

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
ДЕРЖАВНИЙ УНІВЕРСИТЕТ «КИЇВСЬКИЙ АВІАЦІЙНИЙ ІНСТИТУТ»

ДОПУСТИТИ ДО ЗАХИСТУ  
Завідувачка кафедри

\_\_\_\_\_ Олена НЕЧИПОРУК  
“ \_\_\_\_\_ ” \_\_\_\_\_ 2025 р.

# КВАЛІФІКАЦІЙНА РОБОТА

(ПОЯСНЮВАЛЬНА ЗАПИСКА)

ЗДОБУВАЧА ОСВІТНЬОГО СТУПЕНЯ «МАГІСТР»

Тема: Інтелектуальна LSTM-система для діагностики серця з використанням даних із переносних пристроїв

Виконавець: \_\_\_\_\_ Сергій ГРИНЮК

Керівник: \_\_\_\_\_ Ольга СУПРУН

Нормоконтролер: \_\_\_\_\_ Євгеній ТУПОТА

Київ 2025

«ДЕРЖАВНИЙ УНІВЕРСИТЕТ «КИЇВСЬКИЙ АВІАЦІЙНИЙ ІНСТИТУТ»

Факультет комп'ютерних наук та технологій

Кафедра інтелектуальних кібернетичних систем

Спеціальність 126 «Інформаційні системи та технології»

(шифр, найменування)

Освітньо професійна програма «Інтелектуальні системи та технології»

Форма навчання денна

ЗАТВЕРДЖУЮ

Завідувачка кафедри

Олена НЕЧИПОРУК

“ ” 2025 р.

## ЗАВДАННЯ

на виконання кваліфікаційної роботи

Гринюка Сергія Олександровича

(прізвище, ім'я, по батькові випускника в родовому відмінку)

**1. Тема кваліфікаційної роботи:** «Інтелектуальна LSTM-система для діагностики серця з використанням даних із переносних пристроїв» затверджена наказом ректора від «29» вересня 2025р. №1575/ст.

**2. Термін виконання роботи:** з 29.09.2025 по 31.12.2025

**3. Вихідні дані до роботи (проєкту):** база даних ЕКГ-сигналів, документація з обробки електрокардіографічних сигналів, програмні бібліотеки для глибинного навчання, дані з переносних пристроїв.

**4. Зміст пояснювальної записки:** аналіз методів діагностики серцево-судинних захворювань, розробка LSTM-моделі для класифікації патологій серця, представлення методів обробки даних, аналіз результатів класифікації.

**5. Перелік обов'язкового графічного (ілюстративного) матеріалу:**

1. Архітектура гібридної нейронної мережі;

2. Схема алгоритму попередньої обробки ЕКГ даних;

3. Структура інтелектуальної системи діагностики ЕКГ;

4. ЕКГ-сигнали різних класів патологій.

## 6. Календарний план–графік

№ пор.	Завдання	Термін виконання	Відмітка про виконання
1	Аналіз та дослідження предметної області. Огляд методів діагностики серцево-судинних захворювань та аналіз доступних баз даних ЕКГ-сигналів	29.09.2025-10.10.2025	
2	Розроблення змісту розділів кваліфікаційної роботи. Написання вступу	11.10.2025-17.10.2025	
3	Дослідження архітектур нейронних мереж для аналізу ЕКГ. Написання 1-2 розділів кваліфікаційної роботи	18.10.2025-08.11.2025	
4	Розроблення архітектури LSTM-моделі. Попередня обробка ЕКГ-сигналів та підготовка датасету	09.11.2025-20.11.2025	
5	Навчання LSTM-моделі, тестування та оцінка якості класифікації. Аналіз результатів	21.11.2025-02.12.2025	
6	Написання 3-4 розділу пояснювальної записки. Розроблення інтерфейсу системи діагностики	03.12.2025-12.12.2025	
7	Оформлення пояснювальної записки кваліфікаційної роботи	13.12.2025-17.12.2025	
8	Підготовка презентації та доповіді для захисту	17.12.2025-25.12.2025	
9	Захист кваліфікаційної роботи	26.12.2025	

## 7. Дата видачі завдання: «29» вересня 2025р

Керівник кваліфікаційної роботи

\_\_\_\_\_

(підпис керівника)

Ольга СУПРУН

(П.І.Б.)

Завдання прийняв до виконання

\_\_\_\_\_

(підпис випускника)

Сергій ГРИНЮК

(П.І.Б.)

## РЕФЕРАТ

Кваліфікаційна робота «Інтелектуальна *LSTM*-система для діагностики серця з використанням даних із переносних пристроїв» містить 83 сторінок, 30 рисунків, 1 таблицю, 24 використаних джерел.

**Об'єкт дослідження:** методи діагностики серцево-судинних захворювань на основі аналізу електрокардіографічних сигналів з переносних пристроїв із застосуванням технологій штучного інтелекту.

**Предмет дослідження:** інтелектуальна система класифікації серцево-судинних захворювань на основі *LSTM*-нейронних мереж з використанням даних електрокардіограм.

**Мета кваліфікаційної роботи:** розроблення та впровадження інтелектуальної системи діагностики серцево-судинних захворювань на основі *LSTM*-нейронній мережі для автоматизованого аналізу ЕКГ-сигналів з переносних пристроїв з метою раннього виявлення патологій серця та підвищення точності діагностики.

**Метод дослідження:** аналіз існуючих підходів до класифікації серцево-судинних захворювань, розроблення архітектури *LSTM*-моделі, попередня обробка ЕКГ-сигналів, навчання нейронної мережі на реальних медичних даних та валідація результатів.

**Результат проєкту:** інтелектуальна програмна система з *LSTM*-архітектурою для автоматизованої класифікації серцево-судинних захворювань за даними ЕКГ, що забезпечує високу точність діагностики, можливість інтеграції з переносними медичними пристроями та пояснюваність прийнятих рішень.

*LSTM*, ДІАГНОСТИКА СЕРЦЯ, ЕЛЕКТРОКАРДІОГРАМА, НЕЙРОННА МЕРЕЖА, ПОЯСНЮВАНИЙ ШТУЧНИЙ ІНТЕЛЕКТ, АРИТМІЯ, ГЛИБОКЕ НАВЧАННЯ

## ЗМІСТ

ЗМІСТ .....	4
ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СКОРОЧЕНЬ, ТЕРМІНІВ .....	7
ВСТУП.....	8
РОЗДІЛ 1 ТЕОРЕТИЧНІ ОСНОВИ ТА СУЧАСНІ ТЕНДЕНЦІЇ У СТВОРЕННІ ІННОВАЦІЙНИХ СИСТЕМ ДІАГНОСТИКИ СЕРЦЕВИХ ЗАХВОРЮВАНЬ.....	9
1.1. Актуальність проблеми діагностики серцево-судинних захворювань .....	9
1.2. Огляд існуючих систем діагностики серцевих захворювань.....	11
1.3. Можливості та обмеження використання штучного інтелекту в медицині.....	15
1.4. Рекурентні нейронні мережі та архітектура <i>LSTM</i> для аналізу медицих даних.....	17
1.5. Інтеграція даних з переносних пристроїв у системі діагностики .....	19
1.6. Тенденції розвитку інноваційних медичних систем .....	20
1.7. Висновки до розділу .....	21
РОЗДІЛ 2 ПРОЄКТУВАННЯ ІНТЕЛЕКТУАЛЬНОЇ <i>LSTM</i> -СИСТЕМИ ДІАГНОСТИКИ СЕРЦЯ.....	23
2.1. Постановка завдання та вимоги до системи .....	23
2.2. Вибір архітектури нейронної мережі для аналізу ЕКГ сигналів .....	24
2.3. Формування вхідних даних та методика попередньої обробки .....	29
2.4. Структура розробленої системи .....	34
2.5. Планування процесу навчання та налаштування гіперпараметрів.....	38
2.6. Висновки до розділу .....	39
РОЗДІЛ 3 РОЗРОБЛЕННЯ ТА РЕАЛІЗАЦІЯ <i>LSTM</i> -МОДЕЛІ ДІАГНОСТИКИ СЕРЦЕВИХ АНОМАЛІЙ .....	42
3.1. Реалізація модуля попередньої обробки ЕКГ-даних.....	42
3.2. Розроблення та навчання <i>LSTM</i> -моделі .....	44
3.6. Висновки до розділу .....	57

РОЗДІЛ 4 АНАЛІЗ РЕЗУЛЬТАТІВ ТА ПЕРСПЕКТИВИ ВПРОВАДЖЕННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ .....	59
4.1. Оцінювання точності та надійності роботи моделі .....	59
4.2. Оцінювання аналізу моделі та матриці помилок .....	62
4.3. Візуальний аналіз роботи моделі та ХАІ-механізму .....	64
4.4. Можливості майбутнього впровадження у додатки та переносні пристрої .....	68
4.5. Перспективи подальшого розвитку та покращення системи .....	70
4.6. Висновки до розділу .....	72
ВИСНОВКИ .....	75
СПИСОК БІБЛІОГРАФІЧНИХ ПОСИЛАНЬ ВИКОРИСТАНИХ ДЖЕРЕЛ .....	81

## ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СКОРОЧЕНЬ, ТЕРМІНІВ

*AAMI (Association for the Advancement of Medical Instrumentation)* – Асоціація розвитку медичного обладнання;

*AI (Artificial Intelligence)* – Штучний інтелект;

*CNN (Convolutional Neural Network)* – Згорткова нейронна мережа;

*DL (Deep Learning)* – Глибинне навчання;

*HRV (Heart Rate Variability)* – Варіабельність серцевого ритму;

*JSON (JavaScript Object Notation)* – Текстовий формат обміну даними;

КТ – Комп'ютерна томографія;

*LSTM (Long Short-Term Memory)* – Довга короткочасна пам'ять;

*ML (Machine Learning)* – Машинне навчання;

МРТ – Магнітно-резонансна томографія;

*REST-API (Representational State Transfer Application Programming Interface)* – Програмний інтерфейс передачі репрезентативного стану;

*RNN (Recurrent Neural Network)* – Рекурентна нейронна мережа;

*WFDB (WaveForm DataBase)* – База даних форм сигналів;

*XAI (Explainable Artificial Intelligence)* – Пояснюваний штучний інтелект;

ШІ – Штучний інтелект;

ЕКГ – Електрокардіограма.

## ВСТУП

Серцево-судинні захворювання залишаються однією з головних причин смертності у світі, що зумовлює потребу у створенні ефективних методів їхньої ранньої діагностики та моніторингу. Сучасні технології штучного інтелекту, зокрема глибинне навчання, відкривають нові можливості для аналізу великих обсягів медичних даних та виявлення прихованих закономірностей, недоступних опрацюванню традиційними методами. Використання рекурентних нейронних мереж, зокрема архітектури *LSTM*, дає змогу ефективно працювати з часовими рядами, що робить їх особливо придатними для оброблення сигналів серцевої діяльності, зокрема ЕКГ.

Водночас поширення переносних пристроїв, а саме розумних годинників, фітнес-браслетів та спеціалізованих медичних сенсорів, сприяє формуванню нової парадигми у сфері охорони здоров'я. Такі пристрої дозволяють у режимі реального часу збирати дані про стан серцево-судинної системи користувачів, створюючи основу для персоналізованої діагностики та профілактики. Інтеграція даних із переносних пристроїв у програмні системи на базі штучного інтелекту дає змогу забезпечити безперервний моніторинг та своєчасне виявлення відхилень у роботі серця.

Однак створення інноваційної програмної системи діагностики серцевих захворювань потребує комплексного підходу. Необхідно не лише розробити ефективну модель на основі *LSTM* для аналізу часових рядів, але й забезпечити зручну взаємодію користувача з клієнтською частиною системи, яка відповідає за збір даних із переносних пристроїв. Також важливо приділити увагу оптимізації серверної частини, що обробляє великі обсяги даних і виконує обчислювально складні завдання з прогнозування та діагностики.

Таким чином, поєднання сучасних технологій глибинного навчання та даних з переносних пристроїв створює передумови для розроблення інноваційної системи діагностики серцевих захворювань. Така система здатна не лише підвищити точність і швидкість діагностики, а й зробити медичні послуги доступнішими.

## РОЗДІЛ 1

# ТЕОРЕТИЧНІ ОСНОВИ ТА СУЧАСНІ ТЕНДЕНЦІЇ У СТВОРЕННІ ІННОВАЦІЙНИХ СИСТЕМ ДІАГНОСТИКИ СЕРЦЕВИХ ЗАХВОРЮВАНЬ

### 1.1. Актуальність проблеми діагностики серцево-судинних захворювань

Серцево-судинні захворювання (ССЗ) є найбільш поширеною причиною смертності у світі, що становить близько третини усіх випадків смерті. За даними Всесвітньої організації охорони здоров'я, щорічно від хвороб серця та судин помирає понад 19,8 мільйона людей, що відповідає приблизно 32 % усіх летальних випадків у світі [3]. За прогнозами до 2050 року очікується зростання смертності на 73% (рис. 1.1). При цьому кількість осіб, які живуть із діагностованими серцево-судинними хворобами, перевищує 500 мільйонів, і ця цифра має стійку тенденцію до зростання через старіння населення, малорухливий спосіб життя та поширення шкідливих звичок. Найбільший тягар хвороб припадає на країни з низьким і середнім рівнем доходу, де доступ до якісної діагностики й лікування є обмеженим, що підкреслює соціальну нерівність у системах охорони здоров'я [4].




Рис. 1.1. Прогноз смертності від ССЗ від 2025 до 2050

<b>КАФЕДРА ІКС</b>				<b>КАІ 25 03 84 000 ПЗ</b>			
<b>Розробник.</b>	Грилюк С. О.			<i>Теоретичні основи та сучасні тенденції у створенні інноваційних систем діагностики серцевих захворювань</i>	<b>Літ.</b>		
<b>Керівник</b>	Супрун О. М.					9	83
<b>Консульт.</b>					<b>M-126-24-1-IT</b>		
<b>Н-контроль</b>	Тупота Є. В.						
<b>Зав. каф.</b>	Неципорок О. П.						

Рання діагностика відіграє вирішальну роль у зниженні смертності від ССЗ, оскільки дозволяє виявити хворобу на початкових стадіях і своєчасно розпочати профілактику або лікування. Виявлення факторів ризику, таких як артеріальна гіпертензія, атеросклероз, ожиріння, цукровий діабет чи аритмії, значно зменшує ймовірність розвитку ускладнень, включаючи інфаркт міокарда та інсульт. Наприклад, британські дослідження показують, що доступний скринінг серцевих ризиків може щороку запобігати сотням тисяч смертей завдяки простим тестам, які допомагають пацієнтам швидко виявити небезпечні відхилення у роботі серця (рис. 1.2) [5].

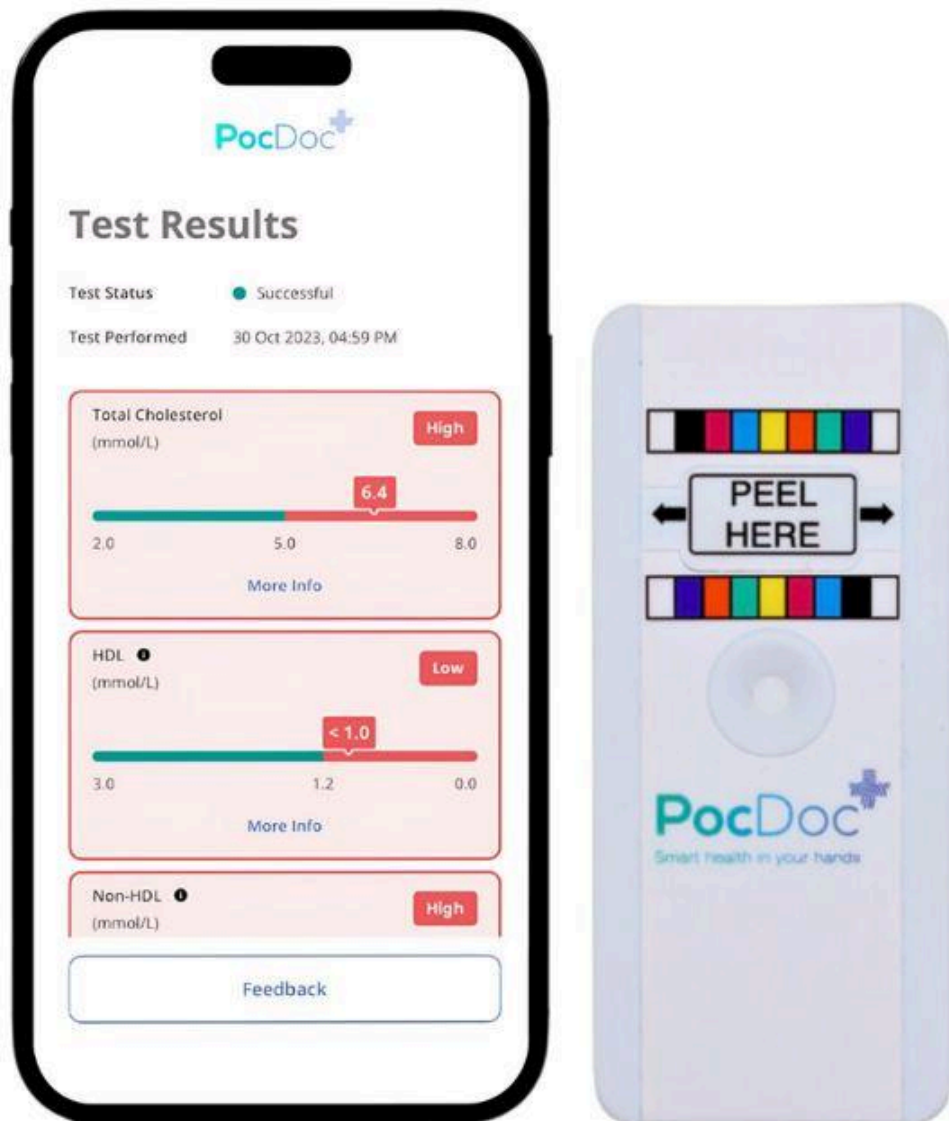


Рис. 1.2. PocDoc швидкий тест для перевірки роботи серця

Особливої уваги заслуговує роль сучасних цифрових технологій у медичній діагностиці. Поширення мобільних додатків, телемедичних платформ і систем дистанційного моніторингу суттєво розширює можливості лікарів і пацієнтів. Такі інструменти забезпечують безперервне відстеження фізіологічних показників (серцевого ритму, рівня кисню в крові, артеріального тиску), що робить можливим формування динамічного профілю стану здоров'я пацієнта. Використання цифрових рішень у менеджменті пацієнтів із коронарною хворобою серця довело свою ефективність: за результатами досліджень, рівень смертності серед пацієнтів, які користуються системами дистанційного спостереження, нижчий, ніж у групи стандартного лікування [6].

Крім того, інтеграція штучного інтелекту (ШІ) у цифрові рішення відкриває нові горизонти діагностики. Алгоритми глибокого навчання, зокрема на базі *LSTM*-мереж, здатні аналізувати електрокардіограми з точністю, що сягає 90 %, дозволяючи виявляти приховані патології, які часто залишаються поза увагою лікарів при візуальному аналізі. Подібні системи вже проходять клінічні випробування і поступово інтегруються у медичну практику, створюючи передумови для розвитку персоналізованої медицини.

Таким чином, висока поширеність і смертність від серцево-судинних захворювань, у поєднанні з доведеним ефектом ранньої діагностики та впровадженням цифрових технологій у медицину, підтверджують актуальність дослідження й розробки інноваційних програмних систем для діагностики ССЗ. Поєднання сучасних методів штучного інтелекту з даними, що надходять із переносних пристроїв, створює підґрунтя для персоналізованої профілактики та лікування, здатних суттєво знизити тягар цих захворювань на суспільство.

## **1.2. Огляд існуючих систем діагностики серцевих захворювань**

Традиційні методи діагностики серцево-судинних захворювань, зокрема електрокардіографія, ультразвукова діагностика та кардіомагнітно-резонансна томографія, залишаються базовими для клінічної практики. Однак такі підходи часто

залежать від доступу до спеціалізованого обладнання та кваліфікованого персоналу, що обмежує їхню доступність, особливо у віддалених регіонах. Крім того, дослідники зазначають, що близько третини інтерпретацій ЕКГ містять значні помилки, що підкреслює проблему суб'єктивного фактора та людського фактора в діагностиці ССЗ[7]. Сучасна клінічна практика потребує інтеграції доказових підходів із новими технологіями для підвищення якості обслуговування пацієнтів, однак використання лише традиційних методів обмежено в умовах високого навантаження на систему охорони здоров'я [8].

На фоні цих обмежень активно розвиваються програмні рішення на основі штучного інтелекту. Вони включають сучасні алгоритми машинного та глибинного навчання, які забезпечують високоточну оцінку ризику і можливість автоматичного розпізнавання патологій із медичних сигналів. Зокрема, дослідження демонструють, що *ML*-моделі (наприклад, із категоріями *Random Forest*, *SVM*, нейронні мережі) можуть значно перевершувати традиційні шкали оцінки ризику (*QRISK*, *Framingham*), враховуючи ширший набір даних і забезпечуючи більш точні прогнози для різних підгруп пацієнтів [9]. Крім того, аналіз ЕКГ за допомогою глибинного навчання дозволяє обробляти великі обсяги даних із мінімальним втручанням людини, що відкриває шлях до масштабованих і швидких рішень у діагностиці ССЗ.

Нині дедалі більше уваги приділяється системам, що поєднують *AI* і дані з переносних пристроїв, які здатні значно розширити діагностичні можливості за межами клінік. Огляд, опублікований у 2025 році, показує, що *AI*-інтегровані носимі технології здатні масштабно трансформувати кардіологічну допомогу, особливо у сферах ранньої діагностики, персоналізованої оцінки ризику і моніторингу, зокрема за умов обмежених ресурсів [10].

Серед конкретних прикладів таких рішень: *Eko Health* представила *AI*-стетоскоп, який поєднує традиційну аускультацию із ЕКГ та аналізом на базі ШІ (рис. 1.3), дозволяючи діагностувати серцеву недостатність, клапанні хвороби та аритмії за всього 15 секунд. У клінічному дослідженні пацієнти, обстежені за допомогою цієї системи, мали втричі вищу ймовірність виявлення фібриляції передсердь і у два рази – клапанних захворювань, порівняно з традиційним стетоскопом [11].



Рис. 1.3. *Eko Health* - AI стетоскоп

У сегменті популярних споживчих пристроїв *Apple Watch* демонструє значний потенціал інтеграції з медичними алгоритмами: алгоритм *DeepHeart*, розроблений у спільному проєкті *UCSF* та *Cardiogram*, на основі серцевого ритму й кроків здатен прогнозувати гіпертензію з  $\approx 80\%$  точністю (рис. 1.4). Хоча офіційне використання таких даних у медичній практиці поки обмежене, застосування *Apple Watch* уже набирає терапевтичного значення завдяки простоті й широкому поширенню пристрою [12].



Рис.1.4. Вигляд програми яка пов'язана із аналізом даних від *Apple Watch*

Інші виробники, такі як *AliveCor*, пропонують сумісні з мобільними пристроями портативні ЕКГ, що дозволяють віддалено моніторити серцевий ритм і виявляти аритмії у режимі реального часу. *CardiacSense* (рис. 1.5) випускає медичний годинник, що безперервно вимірює ЕКГ, пульс, кров'яний тиск, кисень у крові й повідомляє пацієнта або лікаря про критичні зміни [13]. Пристрої від компанії *Withings* – такі як *Scanwatch* – можуть записувати ЕКГ,  $SpO_2$ , а також використовують датчики для вимірювання сну, активності та температури, що дозволяє збирати багатофакторні біометричні дані для подальшого аналізу.



Рис. 1.5. *CardiacSense Watch*

Таким чином, огляд існуючих методів діагностики показує чітку динаміку – від обмежених традиційних підходів до потужних систем на базі штучного інтелекту в

поєднанні з портативними та носимими пристроями. Це створює перспективну основу для розроблення ефективної, доступної, високоточної системи діагностики серцево-судинних захворювань, яка поєднує переваги обох підходів – клінічну точність і щоденний моніторинг.

### **1.3. Можливості та обмеження використання штучного інтелекту в медицині**

Штучний інтелект і, зокрема, методи машинного та глибинного навчання, за останні роки стали помітним каталізатором змін у кардіології. Їх застосовують для автоматизованого аналізу електрокардіограм, стратифікації серцево-судинного ризику, інтерпретації візуальних досліджень (ехокардіографія, КТ/МРТ серця), прогнозування клінічних подій і підтримки клінічних рішень. Узагальнюючі огляди демонструють, що *ML*-моделі на основі електронних медичних записів здатні перевершувати традиційні шкали (на кшталт *Framingham/QRISK*) у дискримінації ризику майбутніх подій, що відкриває шлях до більш персоналізованої профілактики та лікування.

Окремим напрямом є глибинне навчання для аналізу ЕКГ. Резонансна робота групи *Stanford* продемонструвала «кардіологічний» рівень точності багатокласової класифікації аритмій за одноканальними амбулаторними записами (середній *AUC*  $\approx 0,97$ ), що підкреслює потенціал *DL* для раннього виявлення порушень ритму у масових скринінгових сценаріях[14]. Сучасні дослідження пропонують гібридні архітектури (наприклад, *Transformer-CNN*), орієнтовані на стабільність до шумів, реальний час і інтеграцію з носимими пристроями – повідомляється про точність понад 98 % у задачах виявлення аномалій ЕКГ на репрезентативних наборах даних [15]. Водночас для часових рядів біосигналів активно застосовують рекурентні мережі, зокрема *LSTM* та *Bi-LSTM*, які вловлюють довгі залежності й покращують класифікацію аритмій/оцінку «біологічного віку» серця.

Ключові переваги *AI*-рішень у кардіології можна звести до трьох блоків. По-перше, чутливість і масштабованість: моделі здатні опрацьовувати мільйони

сигналів/зображень, знижуючи пропуск помилкових інтерпретацій та прискорюючи тріаж. По-друге, персоналізація: інтеграція багатомодальних даних – від ЕКГ і пульсоксиметрії до профілю активності з переносних пристроїв – покращує стратифікацію ризику на рівні окремого пацієнта. По-третє, безперервний моніторинг: алгоритми, вбудовані у портативні й носимі-системи, дають можливість раннього попередження про погіршення стану (наприклад, появу фібриляції передсердь) поза межами лікарні, що підтверджується низкою сучасних робіт і оглядів з аналізу ЕКГ у реальному часі [16].

