-потoku. Головною метою є забезпечення можливості безконтактного збору біосигналів, що дозволить уникнути фізичного контакту з пацієнтом та забезпечити більш зручний та безпечний спосіб збору інформації. Дистанційний безконтактний метод визначення біосигналів має потенціал бути застосованим в різних медичних областях, включаючи телемедицину, спостереження за пацієнтами у реальному часі та моніторинг стану здоров'я в домашніх умовах.

Розвиток дистанційного безконтактного методу для визначення біосигналів з відео-потoku вимагає ретельного аналізу існуючих методів, розробки нових алгоритмів обробки відео-потoku, валідації та

експериментальних досліджень. Отримані результати можуть мати значний вплив на покращення медичних технологій та практик, сприяючи швидшій, зручній та точній діагностиці та моніторингу стану здоров'я людей.

### 1.3. Актуальність дослідження

Розглянемо низку графіків, що ґрунтуються на даних, які підтверджують високу актуальність завдання профілактики серцево-судинних захворювань.

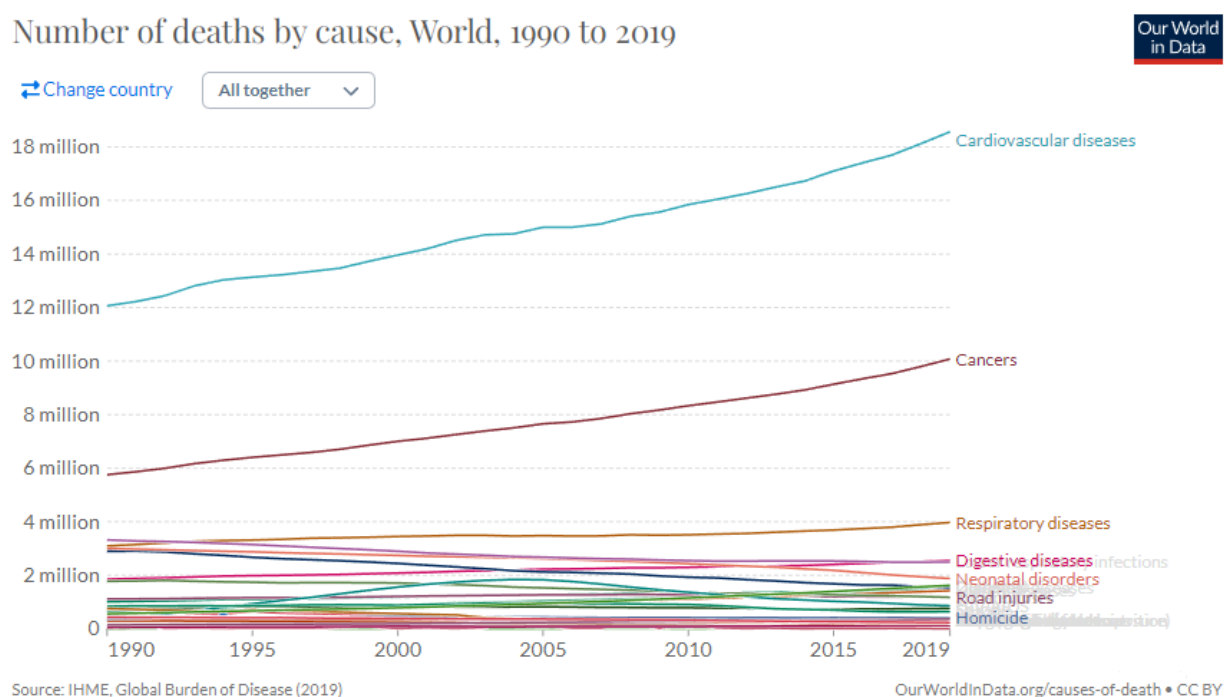


Рисунок 1.1 – Графік смертності від серцево-судинних захворювань [1]

За останні 10 років кількість смертей від серцево-судинних захворювань зросла на 15%. [2]

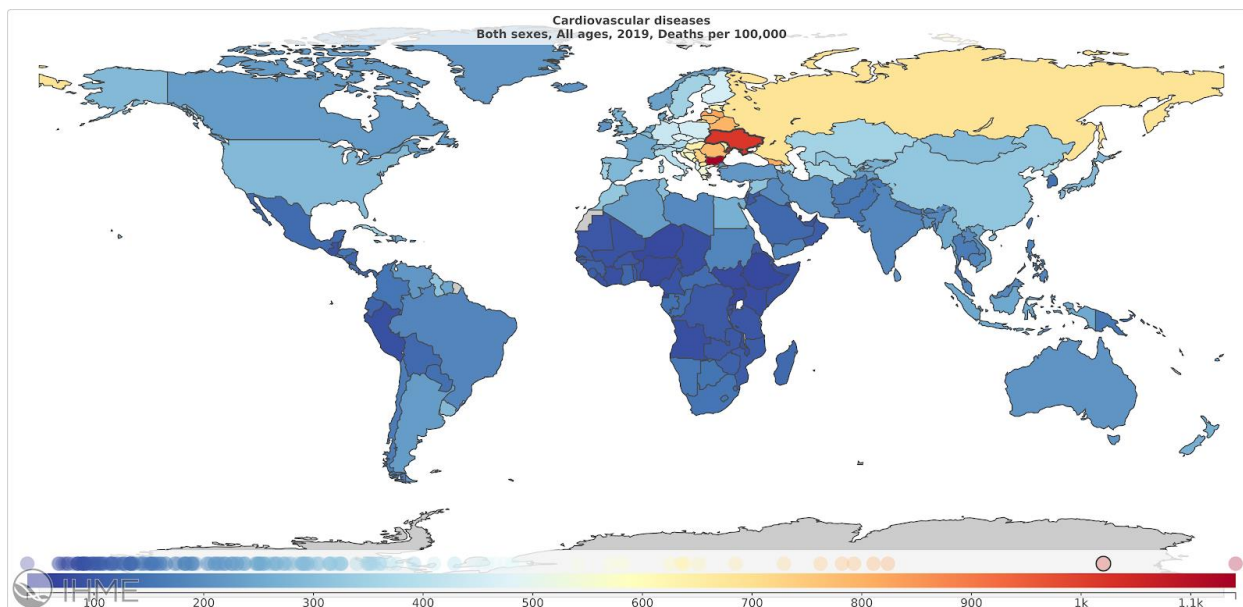


Рисунок 1.2 – Частка серцево-судинних захворювань на 100000 одиниць населення

В Україні серцево-судинні захворювання є головною причиною смертності населення. За цим показником наша країна лишається одним зі світових лідерів. [3]

Згідно з даними ранжування, складеного на основі кількості смертей населення в Україні, найчастішими причинами є:

1. Серцево-судинні захворювання (64,3 %)
2. Новоутворення (14,1 %)
3. Хвороби органів травлення (4,3 %)
4. Неврологічні розлади (3,1 %)
5. Самоушкодження та міжособистісне насильство (2,7 %)

Відповідно до інформації, наданої Світовою організацією охорони здоров'я [4], 80% передчасних інфарктів та інсультів можна запобігти. Здорове харчування, регулярна фізична активність і відмова від тютюнових виробів є запорукою профілактики. Перевірка та контроль факторів ризику серцевих

захворювань та інсульту, таких як високий кров'яний тиск, високий рівень холестерину та цукру в крові або діабет, також дуже важливі.

Рисунок 1.1 наочно демонструє не лише підтвердження попередніх тез про вплив особистих звичок, способу життя та індивідуальних генетичних особливостей на схильність до певних захворювань, але й акцентує увагу на актуальності та масштабі цієї проблеми.

Навіть якщо легко припустити, що кількість смертей від серцево-судинних захворювань прямо пропорційна зростанню населення, то чому кількість смертей від інших причин не корелює зі зростанням населення? Відповідь на це досить проста: розвиток медицини допомагає знижувати смертність серед загальної популяції. Проте, коли мова йде про смертність від серцево-судинних захворювань, вона прямо залежить від змін у поведінці та життєвому стилі людей.

Отже, які основні фактори негативно впливають на здоров'я серцево-судинної системи людей?

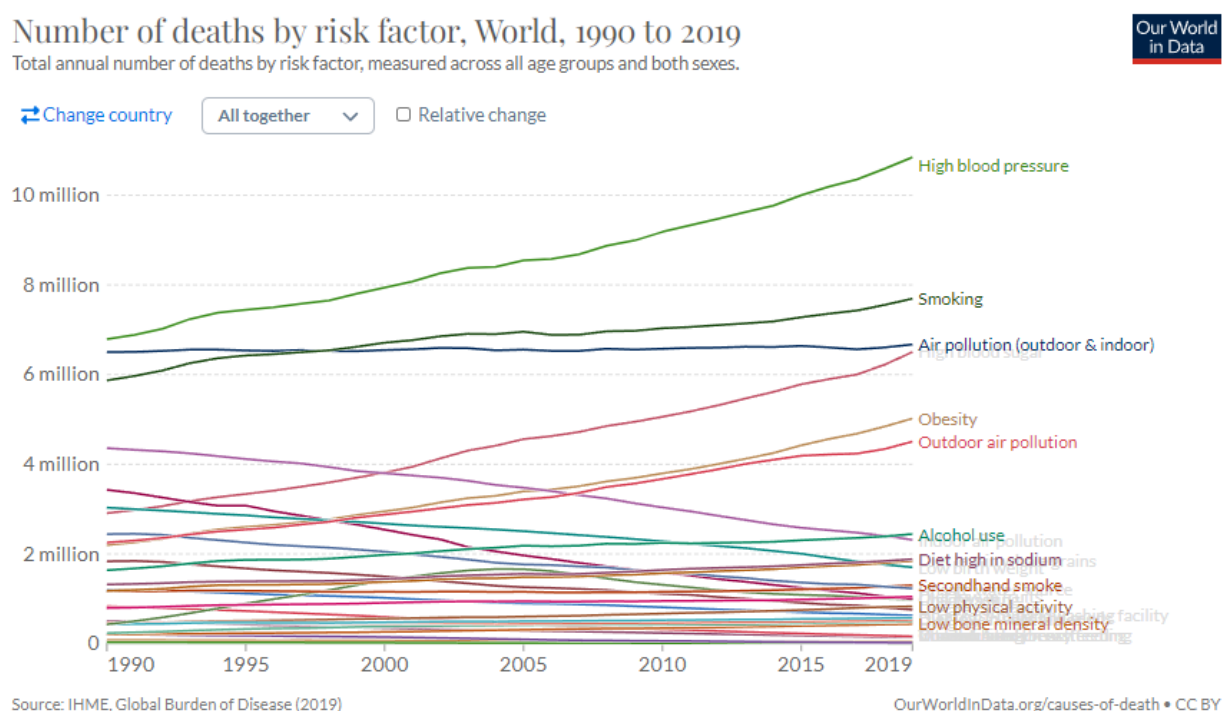


Рисунок 1.3 – Кількість смертей за причинами [1]

Ризик розвитку серцево-судинних захворювань збільшується залежно від факторів, таких як куріння, нездоровий спосіб життя та недостатня фізична активність, але найбільшим чинником залишається саме високий артеріальний тиск.

Ці графіки наголошують на актуальності завдання профілактики серцево-судинних захворювань та показують необхідність вжиття заходів для зниження ризику та підтримки серцево-судинного здоров'я.

Розберемо вище зазначені найбільш високі чинники серцево-судинних захворювань у порядку зростання.

### **1.3.1. Харчування**

На основі аналізу даних з Американського національного опитування з харчування та здоров'я, проведеного вченими з Тафтського Університету в Бостоні, Кембриджського університету в Англії та Монтіфйорського Медичного Центру в Нью-Йорку, було виявлено, що погані харчові звички та дефіцит необхідних поживних речовин становлять значний вплив на здоров'я серцево-судинної системи та метаболічний стан організму.

Дослідники проаналізували дані про понад 700 тисяч померлих людей у 2012 році, у яких серцево-судинні захворювання та діабет другого типу були причиною смерті. В результаті дослідження вони прийшли до висновку, що 45% [6] смертей пов'язані з нездоровим харчуванням та недостатнім надходженням необхідних поживних речовин. Зокрема, було встановлено, що вживання великої кількості солі, обробленої їжі та напоїв, що штучно збагачені цукром, мають суттєвий вплив на здоров'я серцево-судинної системи.

Ці висновки підкреслюють важливість збалансованого харчування та усвідомленого вибору продуктів харчування для збереження здоров'я серцево-судинної системи та запобігання розвитку серцево-судинних захворювань та діабету другого типу.

### **1.3.2. Низька фізична активність**

На початку 1960-х майже половина робочих місць у приватному секторі США потребувала фізичної активності принаймні помірної інтенсивності, тоді як зараз менш ніж 20% потребують такого рівня енерговитрат. З 1960 року середні добові витрати енергії внаслідок фізичної активності, пов'язаної з роботою, знизилися більш ніж на 100 калорій як у жінок, так і у чоловіків. Модель енергетичного балансу передбачила вагові коефіцієнти на основі зміни щоденних витрат енергії, пов'язаних із професійною діяльністю, з 1960 року для кожного періоду обстеження NHANES. Наприклад, з 1960-62 по 2003-06 ми підраховали, що щоденні витрати енергії, пов'язані з професією, у чоловіків зменшилися на 142 калорії. Враховуючи базову вагу 76,9 кг у 1960-02 роках, ми підраховали, що зменшення на 142 калорії призведе до збільшення середньої ваги до 89,7 кг, що майже відповідало середній вазі NHANES 91,8 кг у 2003-06 роках. Результати були схожими для жінок. [5]




Рисунок 1.4 – Метаболічні енерговитрати протягом років з 1960-го року

Врешті, за останні 50 років у США, за нашими оцінками, щоденні витрати енергії, пов'язані з професійною діяльністю, зменшилися більш ніж на 100 калорій, і це зменшення витрат енергії пояснює значну частину збільшення середньої маси тіла та смертність в США для жінок і чоловіків.

### 1.3.3. Зовнішні чинники

Зовнішні чинники, такі як забруднення навколишнього середовища, можуть впливати на ризик розвитку серцево-судинних захворювань. Нижче наведено деякі з основних шляхів, через які забруднення може впливати на серцево-судинну систему:

1. Повітряне забруднення: Високий рівень забруднення повітря, особливо від пилу, токсичних речовин та дрібних часток, може проникати в легені та викликати запалення. Це може сприяти розвитку атеросклерозу, збільшенню ризику виникнення серцевих нападів, інсультів та інших серцево-судинних захворювань.

2. Шкідливі речовини у повітрі: Деякі речовини, які містяться у повітрі, такі як оксиди азоту, сірки, вуглецю, бензопірен та інші токсичні сполуки, можуть мати прямий негативний вплив на серцево-судинну систему. Вони можуть сприяти розвитку запалення, спазму судин, підвищенню артеріального тиску та порушенню серцевого ритму.

3. Забруднення води та ґрунту: Наявність шкідливих речовин у воді та ґрунті може призвести до забруднення харчових продуктів, які споживаються людиною. Велика кількість токсинів у харчі може сприяти розвитку дисліпідемії (порушення рівня ліпідів у крові), цукрового діабету, ожиріння та інших факторів, що збільшують ризик серцево-судинних захворювань.

