

УДК 004.8:681.5

DOI: 10.20998/2411-0558.2026.02.03

Ю. О. ШЕЛІХОВ, аспірант, ХНУРЕ, Харків,

Н. Г. АКСАК, д-р техн. наук, проф., ХНУРЕ, Харків

МОДЕЛЬ ПРЕДСТАВЛЕННЯ СТАНУ ТА ПРОГНОЗУВАННЯ ПАРАМЕТРІВ МІКРОКЛІМАТУ В РОЗПОДІЛЕНИХ ІНФОРМАЦІЙНО-ВИМІРЮВАЛЬНИХ СИСТЕМАХ

У роботі запропоновано та експериментально оцінено хмарну мікросервісну платформу адаптивного керування мікрокліматом, що поєднує потокову обробку гетерогенних сенсорних даних і нейромережеве прогнозування. Удосконалена модель представлення стану формує узгоджений вектор стану на основі потокової агрегації та нормалізації IoT-вимірювань у режимі реального часу. На основі часових послідовностей цього вектора модель LSTM забезпечує коротко- та середньостроковий прогноз, який використовується для проактивного прийняття керуючих рішень у контурі клімат-контролю. Експерименти з віртуальними IoT-пристроями підтвердили придатність підходу до обробки потоків у реальному часі та високу точність прогнозування (MAE для температури $\pm 0,6$ °C; для вологості $\pm 3,1$ %). Іл.: 2. Табл.: 5. Бібліогр.: 10 назв.

Ключові слова: хмарна мікросервісна платформа; IoT; нейромережеве прогнозування; модель LSTM.

Вступ. Сучасні тенденції, пов'язані з підвищенням енергоефективності, екологічності та цифровізації, зумовлюють потребу у створенні розумних систем, здатних автоматично та в реальному часі регулювати параметри навколишнього середовища.

Традиційні централізовані системи управління не забезпечують необхідної масштабованості та швидкості реагування на зміну умов. Ефективною альтернативою є використання технологій хмарних обчислень, мікросервісної архітектури та мереж датчиків. Такий підхід дозволяє створювати децентралізовані адаптивні системи, здатні збирати дані, виконувати аналітику та автоматично оптимізувати параметри мікроклімату.

Стрімкий розвиток Інтернету речей (IoT) та хмарних сервісів сприяє створенню платформ, де обчислювальні ресурси хмари поєднуються з гнучкістю мікросервісів. Це дає змогу ефективно обробляти великі обсяги

сенсорних даних, використовувати методи машинного навчання для прогнозування змін середовища та реалізовувати адаптивні алгоритми керування.

Аналіз останніх досліджень. Адаптивний контроль мікроклімату є важливим напрямом автоматизації підтримки оптимальних параметрів середовища (температури, вологості тощо) у приміщеннях і теплицях на основі даних датчиків. Такі системи спрямовані на підвищення енергоефективності розумних будівель і продуктивності аграрних систем. Сучасні рішення дедалі частіше поєднують технології Інтернету речей (IoT), мікросервісні архітектури та алгоритми машинного навчання (ML), що забезпечує масштабованість, модульність і можливість адаптивного прийняття рішень.

Мікросервісна архітектура передбачає розподіл системи на невеликі незалежні сервіси, які взаємодіють через стандартизовані інтерфейси. У системах контролю мікроклімату це дозволяє виділити окремі сервіси для збору даних датчиків, обробки інформації, прийняття рішень щодо керування обладнанням (вентиляцією, опаленням тощо) та взаємодії з користувачем. Такий підхід забезпечує модульність, можливість незалежного масштабування сервісів та підвищену відмовостійкість системи [1]. Наприклад, у дослідженні Naque et al. (2020) функціональні компоненти системи управління будівлею (BEMS) реалізовано як набір окремих мікросервісів, що дозволило системі керувати до 3200 пристроями, тоді як монолітна архітектура підтримувала лише близько 400 [2].

Мікросервісні платформи активно застосовуються і в агротехнічних системах. Система IRRISENS (2020) реалізує повністю мікросервісну IoT-архітектуру для управління зрошенням, у якій окремі сервіси збирають дані про ґрунт, погоду та стан культур, виконують прогнозування на основі моделей евапотранспірації (evapotranspiration, ET) та формують керувальні команди [3]. Платформа інтегрується з хмарною інфраструктурою FIWARE та успішно протестована на комерційних фермах, продемонструвавши ефективність планування зрошення і захист даних користувачів [3]. Подібні підходи також застосовуються у хмарних системах керування будівлями, де аналітичні мікросервіси прогнозують

енергоспоживання і реалізують стратегії керування HVAC-системами та освітленням [2].

Важливим компонентом таких систем є попередня обробка даних датчиків. Основні підходи включають фільтрацію шуму, агрегацію та злиття даних із різних джерел. Наприклад, фільтри ковзного середнього або Калмана дозволяють згладжувати показники датчиків і зменшувати обсяг передавання даних у хмару [4]. Агрегація вимірювань у часові інтервали або з кількох датчиків знижує навантаження на мережу без втрати ключової інформації [4]. Злиття даних використовується для інтеграції різних показників середовища. Наприклад, комбінація температури листа і вологості повітря дозволяє обчислювати дефіцит тиску пари (VPD), важливий показник водного балансу рослин [5]. У дослідженні Méndez-Guzmán et al. (2022) показник VPD обчислювався у системі аеропонної теплиці та зберігався у хмарному сервісі ThingSpeak для подальшого аналізу [5]. Інші роботи використовують нечітке злиття параметрів температури, вологості та VPD для оцінювання оптимальності мікроклімату в теплицях [6].

Обробка даних зазвичай організована у багаторівневій IoT-архітектурі. Наприклад, чотиришарова модель включає рівень пристроїв (збір даних датчиками), рівень туману (локальна обробка і попередня аналітика), хмарний рівень (зберігання та складні обчислення) та прикладний рівень для взаємодії з користувачем [5]. Такий підхід підвищує швидкість реагування системи і дозволяє підтримувати основні функції навіть при втраті зв'язку з хмарою.