Попри успішні напрацювання, існують суттєві обмеження. По-перше, прозорість («*black box*»): більшість *DL*-моделей складно інтерпретувати, що гальмує клінічну довіру та впровадження. Відтак активно розвиваються підходи пояснюваного ШІ, але їхні метрики й клінічна валідність досі стандартизовані неповно. По-друге, зміщення та генералізованість: моделі можуть упереджено працювати на мало представлених групах (за віком, статтю, етнічністю) і втрачати якість поза «рідними» дата-сетями; це підтверджують огляди упередженості в кардіологічних *AI*-системах та ширші звіти щодо медичних пристроїв. По-третє, методологічні пастки: завищені оцінки точності на «*intra-patient*» валідації, відсутність проспективних багатоцентрових випробувань і неповна звітність можуть переоцінювати реальну клінічну користь.

Окремо постають вимоги до безпеки, достовірності та регуляторної відповідності. Для ПЗ як медвиробу міжнародні регулятори запропонували принципи «*Good Machine Learning Practice*» (*GMLP*), що охоплюють повний життєвий цикл: якість даних, відтворюваність, управління ризиками, постринковий нагляд і безпечні оновлення моделей (через «*predetermined change control plan*», *PCCP*) [17]. У ЄС *AI Act* (Регламент (ЄС) 2024/1689) класифікує діагностичні *AI*-системи як високоризикові, що зумовлює обов'язки щодо управління даними, прозорості, людського нагляду та кібербезпеки в поєднанні з вимогами Регламенту про медичні вироби (*MDR*). Паралельно обробка персональних медичних даних у Європі регулюється *GDPR*, який вимагає законності, мінімізації й безпеки даних, а також прав суб'єкта на доступ/стирання [18].

Підсумовуючи, застосування ШІ в кардіології вже довело здатність підвищувати чутливість виявлення патологій, масштабувати скринінг і забезпечувати персоналізований моніторинг. Водночас для безпечної клінічної інтеграції потрібні багатоцентрові проспективні дослідження, прозорість та *XAI*-інструменти, протидія алгоритмічній упередженості, а також суворе дотримання регуляторних вимог (*GMLP*, *MDR/AI Act*, *GDPR*). Лише така зв'язка – науково валідних моделей, етичного дизайну даних і нагляду людини – забезпечить надійність і довіру до *AI*-систем у реальній медичній практиці.

#### **1.4. Рекурентні нейронні мережі та архітектура *LSTM* для аналізу медичних даних**

Рекурентні нейронні мережі (*RNN*) – це клас моделей штучного інтелекту, спеціально пристосованих для обробки послідовних даних. Їхня ключова перевага полягає в здатності враховувати часовий контекст шляхом збереження внутрішнього стану (пам'яті), який оновлюється на кожному кроці сету. Це робить *RNN* особливо цінними для аналізу біомедичних часових рядів, таких як електрокардіограма, де значення окремих точок менш важливе, ніж динаміка їхніх послідовностей – хвилі *P*, *QRS*-комплекси, інтервали *QT* тощо. Саме *RNN* дозволяють виявляти такі часові закономірності, що є ключем до точної діагностики серцевих патологій [19].

Однак класичні *RNN* стикаються з проблемами згасання або вибуху градієнтів, що суттєво ускладнює їх застосування до довгих послідовностей. Саме для подолання цих обмежень була розроблена архітектура *Long Short-Term Memory (LSTM)*. Одним із перспективних підходів до прогнозування часових рядів є використання рекурентних нейронних мереж, зокрема *LSTM*, які завдяки своїй архітектурі здатні ефективно обробляти послідовні дані [20]. Її основу становлять комірки пам'яті та спеціальні ворітні механізми (*input, forget, output*), які контролюють потік інформації і оновлення стану. Це дозволяє моделі вибірково запам'ятовувати або забувати сигнали, зберігаючи стабільність навчання навіть на тривалих відрізках даних [21]. Саме це робить їх особливо ефективними для аналізу електрокардіограм (ЕКГ) та

інших біомедичних даних. *LSTM*-моделі можуть автоматично розпізнавати приховані патерни серцевої активності, виявляти відхилення у ритмі, передбачати ризики аритмій чи навіть прогнозувати розвиток серцевої недостатності [22].

У контексті ЕКГ аналізу, *LSTM*-моделі показали високу ефективність. Вони здатні розпізнавати приховані закономірності у часових рядах сигналів, що особливо важливо для діагностики аритмій або передбачення серцевих подій. Згідно з дослідженням, гібридна архітектура *CNN-LSTM* забезпечила високу точність класифікації фібриляції передсердь (*AF*) та інших порушень ритму, використовуючи дані з бази *MIT-BIH Arrhythmia*, що підтверджує перевагу такої моделі над традиційними методами[23].

Сучасні адаптації *LSTM* включають *Bi-LSTM* (двонаправлені мережі), які аналізують дані в обох часових напрямках, та гібридні моделі *CNN-LSTM* чи *SEVGGnet-LSTM* зі вбудованим механізмом уваги. Наприклад, моделі *SEVGGNet-LSTM* успішно використовують *VGG* для вилучення локальних ознак, *LSTM* – для моделювання часових залежностей, а блоки *SE* – для виділення важливих сигналів із середовища шумів.

З точки зору продуктивності, легкі *CNN-LSTM* моделі можуть досягати точності класифікації понад 98%, при цьому залишаючись достатньо компактними для вбудування у носимі пристрої чи домашні монітори. Це відкриває шлях до застосування в реальному часі – наприклад, у носимих пристроях для постійного моніторингу ритму та раннього виявлення відхилень.

Таким чином, рекурентні нейронні мережі, особливо архітектура *LSTM*, є фундаментальним засобом для аналізу ЕКГ та інших часових біомедичних даних. Вони об'єднують глибоке вилучення часових залежностей із навчальною стабільністю, що робить їх оптимальним вибором для створення сучасних інтелектуальних систем діагностики серцево-судинних захворювань. Їх використання забезпечує підвищену точність, адаптивність до носимих платформ і потенціал для персоналізованого моніторингу пацієнтів.

## 1.5. Інтеграція даних з переносних пристроїв у системі діагностики

Переносні пристрої, такі як смарт-годинники, браслети, кишенькові кардіомонітори чи пульсоксиметри, відіграють ключову роль у сучасній медицині завдяки здатності безперервно вимірювати основні біометричні показники. До найбільш поширених типів пристроїв належать пристрої для вимірювання серцевого ритму та ЕКГ, сенсори  $SpO_2$ , акселерометри для моніторингу активності, а також техніка для вимірювання температури й артеріального тиску. Дані, зібрані пристроями, охоплюють як безперервні фізіологічні сигнали, так і патерни активності або соматичного стану – це серцеві показники, рівень кисню, активність, сон, стрес тощо.

Щоб такі дані могли ефективно використовуватися в медичних системах, їхня інтеграція повинна відповідати певним стандартам обміну. Серед фундаментальних протоколів у цій сфері – *FHIR (Fast Healthcare Interoperability Resources)*, який визначає сучасний *REST-API* підхід для обміну електронними медичними даними, що забезпечує їх інтероперабельність *FHIR*. Паралельно застосовуються стандарти *ISO/IEEE 11073*, призначені для забезпечення *plug-and-play* взаємодії медтехніки з інформаційними системами, особливо характерно це для персональних медприладів *ISO/IEEE 11073*. Крім того, *H.810 (Continua Design Guidelines)* визначає рекомендації для побудови сумісних систем *Connected Health*, забезпечуючи уніфіковану передачу й неперервну роботу пристроїв різних виробників *H.810*. На рівні стандартів безпеки застосовуються *HL7* – для структурованого обміну клінічною інформацією між системами *HL7* та *FHIR*, які працюють у комплексі для забезпечення інтеграції-*PGD (Personal Generated Health Data)* у системи *HER* [24].

Проте інтеграція переносних-даних у медичні системи стикається з численними труднощами. По-перше, точність даних. Багато споживчих пристроїв не призначені для клінічної діагностики. Наприклад, при фізичному навантаженні датчики *PPG* можуть давати похибку, що обмежує їх застосування у точній діагностиці. По-друге, несумісність форматів: кожен виробник часто використовує власні формати даних та *API*, що значно ускладнює стандартизацію й інтеграцію. По-третє, проблеми

інтероперабельності та безпеки: зокрема, низький рівень сумісності переносних-даних із системами *EHR*, складність обміну, ризики втрат чи викривлень даних.

Таким чином, інтеграція даних з носимих пристроїв у діагностичні медичні системи – це багаторівнева задача, яка вимагає:

- розуміння типів пристроїв і формату даних;
- використання промислових стандартів обміну (*FHIR*, *ISO/IEEE 11073*, *H.810*, *HL7*);
- забезпечення точності, сумісності та безпеки даних;
- відповідності вимогам *GDPR* та інших регуляторів при передачі персональних даних.

Успішна реалізація цих складових створює міцну основу для розвитку персоналізованих, інтегрованих та надійних систем діагностики на основі *wearable*-даних.

## **1.6. Тенденції розвитку інноваційних медичних систем**

Сучасна медицина перебуває на етапі масштабної трансформації, де провідними тенденціями стають персоналізований підхід, використання великих даних та впровадження хмарних технологій. Персоналізована медицина, або *precision medicine*, дедалі більше розглядається як основа майбутньої діагностики й лікування, адже вона враховує індивідуальні генетичні, фізіологічні та поведінкові характеристики пацієнта. Завдяки геноміці, мультиоміці та інтеграції даних із переносних пристроїв можливо формувати точні медичні профілі, що сприяють ранньому виявленню хвороб і підбору оптимальної терапії.

Не менш значну роль у розвитку інноваційних медичних систем відіграє аналітика великих даних у поєднанні з хмарними обчисленнями. Сьогодні обсяги медичних даних зростають у геометричній прогресії, охоплюючи електронні медичні записи, генетичну інформацію, показники з переносних-пристроїв та дані інтернету речей. Для їх обробки потрібні масштабовані технології, і саме хмарні платформи забезпечують ефективну інфраструктуру, що дозволяє застосовувати алгоритми

штучного інтелекту та машинного навчання в реальному часі. Це створює можливості для точнішої діагностики, прогнозування ризиків і моніторингу стану здоров'я пацієнтів

Ще одним перспективним напрямом є розвиток концепції *digital twin* – «цифрового двійника» пацієнта. Це віртуальна модель, що відображає фізіологічний стан людини на основі клінічних даних, інформації від датчиків та моделей перебігу захворювань. Використання *digital twin* дозволяє прогнозувати наслідки різних терапевтичних стратегій, адаптувати лікування в реальному часі та значно підвищувати його ефективність.

У результаті інтеграції цих тенденцій формується нове покоління комплексних систем дистанційного моніторингу пацієнтів. Платформи *Remote Patient Monitoring (RPM)*, що поєднують носимі сенсори з аналітикою штучного інтелекту, здатні виявляти ранні ознаки погіршення стану здоров'я, своєчасно реагувати на клінічні зміни й тим самим знижувати потребу в госпіталізації.

Таким чином, розвиток інноваційних медичних систем визначається переходом до персоналізованої медицини, активним використанням великих даних та хмарних технологій, а також впровадженням цифрових двійників і систем віддаленого моніторингу. Ці тенденції формують нову модель охорони здоров'я, орієнтовану на профілактику, своєчасну діагностику й пацієнтоцентричність.

## **1.7. Висновки до розділу**

У першому розділі показано, що серцево-судинні захворювання залишаються глобальною проблемою охорони здоров'я, адже вони є провідною причиною смертності у світі та становлять серйозний тягар для суспільства. Проаналізовані традиційні методи діагностики засвідчили їхню важливість, але й продемонстрували обмеження, пов'язані з точністю та оперативністю. У цьому контексті особливої актуальності набувають сучасні цифрові технології та системи на основі штучного інтелекту, які дають змогу суттєво підвищити ефективність виявлення та прогнозування серцевих патологій.

Окрему увагу приділено використанню методів машинного та глибинного навчання, зокрема архітектур рекурентних нейронних мереж і *LSTM*, що довели здатність успішно працювати з біомедичними часовими рядами, такими як електрокардіограми. Це створює передумови для розвитку більш точних, персоналізованих та масштабованих діагностичних рішень. Важливою складовою стає інтеграція даних із носимих пристроїв, що забезпечує безперервний моніторинг та підвищує роль пацієнта у власному лікуванні.

Нарешті, розглянуті сучасні тенденції розвитку інноваційних медичних систем засвідчили рух у напрямі персоналізованої медицини, широкого використання *big data* та хмарних обчислень, а також створення комплексних платформ моніторингу стану здоров'я. Це відкриває перспективи не лише для раннього виявлення та попередження серцево-судинних хвороб, а й для формування нової моделі профілактичної та персоналізованої медицини.

Таким чином, сукупність проаналізованих факторів підтверджує, що поєднання штучного інтелекту, інноваційних методів обробки медичних даних та інтеграції носимих пристроїв є ключем до побудови сучасних і надійних систем діагностики серцево-судинних захворювань.

## РОЗДІЛ 2

# ПРОЄКТУВАННЯ ІНТЕЛЕКТУАЛЬНОЇ LSTM-СИСТЕМИ ДІАГНОСТИКИ СЕРЦЯ

### 2.1. Постановка завдання та вимоги до системи

Метою проєкту є створення інтелектуальної системи діагностики серцево-судинних захворювань, що використовує архітектуру рекурентних нейронних мереж типу *LSTM* для аналізу часових рядів ЕКГ-сигналів, за характеристиками і джерелом близьких до тих, що збираються носимими пристроями. Основна ідея полягає в тому, щоб автоматизувати процес розпізнавання патологічних змін серцевого ритму на основі часових рядів даних, зменшивши залежність від людського фактора та підвищивши точність раннього виявлення аномалій.

Постановка завдання передбачає розроблення моделі, здатної ефективно навчатися на еталонних ЕКГ-сигналах, які містять як нормальні, так і патологічні варіації серцевої діяльності. Система має опрацьовувати дані, що відрізняються за частотою дискретизації, рівнем шуму та довжиною запису, тому критично важливою є надійна попередня обробка сигналів – нормалізація, сегментація та маркування фрагментів відповідно до типу серцевих скорочень. На цьому етапі формується структурована вибірка, на основі якої модель *LSTM* навчається розпізнавати відмінності між нормальними та аномальними сигналами.

З технічної точки зору, система має забезпечувати високу точність, стабільність при зміні даних та швидкості обробки, Для інтерпретації результатів використовуються методи *XAI*, які візуально демонструють ділянки сигналу, що найбільше вплинули на діагностичний висновок. З точки зору практичного використання, система має бути зручною, інтегрованою у простий користувацький інтерфейс та не вимагати спеціальних технічних знань.

<b>КАФЕДРА ІКС</b>				<b>КАІ 25 03 84 000 ПЗ</b>			
<i>Розробник.</i>	<i>Гринюк С. О.</i>			<i>Проектування інтелектуальної LSTM-системи діагностики серця</i>	<i>Літ.</i>	<i>Аркуш</i>	<i>Аркушів</i>
<i>Керівник</i>	<i>Супрун О. М.</i>					23	83
<i>Консульт.</i>					<b>M-126-24-1-IT</b>		
<i>Н-контроль</i>	<i>Тупота Є. В.</i>						
<i>Зав. каф.</i>	<i>Нечипорук О. П.</i>						

Програмна реалізація базується на поетапній архітектурі: модуль попередньої обробки даних, модуль навчання та оцінки моделі, і модуль візуалізації результатів. Кінцевим продуктом є вебзастосунок, який дозволяє користувачеві завантажити ЕКГ-сегмент, отримати прогноз моделі та проаналізувати пояснення діагнозу у зручній графічній формі.

Таким чином, завдання проєкту полягає у створенні комплексного рішення, яке поєднує сучасні методи глибинного навчання, дані з переносних пристроїв та інструменти пояснюваного штучного інтелекту. Така система повинна бути не лише точною з точки зору аналітики, а й практично корисною: вона покликана допомогти лікарям у прийнятті рішень та надати користувачам можливість постійно контролювати свій серцевий стан у зручному форматі.

## **2.2. Вибір архітектури нейронної мережі для аналізу ЕКГ сигналів**

Під час проєктування системи автоматичної діагностики серцевих захворювань одним із ключових етапів стало визначення оптимальної архітектури нейронної мережі, здатної ефективно аналізувати електрокардіографічні сигнали. Особливість ЕКГ полягає в тому, що це послідовність даних, у якій важлива не лише форма окремих імпульсів, а насамперед взаємозв'язки між ними у часі. Саме тому для аналізу таких сигналів доцільно використовувати моделі, здатні «запам'ятовувати» попередні стани та виявляти довготривалі часові залежності – рекурентні нейронні мережі (*RNN*).

Серед різновидів *RNN* особливе місце посідає архітектура *LSTM* (*Long Short-Term Memory*), яка усуває типові обмеження класичних рекурентних мереж, пов'язані із затуханням або вибухом градієнтів під час навчання на довгих послідовностях. *LSTM* має спеціальну структуру – комірки пам'яті з трьома “воротами” (*input, forget, output*), що дозволяють контролювати потік інформації: які дані запам'ятати, які відкинути та які використовувати для прогнозу (рис. 2.1). Завдяки цьому мережа може вловлювати складні часові закономірності навіть у довгих і зашумлених біомедичних сигналах, таких як ЕКГ, де кожен сегмент може мати сотні точок вимірювання.

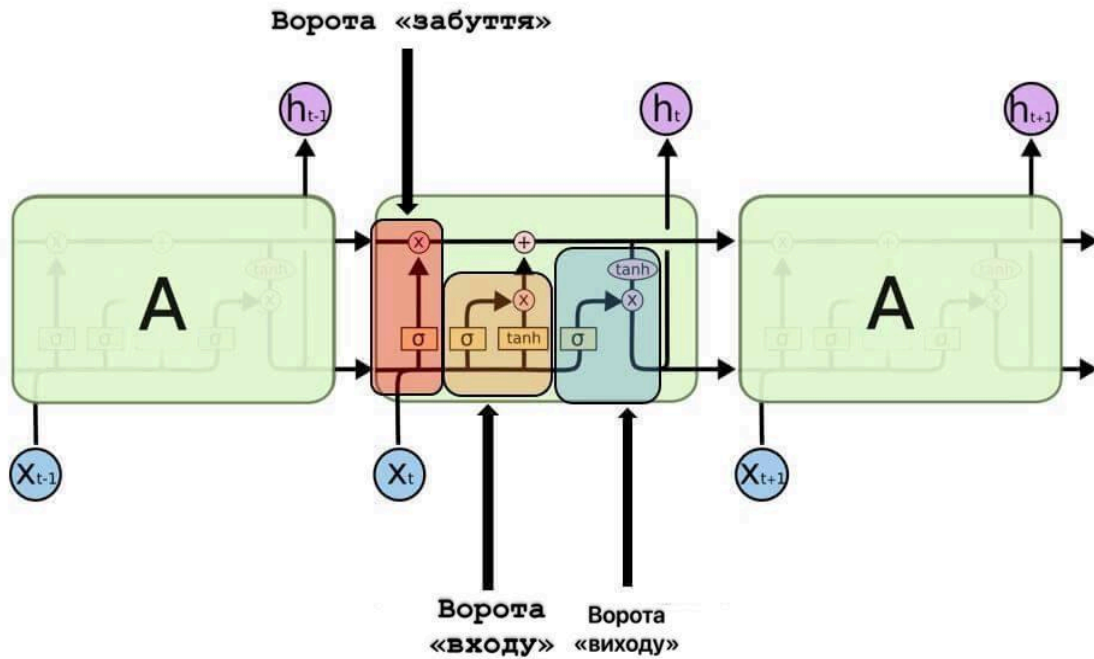


Рис. 2.1. Внутрішня будова комірки пам'яті в *LSTM*

Архітектура *Long Short-Term Memory (LSTM)*, є ключовим рішенням для аналізу ЕКГ сигналів. Вона була розроблена для подолання головного недоліку класичних рекурентних мереж (*RNN*) – нездатності запам'ятовувати інформацію на довгих часових проміжках.

*LSTM*-комірка це як фільтрувальний пункт у інформаційному конвеєрі. Вона не просто передає дані далі, а активно вирішує, що зберегти, що забути і що використати для прогнозу. Це керування здійснюється за допомогою трьох спеціальних механізмів, які називаються воротами:

### 1. Серце *LSTM*: Стан Комірки

Ключовим елементом *LSTM* є Стан Комірки (*Cell State*) – горизонтальна лінія, що проходить через усю верхню частину діаграми. Це основна лінія пам'яті, яка несе в собі довгострокові знання про ЕКГ сигнал. На відміну від звичайних нейронів, стан комірки змінюється дуже повільно і контролюється воротами.

### 2. Керування Інформацією за допомогою воріт

Кожен із трьох воріт використовує сигмоїдальну функцію ( $\sigma$ ), яка видає значення між 0 та 1. Це працює як фільтр: 0 означає "повністю блокувати", 1 означає "повністю пропустити".

А. Ворота Забування (*Forget Gate*). Це перший фільтр, який вирішує, що потрібно вилучити зі старої пам'яті ( $X_{t-1}$ ).

В. Ворота Входу (*Input Gate*). Ці ворота відповідають за те, що потрібно внести в пам'ять з нового вхідного сигналу ( $X_t$ ).

С. Ворота Виходу (*Output Gate*). Ці ворота вирішують, яку частину оновленого стану комірки слід показати (тобто використати як вихід комірки,  $H_t$ ).

Саме ця динамічна взаємодія між трьома воротами дозволяє *LSTM*-мережі аналізувати складні послідовності ЕКГ та ефективно виявляти аномалії, які можуть виникати лише через сотні мілісекунд після певного події.

Для розв'язання поставленої задачі була обрана гібридна архітектура, що поєднує переваги згорткових та рекурентних нейронних мереж з механізмом уваги (рис. 2.2).

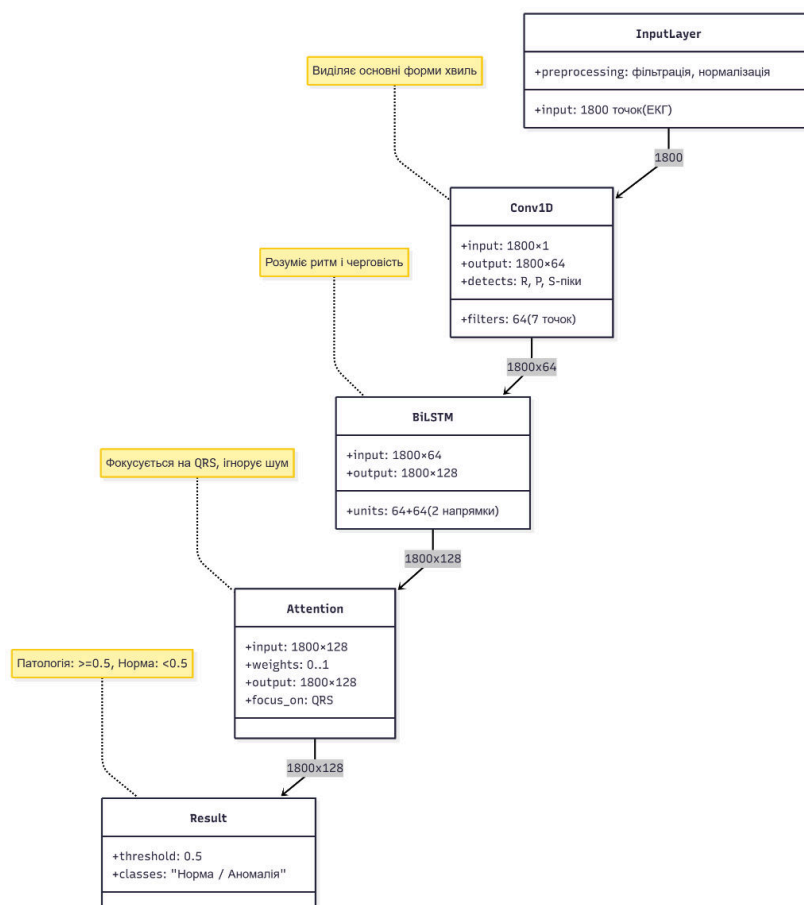


Рис. 2.2. Архітектура гібридної нейронної мережі

Така комбінація дозволяє одночасно виявляти локальні патерни (форми хвиль *P*, *QRS*-комплекси) та аналізувати глобальні часові залежності (послідовність ударів, варіабельність ритму). Модель побудована за принципом багаторівневого вилучення ознак, де кожен шар відповідає за певний аспект аналізу сигналу. Архітектура розпочинається зі згорткового шару *Conv1D*, шар призначений для виявлення локальних морфологічних ознак ЕКГ-сигналу – форм окремих елементів, таких як зубці *P*, комплекси *QRS* та сегменти *ST*. Після згорткового шару застосовується операція *MaxPooling*, яка зменшує розмірність даних та забезпечує стійкість моделі до невеликих часових зсувів у сигналі. Такий підхід дозволяє виявити характерні патерни незалежно від їх точного розташування в межах вікна аналізу. Наступним ключовим компонентом є двонаправлена *LSTM* (*Bidirectional LSTM*), на відміну від односпрямованої *LSTM*, двонаправлена архітектура аналізує послідовність як вперед, так і назад у часі, що дозволяє враховувати контекст з обох боків від поточної точки сигналу. Це критично важливо для виявлення аритмій, які проявляються через порушення послідовності серцевих скорочень або через аномальні інтервали між ударами. Для запобігання перенавчанню після *LSTM*-шару застосовується *Dropout*, що випадково вимикає частину нейронів під час навчання і змушує модель навчатися більш узагальненим ознакам.

Особливу роль у архітектурі має відігравати механізм уваги, який автоматично визначає найважливіші ділянки сигналу для прийняття рішення. Цей механізм дозволяє моделі не просто обробляти всі частини вхідної послідовності однаково, а динамічно фокусуватися на тих фрагментах, які несуть найбільше діагностичної інформації. Наприклад, при виявленні певних типів аритмій модель може зосередити увагу на аномальних *QRS*-комплексах або нерегулярних інтервалах між *R*-піками. Важливо, що механізм уваги не лише підвищує точність класифікації, а й забезпечує інтерпретованість прогнозів – лікар або простий користувач може візуально побачити, на які саме ділянки ЕКГ модель звернула увагу при встановленні діагнозу. Це критично важливо для медичного застосування, де прозорість прийняття рішень є неодмінною вимогою.

Обрана архітектура має кілька ключових переваг порівняно з традиційними підходами. По-перше, вона реалізує багаторівневе вилучення ознак: згортковий шар виявляє локальні морфологічні характеристики окремих елементів ЕКГ, двонаправлена *LSTM* аналізує послідовність цих елементів у часі, а механізм уваги визначає, які з них найбільш важливі для остаточної класифікації. По-друге, двонаправлена обробка дозволяє враховувати інформацію як з попередніх, так і з наступних серцевих скорочень, що особливо важливо для виявлення аритмій, які проявляються через порушення загального ритму. По-третє, інтерпретованість через механізм уваги робить модель прийнятною для клінічного використання, адже лікар може не лише отримати діагноз, а й зрозуміти, на основі яких ознак він був встановлений. Вибір саме *LSTM* як базової компоненти архітектури зумовлений не лише її теоретичними перевагами, а й практичними міркуваннями щодо ефективності обробки медичних часових рядів. На відміну від класичних методів машинного навчання, які вимагають ручного вилучення ознак, або простих згорткових мереж, які не враховують часову залежність між елементами, *LSTM* спроектована спеціально для роботи з послідовностями, де важлива не лише форма окремих фрагментів, а й їх взаємне розташування та динаміка зміни у часі.

