

DOI: [https://doi.org/10.26642/ten-2026-1\(97\)-289-296](https://doi.org/10.26642/ten-2026-1(97)-289-296)
УДК 004.75:004.8

П.О. Яковишен, аспірант
С.Є. Тужанський, к.т.н., доц.
Вінницький національний технічний університет

Гібридна архітектура Edge-cloud для обробки часових рядів у телемедицині IoT-пристроїв

У даній роботі запропоновано гібридну архітектуру edge-cloud для обробки часових рядів у телемедицині IoT-системах, що базуються на використанні носимих пристроїв. Актуальність дослідження зумовлена необхідністю забезпечення оперативного, енергоефективного та масштабованого аналізу великих обсягів біомедицині даних, які генеруються в режимі реального часу. Запропонована архітектура передбачає розподіл обчислювальних задач між edge-рівнем та хмарною інфраструктурою з урахуванням характеристик сигналу. На edge-рівні реалізовано попередню обробку даних, що включає фільтрацію сигналів за допомогою фільтра Калмана, зменшення розмірності методом Piecewise Aggregate Approximation (PAA), а також виявлення аномалій із використанням алгоритму Isolation Forest. Додатково впроваджено адаптивну політику передачі даних, яка базується на оцінці варіабельності сигналу та дозволяє динамічно визначати доцільність передачі повних даних або лише агрегованих ознак до cloud-рівня.

На хмарному рівні здійснюється глибокий аналіз часових залежностей із використанням гібридної моделі CNN-LSTM, що поєднує переваги згорткових та рекурентних нейронних мереж для ефективного виявлення складних патернів у даних. Проведене моделювання на відкритих наборах даних показало, що запропонований підхід дозволяє зменшити затримку обробки даних до 120 мс, скоротити мережевий трафік приблизно на 65 % та досягти точності класифікації аномалій на рівні 91 %. Отримані результати підтверджують ефективність адаптивного розподілу обчислювального навантаження між edge- та cloud-рівнями, що забезпечує баланс між швидкодією, точністю аналізу та енергоефективністю системи. Запропонована архітектура може бути використана для побудови сучасних телемедицині систем моніторингу стану здоров'я, особливо в умовах обмежених мережевих ресурсів та високих вимог до обробки даних у реальному часі.

Ключові слова: телемедицина; IoT; edge computing; часові ряди; CNN-LSTM; виявлення аномалій.

Актуальність теми. Розвиток телемедицині систем у сучасних умовах зумовлений зростаючою потребою в ефективному дистанційному моніторингу стану здоров'я пацієнтів, особливо для груп підвищеного ризику, таких як люди похилого віку та пацієнти з хронічними захворюваннями. Використання носимих IoT-пристроїв дозволяє здійснювати безперервний збір фізіологічних даних, що формуються у вигляді часових рядів та потребують оперативної обробки.

Разом з тим традиційні підходи, орієнтовані переважно на хмарні обчислення, не забезпечують необхідного рівня швидкодії та енергоефективності. Передача великих обсягів даних до віддалених серверів призводить до збільшення затримки обробки, перевантаження мережевої інфраструктури та зростання енергоспоживання пристроїв, що є критичним для телемедицині застосувань.

У зв'язку з цим актуальним є розроблення нових підходів до організації обробки даних у телемедицині IoT-системах, зокрема використання гібридних архітектур edge-cloud, які дозволяють ефективно розподіляти обчислювальні ресурси між локальними та хмарними рівнями системи.

Аналіз останніх досліджень та публікацій, на які спираються автори. У сучасних дослідженнях значна увага приділяється використанню гібридних архітектур edge-cloud для обробки даних у телемедицині IoT-системах. Такі підходи дозволяють поєднати низьку затримку локальної обробки з високою обчислювальною потужністю хмарних сервісів.

У роботі Islam et al. запропоновано гібридну fog-edge архітектуру для систем моніторингу здоров'я в IoT. Автори продемонстрували зменшення затримки обробки приблизно на 32 % завдяки виконанню частини обчислень на периферійних вузлах. Водночас запропонований підхід не враховує адаптацію алгоритмів до змін характеристик сигналу в реальному часі [3].

