

Бугров Анатолій Анатолійович

Аспірант кафедри інформаційних технологій проектування та прикладної математики,

<https://orcid.org/0000-0001-6986-1595>

Київський національний університет будівництва і архітектури, Київ

ОПТИМІЗАЦІЯ ГЕОІНФОРМАЦІЙНОГО СЕРВІСУ В СИСТЕМІ ПІДТРИМКИ ПРОЦЕСУ ВІДНОВЛЕННЯ ОБ'ЄКТІВ НЕРУХОМОСТІ

***Анотація.** Стаття є продовженням низки робіт, що спрямовані на розробку системи підтримки процесу відновлення об'єктів нерухомості. У фокусі дослідження геоінформаційний сервіс цієї системи. Розглянуто підходи до оптимізації геоінформаційного сервісу системи з урахуванням специфіки використання часових рядів і ресурсних метрик. Показано, що унікальні особливості геоінформаційного сервісу і вибраних метрик потребують індивідуального підходу до масштабування і оптимізації, який забезпечить високу продуктивність, адаптивність і економічність системи. Визначено ключові параметри, комплексний аналіз яких забезпечує ефективне управління ресурсами, підвищення продуктивності та зменшення ризику затримок у виконанні завдань системи. Запропоновано інтеграцію таких статистичних методів прогнозування, як експоненціальне згладжування та авторегресійне інтегроване ковзне середнє для передбачення пікових періодів навантаження на основі даних про використання пам'яті, тривалості обробки запитів і періодичності отримання супутникових знімків. Засвідчено, що використання експоненціального згладжування дає змогу швидко реагувати на зміни в періодичності отримання знімків і передбачити наступний час з достатньою точністю. Показано, що графічне представлення часового ряду у вигляді японських свічок має низку переваг порівняно з традиційними графіками. При такому представленні динаміки метрик «обсяг пам'яті» та «час отримання супутникових знімків» дозволяє отримувати комплексну інформацію про динаміку ресурсоспоживання. Практичне значення роботи полягає в забезпеченні безперервного моніторингу ресурсів сервісу, адаптивного управління ними та оперативного оновлення інформації про об'єкти нерухомості. При цьому адаптивне управління ресурсами поєднує проактивне прогнозування з реактивним масштабуванням, що спрямовано на зменшення затримок і підвищення ефективності роботи системи.*

Ключові слова: експоненціальне згладжування; прогнозоване масштабування; оптимізація продуктивності; аналіз часових рядів; свічковий графік

Вступ

У [1] запропоновано систему підтримки процесу відновлення об'єктів нерухомості (СППВОН), що призначається для оперативного збирання, опрацювання і аналізу даних про пошкоджені і зруйновані об'єкти.

У [2] показано доцільність побудови СППВОН на базі високонавантажених архітектур з можливістю динамічного масштабування та інтеграції новітніх технологій оптимізації обробки інформації. Високий рівень навантаження може спричинити одночасний доступ багатьох користувачів і обробка великих обсягів даних із різних джерел. Також у [2] окреслено архітектурні рішення і вимоги до СППВОН, що орієнтовані на обробку просторових даних, які необхідні для формування експертних висновків.

Саме тому серед основних вимог до СППВОН – відповідність вимогам масштабованості, надійності та продуктивності при високих навантаженнях.

Одним із ключових компонентів СППВОН є геоінформаційний сервіс, що отримує різні обсяги даних у різні проміжки часу. Адаптивність до змін режимів роботи цього сервісу є актуальною задачею і важливим етапом удосконалення СППВОН, адже ефективність опрацювання і збереження даних суттєво впливає на продуктивність системи, що уможливило знизити час обробки запитів і забезпечити стійкість до перевантажень.

Аналіз останніх досліджень і публікацій

Аналіз останніх публікацій у сфері розроблення і оптимізації інформаційних систем свідчить про високу зацікавленості у створенні масштабованих, гнучких і продуктивних рішень, що відповідають сучасним викликам роботи з великими обсягами даних.

Дослідження [3] пропонує гібридний підхід до автоматичного масштабування високонавантажених

систем у контексті управління ресурсами, що ґрунтується на прогнозуванні навантаження за часовими рядами. Автори [3] демонструють переваги інтеграції проактивного і реактивного підходів, що дає змогу зменшувати витрати ресурсів, ефективно реагуючи на зміни навантаження. Подібні підходи описані в [4], де запропоновано автоматизовану систему вибору оптимальних алгоритмів аналізу часових рядів, що знижує складність і підвищує ефективність прогнозування.

