ISSN 1998-7927(print) ISSN 2664-6498 (online)

DOI: https://doi.org/10.33216/1998-7927-2026-305-6-43-52

УДК 004.8:004.62

ІНТЕГРОВАНА СИСТЕМА ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ ДЛЯ ПРОГНОЗУВАННЯ ВАРТОСТІ КІБЕРІНЦИДЕНТІВ У КРИТИЧНІЙ ІНФРАСТРУКТУРІ

Гуськова В.Г., Школьников В.І.

INTEGRATED DECISION SUPPORT SYSTEM FOR CYBER INCIDENT COST PREDICTION IN CRITICAL INFRASTRUCTURE

Huskova V.H., Shkolnikov V.I.

Системи критичної інфраструктури функціонують в умовах високої динамічності, нестаціонарності та невизначеності, що висуває підвищені вимоги до сучасних систем підтримки прийняття рішень. Забезпечення своєчасного та достовірного прогнозування стану таких об'єктів є важливою умовою підвищення їхньої надійності та безпеки функціонування. Існуючі методи прогнозування забезпечують високу точність, проте недостатньо враховують невизначеність прогнозів, обмежено підтримують інтерпретованість результатів і недостатньо адаптуються до зміни умов експлуатації, а прогнозування, оцінювання невизначеності та пояснюваність здебільшого реалізуються ізольовано. Метою роботи є підвищення надійності, адаптивності та інтерпретованості підтримки прийняття рішень шляхом розроблення інтегрованої системи прогнозування стану об'єктів критичної інфраструктури.

Запропоновано модульну архітектуру системи, що об'єднує модулі збору та попередньої обробки даних, формування ознак, ансамблевого прогнозування, оцінювання невизначеності, пояснюваності та підтримки прийняття рішень. Гібридний ансамбль поєднує статистичні моделі, регресори машинного навчання та рекурентні нейронні мережі з динамічним байєсівським зважуванням прогнозів. Наукова новизна полягає в інтеграції гібридного прогнозування, динамічної байєсівської агрегації моделей, оцінювання невизначеності прогнозів і адаптивного навчання із замкненим контуром зворотного зв'язку в межах єдиної інформаційної технології підтримки прийняття рішень.

Експериментальну перевірку виконано на відкритому наборі даних ETTh1 (17 420 спостережень, 41 ознака) за протоколом ковзного початку (20 вікон оцінювання, горизонти 1–24 год). Запропонована система забезпечила MAE = 1,329 ± 0,448, RMSE = 1,911 та R^2 = 0,897, що відповідає зменшенню похибки на 24,6–30,1 % порівняно з окремими моделями машинного навчання. Абляційне дослідження показало, що модуль адаптивного навчання забезпечує зменшення MAE на 82,4 %, а модуль байєсівської агрегації — коректне калібрування прогнозних інтервалів (PICP = 0,952 за номінального рівня 0,95). Індекс довіри значуще корелює з фактичною похибкою, що дає змогу використовувати його як критерій ескалації рішення до експерта. Статистичну значущість відмінностей підтверджено критеріями Вілкоксона та Фрідмана.

Ключові слова: *система підтримки прийняття рішень; критична інфраструктура; прогнозування часових рядів; ансамблеве прогнозування; байєсівська агрегація; оцінювання невизначеності.*

Вступ. Системи критичної інфраструктури — зокрема енергетичні мережі, транспортні системи, комунікаційні платформи та середовища промислового керування — функціонують в умовах високої динамічності, складних міжсистемних взаємозв'язків і значних наслідків операційних відмов. Навіть короткочасні порушення можуть спричиняти каскадні ефекти в суміжних секторах, що призводить до суттєвих економічних втрат і соціальних ризиків. Тому системи підтримки прийняття рішень (СППР), які застосовують у таких галузях, мають забезпечувати надійну роботу в умовах невизначеності, нестаціонарності та неповноти інформації.

Традиційні СППР для об'єктів критичної інфраструктури здебільшого ґрунтуються на описовій аналітиці та правилах моніторингу, орієнтованих на порогові значення й статичні індикатори. Такі підходи забезпечують ситуаційну обізнаність, проте не мають прогнозних можливостей і не адаптуються до змін динаміки системи. Сучасні методи машинного та глибинного навчання суттєво підвищили точність

прогнозування, однак зазвичай оптимізуються виключно за критерієм точності та функціонують як «чорні скриньки», що обмежує їх прозорість, стабільність та явне подання невизначеності.

Аналіз останніх публікацій свідчить про фрагментарність наявних рішень. Аналіз часових рядів широко застосовують для прогнозування динаміки об'єктів критичної інфраструктури [1, 2]; класичні моделі ARIMA та SARIMA обмежені припущеннями стаціонарності й лінійності [3]. Для нелінійних залежностей використовують рекурентні нейронні мережі LSTM і GRU [4, 5], проте вони чутливі до концептуального зсуву й не оцінюють невизначеність явно [6]. Ансамблеві методи підвищують стійкість, але їх ваги зазвичай статичні [7]; байєсівські підходи формально оцінюють невизначеність [8, 9], однак застосовуються ізольовано. Пояснюваний штучний інтелект (SHAP, LIME) підвищує прозорість [10, 11], але переважно апостеріорно, окремо від логіки рішень [12]. Адаптація до дрейфу потребує онлайн-навчання [13], а неконтрольована автоматизація деградує якість, тоді як підходи «людина в контурі» рідко інтегруються в єдину рамку [14]. Отже, відсутні інтегровані СППР, які узгоджено поєднують прогнозування, оцінювання невизначеності, пояснюваність і контрольоване адаптивне навчання — що й визначає актуальність роботи.

Метою роботи є підвищення надійності та інтерпретованості рішень для об'єктів критичної інфраструктури шляхом розроблення інтегрованої СППР з урахуванням невизначеності. Для досягнення мети поставлено задачі: побудувати гібридну модель прогнозування нестаціонарних часових рядів з урахуванням багатофакторних впливів; розробити механізм байєсівського зважування прогнозів із динамічним оцінюванням надійності моделей і невизначеності; інтегрувати методи атрибуції факторів у логіку прийняття рішень; реалізувати замкнений контур адаптивного навчання з експертним контролем; експериментально перевірити ефективність підходу.

Об'єкт дослідження — процеси підтримки прийняття рішень для об'єктів критичної інфраструктури в умовах нестаціонарності та невизначеності.

Предмет дослідження — моделі та методи гібридного прогнозування, байєсівської агрегації, пояснюваної логіки рішень і контрольованого адаптивного навчання у складі єдиної СППР.