У дослідженні Xi et al. розглянуто інтеграцію носимих пристроїв із технологіями edge computing та штучного інтелекту для систем персоналізованої реабілітації. Архітектура поєднує обробку сигналів ECG на edge-рівні з використанням глибокого навчання в хмарі, що дозволяє досягти точності виявлення аномалій близько 89 % при низькому енергоспоживанні. Однак локальна модель аналізу залишається фіксованою і не адаптується до зміни статистичних властивостей даних [4].

Робота Prabha et al. присвячена побудові захищеної бездротової IoT-архітектури з використанням edge-AI для моніторингу стану здоров'я. Запропонована система використовує LoRaWAN та 5G для передачі даних і забезпечує зменшення мережевого трафіку приблизно на 50 % завдяки застосуванню федеративного навчання. Разом з тим механізми динамічного розподілу обчислень залежно від характеристик сигналу в роботі не розглядаються [5].

У ряді досліджень гібридні архітектури розглядаються як частина ширшої концепції обчислювального континууму. Зокрема, Ficili et al. аналізують інтеграцію IoT, cloud та edge з використанням алгоритмів штучного інтелекту для обробки медичних даних у режимі реального часу [6]. Подібний підхід також розглядається у роботі Montiel Caminos et al., де запропоновано модель edge-cloud AI continuum для моніторингу здоров'я та спортивної активності [7]. Хоча такі системи демонструють високий потенціал для персоналізованого аналізу даних, вони здебільшого орієнтовані на конкретні прикладні сценарії та не враховують адаптивний розподіл навантаження залежно від варіабельності сигналів.

Окрім роботи присвячені оптимізації обробки великих обсягів даних у гібридних IoT-архітектурах. Наприклад, Tariq et al. запропонували оптимізовану edge-cloud платформу для аналізу великих даних у реальному часі [8]. Подібні підходи передбачають використання алгоритмів машинного навчання для підвищення ефективності обробки даних у розподілених IoT-системах. Незважаючи на ефективність цих підходів, питання адаптивного розподілу обчислювальних ресурсів з урахуванням статистичних характеристик вхідних сигналів залишається недостатньо дослідженим.

Проведений аналіз літератури показує, що більшість існуючих рішень використовують статичні механізми розподілу обчислювального навантаження між edge- та cloud-рівнями. Такий підхід не враховує динаміку часових рядів, зокрема зміну дисперсії та рівня шуму сигналів, що може призводити до неефективного використання мережевих та обчислювальних ресурсів. Крім того, у багатьох роботах недостатньо уваги приділяється питанням енергоефективності в умовах обмеженого енергоспоживання носимих пристроїв та нестабільної мережевої інфраструктури.

Для узагальнення результатів попередніх досліджень у таблиці 1 наведено порівняльну характеристику запропонованих у літературі підходів. Значення показників наведені на основі аналізу результатів відповідних робіт.

Таблиця 1

Узагальнене порівняння результатів досліджень edge-cloud архітектур у телемедичних IoT-системах

Робота	Затримка зменшення (%)	Трафік зменшення (%)	Точність (%)	Енергоспоживання (мВт)
Islam et al.	32	40	85	60
Xi et al.	45	45	89	<5
Prabha et al.	28	50	88	10–20

Метою статті є розробка гібридної edge-cloud архітектури для обробки часових рядів у телемедичних IoT-системах із використанням адаптивного механізму розподілу обчислювального навантаження на основі аналізу варіабельності сигналу. Для досягнення поставленої мети в роботі передбачено розроблення структури гібридної архітектури, реалізацію методів попередньої обробки даних на edge-рівні, застосування моделей глибокого навчання на cloud-рівні, а також проведення оцінки ефективності запропонованого підходу.

Викладення основного матеріалу. Запропонована система реалізована у вигляді гібридної edge-cloud архітектури, яка забезпечує розподілену обробку часових рядів, отриманих від носимих IoT-пристроїв. Такий підхід дозволяє поєднати низьку затримку локальної обробки даних з високою обчислювальною потужністю хмарних сервісів.

Архітектура системи складається з чотирьох функціональних рівнів: збору даних (1), edge-обробки (2), передачі даних (3) та cloud-аналітики (4).

Рівень збору даних представлений носимими IoT-пристроями, оснащеними сенсорами (акселерометр, фотоплетизмографія PPG), які формують часові ряди фізіологічних параметрів із частотою дискретизації близько 50 Гц. Отримані дані передаються до edge-рівня, де виконується їх первинна обробка.