4. Кліматичні зміни: Зміна клімату може мати вплив на здоров'я серця і судин. Екстремальні погодні умови, такі як висока температура, підвищена вологість, засуха або повені, можуть створювати стрес для організму і погіршувати функціонування серцево-судинної системи.

### 1.3.4. Погані звички

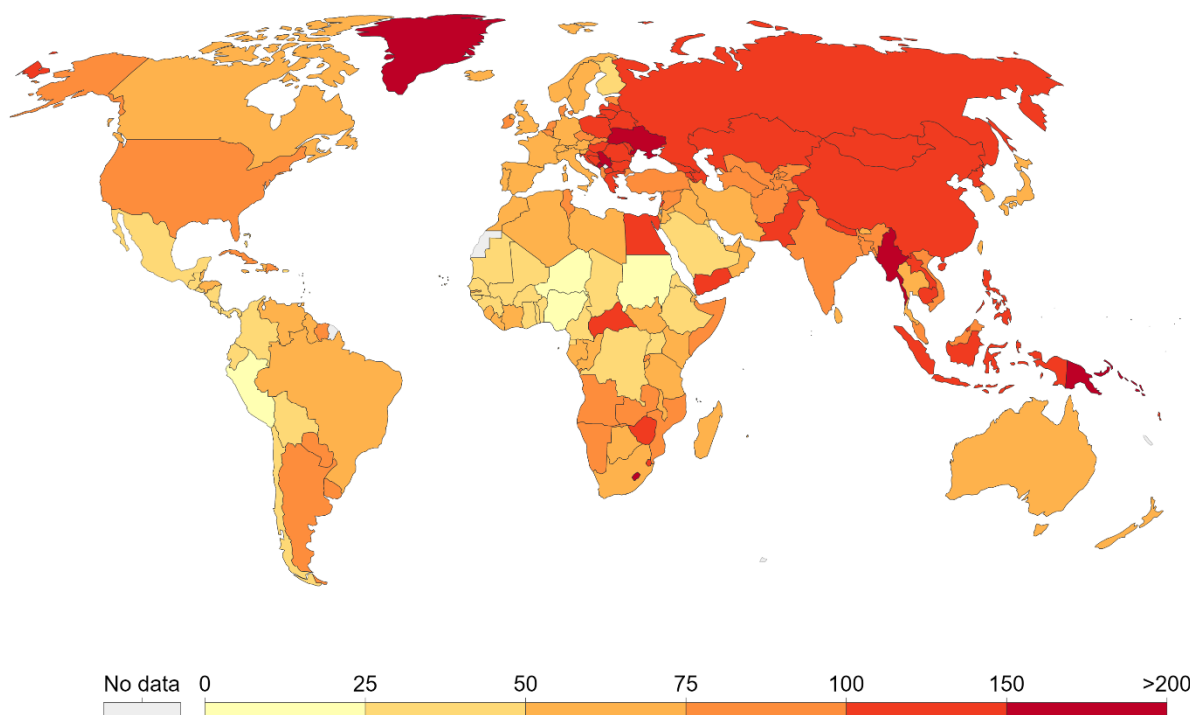


Рисунок 1.5 – Кількість смертей на 100000 одиниць населення по країнах

Вживання тютюнових виробів має серйозний вплив на серцево-судинну систему і може значно збільшити ризик розвитку серцево-судинних захворювань. Тютюн містить багато шкідливих речовин, які можуть негативно впливати на серце, судини і інші органи.

Одним з основних компонентів тютюну є нікотин, який є потужною психоактивною речовиною. Нікотин спричиняє звуження кровоносних судин, що призводить до збільшення артеріального тиску і підвищення навантаження на серце. Це може сприяти розвитку атеросклерозу, утворенню тромбів і збільшенню ризику інфаркту міокарда (серцевого нападу) та інших серцевих захворювань.

Тютюновий дим також містить багато інших шкідливих речовин, таких як вуглекислий газ, тягучі речовини, канцерогени і тверді частки. Ці речовини

можуть пошкоджувати стінки кровоносних судин, сприяти утворенню бляшок і розвитку атеросклерозу. Крім того, вони можуть спричиняти запалення в судинах і сповільнювати процес зцілення. [7]

Постійне вживання тютюнових виробів також збільшує ризик розвитку інших серцево-судинних захворювань, таких як ангіна, аритмія, цереброваскулярні захворювання (інсульт), периферична артеріальна хвороба і серцева недостатність. У довгостроковій перспективі, куріння може призвести до пошкодження судин і серцевої тканини, що збільшує ризик смерті від серцевих захворювань.

### **1.3.5. Високий артеріальний тиск**

Високий артеріальний тиск, також відомий як гіпертонія, має значний вплив на серцево-судинні захворювання. Гіпертонія є одним із головних факторів ризику для розвитку коронарної хвороби. Постійний підвищений тиск на стінки артерій спричиняє формування атеросклеротичних бляшок, які зменшують просвіт судин і обмежують притік крові до серця. Це може призвести до стенокардії (біль у грудях) або навіть до інфаркту міокарда (проблеми з кровопостачанням серця, що можуть призвести до пошкодження м'язової тканини серця) [18].

Також гіпертонія є провідним фактором ризику розвитку інсульту [8]. Високий тиск спричиняє пошкодження судин мозку, збільшує ймовірність формування кров'яних згустків, які можуть заблокувати кровопостачання до окремих ділянок мозку. Це може призвести до інсульту або транзиторних ішемічних атак (ТІА), які можуть бути попередниками інсульту.

#### **1.4. Наукова новизна дослідження**

На додаток до факторів, зазначених у попередньому пункті, збільшення кількості серцево-судинних захворювань та смертей від них також пов'язане зі зростанням рівня стресу у сучасному суспільстві. Стрес має пряму кореляцію з ризиком розвитку серцево-судинних захворювань. Надмірний стрес може сприяти підвищенню кров'яного тиску, вираженим змінам у серцевому ритмі, запаленням судин та іншими негативними фізіологічними реакціями, що сприяють розвитку серцево-судинних проблем.

У зв'язку з цим важливо контролювати біосигнали та показники здоров'я людини для вчасної діагностики хвороб та попередження розвитку органічних змін та патологій. Постійний моніторинг біологічних сигналів, таких як серцевий ритм, артеріальний тиск, рівень стресу та інші, може допомогти виявити незвичайні відхилення та ризик розвитку серцево-судинних проблем. Це дасть можливість вчасно втрутитися та надати необхідне лікування або змінити спосіб життя з метою запобігання серйозним наслідкам та органічним змінам в серцево-судинній системі.

Враховуючи, що кожна хвилина затримки може бути вирішальною для людського життя, регулярний контроль біосигналів та вчасна діагностика серцево-судинних захворювань мають велике значення для збереження здоров'я та попередження серйозних ускладнень.

#### **1.5. Практична цінність дослідження**

Артеріальна гіпертензія є одним з найпоширеніших захворювань, яке значно підвищує ризик розвитку серцево-судинних ускладнень та прискорює

настання передчасної смерті. Рівень артеріального тиску має пряму залежність від ризику серцево-судинних захворювань. Підвищення артеріального тиску збільшує ймовірність інфаркту міокарда, хронічної серцевої недостатності, інсульту та ураження нирок.

Дослідження показують, що у осіб віком від 40 до 70 років збільшення систолічного артеріального тиску на 20 мм рт. ст. або діастолічного артеріального тиску на 10 мм рт. ст. подвоює ризик розвитку серцево-судинних захворювань у всьому діапазоні рівнів артеріального тиску, починаючи від значень 115/75 мм рт. ст. до 185/115 мм рт. ст. [18]

Це свідчить про те, що навіть незначне підвищення артеріального тиску може мати серйозний вплив на здоров'я серцево-судинної системи. Отже, вчасна діагностика та контроль рівня артеріального тиску є важливими для попередження серцево-судинних ускладнень та зменшення ризику передчасної смерті.

З існуючих методів та реалізацій зчитки біологічних сигналів, яким реалізований метод складатиме конкуренцію, можна виділити декілька, що зазначені нижче.

#### 1. Фітнес-трекери.

Фітнес-трекери - це електронні пристрої, які вимірюють різноманітні біологічні сигнали людини, що виникають під час фізичної активності. Ці пристрої здатні вимірювати такі параметри, як пульс, кількість кроків, витрачені калорії, відстань пройденої під час ходьби або бігу, а також інші показники здоров'я та активності. Основний принцип виміру біологічних сигналів фітнес-трекером базується на використанні різноманітних сенсорів, які реагують на фізіологічні зміни, що відбуваються в організмі під час фізичного навантаження.



Рисунок 1.6 – Фітнес-трекер на руці людини

Серцевий ритм є одним з найважливіших показників фітнес-трекерів. Для вимірювання пульсу використовуються фотоплетизмографічні сенсори, розташовані на зворотній стороні пристрою, що контактують зі шкірою користувача. Ці сенсори відбивають світло від судин, і зміни в рефлексії світла дозволяють визначити пульс. Деякі фітнес-трекери також використовують електрокардіографічні сенсори, які реєструють електричну активність серця, щоб отримати більш точні дані про пульс та серцевий ритм.

При вимірюванні біометричних показників фітнес-трекери можуть також вимірювати артеріальний тиск користувача. Для цього використовуються спеціальні сенсори, які реєструють коливання артерій, пов'язані з серцевим циклом. Ці сенсори можуть бути розташовані на задній частині трекера або вбудовані у його ремінець. Під час вимірювання користувач стискає трекер або ремінець до рівня середньої артерії на зап'ясті або плечі, і сенсори реєструють коливання, які виникають внаслідок кровотоку. На основі цих коливань фітнес-трекер визначає значення

артеріального тиску, зокрема систолічного та діастолічного тиску. Ця інформація може бути корисною для контролю за серцево-судинним здоров'ям та оцінки загального стану користувача.

## 2. Пульсоксиметр.

Пульсоксиметр — це один з прикладів пристрою, що базується на трансмісивній фотоплетізмограмі, може включати LED-діод та фотодіод, які розташовані на протилежних боках пальця або іншої ділянки тіла. LED-діод випромінює світло певного спектру, яке проходить через тканину пальця чи іншу ділянку тіла. Фотодіод, розташований з протилежного боку, реєструє поглинання світла тканинами.



Рисунок 1.7 – Пульсоксиметр на руці людини

При пульсації кровоносних судин, об'єм крові в капілярах пальця змінюється, що впливає на кількість світла, яке поглинається фотодіодом. Зміна поглинання світла відображається у вигляді зміни електричного струму,

який генерується фотодіодом. Цей електричний сигнал може бути підсилено і оброблено для отримання інформації про пульсацію кровеносних судин, серцевий ритм та інші параметри.

Такий пристрій на основі трансмісивної фотоплетізограми може використовуватися для невінагороджувального вимірювання пульсу та оцінки рівня оксигенації крові в реальному часі. Він може бути вбудованим у пульсометри, фітнес-трекери, медичні пристрої та інші пристрої для моніторингу здоров'я.

### 3. Binah.AI Wellness Check

100% програмне забезпечення Binah.ai, рішення для перевірки стану здоров'я та самопочуття на основі відео, доступні на обладнаних камерами пристроях, якими люди вже володіють, наприклад, смартфонах або планшетах, виконують функцію оздоровчих послуг, доступних будь-кому та будь-де. Він надає компаніям і користувачам потужний інструмент із високою доступністю та простотою використання. Бачення Binah.ai — це світ, у якому доступ до даних про здоров'я, наданих кінцевими користувачами, є програмним, простим, швидким і доступним, полегшуючи лікування та прийняття рішень за менших витрат. [9]

Наразі це найбільший конкурент метода, що досліджується в даній роботі. Але компанія нині має єдиний недолік: закритість. Наразі додаток, що пропонує компанія, не є публічним і надається за запитом, на який не завжди відповідають. Тому вважати технологію Binah.AI руйнівником теми цієї дипломної роботи неможливо.

## 1.6. Особливості предметної області дипломної роботи

У цій предметній області об'єктами та суб'єктами є люди, з яких збираються біологічні сигнали та дані для проведення експериментів та досліджень. Для цілей даної роботи були використані оброблені дані з відомого датасету, який володіє популярністю у наукових колах. Цей датасет має значний обсяг, що надає можливості для подальшої обробки та очищення даних. Він містить записи різних біологічних сигналів, зокрема фотоплетизмограми, дані артеріального тиску та електрокардіограми. Цей набір даних може бути використаний для різних завдань, включаючи класифікацію та регресію. Однією з переваг цього датасету є його актуальність, адже дані оновлювалися нещодавно.

Основною метою цього набору даних є надання чистих та перевірених сигналів для розробки та проектування алгоритмів, які дозволяють оцінювати артеріальний тиск без використання манжети. Датасет представлений у форматі файлів Matlab, які можуть бути відкриті за допомогою сучасних версій Matlab або інших бібліотек, які підтримують високопродуктивне керування даними в інших середовищах розробки. База даних складається з матриць, де кожен рядок відповідає окремому сигнальному каналу. Вона включає фотоплетизмограми, отримані з кінчиків пальців, дані артеріального тиску (вимірювані інвазивним способом) та сигнали електрокардіограми.

Приклад графіка реальної фотоплетизмограми (PPG) (угорі, синій) і відповідного справжнього артеріального тиску (ABP) разом із згенерованим артеріальним тиском, згенерований за допомогою відповідного PPG, зображено на рисунку 1.8. Обидва сигнали нормалізуються між 0 і 1 із штучним зміщенням сигналів артеріального тиску з ціллю гарно візуалізувати дані. [10]




Рисунок 1.8 – PPG vs. real ABP vs. generated ABP

Отже, ми можемо провести порівняння між сигналами електрокардіограми та фотоплетізмограми. Наступна ілюстрація надає загальний огляд обох сигналів та виділяє більш помітні відмінності між ними, що дозволяє зробити порівняння більш наочним.

## 1.7. Висновки

По-перше, важливо, що робота має високий рівень актуальності. Це означає, що проблема, що досліджується, є важливою і потребує невідкладних розв'язань. Враховуючи сучасні технології та підходи до вирішення даної проблеми, є можливість наблизитись до цього розв'язання.

По-друге, якісний набір даних є ключовим для проведення досліджень і побудови моделі. Це означає, що мається достатньо обґрунтованих та надійних даних, які дозволять виконати дослідження та зробити висновки на підставі них. Якісні дані є основою для будь-якої наукової роботи і дозволяють забезпечити достовірність та надійність отриманих результатів.

Загалом, важливо продовжувати розвивати цю дипломну роботу, враховуючи актуальні технології і використовуючи якісний набір даних. Це допоможе побудувати важливу та цінну модель для розв'язання проблеми, що досліджується.

## РОЗДІЛ 2. ОПИС СПОСОБУ ВИРІШЕННЯ ЗАДАЧІ

### 2.1. Артеріальний тиск. Його види та вимір ззовні.

Артеріальний тиск створюється серцем шляхом послідовного скорочення передсердь та шлуночків. Скорочення передсердь, відоме як систола передсердь, триває близько 0.1-0.2 секунди і сприяє виштовхуванню крові з передсердь у шлуночки. Після цього настає скорочення шлуночків, відоме як систола шлуночків, тривалістю приблизно 0.3-0.4 секунди. Під час цього процесу кров виштовхується з шлуночків у аорту та легеневу артерію, створюючи значний тиск, який сприяє перетоку крові через судини.