Для досягнення поставленої мети необхідно вирішити такі **завдання дослідження**:

- Провести аналіз сучасних методів і систем підтримки прийняття рішень для об'єктів критичної інфраструктури та визначити їх основні переваги й обмеження в умовах нестаціонарності та невизначеності.
- Розробити архітектуру інтегрованої системи підтримки прийняття рішень, яка забезпечує повний цикл оброблення даних, прогнозування, оцінювання невизначеності, пояснення результатів та формування рекомендацій.
- Розробити гібридну модель прогнозування нестаціонарних часових рядів із урахуванням багатофакторних впливів на основі поєднання статистичних моделей, методів машинного навчання та глибинних нейронних мереж.
- Розробити механізм динамічної байєсівської агрегації прогнозів, що забезпечує адаптивне визначення ваг моделей та кількісне оцінювання невизначеності прогнозування.
- Інтегрувати методи пояснюваного штучного інтелекту в процес підтримки прийняття рішень для визначення внеску окремих факторів та підвищення інтерпретованості результатів прогнозування.
- Реалізувати механізм адаптивного навчання із замкненим контуром зворотного зв'язку та експертним контролем для забезпечення стійкості системи до концептуального зсуву.
- Провести експериментальне дослідження ефективності запропонованої СППР та оцінити її точність, стабільність, надійність і інтерпретованість порівняно з існуючими підходами.

Наукова новизна полягає в тому, що запропоновано замкнену, орієнтовану на невизначеність СППР, у якій пояснюваність і моделювання невизначеності інтегровано безпосередньо в процес прийняття рішень, а не як допоміжні компоненти.

Запропонована система підтримки прийняття рішень є інтегрованим програмно-аналітичним середовищем, призначеним для прогнозування стану об’єктів критичної інфраструктури та формування обґрунтованих рекомендацій в умовах невизначеності й нестаціонарності даних. Система забезпечує повний цикл опрацювання інформації — від отримання та підготовки даних до прогнозування, оцінювання надійності результатів, пояснення причин прогнозованих змін і вибору доцільного управлінського рішення і представлена на рисунку 1.

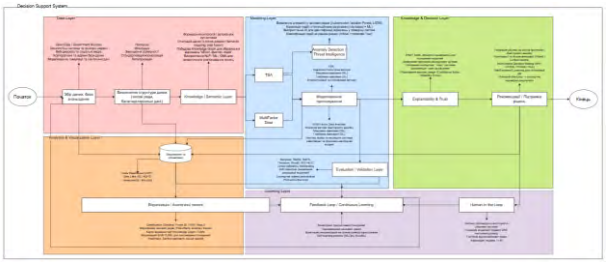


Рис. 1. Архітектура СППР

Архітектуру СППР побудовано за модульним принципом, що забезпечує гнучкість, масштабованість і можливість незалежного оновлення окремих компонентів. Взаємодія модулів організована у вигляді послідовного інформаційного потоку з механізмом зворотного зв’язку. Результати функціонування системи та фактичні дані використовуються для контролю якості

прогнозування, виявлення концептуального зсуву та адаптивного оновлення моделей.

До складу запропонованої СППР входять сім взаємопов'язаних компонентів: модуль збору даних, модуль попередньої обробки, модуль побудови ознак, модуль ансамблевого прогнозування, модуль оцінювання невизначеності, модуль пояснюваності та модуль підтримки прийняття рішень.

Таблиця 1

Функціональні модулі та їх призначення

Модуль збору даних	Модуль забезпечує отримання даних із внутрішніх і зовнішніх джерел, їх інтеграцію та синхронізацію за часовими мітками. На цьому етапі формується єдиний інформаційний потік, який використовується для подальшого аналізу.
Модуль попередньої обробки	Модуль виконує очищення даних, обробку пропусків, усунення аномальних значень, нормалізацію та підготовку інформації до аналізу. Його призначення полягає у підвищенні якості вхідних даних і забезпеченні їхньої узгодженості.
Модуль побудови ознак	Модуль формує інформативний ознаковий простір на основі вихідних даних. На цьому етапі обчислюються лагові, статистичні, сезонні та контекстні ознаки, які найкраще характеризують поточний стан системи та використовуються для прогнозування.
Модуль ансамблевого прогнозування	Модуль реалізує прогнозування за допомогою сукупності статистичних моделей, моделей машинного навчання та глибинних нейронних мереж. Отримані прогнози об'єднуються в єдину оцінку шляхом динамічного байєсівського зважування, що підвищує точність і стійкість прогнозів.
Модуль оцінювання невизначеності	Модуль визначає ступінь надійності отриманого прогнозу шляхом аналізу узгодженості результатів окремих моделей. Результатом його роботи є оцінка невизначеності та індекс довіри, які використовуються під час формування остаточного рішення.
Модуль пояснюваності	Модуль забезпечує інтерпретацію результатів прогнозування шляхом визначення внеску окремих факторів у кінцевий прогноз. Для цього використовуються методи Explainable AI, що дозволяють пояснити причини прийнятого рішення та підвищити довіру до системи.
Модуль підтримки прийняття рішень	Модуль інтегрує результати прогнозування, оцінку невизначеності та пояснення моделей для формування рекомендацій щодо подальших дій. На основі оцінки ризику система генерує обґрунтоване рішення, яке може бути використане оператором або автоматизованою системою управління.

Сукупна робота цих компонентів забезпечує формування не лише прогнозного значення, а й оцінки довіри до прогнозу, визначення ключових факторів впливу та генерування інтерпретованої рекомендації для особи, яка приймає рішення.

Виклад основного матеріалу. Запропонована архітектура є концептуальною основою розробленої системи підтримки прийняття рішень. Її практична реалізація базується на комплексі математичних моделей і методів, що забезпечують підготовку даних, прогнозування, оцінювання невизначеності, інтерпретацію результатів та формування рекомендацій, які розглянуто далі.

Нехай y_t — цільова змінна стану системи, а вектор контекстних і екзогенних факторів має вигляд (1):

$$x_t = \{x_t^{(1)}, ..., x_t^{(m)}\} \tag{1}$$

Мета СППР — формування надійного прогнозу на k кроків уперед разом з оцінкою невизначеності та інтерпретованим обґрунтуванням в умовах змінних розподілів даних:

$$\hat{y}_{t+k} = F(y_{1:t}, x_{1:t}) \tag{2}$$

де $F(\cdot)$ — адаптивна функція прийняття рішень, а не окрема прогностична модель.