Edge-рівень реалізовано у вигляді локального шлюзу (наприклад, Raspberry Pi), який виконує попередню фільтрацію сигналу, зменшення розмірності часових рядів та виявлення аномалій. Це дозволяє значно скоротити обсяг переданих даних та зменшити затримку обробки.

Передача даних між рівнями системи здійснюється за допомогою протоколів MQTT або LoRaWAN залежно від вимог до пропускної здатності та енергоспоживання [9]. Cloud-рівень виконує глибокий аналіз даних із використанням алгоритмів машинного навчання та забезпечує довгострокове зберігання інформації.

Загальна структура системи представлена на рисунку 1.

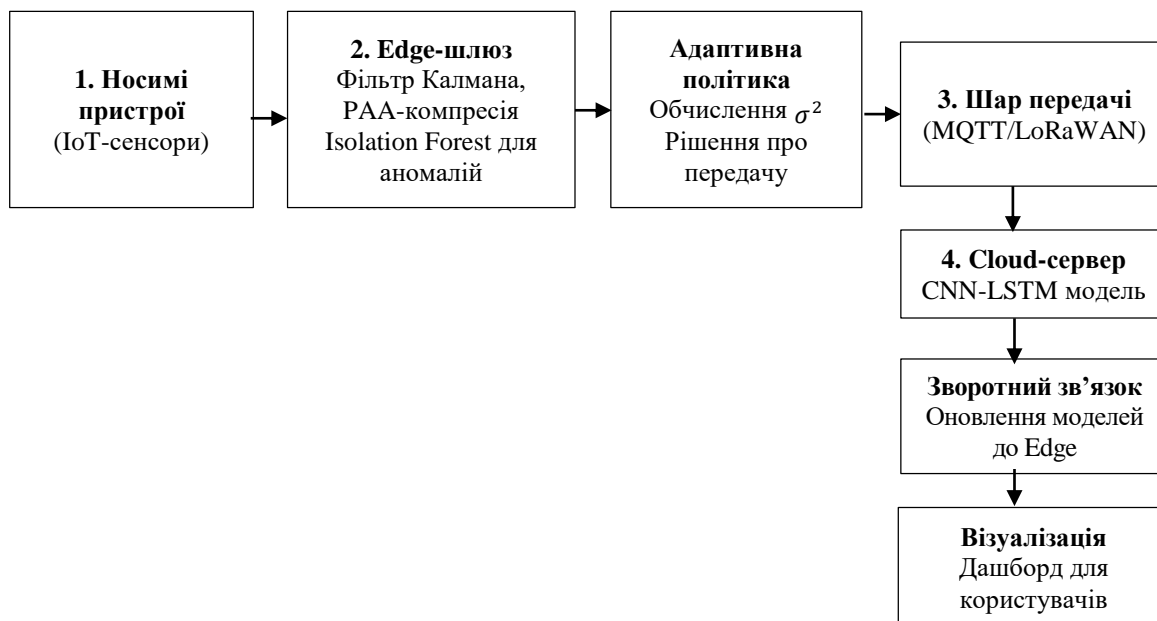


Рис. 1. Блок-схема гібридної edge-cloud архітектури обробки часових рядів

Як показано на рисунку 1, запропонована архітектура забезпечує послідовну обробку даних від рівня збору сигналів до їх глибокого аналізу у хмарному середовищі, що дозволяє ефективно розподіляти обчислювальне навантаження між edge- та cloud-рівнями.

На edge-рівні здійснюється попередня обробка часових рядів з метою зменшення шуму та скорочення обсягу переданих даних. Обробка складається з кількох послідовних етапів: фільтрації сигналу, зменшення розмірності, екстракції ознак та прийняття рішення щодо передачі даних до cloud-рівня.

Фільтрація сигналу виконується за допомогою фільтра Калмана, який дозволяє отримати оптимальну оцінку стану системи в умовах наявності шуму вимірювань. Оновлення оцінки стану здійснюється за формулою [10]:

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

де \hat{x}_k – оцінка стану на кроці k ;

$\hat{x}_{k|k-1}$ – прогноз стану на кроці k на основі попереднього кроку;

K_k – коефіцієнт Калмана;

z_k – поточне вимірювання сигналу;

H – матриця спостереження (як вимірюється стан).