Артеріальний тиск вимірюється у мм ртутного стовпчика і складається з двох значень: систолічного тиску (верхнє число) та діастолічного тиску (нижнє число). Наприклад, нормальний артеріальний тиск може бути показаним як 120/80 мм рт. ст., де 120 - систолічний тиск, а 80 - діастолічний тиск. Після скорочення шлуночків настає фаза діастолі, коли серце розслабляється і наповнюється кров'ю з передсердь. Під час цього періоду артеріальний тиск поступово знижується. Таким чином, серцевий цикл включає чергування між систолою (скорочення) і діастолою (розслаблення) серця.

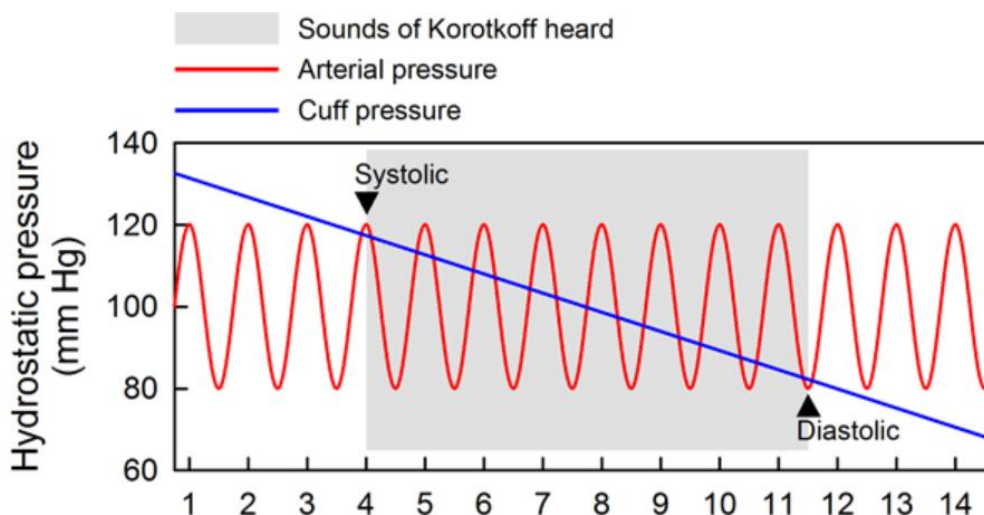


Рисунок 2.1 – Вимірювання гідростатичного артеріального тиску [11]

На рисунку 2.1 зображено традиційний спосіб вимірювання артеріального тиску. Червоною лінією зображено коливання систолічного та діастолічного артеріального тиску, синьою — спадаючий тиск рукава тонометра.

Також на рисунку 2.1 сірим виділено зону, де можна почути тони Короткова. Ці звуки є важливими діагностичними індикаторами для оцінки функції серця та визначення можливих відхилень.

Перша серцева тона (S1) або "луб" є найсильнішим звуком і відбувається в результаті замикання клапанів між передсердями та шлуночками. Під час скорочення шлуночків, мітральний (лівий) та трикуспідальний (правий) клапани закриваються, що створює перший звуковий тон. Цей тон вказує на початок систоли, коли кров виштовхується з шлуночків у аорту та легеневу артерію.

Друга серцева тона (S2) або "даб" виникає під час розслаблення шлуночків та закривання аортального (лівий) та легеневого (правий) клапанів. Цей звуковий тон позначає початок діастоли, коли шлуночки заповнюються кров'ю з передсердь. S2 може бути поділений на два підтони: A2 (аортальний

компонент) та P2 (пульмональний компонент), які відповідають закриттю клапанів аорти та легеневої артерії відповідно. [12]

Таким чином, ґрунтуючи вимірювання на тонах Короткова під час прослуховування артерій, що стискаються тонометром, ми дізнаємося значення систолічного та діастолічного артеріального тиску тільки під час проходження відповідного значення тиску при спадній зміні тиску рукава тонометра. Це створює неточне та непостійне вимірювання тиску, що не дає змогу провести більш детальну діагностику серцево-судинної системи людини.

## 2.2. Метод розв'язку задачі

На сьогоднішній день алгоритми машинного навчання активно розвиваються і знаходять застосування в різних сферах нашого життя. Зокрема, розвиток нейронних мереж сприяє вирішенню проблем, які раніше були складні або недосяжні. Крім того, кожного дня зробляються нові відкриття, які дозволяють збільшити обчислювальну потужність при зменшенні розміру пристроїв. Портативні акумуляторні батареї також стають більш ємними, що відкриває широкі можливості для розробки носимих пристроїв, які здатні контролювати біологічні сигнали в реальному часі. Крім того, наявність ринку таких пристроїв підтверджує готовність користувачів використовувати пристрої, що носяться, для моніторингу біологічних сигналів. Тому ми будемо використовувати підхід з застосуванням машинного навчання для вирішення цієї проблеми, оскільки він відповідає актуальним тенденціям та вимогам ринку.

Тиск визначатиметься за сигналом фотоплетізограми. Він підходить для визначення тиску з кількох причин.

По-перше, він віддалено нагадує сигнал електрокардіограми (ЕКГ), що дозволяє використовувати аналогічні підходи та методи для обробки та аналізу даних. Подібність у репрезентативних властивостях цих сигналів сприяє зручній роботі з фотоплетізограмою і дозволяє використовувати наявні дані артеріального тиску для навчання моделей машинного навчання.

По-друге, використання сигналу фотоплетізограми дозволить нам отримати інформацію про зміни об'єму крові у судинах, які пов'язані з артеріальним тиском, що дозволить нам побудувати модель для прогнозування тиску на основі цих сигналів.

Згортова нейронна мережа Residual Network, або ResNet найкраще підійде для реалізації цього зв'язку. Основна особливість ResNet полягає в

використанні "резидуальних блоків" або "skip connections" для ефективного передавання інформації через мережу, схема яких зображена на рисунку 2.2.

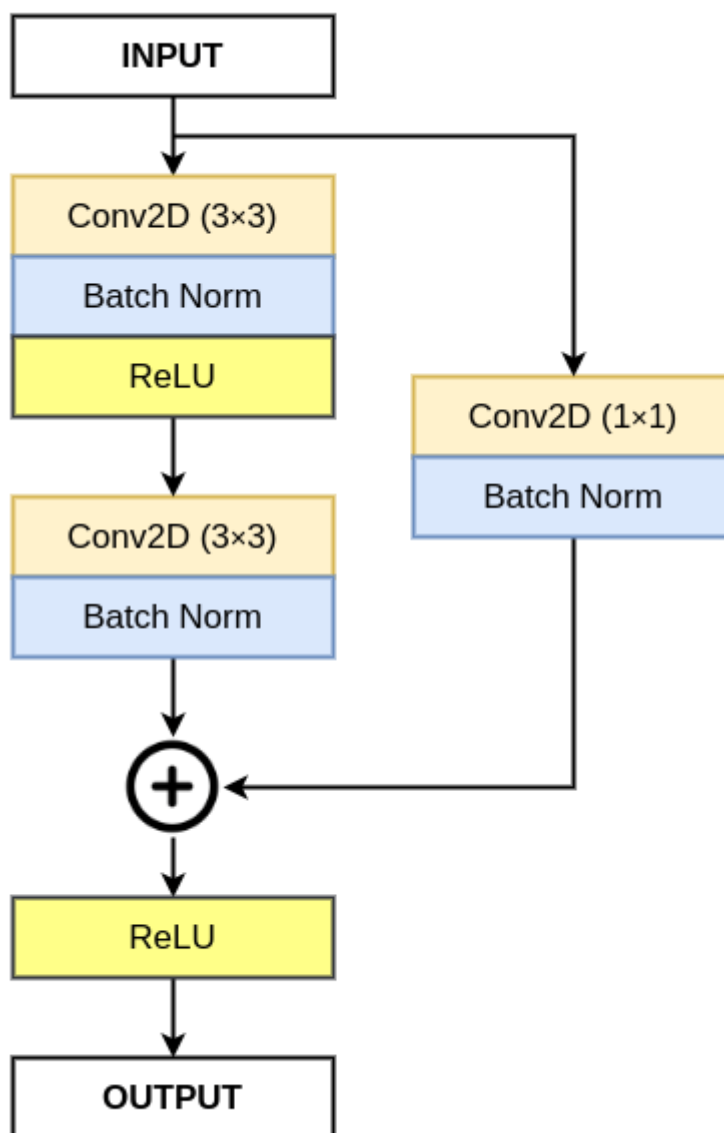


Рисунок 2.2 – Схема резидуальних блоків

Традиційні нейронні мережі мають лінійну послідовну структуру, в якій кожен шар приймає вхідні дані та виробляє вихідні значення, безпосередньо пов'язані з попереднім шаром. Однак, при збільшенні глибини мережі виникають проблеми, такі як зникнення градієнту, що може призвести до погіршення результатів навчання.

У ResNet використовується інноваційний підхід з використанням "skip connections", які дозволяють перескакувати через декілька шарів мережі, передавати інформацію безпосередньо з одного шару до іншого, незалежно від глибини мережі. Це робить мережу більш здатною до навчання глибоких моделей.

"Skip connections" додають резидуальні блоки до мережі, в яких вхідні дані додаються до вихідних значень після проходження через кілька шарів. Це створює так званий "residual" (або "залишковий") блок, який містить інформацію про "різницю" між вхідними та вихідними значеннями шару. Резидуальний блок навчається виробляти та передавати цю різницю, що дозволяє мережі більш ефективно навчатись. [13]

Модель отримуватиме на вхід вектор сигналу протягом певного періоду часу. Цей вектор буде містити інформацію про сигнал фотоплетізограми, що був зібраний і оброблений за відповідний проміжок часу. Подача вхідних даних у вигляді вектора дозволить моделі аналізувати та враховувати різні характеристики сигналу протягом цього періоду часу, що може сприяти кращому розпізнаванню та прогнозуванню значень артеріального тиску. Такий підхід дозволить моделі виявляти залежності та кореляції між вхідними сигналами та значеннями тиску, що є важливим для досягнення високої точності та ефективності.

У багатьох випадках додавання додаткових шарів до глибокої нейронної мережі дозволяє покращити точність та результативність моделі. Це пояснюється тим, що кожен шар мережі поступово навчається розпізнавати все більш складні та абстрактні характеристики вхідних даних. Наприклад, у випадку з впізнаванням зображень перший шар може вчитися розпізнавати краї зображення, другий шар - текстури, третій шар - об'єкти, і так далі.

Проте було виявлено, що існує певний поріг для глибини звичайної згорткової нейронної мережі, коли додавання додаткових шарів призводить до погіршення результатів. Рисунок 2.2, на якому відображений відсоток похибки

під час навчання та тестування, показує це для 20-шарової та 56-шарової нейронної мережі. З цього графіка можна зрозуміти, що зі збільшенням глибини мережі виникають проблеми з перенавчанням та загальною здатністю моделі до узагальнення.




Рисунок 2.3 – Порівняння похибок 20-ти та 56-ти шарових моделей

Дійсно, з графіка видно, що відсоток помилки для 56-шарової мережі є вищим, ніж для 20-шарової мережі, як для навчальних, так і для тестувальних даних. Це свідчить про те, що додавання додаткових шарів не покращує ефективність моделі, а навпаки, може призводити до зниження її продуктивності.

Можливою причиною погіршення продуктивності є проблема вгасання градієнту. При глибоких мережах градієнт може поступово втрачати свою силу під час зворотного поширення, що ускладнює навчання глибоких шарів і призводить до менш точних результатів.

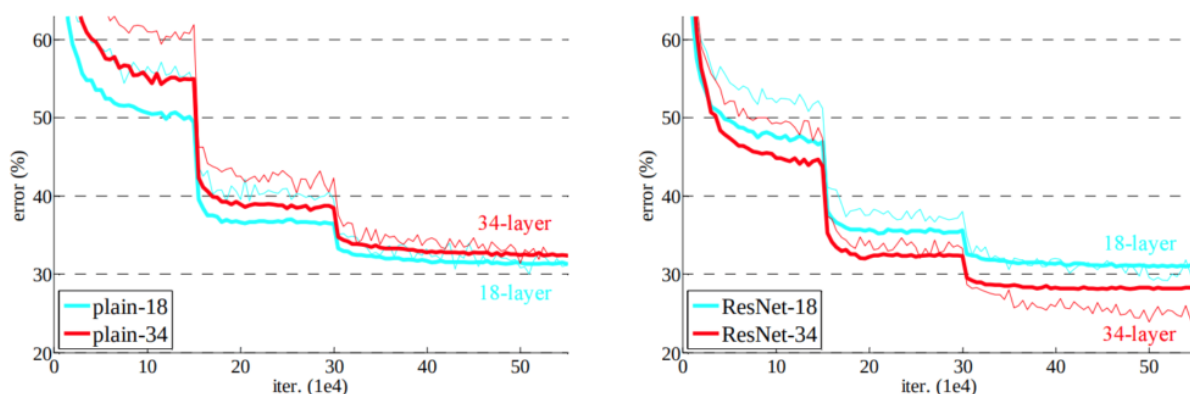


Рисунок 2.4 – Порівняння похибок 18-ти та 34-ьох шарових моделей

Проте, поглянувши на рисунку 2.3, можна запевнитися, що модель ResNet з 34-ма шарами має кращі результати, аніж 18-шарова і тим паче звичайна модель з 34-ма шарами. Також видно, що звичайна 18-ти шарова модель та ResNet майже не відрізняються.

Рисунки 2.3 та 2.4 показують два факти:

- що хоча додавання шарів може покращити результати моделі, необхідно урахувувати оптимальну глибину мережі, щоб уникнути перенавчання та забезпечити ефективну роботу моделі на нових даних;
- ResNet має нижчий рівень помилок порівняно зі звичайною нейронною мережею.

### 2.3. Оцінка якості розв'язку задачі

Використання навчальної та перевірконої вибірки для оцінки якості розв'язання задачі є доброю практикою. Це дозволяє перевірити, наскільки добре модель узгоджується з новими, раніше не баченими даними.

Для оцінки якості виміру похибок порівняно з клінічно вимірним артеріальним тиском, можна використовувати різні метрики. Деякі з них включають:

1. Середня абсолютна похибка (Mean Absolute Error): Ця метрика вимірює середнє значення абсолютних відхилень між прогнозованими значеннями тиску і фактичними значеннями. Чим нижче значення, тим краща точність моделі.

2. Середньоквадратична похибка (Mean Squared Error): Ця метрика вимірює середнє значення квадратів відхилень між прогнозованими значеннями тиску і фактичними значеннями. Вона враховує як величину, так і напрямок похибок. Чим нижче значення, тим краща точність моделі.

3. Коефіцієнт детермінації (Coefficient of Determination): Цей коефіцієнт вимірює пропорцію варіації відповіді, яка може бути пояснена моделлю. Він відображає, наскільки добре модель підходить до даних. Значення коефіцієнта детермінації може бути від 0 до 1, де значення 1 вказує на ідеальне узгодження. Чим ближче до 1, тим краща точність моделі.