Гібридні моделі прогнозування. Фреймворк використовує гетерогенний набір прогностичних моделей

$$M = \{M_1, M_2, ..., M_N\} \tag{3}$$

що охоплює статистичні моделі часових рядів (ARIMA, SARIMA), регресори машинного навчання та глибинні архітектури (LSTM, GRU). Кожна модель формує умовний прогноз:

$$\hat{y}_{t+k}^{(i)} = M_i(y_{1:t}, x_{1:t}) \tag{4}$$

Замість вибору єдиної «найкращої» моделі всі моделі розглядаються як взаємодоповнювальні гіпотези, релевантність яких може змінюватися в часі внаслідок нестаціонарності.

Байєсівсько-зважена агрегація ансамблю. Кожній моделі ставиться у відповідність апостеріорна вага $w_i(t)$, що відображає її достовірність за наявних даних:

$$w_i(t) = P(M_i \mid D_t) \tag{5}$$

Ваги оновлюються динамічно на основі нещодавньої якості прогнозування:

$$w_i(t) \propto w_i(t-1) \cdot \exp(-\lambda \cdot L_i(t)) \tag{6}$$

де $L_i(t)$ — функція втрат (RMSE або MAE) на валідаційному вікні, а λ керує чутливістю до змін якості. Агрегований прогноз обчислюється як:

$$\hat{y}_{t+k} = \sum_{i=1}^{N} w_i(t)\hat{y}_{t+k}^{(i)} \quad (7)$$

Це дозволяє СППР адаптивно посилювати вплив надійних наразі моделей і знижувати вагу моделей, уражених дрейфом чи структурними змінами.

Оцінювання невизначеності та індекс довіри. Невизначеність прогнозу кількісно оцінюється через розсіювання зважених прогнозів моделей:

$$\sigma_{t+k}^2 = \sum_{i=1}^{N} w_i(t)(\hat{y}_{t+k}^{(i)} - \hat{y}_{t+k})^2 \quad (8)$$

На основі цієї міри визначається індекс довіри:

$$CI_{t+k} = \exp(-\alpha\sigma_{t+k}) \quad (9)$$

де α керує чутливістю довіри до невизначеності. Індекс надає особам, які приймають рішення, явну міру надійності прогнозу.

Пояснювана логіка прийняття рішень. Пояснюваність інтегровано на рівні рішення, а не як апостеріорну візуалізацію. Методи атрибуції факторів (SHAP, LIME) кількісно оцінюють внесок окремих факторів:

$$\phi_j(t) = SHAP(x_t^{(j)}) \quad (10)$$

де $\phi_j(t)$ — внесок фактора j в агрегований прогноз. Рекомендації формуються як функція прогнозних значень, внесків факторів і довіри:

$$R_t = g(\hat{y}_{t+k}, \{\phi_j(t)\}, CI_{t+k}) \quad (11)$$

що забезпечує підкріплення кожного рішення інтерпретованими доказами та показниками надійності.

Замкнений контур адаптивного навчання. Для протидії концептуальному зсуву реалізовано замкнений контур навчання: автоматизоване перенавчання запускається за перевищення порогових метрик дрейфу, а експертний зворотний зв'язок обмежує адаптацію:

$$M_{t+1} = \arg\min_M [\alpha(M, D_t) + \beta \cdot Drift(M) - \gamma \cdot ExpertScore(M)] \quad (12)$$

Таке формулювання балансує точність, стабільність і експертну валідацію, запобігаючи неконтрольованій деградації за збереження адаптивності.

Формулювання рішення з урахуванням ризику. Вибір рішення d_t формулюється як задача мінімізації ризику з урахуванням прогнозованого стану та його невизначеності:

$$r_t^* = \arg\min_{r \in R} E[L(r, \hat{y}_{t+k}, U_{t+k})] \quad (13)$$

де $L(\cdot)$ — функція втрат, що відображає операційні витрати, обмеження безпеки та ставлення до ризику. Це дозволяє СППР надавати перевагу консервативним або запобіжним діям за високої невизначеності.

Експериментальне дослідження проведено на відкритому наборі даних Electricity Transformer Temperature (ETT), який містить часові ряди параметрів роботи силових трансформаторів енергетичної інфраструктури та супутні контекстні змінні. Цільова змінна y_t представляє ключовий операційний показник (споживання/навантаження електроенергії, обсяг мережевого трафіку) з годинною дискретизацією; вектор контекстних ознак x_t включає метеорологічні показники, операційні коваріати та індикатори зовнішньої активності. Усі набори даних характеризуються нестаціонарністю, сезонністю та зсувами режимів функціонування.

Попередня обробка охоплювала нормалізацію часових міток, хронологічне впорядкування та узгодження ознак; пропуски заповнювали прямим заповненням (короткі інтервали) і медіанним/сезонним імпутуванням (триваліші), з виключенням витоку майбутньої інформації. Неперервні змінні масштабували робастною нормалізацією (медіана та міжквартильний розмах), параметри якої визначали лише на навчальних даних.

Для відтворення умов реального розгортання застосовано протокол ковзного початку (walk-forward): на кожному кроці t моделі навчали на історичному вікні довжини W і тестували на горизонті k кроків уперед (k ∈ {1, 3, 6, 12, 24}), після чого вікно зсували на один крок. Підхід порівнювали з базовими моделями трьох класів: класичні статистичні методи (ARIMA, SARIMA), регресори машинного навчання з лаговими та екзогенними ознаками, глибинні послідовні моделі (LSTM, GRU), а також традиційний статичний ансамбль. Усі методи використовували однакові вхідні ознаки та ідентичні схеми розбиття даних.

Метрики оцінювання. Точність прогнозування оцінювали стандартними метриками — середньою абсолютною похибкою (MAE):

$$MAE = \frac{1}{N}\sum_{t=1}^{N} | y_t - \hat{y}_t | \quad (14)$$

та коренем середньоквадратичної похибки (RMSE):

$$RMSE = \sqrt{\frac{1}{N}\sum_{t=1}^{N}(y_t - \hat{y}_t)^2} \quad (15)$$

Стабільність оцінювали через дисперсію похибок прогнозу в часі:

$$Stability = Var(y_t - \hat{y}_t) \quad (16)$$

менша дисперсія свідчить про більшу стійкість до структурних змін. Додатково аналізували ймовірність покриття прогнозних інтервалів (PICP), кореляцію похибок з оцінками невизначеності, стабільність рейтингів важливості ознак (SHAP) у часі, а також провели абляційне дослідження з послідовним вимкненням ключових модулів (байєсівське зважування, пояснювана логіка, адаптивне навчання).

Умови відтворюваності. Обчислювальний експеримент виконано на відкритому наборі даних ETTh1 (Electricity Transformer Temperature), що містить 17 420 годинних спостережень за період з 1 липня 2016 р. до 26 червня 2018 р. і не має пропущених значень. Цільовою змінною обрано показник OT; ознаковий простір сформовано із шести операційних коваріат (HUFL, HULL, MUFL, MULL, LUFL, LULL) та похідних лагових, ковзних і календарних ознак — загалом 41 ознака. Усі ознаки є строго причинними: для формування прогнозу $y(t+k)$ використовується виключно інформація, доступна на момент t.