Після фільтрації виконується зменшення розмірності сигналу методом Piecewise Aggregate Approximation (PAA) [11]. Даний метод дозволяє представити часовий ряд у вигляді меншої кількості сегментів шляхом усереднення значень у межах кожного сегменту:

$$\hat{x}_i = 1/2 \sum_{j=(i-1)m+1}^{im} x_j, \quad (2)$$

де \hat{x}_i – апроксимоване значення для i -го сегменту;

m – розмір сегменту;

x_j – оригінальні значення сигналу.

Для виявлення аномальних ділянок сигналу використовується алгоритм Isolation Forest. Модель дозволяє визначати нетипові патерни в часових рядах на основі випадкових дерев ізоляції [12]. Крім того, для оцінки варіабельності сигналу обчислюється дисперсія у ковзному вікні розміром N :

$$\sigma^2 = 1/N \sum (x_i - \mu)^2, \quad (3)$$

де σ^2 – дисперсія сигналу (міра варіабельності);

x_i – значення сигналу в момент i ;

μ – середнє значення сигналу;

N – кількість точок у вікні аналізу.

Отримане значення дисперсії використовується в адаптивній політиці передачі даних. Якщо $\sigma^2 > \theta$ (де θ – порогове значення), то система передає повний сегмент сигналу до cloud-рівня. В іншому випадку передаються лише агреговані статистичні характеристики сигналу.

Такий підхід дозволяє зменшити обсяг переданих даних без суттєвої втрати інформації.

На cloud-рівні виконується поглиблений аналіз часових рядів із використанням гібридної моделі CNN–LSTM. Така архітектура поєднує переваги згорткових нейронних мереж для екстракції локальних ознак сигналу та рекурентних мереж LSTM для моделювання часових залежностей [13].

Згортковий шар Conv1D (64 фільтри, розмір ядра 3) виконує автоматичне виділення локальних патернів у часовому сигналі. Подальша обробка здійснюється рекурентним шаром LSTM (128 нейронів, dropout = 0,2), який враховує довгострокові часові залежності між вимірюваннями.

Навчання моделі здійснюється шляхом мінімізації функції втрат, що поєднує середньоквадратичну похибку прогнозу та L2-регуляризацию:

$$L = 1/n \sum_{i=1}^n (y_i - \hat{y}_i)^2 + \lambda \|W\|_2^2, \quad (4)$$

де y_i – істинне значення;

\hat{y}_i – прогноз моделі;

W – вагові коефіцієнти мережі;

$\lambda = 0,01$ – коефіцієнт регуляризації.

Навчання виконується за допомогою оптимізатора Adam із розміром пакету 32 протягом 50 epoch [14]. Після завершення навчання параметри моделі можуть передаватися на edge-рівень для корекції локальних алгоритмів обробки даних.

Моделювання виконано в середовищі Python. Для реалізації edge-моделей використано бібліотеку scikit-learn, для cloud-рівня – TensorFlow.

Експерименти проведено на відкритих наборах даних: UCI Human Activity Recognition та Daphnet Freezing of Gait.

Формування вибірок здійснювалось методом ковзного вікна. Загальна кількість сформованих зразків становила 10 000. Для моделювання реалістичних умов передачі до сигналу додано гауссів шум із відношенням сигнал/шум SNR = 20 дБ.

Оцінювання проводилось у 1000 повторних ітераціях (Monte Carlo) з фіксацією таких метрик:

- затримка обробки (мс);
- обсяг переданих даних (кБ);
- точність класифікації (Accuracy, F1-score);
- відносне зниження трафіку (%);
- обчислювальні витрати (CPU time як проксі енергоспоживання).

Порівняння виконувалося між двома сценаріями: повна передача часових рядів у cloud та адаптивна edge-фільтрація з передачею зведених ознак.

Отримані результати дозволяють кількісно оцінити вплив гібридної архітектури на затримку передачі, навантаження на канал та точність прогнозування.

Результати проведеного моделювання свідчать про ефективність запропонованої гібридної edge-cloud архітектури для обробки часових рядів у телемедицині IoT-системах. Отримані показники демонструють суттєве покращення ключових характеристик системи порівняно з традиційними підходами.

Зокрема, середня затримка обробки даних зменшилася з 850 мс у випадку повністю хмарної архітектури до 120 мс у запропонованій гібридній моделі. Отримане значення відповідає вимогам систем реального часу для телемедицині застосувань, де допустима затримка зазвичай не перевищує 200 мс [15].