## 2.4. Висновок

Застосування алгоритму машинного навчання для розв'язання цієї задачі є новаторським і може потребувати додаткової розробки та вдосконалення. Втім, такий підхід може привести до зміни багатьох підходів і відкриття нових можливостей в медицині щодо догляду та спостереження за пацієнтами. Крім того, це може створити нові ніші для бізнесу в межах ринку носимих пристроїв.

За допомогою алгоритмів машинного навчання можна розробляти моделі, які здатні аналізувати біологічні сигнали та передбачати показники здоров'я людей. Це відкриває широкі перспективи в галузі медицини, дозволяючи здійснювати моніторинг стану пацієнтів в реальному часі і вчасно реагувати на можливі проблеми або зміни.

Крім того, такі розв'язки можуть стати основою для розробки нових медичних технологій та носимих пристроїв, які дозволять пацієнтам контролювати свій стан здоров'я та отримувати рекомендації для поліпшення його.

Однак, важливо враховувати етичні, конфіденційність та безпекові аспекти використання таких технологій, а також забезпечувати належне валідацію та перевірку моделей перед їх впровадженням у клінічну практику.

Загалом, застосування алгоритмів машинного навчання в медицині для аналізу біологічних сигналів є перспективним напрямом, який може принести значні зміни в медичній практиці і відкрити нові можливості для розвитку бізнесу в галузі носимих пристроїв.

## **РОЗДІЛ 3. ОПИС РОЗРОБЛЕНИХ АЛГОРИТМІВ ТА ПРОГРАМНИХ МОДУЛІВ**

У цьому розділі представлено детальний опис алгоритмів та програмних модулів, розроблених з метою розпізнавання обличчя та виявлення фотоплетизмограми людини на відео-поточці. Враховуючи важливість надійного та ефективного виявлення фотоплетизмограми для аналізу фізіологічного стану людини, було розроблено комплексний підхід, що поєднує в собі обробку відео, аналіз обличчя та алгоритми фотоплетизмографії.

### **3.1. Структура підходу**

Перш ніж починати детально описувати методологію алгоритму отримання артеріального тиску людини з відео-поточку, варто визначити загальну структуру запропонованого алгоритму. Загалом метод поділяється на такі пункти:

1. Розпізнавання обличчя з відео-поточку;
  - 1.1. Виявлення обличчя на відео-поточці;
  - 1.2. Виділення регіонів інтересу на виявленому обличчі;
2. Визначення кольоровості регіонів інтересу для зняття показників фотоплетизмограми;
3. Обробка сигналу фотоплетизмограми. Зменшення нерівностей та шуму;
4. Відфільтрований сигнал потрапляє в нейронну мережу, яка виконує апроксимацію хвилі артеріального тиску на основі вхідного сигналу фотоплетизмограми;

5. Апроксимація хвилі артеріального тиску передається в нейронну мережу, що забезпечує уточнення сигналу

6. Після уточнення з сигналу визначається систолічний та діастолічний тиск

Графічно усі етапи та проміжкові результати запропонованого алгоритму зображено на рисунку 3.1.

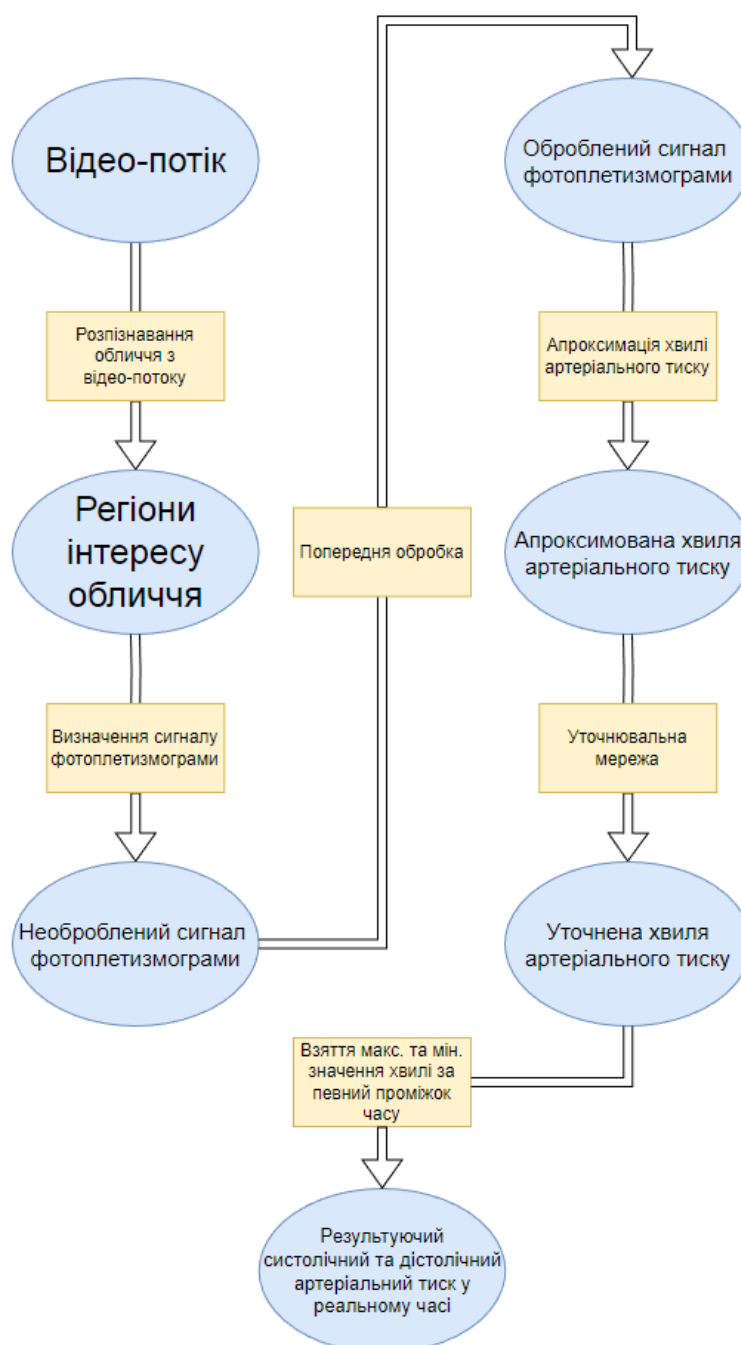


Рисунок 3.1 – Блок-схема структури запропонованого алгоритму

### 3.2. Виявлення обличчя на відео-поточі

Завдання виявлення обличчя з відео-поточу вирішується завдяки системи виявлення об'єктів Віоли-Джонса. [14]

Основна ідея цього алгоритму полягає у використанні "вікон", що ковзають по зображенню, для виявлення об'єктів. Кожне "вікно" представляє собою прямокутну область на зображенні, яка перевіряється на наявність об'єкта. Для кожного "вікна" виконується набір оцінок, що базуються на інтегральному зображенні. Інтегральне зображення — це швидкий метод обчислення суми значень пікселів у певній прямокутній області.

Алгоритм Віоли-Джонса використовує статистичні оцінки, які отримуються з тренувального набору зображень, щоб створити класифікатор об'єктів. Тренувальний процес включає навчання класифікаторів з використанням техніки "адаптивного тренування", яка дозволяє вибирати найбільш розпізнавані ознаки об'єктів. Класифікатори використовуються для визначення того, чи наявний об'єкт у вказаному "вікні". Вони можуть виявляти об'єкти з різними характеристиками, такими як обличчя людей, очі, усі, автомобілі тощо.

Процес виявлення об'єктів Віоли-Джонса ефективний та швидкий завдяки використанню інтегрального зображення, яке дозволяє швидко обчислити характеристики в різних прямокутних регіонах. Також, алгоритм може бути оптимізований шляхом використання каскадного підходу, де багато класифікаторів використовуються послідовно, щоб ефективно відфільтрувати регіони, які не містять об'єкти.

Однією з основних переваг системи Віоли-Джонса є її швидкість та ефективність. Вона може працювати в реальному часі, що робить її придатною для застосування в системах спостереження та розпізнавання об'єктів у

реальному часі. Також, алгоритм є стійким до змін у зовнішніх умовах, таких як освітлення та орієнтація об'єктів.

Для вирішення цієї задачі було обрано класифікатор Хаара, що доступний у бібліотеці OpenCV.

Класифікатор Хаара є одним з найпоширеніших алгоритмів для виявлення обличчя. Він базується на використанні каскаду класифікаторів, які навчені розпізнавати певні особливості обличчя, такі як очі, ніс, рот та інші. Каскад класифікаторів складається з багатьох послідовно з'єднаних класифікаторів, кожен з яких навчений розпізнавати певну ознаку обличчя.

Алгоритм роботи класифікатора Хаара наступний [15]:

1. Перед використанням класифікатора Хаара необхідно завантажити навчену модель класифікатора, яка включає в себе набір позитивних зображень обличчя (з обмеженим регіоном інтересу) і негативних зображень, що не містять обличчя. Ці дані використовуються для навчання класифікатора.

2. Зображення або відео, на якому потрібно виявити обличчя, розбивається на блоки різного розміру, які перевіряються класифікатором. Кожен блок аналізується шляхом порівняння його особливостей з навченою моделлю.

3. Для кожного блоку виконується оцінка наявності обличчя шляхом використання позитивних і негативних ознак, що визначаються класифікатором Хаара. Ознаки можуть включати зміну контрасту, градієнтів, розмірів, форми та інших параметрів, які виявилися важливими для розпізнавання обличчя.

4. Кожен блок проходить каскад класифікаторів, де кожен класифікатор виконує оцінку певної ознаки обличчя. Якщо блок успішно проходить через всі класифікатори каскаду, він визнається як обличчя.

5. Після виявлення обличчя можна виконати додаткову обробку, наприклад, вирівнювання обличчя за допомогою афінних перетворень або

виділення ключових ознак, таких як очі, ніс та рот, для подальшого аналізу.

Важливо зазначити, що класифікатор Хаара може виявляти як обличчя, так і області, що не є обличчями, але можуть мати схожі ознаки. Тому після виявлення обличчя застосовуються додаткові перевірки та для підтвердження обличчя та виключення помилкових виявлень.

### **3.3. Виділення регіонів інтересу**

Для подальшого виявлення фотоплетизмограми на обличчі потрібно виділити регіони інтересу, такі як лоб та щоки. Для цього знаходяться координати обличчя, які були отримані після виявлення за допомогою класифікатора Хаара. Алгоритми визначають регіон лоба шляхом визначення верхньої границі на основі положення дуг очей. Також визначаються регіони щок, шляхом визначення бокових границь на основі положення зовнішніх куточків очей та рота. Отримані координати цих регіонів використовуються для виділення відповідних областей з вхідного зображення або кадру відео. Виділені регіони інтересу (лоб та щоки) будуть використані для подальшого отримання показників фотоплетизмограми, а саме, RR-інтервалів.

### 3.4. Зняття показників фотоплетизмограми з регіонів інтересу

Для створення нейронної мережі, яка визначає RR-інтервали з регіонів інтересу обличчя (щок та лобу), необхідно провести наступні кроки. Початково збираються дані, що включають зображення обличчя та відповідні RR-інтервали. Дані підготовлюють для навчання моделі.

Потім визначається архітектура нейронної мережі, яка може включати згорткові шари (Convolutional Layers) та повністю зв'язані шари (Fully Connected Layers). Мережу навчають з використанням алгоритмів оптимізації, таких як стохастичний градієнтний спуск (SGD), та функції втрати, яка вимірює різницю між прогнозованими і фактичними RR-інтервалами.

Після навчання модель оцінюють за допомогою валідаційного набору даних, використовуючи метрики якості, середньоквадратична помилка тощо. Модель тестують на окремому наборі даних, які не використовувалися під час навчання або валідації.

Залежно від результатів тестування може знадобитися додаткового налагодження та оптимізація моделі. Після досягнення достатньої точності модель використовується для визначення RR-інтервалів з попередньо виявлених регіонів інтересу обличчя. Для цього подається зображення регіону на вхід моделі, а отримані прогнози використовуються як вихідні значення RR-інтервалів.

### 3.5. Тренувальні дані та їх обробка

Для розробки та оцінки запропонованого алгоритму використовується набір даних Physionet MIMIC III. MIMIC-III (Medical Information Mart for Intensive Care) — це велика база даних, яка містить клінічні дані пацієнтів, госпіталізованих на інтенсивну терапію. База даних була розроблена для досліджень та розвитку у галузі медичної інформатики. Джерелом даних для MIMIC-III є медичні системи, використані в госпіталі Beth Israel Deaconess Medical Center у Бостоні, США, а дані зібрані протягом періоду з 2001 по 2012 рік [16].

MIMIC-III містить інформацію про понад 40 000 пацієнтів, яка включає витяги з медичних записів, лабораторні результати, виміри фізіологічних показників, інформацію про адміністрування ліків, дані зображень та інше. Тривалість записів може варіюватись: більшість з них тривають принаймні 20 годин, а деякі можуть мати тривалість 40 годин і більше. Загалом, база даних містить сигнали артеріального тиску та фотоплетизмограми для понад 200 пацієнт-днів, а також супровідні клінічні дані. Ця база даних надає можливість виконувати запити та аналізувати великі обсяги даних, що дозволяє дослідникам вивчати характеристики пацієнтів, вплив лікування на результати, розробляти та валідувати прогностичні моделі та багато іншого.

Використання бази даних MIMIC-III для тренування мережі, що апроксимує систолічний та діастолічний артеріальний тиск на основі сигналу фотоплетизмограми, забезпечує використання реальних клінічних даних, що гарантує високу якість та достовірність моделі. Такий підхід дає можливість розробити точну та ефективну модель, яка може бути застосована для неклінічного моніторингу артеріального тиску на основі сигналу фотоплетизмограми.

Цей набір даних є цінним ресурсом для досліджень у медичній сфері, оскільки він надає доступ до реальних клінічних записів пацієнтів, які перебували в реанімації. Використання цих даних дозволяє дослідникам та розробникам алгоритмів аналізувати сигнали артеріального тиску та фотоплетизмограми, розробляти та оцінювати методи прогнозування артеріального тиску та досліджувати нові підходи до медичної діагностики та моніторингу.

Використання набору даних MIMIC-III дозволяє проводити дослідження та експерименти з реальними клінічними даними, що сприяє поліпшенню якості та ефективності розроблених алгоритмів.

Зазвичай, кожен запис складається зі значної кількості окремих файлів. Дані, що отримані з приліжкових моніторів, розподіляються на файли, кожен з яких містить записи сигналів, тривалістю по 10 хвилин. Після цього файли можуть бути об'єднані без пропусків для створення безперервного запису.

Сигнали артеріального тиску в даному наборі даних мають частоту дискретизації 125 Гц і записуються з точністю 8 біт. Таблиця 1, де відображені мінімальні, максимальні та середні значення цих сигналів, а також середньоквадратичне відхилення, надає детальну статистику для сигналів систолічного, діастолічного та абсолютного артеріального тиску.