Оцінювання виконано за протоколом ковзного (walk-forward) із ковзним навчальним вікном W = 1500 год, тестовим блоком B = 72 послідовні точки відліку прогнозу та кроком зсуву 720 год (30 діб). Загальна кількість вікон оцінювання — 20, що відповідає покриттю близько 1,6 року. Горизонти прогнозування $k \in \{1, 3, 6, 12, 24\}$ год. Параметри масштабування (медіана та міжквартильний розмах) оцінювали виключно на навчальних підвибірках, що виключає витік інформації з тестового блоку.

Конфігурації базових моделей: ARIMA(2,1,2); SARIMA(1,1,1)(1,0,1)[24]; Random Forest (120 дерев, максимальна глибина 10); XGBoost (250 дерев, темп навчання 0,05, максимальна глибина 5); LSTM і GRU (один шар, 32 нейрони, довжина вхідної послідовності 48, 25 епох, оптимізатор Adam). Параметри байєсівської агрегації: $\lambda = 1{,}0$, $\rho = 0{,}9$. Похибка моделі входить в оновлення ваг лише після того, як стає спостережуваною, тобто через k кроків після видачі прогнозу.

Результати дослідження. Для комплексного оцінювання запропонованого підходу спланована серію з взаємодоповнювальних експериментів, які перевіряють не лише точність прогнозування, а й стабільність щодо невизначеності та здатність до відновлення після концептуального зсуву.

Експеримент 1. Порівняння з базовими моделями. Запропоновану гібридну СППР порівняно із сімома моделями: ARIMA, SARIMA, Random Forest, XGBoost, LSTM, GRU та статичним ансамблем із рівномірними вагами. Кількісні результати оцінювання точності за метриками MAE, RMSE, sMAPE і R^2, об'єднані за всіма горизонтами прогнозування, наведено в табл. 2. Для MAE та RMSE подано середнє значення та стандартне відхилення за 20 вікнами оцінювання.

Таблиця 2

Порівняння точності моделей на наборі ETTh1 (протокол walk-forward, 20 вікон оцінювання)

Модель	MAE ± σ	RMSE ± σ	sMAPE, %	R^2
ARIMA	1,390 ± 0,437	2,022 ± 0,614	18,59	0,885
SARIMA	1,309 ± 0,447	1,918 ± 0,643	17,68	0,896
Random Forest	1,903 ± 0,709	2,626 ± 0,854	26,44	0,806
XGBoost	1,876 ± 0,699	2,542 ± 0,811	26,52	0,818
LSTM	1,764 ± 0,821	2,478 ± 0,978	24,79	0,827
GRU	1,441 ± 0,573	2,076 ± 0,769	21,05	0,879
Статичний ансамбль	1,402 ± 0,457	1,973 ± 0,581	21,10	0,890
Запропонована СППР	**1,329 ± 0,448**	**1,911 ± 0,604**	**19,26**	**0,897**

Для наочного порівняння ефективності досліджуваних моделей отримані значення показників якості прогнозування представлено на рис. 2.

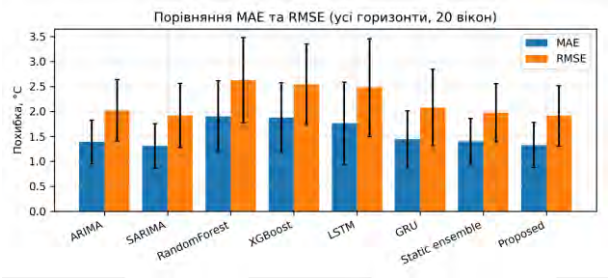


Рис. 2. Порівняння MAE та RMSE базових моделей і запропонованого підходу

Запропонована СППР забезпечила найвище значення коефіцієнта детермінації ($R^2 = 0{,}897$) та найнижче значення RMSE (1,911) серед усіх досліджуваних конфігурацій. Порівняно з окремими моделями машинного навчання зменшення MAE становить 30,1 % відносно Random Forest, 29,2 % відносно XGBoost та 24,6 % відносно LSTM. Відносно статичного ансамблю виграш становить 5,2 %. Водночас показники запропонованого підходу та моделі SARIMA практично збігаються (MAE 1,329 проти 1,309), що відображає високу інерційність цільової змінної досліджуваного набору даних, за

якої одновимірні сезонні моделі працюють близько до оптимуму.

Розподіл похибки за вікнами оцінювання та співвідношення «точність — стабільність» наведено на рис. 3.

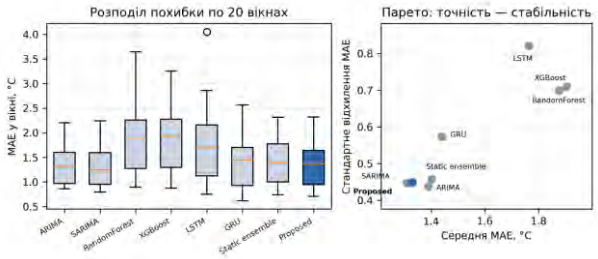


Рис. 3. Розподіл похибки за вікнами оцінювання та співвідношення «точність — стабільність»

Запропонована СППР розташована на межі Парето: вона поєднує низьке середнє значення MAE з найменшим серед ансамблевих конфігурацій стандартним відхиленням, тобто забезпечує передбачувану якість у різних режимах функціонування об’єкта.

Експеримент 2. Якість на різних горизонтах прогнозування. Результати оцінювання точності прогнозування на горизонтах $k \in \{1, 3, 6, 12, 24\}$ год наведено в табл. 3.

Таблиця 3

RMSE залежно від горизонту прогнозування

Горизонт k	ARIMA	SARIMA	LSTM	GRU	Статичний ансамбль	Запропонована СППР
1	0,803	0,769	1,474	1,060	0,916	0,835
3	1,410	1,297	1,844	1,433	1,387	1,317
6	1,956	1,762	2,220	1,842	1,850	1,782
12	2,491	2,281	2,889	2,544	2,318	2,247
24	2,790	2,797	3,443	2,916	2,811	2,756

Динаміку зміни якості прогнозування залежно від горизонту для запропонованої СППР та моделей порівняння представлено на рис. 4.