Алгоритми машинного навчання відіграють ключову роль в адаптивному керуванні мікрокліматом. Вони використовуються для прогнозування параметрів середовища, класифікації станів системи та оптимізації керувальних дій. Зокрема, моделі глибокого навчання LSTM застосовуються для прогнозування температури та вологості у теплицях. У роботі Thwin et al. (2024) багатовимірною моделлю LSTM забезпечила точність прогнозування температури з коефіцієнтом детермінації близько $R^2 \approx 0,98$ та дозволила підтримувати стабільний мікроклімат у теплиці [7]. У деяких системах використовуються гібридні моделі, що поєднують LSTM із SVM для прогнозування та класифікації станів середовища [7].

Іншим перспективним напрямом є використання алгоритмів навчання з підкріпленням (Reinforcement Learning), які дозволяють системі самостійно знаходити оптимальні стратегії керування на основі зворотного зв'язку від середовища [8]. Також розробляються самоадаптивні нейронні мережі, здатні до онлайн-навчання та оновлення моделей при зміні умов експлуатації [9].

Існуючі дослідження охоплюють як теоретичні моделі та архітектури, так і практичні реалізації систем. Наприклад, адаптивна архітектура для енергоефективних будівель була протестована на експериментальному стенді CIESOL (Іспанія), де система могла автоматично реконфігурувати свою поведінку на основі правил і моделей машинного навчання [1]. У практичних проєктах IoT-платформи успішно застосовуються у реальних теплицях і фермах, демонструючи економію ресурсів та підвищення стабільності мікроклімату [3, 7].

Отже, розвиток мікросервісних архітектур, технологій IoT та алгоритмів машинного навчання суттєво підвищив інтелектуальні можливості систем контролю мікроклімату. Такі системи забезпечують масштабованість, гнучкість та можливість адаптивного реагування на зміни середовища. Подальші дослідження спрямовані на створення універсальних самонавчальних платформ, здатних до автономного керування мікрокліматом у розумних будівлях та агротехнічних системах [10].

Постановка проблеми. Традиційні централізовані системи клімат-контролю в розподілених інформаційно-вимірювальних середовищах не забезпечують формування узгодженого вектора стану об'єкта керування в реальному часі на основі гетерогенних потокових сенсорних даних та їх точного коротко- і середньострокового прогнозування, що унеможливорює проактивне керування мікрокліматом; тому актуальною є розробка моделі, яка інтегрує потокову агрегацію і нормалізацію даних із LSTM-прогнозуванням у мікросервісному середовищі.

Мета роботи полягає у розробці та експериментальній перевірці моделі формування узгодженого вектора стану мікроклімату $S^*(t)$ на основі потокової агрегації та нормалізації гетерогенних сенсорних даних

і нейромережевого прогнозування $\hat{S}(t + \Delta)$ (LSTM) у мікросервісному середовищі для забезпечення проактивного керування.

Наукова новизна полягає в удосконаленні моделі представлення стану та прогнозування параметрів мікроклімату в розподілених інформаційно-вимірjuвальних системах, яка, на відміну від відомих підходів, інтегрує потокову агрегацію й нормалізацію гетерогенних сенсорних даних із нейромережевим прогнозуванням (LSTM) у єдиному мікросервісному середовищі, що забезпечує формування узгодженого вектора стану $S^*(t)$ у реальному часі та підвищує точність коротко- і середньострокових прогнозів $\hat{S}(t + \Delta)$ (як основи проактивного керування через політику $\pi(\cdot)$).

Основні внески:

1. Запропоновано процедуру формування стану $S^*(t)$ на основі потокової агрегації та нормалізації сенсорних потоків.

2. Реалізовано LSTM-прогноз $\hat{S}(t+\Delta)$ на базі послідовностей $S^*(t), \dots, S^*(t - n)$.

3. Інтегровано прогноз у контур керування через політику $u(t)=\pi(\hat{S}(t+\Delta))$ та експериментально оцінено роботу платформи в реальному часі.

Хмарна мікросервісна платформа для адаптивного контролю клімату в приміщенні. Ми представляємо архітектуру та технологічну реалізацію хмарної мікросервісної платформи для підтримки адаптивного контролю клімату в приміщенні. Платформа поєднує подієвий зв'язок, аналіз даних датчиків та методи машинного навчання для динамічного регулювання температури, вологості, концентрації CO₂ та освітлення.

Високорівнева архітектура. Загальна система побудована як подієво-орієнтована мікросервісна платформа, у якій взаємодія між сервісами здійснюється асинхронно через шини подій (MQTT/Kafka). Така організація забезпечує високу масштабованість і швидке реагування на зміни параметрів середовища. На рис. 1 наведено високорівневу архітектуру edge–cloud платформи адаптивного керування мікрокліматом.

На периферійному рівні IoT-сенсори вимірюють параметри T , H , CO_2 , L , M , та передають телеметрію до периферійного шлюзу (Edge Gateway), який виконує первинну фільтрацію та буферизацію даних і перетворює вимірювання у події. Далі події публікуються в шині подій MQTT/Kafka як потік сенсорних повідомлень, що забезпечує асинхронну взаємодію компонентів системи.

На хмарному рівні події обробляються мікросервісами, що реалізують основні функції платформи: попередню обробку даних, формування узгодженого вектора стану $S^*(t)$, нейромережеве прогнозування на основі LSTM $\hat{S}(t + \Delta)$ та модуль прийняття керуючих рішень. На основі прогнозу формуються керуючі команди, які передаються до виконавчих пристроїв HVAC (вентиляція, опалення, зволоження, освітлення) для проактивного регулювання мікроклімату.