Таблиця 3.1 — статистика бази даних MIMIC-III

	Макс. зн.	Мін. зн.	Сер. зн.	Сер.-кв. відх.
Систолічний артеріальний тиск	198.71	72.38	133.95	23.06
Діастолічний артеріальний тиск	156.54	50.63	65.89	11.66
Середній артеріальний тиск	172.51	60.19	91.28	15.3

Для подальшого аналізу було вибрано епізоди сигналу артеріального тиску та фотоплетизмограми довжиною 8,192 секунди. Ця довжина обумовлена наявністю 1024 семплів у наборі даних, що дозволяє ефективно навчити глибоку нейронну мережу з оптимізованою обчислювальною складністю. Апроксимація сигналу артеріального тиску здійснюється за допомогою сигналів фотоплетизмограми, що мають таку саму довжину 8,192 секунди.

Для зменшення обчислювальних вимог база даних була оптимізована за такою схемою. Спочатку сигнали загальною тривалістю 741,53 години були розбиті на проміжки довжиною 8,192 секунди відповідно до значень систолічного та діастолічного тиску. Далі, з кожного проміжку було випадковим чином вибрано 25% даних. Однак, якщо кількість вибраних епізодів з одного проміжку перевищувала 2500, то випадковим чином було обрано лише 2500 епізодів. В результаті було отримано загалом 127260 випадкових епізодів, що тривали до 353,5 годин.

Потім вибірку було розділено на тренувальний і перевірочний набори даних. 100000 випадково обраних епізодів (приблизно 78,58%) стали тренувальною вибіркою, а решта 27260 епізодів склали перевірочний набір даних. При розподілі даних було забезпечено, щоб включені були дані сигналів від усіх пацієнтів, а також щоб дані для навчання та перевірки не перетиналися.

Всі ці кроки були виконані з уважністю та належним доглядом для забезпечення якості вибірки та виключення перетину даних.

### 3.6. Апроксимуюча мережа

Після фільтрації, відфільтровані сигнали проходять через апроксимаційну мережу. Ця мережа використовує вхідний сигнал фотоплетизмограми для апроксимації сигналу артеріального тиску. Оптимізована нейронна мережа, така як повна згорткова нейронна мережа U-net, може використовуватися для цієї апроксимації. Метою апроксимаційної мережі є навчання та уявлення внутрішньої залежності між фотоплетизмограмою і сигналом артеріального тиску. Після навчання мережа здатна прогнозувати значення артеріального тиску на основі вхідного сигналу фотоплетизмограми.

Апроксимаційна мережа U-Net є одновимірною глибокою моделлю машинного навчання з вчителем. Вона використовує повні згорткові шари для класифікації кожного значення вхідного сигналу. У порівнянні зі звичайними згортковими мережами, які класифікують всі епізоди сигналу в одну мітку класу, U-Net здатна класифікувати неперервний сигнал, присвоюючи кожній точці вхідного сигналу мітку класу або апроксимоване значення у випадку задачі регресії.

Мережа U-Net складається з двох основних компонентів: енкодера і декодера. Енкодер виконує функцію витягування корисних просторових ознак з вхідного сигналу шляхом застосування звичайних згорткових шарів без повнозв'язаних шарів. Цей процес дозволяє отримати стисле представлення цих ознак у вигляді вектору зменшеної розмірності. Енкодер відповідає на запитання "Які ознаки сигналу вказують на певне значення тиску?".

Декодер виконує функцію розкодування вектору ознак, присвоюючи прогнозоване значення кожній точці вхідного сигналу. Це дозволяє створити вихідний сигнал, який є апроксимованим сигналом артеріального тиску. Декодер відповідає на запитання "Де відбувається зміна тиску вхідного

сигналу?" та встановлює відповідність між прогнозованим значенням тиску та кожною точкою вхідного сигналу.

Таким чином, поєднання енкодера і декодера у мережі U-Net дозволяє апроксимувати сигнал артеріального тиску на основі вхідного сигналу фотоплетизмограми, виконуючи виділення корисних ознак і створення вихідного сигналу з прогнозованими значеннями тиску для кожної точки.

Архітектура U-Net використовує інноваційну ідею пропусків з'єднань, що дозволяють зберегти карти просторових ознак на різних шарах мережі. Це важливо, оскільки стандартні операції пулінгу або об'єднання в згорткових мережах можуть призводити до втрати просторової інформації про ознаки. У випадку U-Net це особливо цінно, оскільки збереження просторової структури вхідного сигналу має велике значення.

Хоча оригінальна архітектура U-Net була розроблена для задачі семантичної сегментації зображень, в даній роботі вона застосовується для регресії на одновимірних сигналах. Тому двовимірні операції згортання, пулінгу та збільшення вибірки замінюються їх одновимірними аналогами. Окрім цього, всі згорткові шари, крім останнього, використовують функцію активації ReLU (випрямлена лінійна функція) та пакетну нормалізацію (batch normalization) для поліпшення навчання та стабільності мережі.

Для отримання результуючого прогнозу регресії використовується останній згортковий шар з лінійною функцією активації, яка дозволяє прогнозувати неперервні значення. Крім того, в мережі U-Net застосовується глибокий нагляд, що означає, що виходи проміжних шарів декодера використовуються як додаткові сигнали для покращення якості прогнозування. Це дозволяє отримати більш точні та стабільні результати.

Глибокий нагляд (deep supervision) є методом, який допомагає поліпшити процес навчання та кінцеві результати прихованих шарів в мережі. У випадку U-Net, що використовується в даній роботі, застосовується глибокий нагляд шляхом обчислення проміжного виходу, який є стиснутим

представленням фактичного вихідного сигналу перед кожною операцією оберненого пулінгу.

Функція втрат обчислюється з поступовим зменшенням коефіцієнта ваги з кожним наступним шаром у глибину мережі. Ці додаткові допоміжні втрати, які враховуються на різних шарах, допомагають "форсувати" навчання прихованих шарів і сприяють поліпшенню якості прогнозування. Зменшення коефіцієнта ваги допомагає акцентувати навчання на більш важливих деталях та особливостях сигналу, що може сприяти кращій апроксимації цілісного сигналу артеріального тиску.

### **3.7. Уточнювальна мережа**

MultiResUNet є модифікацією архітектури U-Net, яка використовується для вдосконалення результатів апроксимаційної мережі. Вона зберігає основний принцип U-Net, а саме наявність енкодера і декодера з з'єднаннями, що зберігаються.

Однак, MultiResUNet використовує блоки з підсумовуванням (downsampling) та збільшенням роздільності (upsampling) з різними розмірами фільтрів для збереження інформації з різних шарів і масштабів. Це дозволяє мережі краще адаптуватися до різних деталей і особливостей сигналу артеріального тиску.

Загальний вигляд мережі MultiResUNet включає декілька повторюваних блоків, кожен з яких складається зі згорткових шарів, функції активації (наприклад, ReLU) і з'єднань. В результаті обробки сигналу через цю мережу отримується вдосконалений результат апроксимації, який має менші

відхилення від фактичних результатів. Загальну схему мережі зображено на рисунку 3.2.




Рисунок. 3.2. Схема мережі MultiResUNet

Блок MultiRes є ключовою складовою моделі MultiResUNet і використовується для поліпшення результатів порівняно з моделлю U-Net. Основна відмінність полягає у включенні блоків MultiRes та пропускових з'єднань Res. Замість звичайних пар згорткових шарів  $3 \times 3$ , блоки MultiRes використовують композицію згорткових операцій  $3 \times 3$ ,  $5 \times 5$  та  $7 \times 7$ . Це дозволяє емулювати результати згортки різного розміру і одночасно зменшує кількість параметрів, що підлягають навчанню. Опис загального вигляду блоку MultiRes представлено на рисунку 3.2 [17].

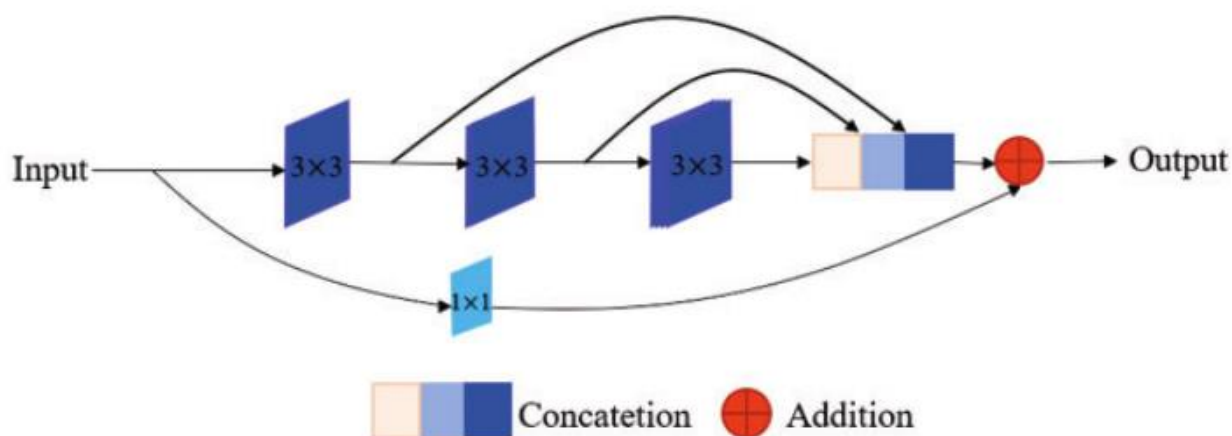


Рисунок 3.2 – Структура блоку MultiRes

Зокрема, в моделі MultiResUNet використовуються Res-шляхи, що мають за мету зменшити розбіжність між картами ознак на різних рівнях енкодера та декодера. Це досягається шляхом додавання додаткових згорткових операцій по парах відповідних з'єднань. Це допомагає забезпечити кращу гармонію між різними рівнями мережі та зменшити розриви у карті ознак. Загальний вигляд таких Res-шляхів (Res Path) показано на рисунку 3.3 [17].




Рисунок 3.3 – Res Path

Для уточнення прогнозу до дуже незначних коливань використовувалась дуже глибока мережа. Проте, це призводило до проблеми повільного навчання через затухання градієнтів. Щоб вирішити цю проблему, було використано з'єднання через декілька шарів. Ці з'єднання передають градієнти від шарів ближчих до декодера до початкових шарів мережі з більшою амплітудою, ніж у випадку послідовного з'єднання шарів. Це сприяє більш ефективному оновленню параметрів в абсолютних значеннях.

Аналогічно до апроксимаційної мережі, ця модель також складається з одновимірних операцій згортки, об'єднання (пулінгу) та зворотного пулінгу в декодері. Функції активації для всіх шарів, крім останнього, використовують ReLU. Останній шар використовує лінійну активацію. Крім того, шари періодично нормалізуються для покращення стійкості та швидкості навчання.

### **3.8. Побудова мереж**

У даній роботі для побудови мереж та проведення дослідження використовується мова програмування Python і бібліотека Keras з підтримкою TensorFlow. Експерименти проводилися у середовищі розробки Google Colab з використанням графічного процесора Nvidia Tesla T4 для навчання моделей.

#### **3.8.1. Вибір придатних для вирішення задачі моделей**

Помічено, що U-Net та MultiResUNet моделі показали кращі результати порівняно з іншими моделями глибокого навчання, такими як SegNet та FCNN. Також було проведено експерименти з комбінацією U-Net та MultiResUNet архітектур для мереж апроксимації та вдосконалення результату.

Під час аналізу результатів було виявлено, що коли U-Net використовувалася як мережа вдосконалення, вона не досягала такої ж продуктивності, як MultiResUNet. З іншого боку, коли MultiResUNet використовувався як апроксимаційна мережа, він показував кращі результати, ніж класична U-Net. Зауважимо, що коли інша модель MultiResUNet використовувалася як мережа вдосконалення, загальна продуктивність залишалася ідентичною.

З цього можна зробити припущення, що хоча MultiResUNet перевершує U-Net у досягненні кращої форми сигналу, з часом вона досягає плато. Проте, через те, що U-Net має меншу обчислювальну складність, вона була використана як модель апроксимації, а MultiResUNet як модель вдосконалення.

### 3.8.2. Вибір функцій втрат

Середня квадратична похибка (Mean Squared Error, MSE) і середня абсолютна похибка (Mean Absolute Error, MAE) є двома найбільш поширеними функціями помилки або збитків в регресійних задачах. Вони використовуються для оцінки різниці між прогнозованими значеннями і фактичними значеннями вихідної змінної.

Загальний вигляд середньої квадратичної похибки та середньої абсолютної похибки представлений нижче відповідно у формулах 3.1 та 3.2.

$$MSE = \frac{\sum(y_i - \hat{y}_i)^2}{n} \quad (3.1)$$

$$MAE = \frac{\sum|y_i - \hat{y}_i|}{n} \quad (3.2)$$

де  $n$  - кількість прикладів у наборі даних,

$y_i$  - фактичне значення для  $i$ -го елемента вибірки,

$\hat{y}_i$  - прогнозоване значення для  $i$ -го елемента вибірки,

$\Sigma$  - сума значень по всіх елементах вибірки.

MSE обчислює середнє значення квадратів різниць між фактичними і прогнозованими значеннями. Він покарає великі помилки більше, ніж MAE, через квадратичну залежність. MAE обчислює середнє абсолютне значення різниць, і він вважає всі помилки рівнозначними без залежності від їх напрямку.

Обидві функції мають свої переваги та застосування в різних контекстах. Вибір між ними залежить від конкретної задачі та важливості різних типів помилок.

Під час дослідження було виявлено, що використання функції втрат MAE (середня абсолютна похибка) для апроксимаційної мережі покращує точність моделі у порівнянні з використанням функції втрат MSE (середня квадратична похибка). Навчання мережі з використанням MSE спричиняє швидший спад помилки.

Експерименти показали наступні результати: на етапі апроксимації сигналу головна мета полягає у отриманні приблизної форми сигналу, і важливо ставити однакові ваги для всіх помилок. Використання MSE як функції втрат покарає більші помилки ширше, оскільки вони підносяться до квадрату. Це може призвести до погіршення загальної апроксимації, оскільки на цьому етапі є обмежена інформація про вихідний сигнал.

З іншого боку, використання MAE на етапі апроксимації мережі враховує всі значення помилок і забезпечує грубий, але задовільний прогноз форми сигналу. На етапі вдосконалення мережі, де вже є загальне наближення форми сигналу, використання MSE стає корисним. Більші значення помилок караються краще, що сприяє поліпшенню результатів.

Отже, емпіричні дані підтверджують, що використання MAE на етапі апроксимації та MSE на етапі вдосконалення дає найкращі результати в контексті побудови точних моделей апроксимації та вдосконалення сигналів.

### **3.8.3. Дослідження кількості згорткових шарів**

Дослідження ефективності ширших варіантів мереж U-Net та MultiResUNet показало, що збільшення кількості згорткових фільтрів

призводить до кращої продуктивності моделей. Це пояснюється тим, що більша кількість фільтрів дозволяє моделям вивчати та фіксувати більше ознак та патернів у вхідних даних.

Однак, разом зі збільшенням кількості фільтрів зростає і обчислювальна складність моделі. Це може вимагати більшої обчислювальної потужності та часу для навчання. Зауважено, що покращення результатів не варто додаткових обчислювальних затрат.

У результаті було прийнято компромісне рішення, враховуючи наявні обчислювальні потужності. Для моделі U-Net було обрано кількість фільтрів, яка була кратна 64 (наприклад, 64, 128, 256, 512, 1024). Щодо MultiResUNet, швидкість навчання була обмежена на рівні 2,5, що дозволяло досягнути прийнятних результатів без зайвих обчислювальних витрат.