Запропонована адаптивна політика передачі даних дозволила скоротити обсяг переданого мережевого трафіку приблизно на 65 %. Це досягається завдяки використанню механізму аналізу дисперсії сигналу: при низькій варіабельності сигналу передаються лише агреговані статистичні характеристики, тоді як при виявленні аномальних ділянок до cloud-рівня передається повний сегмент сигналу.

Точність класифікації аномалій у запропонованій системі склала 91 %, при значеннях precision = 0,89, recall = 0,93 та F1-score = 0,91. Отримані результати демонструють покращення точності на 2–13 % порівняно з базовими моделями, що пояснюється використанням комбінованого підходу, який поєднує попередню обробку на edge-рівні з глибоким аналізом даних у хмарі.

Оцінка обчислювальних витрат показала, що енергоспоживання edge-вузла становить приблизно 42 мВт. Це значення отримано на основі аналізу часу виконання обчислень та типового енергоспоживання процесора Raspberry Pi. Такий рівень енергоспоживання дозволяє забезпечити автономну роботу пристрою протягом тривалого часу при використанні акумуляторного живлення.

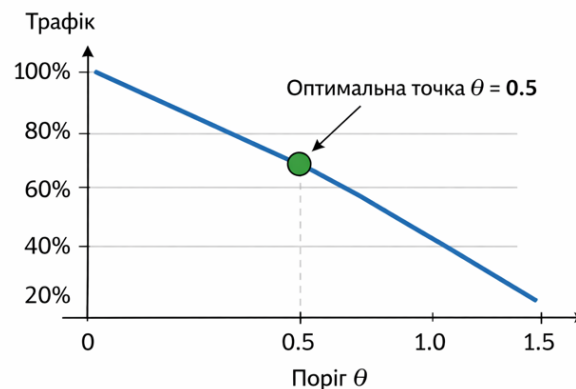
Основні результати експерименту наведено в таблиці 2.

Таблиця 2

Порівняння метрик продуктивності телемедичної IoT-системи

Архітектура	Затримка (мс)	Трафік (% від повного)	Точність (%)	Енергоспоживання (мВт)
Тільки cloud	850	100	89	–
Тільки edge	45	0	78	48
Гібрид ($\theta = 0,5$)	120	35	91	42

Для аналізу впливу порогового параметра θ на обсяг переданих даних на рисунку 2 показано залежність мережевого трафіку від значення цього параметра.

Рис. 2. Залежність обсягу переданого мережевого трафіку від порогового параметра θ

З графіка видно, що зі збільшенням значення θ обсяг переданих даних поступово зменшується. Оптимальним виявилось значення $\theta = 0,5$, при якому досягається компроміс між точністю аналізу та обсягом переданого трафіку.

Для детальнішої оцінки ефективності моделі глибокого навчання проведено аналіз її класифікаційних характеристик на тестових вибірках. Основні метрики продуктивності моделі CNN–LSTM наведено у таблиці 3.

Таблиця 3

Основні метрики продуктивності моделі CNN–LSTM

Метрика	Значення	Стандартне відхилення
Точність	91 %	2,1 %
Precision	0,89	0,03
Recall	0,93	0,02
F1-score	0,91	0,02
Latency (ms)	320	15

Значення latency 320 мс відповідає часу виконання моделі CNN–LSTM на cloud-рівні та не включає затримку передачі даних і попередньої обробки на edge-рівні.

Як видно з результатів, модель демонструє стабільні показники класифікації. Значення F1-score на рівні 0,91 свідчить про збалансованість між точністю та повнотою виявлення аномалій.

Для додаткової оцінки якості класифікації на рисунку 3 наведено ROC-криву запропонованої моделі.

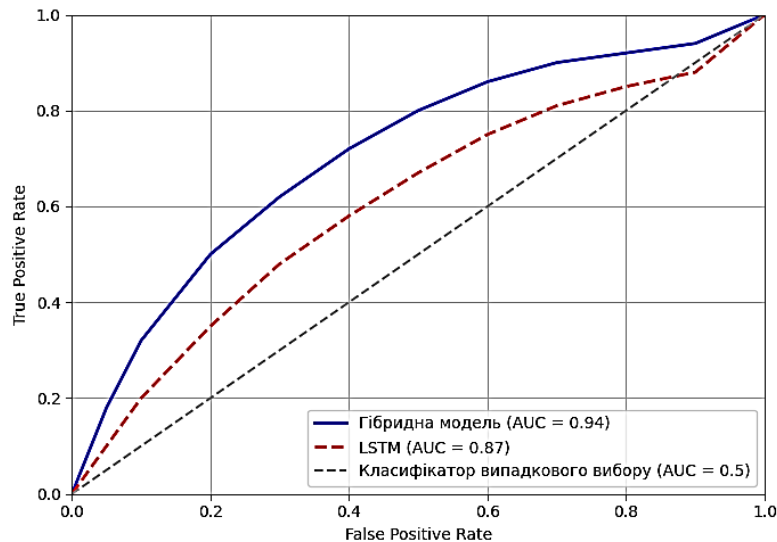


Рис. 3. ROC-крива гібридної CNN–LSTM моделі для виявлення аномалій у часових рядах