На окрему увагу заслуговують методи фрактального аналізу часових рядів, що висвітлені в [5]. Ці методи, зокрема обчислення Hurst експоненти, допомагають виявляти довготривалі залежності у даних, що може бути використано для визначення пікових значень навантаження та ідентифікації характеру навантажень на геоінформаційний сервіс.

Дослідження [6] пропонує інструмент прогнозування навантаження TempoScale, що використовує аналіз коротко- і довгострокових змін із застосуванням складних алгоритмів і нейронних мереж. Хоча цей інструмент демонструє високу ефективність у хмарних середовищах, складність і орієнтація на Kubernetes роблять його непридатним для управління ресурсами і масштабування СППВОН, яка є локальною системою з простішими вимогами до ресурсів.

У дослідженні [7] запропоновано автоматичне масштабування на основі OpenStack Monasca, що використовує прогнозування за допомогою штучних нейромереж для передбачення динаміки ключових метрик і проактивного масштабування. Попри високу точність у хмарних середовищах, складність реалізації і залежність від інфраструктури OpenStack обмежують його застосування в локальних системах із простішими архітектурними вимогами.

Застосування оптимізованої рекурентної нейромережі з довго- і короткотерміною пам'яттю (LSTM) до прогнозування короткострокових змін у високому енергоспоживанні розглянуто у [8]. Попри високу точність результатів, яка досягається завдяки вдосконаленню моделі та використанню алгоритмів оптимізації, застосування LSTM значно залежить від складної попередньої обробки даних і високих обчислювальних ресурсів.

Це ускладнює інтеграцію LSTM в локальні системи з простішими вимогами до масштабування. У [8] також запропоновано підхід до управління ресурсами на основі глибокого навчання, проте його складність і орієнтація на хмарні сервіси з жорсткими вимогами до якості обслуговування не відповідають простішим вимогам і архітектурі локального геоінформаційного сервісу СППВОН.

Серед сучасних рішень щодо автоматичного масштабування в хмарних системах – сервіси, що запропоновані платформами Google Cloud та Amazon Web Services (AWS).

Google Cloud застосовує масштабування з використанням машинного навчання (ML), що базуються на передбаченні навантаження для виявлення шаблонів і прогнозування майбутніх запитів шляхом аналізу історичних даних [10].

AWS пропонує аналогічні підходи, що базуються на Predictive Scaling і інтегрують ML до прогнозування пікових навантажень на ВНС, в яких масштабування залежить від значних обсягів даних і складної архітектури, а витрати на інфраструктуру виправдовуються масштабами використання [11].

Інші підходи, що базуються на гібридних механізмах масштабування чи автоматизації вибору алгоритмів, теж орієнтовані на великі хмарні середовища чи складні алгоритмічні реалізації.

Для СППВОН підходи [7; 8; 10; 11] мають низку таких обмежень, як: фінансова складова; складність імплементації; динаміка даних.

Найбільш доцільними для СППВОН є відносно прості й економічно ефективні:

- експоненціальне згладжування, що для короткотермінового прогнозування використовує найменше обчислювальних ресурсів;
- авторегресійне інтегроване ковзне середнє (ARIMA) для аналізу сезонних або періодичних змін у навантаженні.

- порогове масштабування з використанням лімітів, встановлених на основі історичних даних.

У табл. 1 наведено методи автоматичного масштабування, які забезпечують достатню точність прогнозування і масштабування згідно з вимогами до СППВОН, уникаючи надмірних витрат на складну інфраструктуру.

Простота імплементації також дає змогу швидко адаптувати систему до змінних умов роботи без залучення висококваліфікованих спеціалістів у сфері машинного навчання.

Для аналізу і прогнозування навантаження на геоінформаційний сервіс СППВОН ключовими є такі параметри: тривалість обробки запиту, обсяг використання пам'яті, завантаженість процесору та дата отримання знімка із супутника.

Ці параметри забезпечують комплексний підхід до оцінки:

- продуктивності і ресурсозалежності системи;
- впливу зовнішніх чинників на роботу системи.