Це компромісне рішення дозволяє зберегти баланс між точністю результатів та обчислювальними вимогами при навчанні моделей.

#### **3.8.4. Тренування моделей**

Для навчання апроксимуючої мережі та мережі вдосконалення використовувалися середня абсолютна похибка (MAE) та середня квадратична похибка (MSE) як функції збитків. Ці функції оцінюють відповідність прогнозованого сигналу артеріального тиску до фактичного сигналу на основі абсолютної та квадратичної різниці між ними.

Для оптимізації цих функцій збитків було використано оптимізатор Адам. Адам є модифікацією методу стохастичного градієнтного спуску, який адаптивно обчислює різні швидкості навчання для окремих параметрів на основі оцінок першого та другого моментів градієнтів. Цей оптимізатор

дозволяє швидше знаходити оптимальні значення параметрів моделі під час навчання.

Навчання було проведено протягом 100 епох. Епоха - це одна ітерація навчання, де всі дані перевіряються моделлю один раз. Після 100 епох вдосконалення не спостерігалось в жодній з моделей, що означає, що після цієї точки навчання додаткові епохи не призводять до подальшого покращення результатів.

### **3.8.5. Результати виміру артеріального тиску**

Результати цієї роботи з дослідження показують, що запропонована модель має здатність перетворювати сигнали фотоплетизмограми відповідно на сигнали артеріального тиску, зберігаючи їх форму, довжину та відповідність фаз хвиль. Це означає, що, незважаючи на суттєві різниці у формі хвиль між фотоплетизмограмою та артеріальним тиском, така модель може відносно точно передбачати форму хвилі артеріального тиску, використовуючи лише сигнал фотоплетизмограми.

На рисунку 3.4 показана порівняльна ілюстрація між апроксимованою формою хвилі і уточненою формою хвилі артеріального тиску. Видно, що уточнена форма хвилі досить точно відповідає апроксимованій формі хвилі артеріального тиску. Це свідчить про те, що модель успішно транслює сигнали фотоплетизмограми відповідно на сигнали артеріального тиску, зберігаючи їх основні характеристики.

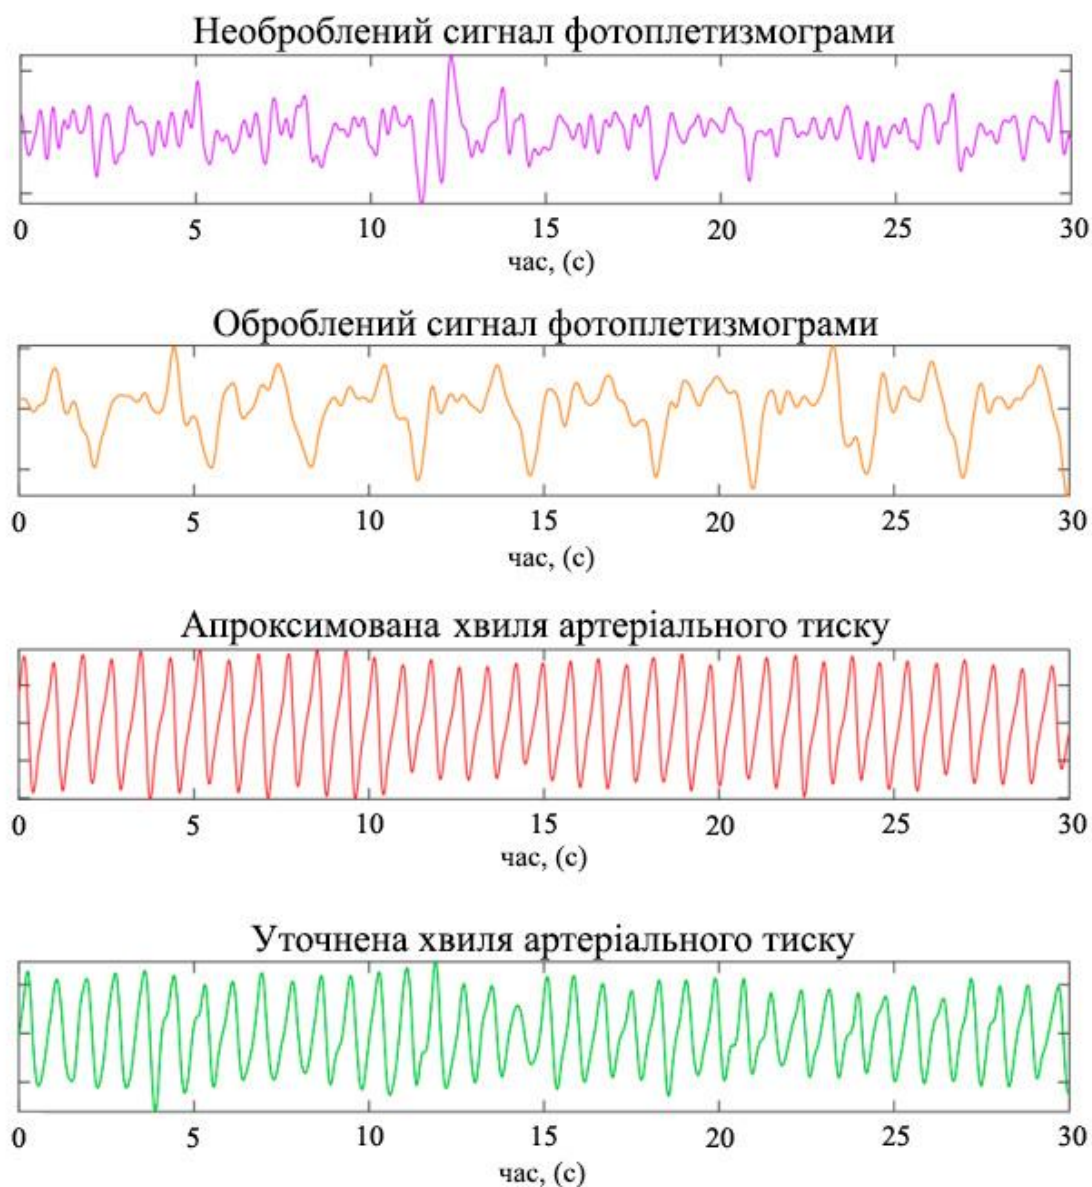


Рисунок 3.4 – Графіки фотоплетизмограми та артеріального тиску

Це важливе досягнення, оскільки доведено, що можна використовувати фотоплетизмограму для непрямого прогнозування артеріального тиску. Це може мати значний потенціал для розвитку неінвазійних методів вимірювання тиску та моніторингу здоров'я.

Середня абсолютна похибка передбачення артеріального тиску становить  $5,141 \pm 3,592$  мм ртутного стовпчика на всьому перевірочному наборі даних. Це означає, що середня похибка передбачення становить

приблизно 5,141 мм ртутного стовпчика, а стандартне відхилення похибки дорівнює 3,592 мм ртутного стовпчика. Ці значення вказують на те, наскільки точно модель може передбачати артеріальний тиск, а також на варіативність результатів.

Крім того, середня абсолютна похибка прогнозування діастолічного і систолічного тиску складає відповідно  $3,326 \pm 7,259$  мм ртутного стовпчика та  $5,579 \pm 8,607$  мм ртутного стовпчика. Це показує, що модель також має добру точність у прогнозуванні цих параметрів, але існує певна розбіжність між передбаченими значеннями і дійсними значеннями, яка виражена стандартним відхиленням.

Цікавим є той факт, що запропонована модель, заснована на глибокому навчанні, змогла подолати фазовий зсув між сигналами фотоплетизмограми та артеріального тиску. Це означає, що модель змогла коректно врахувати затримку між цими сигналами та забезпечити точність прогнозування навіть у випадку фазових відхилень. Це є значною перевагою, оскільки реальні додатки можуть мати різні фазові затримки між сигналами, і здатність моделі працювати з такими відхиленнями є важливою для точного прогнозування.

Ці результати свідчать про потенціал запропонованої моделі на основі глибокого навчання у вирішенні завдань прогнозування артеріального тиску та вирівнювання фазових затримок.

### **3.9. Експеримент**

Для перевірки дієздатності запропонованого алгоритму визначення систолічного та діастолічного тиску з відео-потoku було проведено експеримент.

Експеримент полягатиме в аналізі короткого відео з дебатів між Дональдом Трампом та Хілларі Клінтон [19]. Основна мета експерименту - визначити динаміку та відношення артеріального тиску учасників дебатів на основі аналізу фотоплетизмограми з відео-потoku.

На рисунку 3.5 зображено скрін-шот з відео дебатів між Дональдом Трампом та Хілларі Клінтон, обробленим першим модулем запропонованого алгоритму. На відео Дональд Трамп зображений зліва, а Хілларі Клінтон — справа, обличчя обох виділені першим модулем запропонованого алгоритму.



Рисунок 3.5 – Дональд Трамп (зліва) та Хілларі Клінтон (справа)  
з виділеними обличчями

Далі алгоритм зчитує фотоплетизмограму. З відео витягти фрейми, що містять зображення обличчя кожного з учасників. Використовуючи алгоритми обробки зображень, виділити область, що відповідає регіону пульсації, а саме, лоб та щоки.

Після цього відбувається обробка сигналу фотоплетизмограми. Використовуючи уточнювальну мережу, робиться фільтрація та попередню

обробку сигналу фотоплетизмограми для зменшення шуму та видалення артефактів.

Застосовуючи запропоновану модель, на основі сигналу фотоплетизмограми апроксимується артеріальний тиск.

Отримані результати суб'єкта 1 (Дональда Трампа) та суб'єкта 2 (Хілларі Клінтон) відображені на рисунку 3.6 у вигляді графіків проміжкових результатів кожного модуля запропонованого алгоритму впродовж часу.

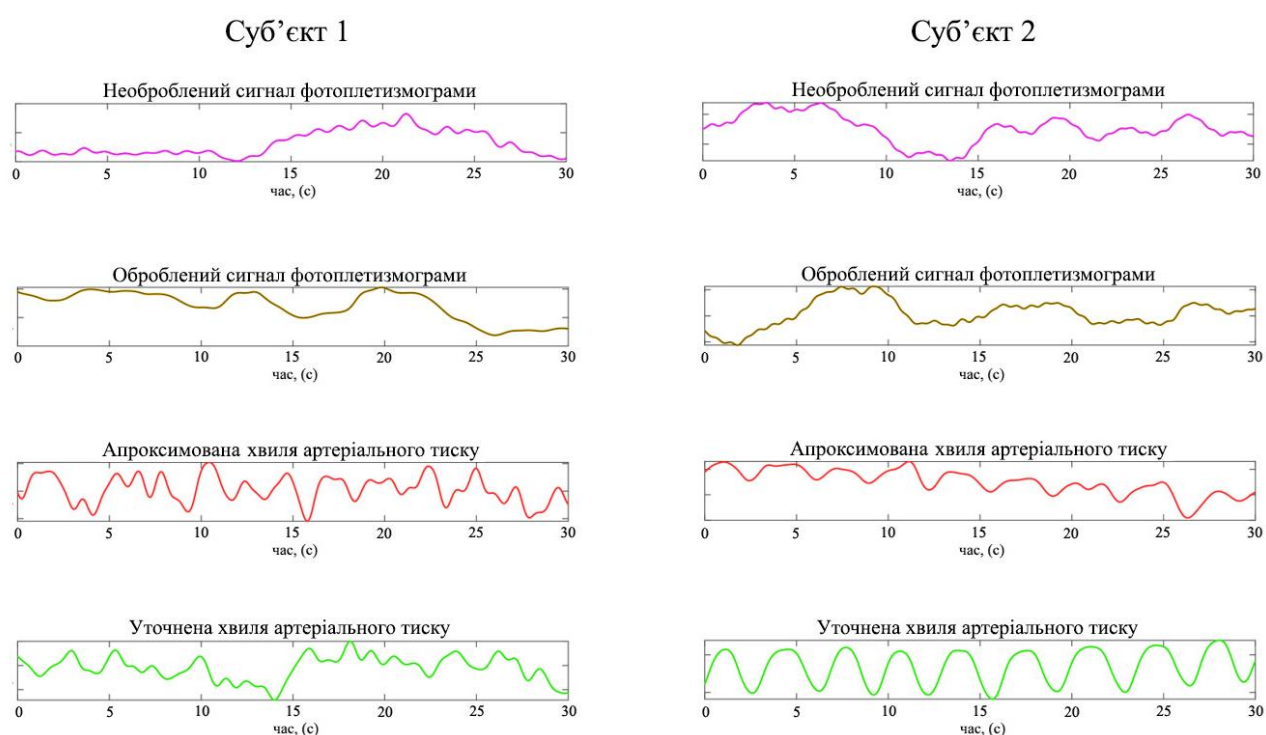


Рисунок 3.6 – Графіки результатів експерименту

Середні значення систолічного тиску суб'єкта 1 складає 135 мм ртутного стовпчика, а діастолічного тиску — 91 мм ртутного стовпчика, у свою чергу, значення систолічного тиску суб'єкта 2 складає 128 мм ртутного стовпчика, а діастолічного тиску — 85 мм ртутного стовпчика. Обидва суб'єкта показують трохи підвищений тиск відносно еталонного 120 на 80, що може бути викликано вже похилим віком обох суб'єктів, розмовою, котра зазвичай підвищує тиск людини, або напруженою ситуацією.

## **РОЗДІЛ 4 ФУНКЦІОНАЛЬНО-ВАРТІСНИЙ АНАЛІЗ ПРОГРАМНОГО ПРОДУКТУ**

У цьому розділі будуть проведені оцінки основних характеристик майбутнього програмного продукту, який спеціалізується на аналізі біосигналів людини з використанням глибокого навчання на основі сигналу фотоплетизмограми. В дослідженні будуть представлені різні варіанти реалізації для забезпечення вибору найкоректнішої та оптимальної стратегії, яка враховуватиме економічні фактори та сумісність з майбутнім програмним продуктом. Для цього застосовуватиметься функціонально-вартісний аналіз.

Функціонально-вартісний аналіз (ФВА) передбачає собою технологію, що дозволяє оцінити реальну вартість продукту або послуги незалежно від організаційної структури компанії. ФВА проводиться з метою виявлення резервів зниження витрат за рахунок ефективніших варіантів виробництва, кращого співвідношення між споживчою вартістю виробу та витратами на його виготовлення. Для проведення аналізу використовується економічна, технічна та конструкторська інформація.

Алгоритм функціонально-вартісного аналізу включає в себе визначення послідовності етапів розробки продукту, визначення повних витрат (річних) та кількості робочих часів, визначення джерел витрат та кінцевий розрахунок вартості програмного продукту.

### **4.1 Постановка задачі проектування**

У роботі застосовується метод ФВА для проведення техніко-економічного аналізу розробки системи класифікації лейкоцитів на зображеннях крові. Оскільки рішення стосовно проектування та реалізації

компонентів, що розробляється, впливають на всю систему, кожна окрема підсистема має її задовольняти. Тому фактичний аналіз представляє собою аналіз функцій програмного продукту, призначеного для збору, обробки та проведення аналізу даних по класифікації.

