

DOI: <https://doi.org/10.36910/6775-2524-0560-2026-62-29>

УДК 004.738.5:004.65

Мусієнко Максим Павлович<sup>1</sup>, д.т.н., професор

<https://orcid.org/0000-0001-9228-2233>

Мусієнко Олена Юрїївна<sup>2</sup>, магістрант

<sup>1</sup>Черкаський національний університет ім. Б.Хмельницького, м. Черкаси, Україна

<sup>2</sup>Чорноморський національний університет ім. П.Могили, м. Миколаїв, Україна

## ПОРІВНЯЛЬНИЙ АНАЛІЗ АРХІТЕКТУР ХМАРНИХ СХОВИЩ ДЛЯ ВИСОКОЧАСТОТНИХ ДАНИХ В СИСТЕМАХ ІоТ: AMAZON DYNAMODB В ПОРІВНЯННІ З AMAZON TIMESTREAM

Мусієнко М.П., Мусієнко О.Ю. Порівняльний аналіз архітектур хмарних сховищ для високочастотних даних в системах ІоТ: Amazon DynamoDB в порівнянні з Amazon Timestream. Стаття присвячена вирішенню науково-практичної задачі оптимізації архітектур хмарного зберігання для систем промислового Інтернету речей (ІоТ), що працюють із високочастотними сигналами, які контролюються п'єзокерамічними датчиками. Встановлено, що при масштабуванні ІоТ-мереж традиційні нереляційні бази даних, такі як Amazon DynamoDB, демонструють значне зростання вартості та зменшення швидкодії системи. Авторами розроблено та обґрунтовано архітектурну модель гібридного зберігання, яка забезпечує баланс між швидкістю оперативної обробки телеметричних даних та економічною доцільністю тривалого зберігання. Модель базується на використанні високошвидкісного DynamoDB для моніторингу в режимі реальному часу та Amazon Timestream як аналітичного сховища для накопичених даних. Описано методику периферійної обробки на мікроконтролерах ESP32, що включає розрахунок середньоквадратичного значення (RMS) для стиснення інформації без втрати інформаційних даних. На основі імітаційного моделювання у середовищі AWS Academy Learning Lab проведено порівняльний аналіз швидкодії та сукупних витрат на утримання інфраструктури. Експериментально доведено, що запропонований підхід підвищує швидкість аналітичних запитів у 5,44 рази та знижує витрати на зберігання на 41% при накопиченні даних понад 30 діб. Наукова новизна полягає у математичному обґрунтуванні «порогу ефективності» архітектур при масштабуванні систем. Практичне значення результатів полягає у створенні рекомендацій для побудови відмовостійких систем прогнозу діагностики з мінімальними експлуатаційними витратами.

**Ключові слова:** AWS, Amazon DynamoDB, Amazon Timestream, ІоТ датчики, високочастотний моніторинг, хмарна архітектура

Musiyenko M., Musiyenko O. Comparative Analysis of Cloud Storage Architectures for High-Frequency Data in IoT Systems: Amazon DynamoDB vs. Amazon Timestream. The article is dedicated to solving the scientific and practical problem of optimizing cloud storage architectures for Industrial Internet of Things (IIoT) systems operating with high-frequency signals monitored by piezoceramic sensors. It has been established that during the scaling of IIoT networks, traditional non-relational databases, such as Amazon DynamoDB, exhibit significant cost increases and system performance degradation. The authors have developed and substantiated an architectural model for hybrid storage that ensures a balance between the speed of operational telemetry data processing and the economic feasibility of long-term storage. The model is based on utilizing high-speed DynamoDB for real-time monitoring and Amazon Timestream as an analytical repository for accumulated data. A method for edge processing on ESP32 microcontrollers is described, involving Root Mean Square (RMS) calculation for data compression without the loss of diagnostic information. Based on simulation modeling within the AWS Academy Learning Lab environment, a comparative analysis of performance and Total Cost of Ownership (TCO) was conducted. It has been experimentally proven that the proposed approach increases the speed of analytical queries by 5.44 times and reduces storage costs by 41% when accumulating data for more than 30 days. The scientific novelty lies in the mathematical substantiation of the «efficiency threshold» for architectures during system scaling. The practical significance of the results consists in creating recommendations for developing fault-tolerant predictive maintenance systems with minimal operating expenses.