Рис. 1. Високорівнева архітектура edge-cloud платформи клімат-контролю на основі подієво-орієнтованих мікросервісів та шини подій MQTT/Kafka

Зберігання даних організовано окремим шаром: часові ряди телеметрії зберігаються у TimescaleDB, а конфігураційні дані та кеш – у PostgreSQL/Redis. Інтерфейс моніторингу та візуалізації забезпечує доступ до станів і метрик сервісів, сповіщень та звітів. Запропонована архітектура забезпечує масштабованість, відмовостійкість і можливість

обробки сенсорних потоків у режимі, близькому до реального часу, у розподіленій системі клімат-контролю.

Рівень Інтернету речей. Цей рівень включає різноманітні датчики, що вимірюють ключові змінні навколишнього середовища: температуру та вологість – DHT22, SHT31; рівень CO₂ – MH-Z19; інтенсивність освітлення – BH1750; виявлення руху – PIR-датчики. Протоколи зв'язку між цими пристроями та системою залежать від можливостей апаратного забезпечення та обмежень реального часу. Для забезпечення сумісності компонентів платформи та балансу між низькою затримкою і модульністю використано поєднання протоколів для різних типів взаємодій (телеметрія, міжсервісні виклики, інтерфейс користувача). Відповідні протоколи для ключових компонентів наведено у табл. 1.

Таблиця 1
Протоколи зв'язку для системних компонентів платформи

Системний компонент	Протоколи
Сенсори та HVAC обладнання	Modbus
Потоки даних від датчиків до мікросервісів	MQTT
Міжсерверний зв'язок	REST API
Керування користувачами та їх налаштування	REST API
Панель керування та моніторинг у режимі реального часу	REST API + WebSocket

Таким чином, MQTT застосовано для легкого pub/sub-обміну телеметрією, тоді як REST/WebSocket використано для структурованих API-запитів і оновлень у реальному часі, що забезпечує масштабованість і керованість платформи. Таке поєднання балансує ефективність у реальному часі з модульністю системи та зручністю обслуговування. MQTT забезпечує легкий обмін повідомленнями pub/sub, який добре підходить для телеметрії датчиків, тоді як REST є кращим для структурованої міжсервісної взаємодії та орієнтованих на користувача API. WebSocket або MQTT мінімізує затримку та підтримує взаємодію з користувачем у реальному часі в сценаріях, що потребують частих оновлень, таких як інформаційні панелі в реальному часі.

Периферійний шлюз. Edge Gateway є посередником між фізичним рівнем Інтернету речей та екосистемою хмарних мікросервісів. Його основна роль полягає в зборі, попередній обробці та пересиланні даних датчиків до магістралі обміну повідомленнями платформи. Цей компонент забезпечує локалізовані обчислення, забезпечуючи надійний зв'язок із вказаними сервісами.

Шлюз виконує такі ключові функції:

- Агрегує дані з різних датчиків (температури, вологості, CO₂).
- Застосовує фільтрацію та перевірку шуму для забезпечення цілісності даних.

- Перетворює специфічні для датчиків формати в єдину схему.
- Публікує відфільтровані події до брокера повідомлень системи.

Для забезпечення гнучкої та масштабованої передачі даних застосовується наступна стратегія протоколу:

- Для доставки подій у режимі реального часу від датчиків до шлюзу використовується протокол MQTT. Його легкий характер та модель публікації-підписки роблять його ідеальним для середовищ з обмеженою пропускну здатністю та пристроїв з низьким енергоспоживанням.

- Для централізованої потокової передачі подій у межах платформи, особливо між основними сервісами, шлюз пересилає події до теми Kafka, забезпечуючи високопродуктивні, довговічні та впорядковані потоки даних для аналітики, обробки та логіки керування.

Цей гібридний підхід поєднує швидкість реагування в режимі реального часу з довгостроковою масштабованістю та відмовостійкістю, дозволяючи системі обробляти тисячі повідомлень датчиків на секунду, зберігаючи при цьому модульність та спостережуваність.

Модель представлення стану мікроклімату та прогнозування параметрів середовища.

Нехай система отримує потоки вимірювань від множини сенсорів:

$$X(t) = \{x_1(t), x_2(t), \dots, x_n(t)\}, \quad (1)$$

де $x_i(t)$ – значення i -го сенсора в момент часу t .

У системі клімат-контролю основними вимірюваними параметрами є температура, відносна вологість, концентрація CO₂, освітленість та

індикатор присутності. Таким чином, базовий вектор стану середовища визначається як

$$S(t) = [T(t), H(t), CO_2(t), L(t), M(t)], \quad (2)$$

де $T(t)$ – температура повітря, $H(t)$ – відносна вологість, $CO_2(t)$ – концентрація вуглекислого газу, $L(t)$ – освітленість, $M(t)$ – індикатор присутності або руху.

Оскільки сенсорні потоки характеризуються шумом та різною частотою дискретизації, перед формуванням узгодженого стану виконується потокова агрегація даних. Для цього використовується ковзне часове вікно довжини k :

$$\bar{x}_i(t) = \frac{1}{k} \sum_{j=0}^{k-1} x_i(t-j). \quad (3)$$

Отримані значення агрегованих параметрів піддаються процедури нормалізації для усунення масштабних відмінностей між різними типами сенсорів. Для цього використовується стандартна Z -нормалізація

$$x_i^{norm}(t) = \frac{x_i(t) - \mu_i}{\sigma_i}, \quad (4)$$

де μ_i та σ_i – відповідно середнє значення та стандартне відхилення параметра.

Після виконання агрегації та нормалізації формується узгоджений вектор стану системи

$$S^*(t) = [T_n(t), H_n(t), CO_{2n}(t), L_n(t), M_n(t)], \quad (5)$$

який представляє нормалізований стан середовища у момент часу t .

Для реалізації узгодженого представлення стану середовища кожен параметр мікроклімату приводиться до спільного формату через потокову агрегацію та нормалізацію, після чого формується вектор стану $S^*(t)$. Склад вектора стану, джерела вимірювань та застосовані перетворення наведено у табл. 2.