Таблиця 1 – Порівняння методів автоматичного масштабування

Метод	Опис	Переваги	Недоліки	Рекомендації щодо використання
Реактивне масштабування	Реагує на досягнення порогових значень метрик (CPU, пам'ять) у режимі реального часу.	Простота реалізації, не потребує попереднього аналізу.	Затримка реакції на раптові сплески, можливі порушення SLA.	Системи з низькою вартістю затримки і передбачуваними сплесками навантаження.
Прогнозоване (на основі ML)	Використовує машинне навчання для прогнозування майбутнього навантаження і масштабування на випередження.	Висока точність для складних і динамічних робочих навантажень.	Високі витрати на обчислення, складність впровадження.	Великі динамічні системи з достатніми ресурсами і бюджетами.
Прогнозоване (статистичне)	Використовує статистичні моделі (експоненціальне згладжування, ARIMA) для прогнозування навантаження.	Низька вартість, зрозумілість, зручність для передбачуваних шаблонів.	Менш ефективні при сильно нестабільних і нециклічних навантаженнях.	Чутливі до витрат, системи з передбачуваними шаблонами навантаження.
Гібридне масштабування	Поєднує прогнозування (статистичне, на базі ML) із реактивними механізмами для реального часу.	Поєднання прогнозування на випередження і швидкої реакції.	Більш складні через інтеграцію кількох механізмів.	Критичні системи, що вимагають і точності, і швидкої реакції.

Також аналіз цих параметрів є основою для адаптації системи до змінних умов роботи. При цьому відомі методи масштабування, гібридні підходи на основі ML чи автоматизація вибору алгоритмів, орієнтовані на системи з високим рівнем варіативності навантаження, що вимірюється такими традиційними метриками, як CPU, RAM і частота запитів. Проте до геоінформаційного сервісу СППВОН висуваються спеціальні вимоги щодо продуктивності й адаптивності. Саме це обумовлює непридатність стандартних підходів і готових рішень від Google Cloud чи AWS.

Окрім того, готові рішення Google Cloud і AWS для прогнозування навантаження, які базуються на ML, вимагають значних обчислювальних ресурсів та фінансових витрат. Для геоінформаційного сервісу прогнозування навантаження, які базуються на ML, є недоцільним. Тому є сенс використовувати для масштабованих хмарних систем такі метрики, як обсяг пам'яті, час і періодичність отримання супутникових знімків. Зокрема остання метрика є нетиповою і це обмежує можливості її ефективного аналізу за допомогою стандартних підходів.

Отже, проведений аналіз виявив доцільність розробки підходу до оптимізації геоінформаційного сервісу СППВОН на базі статистичних методів прогнозування передачі даних супутникових знімків, оскільки:

- буде адаптований до спеціальних умов роботи геоінформаційного сервісу;
- дозволить ефективно масштабувати систему за умови мінімальних витрат ресурсів.

Мета публікації

Метою статті є оптимізація геоінформаційного сервісу в системі підтримки процесу відновлення об'єктів нерухомості в напрямі забезпечення стійкості до перевантажень і адаптивності до змін у режимах роботи.

Виклад основного матеріалу

Для ефективної роботи геоінформаційного сервісу СППВОН потрібно передбачати час отримання супутникових знімків. При цьому дані супутникового моніторингу мають періодичний характер і суттєво впливають на навантаження на систему в час їх надходження. Точне прогнозування часу наступного прольоту супутника дає змогу ефективно розподіляти ресурси сервісу, зменшуючи затримки і оптимізуючи обробку даних.

Для розв'язання цієї задачі можна використати експоненціальне згладжування, що здійснюється за формулою:

$$S_t = \alpha X_t + (1 - \alpha)S_{t-1}, \quad (1)$$

де S_t – згладжене значення в час t ; X_t – фактичне значення параметра; S_{t-1} – згладжене значення у

момент часу $t - 1$; α ($0 < \alpha \leq 1$) – коефіцієнт згладжування, що визначає вагу останніх спостережень.

Нехай дати отримання знімків за останні п'ять періодів: $X_1 = 3, X_2 = 4, X_3 = 2, X_4 = 3, X_5 = 4$ (в днях); коефіцієнт згладжування $\alpha = 0.5$; початкове згладжене значення $S_0 = 3$ (вибрано на основі першого значення).