**Keywords:** AWS, Amazon DynamoDB, Amazon Timestream, IIoT sensors, high-frequency monitoring, cloud architecture.

**Постановка наукової проблеми.** Сучасний розвиток промислового Інтернету речей (Industrial Internet of Things, ІоТ) характеризується переходом від простого збору вимірювальної інформації (з датчиків) до побудови інтелектуальних систем прогнозного аналізу в реальному режимі часу. Важливе місце в таких системах займають високочастотні датчики, наприклад, п'єзокерамічні датчики, які можуть вимірювати багато фізичних величин різної природи. Інтеграція таких датчиків із мікроконтролерами первинної обробки інформації та інфраструктурою хмарного провайдера, наприклад, Amazon Web Services (AWS), дозволяє ефективно виявляти мікрodefекти обладнання на ранніх стадіях його життєвого циклу.

Однак масштабування таких систем до індустриального рівня з сотнями точок вимірювань створює суттєву проблему – накопичення великих обсягів вимірювальних даних. Кількість підключених ІоТ пристроїв вже сягає десятків мільярдів екземплярів і ця цифра з кожним роком тільки зростає. Це потребує не тільки надійних каналів передачі даних, а й економічно доцільних та швидкодіючих архітектур зберігання отриманих вимірювальних даних.

Традиційно для зберігання IoT даних в AWS використовується сервіс Amazon DynamoDB – потужна нереляційна (NoSQL) база даних, яка може забезпечити мінімальну затримку при записі даних. Однак при роботі з великим потоком даних, наприклад, при заданні високої частоти дискретизації сигналу з п'єзодатчиків, DynamoDB демонструє суттєві недоліки: високу вартість зберігання накопичених даних та відсутність вбудованих функцій для аналізу телеметричної інформації. Альтернативним рішенням є застосування Amazon Timestream – спеціалізоване безсерверне сховище, яке пропонує багаторівневу архітектуру типів зберігання даних, що дозволяє зменшити витрати на зберігання накопичених даних на кілька десятків відсотків.

Незважаючи на наявність чималих досліджень сервісів AWS, практично відсутні наукові дослідження, що дозволяють порівняти ефективність різних типів сховищ: DynamoDB та Timestream, які працюють з телеметричною інформацією, що отримана від множини високочастотних IoT датчиків.

**Наукова проблема** полягає у дослідженні та обґрунтуванні архітектурної моделі гібридного зберігання даних з IoT датчиків у різних типах сховищ: NoSQL та бази даних часових рядів (БДЧР), яка б забезпечувала швидкодію системи та економічну доцільність тривалого зберігання великого обсягу накопичених телеметричних даних. Для цього необхідно вирішити задачу оптимального вибору хмарного сховища при врахуванні кількісних метрик швидкодії та сукупних витрат на утримання інфраструктури (англ. Total Cost of Ownership – TCO).

**Практичне значення** вирішення цієї поставленої задачі пов'язане з отриманням методичних рекомендацій щодо побудови масштабованих вимірювальних IoT систем, які дозволяють організаціям зменшити експлуатаційні витрати на хмарну інфраструктуру при збереженні точності прогнозної діагностики.

Таким чином, актуальність теми науково-практичного дослідження обумовлена необхідністю оптимізації ресурсів хмарного провайдера AWS для IoT систем моніторингу промислових об'єктів із застосуванням високочастотних датчиків.

**Аналіз останніх досліджень.** Сучасний розвиток досліджень IoT пристроїв характеризується переносом уваги від простого збору телеметричної інформації до складних аналітичних завдань. У попередніх працях авторів [1] була показана ефективність використання п'єзокерамічних датчиків та мікроконтролерів обробки первинної інформації для побудови прогнозних систем у хмарі AWS, доведена висока точність при застосуванні алгоритмів машинного навчання для виявлення аномалій. Актуальність цього підходу підтверджується і в сучасних дослідженнях [2], де вказується на необхідності впровадження адаптивних методів аналізу багатовимірних потоків вимірювальних даних у критичних IoT системах.

Проте, як зазначено дослідниками в роботі [3], при масштабуванні IoT-мереж виникає суттєва проблема інформаційного перевантаження сховищ, що призводить до значного зменшення швидкодії всієї вимірювальної системи.