Наведена структура забезпечує зіставність гетерогенних параметрів і формує стабільний вхід для прогнозування LSTM та подальшого проактивного керування. Для коротко- та середньострокового прогнозування параметрів мікроклімату

застосовується рекурентна нейронна мережа типу LSTM (Long Short-Term Memory), здатна враховувати часові залежності сенсорних даних. Модель прогнозування визначається як

$$\hat{S}(t + \Delta) = LSTM(S^*(t), S^*(t - 1), \dots, S^*(t - n)), \quad (6)$$

де n – довжина історії спостережень, Δ – горизонт прогнозування.

Таблиця 2

Склад вектора стану

Компонента стану	Джерело	Обробка	Нормалізація
$T_n(t)$	DHT22/SHT31	ковзне середнє	z-score
$H_n(t)$	DHT22/SHT31	ковзне середнє	z-score
$CO_{2n}(t)$	MH-Z19	агрегація по вікну	min-max
$L_n(t)$	BH1750	усереднення	min-max
$M_n(t)$	PIR	бінаризація	не потрібна

Отриманий прогнозований стан $\hat{S}(t + \Delta)$ використовується для формування проактивних керуючих дій системи клімат-контролю, зокрема регулювання вентиляції, опалення, зволоження або освітлення.

Керуюча дія формується як функція від прогнозованого стану:

$$u(t) = \pi(\hat{S}(t + \Delta)), \quad (7)$$

де $u(t) = [u_h, u_v, u_l, u_m]$ – вектор керування HVAC-системою: u_h – керування опаленням, u_v – вентиляцією, u_l – освітленням, u_m – зволоженням.

Мета керування – мінімізувати відхилення прогнозованого стану від бажаного стану S_{ref} :

$$J = \|S_{ref} - \hat{S}(t + \Delta)\|^2. \quad (8)$$

Оптимальна дія визначається як

$$u^*(t) = \arg \min_u J. \quad (9)$$

Таким чином, прогноз LSTM інтегрується у контур керування через політику $\pi(\cdot)$, забезпечуючи проактивне налаштування параметрів мікроклімату.

Алгоритм 1. Формування узгодженого вектора стану та прогнозування.

Вхід: Потoki сенсорних даних $X(t)$ від IoT-датчиків (температура, вологість, CO₂, освітленість, рух).

Вихід: Узгоджений вектор стану середовища $S^*(t)$ та прогнозований стан $\hat{S}(t + \Delta)$.

Процедура:

1. Отримати потоки даних датчиків із MQTT-тем.
2. Виконати фільтрацію шуму в необроблених сенсорних даних.
3. Застосувати агрегацію вимірювань за допомогою ковзного часового вікна.
4. Виконати нормалізацію гетерогенних параметрів датчиків.
5. Сформувати узгоджений вектор стану системи $S^*(t)$.
6. Передати вектор стану до сервісу прогнозування LSTM.
7. Обчислити прогнозований стан середовища $\hat{S}(t + \Delta)$.
8. Передати прогнозований стан до модуля прийняття керуючих рішень.

На рис. 2 подано узагальнену схему формування $S^*(t)$ та отримання прогнозу $\hat{S}(t+\Delta)$ у межах мікросервісного контуру обробки поточкових даних.

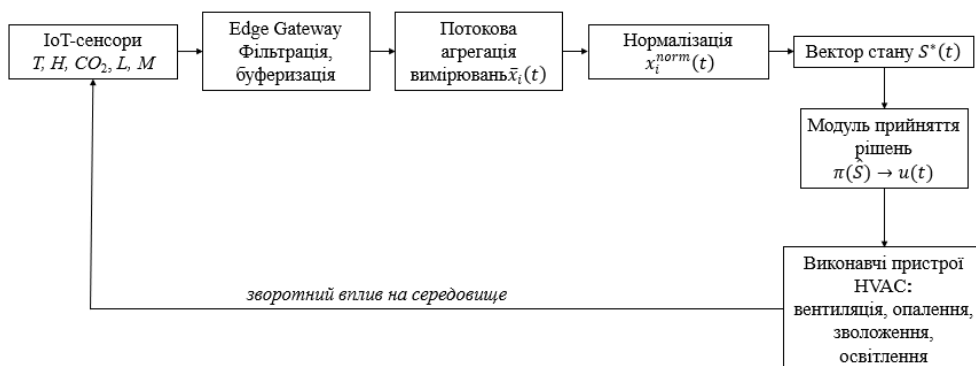


Рис. 2. Пайплайн формування узгодженого вектора стану $S^*(t)$ та контур проактивного керування мікрокліматом на основі потокової агрегації, нормалізації й політики $\pi(\cdot)$ у системі HVAC

На рис. 2 показано пайплайн формування стану та прогнозування параметрів мікроклімату у розподіленій інформаційно-вимірювальній системі. Потoki телеметрії від IoT-сенсорів (T, H, CO_2, L, M) надходять до Edge Gateway, де виконується первинна фільтрація та буферизація даних. Далі реалізується потокова агрегація вимірювань $\bar{x}_i(t)$, після чого значення приводяться до порівнюваного масштабу шляхом нормалізації $x_i^{norm}(t)$. На основі агрегованих і нормалізованих даних формується узгоджений вектор стану середовища $S^*(t)$, який слугує вхідною послідовністю для модуля LSTM-прогнозування, що обчислює прогнозований стан $\hat{S}(t + \Delta)$ на заданому горизонті Δ .

Прогноз $\hat{S}(t + \Delta)$ передається до модуля прийняття рішень, який реалізує політику керування $\pi(\hat{S}) \rightarrow u(t)$ та формує керуючі впливи $u(t)$. Команди керування надходять до виконавчих пристроїв HVAC (вентиляція, опалення, зволоження, освітлення), що змінюють параметри середовища. Лінія з позначенням «зворотний вплив на середовище» відображає замкнений контур: керуючі дії змінюють мікроклімат, який знову вимірюється сенсорами, забезпечуючи безперервний цикл адаптивного проактивного контролю.