Тоді згідно з (1) для кожного періоду:

$$S_1 = \alpha X_1 + (1 - \alpha)S_0 = \frac{1}{2} \cdot 3 + \left(1 - \frac{1}{2}\right) \cdot 3 = 3.0;$$

$$S_2 = \alpha X_2 + (1 - \alpha)S_1 = \frac{1}{2} \cdot 4 + \left(1 - \frac{1}{2}\right) \cdot 3 = 3.5;$$

$$S_3 = \alpha X_3 + (1 - \alpha)S_2 = \frac{1}{2} \cdot 2 + \left(1 - \frac{1}{2}\right) \cdot 3.5 = 2.75;$$

$$S_4 = \alpha X_4 + (1 - \alpha)S_3 = \frac{1}{2} \cdot 3 + \left(1 - \frac{1}{2}\right) \cdot 2.75 = 2.875;$$

$$S_5 = \alpha X_5 + (1 - \alpha)S_4 = \frac{1}{2} \cdot 4 + \left(1 - \frac{1}{2}\right) \cdot 2.875 = 3.4375.$$

На рис. 1 показано графіки, що відображають фактичні значення (X_t), згладжені значення (S_t) і прогноз для наступного періоду (X_6).




Рисунок 1 – Розрахунок експоненціальним зважуванням

Прогнозоване значення X_6 ґрунтується на останньому згладженому значенні S_5 . Результат 3,4375 днів вказує, що наступний супутниковий знімок очікується через 3 дні 10 годин і 30 хвилин після останнього.

Часовий ряд, який представляє дані, такі як навантаження на систему або кількість запитів, може бути подано у вигляді японських свічок (рис. 2).




Рисунок 2 – Свічковий графік використання пам'яті

Цей формат використовується у фінансовому аналізі, що уможливорює візуалізувати часовий ряд за

допомогою таких атрибутів, як відкриття, закриття, максимальне і мінімальне значення для певного періоду. Перехід від білих до чорних свічок і навпаки допомагає ідентифікувати моменти зміни тенденції. Це робить свічковий графік більш зручним для аналізу часових рядів, де важливо не лише фіксувати значення, але й розуміти їхній напрям.

Графічне представлення часового ряду у вигляді японських свічок має низку переваг порівняно з традиційними графіками. По-перше, свічкові графіки забезпечують більш компактне представлення даних, уможливаючи одночасно відображати кілька ключових показників, таких як значення на початку періоду, у кінці, а також мінімальні і максимальні значення [9].

Цей підхід значно підвищує інформативність графіка, надаючи користувачеві повну картину про варіативність даних у кожному окремому інтервалі. Окремо слід зазначити зручність візуалізації трендів і реверсій. Завдяки кольоровому кодуванню (білий для зростання і чорний для спаду) японські свічки відображають напрямок змін у даних.

У табл. 2 наведено приклад даних, які буде отримувати геоінформаційний сервіс для аналізу та представлення характеристик:

- Open відображає рівень використання пам'яті на початку певного періоду.
- Close показує рівень пам'яті на момент завершення цього періоду.
- High свідчить про пікове використання пам'яті, наприклад, під час інтенсивних запитів.
- Low показує найнижчий рівень споживання пам'яті в межах періоду.

Згідно з таблицею:

- вранці спостерігається стабільне зростання використання пам'яті, що свідчить про активізацію системи після низької нічної активності;
- вдень спостерігається значне зниження використання пам'яті, яке може бути спричинене завершенням ресурсоемних завдань;
- початок вечора демонструє плавне зростання, яке переходить у пікове навантаження;
- після піку спостерігається поступове зниження використання пам'яті, що характерно для завершення активного робочого дня.

Максимальні значення використання пам'яті в цей період свідчать про одночасну активність багатьох користувачів чи виконання складних операцій.

На рис. 3 показано процес проактивного і реактивного масштабування.

Цей процес складається з кількох послідовних етапів: отримання метрик системи, аналізу часових рядів, прийняття рішень на основі порогових значень і застосування відповідних масштабуючих дій проактивного та реактивного характеру.

Таблиця 2 – Вхідні дані графіка використання пам'яті

Часовий період	Open (ГБ)	High (ГБ)	Low (ГБ)	Close (ГБ)
Ранок (1-ша свічка)	1.5	1.9	2.5	2.2
Ранок (2-га свічка)	2.3	2.8	3.6	3.0
День (3-тя свічка)	2.8	2.4	1.8	1.6
Початок вечора (4-та свічка)	2.2	3.0	3.8	3.5
Вечірній пік (5-та свічка)	3.4	4.0	4.5	3.9
Кінець вечора (6-та свічка)	3.6	3.3	2.7	2.5