В останні роки чимало робіт було присвячено архітектурній оптимізації хмарних сховищ для сенсорних мереж. Зокрема, у дослідженні [4] наведено детальну класифікацію витрат на хмарне зберігання, де показана складність прогнозування сукупних витрат на утримання інфраструктури через багатофакторну тарифікацію операцій із даними. При цьому, аналіз [5] практичного застосування NoSQL для великих масивів телеметричної інформації вказує на їхню обмежену ефективність: Amazon DynamoDB забезпечує стабільно низьку затримку при записі окремих транзакцій, проте демонструє значне зростання обчислювальних витрат при виконанні складних записів за великі проміжки часу.

Інший підхід полягає у застосуванні спеціалізованих БДЧР. У роботі [6] авторами показано, що при обробці телеметричної інформації такі системи мають вищу продуктивність порівняно з традиційними базами. Зокрема, виконання сховища на базі Amazon Timestream дозволяє автоматизувати життєвий цикл вимірювальних даних завдяки багаторівневій архітектурі (використанню швидкої пам'яті Memory Store та економічного сховища Magnetic Store), що суттєво знижує сукупні витрати на утримання хмарної інфраструктури.

Незважаючи на значну кількість наукових праць, що присвячених окремим сервісам AWS, практично відсутні комплексні дослідження порівняння ефективності гібридного застосування DynamoDB та Timestream саме в контексті високочастотних сигналів з IoT датчиків, що потребує одночасного забезпечення в режимі реальному часу моніторингу стану об'єкту та глибокої аналітики накопичених даних.

**Виділення невіршених раніше частин загальної проблеми.** Незважаючи на значний прогрес у розробці апаратної інтеграції високочастотних датчиків із хмарними платформами (зокрема, AWS) та успішну реалізацію алгоритмів машинного навчання для визначення дефектів, поза увагою науковців залишається проблема оптимізації архітектури збереження вимірювальних даних. В більшості сучасні рішення побудовані із використанням NoSQL бази даних (наприклад, Amazon DynamoDB), які забезпечують мінімальну затримку при записі, але мають суттєві обмеження в питаннях аналітичної обробки інформації. Використання DynamoDB для великих обсягів телеметричної інформації веде до нелінійного зростання обчислювальних витрат. Спеціалізовані рішення, наприклад, Amazon Timestream, пропонують принципово іншу модель гібридного зберігання (швидкої пам'яті Memory Store та економічного сховища Magnetic Store). Проте визначення межі економічної та технічної доцільності («порог ефективності») впровадження спеціалізованих архітектур порівняно з поширеними NoSQL системами саме для сигналів високочастотних датчиків потребує додаткового дослідження. Існує нагальна потреба в дослідженні кількісних показників швидкодії та економічної доцільності при масштабуванні IIoT вимірювальних систем, що дозволить обґрунтовано обирати ефективні типи сховищ ще на етапі проектування системи.

**Мета роботи** полягає у розробці та обґрунтуванні архітектурної моделі гібридного зберігання телеметричних даних з високочастотних IIoT датчиків у промисловому Інтернеті речей на основі порівняльного аналізу сервісів Amazon DynamoDB та Amazon Timestream.

**Виклад основного матеріалу дослідження.**

*Архітектурна модель гібридного зберігання IIoT даних.* Для вирішення проблеми високої вартості та зменшення швидкодії при обробці високочастотних сигналів у роботі розроблено архітектурну модель гібридного диференційованого зберігання (рис. 1). Основна ідея полягає у розподілі вимірювальної інформації на два функціональні потоки залежно від їхньої терміновості доступу та типу аналізу.