Основні мікросервіси. Функціональність платформи декомпововано на спеціалізовані мікросервіси, що взаємодіють асинхронно через шину подій, забезпечуючи незалежне масштабування та ізоляцію збоїв. Перелік основних сервісів, технологічний стек і призначення наведено у табл. 3.

Такий розподіл функцій дозволяє окремо масштабувати контури обробки даних і прийняття рішень залежно від інтенсивності сенсорних потоків та обчислювального навантаження. Ці сервіси працюють незалежно та розгортаються в контейнерах, що забезпечує гнучке масштабування та оновлення.

Рівень зберігання даних. Для керування як історичними, так і реальними даними платформа використовує:

- TimescaleDB – ефективне зберігання даних часових рядів.

- PostgreSQL – централізована конфігурація, дані користувачів та правила.

- Redis – кешування, швидкий доступ.

Ця гібридна стратегія обробки даних поєднує продуктивність зі структурою та довгостроковою доступністю.

Таблиця 3

Основні мікросервіси та їхні функції в хмарній платформі клімат-контролю

Сервіс	Технологічний стек	Функціональність
Захоплення даних датчика	Node.js / Python + Kafka	Отримує вхідні дані та направляє їх до сховища
Обробка даних	Python (Pandas, NumPy)	Виконує нормалізацію, виявлення трендів та виявлення аномалій
Механізм правил	Drools / Python	Застосовує заздалегідь визначену логіку для запуску дій керування
Служба прийняття рішень з машинного навчання	TensorFlow / Scikit-learn	Прогнозує майбутні стани та рекомендує оптимальні дії
Керування пристроями	MQTT / REST	Виконує команди (наприклад, увімкнути вентиляцію)
Оповіщення та ведення журналу	ELK Stack / Prometheus	Контролює операції та надсилає сповіщення
Керування користувачами	JWT / OAuth2	Обробляє безпечний доступ та авторизацію

Аналітика та машинне навчання. Оброблені дані потім аналізуються для отримання аналітичних висновків та прогнозів на майбутнє:

- Інформаційні панелі Grafana візуалізують ключові тенденції (наприклад, зростання рівня CO₂).

- Моделі LSTM прогнозують тенденції температури для проактивного коригування.

- Агенти Q-навчання оптимізують стратегії керування на основі історичної ефективності.

Платформа поєднує логіку на основі правил із рішеннями, керованими машинним навчанням, що дозволяє приймати резервні та безвідмовні операції.

Реалізація та розгортання. Запропонована платформа реалізована у вигляді набору контейнеризованих мікросервісів, що взаємодіють асинхронно через шину подій (MQTT/Kafka) у межах edge-cloud архітектури. Периферійний компонент (Edge Gateway) виконує первинну фільтрацію та буферизацію телеметрії IoT-сенсорів і публікує події у брокер повідомлень для подальшої потокової обробки. У хмарному середовищі спеціалізовані сервіси виконують попередню обробку даних, формування узгодженого вектора стану $S^*(t)$, прогнозування $\hat{S}(t + \Delta)$ на основі LSTM та генерацію керуючих команд для HVAC. Історичні часові ряди зберігаються у СУБД часових рядів (TimescaleDB), а конфігураційні дані та кеш – у реляційній БД/кеш-сховищі (PostgreSQL/Redis). Моніторинг роботи системи та збір експериментальних метрик виконуються засобами спостережуваності з виведенням показників у панель контролю.

Питання реалізації інтерфейсів користувача, механізмів автентифікації/авторизації та вибору інструментів оркестрації (Compose/Kubernetes) не є предметом даного дослідження та розглядаються як інженерні аспекти впровадження.

Експериментальна установка. Для перевірки продуктивності, масштабованості та адаптивності запропонованої хмарної мікросервісної платформи для клімат-контролю було розгорнуто спеціальне експериментальне середовище. Середовище емулює реалістичний сценарій розумної будівлі з кількома пристроями Інтернету речей, обробкою периферійних даних та хмарною аналітикою.

Експериментальна установка складається з таких компонентів:

1. Емуляція пристроїв Інтернету речей:

Для імітації потоків даних реального світу було розгорнуто набір віртуалізованих датчиків. Кожен віртуальний пристрій генерує показники температури, вологості, концентрації CO₂, інтенсивності освітлення та виявлення руху.

Генерація даних датчиків відповідає реалістичним шаблонам з випадковим шумом для імітації мінливості навколишнього середовища.

2. Розгортання Edge Gateway:

Edge Gateway розгортається на окремій легкій віртуальній машині. Він агрегує вхідні повідомлення MQTT від емульованих датчиків Інтернету речей, виконує початкову перевірку та фільтрацію, а також повторно публікує дані до брокера Kafka.

3. Хмарне середовище:

Основні мікросервіси, модулі машинного навчання, сховище даних та шлюз API розгортаються за допомогою Docker Compose на сервері, оснащеному: ЦП: 16 ядер; ОЗП: 32 ГБ; Сховище: 500 ГБ SSD; ОС: Ubuntu Server 22.04 LTS. Це середовище наближається до умов розгортання середнього масштабу.

4. Інфраструктура обміну повідомленнями:

Apache Kafka використовується для асинхронного зв'язку між сервісами. Темп налаштовуються для отримання даних від датчиків, оцінки правил, прогнозування машинного навчання та відправлення команд керування.

5. Зберігання даних:

- TimescaleDB обробляє високочастотні дані часових рядів за допомогою оптимізованих запитів для аналізу трендів.

- PostgreSQL зберігає налаштування конфігурації, правила та дані користувачів.

- Redis служить шаром кешування для швидкого отримання метаданих середовища виконання.

6. Моніторинг та спостереження:

Використання системних ресурсів, пропускна здатність повідомлень та час відгуку мікросервісів контролюються за допомогою Prometheus та візуалізуються через панелі інструментів Grafana.

Були зібрані користувацькі показники, включаючи затримку обробки повідомлень, кількість активних підключень та коефіцієнти виявлення аномалій.