Результати свідчать про залежність відносної ефективності підходів від горизонту прогнозування. На горизонті k = 1 найкращий результат забезпечують одновимірні статистичні моделі, тоді як починаючи з k = 6 запропонована СППР демонструє найнижче значення RMSE серед усіх конфігурацій. Це узгоджується з теоретичними уявленнями: на коротких горизонтах домінує автокореляційна складова, яку адекватно описує сезонна модель, а на середніх і довгих горизонтах зростає роль екзогенних факторів та диверсифікації модельних гіпотез. Приріст похибки зі зростанням горизонту для запропонованого підходу є більш плавним, що підтверджує його придатність для середньострокового прогнозування.

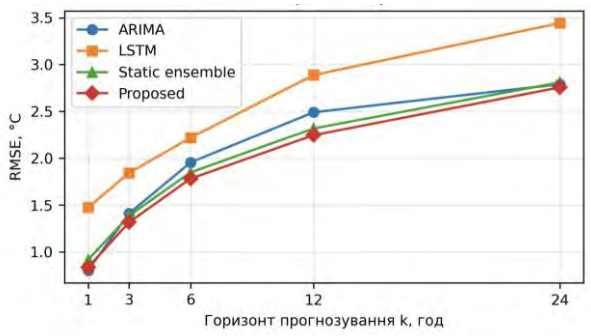


Рис. 4. Порівняння точності моделей на різних горизонтах прогнозування

Розподіл похибок запропонованої СППР за горизонтами наведено на рис. 5.

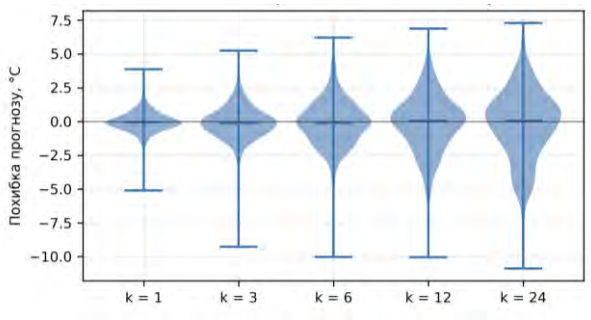


Рис. 5. Розподіл похибок запропонованої СППР за горизонтами прогнозування

Медіанне значення похибки на всіх горизонтах близьке до нуля, що свідчить про відсутність систематичного зміщення прогнозу; розширення розподілу зі зростанням k відповідає очікуваному накопиченню невизначеності.

Експеримент 3. Абляційне дослідження. Внесок кожного модуля оцінено шляхом послідовного вимкнення компонентів: без байєсівського зважування (рівномірні ваги), без пояснюваної логіки (використання усіх 41 ознаки замість відібраних за значеннями SHAP) та без адаптивного навчання (параметри всіх моделей зафіксовано на першому вікні оцінювання). Результати наведено в табл.4.

Найбільшу деградацію спричиняє вимкнення адаптивного навчання: MAE зростає з 1,329 до 2,424, тобто на 82,4 %, а RMSE — з 1,911 до 3,102. Це підтверджує ключову роль замкненого контуру перенавчання за умов нестаціонарності. Вимкнення байєсівського зважування погіршує точність незначно (+0,073 за MAE), проте призводить до суттєвого погіршення калібрування: ймовірність покриття прогнозних інтервалів PICP знижується з 0,952 до 0,886 за номінального рівня 0,95. Отже, роль цього модуля полягає передусім у формуванні коректних оцінок невизначеності, а не в підвищенні точності точкового прогнозу (рис. 6).

Таблиця 4

Абляційне дослідження

Конфігурація	MAE ± σ	RMSE	PICP	Δ MAE до Full
Full (повна модель)	**1,329 ± 0,448**	**1,911**	**0,952**	—
− Bayesian	1,402 ± 0,457	1,973	0,886	+0,073
− XAI	1,320 ± 0,443	1,892	0,951	−0,009
− Adaptive	2,424 ± 0,959	3,102	0,910	+1,095

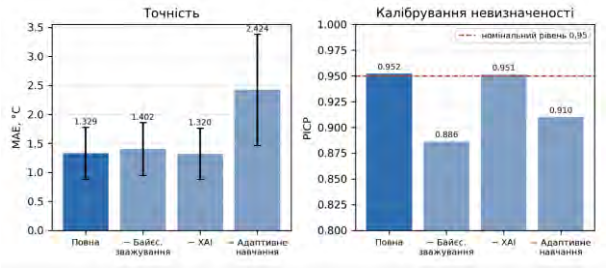


Рис. 6. Вплив вимкнення окремих модулів на точність і калібрування

Вимкнення модуля пояснюваності практично не впливає на точність (−0,009 за MAE, що перебуває в межах статистичної похибки), однак позбавляє систему механізму обґрунтування рішень, критично важливого для застосування в критичній інфраструктурі.

Експеримент 4. Робота в умовах концептуального зсуву. Адаптивність підходу перевірено шляхом порівняння динаміки похибки трьох конфігурацій упродовж усього періоду оцінювання. Точку максимального зсуву розподілу цільової змінної визначено за статистикою Колмогорова — Смирнова, обчисленою між сусідніми вікнами оцінювання. Результати наведено на рис. 7.

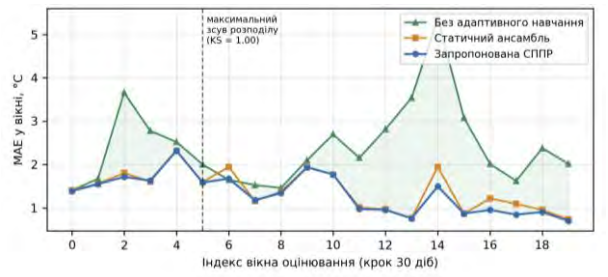


Рис. 7. Динаміка MAE у вікнах оцінювання за наявності та відсутності адаптивного навчання

Конфігурація без адаптивного навчання демонструє прогресивне накопичення похибки: якщо на початку періоду її показники збігаються з повною конфігурацією, то у 14-му вікні MAE досягає 5,2, тоді як запропонована СППР зберігає рівень близько 1,5. Розбіжність між кривими зростає в міру віддалення від моменту останнього навчання, що відповідає теоретичним уявленням про накопичення концептуального зсуву. Запропонований підхід зберігає стабільну якість завдяки перерозподілу ваг модельних гіпотез і періодичному перенавчанню базових моделей.

Експеримент 5. Калібрування невизначеності. Перевірено, чи відповідає індекс довіри C(t) фактичній похибці прогнозу. Залежність абсолютної похибки від індексу довіри наведено на рис. 8.