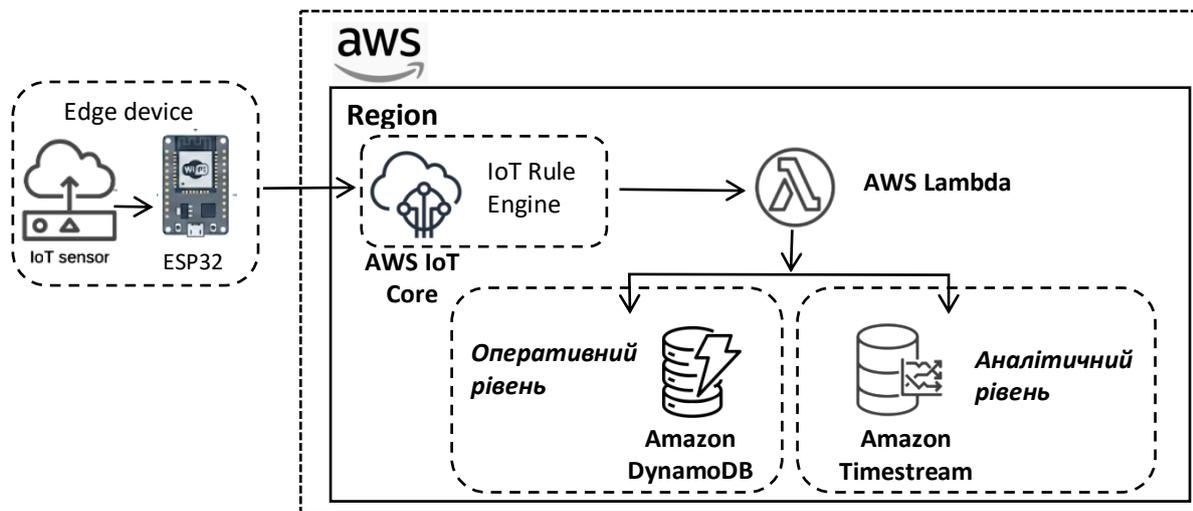


Рис. 1. Архітектурна модель гібридного зберігання високочастотних IIoT даних

Згідно із запропонованою моделлю, дані від високочастотних датчиків (Edge device), попередньо оброблені мікроконтролером, надходять до хмарного вузла обробки повідомлень AWS IoT Core. Завдяки механізму AWS IoT Rules Engine та роботі AWS Lambda (тригеру), система здійснює вибіркочу маршрутизацію вхідних MQTT-повідомлень: критичні показники (наприклад, вібрації) для миттєвого реагування спрямовуються до NoSQL таблиць Amazon DynamoDB, в той час, як повний масив телеметричних даних переадресовується до БДЧР в Amazon Timestream. Таким чином, отримуємо два рівні:

– *оперативний рівень*: спрямовує агреговані (тобто узагальнені, статистично оброблені) показники високочастотного сигналу (наприклад, параметрів вібрації від п'єзокерамічних датчиків) в Amazon DynamoDB. Це забезпечує мінімальну затримку (latency) для систем моніторингу

реального часу та систем аварійної сигналізації. На цьому рівні дані мають обмежений життєвий цикл і автоматично видаляються після завершення визначеного періоду (наприклад, через тиждень).

– *аналітичний рівень*: паралельно спрямовує повний потік вимірювальних показників в Amazon Timestream. На даному рівні дані зберігаються у двох режимах: Memory Store (для швидкого аналізу показників, наприклад, останніх 30 діб) та Magnetic Store (для економічного довгострокового зберігання накопичених даних строком до декількох років).

Така дворівнева модель дозволяє уникнути обмеження поширених NoSQL баз даних, де виконання SQL-запитів до великих масивів накопичених даних є повільним та дорогим з точки зору виконання відповідних обчислень.

*Математичне обґрунтування та методи обробки сигналів*. Реалізація запропонованої моделі гібридного зберігання потребує попередньої математичної обробки «сирих» сигналів на стороні мікроконтролера первинної обробки інформації (наприклад, ESP32). Оскільки високочастотні датчики мають велику вибірку через малий час дискретизації сигналу (наприклад, п'єзокерамічні датчики вібрації muRata 7BB-12-9 мають частоту резонансу біля 9 кГц), то пряма передача кожного значення вимірювання в хмару призвела б до перевантаження мережі та значного зростання витрат у DynamoDB.

Для стиснення інформації без втрати діагностичних ознак у роботі застосовано метод віконної агрегації [7–9]. Основним показником інтенсивності, наприклад, вібрації, обрано середньоквадратичне значення (Root Mean Square – RMS), яке найбільш точно описує енергетичний стан обладнання [10]. Розрахунок цього значення ( $A_{RMS}$ ) на периферійному пристрої (Edge device) здійснюється за формулою:

$$A_{RMS} = \sqrt{\frac{1}{n} \sum_{i=1}^n a_i^2},$$

де  $a_i$  – амплітуда одиничного виміру,  $n$  – кількість вибірок у вікні аналізу (для дослідження було обрано  $n = 1024$ ). Це агреговане значення передається на оперативний рівень (в DynamoDB) для моніторингу в режимі реальному часу.