Технічні вимоги до програмного продукту є наступні:

- функціонування на персональних комп'ютерах із стандартним набором компонентів;
- зручність та зрозумілість для користувача;
- швидкість обробки даних та доступ до інформації в реальному часі;
- можливість зручного масштабування та обслуговування;
- мінімальні витрати на впровадження програмного продукту.

## 4.2 Обґрунтування функцій програмного продукту

Головна функція  $F_0$  – розробка програмного продукту, який вирішує задачу розпізнавання та класифікації лейкоцитів на зображеннях крові. Беручи за основу цю функцію, можна виділити наступні:

$F_1$  – вибір мови програмування.

$F_2$  – вибір фреймворку машинного навчання.

$F_3$  – вибір середовища розробки.

Кожна з цих функцій має декілька варіантів реалізації:

Функція  $F_1$ :

а) Python.

б) C++.

Функція  $F_2$ :

а) TensorFlow.

б) Dlib.

Функція  $F_3$ :

a) Visual Studio Code.

б) PyCharm.

Варіанти реалізації основних функцій наведені у морфологічній карті системи (рис. 4.1).

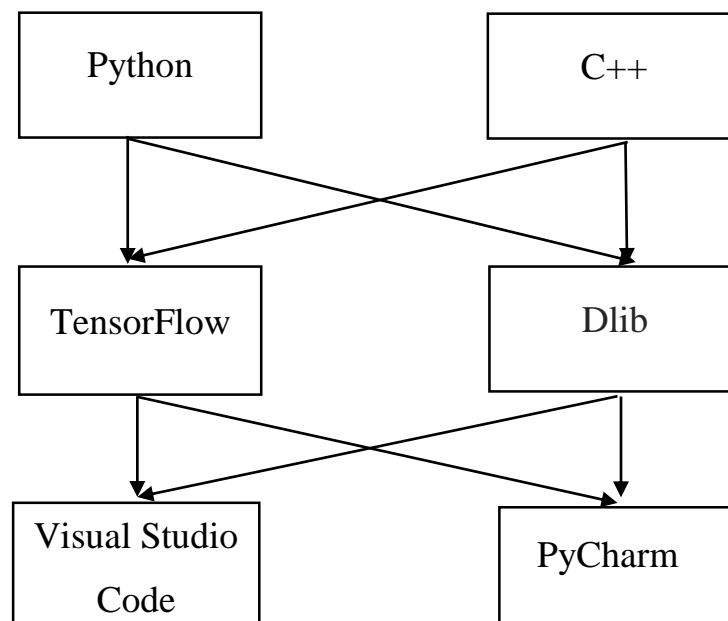


Рисунок 4.1 – Морфологічна карта

Морфологічна карта відображає множину всіх можливих варіантів основних функцій. Позитивно-негативна матриця показана в таблиці 4.1.

Таблиця 4.1. – Позитивно-негативна матриця

Функції	Варіанти реалізації	Переваги	Недоліки
$F_1$	$A$	Зручність, багатофункціональність, широкий вибір бібліотек	Швидкодія, обмежена підтримка апаратного прискорення

	<i>B</i>	Висока швидкодія, доступ до оптимізаційних можливостей процесора,	Складність, менша кількість бібліотек, вимога до вміння ручного керування пам'яттю
$F_2$	<i>A</i>	Широкий вибір моделей, розширені можливості управління пам'яттю	Складніший синтаксис, більша кількість коду для досягнення тих самих результатів.
	<i>B</i>	Простий синтаксис, динамічні графи, легкість у розробці та налагодженні моделей, підтримка більшої кількості додаткових модулів	Менша швидкодія порівняно з TensorFlow на деяких завданнях
$F_3$	<i>A</i>	Інтерактивність, можливість візуалізації даних та результатів, зручність	Потребує багато ресурсів, обмежена підтримка великих обсягів даних,
	<i>B</i>	Підтримка автодоповнення, інструменти для оптимізації, робота з великими проектами	Висока ціна платної версії, проблеми з налаштуванням деяких бібліотек

На основі аналізу позитивно-негативної матриці робимо висновок, що при розробці програмного продукту деякі варіанти реалізації функцій варто

відкинути, тому, що вони не відповідають поставленим перед програмним продуктом задачам. Ці варіанти відзначені у морфологічній карті.

Функція  $F_1$ :

Перевагу даємо зручності, багатофункціональності, широкому вибору бібліотек. Для спрощення роботи по написанню коду варіант Б має бути відкинтий.

Функція  $F_2$ :

Програма допускає обрання обох варіантів. Можливо використати варіанти А чи Б.

Функція  $F_3$ :

Реалізація першого варіанту є сприйнятливою для програми. Це варіант А.

Таким чином, будемо розглядати такі варіанти реалізації ПП:

$$F_1a - F_2a - F_3a$$

$$F_1a - F_2б - F_3a$$

Для оцінювання якості розглянутих функцій обрана система параметрів, описана нижче.

### 4.3 Обґрунтування системи параметрів програмного продукту

На основі даних, розглянутих вище, визначаються основні параметри вибору, які будуть використані для розрахунку коефіцієнта технічного рівня.

Для того, щоб охарактеризувати програмний продукт, будемо використовувати наступні параметри:

- X1 – швидкодія мови програмування;
- X2 – об’єм пам’яті для обчислень та збереження даних;
- X3 – час навчання даних;
- X4 – потенційний об’єм програмного коду.

Гірші, середні і кращі значення параметрів вибираються на основі вимог замовника й умов, що характеризують експлуатацію програмного продукту, як показано у таблиці 4.2.

Таблиця 4.2 – Основні параметри програмного продукту

Назва Параметра	Умовні позначе ння	Одиниці виміру	Значення параметра		
			гірші	середні	кращі
Швидкодія мови програмування	X1	оп/мс	6000	10000	14000
Об’єм пам’яті	X2	Мб	512	128	32
Час попередньої обробки даних	X3	мс	6	4	2
Потенційний об’єм програмного коду	X4	кількість рядків коду	500	400	300

За даними таблиці 4.3 будуються графічні характеристики параметрів – рис. 4.2 – рис. 4.5.




Рисунок 4.2 – X1, швидкодія мови програмування




Рисунок 4.3 – X2, об'єм пам'яті




Рисунок 4.4 – X3, час попередньої обробки даних




Рисунок 4.5 – X4, потенційний об'єм програмного коду

#### 4.4 Аналіз експертного оцінювання параметрів

Після детального обговорення й аналізу кожний експерт оцінює ступінь важливості кожного параметру для конкретно поставленої цілі – розробка програмного продукту, який дає найбільш точні результати при знаходженні параметрів моделей адаптивного прогнозування і обчислення прогнозних значень.

Значимість кожного параметра визначається методом попарного порівняння. Оцінку проводить експертна комісія із 7 людей. Визначення коефіцієнтів значимості передбачає:

- визначення рівня значимості параметра шляхом присвоєння різних рангів;
- перевірку придатності експертних оцінок для подальшого використання;
- визначення оцінки попарного пріоритету параметрів;
- обробку результатів та визначення коефіцієнту значимості.

Результати експертного ранжування наведені у таблиці 4.3.

Таблиця 4.3 – Результати ранжування параметрів

Позначення параметра	Назва параметра	Одиниці виміру	Ранг параметра за оцінкою експерта							Сума рангів $R_i$	Відхилення $\Delta_i$	$\Delta_i^2$
			1	2	3	4	5	6	7			
X1	Швидкодія мови програмування	Оп/мс	2	4	4	4	2	2	3	21	-6,25	39,0625

X2	Об'єм пам'яті	Мб	6	5	5	4	8	4	7	39	12,75	162,5625
X3	Час попередньої обробки даних	мс	3	3	3	3	1	4	2	19	-7,25	52,5625
X4	Потенційний об'єм програмного коду	Кількість рядків коду	4	3	3	4	4	5	3	26	0,25	0,0625
	Разом		15	15	15	15	15	15	15	105	0,5	254,25

Для перевірки степені достовірності експертних оцінок, визначимо наступні параметри:

а) сума рангів кожного з параметрів і загальна сума рангів:

$$R_i = \sum_{j=1}^N r_{ij} R_{ij} = \frac{Nn(n+1)}{2} = 105, \quad (4.1)$$

де  $N$  – число експертів,

$n$  – кількість параметрів;

б) середня сума рангів:

$$T = \frac{1}{n} R_{ij} = 26,25 \quad (4.2)$$

в) відхилення суми рангів кожного параметра від середньої суми рангів:

$$\Delta_i = R_i - T. \quad (4.3)$$

Сума відхилень по всіх параметрах повинна дорівнювати 0;

г) загальна сума квадратів відхилення:

$$S = \sum_{i=1}^N \Delta_i^2 = 254,25. \quad (4.4)$$

Порахуємо коефіцієнт узгодженості:

$$W = \frac{12S}{N^2(n^3 - n)} = \frac{12 \cdot 254,25}{7^2(4^3 - 4)} = 1,038 > W_k = 0,67. \quad (4.5)$$

Ранжування можна вважати достовірним, тому що знайдений коефіцієнт узгодженості перевищує нормативний, котрий дорівнює 0,67.

Скориставшись результатами ранжирування, проведемо попарне порівняння всіх параметрів і результати занесемо у таблицю 4.4.

Таблиця 4.4 – Попарне порівняння параметрів.

Параметри	Експерти							Кінцева оцінка	Числове значення
	1	2	3	4	5	6	7		
X1 і X2	<	<	>	=	<	<	<	<	0,5
X1 і X3	<	>	>	>	>	<	>	>	1,5
X1 і X4	<	>	>	=	<	<	=	<	0,5
X2 і X3	>	>	>	>	>	=	>	>	1,5
X2 і X4	>	>	=	=	>	<	>	>	1,5
X3 і X4	<	=	<	<	<	<	<	<	0,5

Числове значення, що визначає ступінь переваги  $i$ -го параметра над  $j$ -тим,  $a_{ij}$  визначається по формулі:

$$a_{ij} = \begin{cases} 1.5 & \text{при } X_i > X_j \\ 1.0 & \text{при } X_i = X_j \\ 0.5 & \text{при } X_i < X_j \end{cases} \quad (4.6)$$

З отриманих числових оцінок переваги складемо матрицю  $A = \| a_{ij} \|$ .

Для кожного параметра зробимо розрахунок вагомості  $K_{\text{вi}}$  за наступними формулами:

$$K_{\text{вi}} = \frac{b_i}{\sum_{i=1}^n b_i} \quad (4.7)$$

$$b_i = \sum_{i=1}^N a_{ij} \quad (4.8)$$

Відносні оцінки розраховуються декілька разів доти, поки наступні значення не будуть незначно відрізнятися від попередніх (менше 2%). На другому і наступних кроках відносні оцінки розраховуються за наступними формулами:

$$K_{\text{вi}} = \frac{b'_i}{\sum_{i=1}^n b'_i}, \quad (4.9)$$

$$b'_i = \sum_{i=1}^N a_{ij} b_j \quad (4.10)$$

Як видно з таблиці 4.5, різниця значень коефіцієнтів вагомості не перевищує 2%, тому більшої кількості ітерацій не потрібно.

Таблиця 4.5 - Розрахунок вагомості параметрів

Параметри $x_i$	Параметри $x_j$	Перша ітер.	Друга ітер.	Третя ітер.
-----------------	-----------------	-------------	-------------	-------------

	X1	X2	X3	X4	$b_i$	$K_{Bi}$	$b_i^1$	$K_{Bi}^1$	$b_i^2$	$K_{Bi}^2$
X1	1,0	0,5	1,5	0,5	3,5	0,21	12,25	0,21	44,875	0,21
X2	1,5	1,0	1,5	1,5	5,5	0,36	21,25	0,35	77,825	0,36
X3	0,5	0,5	1,0	0,5	2,5	0,15	9,25	0,16	34,125	0,15
X4	1,5	0,5	1,5	1,0	4,5	0,28	16,25	0,28	59,125	0,28
Всього:					16	1	59	1	216	1

#### 4.5 Аналіз рівня якості варіантів реалізації функцій

Визначаємо рівень якості кожного варіанту виконання основних функцій окремо.

Абсолютні значення параметрів  $X2$  (Об'єм пам'яті),  $X3$  (час попередньої обробки даних) та  $X4$  (потенційний об'єм програмного коду) відповідають технічним вимогам умов функціонування даного ПП.

Абсолютне значення параметра  $X1$  (швидкість роботи мови програмування) обрано не найгіршим.

Коефіцієнт технічного рівня для кожного варіанта реалізації ПП розраховується так (таблиця 4.6):

$$K_K(j) = \sum_{i=1}^n K_{ei,j} B_{i,j}, \quad (4.11)$$

де  $n$  – кількість параметрів;

$K_{ei}$  – коефіцієнт вагомості  $i$ -го параметра;

$B_i$  – оцінка  $i$ -го параметра в балах.

Таблиця 4.6 - Розрахунок показників рівня якості варіантів реалізації основних функцій ПП

Основні функції	Варіант реалізації функції	Параметри	Абсолютне значення параметра	Бальна оцінка параметра	Коефіцієнт вагомості параметра	Коефіцієнт рівня якості
F1	A	X1	6000	16	0,21	3,36
F2	A	X2	32	14	0,36	5,04
	Б	X3	128	8	0,15	1,2
F3	A	X4	300	10	0,28	2,8

За даними з таблиці 4.6 за формулою:

$$K_K = K_{TY}[F_{1k}] + K_{TY}[F_{2k}] + \dots + K_{TY}[F_{zk}], \quad (4.12)$$

визначаємо рівень якості кожного з варіантів:

$$K_{K1} = 3,36 + 5,04 + 2,8 = 11,2 ;$$

$$K_{K2} = 3,36 + 1,2 + 2,8 = 7,36 .$$

Як видно з розрахунків, кращим є 1 варіант, для якого коефіцієнт технічного рівня має найбільше значення.

#### 4.6 Економічний аналіз варіантів розробки ПП

Для визначення вартості розробки ПП спочатку проведемо розрахунок трудомісткості.

Всі варіанти включають в себе два окремих завдання:

1. Розробка проекту програмного продукту;

## 2. Розробка програмної оболонки;

Завдання 1 за ступенем новизни відноситься до групи А, завдання 2 – до групи Б. За складністю алгоритми, які використовуються в завданні 1 належать до групи 1; а в завданні 2 – до групи 3.

Для реалізації завдання 1 використовується довідкова інформація, а завдання 2 використовує інформацію у вигляді даних.

Проведемо розрахунок норм часу на розробку та програмування для кожного з завдань.

Загальна трудомісткість обчислюється як:

$$T_0 = T_P \cdot K_{\Pi} \cdot K_{СК} \cdot K_M \cdot K_{СТ} \cdot K_{СТ.М}, \quad (4.13)$$

де  $T_P$  – трудомісткість розробки ПП;

$K_{\Pi}$  – поправочний коефіцієнт;

$K_{СК}$  – коефіцієнт на складність вхідної інформації;

$K_M$  – коефіцієнт рівня мови програмування;

$K_{СТ}$  – коефіцієнт використання стандартних модулів і прикладних програм;

$K_{СТ.М}$  – коефіцієнт стандартного математичного забезпечення

Для першого завдання, виходячи із норм часу для завдань розрахункового характеру степеню новизни А та групи складності алгоритму 1, трудомісткість дорівнює:  $T_P = 35$  людино-днів. Поправочний коефіцієнт, який враховує вид нормативно-довідкової інформації для першого завдання:  $K_{\Pi} = 1.5$ . Поправочний коефіцієнт, який враховує складність контролю вхідної та вихідної інформації для всіх семи завдань рівний 1:  $K_{СК} = 1$ . Оскільки при розробці першого завдання використовуються стандартні модулі, врахуємо це за допомогою коефіцієнта  $K_{СТ} = 0.9$ . Тоді загальна трудомісткість програмування першого завдання дорівнює:

$$T_1 = 35 \cdot 1.5 \cdot 0.9 = 47,25 \text{ людино-днів.}$$

Проведемо аналогічні розрахунки для подальших завдань.