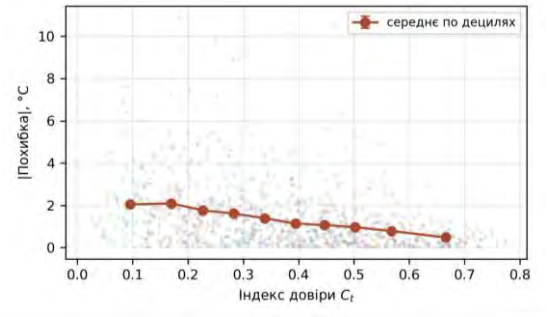


Рис. 8. Залежність абсолютної похибки від індексу довіри

Спостерігається виражена від'ємна залежність: коефіцієнт рангової кореляції Спірмена становить ρ = −0,393 (p < 0,001). Середня абсолютна похибка в нижньому децилі індексу довіри дорівнює 2,05, тоді як у верхньому — 0,48, тобто відрізняється більш ніж учетверо. Це підтверджує, що система здатна розпізнавати ситуації підвищеної невизначеності та відповідно знижувати рівень довіри до власного прогнозу.

Ймовірність покриття прогнозних інтервалів становить PICP = 0,952 за номінального рівня 0,95 і середньої ширини інтервалу MPIW = 7,98. Додатково побудовано діаграму надійності для рівнів довіри від 0,50 до 0,99 (рис. 9).

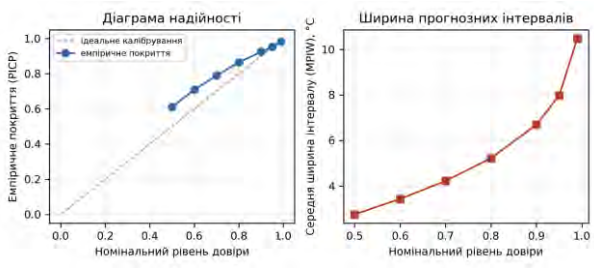


Рис. 9. Діаграма надійності та ширина прогнозних інтервалів

Емпіричне покриття становить 0,611; 0,708; 0,790; 0,864; 0,924; 0,952 та 0,982 для номінальних рівнів 0,50; 0,60; 0,70; 0,80; 0,90; 0,95 та 0,99 відповідно. На низьких рівнях довіри інтервали є дещо консервативними, тоді як у практично значущому діапазоні 0,90–0,99 відхилення від номінального рівня не перевищує 0,024. Це свідчить

про коректність запропонованої моделі невизначеності саме в тій області, яка використовується для формування рішень.

Експеримент 6. Аналіз інтерпретованості. Для оцінювання інтерпретованості обчислено внески ознак методом SHAP для компонента градієнтного бустингу на горизонті k = 1, усереднені за 20 вікнами оцінювання (рис. 10).

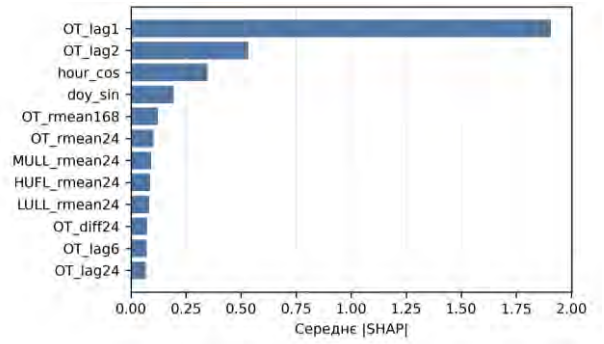


Рис. 10. Внесок ознак у прогноз (середні значення |SHAP|)

Провідними ознаками виявилися перше лагове значення цільової змінної (середнє |SHAP| = 1,907), друге лагове значення (0,533), добова гармоніка hour_cos (0,348) та річна гармоніка doy_sin (0,194). Далі йдуть ковзні середні цільової змінної за тижневим і добовим вікнами (0,123 та 0,103) і ковзні середні операційних коваріат MULL, HUFL та LULL (0,092; 0,087 та 0,084 відповідно). Отже, прогнозована величина визначається насамперед поточним станом об’єкта та регулярними добовими й сезонними закономірностями, що узгоджується з доменними уявленнями про динаміку об’єктів критичної інфраструктури. Операційні коваріати мають другорядний, проте стабільно ненульовий вплив.

Стабільність рейтингів важливості ознак у часі оцінено коефіцієнтом рангової кореляції Кендалла між послідовними вікнами оцінювання: середнє значення становить $\tau = 0{,}345$, причому склад першої трійки ознак залишається незмінним у всіх вікнах. Це свідчить про надійність пояснень на рівні провідних факторів за помірної варіативності рангів ознак другого порядку.

Динаміку ваг модельних гіпотез, сформованих модулем байєсівської агрегації, наведено на рис. 11.

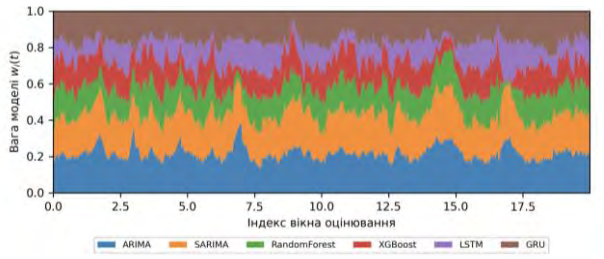


Рис. 11. Динаміка байєсівських ваг модельних гіпотез (k = 1)

Ваги змінюються неперервно відповідно до поточної якості кожної моделі, причому в періоди підвищеної нестаціонарності зростає внесок статистичних моделей, а в стабільних режимах — рекурентних мереж. Це підтверджує, що механізм зважування не вироджується в статичну комбінацію.

Експеримент 7. Статистична перевірка значущості. Значущість відмінностей перевірено попарним критерієм Вілкоксона для знакових рангів та критерієм Фрідмана для множини моделей. Одиницею спостереження є значення MAE в окремому вікні оцінювання (n = 20). Як міру розміру ефекту для критерію Вілкоксона використано ранг-бісеріальну кореляцію, для критерію Фрідмана — коефіцієнт конкордації Кендалла W. Результати наведено в табл. 5.

Таблиця 5

Результати статистичної перевірки (n = 20 вікон оцінювання)

Порівняння	Критерій	Статистика	p-значення	Розмір ефекту
Запропонована vs ARIMA	Вілкоксона	W = 72,0	0,231	r = 0,40
Запропонована vs SARIMA	Вілкоксона	W = 94,0	0,701	r = 0,20
Запропонована vs LSTM	Вілкоксона	W = 12,0	< 0,001	r = 0,80
Запропонована vs GRU	Вілкоксона	W = 64,0	0,133	r = 0,20
Запропонована vs статичний ансамбль	Вілкоксона	W = 35,0	0,007	r = 0,40
Усі вісім моделей	Фрідмана	$\chi^2(7) = 63{,}62$	< 0,001	W = 0,454

Критерій Фрідмана підтверджує наявність статистично значущих відмінностей між досліджуваними моделями ($\chi^2(7) = 63{,}62$; $p < 0{,}001$) за помірного розміру ефекту ($W = 0{,}454$). Попарне порівняння показує статистично значущу перевагу запропонованого підходу над моделлю LSTM ($p < 0{,}001$) та над статичним ансамблем ($p = 0{,}007$). Натомість відмінності від моделей ARIMA, SARIMA та GRU не є статистично значущими на рівні $\alpha = 0{,}05$ ($p = 0{,}231$; 0,701 та 0,133 відповідно). Запропонована СППР переважає SARIMA у 12 вікнах оцінювання з 20 та ARIMA — у 14 з 20.