Для наукового обґрунтування вибору між DynamoDB та Timestream в роботі розроблена математична модель сукупних витрат на утримання інфраструктури ( $C_{TCO}$ ), яка враховує специфіку тарифів хмарних сервісів AWS. Загальна функція витрат описується рівнянням:

$$C_{TCO} = C_{ing}(V) + C_{stor}(V, t) + C_q(V, q),$$

де  $C_{ing}(V)$  – вартість прийому даних (*ingest*), що для DynamoDB залежить від одиниць потужності запису ( $WCU$  – *Write Capacity Units*), а для Timestream – від об'єму вхідних Гб;

$C_{stor}(V, t)$  – вартість зберігання (*storage*), яка в Timestream є нелінійною функцією часу  $t$  (переміщення даних із дорогого Memory Store у дешевший Magnetic Store);

$C_q(V, q)$  – вартість виконання запитів (*query*), що залежить від кількості  $q$  та об'єму просканованих даних  $V$ .

Економічна перевага при використанні Timestream ( $\Delta C$ ) для довгострокових накопичених даних (при  $t > 30$  діб) визначається формулою:

$$\Delta C = C_{DynDB} - (C_{T\_Mem} + C_{T\_Mag}),$$

де  $C_{DynDB}$  – вартість зберігання даних в DynamoDB;

$C_{T\_Mem}$  – вартість зберігання даних в Timestream (при використанні Memory Store);

$C_{T\_Mag}$  – вартість зберігання даних в Timestream (при використанні Magnetic Store).

Згідно з гіпотезою дослідження, за рахунок використання Magnetic Store, який у десятки разів дешевший за сховище DynamoDB, значення  $\Delta C$  зростатиме пропорційно обсягу накопичених даних та кількості датчиків. Це математично підтверджує доцільність використання Timestream як основного аналітичного сховища для накопичених даних високочастотних сигналів IoT датчиків.

*Опис експериментальної установки та методика проведення досліджень*. Для експериментальної перевірки запропонованої моделі було розроблено лабораторний стенд, що імітує роботу промислового пристрою з контрольованим рівнем вібрації.

В якості IoT датчиків параметрів вібрації використанні асиметричні біморфні п'єзокерамічні елементів muRata 7BB-12-9, що були закріплені на консольній сталевій пластині марки 08пс/3сп розміром 35×20×0,4 мм. Механічні коливання генерувалися мотором AMS1141M з асиметричним навантаженням на валу. Для збору даних та їх первинної обробки (в тому числі розрахунку RMS) використовувався мікроконтролер ESP32-WROOM-32, який забезпечує передачу пакетів у форматі JSON через протокол MQTT.

Методика дослідження передбачала імітаційне моделювання навантаження у середовищі AWS Academy Learning Lab (регіон us-east-1). Для порівняльного аналізу було сформовано потік даних, що еквівалентний роботі 100 вібродатчиків з інтенсивністю 1 000 000 записів на добу. З використанням AWS IoT Rule Engine сформовані пакети телеметричних даних паралельно направлялися у два сховища (табл. 1).

Таблиця 1. Параметри налаштувань хмарного середовища

Характеристика	DynamoDB	Timestream
Режим роботи	On-demand	Serverless
Індексація	Складений ключ (ID + Time)	Потокова (БДЧР)
Життєвий цикл	TTL (Time To Live) = 7 діб	Retention: memory: 30 діб magnetic: 365 діб
Рівні зберігання	Один рівень (SSD)	Дворівневе (Mem/Mag)

Таблиця DynamoDB налаштована у режимі On-demand зі складеним ключем (SensorID та Timestamp). Для бази даних Timestream налаштовано дворівневу політику: дані зберігаються у високопродуктивному Memory Store протягом 30 діб (для оперативної аналітики), після чого автоматично переміщуються у Magnetic Store для довгострокового зберігання терміном до 365 діб. Це дозволяє оптимізувати витрати без втрати доступу до накопичених даних. Тестування здійснювалося за двома ключовими метриками: затримка запитів (Query Latency) та сукупна вартість хмарних ресурсів (за результатами з AWS Cost Explorer). Для оцінки масштабованості системи було змодельовано накопичення даних за період до 10 діб, що дозволило оцінити продуктивність запитів на масивах різного обсягу.

*Результати досліджень та їх аналіз.* Під час експериментального дослідження було встановлено суттєві розбіжності у продуктивності систем при здійсненні аналітичних операцій. DynamoDB продемонструвала мінімальну затримку при записі одиничних значень RMS ( $\approx 8-12$  мс), проте час виконання агрегаційних запитів лінійно зростає зі збільшенням обсягу вибірки. Це пояснюється відсутністю вбудованої в DynamoDB аналітичної логіки, що потребує повного сканування таблиці.