Для другого завдання (використовується алгоритм третьої групи складності, степінь новизни Б), тобто  $T_p = 28$  людино-днів,  $K_{II} = 1.4$ ,  $K_{СК} = 1$ ,  $K_{СТ} = 0.9$ :

$$T_2 = 28 \cdot 1.4 \cdot 0.9 = 35,28 \text{ людино-днів.}$$

Складаємо трудомісткість відповідних завдань для кожного з обраних варіантів реалізації програми, щоб отримати їх трудомісткість:

$$T_I = (47,25 + 35,28 + 6.2 + 35,28) \cdot 8 = 992,08 \text{ людино-годин.}$$

$$T_{II} = (47,25 + 35,28 + 8.45 + 35,28) \cdot 8 = 1010,08 \text{ людино-годин.}$$

Найбільш високу трудомісткість має варіант II.

В розробці беруть участь два програмісти з окладом 27687 грн., один аналітик в області даних з окладом 36917. Визначимо середню зарплату за годину за формулою:

$$C_{ч} = \frac{M}{T_m \cdot t} \text{ грн.,} \quad (4.14)$$

де  $M$  – місячний оклад працівників;

$T_m$  – кількість робочих днів тиждень;

$t$  – кількість робочих годин в день.

$$C_{\text{ч}} = \frac{27687 + 27687 + 36917}{3 \cdot 21 \cdot 8} = 183,12 \text{ грн.} \quad (4.15)$$

Тоді, розрахуємо заробітну плату за формулою:

$$C_{\text{зп}} = C_{\text{ч}} \cdot T_i \cdot K_{\text{д}}, \quad (4.16)$$

де  $C_{\text{ч}}$  – величина погодинної оплати праці програміста;

$T_i$  – трудомісткість відповідного завдання;

$K_{\text{д}}$  – норматив, який враховує додаткову заробітну плату.

Зарплата розробників за варіантами становить:

$$\text{I. } C_{\text{зп}} = 183,12 \cdot 992,08 \cdot 1,2 = 218003,63 \text{ грн.}$$

$$\text{II. } C_{\text{зп}} = 183,12 \cdot 1010,08 \cdot 1,2 = 221959,02 \text{ грн.}$$

Відрахування на єдиний соціальний внесок становить 22%:

$$\text{I. } C_{\text{від}} = C_{\text{зп}} \cdot 0,22 = 218003,63 \cdot 0,22 = 47960,79 \text{ грн.}$$

$$\text{II. } C_{\text{від}} = C_{\text{зп}} \cdot 0,22 = 221959,02 \cdot 0,22 = 48830,98 \text{ грн.}$$

Тепер визначимо витрати на оплату однієї машино-години. ( $C_{\text{м}}$ )

Так як одна ЕОМ обслуговує одного програміста з окладом 25000 грн., з коефіцієнтом зайнятості 0,2 то для однієї машини отримаємо:

$$C_{\text{г}} = 12 \cdot M \cdot K_3 = 12 \cdot 25000 \cdot 0,2 = 60000 \text{ грн.}$$

З урахуванням додаткової заробітної плати:

$$C_{\text{зп}} = C_{\text{г}} \cdot (1 + K_3) = 60000 \cdot (1 + 0,2) = 72000 \text{ грн.}$$

Відрахування на соціальний внесок:

$$C_{\text{ВІД}} = C_{\text{ЗП}} \cdot 0.22 = 72000 \cdot 0.22 = 15840 \text{ грн.}$$

Амортизаційні відрахування розраховуємо при амортизації 25% та вартості ЕОМ – 20000 грн.

$$C_A = K_{\text{ТМ}} \cdot K_A \cdot Ц_{\text{ПР}} = 1.2 \cdot 0.25 \cdot 20000 = 6000 \text{ грн.},$$

де  $K_{\text{ТМ}}$  – коефіцієнт, який враховує витрати на транспортування та монтаж приладу у користувача;

$K_A$  – річна норма амортизації;

$Ц_{\text{ПР}}$  – договірна ціна приладу.

Витрати на ремонт та профілактику розраховуємо як:

$$C_P = K_{\text{ТМ}} \cdot Ц_{\text{ПР}} \cdot K_P = 1.2 \cdot 20000 \cdot 0.03 = 720 \text{ грн.},$$

де  $K_P$  – відсоток витрат на поточні ремонти.

Ефективний годинний фонд часу ПК за рік розраховуємо за формулою:

$$\begin{aligned} T_{\text{ЕФ}} &= (D_K - D_B - D_C - D_P) \cdot t_3 \cdot K_B = (365 - 104 - 12 - 10) \cdot 8 \cdot 0.9 = \\ &= 1720,8 \text{ годин,} \end{aligned}$$

де  $D_K$  – календарна кількість днів у році;

$D_B, D_C$  – відповідно кількість вихідних та святкових днів;

$D_p$  – кількість днів планових ремонтів устаткування;

$t$  – кількість робочих годин в день;

$K_B$  – коефіцієнт використання приладу у часі протягом зміни.

Витрати на оплату електроенергії розраховуємо за формулою:

$$C_{\text{ЕЛ}} = T_{\text{ЕФ}} \cdot N_C \cdot K_3 \cdot C_{\text{ЕН}} = 1720,8 \cdot 0,3 \cdot 0,9 \cdot 4,8 = 2230,16 \text{ грн.},$$

де  $N_C$  – середньо-споживча потужність приладу;

$K_3$  – коефіцієнтом зайнятості приладу;

$C_{\text{ЕН}}$  – тариф за 1 кВт-годин електроенергії.

Накладні витрати розраховуємо за формулою:

$$C_H = C_{\text{ПР}} \cdot 0,67 = 20000 \cdot 0,67 = 13400 \text{ грн.}$$

Тоді, річні експлуатаційні витрати будуть:

$$C_{\text{ЕКС}} = C_{\text{ЗП}} + C_{\text{ВІД}} + C_A + C_P + C_{\text{ЕЛ}} + C_H, \quad (4.17)$$

$$C_{\text{ЕКС}} = 72000 + 15840 + 6000 + 720 + 2230,16 + 13400 = 110190,16 \text{ грн.}$$

Собівартість однієї машино-години ЕОМ дорівнюватиме:

$$C_{\text{М-Г}} = C_{\text{ЕКС}} / T_{\text{ЕФ}} = 110190,16 / 1720,8 = 64,03 \text{ грн/год.}$$

Оскільки в даному випадку всі роботи, які пов'язані з розробкою програмного продукту ведуться на ЕОМ, витрати на оплату машинного часу, в залежності від обраного варіанта реалізації, складає:

$$C_M = C_{M-Г} \cdot T, \quad (4.18)$$

$$I. C_M = 64,03 \cdot 992,08 = 63522,88 \text{ грн.}$$

$$II. C_M = 64,03 \cdot 1010,08 = 64675,42 \text{ грн.}$$

Накладні витрати складають 67% від заробітної плати:

$$C_H = C_{ЗП} \cdot 0,67, \quad (4.19)$$

$$I. C_H = 218003,63 \cdot 0,67 = 146062,43 \text{ грн.}$$

$$II. C_H = 221959,02 \cdot 0,67 = 148712,54 \text{ грн.}$$

Отже, вартість розробки ПП за варіантами становить:

$$C_{ПП} = C_{ЗП} + C_{Від} + C_M + C_H, \quad (4.20)$$

$$I. C_{ПП} = 218003,63 + 47960,79 + 63522,88 + 146062,43 = 475549,73 \text{ грн.}$$

$$II. C_{ПП} = 221959,02 + 48830,98 + 64675,42 + 148712,54 = 484177,96 \text{ грн.}$$

#### 4.7 Вибір кращого варіанту ІІІ техніко-економічного рівня

Розрахуємо коефіцієнт техніко-економічного рівня за формулою:

$$K_{\text{TEP}j} = K_{\text{K}j} / C_{\text{Ф}j}, \quad (4.21)$$

$$K_{\text{TEP}1} = 11,2 / 475549,73 = 2,3552 \cdot 10^{-5},$$

$$K_{\text{TEP}2} = 7,36 / 484177,96 = 1,5201 \cdot 10^{-5}.$$

Як бачимо, найбільш ефективним є перший варіант реалізації програми з коефіцієнтом техніко-економічного рівня  $K_{\text{TEP}1} = 2,3552 \cdot 10^{-5}$ .

Після виконання функціонально-вартісного аналізу програмного комплексу що розроблюється, можна зробити висновок, що з альтернатив, що залишилися після першого відбору двох варіантів виконання програмного комплексу оптимальним є перший варіант реалізації програмного продукту. У нього виявився найкращий показник техніко-економічного рівня якості  $K_{\text{TEP}} = 2,3552 \cdot 10^{-5}$ .

Цей варіант реалізації програмного продукту має такі параметри:

- Мова програмування – Python;
- Широкий вибір моделей, розширені можливості управління пам'яттю
- Інтерактивність, можливість візуалізації даних та результатів, зручність

Даний варіант виконання програмного комплексу дає користувачу зручний інтерфейс, швидку та зручну реалізацію програми, доступний функціонал для роботи.

#### **4.8 Висновки до четвертого розділу**

В даній частині було проведено повний функціонально-вартісний аналіз програмного продукту. Також було знайдено оцінку основних функцій програмного продукту.

В результаті виконання функціонально-вартісного аналізу програмного комплексу що розроблюється, було визначено та проведено оцінку основних функцій програмного продукту, а також знайдено параметри, які його характеризують.

На основі аналізу вибрано варіант реалізації програмного продукту.

## ПЕРЕЛІК ПОСИЛАНЬ

1. Our World in Data. Causes of death. [Електронний ресурс] – Режим доступу до ресурсу: <https://ourworldindata.org/causes-of-death>
2. SAS Blogs. Graphing cardiovascular disease mortality data. [Електронний ресурс] – Режим доступу до ресурсу: <https://blogs.sas.com/content/graphicallspeaking/2019/02/19/graphing-cardiovascular-disease-mortality-data/>
3. Центр громадського здоров'я. МОЗ України. [Електронний ресурс] – Режим доступу до ресурсу: <https://phc.org.ua/news/sercevo-sudinni-zakhvoryuvannya-golovna-prichina-smerti-ukrainciv-visnovki-z-doslidzhennya>
4. World Health Organization. Cardiovascular diseases: Avoiding heart attacks and strokes. [Електронний ресурс] – Режим доступу до ресурсу: <https://www.who.int/news-room/questions-and-answers/item/cardiovascular-diseases-avoiding-heart-attacks-and-strokes>
5. National Library of Medicine. Trends over 5 decades in U.S. occupation-related physical activity and their associations with obesity. [Електронний ресурс] – Режим доступу до ресурсу: <https://pubmed.ncbi.nlm.nih.gov/21647427/>
6. National Institutes of Health. How dietary factors influence disease risk. [Електронний ресурс] – Режим доступу до ресурсу: <https://www.nih.gov/news-events/nih-research-matters/how-dietary-factors-influence-disease-risk>
7. Wikipedia. Tobacco use. [Електронний ресурс] – Режим доступу до ресурсу: [https://en.wikipedia.org/wiki/Prevalence\\_of\\_tobacco\\_use](https://en.wikipedia.org/wiki/Prevalence_of_tobacco_use)
8. Centers for Disease Control and Prevention. Know Your Risk for Stroke. [Електронний ресурс] – Режим доступу до ресурсу: [https://www.cdc.gov/stroke/risk\\_factors.htm](https://www.cdc.gov/stroke/risk_factors.htm)

9. Binah.AI. About us. [Электронный ресурс] – Режим доступа до ресурсу: <https://www.binah.ai/company/>
10. ResearchGate. Estimation of Continuous Blood Pressure from PPG via a Federated Learning Approach. [Электронный ресурс] – Режим доступа до ресурсу:  
[https://www.researchgate.net/publication/349583500\\_Estimation\\_of\\_Continuous\\_Blood\\_Pressure\\_from\\_PPG\\_via\\_a\\_Federated\\_Learning\\_Approach](https://www.researchgate.net/publication/349583500_Estimation_of_Continuous_Blood_Pressure_from_PPG_via_a_Federated_Learning_Approach)
11. PhysiologyWeb. Physiology Graph. Measurement of hydrostatic blood pressure. [Электронный ресурс] – Режим доступа до ресурсу:  
[https://www.physiologyweb.com/figures/physiology\\_graph\\_kOmgHIRVcRNo0zfrBCKzz1dZcNyZkjeC\\_measurement\\_of\\_hydrostatic\\_blood\\_pressure.html](https://www.physiologyweb.com/figures/physiology_graph_kOmgHIRVcRNo0zfrBCKzz1dZcNyZkjeC_measurement_of_hydrostatic_blood_pressure.html)
12. Wikipedia. Korotkoff sounds. [Электронный ресурс] – Режим доступа до ресурсу: [https://en.wikipedia.org/wiki/Korotkoff\\_sounds](https://en.wikipedia.org/wiki/Korotkoff_sounds)
13. Connor Shorten. Introduction to ResNets. [Электронный ресурс] – Режим доступа до ресурсу: <https://towardsdatascience.com/introduction-to-resnets-c0a830a288a4>
14. P. Viola and M. J. Jones, “Rapid Object Detection using a Boosted Cascade of Simple Features”. [Электронный ресурс] – Режим доступа до ресурсу: <https://www.cs.cmu.edu/~efros/courses/LBMV07/Papers/viola-cvpr-01.pdf>
15. OpenCV. Cascade Classifier. [Электронный ресурс] – Режим доступа до ресурсу:  
[https://docs.opencv.org/3.4/db/d28/tutorial\\_cascade\\_classifier.html](https://docs.opencv.org/3.4/db/d28/tutorial_cascade_classifier.html)
16. PhysioNet. MIMIC-III Clinical Database. [Электронный ресурс] – Режим доступа до ресурсу: <https://physionet.org/content/mimiciii/1.4/>
17. Jia Chen, Zhiqiang He, Dayong Zhu, Bei Hui. Mu-Net: Multi-Path Upsampling Convolution Network for Medical Image Segmentation. Computer Modeling in Engineering and Sciences. January 2022.

18. ДНУ «НПЦ ПКМ» ДУС. АРТЕРІАЛЬНИЙ ТИСК І АРТЕРІАЛЬНА ГІПЕРТЕНЗІЯ. [Електронний ресурс] – Режим доступу до ресурсу: <https://clinic.gov.ua/?p=5798>

19. YouTube. Bloomberg Television. Trump & Clinton Debate Night. [Електронний ресурс] – Режим доступу до ресурсу: <https://www.youtube.com/watch?v=UaVWRetR4jg>