Отримана площа під кривою (AUC = 0,94) перевищує відповідний показник базової моделі LSTM (AUC = 0,87), що свідчить про покращення чутливості та специфічності запропонованого підходу. Таким чином, результати експерименту підтверджують ефективність використання гібридної edge-cloud архітектури для телемедичних систем моніторингу.

Отже, отримані результати демонструють, що використання адаптивної політики передачі даних на основі дисперсії сигналу дозволяє ефективно балансувати навантаження між edge- та cloud-рівнями системи. У випадках високої варіабельності сигналу ($\sigma^2 > 0,5$) передача повного сегмента забезпечує збереження точності аналізу, тоді як при низькій варіабельності передача агрегованих характеристик дозволяє значно зменшити обсяг переданих даних.

Затримка обробки на рівні 120 мс дозволяє використовувати систему для задач оперативного моніторингу стану пацієнтів, зокрема для виявлення падінь або інших критичних подій. Водночас зменшення мережевого трафіку сприяє підвищенню енергоефективності системи та зменшенню навантаження на мережеву інфраструктуру.

Ефективність моделі CNN–LSTM пояснюється здатністю згорткових нейронних мереж виділяти локальні патерни сигналу, тоді як рекурентні мережі LSTM дозволяють враховувати довгострокові часові залежності у даних.

Для оцінки ефективності запропонованої архітектури проведено порівняльний аналіз із сучасними дослідженнями у галузі edge-cloud обчислень для телемедичних IoT-систем.

У роботі Islam et al. запропоновано гібридну fog-edge архітектуру для систем моніторингу здоров'я в IoT, яка дозволяє виконувати попередню обробку даних на периферійних вузлах і передавати до хмари лише значущі події. За результатами експериментального дослідження автори повідомляють про приблизно 70 % зменшення затримки, близько 60 % економії мережевого трафіку та покращення енергоефективності приблизно на 30 % порівняно з традиційною cloud-орієнтованою архітектурою.

У дослідженні Xi et al. розглянуто інтеграцію носимих пристроїв із edge computing та алгоритмами штучного інтелекту для систем персоналізованої реабілітації. Запропонований підхід поєднує локальну обробку сигналів ECG на edge-рівні з глибоким аналізом даних у хмарному середовищі. Отримана точність виявлення аномалій становить приблизно 89 %, що підтверджує ефективність використання гібридних архітектур для аналізу медичних часових рядів.

У роботі Prabha et al. запропоновано безпечну бездротову IoT-архітектуру для моніторингу стану здоров'я з використанням edge-AI. У системі застосовано механізми федеративного навчання та оптимізовану передачу даних через LoRaWAN і 5G, що дозволяє скоротити обсяг мережевого трафіку приблизно на 50 %. Проте запропонований підхід не враховує адаптивний розподіл обчислювального навантаження залежно від статистичних характеристик сигналів.

Порівняно з наведеними дослідженнями, у даній роботі запропоновано адаптивну edge-cloud архітектуру, яка використовує аналіз дисперсії сигналу для динамічного прийняття рішення щодо передачі даних до cloud-рівня. Проведені експерименти показали, що такий підхід дозволяє досягти точності 91 %, скоротити обсяг переданого трафіку приблизно на 65 % та зменшити затримку обробки до 120 мс.

Отримані результати підтверджують, що використання адаптивного механізму розподілу обчислень між edge- та cloud-рівнями дозволяє ефективніше використовувати мережеві та обчислювальні ресурси порівняно з більшістю існуючих рішень.