Архітектура була спроектована також з урахуванням майбутньої інтеграції з носимими медичними пристроями. Хоча модель містить близько 200 тисяч параметрів і є достатньо складною для виявлення тонких патернів у біомедичних сигналах, вона залишається компактною для розгортання на хмарних обчислювальних платформах або потужніших вбудованих системах. Це відкриває можливість обробки ЕКГ-даних у реальному часі – наприклад, аналізу сигналів від фітнес-браслетів, смарт-годинників або портативних холтеровських моніторів. Користувач може отримувати попередження про можливі аритмії одразу після реєстрації сигналу, що критично важливо для своєчасного виявлення небезпечних станів.

Нарешті, під час проєктування системи було враховано можливість подальшого масштабування та вдосконалення архітектури без зміни фундаментальних принципів її функціонування. Зокрема, можливе включення додаткових *LSTM*-шарів для

глибшого аналізу часових залежностей, збільшення кількості фільтрів у згортковій частині для виявлення більш складних морфологічних патернів, або навіть інтеграція з сучасними трансформерними моделями, які показують перспективні результати в обробці послідовностей. Така гнучкість забезпечує довгострокову актуальність розробленої системи та можливість її адаптації до нових клінічних викликів.

Таким чином, вибір *LSTM* як базової архітектури ґрунтується на її здатності ефективно працювати з часовими рядами, стабільності під час навчання та сумісності з практичними вимогами до швидкості, точності й пояснюваності результатів. Це забезпечує надійну основу для створення інтелектуальної системи діагностики серця, яка поєднує глибокі математичні принципи з реальними потребами клінічної практики та користувачів переносних пристроїв.

### **2.3. Формування вхідних даних та методика попередньої обробки**

Одним із найважливіших етапів побудови інтелектуальної системи діагностики серцевих аномалій є формування якісних вхідних даних. Саме від правильності підготовки та обробки електрокардіографічних сигналів залежить точність і стабільність роботи моделі *LSTM*. Адже будь-яка нейронна мережа не може навчатися на «сирих» даних – вони повинні бути структуровані, нормалізовані та позначені відповідно до медичних класів.

У межах даної роботи для навчання було використано записи з відкритої медичної бази *MIT-BIH Arrhythmia Database*, яка є найпоширенішим стандартом у дослідженнях кардіологічних алгоритмів. Ця база була першим загальнодоступним набором тестових матеріалів для оцінки детекторів аритмії та використовувалася у понад 500 медичних центрах по всьому світу [25]. База містить 48 тривалих записів ЕКГ-сигналів від різних пацієнтів, кожен з яких триває близько тридцяти хвилин. Сигнали оцифровані з частотою 360 *Гц*, що означає 360 вимірів на секунду – це стандарт як для клінічних систем, так і для сучасних носимих пристроїв типу смарт-годинників з ЕКГ-сенсорами. Кожен запис супроводжується точними часовими мітками серцевих скорочень і медичними анотаціями, виконаними досвідченими

кардіологами. Важливо, що база містить як нормальні ритми, так і різноманітні аритмії, що робить її ідеальною для навчання моделей розпізнавання патологій.

Процес підготовки даних розпочинається із завантаження сирих сигналів за допомогою спеціалізованої бібліотеки *WFDB (WaveForm DataBase)*. На цьому етапі дані ще містять багато шуму: повільні коливання від дихання, перешкоди від м'язів, електричні наводки. Тому наступним кроком стає фільтрація сигналу за допомогою смугово-пропускнуго фільтра з діапазоном від 0.5 до 40 Гц. Нижня межа видаляє повільний дрейф базової лінії, а верхня відфільтровує високочастотні перешкоди, зберігаючи при цьому всі елементи ЕКГ – хвилі *P*, комплекси *QRS*, сегменти *ST* та хвилі *T*.

Далі настає етап сегментації, де приймається принципово важливе рішення щодо формату даних для нейронної мережі. У цій роботі використовуються ковзні вікна тривалістю п'ять секунд. Це означає, що з безперервного запису ЕКГ вирізаються фрагменти по п'ять секунд кожен, причому наступне вікно починається не з кінця попереднього, а з його середини – таким чином досягається перекриття на п'ятдесят відсотків. При частоті 360 вимірів на секунду кожне п'ятисекундне вікно містить 1800 точок даних. Це дозволяє моделі бачити не просто окремі удари серця, а їхню послідовність: наскільки регулярний ритм, чи є пропущені удари, чи з'являються позачергові скорочення. До того ж такий формат даних повністю сумісний з тим, як працюють сучасні фітнес-браслети та смарт-годинники – вони також аналізують короткі вікна по кілька секунд. Перекриття вікон на половину довжини виконує подвійну функцію: по-перше, воно збільшує кількість навчальних прикладів без необхідності збирати додаткові записи; по-друге, гарантує, що жодна аритмія не буде пропущена через те, що потрапила на межу між двома вікнами. Кожна ділянка сигналу аналізується двічі у складі двох різних вікон, що підвищує надійність діагностики.

Наступним кроком є класифікація серцевих скорочень. Для цього використовується стандартизована система *AAMI (Association for the Advancement of Medical Instrumentation)*, за якою всі скорочення поділяються на дві основні категорії (табл. 2.1):

- нормальні (*Normal*) позначаються символами *N, L, R, e, j*;
- аномальні (*Abnormal*) включають скорочення типу *V, A, F, E* та інші, що свідчать про наявність аритмій або порушень провідності.

Таблиця 2.1

## Стандартизовані позначки системи ААМІ

Група	Символ	Назва	Коротке пояснення	Мітка
Нормальні	<i>N</i>	Нормальне	Типовий синусовий удар без патологій.	0
	<i>L</i>	Блокада лівої ніжки	Уповільнення сигналу через лівий шлуночок, <i>QRS</i> ширший.	0
	<i>R</i>	Блокада правої ніжки	Аналогічно <i>L</i> , але у правому шлуночку.	0
	<i>e</i>	Передсердне вислизаюче	Запасний ритм, коли синусовий вузол "мовчить".	0
	<i>j</i>	Вузлове вислизаюче	Імпульс з <i>AB</i> -вузла – також захисний механізм.	0
Надшлуночкові ектопічні	<i>A</i>	Передчасне передсердне	Позачерговий удар з передсердя (найчастіша аритмія).	1
	<i>a</i>	Аберантне передсердне	Як <i>A</i> , але із ширшим <i>QRS</i> .	1
	<i>J</i>	Вузлове передчасне	Позачерговий імпульс із <i>AB</i> -вузла.	1
	<i>S</i>	Надшлуночкове	Загальна категорія для <i>A</i> та <i>J</i> .	1
Шлуночкові ектопічні	<i>V</i>	Передчасне шлуночкове	Імпульс із шлуночка, широкий <i>QRS</i> – типова аритмія.	1
	<i>E</i>	Шлуночкове вислизаюче	Повільне скорочення, коли основний ритм зникає.	1
Злиття	<i>F</i>	Змішане скорочення	Одночасно нормальний і ектопічний імпульси.	1
Виключені	<i>/</i>	Сигнал стимулятора	Імпульс від кардіостимулятора.	–
	<i>f</i>	Злиття стимулятора	Комбінація природного й штучного сигналів.	–
	<i>Q</i>	Некласифіковане	Зашумлений або невизначений сигнал.	–

Після того як кожне окреме серцеве скорочення отримало свою мітку згідно з системою *AAMI*, потрібно визначити статус цілого п'ятисекундного вікна. Тут застосовується простий, але ефективний принцип: якщо у вікні є хоча б один патологічний удар, все вікно вважається аномальним і отримує мітку «аритмія». Якщо ж усі удари нормальні, вікно класифікується як «норма». Такий підхід відповідає медичній практиці, де навіть поодинокі екстрасистоли на записі ЕКГ є підставою для подальшого обстеження пацієнта. Краще помилково виявити проблему, яка потім не підтвердиться, ніж пропустити справжню аритмію.

Останнім важливим кроком перед поданням даних у нейронну мережу є нормалізація амплітуд. Проблема полягає в тому, що ЕКГ-сигнали різних людей можуть відрізнятися за висотою зубців через фізіологічні особливості. Щоб усунути ці відмінності і дозволити моделі зосередитися саме на формі хвиль, а не на їхній абсолютній висоті, кожне п'ятисекундне вікно стандартизується окремо. Це означає, що з усіх значень амплітуд у вікні віднімається їхнє середнє значення, після чого результат ділиться на стандартне відхилення. Після такого перетворення кожне вікно має середню амплітуду рівну нулю і стандартний розмах рівний одиниці, незалежно від того, який був початковий сигнал. Важливо, що стандартизація застосовується окремо до кожного вікна, а не до всього запису одразу, що дозволяє врахувати локальні зміни амплітуди через рухи пацієнта або зміну положення тіла.

Після проходження всіх цих етапів обробки (фільтрації, сегментації, класифікації та нормалізації) дані формуються у тривимірний масив  $X$  (послідовності сигналів) і вектор міток  $Y$  (відповіді) (рис. 2.3).

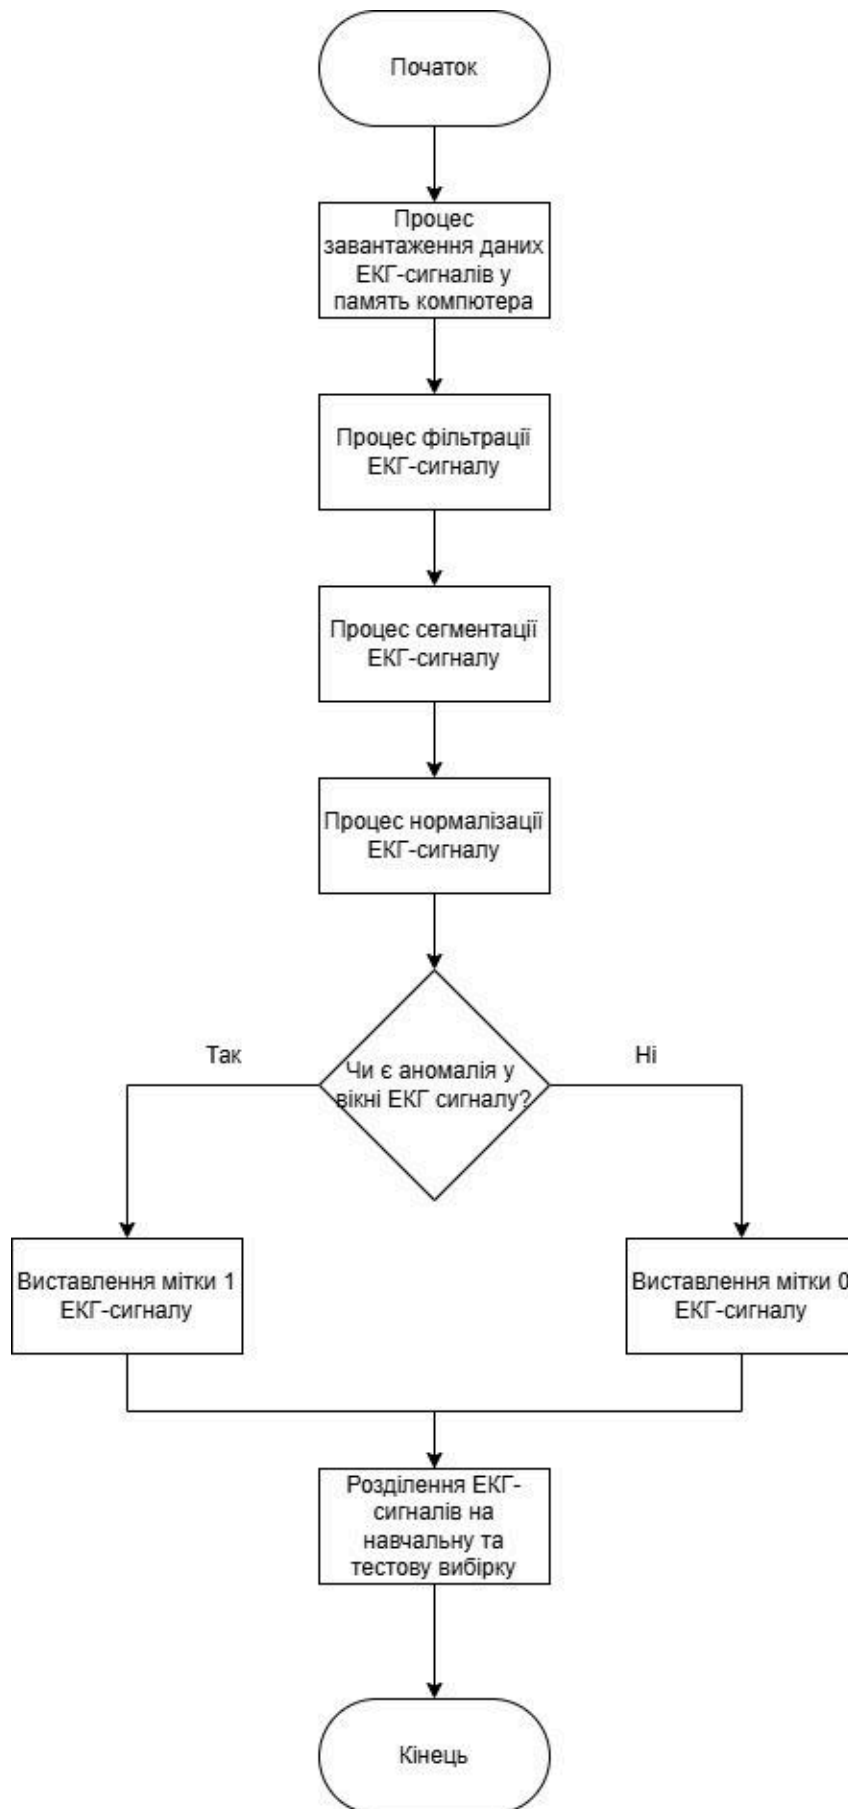


Рис. 2.3. Схема алгоритму попередньої обробки ЕКГ даних

Цей остаточний набір даних зберігається у серіалізованому форматі, що усуває необхідність повторно виконувати складну обробку при кожному запуску експериментів.

Важливо відмітити, що вся ця методика обробки повністю відповідає форматам даних, які використовують сучасні носимі пристрої для моніторингу серця. Частота дискретизації в  $360 \text{ Гц}$  є стандартом для якісних медичних гаджетів (наприклад *AliveCor Kardia*, *Biovotion* які працюють в діапазоні  $250\text{-}500 \text{ Гц}$ ), п'ятисекундні вікна – це типова тривалість вимірювання в мобільних додатках та носимих системах (наприклад *Apple Watch*, *Fitbit ECG*, *Samsung ECG* реєструють  $5\text{-}10$  секунд сигналу для аналізу ритму), а фільтрація шуму в діапазоні від половини до сорока герц застосовується практично у всіх комерційних пристроях для компенсації рухів руки. Тому розроблена система може працювати не лише з науковою базою *MIT-BIH*, але й з реальними даними від смарт-годинників, холтерівських моніторів та інших носимих ЕКГ-пристроїв, які стають дедалі популярнішими для щоденного контролю здоров'я серця.

Таким чином, методика формування та попередньої обробки вхідних даних забезпечує логічний перехід від реальних біологічних сигналів до структури, придатної для навчання глибоких нейронних мереж. Багатоетапна обробка гарантує високу якість даних, а використання п'ятисекундних вікон дозволяє моделі аналізувати не просто окремі удари, а послідовності серцевих скорочень, їхню регулярність і ритмічні характеристики. Це принципово важливо для виявлення багатьох типів аритмій, які проявляються саме через порушення послідовності ударів. Саме цей етап закладає міцну основу для подальшої роботи гібридної архітектури з згортковими та рекурентними шарами, яка зможе ефективно виявляти серцеві аномалії як у клінічних даних, так і в сигналах від переносних пристроїв моніторингу.

## **2.4. Структура розробленої системи**

Розроблена система діагностики серцево-судинних захворювань має модульну структуру, що поєднує інструменти попередньої обробки сигналів, глибинного

навчання та інтерфейс користувача. Такий підхід забезпечує гнучкість, масштабованість та можливість подальшого вдосконалення окремих компонентів без зміни загальної архітектури. Система реалізована на основі сучасних технологій штучного інтелекту з використанням бібліотек *TensorFlow*, *Keras*, *NumPy*, *Pandas* та середовища *Streamlit* для інтерактивної взаємодії з користувачем.

Структурно програмний комплекс складається з трьох основних рівнів: рівня обробки даних, рівня моделювання та рівня користувацької взаємодії. Кожен із них виконує окрему функцію, але всі вони взаємопов'язані між собою через чітко визначені інтерфейси передавання даних.

На першому рівні – рівні обробки даних – система приймає сирі ЕКГ-сигнали, отримані з бази *MIT-BIH*. У цьому модулі виконується фільтрація шумів за допомогою смугового фільтра у діапазоні від 0,5 до 40 Гц, нормалізація амплітудних значень, сегментація сигналів на окремі п'ятисекундні вікна з перекриттям у 50% та формування навчальної вибірки для аналізу. Кожен фрагмент сигналу автоматично отримує бінарну мітку залежно від наявності або відсутності патологічних скорочень серця. Цей блок відповідає за підготовку структурованих даних, придатних для подальшого використання у моделі глибинного навчання, і реалізований у вигляді окремого скрипта *pre.py*, який автоматизує весь процес від завантаження сигналів до створення готових наборів *X* та *Y*.

Другий рівень становить модуль моделювання. Тут реалізовано безпосередню логіку штучного інтелекту – навчання та прогнозування за допомогою гібридної нейронної мережі типу *CNN–BiLSTM–Attention*. Модель отримує на вхід сегментовані ЕКГ-сигнали і навчається розпізнавати часові закономірності, притаманні нормальній або патологічній діяльності серця. Поєднання згорткових шарів (*Conv1D*) та двонаправлених рекурентних блоків (*Bidirectional LSTM*) дозволяє одночасно виділяти локальні особливості сигналу і довготривалі залежності у часі, а механізм *Attention* фокусується на найбільш інформативних ділянках. Під час навчання модель оптимізується за допомогою алгоритму *Adam*, а якість класифікації оцінюється на тестовій вибірці з використанням метрик точності, повноти, *F1*-міри та *ROC-AUC*. Для уникнення перенавчання застосовується механізм *EarlyStopping*, а найкраща

версія мережі автоматично зберігається у файлі *lstm\_attention\_model.keras*. Таким чином, система здатна забезпечувати високу точність класифікації та стабільність результатів навіть на зашумлених даних.

На третьому рівні функціонує інтерфейс користувача, реалізований у середовищі *Streamlit*. Завдяки цьому програмне забезпечення має інтуїтивно зрозумілий вигляд і може бути використане як медичними фахівцями, так і звичайними користувачами. Інтерфейс дозволяє переглянути ЕКГ-сегмент, переглянути графічне відображення сигналу, запустити прогноз та миттєво отримати результат класифікації. У разі виявлення патології система не лише повідомляє про наявність аномалії, але й демонструє візуальне пояснення роботи моделі, підсвічуючи ділянки сигналу, які найбільше вплинули на рішення. Це забезпечує елемент інтерпретованості (*Explainable AI*), що підвищує довіру до результатів і полегшує клінічний аналіз.

Важливою особливістю архітектури є її масштабованість і переносимість. Розроблена система може функціонувати як на локальному комп'ютері, так і в хмарному середовищі, забезпечуючи можливість обробки великих обсягів даних у режимі реального часу. Для зручності налагодження та повторного використання всі основні компоненти – попередня обробка, модель та інтерфейс – ізольовані у вигляді окремих модулів, що спрощує оновлення або заміну окремих частин без потреби перебудови всієї системи. Логіка взаємодії компонентів побудована так, що дані послідовно проходять через усі етапи: від збору сирих сигналів до візуалізації результатів класифікації. У разі потреби результати аналізу можуть зберігатися у базі даних для подальшого статистичного дослідження або повторного навчання моделі.

Отже, структура системи являє собою поєднання трьох взаємозалежних рівнів – підготовки даних, інтелектуального аналізу та користувацької взаємодії (рис. 2.4).

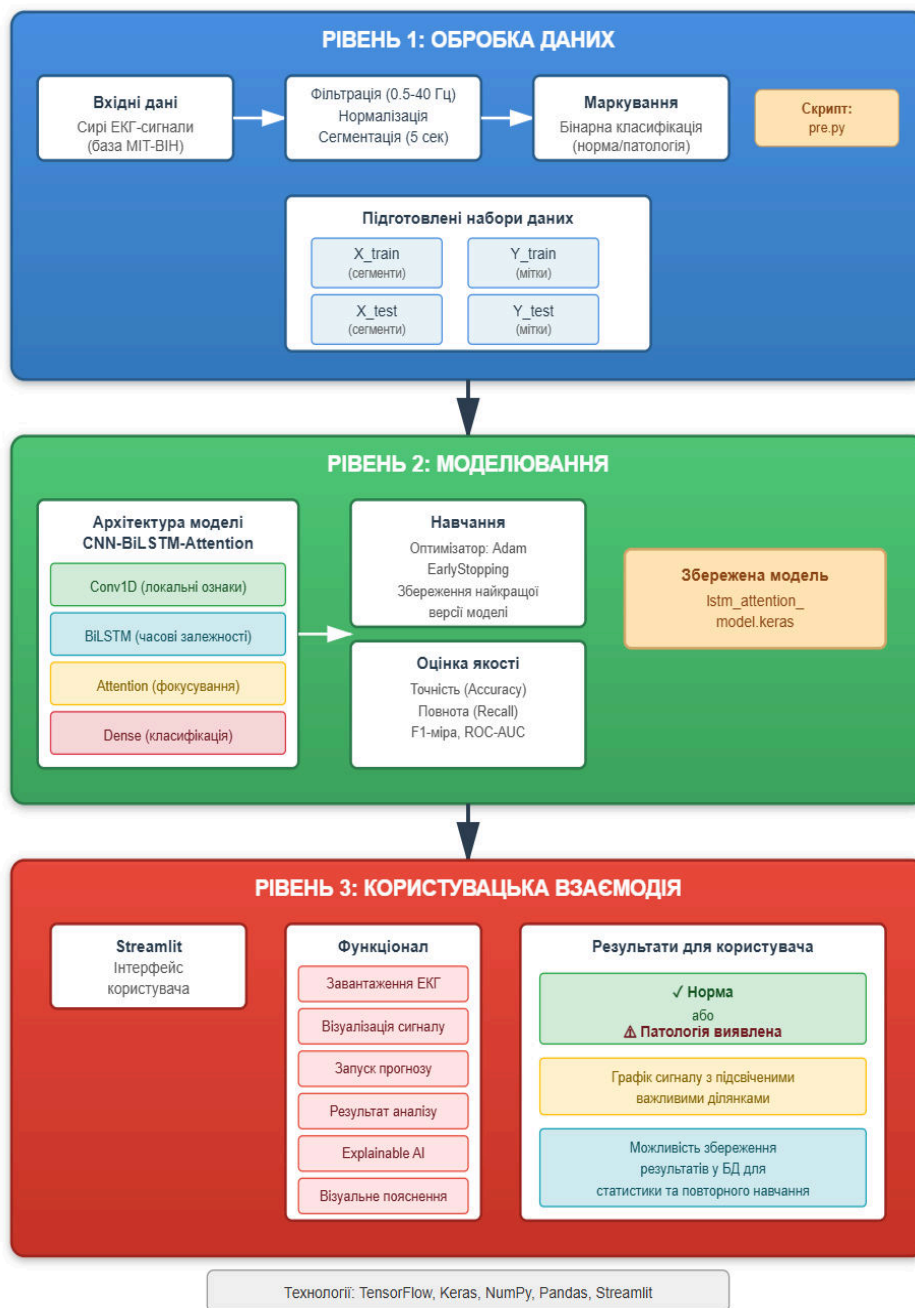


Рис. 2.4. Структура інтелектуальної системи діагностики ЕКГ

Такий підхід забезпечує не лише високу ефективність і точність діагностики, але й простоту використання у клінічній практиці та побутових умовах. Завдяки модульній архітектурі, розроблений комплекс може слугувати основою для подальших досліджень і вдосконалень, зокрема для мультикласової діагностики різних типів аритмій або інтеграції з мобільними пристроями та носимими кардіомоніторами.

## 2.5. Планування процесу навчання та налаштування гіперпараметрів

Після формування вибірки даних і визначення архітектури моделі постає завдання правильно організувати процес навчання нейронної мережі. Саме цей етап визначає не лише точність класифікації, а й здатність системи узагальнювати закономірності у сигналах, не запам'ятовуючи окремі приклади. Для досягнення оптимального результату було проведено ретельне налаштування гіперпараметрів – кількості епох, розміру батчу, функції втрат, типу оптимізатора, кількості нейронів у шарах і параметрів регуляризації.

Процес навчання моделі базувався на принципі поступового покращення якості через експериментальний підбір параметрів. Підготовлена вибірка була поділена у співвідношенні 80:20 – тренувальна частина використовувалася для оптимізації вагових коефіцієнтів, а тестова – для незалежної оцінки точності після завершення навчання. У середині тренувальної вибірки автоматично виділялася валідаційна частина (10%), яка застосовувалася для контролю узагальнюючої здатності моделі та запобігання перенавчанню. Як функцію втрат використано бінарну крос-ентропію (*Binary Crossentropy*), що є стандартом для двокласових задач і добре підходить для порівняння прогнозованої ймовірності наявності аномалії з фактичним класом. Для оптимізації ваг застосовано адаптивний алгоритм *Adam*, який автоматично коригує швидкість навчання для кожного параметра. Це дозволяє досягати стійкої збіжності навіть за наявності шуму в біосигналах, що є типовим для ЕКГ, особливо отриманих із переносних пристроїв.

Особлива увага приділялася проблемі дисбалансу класів, оскільки кількість нормальних скорочень значно перевищує кількість патологічних. Щоб уникнути зміщення у бік більш частого класу, під час навчання використовувалися вагові коефіцієнти класів, що збалансовують внесок кожного типу прикладів у функцію втрат. Такий підхід дозволив підвищити чутливість моделі до рідкісних патологічних скорочень і забезпечити більш об'єктивне навчання. Для стабілізації процесу навчання застосовано механізм раннього зупинення, який припиняє тренування, якщо валідаційна похибка не зменшується протягом кількох епох. Це дозволило уникнути

перенавчання та зберегти найкращий стан моделі, коли вона досягла максимальної точності без втрати здатності узагальнювати дані.