Експеримент 8. Аналіз часу роботи. Для оцінювання придатності до застосування в реальному часі виміряно середній час навчання моделі на одному вікні та середній час формування одного прогнозу (табл. 6).

Сумарний час навчання ансамблю становить 22,13 с на одне вікно, що є прийнятним для періодичного перенавчання з добовою або тижневою періодичністю. Час формування прогнозу становить 0,114 с, причому понад 90 % цього часу припадає на рекурсивне оновлення стану сезонної моделі SARIMA. Обчислювальні витрати самого модуля

байєсівської агрегації не перевищують $2{,}5 \cdot 10^{-5}$ с, тобто є практично нехтовними. Отриманий час прогнозування задовольняє вимоги оперативної підтримки прийняття рішень.

Таблиця 6

Час навчання та прогнозування

Модель	Навчання, с	Прогноз, с
ARIMA	0,49	0,0113
SARIMA	4,40	0,1023
Random Forest	1,43	0,0002
XGBoost	0,41	0,00003
LSTM	3,87	0,00003
GRU	11,54	0,00005
Статичний ансамбль	22,13	0,1139
Запропонована СППР	**22,13**	**0,1139**

Аналіз чутливості до параметра λ. Оскільки параметр λ керує чутливістю байєсівського зважування до змін якості моделей, досліджено його вплив на MAE (рис. 12).

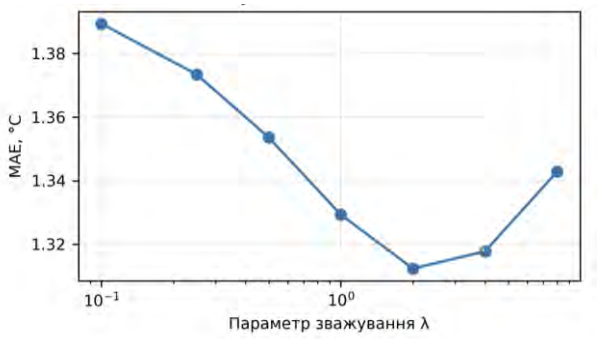


Рис. 12. Чутливість MAE до параметра зважування λ

Значенням λ = 0,1; 0,25; 0,5; 1,0; 2,0; 4,0 та 8,0 відповідають значення MAE 1,389; 1,373; 1,354; 1,329; 1,312; 1,318 та 1,343. Мінімум досягається в околі λ = 2, причому в діапазоні λ ∈ [1; 4] похибка змінюється не більше ніж на 1,3 %, що свідчить про низьку чутливість підходу до вибору цього параметра. Занадто малі значення λ послаблюють адаптацію та наближають схему до рівномірного усереднення, а завеликі — спричиняють нестабільне перемикання між моделями та зростання дисперсії прогнозу.

Абляційний і статистичний аналіз разом підтверджують, що спостережувані властивості системи забезпечуються взаємодією модулів прогнозування, байєсівської агрегації, пояснюваності та адаптивного навчання, причому провідну роль у підтриманні точності відіграє адаптивне навчання, а в підтриманні коректності оцінок невизначеності — байєсівська агрегація.

Обговорення отриманих результатів. Отримані результати підтверджують, що підтримка прийняття рішень у критичній інфраструктурі не може зводитися лише до максимізації точності прогнозування. Запропонована СППР забезпечила MAE = 1,329, RMSE = 1,911, sMAPE = 19,26 % та R^2 = 0,897, що відповідає зменшенню MAE на 30,1 % порівняно з Random Forest на 24,6 % порівняно з LSTM та на 5,2 % порівняно зі статичним ансамблем.

Відносна ефективність підходів залежить від горизонту прогнозування. На горизонті k = 1 найкращий результат забезпечує SARIMA (RMSE = 0,769 проти 0,835), тоді як починаючи з k = 6 запропонована СППР демонструє найнижче значення RMSE серед усіх конфігурацій (1,782 проти 1,762 у SARIMA на k = 6 та 2,247 проти 2,281 на k = 12). Це підтверджує вищу стійкість запропонованого підходу до накопичення похибки під час середньострокового прогнозування, коли зростає роль екзогенних факторів.

Абляційне дослідження виявило чіткий розподіл функцій між модулями. Найбільший внесок у підтримання точності забезпечує модуль адаптивного навчання: його вимкнення збільшує MAE з 1,329 до 2,424, тобто на 82,4 %. Модуль байєсівського зважування практично не впливає на точність точкового прогнозу (+0,073 за MAE), проте є критично важливим для калібрування невизначеності: без нього PICP знижується з 0,952 до 0,886 за номінального рівня 0,95.

Висновки. Запропоновано інтегровану СППР з урахуванням невизначеності для об'єктів критичної інфраструктури. Поєднання гібридного прогнозування, байєсівсько-зваженої агрегації, оцінювання невизначеності, пояснюваної логіки рішень і замкненого адаптивного навчання забезпечує перехід від ізольованого прогнозування до надійного та прозорого підтримання рішень.

Обчислювальні експерименти на відкритому наборі даних ETTh1 (17 420 годинних спостережень, протокол ковзного початку, 20 вікон оцінювання) показали, що запропонований підхід забезпечує MAE = 1,329 ± 0,448 та R^2 = 0,897, зменшуючи похибку на 24,6–30,1 % порівняно з окремими моделями машинного навчання та на 5,2 % порівняно зі статичним ансамблем. Статистична значущість переваги підтверджена для моделі LSTM ($p < 0{,}001$) та статичного ансамблю ($p = 0{,}007$); порівняно з одновимірними сезонними моделями точність є зіставною.

Ключовими результатами дослідження є два висновки. По-перше, модуль адаптивного навчання є визначальним для підтримання якості прогнозу в часі: його вимкнення призводить до зростання MAE на 82,4 %, причому розбіжність накопичується прогресивно в міру віддалення від моменту останнього навчання. По-друге, модуль байєсівської агрегації забезпечує коректне калібрування невизначеності (PICP = 0,952 за номінального рівня 0,95; відхилення емпіричного покриття від

номінального в діапазоні 0,90–0,99 не перевищує 0,024), тоді як без нього це значення знижується до 0,886. Індекс довіри значуще корелює з фактичною похибкою ($\rho = -0{,}393$), що дає змогу використовувати його для ескалації рішень до експерта.