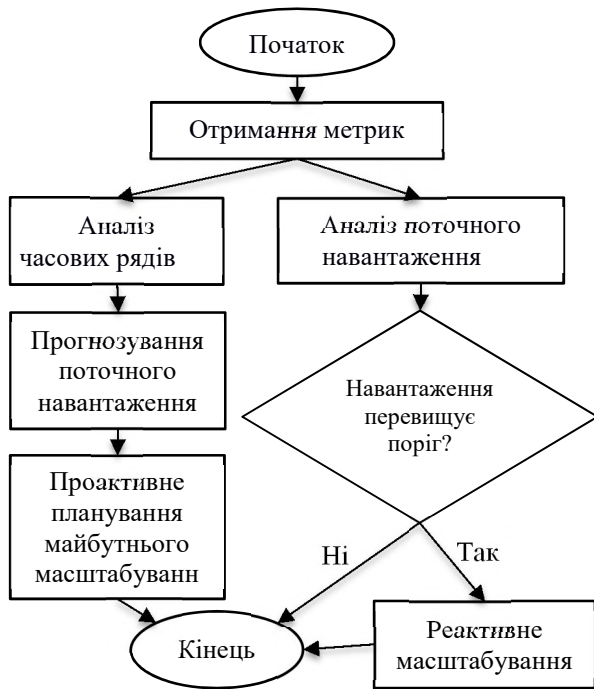


Рисунок 3 – Блок-схема процесу масштабування

На початковому етапі здійснюється моніторинг ключових метрик, таких як тривалість обробки запитів, періодичність отримання супутникових знімків і використання пам'яті. Ці дані використовуються в процесі аналізу часових рядів для визначення довгострокових трендів і прогнозування періодів можливого пікового навантаження. Далі на основі прогнозів поточного

навантаження приймаються рішення щодо планування майбутнього масштабування.

Паралельно з прогнозуванням здійснюється тривіальний аналіз поточного навантаження для оперативного (реактивного) масштабування за умови, що поточне навантаження перевищує встановлені пороги. Заключним етапом процесу є оптимізація використання ресурсів. Після виконання масштабування система переглядає стан ресурсів і, за необхідності, проводить їх балансування для забезпечення максимальної ефективності роботи.

Висновки

1. Проведений аналіз останніх досліджень і публікацій засвідчив, що впровадження статистичних методів прогнозування в поєднанні з реактивним масштабуванням надає можливість покращити стійкість системи підтримки процесу відновлення об'єктів нерухомості до перевантажень і її адаптивність до змін у режимах роботи.

2. Запропоновано поєднання проактивного і реактивного масштабування, що допомагає уникати перевантаження СППВОН і знизити витрати на ресурси, підтримуючи їх використання на оптимальному рівні.

3. У подальшому слід розглянути інтеграцію алгоритмів оптимального планування ресурсів, що враховують пріоритетність окремих запитів залежно від їх впливу на загальну продуктивність системи. Це забезпечить не лише ефективність системи в сучасних умовах, а й матиме значний потенціал для адаптації до більш складних сценаріїв роботи.

Список літератури / References

1. Terenchuk S., Pasko R., Buhrov A., Ploskyi V., Panko O. and Zapryvoda V. (2022). "Computerization of the process of reconstruction of damaged or destroyed real estate," *2022 IEEE 3rd KhPI Week on Advanced Technology (KhPIWeek)*, Kharkiv, Ukraine, pp. 1–6, doi: 10.1109/KhPIWeek57572.2022.9916470.
2. Terenchuk S., Pasko R., Bosenko I., Buhrov A., Yaschenko A. and Volokh B., (2023). "Ontology Formation of Support System for Restoration of Buildings, Property and Infrastructure Objects," *2023 IEEE 4th KhPI Week on Advanced Technology (KhPIWeek)*, Kharkiv, Ukraine, pp. 1–5, doi: 10.1109/KhPIWeek61412.2023.10313006.
3. Singh, P., Kaur, A., Gupta, P. et al. (2021). RHAS: robust hybrid auto-scaling for web applications in cloud computing. *Cluster Comput* 24, 717–737. <https://doi.org/10.1007/s10586-020-03148-5>.