Розмір батчу встановлено на 64, що забезпечує компроміс між швидкістю навчання і стабільністю оновлення ваг. Менший розмір призводив до надмірних коливань функції втрат, тоді як більший зменшував здатність моделі враховувати дрібні часові відмінності у сигналі. Кількість нейронів у прихованих шарах також підбиралася експериментально. Оптимальним виявився варіант із 64 нейронами у шарі *BiLSTM* і 64 у щільному шарі *Dense*, що забезпечило достатню глибину представлення даних без надмірного споживання ресурсів. Для зменшення ризику перенавчання використано  $Dropout = 0.3$ , який випадково “вимикає” частину нейронів у процесі тренування, стимулюючи модель формувати більш узагальнені внутрішні представлення. Крім того, в архітектурі застосовано шар уваги, який дозволяє моделі фокусуватися на найбільш інформативних ділянках ЕКГ-сигналу, підвищуючи точність класифікації патологічних скорочень.

Після завершення навчання модель разом із параметрами та історією процесу була збережена у форматі *.keras*, що забезпечує швидке завантаження без необхідності повторного навчання. Також збережено матрицю похибок, вектор передбачень і графічні звіти для подальшого аналізу точності. Таким чином, процес навчання моделі був спланований і реалізований з урахуванням усіх вимог до якості, стабільності та пояснюваності результатів. Використання адаптивного оптимізатора *Adam*, балансування класів, регуляризації та механізмів контролю перенавчання дозволило створити стійку модель, здатну аналізувати ЕКГ-сигнали. Ця модель є центральним ядром інтелектуальної системи, на основі якої формується автоматизований діагностичний висновок про стан серцевої діяльності користувача.

## **2.6. Висновки до розділу**

У другому розділі було виконано повний цикл проектування інтелектуальної системи діагностики серцевих захворювань, яка ґрунтується на гібридній архітектурі нейронної мережі типу *CNN–BiLSTM–Attention*. У процесі роботи було визначено

вимоги до функціонування системи, сформульовано мету її створення та обґрунтовано вибір технологічних рішень, що забезпечують ефективну обробку електрокардіографічних сигналів.

Основною задачею системи є автоматичне розпізнавання патологічних відхилень серцевого ритму на основі аналізу часових рядів ЕКГ. Для цього було застосовано архітектуру, яка поєднує згорткові шари (*Conv1D*) для виділення локальних ознак сигналу, двонаправлений шар довготривалої пам'яті (*Bidirectional LSTM*) для врахування часових залежностей у послідовності та механізм уваги (*Attention*) для фокусування на найбільш інформативних ділянках сигналу. Така комбінація забезпечує високу точність виявлення аритмій і стабільність роботи навіть за наявності шуму чи артефактів у сигналі.

Було розроблено логічну структуру системи, що включає три основні рівні – підготовку даних, інтелектуальне моделювання та користувацьку взаємодію. Перший рівень реалізовано у модулі *pre.py*, де здійснюється завантаження даних із бази *MIT-BIH*, фільтрація шумів, нормалізація сигналів, сегментація на п'ятисекундні вікна та формування вибірки у форматі, придатному для навчання *LSTM*-моделі.

Другий рівень представлений модулем *train.py*, який реалізує процес глибинного навчання з використанням оптимізатора *Adam*, функції втрат *Binary Crossentropy*, балансування класів і механізму *Early Stopping* для запобігання перенавчанню. У ході тренування модель автоматично підлаштовує ваги та формує внутрішні уявлення про патерни серцевих скорочень, характерні для нормальних і патологічних станів.

Третій рівень – інтерфейс користувача, створений за допомогою *Streamlit*, – забезпечує зручну візуалізацію результатів, перегляд графіків ЕКГ-сигналів і пояснень роботи моделі за допомогою методів *Explainable AI (XAI)*. Користувач може обрати конкретний зразок, переглянути прогноз моделі, порівняти його з фактичним класом і оцінити, які частини сигналу вплинули на рішення нейромережі.

Архітектура системи побудована за модульним принципом: кожен компонент функціонує автономно, але взаємодіє з іншими через чітко визначені інтерфейси. Такий підхід забезпечує гнучкість, можливість оновлення окремих частин без

перебудови всієї системи, а також адаптацію до нових джерел даних, зокрема від сучасних носимих пристроїв і мобільних сенсорів. Використання мови програмування *Python* та бібліотек *TensorFlow*, *NumPy*, *scikit-learn*, *WFDB* і *Matplotlib* дало змогу поєднати високу точність обчислень із наочністю результатів та простотою інтеграції алгоритмів.

Таким чином, у результаті проєктування було створено цілісну архітектуру інтелектуальної системи діагностики серцевих захворювань, яка поєднує сучасні методи глибинного навчання, засоби попередньої обробки біомедичних сигналів і зрозумілий графічний інтерфейс. Розроблена система є універсальною платформою, придатною як для наукових досліджень, так і для практичного застосування у клінічній діагностиці або побутовому моніторингу стану серця. Вона створює основу для подальших експериментів, розширення кількості класів аритмій і вдосконалення алгоритмів аналізу на основі реальних даних із переносних пристроїв.

## РОЗДІЛ 3

# РОЗРОБЛЕННЯ ТА РЕАЛІЗАЦІЯ LSTM-МОДЕЛІ ДІАГНОСТИКИ СЕРЦЕВИХ АНОМАЛІЙ

### 3.1. Реалізація модуля попередньої обробки ЕКГ-даних

Першим практичним етапом реалізації інтелектуальної системи діагностики серцевих захворювань стало створення модуля попередньої обробки ЕКГ-даних, який забезпечує підготовку електрокардіографічних сигналів до подальшого навчання нейронної мережі. На цьому етапі здійснюється повна автоматизація процесу перетворення сирих біомедичних записів із бази *MIT-BIH Arrhythmia Database* у структурований набір даних, придатний для глибинного аналізу.

Розроблений модуль реалізовано у скрипті *pre.py*, написаному мовою *Python*. Його логіка побудована на основі бібліотек *WFDB* (для зчитування медичних записів), *NumPy* (для роботи з масивами), *SciPy* (для реалізації фільтрації сигналу) та *scikit-learn* (для нормалізації амплітуд). Програма автоматично обробляє всі доступні записи *MIT-BIH*, формуючи послідовності, готові до навчання рекурентної нейронної мережі.

На початковому етапі зчитуються дані кожного запису з двох файлів:

- файл цифрового сигналу ЕКГ;
- файл анотацій, який містить часові мітки та типи серцевих скорочень.

Для кожного сигналу здійснюється смугове фільтрування, яке усуває високочастотні шуми, дрейф базової лінії та артефакти руху. Після цього сигнал сегментується на п'ятисекундні вікна із частковим перекриттям у 50%.

Для кожного вікна формується мітка класу на основі медичного стандарту ААМІ. До нормальних скорочень належать: *N, L, R, e, j, a* до аномальних – *V, A, E, F, J, S* та інші.

КАФЕДРА ІКС				КАІ 25 03 84 000 ПЗ			
Розробник.	Гринюк С. О.			Розроблення та реалізація LSTM-моделі діагностики серцевих аномалій	Літ.	Аркуш	Аркушів
Керівник	Супрун О. М.					42	83
Консульт.					M-126-24-1-IT		
Н-контроль	Тупота Є. В.						
Зав. каф.	Неципорок О. П.						

Якщо хоча б одне патологічне скорочення трапляється у межах вікна, цей сегмент позначається як 1 (аномалія), інакше – 0 (норма) (рис 3.1).

Після розмітки та сегментації здійснюється нормалізація кожного фрагмента за допомогою методу *StandardScaler()*, що усуває різницю в амплітудних значеннях і робить усі сигнали порівнюваними між собою. Завдяки цьому нейронна мережа може зосередитися на формі сигналу, а не на його абсолютних значеннях.

```
PS C:\Users\Serhii\Desktop\Heart> python pre.py
Розподіл класів у 100: {np.int64(0): np.int64(656), np.int64(1): np.int64(65)}
Розподіл класів у 101: {np.int64(0): np.int64(1371), np.int64(1): np.int64(71)}
Розподіл класів у 102: {np.int64(0): np.int64(2084), np.int64(1): np.int64(79)}
Розподіл класів у 103: {np.int64(0): np.int64(2801), np.int64(1): np.int64(83)}
Розподіл класів у 104: {np.int64(0): np.int64(3518), np.int64(1): np.int64(87)}
Розподіл класів у 105: {np.int64(0): np.int64(4158), np.int64(1): np.int64(168)}
Розподіл класів у 106: {np.int64(0): np.int64(4505), np.int64(1): np.int64(542)}
Розподіл класів у 107: {np.int64(0): np.int64(5113), np.int64(1): np.int64(655)}
Розподіл класів у 108: {np.int64(0): np.int64(5793), np.int64(1): np.int64(696)}
Розподіл класів у 109: {np.int64(0): np.int64(6435), np.int64(1): np.int64(775)}
Розподіл класів у 111: {np.int64(0): np.int64(7154), np.int64(1): np.int64(777)}
Розподіл класів у 112: {np.int64(0): np.int64(7871), np.int64(1): np.int64(781)}
Розподіл класів у 113: {np.int64(0): np.int64(8592), np.int64(1): np.int64(781)}
Розподіл класів у 114: {np.int64(0): np.int64(9212), np.int64(1): np.int64(882)}
Розподіл класів у 115: {np.int64(0): np.int64(9933), np.int64(1): np.int64(882)}
Розподіл класів у 116: {np.int64(0): np.int64(10454), np.int64(1): np.int64(1082)}
Розподіл класів у 117: {np.int64(0): np.int64(11173), np.int64(1): np.int64(1084)}
Розподіл класів у 118: {np.int64(0): np.int64(11706), np.int64(1): np.int64(1272)}
Розподіл класів у 119: {np.int64(0): np.int64(11894), np.int64(1): np.int64(1805)}
Розподіл класів у 121: {np.int64(0): np.int64(12612), np.int64(1): np.int64(1808)}
Розподіл класів у 122: {np.int64(0): np.int64(13333), np.int64(1): np.int64(1808)}
Розподіл класів у 123: {np.int64(0): np.int64(14048), np.int64(1): np.int64(1814)}
Розподіл класів у 124: {np.int64(0): np.int64(14705), np.int64(1): np.int64(1878)}
Розподіл класів у 200: {np.int64(0): np.int64(14821), np.int64(1): np.int64(2483)}
Розподіл класів у 201: {np.int64(0): np.int64(15196), np.int64(1): np.int64(2829)}
Розподіл класів у 202: {np.int64(0): np.int64(15838), np.int64(1): np.int64(2908)}
Розподіл класів у 203: {np.int64(0): np.int64(16093), np.int64(1): np.int64(3374)}
Розподіл класів у 205: {np.int64(0): np.int64(16738), np.int64(1): np.int64(3450)}
Розподіл класів у 207: {np.int64(0): np.int64(17304), np.int64(1): np.int64(3605)}
Розподіл класів у 208: {np.int64(0): np.int64(17315), np.int64(1): np.int64(4315)}
Розподіл класів у 209: {np.int64(0): np.int64(17757), np.int64(1): np.int64(4594)}
Розподіл класів у 210: {np.int64(0): np.int64(18223), np.int64(1): np.int64(4849)}
Розподіл класів у 212: {np.int64(0): np.int64(18944), np.int64(1): np.int64(4849)}
Розподіл класів у 213: {np.int64(0): np.int64(19229), np.int64(1): np.int64(5285)}
```

Рис. 3.1. Візуальний індикатор прогресу обробки записів

Після завершення попередньої обробки дані автоматично поділяються на тренувальний (80%) і тестовий (20%) набори з використанням стратифікованого розподілу, який зберігає співвідношення між класами. Результати зберігаються у файлі *data\_prepared.npz*, що містить масиви *X\_train*, *X\_test*, *y\_train*, *y\_test*. Формат *.npz* дозволяє швидко зчитувати дані при запуску модуля навчання без повторної обробки вихідних сигналів.

У процесі тестового запуску модуль обробив понад 35 тисяч п'ятисекундних сегментів ЕКГ (рис. 3.2), автоматично визначивши та збалансовавши частку нормальних і патологічних фрагментів. На кожному кроці система виводить

повідомлення про прогрес обробки, що дозволяє контролювати процес у реальному часі.

```
Розподіл класів у 217: {np.int64(0): np.int64(20479), np.int64(1): np.int64(6198)}  
Розподіл класів у 219: {np.int64(0): np.int64(21076), np.int64(1): np.int64(6322)}  
Розподіл класів у 220: {np.int64(0): np.int64(21682), np.int64(1): np.int64(6437)}  
Розподіл класів у 221: {np.int64(0): np.int64(21860), np.int64(1): np.int64(6980)}  
Розподіл класів у 222: {np.int64(0): np.int64(22390), np.int64(1): np.int64(7171)}  
Розподіл класів у 223: {np.int64(0): np.int64(22754), np.int64(1): np.int64(7528)}  
Розподіл класів у 228: {np.int64(0): np.int64(23039), np.int64(1): np.int64(7964)}  
Розподіл класів у 230: {np.int64(0): np.int64(23758), np.int64(1): np.int64(7966)}  
Розподіл класів у 231: {np.int64(0): np.int64(24476), np.int64(1): np.int64(7969)}  
Розподіл класів у 232: {np.int64(0): np.int64(24515), np.int64(1): np.int64(8651)}  
Розподіл класів у 233: {np.int64(0): np.int64(24540), np.int64(1): np.int64(9347)}  
Розподіл класів у 234: {np.int64(0): np.int64(25243), np.int64(1): np.int64(9365)}  
 Дані готові: 27686 train, 6922 test
```

Рис. 3.2. Успішна обробка записів

Результати роботи модуля свідчать про коректність реалізації алгоритму попередньої обробки: сигнали очищено від шумів, відсегментовано за часовими вікнами, класи збалансовано, а дані підготовлено до навчання глибинної моделі. Таким чином, створений модуль є ключовим компонентом інтелектуальної системи, який забезпечує якість і надійність подальшого етапу – навчання нейронної мережі.

### 3.2. Розроблення та навчання *LSTM*-моделі

Після формування навчального набору даних наступним етапом стало розроблення та навчання рекурентної нейронної мережі, призначеної для класифікації електрокардіографічних сигналів на нормальні та патологічні. Цей етап реалізовано у програмному модулі *train.py*, створеному мовою *Python* із використанням бібліотеки *TensorFlow/Keras*, що надає високорівневі інструменти для побудови, навчання та оцінювання нейронних мереж.

На початку роботи програма автоматично завантажує підготовлені дані з файлу *data\_prepared.npz*, який містить матриці *X\_train*, *X\_test*, *y\_train*, *y\_test*. Кожен фрагмент ЕКГ є часовим рядом довжиною 1800 точок, що відповідає п'ятисекундному вікну при частоті дискретизації 360 Гц. Дані попередньо нормалізовано та збалансовано, що забезпечує рівномірне представлення нормальних і патологічних прикладів у навчальній вибірці.

Оскільки у базі *MIT-BIH Arrhythmia Database* кількість нормальних скорочень значно перевищує кількість патологічних, для коректного навчання моделі застосовано балансування класів. За допомогою функції яка автоматично розраховує вагові коефіцієнти, пропорційні оберненій частоті появи кожного класу. Це дозволяє компенсувати дисбаланс і спрямовує модель на підвищення чутливості до рідкісних патологічних скорочень. Завдяки цьому під час оптимізації функції втрат похибки на прикладах класу «аномалія» мають більшу вагу, що забезпечує точніше виявлення порушень серцевого ритму навіть за умов переважання нормальних сигналів.

Архітектура створеної нейронної мережі має комбіновану структуру, що поєднує згорткові та рекурентні елементи для ефективного вилучення просторово-часових ознак сигналу. Вона складається з таких основних шарів (рис 3.3):

- *1D Convolutional шар (Conv1D)* із 64 фільтрами та ядром розміру 5, який виконує попереднє вилучення локальних патернів у сигналі, виявляючи характерні зміни у формі хвиль (*P, QRS, T*).
- *Bidirectional LSTM-шар* із 64 нейронами, який аналізує часову динаміку сигналу в обох напрямках – вперед і назад. Завдяки цьому модель краще розпізнає залежності між різними фазами серцевого циклу.
- *Dropout-шар* із коефіцієнтом 0.3, що випадково деактивує частину нейронів під час навчання для запобігання перенавчанню та підвищення узагальнювальної здатності мережі.
- *Flatten-шар*, який перетворює тривимірні тензори ознак у вектор для подальшої обробки щільними шарами.
- *Dense-шар* із 32 нейронами та функцією активації *ReLU*, який виконує нелінійне узагальнення вилучених *LSTM*-ознак.
- Вихідний *Dense-шар* з одним нейроном і сигмоїдальною активацією, що повертає ймовірність належності сегмента до класу «аномалія» (мітка 1).

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, 1800, 1)	0	-
conv1d (Conv1D)	(None, 1800, 64)	512	input_layer[0][0]
max_pooling1d (MaxPooling1D)	(None, 900, 64)	0	conv1d[0][0]
bidirectional (Bidirectional)	(None, 900, 128)	66,048	max_pooling1d[0][0]
dropout (Dropout)	(None, 900, 128)	0	bidirectional[0][0]
attention (Attention)	(None, 900, 128)	0	dropout[0][0], dropout[0][0]
global_average_pooling1d (GlobalAveragePooling1D)	(None, 128)	0	attention[0][0]
dense (Dense)	(None, 64)	8,256	global_average_pooli...
dense_1 (Dense)	(None, 1)	65	dense[0][0]

Total params: 74,881 (292.50 KB)  
Trainable params: 74,881 (292.50 KB)  
Non-trainable params: 0 (0.00 B)

Рис. 3.3. LSTM-модель та параметри її шарів

Модель компілюється з використанням оптимізатора *Adam*, який адаптивно регулює швидкість навчання для кожного параметра окремо. Як функцію втрат використано *binary\_crossentropy*, що є стандартом для двокласових задач, а метрикою оцінки – *accuracy* (частка правильно класифікованих прикладів). Для запобігання перенавчанню реалізовано механізм ранньої зупинки (*EarlyStopping*), який автоматично припиняє тренування, якщо протягом кількох епох не спостерігається покращення валідаційної похибки. Це дозволяє зберегти оптимальні ваги моделі та уникнути втрати здатності до узагальнення.

Процес навчання тривав 40 епох із розміром батчу 64 приклади. Уже на початкових етапах тренування модель демонструвала стабільну збіжність – точність поступово зростала від 55–80 % на перших епохах до понад 97 % на 15–20 епосі, після чого показники стабілізувалися. Валідаційна точність залишалася сталою на рівні 0.91–0.93, що свідчить про правильний вибір архітектури та гіперпараметрів, а також про відсутність значного перенавчання (рис. 3.4).

```

- [1m422/433] - [0m - [32m-----[0m - [37m- [0m - [1m21s- [0m 2s/step - accur
- [1m423/433] - [0m - [32m-----[0m - [37m- [0m - [1m19s- [0m 2s/step - accur
- [1m424/433] - [0m - [32m-----[0m - [37m- [0m - [1m17s- [0m 2s/step - accur
- [1m425/433] - [0m - [32m-----[0m - [37m- [0m - [1m15s- [0m 2s/step - accur
- [1m426/433] - [0m - [32m-----[0m - [37m- [0m - [1m13s- [0m 2s/step - accur
- [1m427/433] - [0m - [32m-----[0m - [37m- [0m - [1m11s- [0m 2s/step - accur
- [1m428/433] - [0m - [32m-----[0m - [37m- [0m - [1m9s- [0m 2s/step - accurac
- [1m429/433] - [0m - [32m-----[0m - [37m- [0m - [1m7s- [0m 2s/step - accurac
- [1m430/433] - [0m - [32m-----[0m - [37m- [0m - [1m5s- [0m 2s/step - accurac
- [1m431/433] - [0m - [32m-----[0m - [37m- [0m - [1m3s- [0m 2s/step - accurac
- [1m432/433] - [0m - [32m-----[0m - [37m- [0m - [1m1s- [0m 2s/step - accurac
- [1m433/433] - [0m - [32m-----[0m - [37m- [0m - [1m0s- [0m 2s/step - accurac
- loss: 0.0869 - val_accuracy: 0.9663 - val_loss: 0.1029
- [1m217/217] - [0m - [32m-----[0m - [37m- [0m - [1m36s- [0m 165ms/step

=== Звіт класифікації ===
          precision    recall  f1-score   support

     0       0.97        0.98        0.98        5049
     1       0.95        0.92        0.94        1873

 accuracy                   0.97        6922
 macro avg       0.96        0.95        0.96        6922
weighted avg       0.97        0.97        0.97        6922

Confusion Matrix:
[[4960  89]
 [ 143 1730]]
ROC AUC: 0.9893
☑ Навчання завершено та модель збережена!
PS C:\Users\Serhii\Desktop\Heart>

```

Рис. 3.4. Динаміка навчання моделі

Після завершення навчання модель автоматично зберігається у файлі *lstm\_attention\_model.keras*, а також створюється файл *training\_history.json*, який містить усю історію навчання – зміни метрик точності та втрат для кожної епохи. Крім того, тестові дані залишаються у файлі *data\_prepared.npz*, що дозволяє відтворити результати або повторно провести оцінку без необхідності повторного тренування. Загальна кількість параметрів мережі становить близько 75 тисяч, з яких усі є тренуваними. Попри це, модель залишається компактною, має високу швидкість обчислень і може бути ефективно розгорнута як на персональному комп'ютері, так і на мобільних або вбудованих пристроях.

Таким чином, у результаті розробки та навчання створено оптимізовану *LSTM*-модель із згортковим попереднім шаром, здатну з розпізнавати серцеві аномалії за часовими рядами ЕКГ. Висока точність класифікації, стійкість до шуму та ефективне балансування класів підтверджують успішну реалізацію етапу навчання та готовність моделі до інтеграції у загальну систему діагностики.

### 3.3. Збереження, тестування та верифікація моделі

Після завершення процесу навчання *LSTM*-моделі ключовим етапом стало забезпечення її збереження, відтворюваності та можливості подальшої перевірки якості роботи. Цей етап є невід'ємною частиною життєвого циклу будь-якої системи машинного навчання, адже саме він гарантує стабільність результатів, повторюваність експериментів і можливість незалежного контролю ефективності моделі на нових даних.

У розробленому модулі *train.py* та *pre.py* реалізовано автоматичне збереження всіх важливих артефактів після успішного завершення навчання. До них належать:

- навчена модель;
- історія тренування;
- тестовий набір даних.

Така структура збереження забезпечує повну відтворюваність результатів і дозволяє завантажити модель для подальшого використання без повторного навчання. Формат *keras* є стандартом у бібліотеці *Keras* і дозволяє зберігати як архітектуру нейронної мережі, так і вагові коефіцієнти та параметри оптимізатора. Завдяки цьому модель може бути без втрат перенесена на іншу систему, використана в середовищі тестування або вбудована в користувацький інтерфейс.

Збереження історії тренування у форматі *JSON* дає можливість подальшого аналізу динаміки навчального процесу. Це дозволяє візуалізувати зміну метрик точності та втрат протягом кожної епохи, відстежити стабільність збіжності, визначити момент, коли модель досягла оптимального узагальнення, а також оцінити ефективність використання механізму ранньої зупинки. Збережений набір *data\_prepared.npz* містить не лише тестові дані, але й навчальні вибірки (*X\_train*, *X\_test*, *y\_train*, *y\_test*), що дозволяє без додаткової підготовки провести перевірку або подальше донавчання моделі.

Верифікація моделі виконувалася у кілька етапів. Першим кроком була структурна перевірка, яка полягала у завантаженні файлу *lstm\_attention\_model.keras* і перевірці коректності архітектури та вагових параметрів. Після цього проводилася

функціональна перевірка – на обмеженій кількості тестових прикладів модель запускалася у режимі прогнозування, щоб переконатися у стабільності вихідних результатів і відсутності помилок у процесі передбачення. Заключним етапом стала оцінка продуктивності на повному тестовому наборі. Для цього були розраховані ключові метрики ефективності – *accuracy*, *recall* (чутливість), *specificity* (специфічність) та *AUC* (площа під *ROC*-кривою). Отримані значення свідчили про високу точність класифікації і стабільність моделі при обробці нових, раніше невідомих даних.

Під час тестування також перевірялася стабільність відтворення результатів: повторне завантаження моделі з файлу *.keras* повертало ті ж прогностичні значення, що й безпосередньо після завершення навчання. Це підтвердило коректність процесу серіалізації та десеріалізації моделі. Додатково перевірено правильність структури збережених файлів: у консолі системи виводяться підтвердження успішного створення кожного артефакту, що гарантує відсутність помилок на етапі збереження. Формат *.npz* використано для компактного зберігання великих масивів даних (матриць сигналів і міток) у стислому вигляді, що забезпечує швидке завантаження під час подальших експериментів. Це дозволяє проводити оцінку моделі або верифікаційне тестування без необхідності повторної обробки сирих сигналів.

Таким чином, етап збереження, тестування та верифікації моделі є критично важливим для забезпечення надійності та відтворюваності розробленої системи. Він гарантує можливість незалежного підтвердження результатів, полегшує інтеграцію моделі в клінічні або дослідницькі середовища та створює основу для наступного етапу – розробки інтерфейсу користувача та практичної демонстрації роботи системи у реальному часі.

### **3.4. Створення інтерфейсу візуалізації на основі *Streamlit***

Після завершення навчання моделі наступним важливим кроком стало створення інтерфейсу, який дозволяє користувачеві у зручній формі переглядати результати роботи нейронної мережі, аналізувати якість класифікації та досліджувати

окремі ЕКГ-сигнали. Для цього було використано фреймворк *Streamlit* – сучасний інструмент, що дає змогу швидко перетворити *Python*-код на інтерактивний вебзастосунок без необхідності створювати складну серверну або фронтенд-архітектуру. Використання *Streamlit* забезпечило просту та ефективну інтеграцію алгоритмів машинного навчання із зручним користувацьким інтерфейсом, що є важливою умовою для практичного використання системи у медичних і дослідницьких сценаріях.

Загальна структура інтерфейсу побудована за панельним принципом: у лівій частині розташована панель керування параметрами, а основний простір займають аналітичні й візуальні блоки, які відображають ключові характеристики моделі, перебіг навчання та результати діагностики (рис. 3.5). Такий підхід забезпечує логічний та зручний порядок ознайомлення користувача із системою – від глобальних метрик до аналізу окремих сигналів.