Водночас, Amazon Timestream, за рахунок особливого формату зберігання часових рядів та вбудованих SQL-функцій, показав у 5,44 рази вищу швидкість виконання складних аналітичних запитів до накопичених даних – масивів понад 10 Гб (табл. 2).

Таблиця 2. Порівняння швидкодії аналітичних запитів (Query Latency)

Обсяг вибірки	DynamoDB (мс)	Timestream (мс)	Ефективність (разів)
100 тис. записів	418	184	2,27
1 млн. записів	3872	812	4,77
10 млн. записів	34145	6280	5,44

Економічний аналіз за допомогою моделі  $C_{TCO}$  підтвердив припущення про «поріг ефективності» сукупної вартості. Протягом перших 7 діб DynamoDB виявилася конкурентоспроможною завдяки моделі оплати за  $WCU$ . Проте при накопиченні телеметричних даних понад 30 діб Timestream забезпечив зниження витрат на зберігання на 41% (рис. 2).

Як видно з рис. 2, на початковому етапі (до 30 діб) вартість зберігання в Amazon DynamoDB є нижчою або наближеною до Amazon Timestream, оскільки остання використовує дорогу оперативну пам'ять (Memory Store) для оперативних запитів. Проте після 30-ї доби, згідно з

налаштованою політикою, відбувається автоматичне переміщення накопичених даних у Magnetic Store. На графіку це позначається стрімким сповільненням зростання витрат для Timestream (синя пунктирна лінія). Точка окупності («порог ефективності») настає приблизно на 35-ту добу, коли накопичена економія від використання дешевого архівного сховища повністю перекидає початкові витрати на Memory Store та вхідний потік даних.

При досягненні глибини архіву у 100 діб запропонована гібридна модель забезпечує зниження сукупних витрат на утримання інфраструктури на 41%. Розрахункова економія для системи зі 100 п'єзодатчиками становить 137 дол. США на місяць при збереженні річного накопичення даних параметрів вібрації. Це підтверджує гіпотезу про те, що Timestream є найкращим вибором для великомасштабних ІоТ систем вимірювання з подовженим періодом аналізу.

Таким чином, результати експериментів підтверджують, що запропонована в роботі гібридна модель забезпечує необхідну швидкість реакції на критичні зміни параметрів вібрації завдяки високошвидкісному потоку DynamoDB та одночасно гарантує економічно вигідний аналіз через аналітичний рівень сховища Timestream.