Література

1. Hyndman R. J., Athanasopoulos G. Forecasting: Principles and Practice. 3rd ed. Melbourne : OTexts, 2021. 442 p. URL: https://otexts.com/fpp3/
2. Tao Hong, Pierre Pinson, Shu Fan, Global Energy Forecasting Competition 2012, International Journal of Forecasting, Volume 30, Issue 2, 2014, 357-363, https://doi.org/10.1016/j.ijforecast.2013.07.001
3. Box G. E. P., Jenkins G. M., Reinsel G. C. Time Series Analysis: Forecasting and Control. 4th ed. Hoboken : John Wiley & Sons, 2008. 784 p. https://doi.org/10.1002/9781118619193
4. Hochreiter S., Schmidhuber J. Long short-term memory // Neural Computation. 1997. Vol. 9, No. 8. P. 1735–1780. DOI: https://doi.org/10.1162/neco.1997.9.8.1735
5. Cho K., van Merrienboer B., Gulcehre C. et al. Learning phrase representations using RNN encoder–decoder for statistical machine translation // Proc. EMNLP. 2014. P. 1724–1734. DOI: https://doi.org/10.3115/v1/D14-1179
6. Gal Y., Ghahramani Z. Dropout as a Bayesian approximation: representing model uncertainty in deep learning // Proc. ICML. 2016. P. 1050–1059. DOI: https://doi.org/10.48550/arXiv.1506.02142
7. Zhou Z.-H. Ensemble Methods: Foundations and Algorithms. Boca Raton : CRC Press, 2012. 236 p. DOI: https://doi.org/10.1201/b12207
8. Hoeting J. A., Madigan D., Raftery A. E., Volinsky C. T. Bayesian model averaging: a tutorial // Statistical Science. 1999. Vol. 14, No. 4. P. 382–401. DOI: https://doi.org/10.1214/ss/1009212519
9. Raftery A. E., Madigan D., Hoeting J. A. Bayesian model averaging for linear regression models // Journal of the American Statistical Association. 1997. Vol. 92, No. 437. P. 179–191. DOI: https://doi.org/10.1080/01621459.1997.10473615
10. Lundberg S. M., Lee S.-I. A unified approach to interpreting model predictions // Advances in Neural Information Processing Systems. 2017. Vol. 30. P. 4765–4774. DOI: https://doi.org/10.48550/arXiv.1705.07874
11. Ribeiro M. T., Singh S., Guestrin C. "Why should I trust you?" Explaining the predictions of any classifier // Proc. 22nd ACM SIGKDD. 2016. P. 1135–1144. DOI: https://doi.org/10.1145/2939672.2939778
12. Barredo Arrieta A., Diaz-Rodriguez N., Del Ser J. et al. Explainable artificial intelligence (XAI): concepts, taxonomies, opportunities and challenges toward responsible AI // Information Fusion. 2020. Vol. 58. P. 82–115. DOI: https://doi.org/10.1016/j.inffus.2019.12.012
13. Gama J., Zliobaite I., Bifet A., Pechenizkiy M., Bouchachia A. A survey on concept drift adaptation // ACM Computing Surveys. 2014. Vol. 46, No. 4. Article 44. DOI: https://doi.org/10.1145/2523813
14. Mosqueira-Rey, E., Hernández-Pereira, E., Alonso-Ríos, D. et al. Human-in-the-loop machine learning: a state of the art. Artif Intell Rev 56, 3005–3054 (2023). https://doi.org/10.1007/s10462-022-10246-w

Huskova V. H., Shkolnikov V. I. Integrated decision support system for cyber incident cost prediction in critical infrastructure.

Critical infrastructure systems operate under conditions of high dynamics, non-stationarity, and uncertainty, which imposes stringent requirements on modern decision support systems. Timely and reliable forecasting of the condition of such facilities is an essential prerequisite for improving their reliability and operational safety. Existing forecasting methods provide high predictive accuracy; however, they insufficiently account for prediction uncertainty, offer limited interpretability of results, and exhibit inadequate adaptability to changing operating conditions, while forecasting, uncertainty estimation, and explainability are mostly implemented in isolation from one another. The aim of this study is to improve the reliability, adaptability, and interpretability of decision support by developing an integrated system for forecasting the condition of critical infrastructure facilities.

A modular system architecture is proposed that integrates data acquisition and preprocessing, feature engineering, ensemble forecasting, uncertainty estimation, explainability, and decision support modules. The hybrid ensemble combines statistical models, machine learning regressors, and recurrent neural networks with dynamic Bayesian weighting of their forecasts. The scientific novelty lies in the integration of hybrid forecasting, dynamic Bayesian model aggregation, prediction uncertainty estimation, and adaptive learning with a closed-loop feedback mechanism within a unified decision support information technology.

The experimental evaluation was carried out on the open ETTh1 dataset (17,420 observations, 41 features) using a walk-forward protocol (20 evaluation windows, forecast horizons of 1–24 hours). The proposed system achieved MAE = 1.329 ± 0.448, RMSE = 1.911 and R^2 = 0.897, which corresponds to an error reduction of 24.6–30.1 % compared with individual machine learning models. The ablation study showed that the adaptive learning module accounts for an 82.4 % reduction in MAE, while the Bayesian aggregation module ensures correct calibration of prediction intervals (PICP = 0.952 at a nominal level of 0.95). The confidence index correlates significantly with the actual forecast error, which allows it to be used as a criterion for escalating decisions to a human expert. The statistical significance of the differences was confirmed by the Wilcoxon and Friedman tests.

Keywords: *decision support system; critical infrastructure; time series forecasting; ensemble forecasting; Bayesian aggregation; uncertainty estimation.*

Гуськова Віра Геннадіївна – доктор філософії (PhD), доцент, доцент кафедри штучного інтелекту, Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», м. Київ, Україна.
https://orcid.org/0000-0001-7637-201X
email: guskovavera2009@gmail.com

Школьников Владислав Ігорович – доктор філософії (PhD), доцент, доцент кафедри кримінології та інформаційних технологій, Національна академія внутрішніх справ, м. Київ, Україна.
https://orcid.org/0000-0003-2041-9450
email: shkolnikov.v.i@navs.edu.ua

Дата першого надходження статті 29.07.2026.
Дата прийняття статті до друку після рецензування 26.08.2026.
Дата публікації 30.09.2026.

Стаття з відкритим доступом, відповідно до умов ліцензії **Creative Commons (CC BY 4.0)**