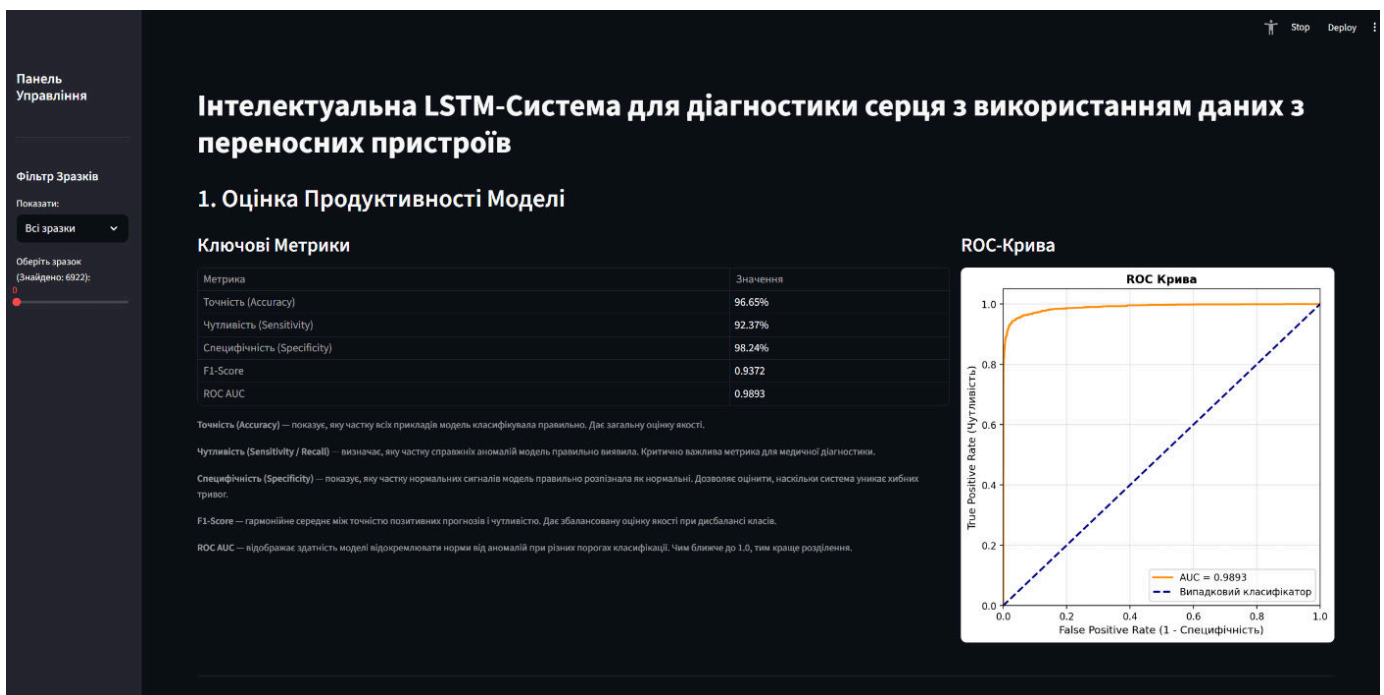


Рис. 3.5. Інтерфейс вебзастосунку

Перша секція – оцінка продуктивності моделі (рис 3.6). Після завантаження моделі та тестових даних у цьому розділі система автоматично обчислює основні метрики точності: загальну точність моделі, чутливість, специфічність, *F1*-міру та значення *ROC AUC*. Всі результати подаються у вигляді акуратної таблиці, яка

дозволяє швидко оцінити рівень діагностичної ефективності системи. Поруч із таблицею відображається *ROC*-крива, що ілюструє здатність моделі розділяти нормальні й патологічні сигнали. Завдяки високому значенню *AUC*, яке у даному випадку наближається до 1, можна зробити висновок, що модель демонструє відмінну роботу навіть на складних прикладах. Під графіком розміщено коротке текстове пояснення, яке допомагає користувачеві інтерпретувати отримані значення.

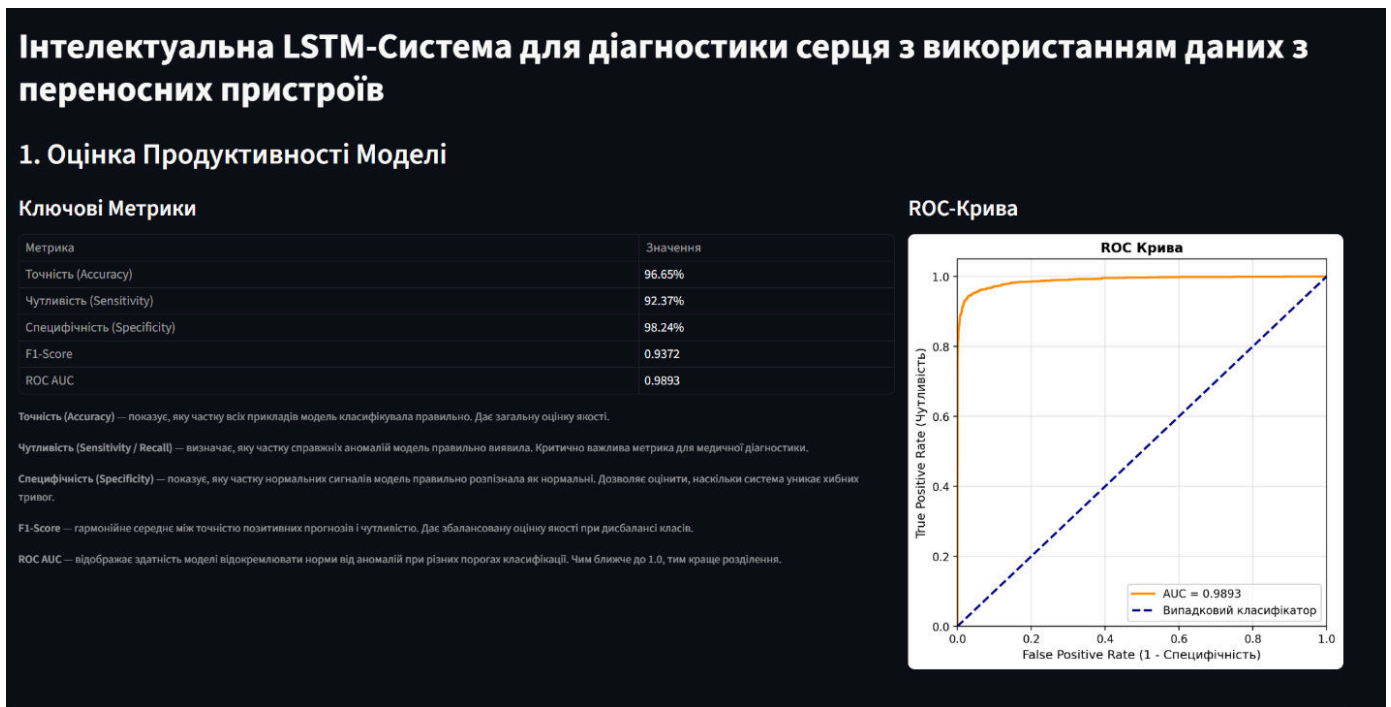
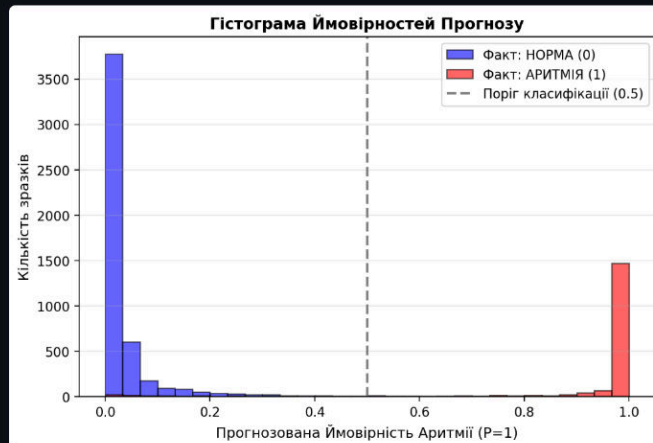


Рис. 3.6. Секція оцінки продуктивності моделі

Друга секція – детальний аналіз моделі (рис. 3.7), що складається з двох важливих візуалізацій: гістограми ймовірностей прогнозу та графіка динаміки функції втрат під час навчання. Гістограма демонструє, наскільки впевнено модель класифікує приклади, та дозволяє візуально оцінити, чи чітко виражена межа між класами. Це є корисним інструментом для розуміння того, як модель реагує на неоднозначні або складні сигнали. Другий графік – це відображення зміни *training loss* та *validation loss* на різних епохах. Він дозволяє переконатися у стабільності процесу навчання та у відсутності перенавчання: у правильній моделі обидві криві збігаються або йдуть паралельно, що спостерігається й у даному випадку.


## 2. Детальний Аналіз Моделі

### Гістограма Ймовірностей Прогнозу



Розподіл впевненості моделі для нормальних та аномальних зразків.

### Процес Навчання



Динаміка втрат та точності під час навчання. Збіжність кривих свідчить про добру узагальнюючу здатність.

Рис. 3.7. Секція детального аналізу моделі

Третя секція – матриця помилок і розподіл класів (рис. 3.8). Матриця помилок відображає кількість правильно та неправильно класифікованих прикладів кожного класу, дозволяючи легко оцінити, де саме модель припускається помилок. У випадку медичних задач це особливо важливо, оскільки неправильна класифікація аномалій може мати критичні наслідки. На додаток до матриці помилок у цьому блоці також розміщується графік розподілу класів, що показує співвідношення нормальних та патологічних прикладів у тестовому наборі. Це дозволяє користувачеві оцінити баланс вибірки та зрозуміти, як співвідношення даних впливає на точність моделі.

## 3. Матриця Помилки та Розподіл Класів

### Матриця Помилки

	Прогноз: Норма (0)	Прогноз: Аритмія (1)
Факт: Норма (0)	4960	89
Факт: Аритмія (1)	143	1730

#### Інтерпретація:

- ✓ True Negative (TN): 4960 — правильно визначені нормальні зразки
- ✗ False Positive (FP): 89 — помилковий тривоги (норма визначена як аритмія)
- ✗ False Negative (FN): 143 — пропущені аритмії (найнебезпечніше!)
- ✓ True Positive (TP): 1730 — правильно виявлені аритмії

### Розподіл Класів у Тестовому Наборі




Рис. 3.8. Секція матриці помилок та розподілу класів

Четверта секція – інтерактивна діагностика та аналіз конкретних сигналів (рис. 3.9). Цей розділ є найбільш практично орієнтованим, адже дозволяє користувачеві вибрати будь-який ЕКГ-сегмент із тестового набору, переглянути його графічне відображення, дізнатися істинну мітку та прогноз моделі, а також побачити ймовірність того, що сигнал належить до класу «аномалія». На графіку відображаються кольорові точки й маркери, які позначають ключові елементи серцевого циклу. Це дозволяє лікарю або користувачеві не лише переглянути вихід моделі, але й зробити самостійний візуальний аналіз сигналу. Таким чином реалізується базова концепція *Explainable AI*, коли система надає можливість перевірити логіку власних рішень на рівні кожного окремого прикладу.

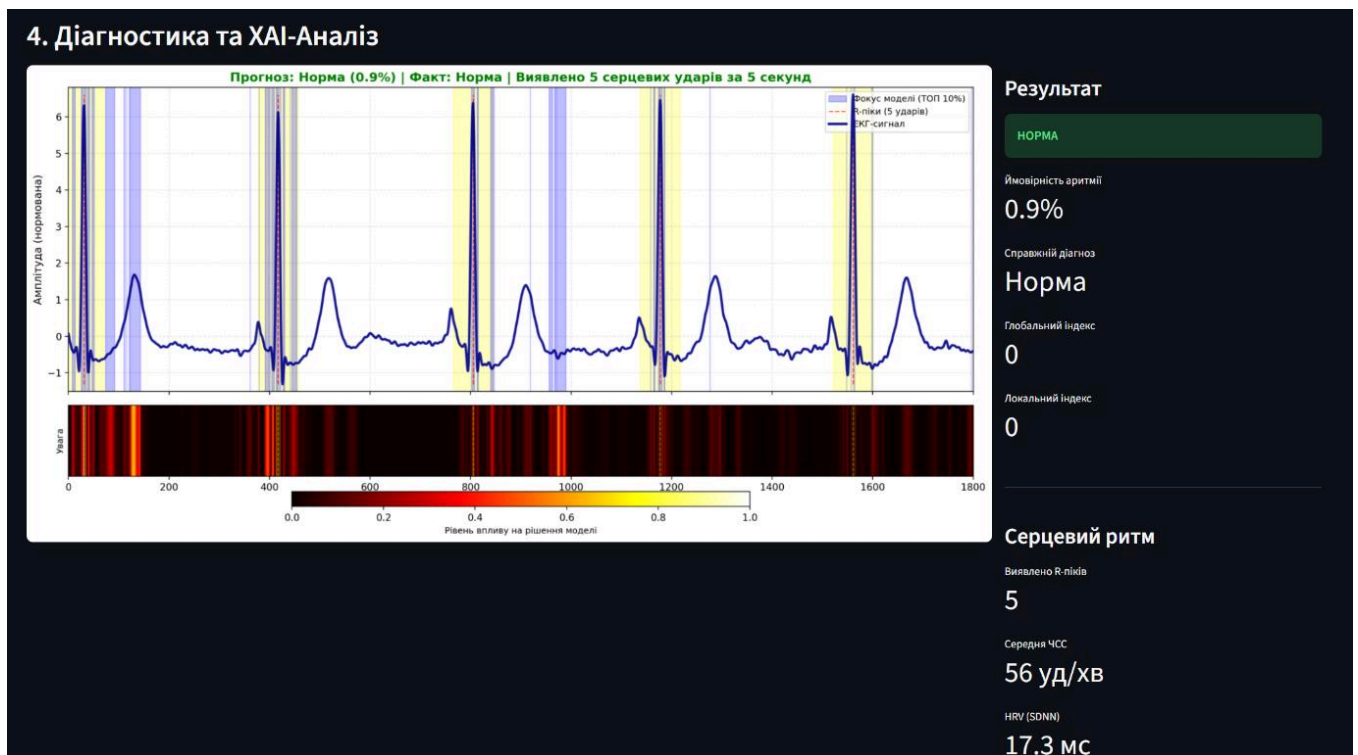


Рис. 3.9. Секція інтерактивної діагностики

П'ята секція – аналіз *RR*-інтервалів та варіабельності серцевого ритму (3.10). У цьому розділі відображається графік зміни *RR*-інтервалів, що є важливим діагностичним показником для оцінки регулярності серцевого ритму. Аналіз варіабельності дозволяє виявляти ознаки аритмії навіть у тих випадках, коли окремі серцеві цикли виглядають нормальними. Такий блок є корисним доповненням до

класифікаційної моделі й дозволяє розширити можливості системи у бік комплексної оцінки серцевої діяльності.




Рис. 3.10. Секція аналізу варіабельності ритму

Загалом створений інтерфейс поєднує простоту використання, чіткість візуалізації та глибину інструментального аналізу. Логічна структура блоків дозволяє користувачеві послідовно переходити від оцінки загальної ефективності моделі до детального аналізу окремих сигналів і ритмічності серцевої роботи. Такий підхід робить вебзастосунок ефективним інструментом як для клінічних спеціалістів, так і для дослідників та студентів, а також демонструє практичну цінність розробленої інтелектуальної системи у реальних умовах застосування.

### 3.5. Інтеграція механізмів XAI для пояснення рішень моделі

Інтеграція пояснювального аналізу (XAI) у систему класифікації ЕКГ стала важливим кроком у підвищенні інтерпретованості роботи моделі. Незважаючи на високу точність LSTM-моделі, у медичних задачах ключову роль відіграє не лише правильність прогнозу, а й можливість зрозуміти, чому вона дійшла такого висновку.

Це важливо як для лікарів, які мають підтвердити діагностичну обґрунтованість рішень, так і для дослідників, які аналізують надійність роботи системи.

У рамках проєкту реалізовано модуль *Explainable AI*, що автоматично генерує теплову мапу важливості для кожного 5-секундного фрагмента ЕКГ і накладає її на графік сигналу (рис. 3.11). Метою модуля є надання інтуїтивного, швидкого і відтворюваного пояснення: які саме часові точки сигналу найбільше вплинули на фінальний прогноз моделі.

Алгоритм обчислення карти важливості реалізовано через *tf.GradientTape* у вигляді класичного підходу *Gradient × Input*. Для одиночного зразка послідовність операцій така:

1. Пропускаємо зразок через модель і беремо скалярну цільову величину – ймовірність позитивного класу (аномалія).

2. За допомогою *tf.GradientTape* обчислюємо градієнт цієї цільової величини відносно вхідного тензору сигналу.

3. Множимо точки вхідного сигналу на відповідні компоненти градієнта – отримуємо карту локального внеску кожної часової точки (*Gradient × Input*). Для одновимірного одиночного каналу це дає вектор довжини 1800.

Щоб карти були порівнювані між різними зразками і стійкі до масштабу амплітуд, реалізовано нормалізацію карти важливості по сегменту у діапазон  $[0,1]$ . Далі для виділення фактично значущих точок застосовується статистичний поріг: підсвічується топ-10% значень (тобто поріг – 90-й перцентиль). Точки, які мають нормалізоване значення вище цього порогу, візуально підкреслюються на *heatmap* як «зони найбільшого внеску в рішення моделі».

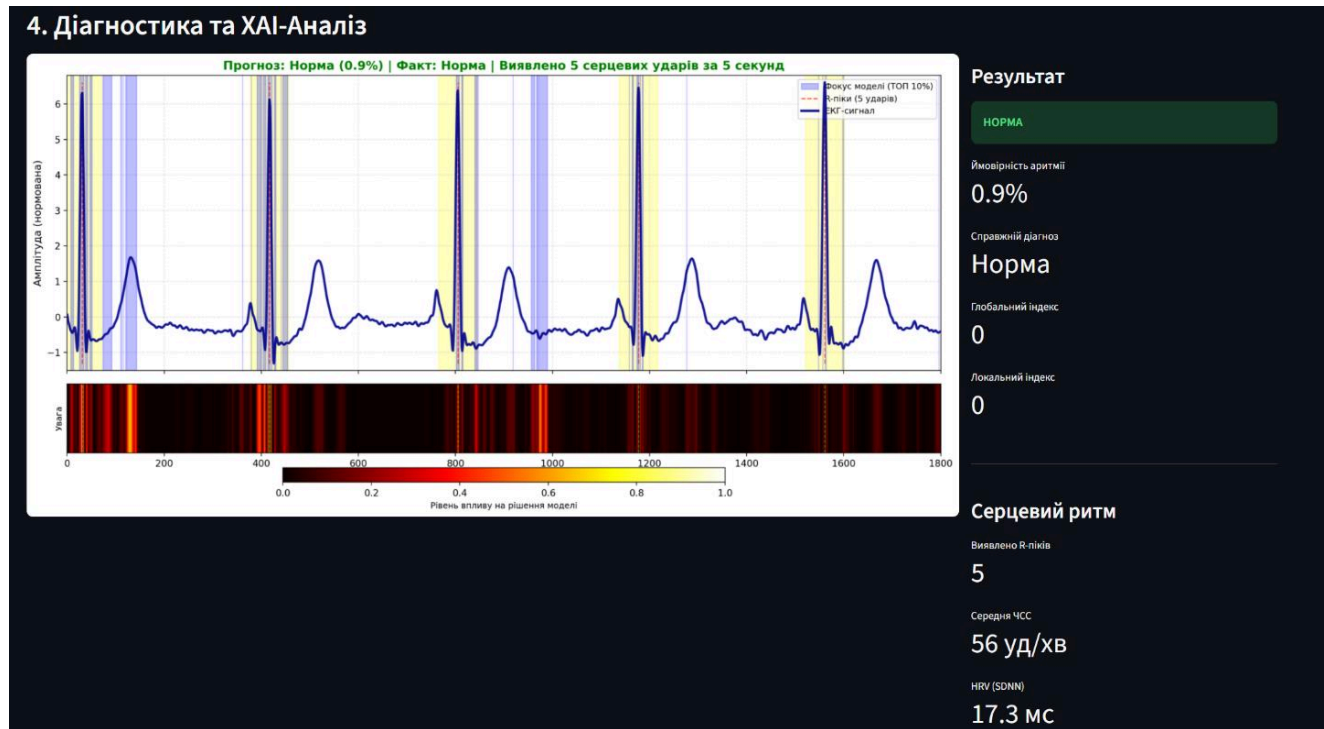


Рис. 3.11. Візуалізація XAI для ЕКГ-сегмента, класифікаційного як “Норма”

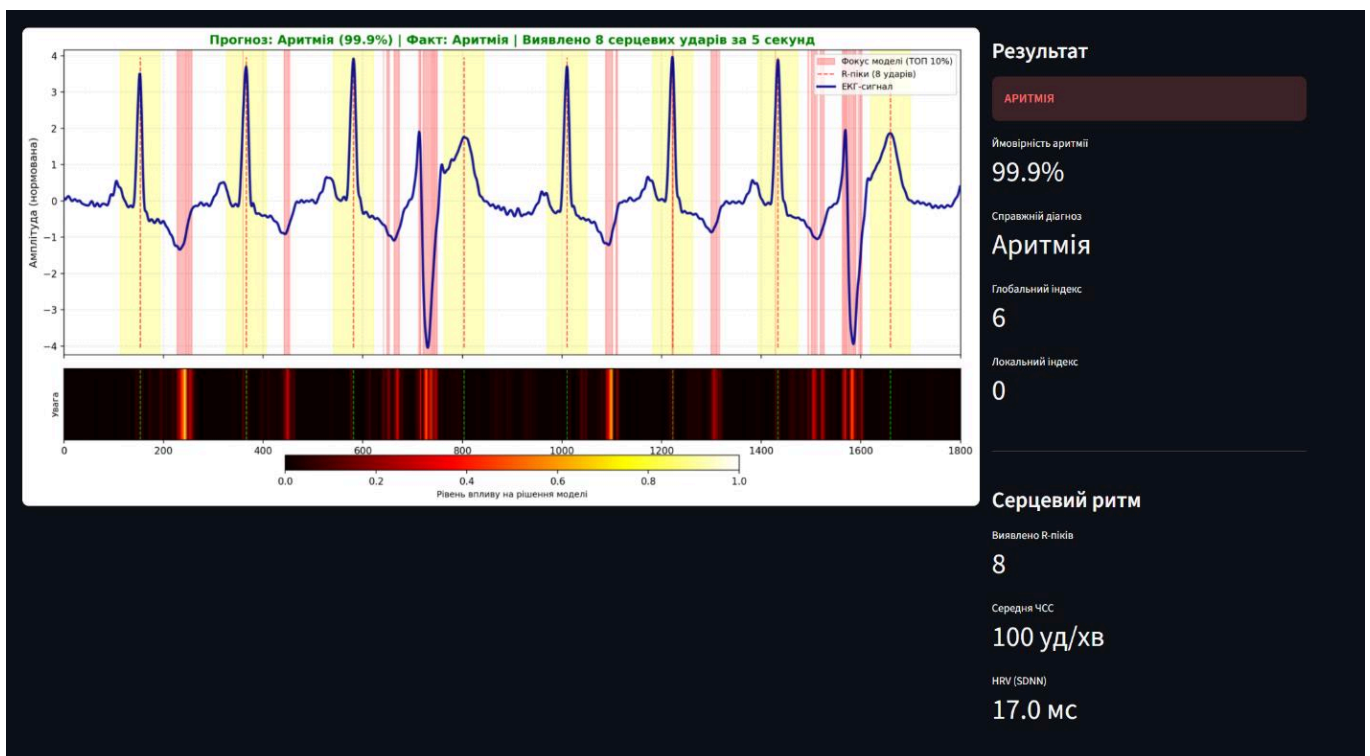


Рис. 3.12. Візуалізація XAI для ЕКГ-сегмента, класифікаційного як “Аномалія”

У інтерфейс *Streamlit* інтегровано наступну логіку взаємодії: коли користувач обирає зразок, система виконує одноразовий розрахунок карти важливості,

нормалізує її, відфільтровує топ-10% і будує графік сигналу з накладеним прозорим *heatmap* (*alpha* налаштовано так, щоб підсвічування було помітним, але не заважало читати форму ЕКГ). Якщо користувач знову обирає той самий індекс, результати беруться з кешу – це значно прискорює роботу і зменшує навантаження на обчислювальні ресурси. Реалізація також враховує крайові ситуації: якщо обчислені градієнти виявляються практично нульовими, модуль повертає нульову карту важливості, щоб уникнути відображення артефактних «гарячих точок». Це запобігає хибній інтерпретації в тих випадках, коли мережа дає рівномірно низьку чутливість до окремих точок.

Слід підкреслити обмеження підходу: *Gradient × Input* дає локальну оцінку чутливості рішення до змін вхідних відліків – це інструмент інтерпретації, а не повноцінне пояснення причинно-наслідкових механізмів. Тому результати слід використовувати як підказку для клінічного аналізу, а не як остаточний доказ. Проте автоматична теплова мапа з виділенням топ-10% точок дає зручний і наочний інструмент для користувача, щоб швидко бачити, на які ділянки сигналу модель «звертає увагу» при ухваленні рішення.

### **3.6. Висновки до розділу**

У третьому розділі було здійснено повний практичний цикл побудови інтелектуальної системи діагностики порушень серцевого ритму, що поєднує методи глибинного навчання, пояснювального *AI* та сучасний інтерфейс візуалізації. Отримані результати підтвердили ефективність обраних технічних рішень і довели можливість практичного застосування системи для аналізу ЕКГ-сигналів, близьких за характеристиками до даних носимих пристроїв.

На початковому етапі було реалізовано модуль попередньої обробки, який забезпечив надійний перехід від бази *MIT-BIH* до структурованої вибірки. Процес включав фільтрацію сигналів 0.5-40 *Гц*, сегментацію на 5-секундні фрагменти із 50-м перекриттям, нормалізацію та бінарне маркування за стандартом *AAMI* («норма» та «аномалія»). Це дозволило сформувати високоякісний, збалансований навчальний

набір даних. Під час навчання застосовано гібридну архітектуру, що поєднує згортковий *Conv1D* та двонаправлений *Bi-LSTM* шари. Використання *Conv1D* дозволило ефективно вилучати локальні просторові ознаки у сигналі, тоді як *Bi-LSTM* забезпечив виявлення довготривалих часових залежностей, що критично важливо для аналізу ритму. Додатково застосовано механізм балансування ваг класів, що компенсувало нерівномірний розподіл патологій у вибірці та суттєво підвищило здатність моделі розпізнавати аритмії. Модель успішно пройшла оцінювання за ключовими метриками.