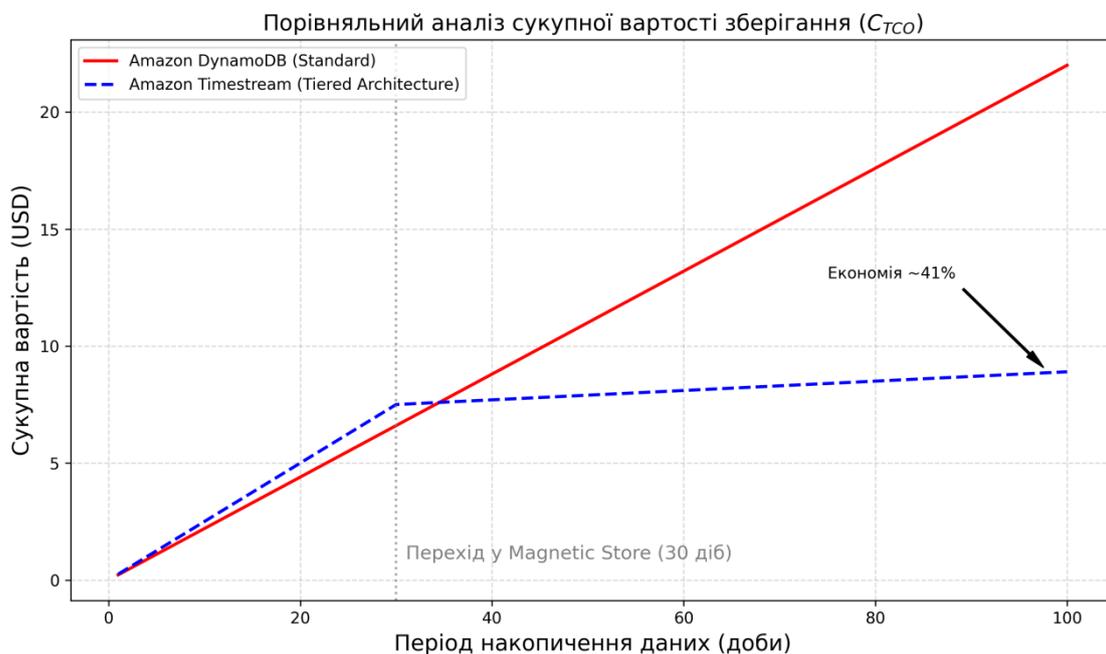


Рис. 2. Динаміка витрат на зберігання даних залежно від глибини архіву

**Висновки з дослідження.** У роботі вирішено важливу науково-практичну задачу оптимізації архітектури зберігання високочастотних ІоТ даних шляхом впровадження моделі гібридного доступу.

1. Обґрунтовано доцільність використання дворівневої структури сховища, де Amazon DynamoDB виконує роль високошвидкісного моніторингу в режимі реального часу, а Amazon Timestream – роль аналітичного накопичувача для аналізу довгострокових змін параметрів вібрації.

2. Експериментально доведено, що запропонований підхід дозволяє підвищити швидкість виконання складних аналітичних запитів у 5,44 рази порівняно з поширеними NoSQL рішеннями за рахунок вбудованих механізмів обробки БДЧР.

3. Встановлено, що використання багаторівневої системи зберігання Timestream (Memory та Magnetic Store) забезпечує зниження сукупних витрат на утримання інфраструктури на 41% при накопиченні телеметричних даних понад 30 діб.

Наукова новизна результатів полягає у математичному обґрунтуванні «порогу ефективності» економічної та технічної ефективності хмарних сховищ саме для високочастотних сигналів, що отримуються з ІоТ датчиків.

**Перспективи подальших досліджень.** Подальший розвиток даної тематики полягає в дослідженні використання агентів генеративного штучного інтелекту на базі Amazon Bedrock для

автоматизованого формування інженерних звітів про стан обладнання на основі аналізу накопичених телеметричних даних.

#### Список бібліографічного опису

1. Мусієнко М. П., Мусієнко О. Ю. Інтеграція п'єзокерамічних IoT-систем моніторингу з Amazon SageMaker для прогнозного аналізу. *Комп'ютерно-інтегровані технології: освіта, наука, виробництво*. 2025. № 61. С. 164–170. DOI: <https://doi.org/10.36910/6775-2524-0560-2025-61-23>
2. Raeiszadeh M., Ebrahimzadeh A., Glitho R. H. [et al.]. Real-Time Adaptive Anomaly Detection in Industrial IoT Environments. *IEEE Transactions on Network and Service Management*. 2024. URL: <https://arxiv.org/abs/2601.03085> (дата звернення: 19.02.2026). DOI: <https://doi.org/10.48550/arXiv.2601.03085>
3. Kuraś P., Bolanowski M., Loza M. Optimization of machine learning models for effective anomaly detection in industrial IoT systems. *Advances in Science and Technology Research Journal*. 2026. Vol. 20(1). P. 203–221. DOI: <https://doi.org/10.12913/22998624/210686>.
4. Khan A. Q., Matskin M., Prodan R. [et al.]. Cloud storage cost: a taxonomy and survey. *World Wide Web*. 2024. Vol. 27, no. 36. DOI: <https://doi.org/10.1007/s11280-024-01273-4>
5. Nadimi R., Hashemi M., Tokimatsu K. Cost and Time Optimization of Cloud Services in Arduino-Based Internet of Things Systems for Energy Applications. *Journal of Internet of Things*. 2025. Vol. 7, no. 1. P. 49–69. DOI: <https://doi.org/10.32604/jiot.2025.070822>
6. Shah B., Jat P. M., Sasidhar K. Performance study of time series databases. *arXiv preprint arXiv:2208.13982*. 2022. URL: <https://arxiv.org/abs/2208.13982> (дата звернення: 19.02.2026). DOI: <https://doi.org/10.48550/arXiv.2208.13982>.
7. Verwiebe J., Grulich P. M., Traub J. [et al.]. Survey of window types for aggregation in stream processing systems. *The VLDB Journal*. 2023. Vol. 32. P. 985–1011. DOI: <https://doi.org/10.1007/s00778-022-00778-6>
8. Kaushik S. Application of Windowing Techniques to Retail Data for Anomaly Detection. *Journal of Information Systems Engineering and Management*. 2024. Vol. 9, No. 4. URL: [https://www.jisem-journal.com/download/122\\_HR-3415.pdf](https://www.jisem-journal.com/download/122_HR-3415.pdf) (дата звернення: 19.02.2026).
9. Traub J., Grulich P., Cuéllar A. R. [et al.]. Efficient Window Aggregation with General Stream Slicing. *Proceedings of the 22nd International Conference on Extending Database Technology (EDBT)*. 2019. P. 97–108. URL: [https://openproceedings.org/2019/conf/edbt/EDBT19\\_paper\\_171.pdf](https://openproceedings.org/2019/conf/edbt/EDBT19_paper_171.pdf) (дата звернення: 19.02.2026)
10. Randall R. B. *Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications*. Chichester: Wiley, 2011. 312 p. DOI: <https://doi.org/10.1002/9780470977668>.