7. Моделювання навантаження:

Експерименти проводилися з різною кількістю змодельованих пристроїв Інтернету речей, від 100 до 5000 одночасних датчиків, щоб оцінити масштабованість та стабільність платформи за різних робочих навантажень.

8. Тестові сценарії:

- Раптові сплески рівня CO₂ запускають керування вентиляцією.
- Поступові зміни температури для перевірки прогнозованих налаштувань HVAC на основі машинного навчання.
- Аномальні закономірності в показниках вологості для перевірки механізму оповіщення.

Усі результати тестів були записані, а поведінка системи за різних умов була проаналізована для оцінки швидкості реагування, відмовостійкості, масштабованості та потенціалу оптимізації енергоспоживання.

Результати та обговорення. Експериментальна оцінка запропонованої платформи адаптивного клімат-контролю на основі мікросервісів була зосереджена на оцінці продуктивності системи, масштабованості, швидкості реагування та ефективності прогнозів на основі машинного навчання.

Система продемонструвала високу швидкість реагування у всіх конфігураціях. Середня затримка від початку до кінця (від генерації даних датчиків до спрацьовування пристрою) залишалася менше 250 мс для 100 активних датчиків. Для більших установок з 500 одночасними датчиками затримка дещо збільшилася приблизно до 430 мс, що залишається прийнятним для застосувань клімат-контролю в приміщенні.

Платформа підтримувала стабільну пропускну здатність зі збільшенням кількості підключених пристроїв.

Kafka підтримувала швидкість прийому повідомлень понад 5000 повідомлень на хвилину без значної затримки.

Мікросервісні контейнери масштабуються горизонтально без перерв у роботі, що підтримується динамічним розподілом ресурсів у Docker Compose. Моделі прогнозування на основі LSTM досягли:

- Середньої абсолютної похибки (MAE) для прогнозів температури: $\pm 0,6^{\circ}\text{C}$.

- MAE для прогнозів вологості: $\pm 3,1\%$ відносної вологості.

Для обґрунтування ефективності запропонованої моделі прогнозування виконано порівняння з базовими підходами: найвним прогнозом (persistence baseline) та LSTM без попередньої потокової обробки (без агрегації/нормалізації та без узгодженого вектора стану). Результати порівняння за метриками MAE і RMSE для температури та вологості наведено у табл. 4.

Таблиця 4

Порівняння методів прогнозування

Метод	MAE(T)	RMSE(T)	MAE(H)	RMSE(H)
Persistence baseline	1,25 °C	1,74 °C	5,9%	7,8%
LSTM без preprocessing	0,91 °C	1,23 °C	4,4%	5,8%
Запропонована модель	0,60 °C	0,88 °C	3,10%	4,20%

Отримані результати підтверджують, що інтеграція потокової агрегації й нормалізації в процес формування $S^*(t)$ підвищує точність прогнозів порівняно з базовими методами, що є критичним для проактивного керування.

Щоб оцінити вплив прогнозування на якість керування, виконано порівняння трьох стратегій: порогового (реактивного) керування, rule-based керування та запропонованого підходу з прогнозуванням $\hat{S}(t + \Delta)$. Порівняльні показники стабілізації мікроклімату, кількості активацій HVAC і енерговитрат наведено у табл. 5.

Таблиця 5

Порівняння стратегій керування мікрокліматом

Підхід	Середнє відхилення T, °C	Активації HVAC	Енерговитрати
Порогове керування	1,8 °C	120	100%
Rules only	1,2 °C	104	93%
Запропонована модель	0,7 °C	89	86%

Як видно з табл. 5, використання прогнозу зменшує відхилення параметрів від цільових значень та скорочує частоту зайвих увімкнень HVAC, що в підсумку підвищує енергоефективність системи.

Для компактної інтерпретації ефекту проактивного керування додатково введено індекс непотрібних активацій HVAC, нормований відносно порогового керування (базове значення 1,00). Аналіз показує, що застосування різних стратегій призводить до наступних результатів: для базового порогового (статичного) підходу індекс фіксується на рівні 1,00, тоді як для запропонованої стратегії $\pi(\hat{S}(t+\Delta))$ цей показник знижується до 0,86. Таке зменшення індексу непотрібних активацій підтверджує, що політика $\pi(\hat{S}(t+\Delta))$ забезпечує більш раціональне керування виконавчими пристроями, знижуючи надмірні перемикання без втрати стабільності мікроклімату. Досягнута точність прогнозування дозволила виконувати проактивні дії керування, зокрема превентивне регулювання HVAC, що призвело до плавнішого регулювання параметрів навколишнього середовища порівняно з керуванням на основі лише реактивних правил.

Механізм правил правильно запуслав попередньо визначені дії керування у понад 98% змодельованих критичних подій (наприклад, перевищення порогового значення CO₂, раптові стрибки вологості).

Комбіновані стратегії керування на основі правил та машинного навчання зменшили непотрібні активації HVAC на 14% порівняно зі статичним керуванням лише на основі порогового значення.

Результати моніторингу показали помірне використання процесора та пам'яті:

- Середнє завантаження процесора на контейнер мікросервісів: 15–22% під час пікової роботи.
- Використання пам'яті залишалося стабільним приблизно на рівні 120–180 МБ на контейнер.

Під час змодельованих збоїв мережі (тимчасові відключення брокера Kafka) мікросервіси буферизували події локально та успішно відновлювали операції без втрати даних, демонструючи стійкість системи до тимчасових збоїв.

Експериментальні результати підтверджують, що запропонована хмарна архітектура мікросервісів підтримує ефективне та масштабоване адаптивне керування кліматом у приміщенні. Поєднання прийняття рішень на основі правил з прогнозними моделями машинного навчання

дозволяє платформі збалансувати швидкість реагування, оптимізацію ресурсів та довгострокову адаптивність.