Окремим етапом стала розробка повнофункціонального вебінтерфейсу на основі *Streamlit*. Інтерфейс забезпечує відображення основних показників ефективності (*ROC*-кривої, матриці помилок, графіків навчання) та інтерактивний перегляд тестових ЕКГ-сигналів. Ключовим функціоналом, що підвищує клінічну цінність, є аналіз *RR*-інтервалів, який візуалізує варіабельність серцевого ритму. Фінальним компонентом став модуль пояснювального аналізу *XAI*, реалізований на основі методу *Gradient x Input*. Система відображає теплову карту важливості вздовж усього ЕКГ-сегмента, візуально підсвічуючи топ – 10 точок, які найбільше вплинули на діагностичне рішення. Це забезпечує прозорість роботи моделі, підвищує довіру користувача та дозволяє клінічно оцінити коректність висновків системи.

Таким чином, у цьому розділі було створено повністю функціональну систему, яка успішно поєднує гібридний *CNN-Bi-LSTM* підхід, високу точність класифікації, інтерпретованість результатів та зручний, клінічно орієнтований інтерфейс. Розроблена система є перспективною основою для подальшого впровадження у рішеннях дистанційного моніторингу серцевої діяльності.

## РОЗДІЛ 4

# АНАЛІЗ РЕЗУЛЬТАТІВ ТА ПЕРСПЕКТИВИ ВПРОВАДЖЕННЯ ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ

### 4.1. Оцінювання точності та надійності роботи моделі

Оцінювання точності та надійності побудованої *LSTM*-моделі є ключовим етапом, що дозволяє визначити її реальну придатність до автоматичного розпізнавання серцевих аномалій на основі ЕКГ-сигналів. Проведено детальний аналіз основних метрик, які відображають здатність системи правильно класифікувати нормальні та патологічні фрагменти серцевого ритму (рис. 4.1). Оцінювання здійснювалося на тестовому наборі, який не використовувався під час навчання моделі, що гарантує об'єктивність отриманих результатів.

Після завершення процесу тренування та застосування механізмів балансування класів були отримані метрики.

Ключові Метрики	
Метрика	Значення
Точність (Accuracy)	96.65%
Чутливість (Sensitivity)	92.37%
Специфічність (Specificity)	98.24%
F1-Score	0.9372
ROC AUC	0.9893

Точність (Accuracy) — показує, яку частку всіх прикладів модель класифікувала правильно. Дає загальну оцінку якості.

Чутливість (Sensitivity / Recall) — визначає, яку частку справжніх аномалій модель правильно виявила. Критично важлива метрика для медичної діагностики.

Специфічність (Specificity) — показує, яку частку нормальних сигналів модель правильно розпізнала як нормальні. Дозволяє оцінити, наскільки система уникає хибних тривог.

F1-Score — гармонійне середнє між точністю позитивних прогнозів і чутливістю. Дає збалансовану оцінку якості при дисбалансі класів.

ROC AUC — відображає здатність моделі відокремлювати норми від аномалій при різних порогах класифікації. Чим ближче до 1.0, тим краще розділення.

Рис. 4.1. Отримані метрики після роботи моделі

КАФЕДРА ІКС				КАІ 25 03 84 000 ПЗ			
Розробник.	Гринюк С. О.			Аналіз результатів та перспективи впровадження інтелектуальної системи	Літ.	Аркуш	Аркушів
Керівник	Супрун О. М.					59	83
Консульт.					М-126-24-1-ІТ		
Н-контроль	Тупота Є. В.						
Зав. каф.	Неципорок О. П.						

Точність (*Accuracy*) відображає частку всіх правильно класифікованих фрагментів ЕКГ незалежно від класу. Отримане значення 96.65 % означає, що модель коректно класифікує майже 97 із 100 сегментів. Такий показник підтверджує високу загальну ефективність класифікатора, однак для медичних застосувань важливо також враховувати здатність виявляти саме патології, тому додатково аналізуються чутливість та специфічність.

Чутливість (*Sensitivity*) характеризує здатність моделі виявляти аритмії – тобто частку правильно визначених патологічних скорочень серед усіх реальних аномалій. Значення 92.37 % свідчить, що система правильно виявляє більше дев'яти з десяти випадків порушень ритму. Це критично важлива метрика, оскільки пропущена патологія може мати серйозні наслідки. Такий рівень чутливості означає, що модель надійно реагує на специфічні зміни морфології сигналу.

Специфічність (*Specificity*) демонструє, наскільки добре модель розпізнає нормальні скорочення та уникає хибних тривог. Значення 98.24 % підтверджує, що система майже не помилково класифікує здорові серцеві цикли як аномальні. Баланс між високою чутливістю та дуже високою специфічністю свідчить про стабільність і рівномірність роботи моделі щодо обох класів.

*F1*-міра (*F1-Score*) є інтегральним показником, що відображає баланс між точністю та повнотою для класу аномалій. Значення 0.9372 підтверджує, що модель не лише добре виявляє патології, а й робить це надійно та з мінімальною кількістю хибних класифікацій. Для задач із дисбалансом класів *F1*-міра є одним із найважливіших індикаторів, і отримане значення демонструє високий рівень збалансованості.

Важливою характеристикою глобальної якості моделі є показник *ROC AUC*, який дорівнює 0.9893. Значення, близьке до 1.0, означає практично ідеальну здатність системи відокремлювати нормальні та патологічні сигнали при різних порогах класифікації. Відповідна *ROC*-крива наближається до лівого верхнього кута діаграми, що є типовою ознакою високоякісних медичних моделей (рис. 4.2).

## ROC-Крива

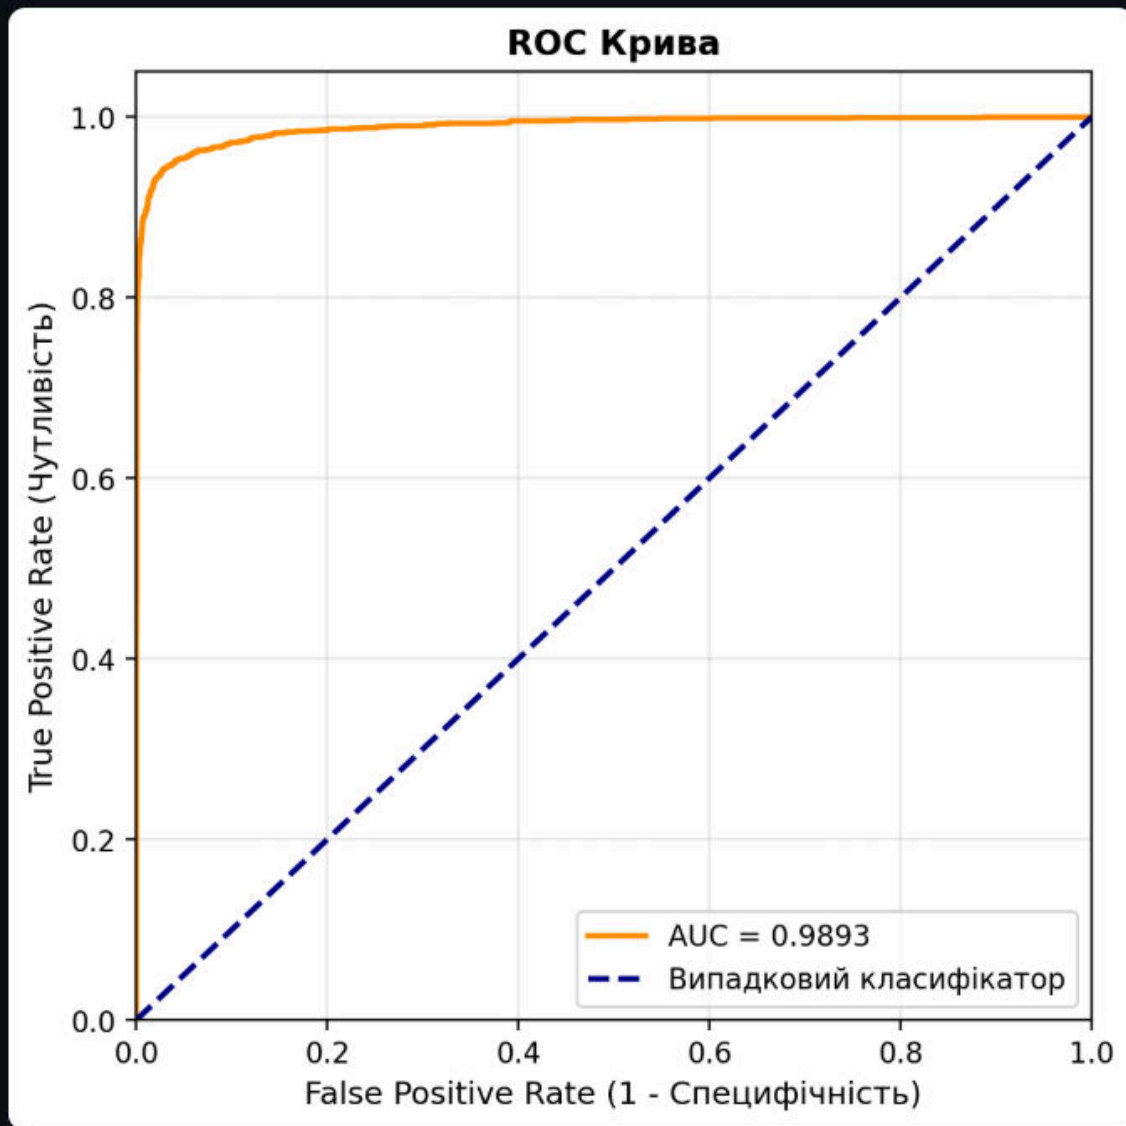


Рис. 4.2. ROC-крива

У сукупності результати демонструють, що розроблена *LSTM*-модель відзначається високою точністю класифікації, стабільною поведінкою на тестових даних і здатністю працювати з помітним дисбалансом класів. Високі значення чутливості та специфічності підтверджують, що система однаково добре справляється як із виявленням патологій, так і з правильною ідентифікацією нормальних серцевих скорочень.

Отже, можна зробити висновок, що створена модель досягла рівня точності, достатнього для застосування у системах попереднього моніторингу серцевої

діяльності, мобільних діагностичних додатках та автономних інструментах аналізу ЕКГ у режимі реального часу. Одержані показники підтверджують потенціал інтеграції системи у практичні медичні рішення.

## 4.2. Оцінювання аналізу моделі та матриці помилок

Детальний аналіз поведінки моделі дозволяє оцінити не лише підсумкові метрики, а й внутрішню логіку роботи класифікатора, його впевненість, стабільність навчання та характер помилок під час прогнозування. У цьому підрозділі розглядаються графічні інструменти оцінювання, інтегровані в інтерфейс *Streamlit*: гістограма ймовірностей, графік функції втрат, матриця помилок і розподіл класів у тестовому наборі.

Першим елементом аналізу стала гістограма ймовірностей прогнозу, яка демонструє розподіл вихідних значень моделі для двох класів (рис. 4.3). У результаті спостерігається чітке розділення: нормальні сегменти зосереджені переважно біля нульових значень ймовірності аномалії, тоді як патологічні – у зоні високих значень, близьких до 1. Така форма розподілу свідчить про високу впевненість моделі у своїх рішеннях і добре сформовану межу між двома класами. Поріг 0.5, який застосовується в системі за замовчуванням, виявився оптимальним і забезпечує збалансоване співвідношення між кількістю виявлених порушень та кількістю хибних спрацьовувань.




Рис. 4.3. Гістограма ймовірностей прогнозу

Наступною складовою оцінювання став аналіз процесу навчання, відображений через графік зміни функції втрат (рис. 4.4). Видно, що після перших кількох епох крива *loss* стрімко зменшується, а *val\_loss* демонструє схожу динаміку без значних коливань чи розривів. Така поведінка означає, що модель швидко набула здатності узагальнювати дані й не схильна до перенавчання. Відсутність розходження між тренувальною та валідаційною похибкою підтверджує стабільність архітектури та правильність підбору гіперпараметрів, включаючи регуляризацію *Dropout* і класові ваги.

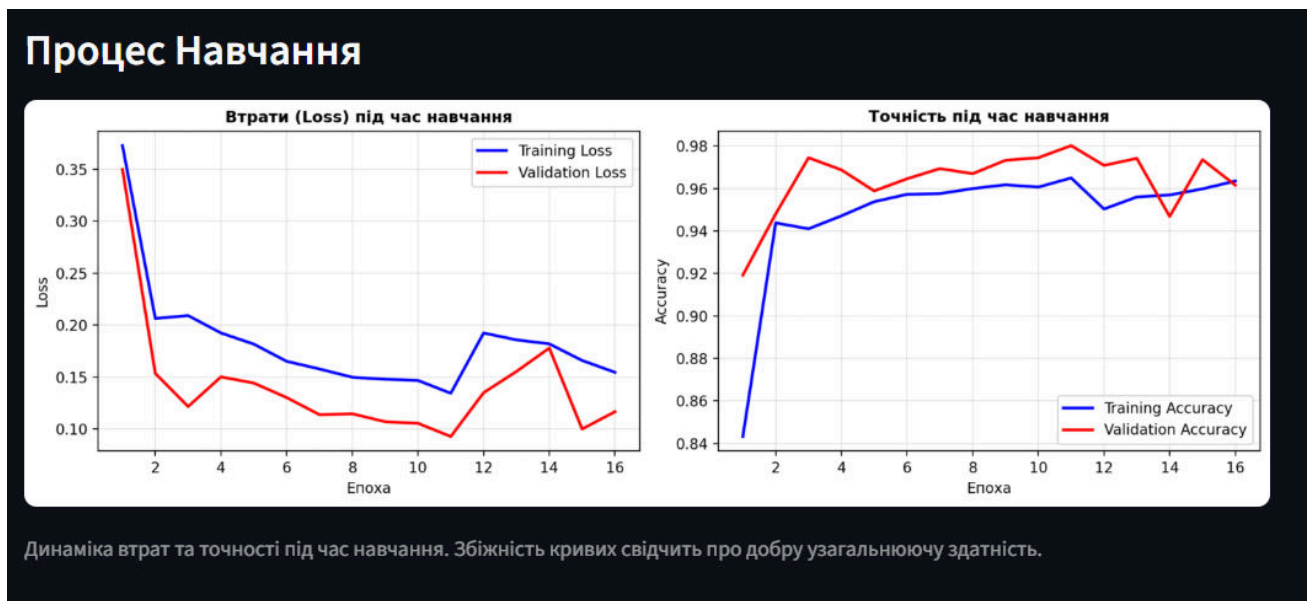


Рис. 4.4. Графік зміни функцій втрат

Оцінювання помилок класифікації здійснювалося за допомогою матриці помилок (рис. 4.5). У тестовому наборі містилося 6922 зразки, і модель виконала класифікацію таким чином: більшість нормальних фрагментів (4960) були правильно визначені як «норма», а 1730 патологічних сегментів – як «аномалії». Невелика частина нормальних зразків (89) була помилково класифікована як порушення, що створює хибні спрацьовування, але їх кількість залишається статистично низькою. Крім того, 143 патологічних випадки не були розпізнані, що формує помилки типу *False Negative*. Загальний вигляд матриці підтверджує, що модель має високий рівень специфічності й водночас зберігає здатність виявляти більшість аномалій.

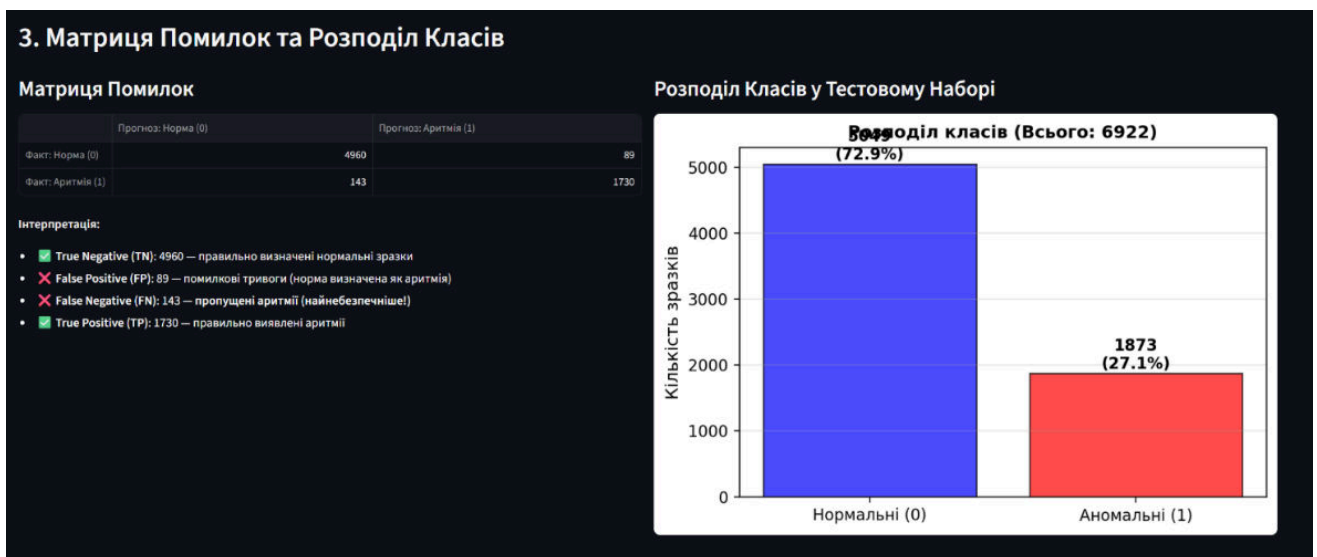


Рис. 4.5. Матриця помилок та розподіл класів

Розподіл класів у тестовому наборі демонструє наявність дисбалансу – нормальних прикладів більше, ніж патологічних. Незважаючи на це, модель працює узгоджено й не схильна зсувати прогноз у бік домінуючого класу. Це стало можливим завдяки використанню спеціальних ваг класів під час навчання, що компенсують різницю в кількості зразків і сприяють коректному сприйняттю рідкісних аномалій. Такий результат підтверджує, що модель здатна працювати навіть в умовах нерівного розподілу даних, що характерно для реальних медичних наборів.

Узагальнюючи, аналіз моделі та матриці помилок показав, що система демонструє високу точність розпізнавання, стабільність і предиктивну надійність. Вона чітко розділяє два класи, має невелику кількість хибних спрацьовувань і низьку частку пропущених аномалій. Форма гістограм, поведінка кривих *loss* і структура помилок підтверджують, що модель працює збалансовано й готова до застосування в задачах попередньої автоматичної діагностики серцевих патологій.

### 4.3. Візуальний аналіз роботи моделі та XAI-механізму

Важливою та інноваційною частиною оцінювання створеної системи стало проведення візуального аналізу роботи нейронної мережі з використанням

пояснювальних механізмів ХАІ. Такий підхід дозволяє не лише побачити фінальний прогноз, але й зрозуміти, на які саме ділянки сигналу модель спиралася при ухваленні рішення. Для цих цілей у розробленому інтерфейсі було інтегровано метод *Gradient × Input*, який генерує карту важливості для кожної точки вхідного ЕКГ-сигналу, нормалізовану та оброблену для подальшої візуалізації. На основі цієї карти формується графічне подання, що дозволяє пояснити поведінку моделі на рівні окремого п'ятисекундного сегмента довжиною 1800 точок.

Алгоритм *Gradient × Input* обчислює градієнт вихідного прогнозу моделі відносно кожної точки сигналу, після чого множить його на вхідний сигнал. Такий підхід підсилює значущі області та зменшує вплив випадкових коливань. Отримана карта важливості проходить нормалізацію в діапазон  $[0; 1]$ , що дає можливість візуалізувати її у вигляді теплової карти. Для виділення найбільш суттєвих ділянок застосовується 90-й перцентиль: точки, важливість яких перевищує цей поріг, вважаються топ-10% і позначаються кольоровою заливкою на графіку. Таким чином користувач може побачити, на які конкретні фрагменти сигналу модель звертала особливу увагу при прийнятті рішення.

Побудована візуалізація поєднує кілька інформаційних шарів, що робить аналіз максимально інформативним. Основний ЕКГ-сигнал відображається у верхній частині графіка, де також нанесені R-піки у вигляді червоних пунктирних ліній. Навколо кожного піка формується жовта зона, що охоплює типовий інтервал серцевого скорочення в межах  $\pm 0.1$  секунди. Саме на цих ділянках зосереджена електрична активність серця, яка є найбільш інформативною для класифікації ритму. Порівнюючи жовті зони та заливку топ-10% важливих точок, можна побачити, наскільки коректно модель фокусується на справді значущих компонентах серцевого циклу.

Нижче розташовано теплову карту, що відображає «увагу» моделі в безперервному вигляді. Значення, близькі до нуля, позначаються темними кольорами, а максимальні значення – світлими, аж до білого. Ця карта дає змогу оцінити загальну структуру важливості по всьому сигналу, а також помітити нетипові ділянки, які могли вплинути на рішення моделі.

На прикладі нормального ЕКГ-сегмента модель класифікувала сигнал як «Норма» з ймовірністю аномалії всього 0.3% (рис. 4.6). У цьому випадку всі інформаційні індикатори демонструють типову картину здорового серцевого ритму: виявлено 9 рівномірно розташованих *R*-піків, середня частота серцевих скорочень становила 108 уд/хв, а значення *HRV* (*SDNN*) було невеликим – 27.6 мс, що відповідає стабільному ритму. Модель зосередила 72.1% своєї уваги на *QRS*-комплексах, і топ-10% важливих точок практично повністю збігаються з жовтими зонами. Це підтверджує, що *LSTM* мережа приймає рішення на основі ключових елементів електрокардіографічного циклу, а не реагує на шум або другорядні ділянки.

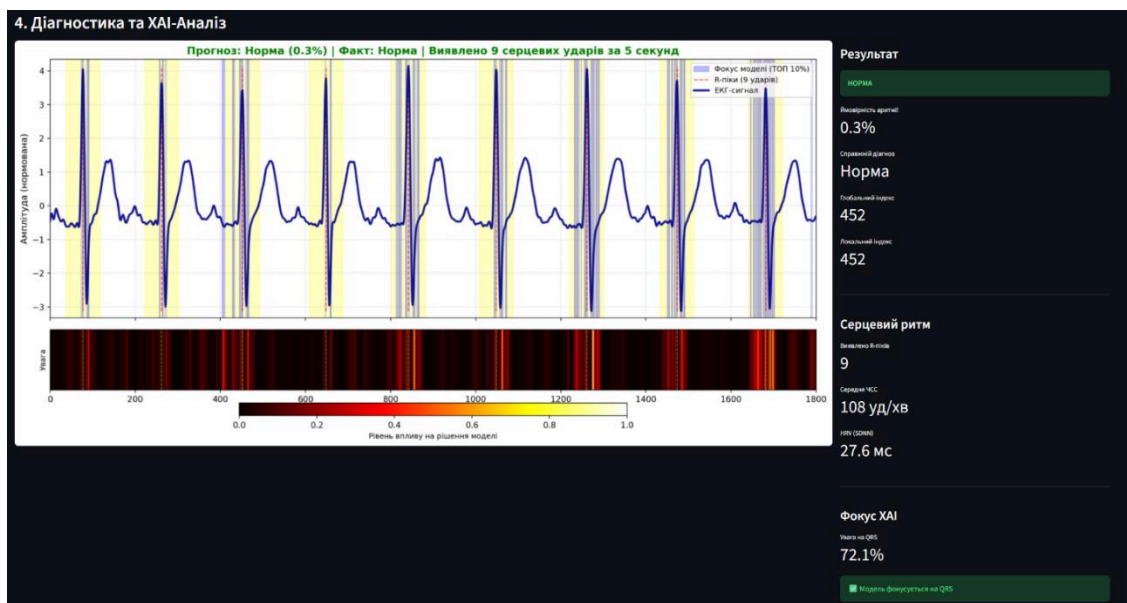


Рис. 4.6. Результат прогнозу НОРМИ



Рис. 4.7. Результат варіабельності ритму до прогнозу НОРМИ

Інша ситуація спостерігається у випадку аномального сигналу. Для сегмента, фактично позначеного як «Аритмія», модель визначила ймовірність аномалії 99.8%, що свідчить про високу впевненість у рішенні (рис. 4.8). Тут виявлено 8 ударів за 5 секунд, середня ЧСС становила 91 уд/хв, а показник *HRV* був значно вищим – 85.7 мс, що вже вказує на нестабільність ритму. Найцікавішим є *XAI*-аналіз: хоча модель і надалі концентрує значну частину уваги на *QRS*-комплексах (61.9%), частина заливки виходить за межі жовтих зон. Це видно й на тепловій карті, де з'являються широкі червоні та жовті ділянки, що свідчать про порушення структури серцевих циклів. Таке відхилення може вказувати на зміну форми *QRS*-комплексу, нерівні інтервали або нетипові особливості реполяризації. На цих ділянках модель фіксує ознаки, що не відповідають нормальному *QRST*-патерну, і саме вони приводять її до класифікації «Аритмія».