#### References

1. Musiyenko, M. P., Musiyenko, O. Yu. (2025). Integration of Piezoceramic IoT Monitoring Systems with Amazon SageMaker for Predictive Analysis. *Computer-Integrated Technologies: Education, Science, Production*, (61), 164–170. DOI: <https://doi.org/10.36910/6775-2524-0560-2025-61-23>
2. Raeiszadeh, M., Ebrahimzadeh, A., Glitho, R. H., Eker, J., Mini, R. A. F. (2024). Real-Time Adaptive Anomaly Detection in Industrial IoT Environments. *IEEE Transactions on Network and Service Management*. URL: <https://arxiv.org/abs/2601.03085> (access date: 19.02.2026). DOI: <https://doi.org/10.48550/arXiv.2601.03085>.
3. Kuraś P., Bolanowski M., Loza M. (2026). Optimization of machine learning models for effective anomaly detection in industrial IoT systems. *Advances in Science and Technology Research Journal*, 20(1), 203–221. DOI: <https://doi.org/10.12913/22998624/210686>.
4. Khan, A. Q., Matskin, M., Prodan, R., Bussler, C., Roman, D., Soylyu, A. (2024). Cloud storage cost: a taxonomy and survey. *World Wide Web*, 27(36). DOI: <https://doi.org/10.1007/s11280-024-01273-4>
5. Nadimi, R., Hashemi, M., Tokimatsu, K. (2025). Cost and Time Optimization of Cloud Services in Arduino-Based Internet of Things Systems for Energy Applications. *Journal of Internet of Things*, 7(1), 49–69. DOI: <https://doi.org/10.32604/jiot.2025.070822>.
6. Shah, B., Jat, P. M., Sasidhar, K. (2022). Performance study of time series databases. *arXiv preprint arXiv:2208.13982*. URL: <https://arxiv.org/abs/2208.13982> (access date: 19.02.2026). DOI: <https://doi.org/10.48550/arXiv.2208.13982>.
7. Verwiebe, J., Grulich, P. M., Traub, J. et al. (2023). Survey of window types for aggregation in stream processing systems. *The VLDB Journal*, 32, 985–1011. DOI: <https://doi.org/10.1007/s00778-022-00778-6>
8. Kaushik, S. (2024). Application of Windowing Techniques to Retail Data for Anomaly Detection. *Journal of Information Systems Engineering and Management*, 9(4). URL: [https://www.jisem-journal.com/download/122\\_HR-3415.pdf](https://www.jisem-journal.com/download/122_HR-3415.pdf)
9. Traub, J., Grulich, P., Cuéllar, A. R. et al. (2019). Efficient Window Aggregation with General Stream Slicing. *Proceedings of the 22nd International Conference on Extending Database Technology (EDBT)*, 97–108. URL: [https://openproceedings.org/2019/conf/edbt/EDBT19\\_paper\\_171.pdf](https://openproceedings.org/2019/conf/edbt/EDBT19_paper_171.pdf) (access date: 19.02.2026).
10. Randall, R. B. (2011). *Vibration-based Condition Monitoring: Industrial, Aerospace and Automotive Applications*. Chichester: Wiley. 312 p. DOI: <https://doi.org/10.1002/9780470977668>.

Історія статті:

Отримано: 19.02.2026 Доопрацьовано: 12.03.2026 Прийнято до друку: 23.03.2026 Опубліковано: 29.03.2026