Модель комунікації на основі подій системи (MQTT/Kafka) виявилася важливою для мінімізації затримки та підтримки модульності при динамічних навантаженнях. Крім того, моніторинг у режимі реального часу за допомогою Prometheus та Grafana дозволив своєчасно виявляти та вирішувати вузькі місця системи.

Висновки. У статті представлено модель представлення стану та прогнозування параметрів мікроклімату в розподілених інформаційно-вимірjuвальних системах, яка поєднує потокову агрегацію та нормалізацію гетерогенних сенсорних даних із нейромережним прогнозуванням на основі LSTM у мікросервісному середовищі. Запропонований підхід забезпечує формування узгодженого вектора стану об'єкта керування в режимі реального часу та побудову коротко- і середньострокового прогнозу параметрів середовища як основи проактивного керування. Реалізація у вигляді подієво-орієнтованої edge-cloud платформи підтвердила працездатність контуру "сенсори – формування стану – прогноз – керуюча дія – HVAC". Експериментальні результати засвідчили високу точність прогнозування (MAE для температури $\pm 0,6$ °C; для вологості $\pm 3,1$ %) та придатність підходу до обробки потоків у реальному часі.

Подальша робота. Перспективними напрямками розвитку є: (1) розширення моделі стану за рахунок контекстних змінних і збурень (зовнішні умови, заповненість приміщення, режими обладнання) та перехід до адаптивного злиття ознак; (2) удосконалення прогнозування до багатогоризонтного та ймовірнісного з оцінюванням невизначеності прогнозу; (3) інтеграція прогнозу в оптимізаційний контур керування з урахуванням енерговитрат, інерційності та обмежень виконавчих пристроїв. Окремо доцільно дослідити онлайн- та федеративне навчання моделей для масштабування на мережу об'єктів із збереженням приватності, а також підвищення стійкості до деградації сенсорів і пропусків даних через механізми виявлення аномалій та відновлення показників. Для підсилення доказової бази планується розширення

експериментальної валідації (різні профілі навантаження, сезонність) і використання цифрових двійників для сценарійного тестування стратегій проактивного керування перед розгортанням у реальних умовах.

Список літератури:

1. *Rodríguez-Gracia, D., Piedra-Fernández, J.A., Iribarne, L., Criado, J., Ayala, R., Alonso-Montesinos, J. and Maria de las Mercedes, C.U.* Microservices and machine learning algorithms for adaptive green buildings. *Sustainability*. 2019. Vol. 11, No. 16. Art. 4320. DOI: 10.3390/su11164320.
2. *Haque, A., Rahman, R. and Rahman, S.* Microservice-based Architecture of a Software as a Service (SaaS) Building Energy Management Platform. *Proceedings of the 2020 6th IEEE International Energy Conference (ENERGYCon)*. Gammarth, Tunisia. 2020. Pp. 967–972. DOI: 10.1109/ENERGYCon48941.2020.9236617.
3. *Filev Maia, R., Ballester Lurbe, C., Agrahari Baniya, A. and Hornbuckle, J.* IRRISENS: an IoT platform based on microservices applied in commercial-scale crops working in a multi-cloud environment. *Sensors*. 2020. Vol. 20, No. 24. Art. 7163. DOI: 10.3390/s20247163.
4. Amazon Web Services. Perform analytics at the edge. AWS Well-Architected Framework – IoT Lens. Available at: <https://docs.aws.amazon.com/wellarchitected/latest/iot-lens/perform-analytics-at-the-edge.html> (accessed 24 January 2026).
5. *Méndez-Guzmán, H.A., Padilla-Medina, J.A., Martínez-Nolasco, C., Martínez-Nolasco, J.J., Barranco-Gutiérrez, A.I., Contreras-Medina, L.M. and Leon-Rodríguez, M.* IoT-based monitoring system applied to aeroponics greenhouse. *Sensors*. 2022. Vol. 22, No. 15. Art. 5646. DOI: 10.3390/s22155646.
6. *Rezvani, S.M.E., Abyaneh, H.Z., Shamshiri, R.R., Balasundram, S.K., Dworak, V., Goodarzi, M. and Mahns, B.* IoT-based sensor data fusion for determining optimality degrees of microclimate parameters in commercial greenhouse production of tomato. *Sensors*. 2020. Vol. 20, No. 22. Art. 6474. DOI: 10.3390/s20226474.
7. *Thwin, K.M.M., Horanont, T. and Phatrapornnant, T.* Machine-Learning Microclimate Forecasting for Adaptive Equipment Control via Web Integration in Open-Ventilated Greenhouses. *AgriEngineering*. 2024. Vol. 6, No. 3. Pp. 2845–2869. DOI: 10.3390/agriengineering6030165.
8. *Ajagekar, A., Mattson, N.S. and You, F.* Energy-efficient AI-based control of semi-closed greenhouses leveraging robust optimization in deep reinforcement learning. *Advances in Applied Energy*. 2023. Vol. 9. Art. 100119. DOI: 10.1016/j.adapen.2022.100119.
9. *Miranda, L. and Schillaci, G.* Adaptive architecture towards portability of greenhouse models. *Acta Horticulturae*. 2020. Vol. 1296. Pp. 25–31. DOI: 10.17660/ActaHortic.2020.1296.4.
10. *Tung, Y.C., Syahputri, N.W. and Diputra, I.G.N.A.S.* Greenhouse Environment Sentinel with Hybrid LSTM-SVM for Proactive Climate Management. *AgriEngineering*. 2025. Vol. 7, No. 4. Art. 96. DOI: 10.3390/agriengineering7040096.