4. Mu, T., Sheng, Z., Zhou, L., Wang, H., (2023). Auto-TSA: An Automatic Time Series Analysis System Based on Meta-learning. In: El Abbadi, A., et al. Database Systems for Advanced Applications. DASFAA 2023 International Workshops. DASFAA 2023. Lecture Notes in Computer Science, vol. 13922. Springer, Cham. https://doi.org/10.1007/978-3-031-35415-1_10.
5. Biloshchytskyi A., Neftissov A., Kuchanskyi O., Andrashko Y., Biloshchytska S., Mukhatayev A., Kazambayev I. (2024). Fractal Analysis of Air Pollution Time Series in Urban Areas in Astana, Republic of Kazakhstan. Urban Science. 2024; 8 (3):131. <https://doi.org/10.3390/urbansci8030131>.
6. Wen L., Xu M., Toosi A. N. and Ye K., (2024). "TempoScale: A Cloud Workloads Prediction Approach Integrating Short-Term and Long-Term Information," 2024 IEEE 17th International Conference on Cloud Computing (CLOUD), Shenzhen, China, pp. 183–193, doi: 10.1109/CLOUD62652.2024.00030.
7. Lanciano G., Galli F., Cucinotta T., Bacciu D., and Passarella A. (2021). Predictive auto-scaling with OpenStack Monasca. In Proceedings of the 14th IEEE/ACM International Conference on Utility and Cloud Computing (UCC '21). Association for Computing Machinery, New York, NY, USA, Article 20, 1–10. <https://doi.org/10.1145/3468737.3494104>.
8. Ma Y., Tang Y., Li B. and Qi, B. (2020). "Residential High-Power Load Prediction Based on Optimized LSTM Network," 2020 International Conference on Artificial Intelligence and Computer Engineering (ICAICE), Beijing, China, pp. 538–541, doi: 10.1109/ICAICE51518.2020.00109.
9. Ladyzhets, V. & Terenchuk S. (2021). Models and methods of technical analysis of financial markets. Management of Development of Complex Systems, 48, 47–52, dx.doi.org/10.32347/2412-9933.2021.48.47-52.
10. Scaling based on predictions | cloud.google. Google Cloud. URL: <https://cloud.google.com/compute/docs/autoscaler/predictive-autoscaling>.
11. Automatically scale your Amazon ECS service | docs.aws.amazon. AWS. URL: <https://docs.aws.amazon.com/AmazonECS/latest/developerguide/service-auto-scaling.html>

Стаття надійшла до редколегії 12.04.2025

Buhrov Anatolii

Postgraduate student of Department of Information Technology Design and Applied Mathematics,
<https://orcid.org/0000-0001-6986-1595>
Kyiv National University of Construction and Architecture, Kyiv, Ukraine

OPTIMIZATION OF THE GEOINFORMATION SERVICE IN THE REAL ESTATE RESTORATION SUPPORT SYSTEM

Abstract. This article is a continuation of a series of studies aimed at developing a support system for the restoration process of real estate objects. The focus of the research is on the geoinformation service of this system. Approaches to optimizing the geoinformation service are examined, taking into account the specifics of time series analysis and resource metrics. It is demonstrated that the unique characteristics of the geoinformation service and the selected metrics necessitate an individualized approach to scaling and optimization, thereby ensuring high performance, adaptability, and cost-effectiveness of the system. Key parameters are identified whose comprehensive analysis facilitates efficient resource management, enhanced performance, and a reduction in the risk of execution delays. An integration of statistical forecasting methods, such as exponential smoothing and autoregressive integrated moving average, is proposed for predicting peak load periods based on data concerning memory usage, query processing duration, and the frequency of satellite image acquisitions. The application of exponential smoothing is shown to enable rapid responses to changes in the periodicity of image acquisitions and to forecast subsequent intervals with sufficient accuracy. Moreover, it is demonstrated that representing time series data in the form of Japanese candlesticks offers several advantages over traditional graphs. Such a representation of the dynamics of "memory usage" and "satellite image acquisition time" provides comprehensive insights into resource consumption trends. The practical significance of this work lies in ensuring continuous resource monitoring of the service, adaptive management, and the prompt updating of real estate object information. In this context, adaptive resource management combines proactive forecasting with reactive scaling to reduce delays and enhance overall system efficiency.

Keywords: exponential smoothing; predictive scaling; performance optimization; time series analysis; candlestick chart

Посилання на публікацію

- APA Buhrov A. (2025). Optimization of the geoinformation service in the real estate restoration support system. *Management of Development of Complex Systems*, 61, 187–192, dx.doi.org/10.32347/2412-9933.2025.61.187-192.
- ДСТУ Бугров А. А. Оптимізація геоінформаційного сервісу в системі підтримки процесу відновлення об'єктів нерухомості. *Управління розвитком складних систем*. Київ, 2025. № 61. С. 187 – 192, dx.doi.org/10.32347/2412-9933.2025.61.187-192.