Проведене дослідження має низку обмежень, які необхідно враховувати при інтерпретації отриманих результатів. По-перше, експериментальна оцінка ефективності системи виконувалася у середовищі симуляційного моделювання. Хоча використані набори даних та параметри моделювання відповідають реалістичним умовам роботи телемедицини систем, у реальних IoT-мережах можливі додаткові затримки, пов'язані з нестабільністю мережевого з'єднання, апаратними обмеженнями пристроїв та особливостями роботи бездротових каналів зв'язку. По-друге, ефективність запропонованої адаптивної політики передачі даних залежить від вибору порогового параметра θ , який визначає умову передачі повного сегмента сигналу до cloud-рівня. Проведений експериментальний аналіз показав, що при значеннях $\theta < 0,3$ обсяг переданого трафіку значно зростає (до приблизно 70 % від повного), оскільки система частіше передає повні сегменти сигналу. Натомість при $\theta > 0,8$ спостерігається зниження точності виявлення аномалій (до приблизно 84 %) через пропуск деяких значущих змін сигналу. Оптимальним значенням параметра у проведених експериментах виявилось $\theta = 0,5$, що забезпечує баланс між точністю аналізу та обсягом переданих даних.

Крім того, у даній роботі розглядався аналіз часових рядів окремих сенсорів, тоді як у реальних телемедицини системах часто використовуються мультимодальні дані, отримані з кількох типів датчиків. Урахування кореляції між різними сенсорними каналами може додатково покращити точність аналізу та є перспективним напрямом подальших досліджень.

Незважаючи на зазначені обмеження, результати моделювання демонструють потенціал запропонованої гібридної архітектури для підвищення ефективності обробки даних у телемедицини IoT-системах.

Висновки та перспективи подальших досліджень. У роботі запропоновано гібридну архітектуру edge-cloud для обробки часових рядів у носимих IoT-пристроях телемедицини систем. Архітектура поєднує попередню обробку сигналів на edge-рівні з використанням алгоритмів машинного навчання на cloud-рівні, що дозволяє ефективно розподіляти обчислювальне навантаження між рівнями системи.

Для реалізації edge-обробки застосовано фільтр Калмана, алгоритм зменшення розмірності PAA та метод виявлення аномалій Isolation Forest. На cloud-рівні використано гібридну модель глибокого навчання CNN-LSTM, що дозволяє враховувати як локальні, так і довгострокові часові залежності у сигналах.

Результати експериментального моделювання показали, що використання запропонованої архітектури дозволяє:

- зменшити затримку обробки даних з 850 мс до 120 мс;
- скоротити обсяг переданого мережевого трафіку приблизно на 65 %;
- досягти точності класифікації аномалій на рівні 91 %;
- знизити обчислювальні витрати на edge-рівні до приблизно 42 мВт.

Отримані результати підтверджують ефективність використання адаптивного підходу передачі даних на основі аналізу дисперсії сигналу для оптимізації обробки даних у телемедицини IoT-системах.

Подальші дослідження можуть бути спрямовані на розширення можливостей запропонованої архітектури та її практичну апробацію. Зокрема, перспективними напрямами є:

- проведення експериментальних досліджень на реальних носимих телемедицини пристроях;
- використання мереж 5G для пріоритетної передачі критичної медичної інформації;
- аналіз мультимодальних сенсорних даних (PPG, акселерометр, ECG) для підвищення точності діагностики;
- дослідження енергоефективних алгоритмів обробки сигналів для пристроїв з обмеженими ресурсами.

Реалізація зазначених напрямів може сприяти подальшому розвитку телемедицини систем моніторингу стану здоров'я та підвищенню ефективності використання IoT-технологій у медичних застосуваннях.

References:

1. Islam, S.M.R. et al. (2015), «The Internet of Things for Health Care: A Comprehensive Survey», *IEEE Access*, Vol. 3, pp. 678–708, doi: 10.1109/ACCESS.2015.2437951.
2. Himanshu, V. et al. (2023), «A Comprehensive review of 'Internet of Healthcare Things': Networking aspects, technologies, services, applications, challenges, and security concerns», *Computer Science Review*, Vol. 50, doi: 10.1016/j.cosrev.2023.100591.
3. Islam, U. et al. (2025), «A hybrid fog-edge computing architecture for real-time health monitoring in IoMT systems with optimized latency and threat resilience», *Scientific Reports*, doi: 10.1038/s41598-025-09696-3.
4. Xi, L. et al. (2025), «Integrating wearable health devices with AI and edge computing for personalized rehabilitation», *J Cloud Comput.* doi: 10.1186/s13677-025-00795-0.