References:

1. Rodríguez-Gracia, D., Piedra-Fernández, J.A., Iribarne, L., Criado, J., Ayala, R., Alonso-Montesinos, J. and Maria de las Mercedes, C.U. (2019), "Microservices and machine learning algorithms for adaptive green buildings", *Sustainability*, Vol. 11, No. 16, Art. 4320, doi:10.3390/su11164320.
2. Haque, A., Rahman, R. and Rahman, S. (2020), "Microservice-based Architecture of a Software as a Service (SaaS) Building Energy Management Platform", *Proceedings of the 2020 6th IEEE International Energy Conference (ENERGYCon)*, Gammarth, Tunisia, pp. 967–972, doi:10.1109/ENERGYCon48941.2020.9236617.
3. Filev Maia, R., Ballester Lurbe, C., Agrahari Baniya, A. and Hornbuckle, J. (2020), "IRRISENS: an IoT platform based on microservices applied in commercial-scale crops working in a multi-cloud environment", *Sensors*, Vol. 20, No. 24, Art. 7163, doi:10.3390/s20247163.
4. Amazon Web Services (n.d.), "Perform analytics at the edge", AWS Well-Architected Framework – IoT Lens, available at: <https://docs.aws.amazon.com/wellarchitected/latest/iot-lens/perform-analytics-at-the-edge.html> (accessed 24 January 2026).
5. Méndez-Guzmán, H.A., Padilla-Medina, J.A., Martínez-Nolasco, C., Martínez-Nolasco, J.J., Barranco-Gutiérrez, A.I., Contreras-Medina, L.M. and Leon-Rodríguez, M. (2022), "IoT-based monitoring system applied to aeroponics greenhouse", *Sensors*, Vol. 22, No. 15, Art. 5646, doi:10.3390/s22155646.
6. Rezvani, S.M.E., Abyaneh, H.Z., Shamshiri, R.R., Balasundram, S.K., Dworak, V., Goodarzi, M. and Mahns, B. (2020), "IoT-based sensor data fusion for determining optimality degrees of microclimate parameters in commercial greenhouse production of tomato", *Sensors*, Vol. 20, No. 22, Art. 6474, doi:10.3390/s20226474.
7. Thwin, K.M.M., Horanont, T. and Phatrapornnant, T. (2024), "Machine-Learning Microclimate Forecasting for Adaptive Equipment Control via Web Integration in Open-Ventilated Greenhouses", *AgriEngineering*, Vol. 6, No. 3, pp. 2845–2869, doi:10.3390/agriengineering6030165.
8. Ajagekar, A., Mattson, N.S. and You, F. (2023), "Energy-efficient AI-based control of semi-closed greenhouses leveraging robust optimization in deep reinforcement learning", *Advances in Applied Energy*, Vol. 9, Art. 100119, doi:10.1016/j.adapen.2022.100119.
9. Miranda, L. and Schillaci, G. (2020), "Adaptive architecture towards portability of greenhouse models", *Acta Horticulturae*, Vol. 1296, pp. 25–31, doi:10.17660/ActaHortic.2020.1296.4.
10. Tung, Y.C., Syahputri, N.W. and Diputra, I.G.N.A.S. (2025), "Greenhouse Environment Sentinel with Hybrid LSTM-SVM for Proactive Climate Management", *AgriEngineering*, Vol. 7, No. 4, Art. 96, doi:10.3390/agriengineering7040096.

Надійшла (received) 25.12.2025

Стаття прийнята до друку 20.01.2026

Опублікована 27.03.2026

Yurii SHELIKHOV, postgraduate
Kharkiv National University of Radio Electronics,
Nauky Ave. 14, Kharkiv, 61166, Ukraine
Tel.: 099 069 0069
E-mail: yurii.shelikhov@nure.ua
ORCID: 0009-0009-8970-6571

Natalia AXAK, DSc (Engin.), Prof.
Kharkiv National University of Radio Electronics,
Nauky Ave. 14, Kharkiv, 61166, Ukraine
Tel.: 050 142 1880
E-mail: nataliia.axak@nure.ua
ORCID: 0000-0001-8372-8432

УДК 004.8:681.5

Модель представлення стану та прогнозування параметрів мікроклімату в розподілених інформаційно-вимірювальних системах / Шеліхов Ю.О., Аксак Н.Г. // Вісник НТУ "ХПІ". Серія: Інформатика та моделювання. – Харків: НТУ "ХПІ". – 2026. – № 2 (16). – С. 36 – 58.

У роботі запропоновано та експериментально оцінено хмарну мікросервісну платформу адаптивного керування мікрокліматом, що поєднує потокову обробку гетерогенних сенсорних даних і нейромережеве прогнозування. Удосконалена модель представлення стану формує узгоджений вектор стану на основі потокової агрегації та нормалізації IoT-вимірювань у режимі реального часу. На основі часових послідовностей цього вектора модель LSTM забезпечує коротко- та середньостроковий прогноз, який використовується для проактивного прийняття керуючих рішень у контурі клімат-контролю. Експерименти з віртуальними IoT-пристроями підтвердили придатність підходу до обробки потоків у реальному часі та високу точність прогнозування (MAE для температури $\pm 0,6$ °C; для вологості $\pm 3,1$ %). Іл.: 2. Табл.: 5. Бібліогр.: 10 назв

Ключові слова: хмарна мікросервісна платформа; IoT; нейромережеве прогнозування; модель LSTM.

UDC 004.8:681.5

State Representation and Microclimate Parameter Forecasting Model in Distributed Information and Measurement Systems / Shelikhov Yu., Axak N. // Herald of the National Technical University "KhPI". Series of "Informatics and Modeling". – Kharkov: NTU "KhPI". – 2026. – No 2 (16). – P. 36 – 58.

This paper proposes and experimentally evaluates a cloud-based microservice platform for adaptive microclimate control that combines streaming processing of heterogeneous sensor data with neural-network forecasting. The improved state representation model forms a unified state vector through real-time streaming aggregation and normalization of IoT measurements. Based on time sequences of this state vector, an LSTM model provides short- and mid-term forecasts that are used for proactive control decisions within the climate-control loop. Experiments with virtual IoT devices confirmed the feasibility of real-time stream processing and the high forecasting accuracy (MAE ± 0.6 °C for temperature and $\pm 3.1\%$ for relative humidity). Fig.: 2. Tables: 5. References: 10.

Keywords: cloud microservice platform; IoT; neural network forecasting; LSTM model.