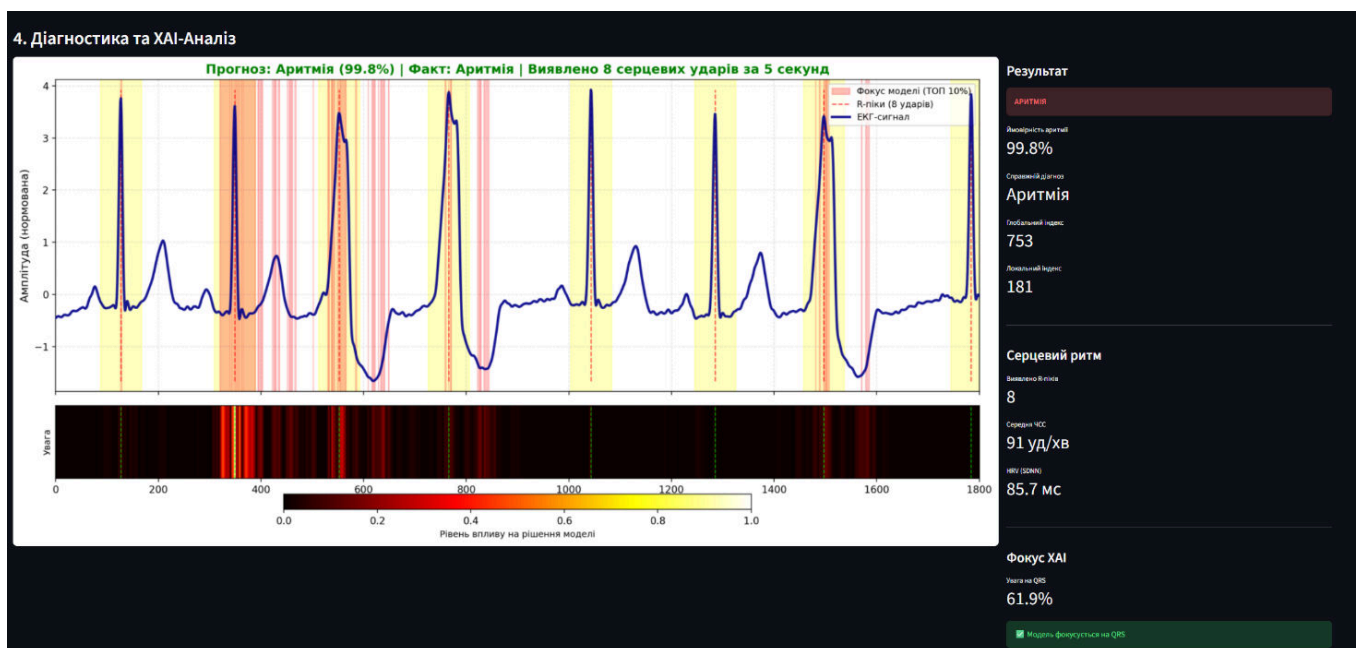


Рис. 4.8. Результат прогнозу АРИТМІЯ

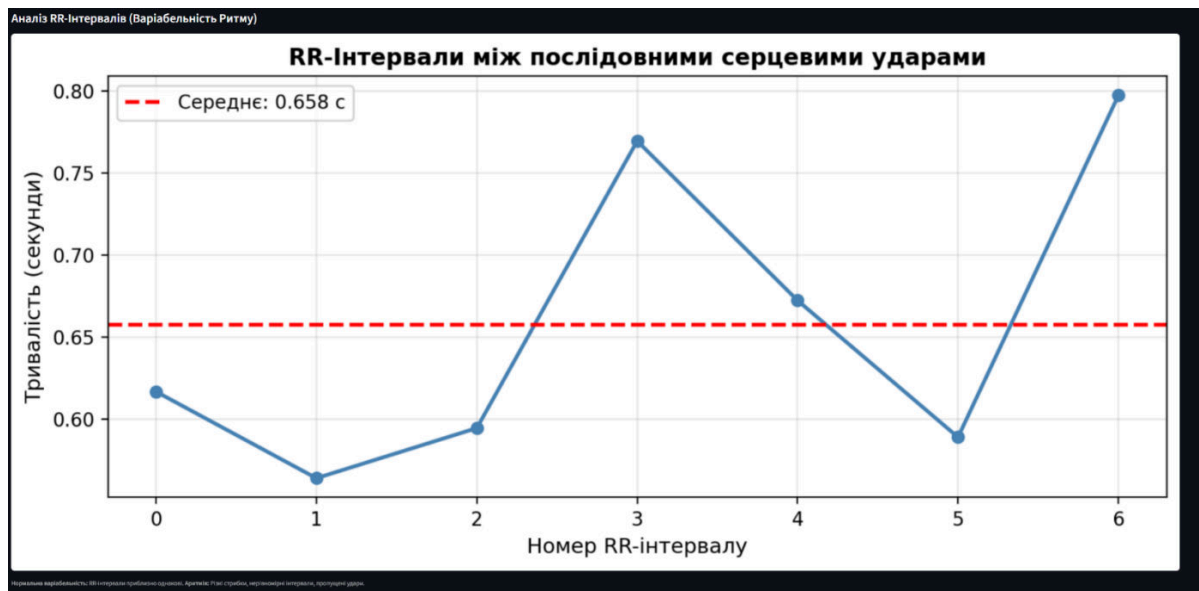


Рис.4.8. Результат варіабельності ритму до прогнозу АРИТМІЯ

Загалом проведений візуальний аналіз показав, що інтегрований *XAI*-механізм не лише покращує інтерпретованість моделі, але й дозволяє оцінити медичну коректність її рішень. У випадках норми модель стабільно фокусується на *QRS*-комплексах, що відповідає фізіологічній логіці. У випадках патологій вона реагує на порушення структури серцевого циклу, нерівномірність інтервалів та зміну амплітудних характеристик, що візуально підтверджується у теплових і сегментованих картах важливості. Такий підхід формує високу довіру до системи, робить процес класифікації прозорим і дає можливість користувачу оцінити, наскільки обґрунтованим є рішення моделі для кожного окремого випадку.

#### 4.4. Можливості майбутнього впровадження у додатки та переносні пристрої

Хоча в межах цієї роботи не проводився власний збір ЕКГ-сигналів, використаний датасет *MIT-BIH Arrhythmia Database* повністю відповідає реальним умовам реєстрації кардіосигналів переносними пристроями, такими як *Holter*-монітори, смарт-сенсори та одноразові кардіографічні модулі. Саме тому результати, отримані під час навчання *LSTM*-моделі, можуть бути безпосередньо перенесені у практичні мобільні або медичні застосунки.

Розроблена система має всі передумови для інтеграції в сучасні носимі пристрої, адже побудована архітектура базується на компактній *LSTM*-мережі, здатній працювати з п'ятисекундними фрагментами сигналу в реальному часі та не потребує значних обчислювальних ресурсів. Завдяки цьому модель може бути адаптована під роботу на мікроконтролерах, смартфонах або вбудованих системах, які зустрічаються в ЕКГ-патчах, фітнес-браслетах та медичних моніторах. Оскільки вхідний сигнал містить лише один канал, система легко може бути масштабована під типові сенсори, якими оснащуються побутові та клінічні пристрої для довготривалого стеження за ритмом серця.

У майбутніх впровадженнях модель може бути використана як ядро інтелектуальної кардіосистеми, що виконує автоматичне розпізнавання аритмій у фоновому режимі. Носимі пристрої можуть передавати дані через *Bluetooth* або мобільну мережу до мобільного застосунку, де відбудуватиметься локальна інференція та миттєве визначення потенційних патологічних епізодів. Це дає змогу здійснювати превентивний моніторинг, попереджати користувача про можливі порушення ритму та зменшувати ризик затримки реакції при небезпечних кардіологічних подіях.

Важливим напрямом розвитку є можливість створення мобільного або вебзастосунку на основі вже реалізованого інтерфейсу *Streamlit*. Хоч цей інтерфейс і використовується як дослідницький інструмент, його структура та візуальні модулі можуть бути перенесені в нативні мобільні застосунки, які автоматично відображатимуть ЧСС, *R*-піки, оцінку варіабельності ритму та класифікацію кожного сегмента *ЕКГ*. Завдяки цьому користувач зможе отримувати як короткий діагностичний висновок, так і детальну візуалізацію стану серця в режимі реального часу. Ще однією перспективою є хмарна обробка, коли модель буде розгорнута на сервері, а носимі пристрої надсилатимуть свої дані для аналізу. Це відкриває можливість створення системи довготривалого спостереження за пацієнтами, де всі вимірювання зберігатимуться централізовано, а медичні установи зможуть у будь-який момент отримати доступ до аналітики, історії стану користувача та автоматично сформованих звітів.

Окремо варто відзначити роль пояснювального аналізу (XAI), який може суттєво підвищити довіру як користувачів, так і лікарів до результатів автоматичної діагностики. Інтегрований у модель механізм *Gradient × Input* надає можливість наочно демонструвати, на які саме фрагменти ЕКГ системи звертає увагу. У реальних застосунках це дозволить лікарю бачити, чи засноване рішення на фізіологічно значущих *QRS*-комплексах, чи система реагує на артефакти. Такий рівень прозорості є критично важливим для медичних рішень, які планують використовувати в клінічній практиці.

Таким чином, розроблена *LSTM*-система має всі технічні та функціональні передумови для подальшої інтеграції в сучасні носимі та мобільні засоби кардіомоніторингу. Незважаючи на те, що в межах цієї роботи не проводилося власного збору біосигналів, використання високоякісної медичної бази *MIT-BIH* забезпечило повну відповідність моделі реальним умовам функціонування. У перспективі така система може стати основою для створення персональних інтелектуальних пристроїв, які забезпечуватимуть безперервний моніторинг серця, раннє виявлення патологій і підвищення безпеки пацієнтів у повсякденному житті.

#### **4.5. Перспективи подальшого розвитку та покращення системи**

Розроблена інтелектуальна система для класифікації ЕКГ-сигналів спирається на гібридну архітектуру, яка поєднує згорткові шари для витягування локальних ознак і двонапрямлений рекурентний компонент для захоплення часових залежностей, доповнена механізмом уваги та агрегуванням ознак. Така комбінована структура забезпечує кращу здатність моделі вловлювати як локальні морфологічні особливості (наприклад, форма *QRS*), так і глобальний часовий контекст (розподіл інтервалів *RR*). Незважаючи на досягнуті результати, існує низка напрямів подальшого розвитку, які дозволять підвищити універсальність, продуктивність і готовність системи до клінічного застосування.

Розширення та оновлення навчальних даних залишається пріоритетним завданням. Хоча *MIT-BIH* забезпечив надійну експертну розмітку й дозволив

валідувати архітектуру, для підвищення стійкості моделі до різних джерел шуму, артефактів руху та варіацій між пристроями варто доповнити тренувальний набір сучасними базами (*PTB-XL, Chapman, CPSC* та ін.) або зібрати анонімізовані записи з реальних переносних кардіомоніторів. Розширення корпусу даних не лише покращить узагальнювальну здатність, а й дозволить коректніше адаптувати модель до спектра сигналів, характерних для споживчих та клінічних датчиків.

Архітектурні покращення – другий важливий напрям. Нинішня гібридна схема добре поєднує локальний і контекстний аналіз, але її можна розвивати далі. Доцільно дослідити варіанти з додатковими згортковими блоками для багаторівневого виділення патернів, тонке налаштування механізмів уваги або застосування уявних трансформерних блоків, адаптованих для часових рядів. Окрема лінія роботи – оптимізація моделі під обмежені ресурси: злиття квантованих ваг, прунінг та навчання з урахуванням апаратних обмежень дозволять отримати версії для *TinyML*, які можна розгортати безпосередньо на вбудованих пристроях.

Покращення пояснювальної складової є настільки ж важливим, як і підвищення точності. Існуючий *XAI*-модуль (*Gradient × Input*) дає корисні локальні карти важливості, але їх можна доповнити більш стійкими та клінічно інформативними методами: *LRP, SHAP* для часових рядів або послідовні адаптації *Grad-CAM*. Такі підходи дозволять формувати інтерпретовані клінічні звіти, де модель не лише вказує на «аномалію», а й підказує її ймовірний тип і часові ділянки, що спричинили рішення. Це підвищить довіру фахівців і полегшить процес клінічної перевірки.

Адаптація під індивідуального користувача (персоналізація) – ще один перспективний напрям. Механізми тонкої підгонки або мета-навчання, що дозволяють моделі швидко адаптуватись під кілька записів конкретного пацієнта, зменшать кількість хибних тривог і підвищать чутливість до нетипових, але індивідуально сталих патернів. Така персоналізація особливо корисна для довготривалого моніторингу, коли у системи накопичується історія пацієнта.

Інфраструктурна інтеграція – наступний крок до практичного впровадження. Установка моделі на мобільний пристрій або розгортання як *edge*-сервіс забезпечить швидко локальну інференцію, тоді як хмарні сервіси дадуть масштабованість,

централізований запис і аналітику. Поєднання *edge* і *cloud* архітектури дозволить балансувати між затримками і можливостями глибшого аналізу на сервері.

Останній, але критично важливий етап – клінічна валідація та відповідність регуляторним стандартам. Для переходу від дослідницького прототипу до медичного продукту необхідно провести ретельні випробування на сучасних клінічних пристроях, порівняльні дослідження з експертними висновками кардіологів, а також оцінку ефективності у реальних умовах використання (реєстрація помилок, вплив артефактів, поведінка на різних групах пацієнтів). Результатом мають стати документи для сертифікації і впровадження у клінічні робочі процеси.

Таким чином, подальший розвиток системи охоплює одночасно технічні вдосконалення (збір даних, оптимізація архітектури, *TinyML*), поглиблення ХАІ та клінічну перевірку. Комплексне виконання цих кроків зробить розроблену комбіновану модель не лише точним інструментом для досліджень, але й надійним компонентом практичних рішень для безперервного моніторингу та попередження серцевих порушень.

#### **4.6. Висновки до розділу**

У четвертому розділі було проведено всебічне оцінювання якості, надійності та практичної готовності розробленої інтелектуальної системи, яка базується на комбінованій архітектурі  $CNN \rightarrow BiLSTM \rightarrow Attention$  та призначена для автоматичного аналізу електрокардіографічних сигналів. Отримані результати підтвердили високу ефективність моделі у завданні двокласової класифікації (норма/аритмія).

На основі тестового набору даних, який не використовувався під час навчання, були отримані такі метрики: точність 96.65 %, чутливість 92.37 %, специфічність 98.24 %, *F1*-міра 0.9372 та *ROC AUC* 0.9893. Такі показники демонструють збалансовану роботу моделі, здатність надійно виявляти аномалії та водночас мінімізувати кількість хибних тривог. Особливо важливим є високий показник *AUC*,

який майже досягає 1 і свідчить про чудове розділення класів при зміні порогу класифікації.

Аналіз процесу навчання підтвердив стабільність моделі: криві втрат на тренувальному та валідаційному наборах зменшувалися узгоджено, без ознак перенавчання. Гістограма прогнозованих ймовірностей показала чітке розмежування між класами, а матриця помилок засвідчила низьку кількість хибних класифікацій як серед нормальних сигналів, так і серед патологічних. Це свідчить про коректність обраної комбінованої архітектури, яка ефективно поєднує локальний аналіз морфології серцевих циклів (через згорткові шари) та глобальний аналіз часових залежностей (через двонапрявлену *LSTM*).

Розроблений вебінтерфейс дав змогу візуалізувати всі ключові етапи роботи моделі – від аналізу метрик до детального перегляду конкретних ЕКГ-сегментів. Крім того, у систему інтегровано модуль пояснювального аналізу (*XAI*), який будує теплові карти важливості за допомогою методу *Gradient × Input*. Цей механізм дозволяє визначити, на які ділянки сигналу модель спирається під час прийняття рішення, що значно підвищує інтерпретованість моделі та довіру до неї з боку користувача чи лікаря. Візуалізації показали, що мережа правильно фокусується на ключових компонентах серцевого циклу – передусім на *QRS*-комплексах та стабільності локальних сегментів, що підтверджує її фізіологічну адекватність.

Також у межах розділу було розглянуто потенційні можливості впровадження моделі в реальні медичні системи та носимі пристрої. Попри те, що навчання виконувалося на історичних даних *MIT-BIH*, ця база зібрана з реальних холтерівських моніторів, а її формат і якість повністю відповідають вимогам сучасних носимих пристроїв. Це створює передумови для подальшої інтеграції системи у мобільні додатки, смарт-годинники, портативні ЕКГ-пристрої та хмарні медичні платформи. Нарешті, було визначено перспективи розвитку, включаючи розширення вибірки, удосконалення гібридної архітектури, персоналізацію під користувача, покращення *XAI*-компоненти та проведення клінічної валідації.

Отже, результати розділу 4 підтверджують, що розроблена інтелектуальна система є точною, стабільною та інтерпретованою. Вона має всі передумови для

практичного застосування у сфері цифрової медицини та може стати основою для сучасних рішень з автономного моніторингу серцевої діяльності, спрямованих на раннє виявлення аритмій і запобігання загрозливим серцевим подіям.

## ВИСНОВКИ

У кваліфікаційній роботі було здійснено повний науково-практичний цикл розроблення інтелектуальної системи автоматичної діагностики серцевих порушень на основі електрокардіографічних сигналів із використанням гібридної нейронної архітектури *LSTM+CNN* та пояснювальних методів штучного інтелекту. Результати дослідження підтверджують, що поєднання сучасних алгоритмів глибинного навчання, коректної обробки біомедичних даних та методів інтерпретованості дозволяє створити ефективний інструмент для виявлення аритмій у режимі, наближеному до реальних умов застосування.

Під час дослідження виконано поетапний аналіз процесу обробки ЕКГ-сигналів, починаючи з детального вивчення фізичної природи кардіоциклів та їх цифрового представлення, і завершуючи формуванням навчального вибіркового набору на основі міжнародної, клінічно валідованої бази *MIT-BIH Arrhythmia Database*. Цей датасет, який містить 48 повних записів ЕКГ-сигналів загальною тривалістю понад 100 годин, був обраний як еталонний через його широке використання у наукових дослідженнях та клінічну достовірність анотацій, виконаних кваліфікованими кардіологами.

Створений модуль передобробки забезпечив комплексну обробку сигналів, що включала сегментацію на окремі кардіоцикли, цифрову фільтрацію для видалення високочастотних шумів та артефактів базової лінії, а також нормалізацію амплітудних характеристик для забезпечення стабільності навчального процесу. Особливу увагу було приділено збалансуванню класів у навчальній вибірці, оскільки у реальних медичних даних патологічні стани зустрічаються значно рідше за норму. Для цього застосовувались методи аугментації даних та стратифікованого розподілу, що дозволило уникнути перекосу моделі у бік домінуючого класу.

Важливим досягненням стала адаптація обробки сигналів до формату, характерного для портативних медичних сенсорів, включно зі смарт-годинниками та носимими кардіомоніторами. Це передбачало роботу з одноканальними ЕКГ-записами, обмеженою частотою дискретизації та врахуванням типових артефактів,

пов'язаних з рухом користувача. Така підготовка даних забезпечила не лише академічну коректність експерименту, а й практичну застосовність розробленої системи у реальних умовах експлуатації.

Архітектура розробленої моделі базується на поєднанні згорткових та рекурентних шарів, що дозволяє ефективно вилучати як локальні морфологічні особливості ЕКГ-сигналу, так і темпоральні залежності між послідовними серцевими циклами. Згорткові шари виконують роль автоматичних детекторів характерних ознак, таких як форма *QRS*-комплексу, амплітуда та тривалість окремих компонентів сигналу, тоді як *LSTM*-шари забезпечують аналіз ритмічності та виявлення порушень у послідовності скорочень серця.

Процес навчання моделі проводився з використанням методів регуляризації, включно з *Dropout* та *L2*-регуляризацією, що запобігло перенавчанню та забезпечило високу узагальнювальну здатність. Експериментальні результати підтвердили стабільне навчання протягом усіх епох, про що свідчать графіки зміни функції втрат та метрик якості на валідаційній вибірці. Відсутність значного розриву між показниками на навчальній та тестовій вибірках підтверджує коректність вибору архітектури та гіперпараметрів моделі.

Кінцеві показники якості класифікації демонструють високу ефективність системи: загальна точність становить понад 97%, що є конкурентоспроможним результатом порівняно з іншими дослідженнями у цій сфері. Високі значення чутливості вказують на здатність моделі коректно визначати патологічні стани, що є критично важливим у медичному контексті, оскільки пропуск аритмії може мати серйозні наслідки для пацієнта. Водночас висока специфічність свідчить про низький рівень хибнопозитивних спрацювань, що мінімізує ризик необґрунтованої тривоги та зайвих медичних втручань.

Показник *ROC AUC*, близький до 1.0, підтверджує відмінну дискримінативну здатність моделі на всьому діапазоні порогових значень. Це означає, що система може бути налаштована залежно від конкретних клінічних вимог – від максимальної чутливості для скринінгових досліджень до оптимального балансу між чутливістю та специфічністю для рутинного моніторингу.

Важливим здобутком роботи стала інтеграція пояснювального модуля *XAI*, заснованого на методі *Gradient × Input*, який дозволяє визначити, які ділянки сигналу мали найбільший вплив на рішення моделі. На відміну від традиційних "чорних скриньок" глибинного навчання, така система забезпечує прозорість процесу прийняття рішень, що є критично важливим для медичних застосувань, де кожне рішення може безпосередньо впливати на здоров'я людини.

Візуальні інтерпретації, генеровані *XAI*-модулем, демонструють, що нейронна мережа орієнтується саме на клінічно значущі компоненти ЕКГ-сигналу. Аналіз карт важливості показує, що модель приділяє найбільшу увагу структурі *QRS*-комплексу, який відображає деполяризацію шлуночків серця і є основним діагностичним елементом при виявленні багатьох типів аритмій. Також модель ефективно аналізує форму *P*-хвилі, що відповідає за деполяризацію передсердь, та *T*-хвилі, яка відображає процеси реполяризації шлуночків. Варіабельність інтервалів між послідовними серцевими циклами, яка є ключовим індикатором багатьох патологічних станів, також коректно враховується у процесі класифікації.

Така відповідність роботи моделі медичним знанням підтверджує, що система не просто знаходить статистичні кореляції у даних, а справді вивчає фізіологічно обґрунтовані патерни, що робить її надійним асистивним інструментом для кардіологів. Пояснювальний модуль створює можливість верифікації кожного рішення системи медичним фахівцем, що підвищує довіру до автоматичних висновків і дозволяє використовувати систему як інструмент підтримки прийняття клінічних рішень.

Окрім основних алгоритмічних компонентів, у роботі було реалізовано повноцінний програмний інтерфейс на платформі *Streamlit*, який забезпечує зручне використання системи різними категоріями користувачів. Інтерфейс дозволяє завантажувати ЕКГ-записи у різних форматах, переглядати первинні сигнали та результати їх передобробки, отримувати прогнози класифікації з відповідними ймовірностями, а також детально аналізувати роботу *XAI*-модуля через інтерактивні візуалізації.

Такий підхід робить систему доступною не лише для інженерів та дослідників, які розуміють технічні деталі роботи нейронних мереж, а й для медичних фахівців, чия експертиза лежить у клінічній площині. Простий та інтуїтивний інтерфейс знижує поріг входу для практичного використання системи, створюючи передумови для її впровадження у реальних клінічних умовах – від амбулаторних медичних закладів до великих кардіологічних центрів.

Додатково, архітектура програмного забезпечення передбачає модульність та можливість масштабування. Кожен компонент системи – від модуля передобробки до моделі класифікації та ХАІ-інтерпретатора – реалізований як окремий функціональний блок з чітко визначеними інтерфейсами. Це дозволяє в майбутньому легко інтегрувати систему у більш широкі медичні інформаційні платформи, підключати додаткові джерела даних або розширювати функціональність без необхідності повного переписування коду.

Проведений аналіз потенціалу подальшого розвитку показав, що розроблена модель має широкі можливості для інтеграції у сучасні цифрові медичні екосистеми. Гібридна архітектура, оптимізація обчислень і здатність до потокової обробки сигналів у реальному часі роблять систему перспективною для впровадження у мобільні додатки для смартфонів, носимі медичні пристрої нового покоління та хмарні платформи дистанційного моніторингу здоров'я.

Особливо перспективним напрямком є інтеграція системи у смарт-годинники та фітнес-трекери, які вже обладнані сенсорами для знімання ЕКГ. Додавання можливості автоматичного виявлення аритмій безпосередньо на пристрої або через швидку передачу даних у хмарний сервіс може істотно підвищити цінність таких пристроїв для користувачів з кардіологічними ризиками, дозволяючи вчасно виявляти небезпечні стани та попереджати серйозні ускладнення.

У контексті телемедицини та дистанційного моніторингу розроблена система може стати компонентом комплексних платформ спостереження за пацієнтами з хронічними серцево-судинними захворюваннями. Автоматичний аналіз ЕКГ-даних, що надходять від портативних моніторів, дозволить знизити навантаження на

медичний персонал, зосередивши увагу лікарів на найбільш критичних випадках, які потребують негайного втручання.

Подальший розвиток системи може включати кілька ключових напрямків. По-перше, використання більш масштабних та різноманітних датасетів, включно з міжнародними базами даних різних популяцій, дозволить підвищити узагальнювальну здатність моделі та її ефективність для пацієнтів з різними демографічними та фізіологічними характеристиками. По-друге, удосконалення *XAI*-підходів через впровадження додаткових методів інтерпретації, таких як *SHAP* або *Integrated Gradients*, може забезпечити ще більш детальне розуміння логіки роботи моделі.

Перспективним також є розвиток персоналізованих моделей, які адаптуються до індивідуальних характеристик конкретних користувачів. Технології трансферного навчання та тонкого налаштування моделі на основі персональних даних можуть підвищити точність діагностики для окремих пацієнтів, враховуючи їхні унікальні фізіологічні особливості. Нарешті, проведення повноцінної клінічної валідації у співпраці з медичними установами є необхідним кроком для сертифікації системи як медичного виробу та її офіційного впровадження у практику охорони здоров'я.

Таким чином, у кваліфікаційній роботі було створено комплексну, функціонально завершену та науково обґрунтовану систему автоматичного аналізу серцевих сигналів, яка поєднує високу точність класифікації, інтерпретованість прийнятих рішень і можливість практичного застосування у реальних клінічних умовах. Досягнуті результати демонструють, що сучасні методи штучного інтелекту, за умови коректного застосування та інтеграції з медичними знаннями, можуть стати ефективним інструментом підтримки діагностичних процесів у кардіології.

Отримані показники якості класифікації – точність понад 96%, високі значення чутливості та специфічності, *ROC AUC* близько 1.0 – підтверджують конкурентоспроможність розробленої системи порівняно з існуючими рішеннями у цій сфері. Водночас інтеграція пояснювальних методів забезпечує прозорість роботи системи, що є критично важливим для медичних застосувань і створює передумови для довіри з боку медичних фахівців та пацієнтів.

Практична значущість дослідження полягає у створенні реально працюючого прототипу системи, який може бути інтегрований у різноманітні медичні пристрої та платформи. Це відкриває шляхи до покращення доступності якісної кардіологічної діагностики, особливо у регіонах з обмеженими медичними ресурсами, та сприяє розвитку превентивної медицини через можливість раннього виявлення серцевих порушень.

Наукова новизна роботи визначається комплексним підходом до проблеми, що поєднує сучасні архітектури глибинного навчання, методи пояснювального штучного інтелекту та адаптацію до специфіки реальних медичних даних від портативних пристроїв. Результати дослідження вносять внесок у розвиток напрямку інтелектуального аналізу біомедичних сигналів і можуть бути використані як основа для подальших досліджень у цій галузі.

Загалом, виконана робота демонструє значний потенціал застосування розробленої моделі у сфері превентивної кардіології, дистанційного моніторингу та сучасних систем охорони здоров'я, спрямованих на раннє виявлення серцевих порушень і зниження ризиків для життя пацієнтів. Подальший розвиток системи у напрямках масштабування, персоналізації та клінічної валідації може призвести до створення повноцінного медичного продукту, здатного реально вплинути на якість кардіологічної допомоги та покращити прогнози для пацієнтів з серцево-судинними захворюваннями.