5. Prabha, M. et al. (2025), «Edge-AI integrated secure wireless IoT architecture for real time healthcare monitoring and federated anomaly detection», *Sci Rep*, doi: 10.1038/s41598-025-30150-x.
6. Ficili, I. et al. (2025), «From Sensors to Data Intelligence: Leveraging IoT, Cloud, and Edge Computing with AI», *Sensors*, doi: 10.3390/s25101763.
7. Montiel Caminos, J. et al. (2025), «Advancing Wearable Health and Sports Monitoring Through an Edge-Cloud AI Continuum», *ACM*, doi: 10.1145/3706594.3727580.
8. Tariq, M.U. et al. (2023), «An optimized IoT-enabled big data analytics architecture for edge-cloud computing», *IEEE Internet of Things Journal*, doi: 10.1109/JIOT.2023.3294809.
9. Yakovyshen, P.O. and Tuzhanskyi, S.Ye. (2024), «Analiz metodiv peredavannia danykh v teledychnykh systemakh», *Optyko-elektronni informatsiino-enerhetychni tekhnolohii*, doi: 10.31649/1681-7893-2024-47-1-222-232.
10. Kalman, R.E. (1960), «A new approach to linear filtering and prediction problems», *J Basic Eng*, doi: 10.1115/1.3662552.
11. Keogh, E. et al. (2001), «Dimensionality reduction for fast similarity search in large time series databases», *Knowl Inf Syst*, doi: 10.1007/PL00011623.
12. Liu, F.T. et al. (2008), «Isolation Forest», *IEEE International Conference on Data Mining*, doi: 10.1109/ICDM.2008.17.
13. Hochreiter, S. and Schmidhuber, J. (1997), «Long Short-Term Memory», *Neural Computation*, doi: 10.1162/neco.1997.9.8.1735.
14. Kingma, D. and Ba, J. (2015), «Adam: A Method for Stochastic Optimization», *ICLR*, doi: 10.48550/arXiv.1412.6980.
15. Vergütz, A. et al. (2020), «An Architecture for the Performance Management of Smart Healthcare Applications», *Sensors*, doi: 10.3390/s20195566.

Яковишен Павло Олександрович – аспірант кафедри біомедичної інженерії та оптико-електронних систем Вінницького національного технічного університету.

<https://orcid.org/0009-0006-6292-0226>.

Наукові інтереси:

- телемедичні системи;
- обробка та передача біомедичних даних.

Тужанський Станіслав Євгенович – доцент кафедри біомедичної інженерії та оптико-електронних систем Вінницького національного технічного університету.

<https://orcid.org/0000-0002-0185-7490>.

Наукові Інтереси:

- оптико-інформаційні системи;
- лазерні медичні системи і технології.

Yakovyshen P.O., Tuzhanskyi S.Ye.

A hybrid edge-cloud architecture for time series processing in telemedicine IoT systems

This paper proposes a hybrid edge-cloud architecture for processing time series data in telemedicine IoT systems based on wearable devices. The relevance of the study is driven by the need to ensure efficient, low-latency, energy-efficient, and scalable analysis of large volumes of biomedical data generated in real time. The proposed architecture enables the distribution of computational tasks between the edge layer and cloud infrastructure, taking into account signal characteristics. At the edge level, preliminary data processing is performed, including signal filtering using a Kalman filter, dimensionality reduction via Piecewise Aggregate Approximation (PAA), and anomaly detection using the Isolation Forest algorithm. In addition, an adaptive data transmission policy is implemented, based on signal variability estimation, which allows dynamic selection between transmitting full data segments or aggregated features to the cloud.

At the cloud level, in-depth analysis of temporal dependencies is carried out using a hybrid CNN-LSTM model that combines the advantages of convolutional and recurrent neural networks for effective extraction of complex patterns in the data. Simulation results on publicly available datasets demonstrate that the proposed approach reduces processing latency to 120 ms, decreases network traffic by approximately 65 %, and achieves anomaly detection accuracy of 91 %. The obtained results confirm the effectiveness of adaptive workload distribution between edge and cloud layers, ensuring a balance between system responsiveness, analytical accuracy, and energy efficiency. The proposed architecture can be applied in modern telemedicine monitoring systems, particularly under conditions of limited network resources and strict real-time processing requirements.

Keywords: telemedicine; IoT; edge computing; time series; CNN-LSTM; anomaly detection.

Стаття надійшла до редакції 31.12.2025.