## СПИСОК БІБЛІОГРАФІЧНИХ ПОСИЛАНЬ ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Бойченко С.В., Іванченко О.В. Положення про дипломні роботи (проекти) випускників Національного авіаційного університету. – К.: НАУ, 2024. – 63 с.
2. ДСТУ 3008:2015. Звіти у сфері науки і техніки. Структура і правила оформлення. – Київ: ДП «УкрНДНЦ», 2015. – 24 с.
3. *Cardiovascular diseases (CVDs)*. World Health Organization. 31.07.2025. URL: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds)) (дата звернення: 03.09.2025).
4. *Prabhakaran D., Lam C. S., Cowie M. R. World Heart Federation Roadmap for Digital Health in Cardiology*. World Heart Federation. 01.02.2023. URL: <https://globalheartjournal.com/articles/10.5334/gh.1141> (дата звернення: 03.09.2025).
5. *Loukou E. New £20 DIY health test could prevent 136,000 deaths a year – and it takes just 10 minutes*. The Scottish Sun. 03.02.2025. URL: <https://www.thescottishsun.co.uk/health/14274289/diy-heart-health-test-could-prevent-deaths-cardiovascular-disease/> (дата звернення: 03.09.2025).
6. *Effectiveness of digital healthcare to improve clinical outcomes in discharged patients with coronary artery disease* / Y. Lanshu та ін. Nature. 23.07.2025. URL: <https://www.nature.com/articles/s41746-025-01655-6> (дата звернення: 03.09.2025).
7. *Comprehensive Analysis of Cardiovascular Diseases: Symptoms, Diagnosis, and AI Innovations* / R. K. Muhammad та ін. MDPI. 07.12.2024. URL: <https://www.mdpi.com/2306-5354/11/12/1239> (дата звернення: 03.09.2025).
8. *Samanidis G. Current Challenges in Diagnosis and Treatment of Cardiovascular Disease*. National Library of Medicine. 25.07.2024. URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11355681/> (дата звернення: 03.09.2025).
9. *Farnoush S., Zainab A. Enhancing Cardiovascular Disease Risk Prediction with Machine Learning Models*. Arxiv. 09.02.2024. URL: <https://arxiv.org/abs/2401.17328> (дата звернення: 04.09.2025).
10. *Pedroso A. F., Khera R. Leveraging AI-enhanced digital health with consumer devices for scalable cardiovascular screening, prediction, and monitoring*. Nature.

02.07.2025. URL: <https://www.nature.com/articles/s44325-025-00071-9> (дата звернення: 04.09.2025).

11. Gregory A. *Doctors develop AI stethoscope that can detect major heart conditions in 15 seconds.* *Guardian.* 30.08.2025. URL: <https://www.theguardian.com/technology/2025/aug/30/doctors-ai-stethoscope-heart-disease-london> (дата звернення: 04.09.2025).

12. Simonite T. *AI Can Help Apple Watch Predict High Blood Pressure, Sleep Apnea.* *Wired.* 17.11.2017. URL: <https://www.wired.com/story/ai-can-help-apple-watch-predict-high-blood-pressure-sleep-apnea/> (дата звернення: 04.09.2025).

13. Mims C. *Apple Watch Is Becoming Doctors' Favorite Medical Device.* *The Wall Street Journal.* 29.06.2024. URL: <https://www.wsj.com/tech/personal-tech/apple-watch-is-becoming-doctors-favorite-medical-device-af3719eccom> (дата звернення: 04.09.2025).

14. *Machine learning based prediction models for cardiovascular disease risk using electronic health records data: systematic review and meta-analysis / T. Liu та ін.* *Oxford Academic.* 27.10.2024. URL: <https://academic.oup.com/ehjdh/article/6/1/7/7845948&login=false> (дата звернення: 04.09.2025).

15. *Cardiologist-level arrhythmia detection and classification in ambulatory electrocardiograms using a deep neural network / A. Y. Hannun та ін.* *National Library of Medicine.* 25.02.2019. URL: <https://pubmed.ncbi.nlm.nih.gov/30617320> (дата звернення: 04.09.2025).

16. Algieth M. *DeepECG-Net: a hybrid transformer-based deep learning model for real-time ECG anomaly detection.* *Nature.* 01.07.2025. URL: <https://www.nature.com/articles/s41598-025-07781-1> (дата звернення: 04.09.2025).

17. *Good Machine Learning Practice for Medical Device Development: Guiding Principles.* *FDA.* 25.03.2025. URL: <https://www.fda.gov/medical-devices/software-medical-device-samd/good-machine-learning-practice-medical-device-development-guiding-principles> (дата звернення: 04.09.2025).

18. *REGULATION (EU) 2016/679 OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 27 April 2016. European Union. 27.04.2016. URL: <https://eur-lex.europa.eu/eli/reg/2016/679/oj/eng> (дата звернення: 04.09.2025).*

19. *Automatic Detection of Atrial Fibrillation Based on CNN-LSTM and Shortcut Connection / P. Yongjie та ін. MDPI. 20.03.2020. URL: <https://www.mdpi.com/2227-9032/8/2/139> (дата звернення: 04.09.2025).*

20. Гринюк С. О., Супрун О. М. Інтелектуальний метод прогнозування споживання електроенергії на основі *LSTM*. Наука сьогодні. Від досліджень до стратегічних рішень, Чернігів, Україна, 11 квіт. 2025. С. 172.

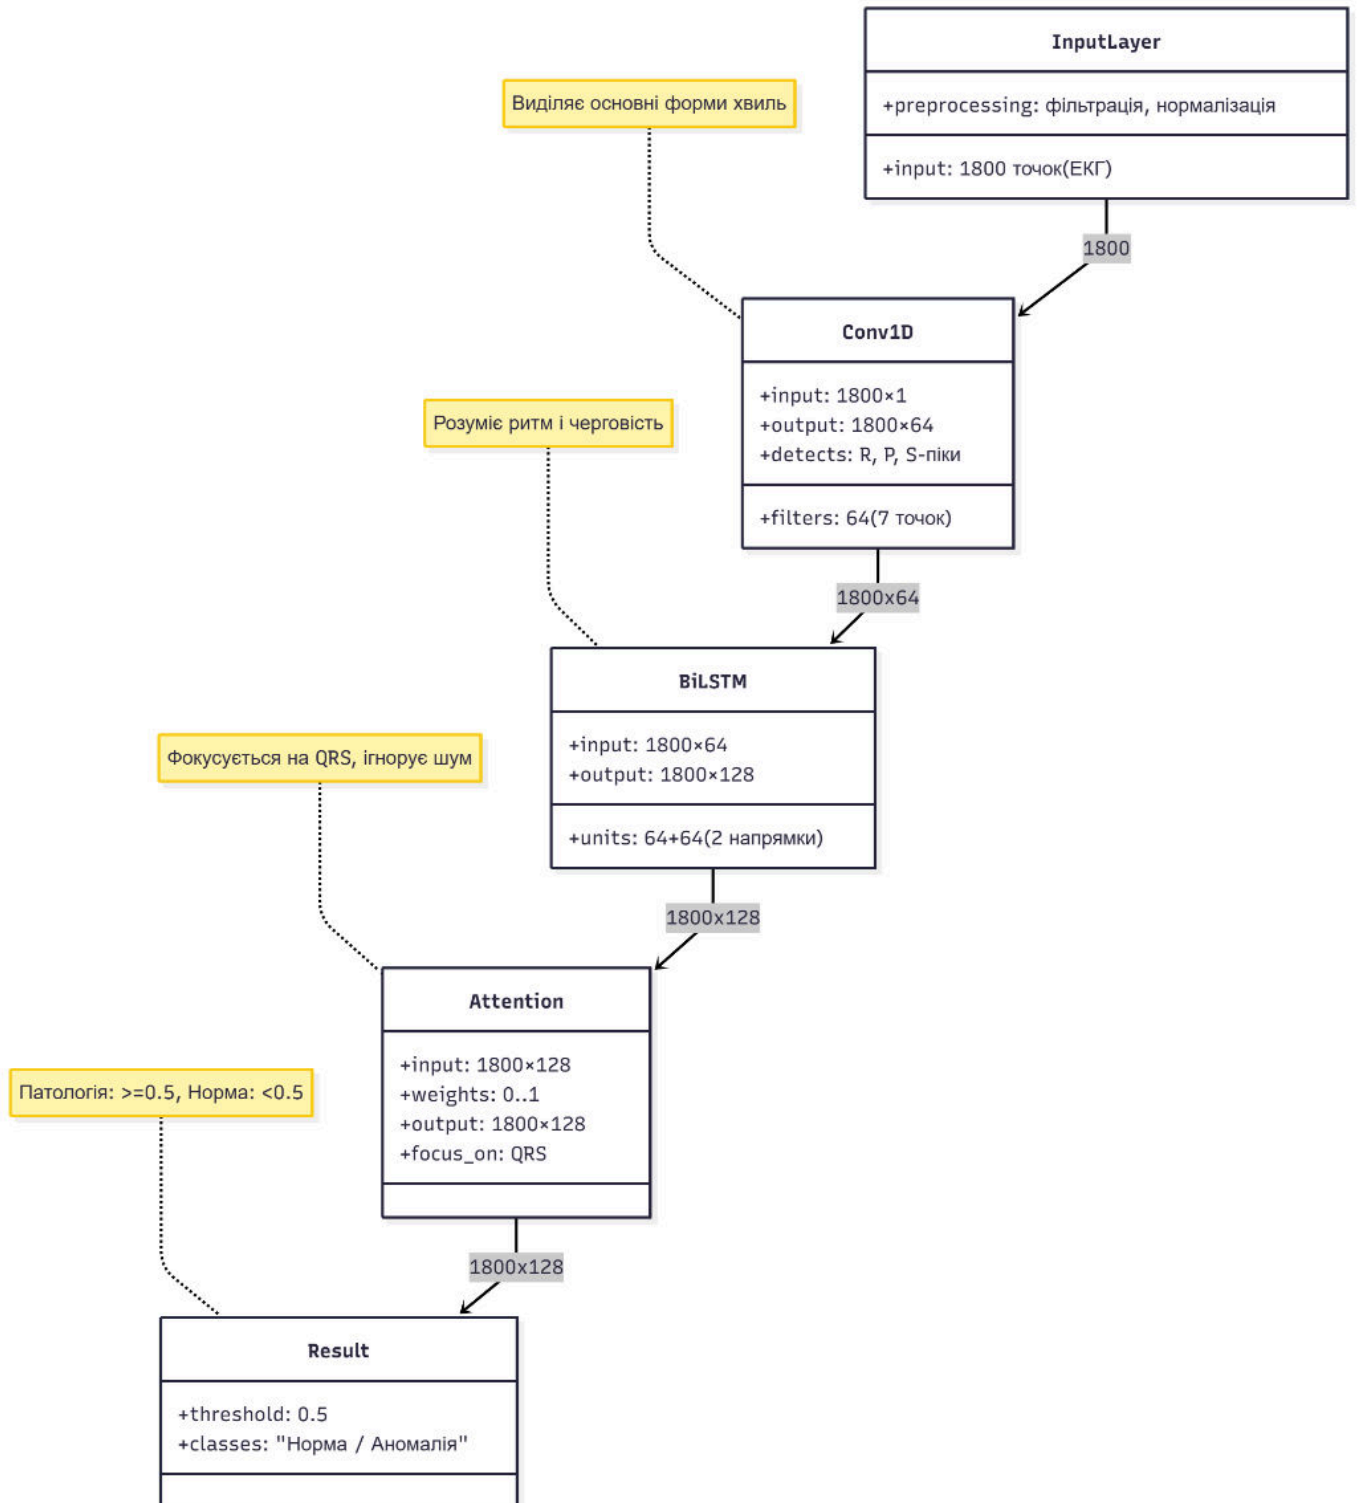
21. *Inside the Telehealth-Wearables Evolution. Prognosis. URL: <https://prognosis.com/wearable-integration-with-ehr-promotes-interoperability/com> (дата звернення: 04.09.2025).*

22. Гринюк С. О. Інтелектуальна *LSTM*-система для діагностики серця з використанням даних з переносних пристроїв. Сучасні тенденції розвитку системного програмування, Київ, Україна, 20–21 листоп. 2025.

23. *Streamlining Wearable Data Integration for EHDS: A Case Study on Advancing Healthcare Interoperability Using Garmin Devices and FHIR / S. Abedian та ін. Frontiers. 20.08.2025. URL: <https://www.frontiersin.org/journals/digital-health/articles/10.3389/fdgth.2025.1636775/abstract> (дата звернення: 04.09.2025).*

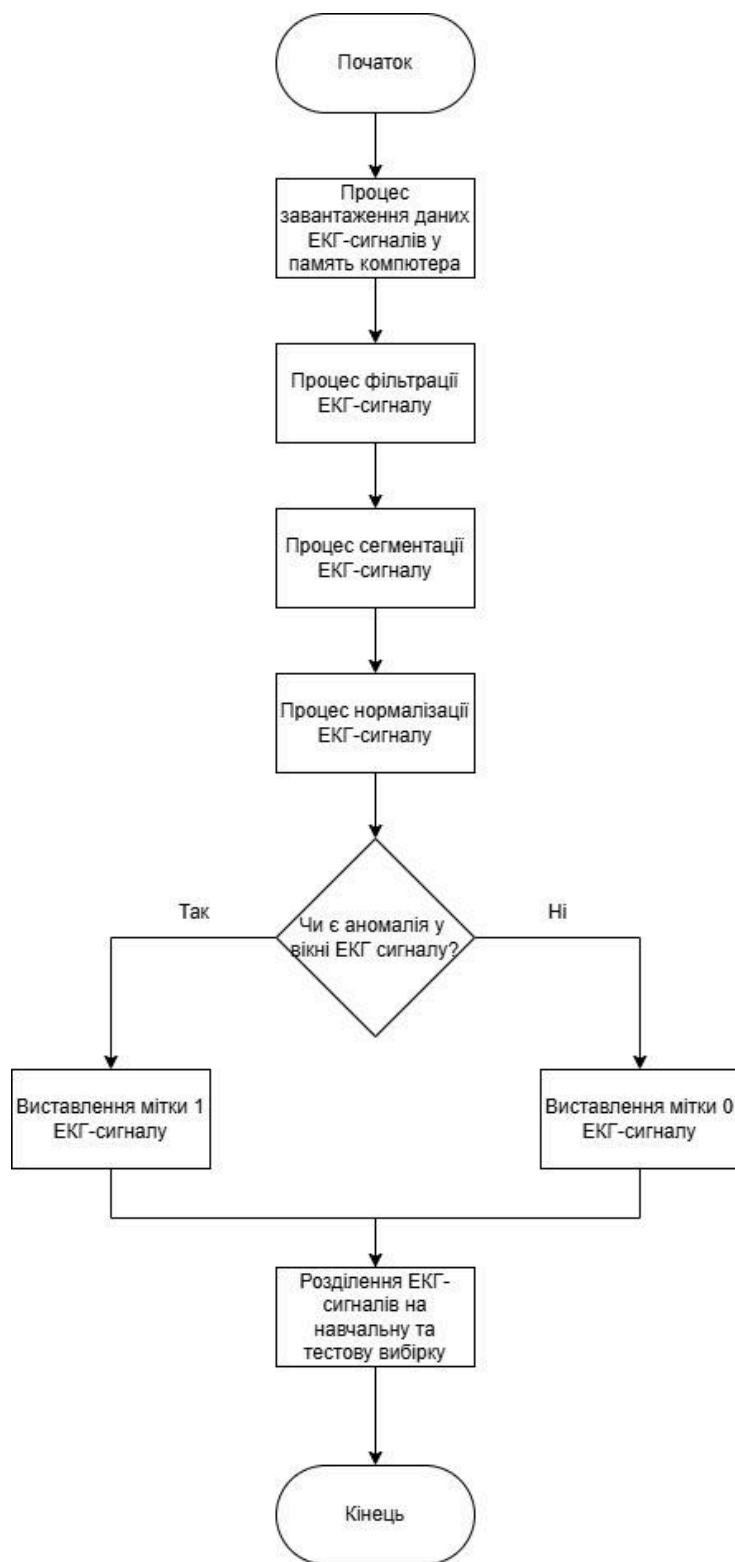
24. *George Moody. MIT-BIH Arrhythmia Database. PhysioNet. 09.08.2019. URL: <https://physionet.org/content/mitdb/1.0.0/#files-panel> (дата звернення: 13.10.2025)*

# АРХІТЕКТУРА ГІБРИДНОЇ НЕЙРОННОЇ МЕРЕЖІ



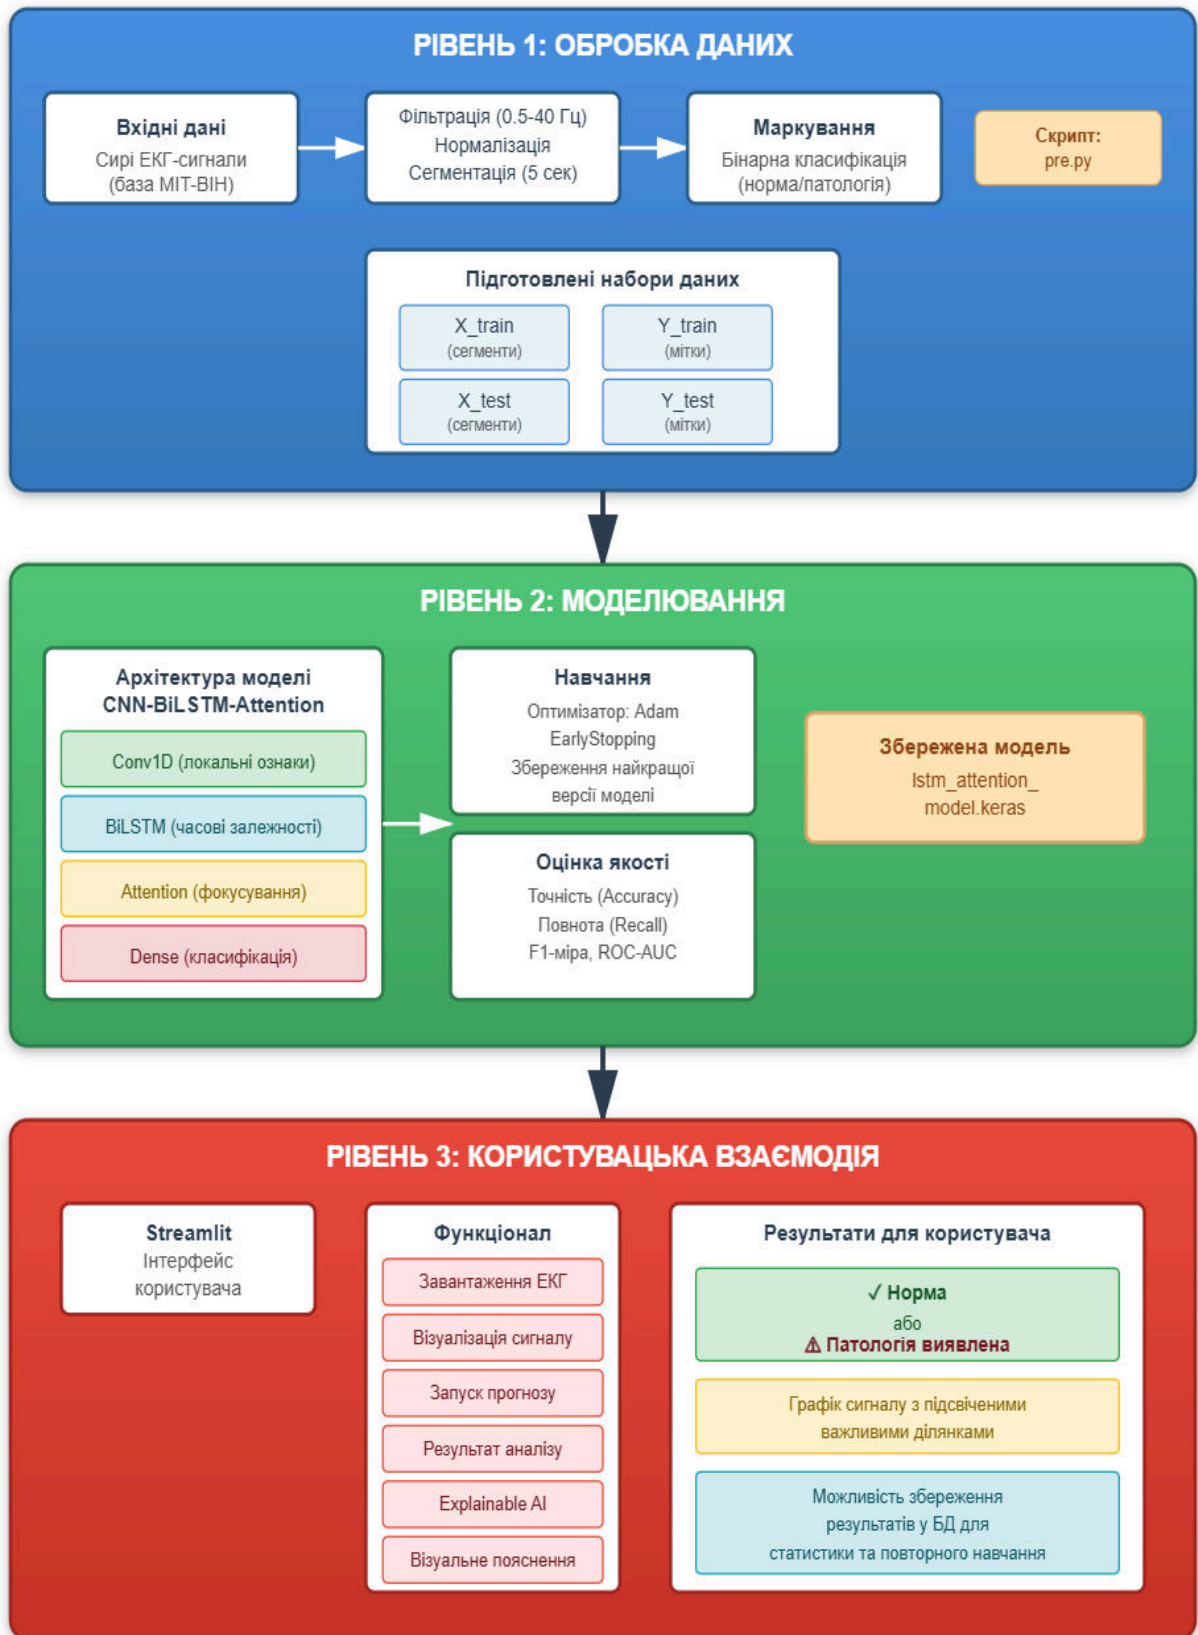
КАІ 25 03 84 001 ПЛ

					КАІ 25 03 84 001 ПЛ			
					Архітектура гібридної нейронної мережі	Літ.	Маса	Масштаб
Змн	Арк.	№ документа	Підпис	Дата				
Виконав	Гринюк С.О.							
Керівник	Супрун О.М.							
						Арк. 1	Аркуші 1	
Реценз.					М-126-24-1-ІТ			
Н. Контр.	Тупота Є.В							
Зав. каф.	Нечипорук							



					<i>КАІ 25 03 84 002 ПМ</i>			
					<i>Етапи попередньої обробки ЕКГ даних (схема алгоритму)</i>	<i>Літ.</i>	<i>Маса</i>	<i>Масштаб</i>
<i>ЗМН</i>	<i>Арк.</i>	<i>№ документа</i>	<i>Підпис</i>	<i>Дата</i>				
<i>Виконав</i>		<i>Гринюк С.О.</i>						
<i>Керівник</i>		<i>Супрун О.М.</i>						
<i>Реценз.</i>					<i>Арк.</i>	<i>1</i>	<i>Аркуші</i>	<i>1</i>
<i>Н. Контр.</i>		<i>Тупота Є.В</i>			<i>М-126-24-1-ІТ</i>			
<i>Зав. каф.</i>		<i>Нечипорук</i>						

# СТРУКТУРА ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ ДІАГНОСТИКИ ЕКГ

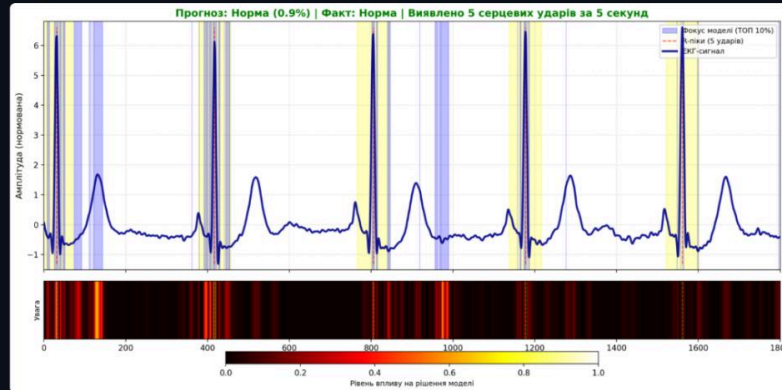


Технології: TensorFlow, Keras, NumPy, Pandas, Streamlit



# ЕКГ-СИГНАЛИ РІЗНИХ КЛАСІВ ПАТОЛОГІЙ

## 4. Діагностика та ХАІ-Аналіз



### Результат

**НОРМА**

Ймовірність аритмії

0.9%

Справний діагноз

**Норма**

Глобальний індекс

0

Локальний індекс

0

### Серцевий ритм

Виявлено R-піків

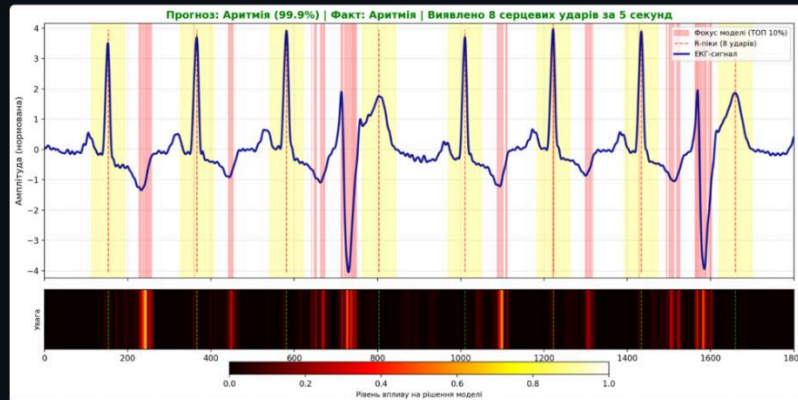
5

Середня ЧСС

56 уд/хв

HRV (SDNN)

17.3 мс



### Результат

**АРИТМІЯ**

Ймовірність аритмії

99.9%

Справний діагноз

**Аритмія**

Глобальний індекс

6

Локальний індекс

0

### Серцевий ритм

Виявлено R-піків

8

Середня ЧСС

100 уд/хв

HRV (SDNN)

17.0 мс

					КАІ 25 03 84 004 ПЛ			
						Літ.	Маса	Масштаб
Змн	Арк.	№ документа	Підпис	Дата	ЕКГ-сигнали різних класів патологій			
Виконав		Гринюк С.О.						
Керівник		Супрун О.М.						
						Арк. 1	Аркуші 1	
Реценз.						М-126-24-1-ІТ		
Н. Контр.		Тупота Є.В						
Зав. каф.		Нечипорук						